Trabajo final de carrera Ingeniería Geodésica y Cartográfica

Detección y localización de árboles en áreas forestales empleando datos LIDAR e imágenes de alta resolución

Autor: **José Luis Gil Yepes**

Tutores: **Luis Ángel Ruiz Fernández**
Alfonso Fernández Sarría

UNIVERSIDAD POLITÉCNICA DE VALENCIA

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA
GEODÉSICA, CARTOGRÁFICA Y TOPOGRÁFICA

A mis padres,
a mi hermano Alberto y
a Elena.

AGRADECIMIENTOS

Quiero agradecer en primer lugar a mis tutores Alfonso y Luis por las facilidades que me han ofrecido en cuanto a la disposición de los medios necesarios para la realización de este trabajo.

También quiero agradecer a mis compañeros Jaime y Gerson del seminario de teledetección toda la ayuda, atención y amabilidad que me han mostrado durante este tiempo a la vez que lo han amenizado con su compañía. Me gustaría hacer una mención especial a Txomin y agradecerle toda la paciencia que ha tenido conmigo durante mi estancia en el seminario. Agradezco también a Luci y a Gonzalo el apoyo prestado durante estos meses de trabajo.

Deseamos agradecer al Ministerio de Industria, Comercio y Turismo dentro del Plan Nacional de Investigación Científica, Desarrollo e Innovación Tecnológica 2008-2011 y al Fondo Europeo de Desarrollo Regional (FEDER) por los datos que han puesto a la disposición de este trabajo.

Agradezco a mis padres y a mi hermano la ayuda y apoyo que me han dado permitiéndome acabar así los estudios. Muchas gracias.

En último lugar quiero darle las gracias a Elena por la paciencia que ha tenido conmigo ya que durante estos últimos meses me he pasado más tiempo centrado en el trabajo que en ella.

RESUMEN

El presente trabajo plantea un procedimiento metodológico con el que trabajar para poder detectar la unidad de árbol automáticamente sobre zonas forestales. Esta detección se realizó a partir de una combinación de datos multiespectrales y fotogramétricos así como datos LIDAR para la obtención de variables que permitieron la detección de dicha unidad de árbol. Para esta metodología se emplearon algoritmos especializados para la detección de árboles (*watershed* y *máximos locales*) así como metodologías clásicas en el campo de la teledetección actual. El procedimiento metodológico se puede dividir en dos partes básicas: (i) la segmentación inicial basada en el algoritmo watershed y (ii) una segunda segmentación basada en el algoritmo de máximos locales. La primera segmentación sirve para una primera aproximación de los árboles, mientas que la segunda trabaja sobre la primera para la correcta localización de los árboles y la detección del contorno de sus copas. Los resultados obtenidos presentaban problemas en ciertas zonas donde se encontraban grandes densidades de masas forestales detectando un número menor de árboles con respecto a la realidad. En general, los resultados obtenidos fueron satisfactorios consiguiendo un conteo y una clasificación aceptables.

ÍNDICE

Capítulo I - INTRODUCCIÓN

1.1. Introducción 1

1.2. Objetivos 3

Capítulo II - DATOS UTILIZADOS PARA EL TRABAJO

2.1. Zona de estudio 5

2.2. Datos de partida 7

Capítulo III - METODOLOGÍA

3.1. Introducción 11

3.2. Software empleado 13

3.3. Preprocesado de los datos 15

3.3.1. Preprocesado de las imágenes 15

3.3.2. Preprocesado de datos LIDAR (cálculo de modelos digitales) 16

3.3.2.1. Comparación y evaluación de los métodos 22

3.3.2.1.1. Diferencia entre modelos LIDEX y FUSION 23

3.3.2.1.2. Estudio de orientaciones de modelos LIDEX y FUSION 25

3.3.2.1.3. Comparación punto-imagen con MDT del PNOA 27

3.3.2.1.4. Comparación imagen-imagen con MDT del PNOA 30

3.3.2.1.5. Estudio de orientaciones del modelo del PNOA 35

3.4. Segmentación inicial 37

3.5. Clasificación por píxel 44

3.5.1. Clasificación BGR-IR-NDVI-CHM PNOA 45

3.5.2. Clasificación BGR-IR-NDVI-CHM IKONOS 48

3.5.3. Clasificación GR-NDVI-CHM PNOA 51

3.7. Post-segmentación 58

3.8. Evaluación 62

Capítulo IV - RESULTADOS

4.1. Introducción a los resultados 65
4.2. Resultados de la clasificación por píxel 66
4.4.1. Conteo por el método de la primera segmentación 71
4.4.2. Conteo por el método de la post-segmentación 76
4.5. Resultados de la localización 80
4.5.1. Localización por el método de la primera segmentación 80
4.5.2. Localización por el método de post-segmentación 85
4.6. Resultados de copas de la post-segmentación 88
4.7. Discusión de resultados. 89

Capítulo V - CONCLUSIONES

5.1. Conclusiones 91

REFERENCIAS 95

Anejo I – SITUACIÓN Y NUMERACIÓN DE PARCELAS 99

Anejo II – PARCELAS DE EVALUACIÓN 101

Anejo III - RESULTADO DE LAS "DIANAS" DEL MÉTODO DE LA PRIMERA SEGMENTACIÓN 103

Anejo IV – RESULTADOS DE LAS "DIANAS" DEL MÉTODO DE LA POST-SEGMENTACIÓN.....119

Capítulo I
INTRODUCCIÓN

1.1. Introducción

La gestión de zonas forestales es una necesidad actual para trabajos tanto científicos como medioambientales y políticos. La tecnología LIDAR en los últimos años ha captado la atención para las utilidades de esta gestión de zonas forestales (Hudak et al., 2009), proveyendo de medidas tridimensionales de alta precisión (x, y, z, intensidad) (Yu et al., 2010) basándose en medidas láser conjuntamente con sistemas de posicionamiento.

El LIDAR (Light Detection And Ranging) es un sistema basado en una combinación de tres sistemas de toma de datos diferentes: un láser escáner montado sobre un avión, un sistema de posicionamiento global (GPS) y un sistema inercial de navegación (INS) (Baltsavias, 1999). Esta tecnología está ganando terreno a los métodos fotogramétricos para el cálculo de modelos digitales de terreno y de superficie. Este láser montado sobre el avión emite una señal sobre la superficie terreno siendo ésta reflejada de vuelta y captada por un sensor, que junto con el GPS e INS, permiten el cálculo de sus coordenadas. Con unas condiciones normales, dependiendo de variables como la velocidad de vuelo, altura, etc., se pueden registrar coordenadas con precisiones de hasta 5 cm. El láser emite pulsos láser hacia el terreno con gran frecuencia (aproximadamente de 2000 a 50000 pulsos por segundo) y son reflejadas de vuelta al instrumento. Con el tiempo en el que cada pulso tarda en alcanzar el terreno y volver y con el ángulo del nadir con el que este fue emitido, se determina la posición relativa del punto reflectado del terreno (con un tamaño desde 60 cm hasta 3 m dependiendo de la altura de vuelo) con respecto al punto donde se sitúa el emisor del láser escáner. Al tratarse de un escáner de barrido láser, permite un gran acercamiento a la realidad de lo objetos a representar. Este sistema a su vez, tiene la ventaja de reducir el tiempo de generación de la ortofotografía.

Con estos datos LIDAR son muchas las variables que se pueden obtener de las zonas forestales, que sin embargo, otros trabajos de campo no pueden obtener para caracterizar la estructura forestal. Esta estructura viene definida por medidas relacionadas con la cobertura vegetal y la altura, siendo éstas las variables más comunes, y otras como son las relaciones entre altura, copa y diámetro, sin contar con los modelos digitales de terreno y de vegetación, fácilmente calculables con las nubes de puntos LIDAR. Estas variables permiten un mejor conocimiento y control de las zonas forestales, pero bajo circunstancias especiales y para cuestiones concretas, las unidades de árbol son las únicas variables sobre las que se puede trabajar (Heinzel et al., 2008) que junto con información multiespectral, se puede llegar a conocer incluso su especie y proporcionar información sobre los parámetros forestales. Básicamente, el estudio de estas variables dendrométricas es necesario para el inventariado y catalogación de bosques debido a que permiten un conocimiento en profundidad de su estructura interna, su biomasa, su biodiversidad, permiten la estimación del crecimiento o la detección de cambios en los ecosistemas, etc. Trabajos realizados utilizando métodos multiespectrales con procedimientos LIDAR muestran resultados esperanzadores para la segmentación de zonas forestales mostrando valores elevados de precisión en cuanto a la detección de árboles (Suárez et al., 2005).

La segmentación de árboles se puede abordar desde diferentes puntos de vista tratando con diferentes algoritmos. Los dos algoritmos más utilizados son los algoritmos *Watershed* y *LocalMaxima*. El algoritmo de máximos locales se utiliza generalmente para la detección y posicionamiento de los árboles, mientras que el algoritmo watershed se utiliza una vez detectados los árboles para poder delimitar la superficie de las copas (Yu et al., 2010; Hirata et al., 2009; Wulder et al., 2000; Pouliot et al., 2002; Leckie et al., 2005). A pesar de que la metodología más extendida de trabajo sea la utilización del método de detección-delineación, hay software específico dedicado a la detección basados únicamente en un algoritmo principal *watershed* (Castilla y Hay, 2007) o también en máximos locales (Popescu, 2007). Estos estudios de segmentación no solo utilizan la información multiespectral o LIDAR por separado, sino que hay metodologías capaces de combinar las variables necesarias para realizar la segmentación (Suarez et al., 2005; Viñas et al., 2009).

Las aplicaciones de LIDAR e imágenes multiespectrales no solo se quedan en el inventariado de los bosques o segmentación de árboles sino que van más allá alcanzando aplicaciones como clasificación, detección de edificios, aplicaciones agrícolas, estudios sobre incendios, etc., con los que se pueden crear modelos de predicción conocidos como 'fire models' o 'fuel models' sobre el comportamiento que puede tener el fuego sobre las zona forestales, (Scott y Burgan, 2005). Entre otras aplicaciones se pueden encontrar estudios ecológicos sobre la fauna de la zona e incluso geología e hidrología superficial (Hudak et al., 2009). De la misma forma se encuentran infinidad de trabajos en los que una combinación de información LIDAR con la información multiespectral solucionan situaciones que, utilizando otras metodologías y técnicas, sería casi imposible de abordar. El presente trabajo intenta aportar una solución práctica a un problema real a partir de la combinación de dicha información.

1.2. Objetivos

El objetivo principal del trabajo es el desarrollo de una metodología que automatice la detección de árboles sobre zonas forestales utilizando información multiespectral y datos LIDAR. A lo largo del desarrollo de dicha metodología, se han realizado otros estudios que se pueden considerar como objetivos secundarios pero necesarios para el desarrollo de la metodología. Entre estos están la comparación y evaluación de varios algoritmos para la creación de los modelos digitales, la comparación de metodologías para la detección de árboles, la evaluación de la metodología comparando los resultados con datos veraces en cuanto a detección del número de árboles y la evaluación de la metodología en cuanto al posicionamiento de los árboles.

Para la comparación de los modelos digitales se desea comparar varios algoritmos de interpolación para evaluar cuál de ellos proporciona mejores resultados mediante varios estudios de diferencias, orientaciones y comparaciones de los resultados con modelos oficiales.

Para la detección de árboles se desea estudiar una metodología basada en dos algoritmos, uno de segmentación y otro de detección. Estos serán implementados de forma independiente para poder comprobar los resultados con los datos de campo de los que se dispone para este trabajo.

Una vez obtenidos los resultados, se realizará una evaluación con respecto a la localización de cada árbol detectado por la metodología anterior.

Con el método desarrollado para la detección y localización de los árboles, se pretende avanzar en el desarrollo de las técnicas de localización para el cálculo de las características dendrométricas necesarias para cualquier inventariado o estudio de las áreas forestales. Las variables por unidad de árbol podrán proporcionar información tal como existencias, crecimiento, biomasa y estructura entre otros, que junto con información multiespectral, se podrá detectar incluso la especie y realizar inventariados con alto nivel de detalle sin la necesidad de ir a campo.

Capítulo II
DATOS UTILIZADOS PARA EL TRABAJO

2.1. Zona de estudio

La zona de estudio para la realización del trabajo es una zona de montaña con grandes zonas forestales situada en la provincia de Cuenca. La zona está delimitada por un rectángulo de coordenadas UTM esquina superior izquierda (591600,4463800) y esquina inferior derecha (604300,4449500) de huso 30 norte y datum ED50.

Figura 2.1. Imagen de situación de la zona de estudio y detalle.

En esta zona se extienden grandes masas forestales con diferentes densidades de vegetación. También se encuentran zonas de matorrales y zonas de suelo desnudo. En estas hay diversas especies de árboles siendo el árbol predominante el pino, del cual se pueden diferencias tres especies básica: *"Pinus Sylvestris"*, *"Pinus Nigra"* y *"Pinus Pinaster"*. La altura media de dicha vegetación forestal está en torno a los 10 metros encontrando árboles de 2 metros como altura mínima hasta una altura máxima de casi 22 metros. Hay ciertas áreas de

trabajo complicadas dentro de la zona de estudio debido a que se encuentran grandes desniveles como son paredes verticales, problemáticas a la hora de calcular un modelo digital del terreno y por tanto, introduciendo ciertas anomalías en los modelos de vegetación necesarios para el cálculo de la segmentación. No hay que olvidar que por la zona pasa el Arroyo Valduerguinas pudiendo también introducir errores en los cálculos de los modelos.

2.2. Datos de partida

Los datos de partida para el trabajo son datos LIDAR, imágenes multiespectrales IKONOS, datos adquiridos del PNOA (Plan Nacional de Ortofotografía Aérea) y datos tomados en campo con el inventariado de zonas forestales para la evaluación de la metodología desarrollada en el trabajo.

Los datos LIDAR de la zona fueron los mismos utilizados en los trabajos enmarcados dentro del proyecto TSI-020100-2009-815, *Desarrollo de técnicas y métodos para la gestión forestal sostenible a partir de datos de observación de la Tierra* (INFOREST-II). Programa cofinanciado por el Ministerio de Industria, Turismo y Comercio, dentro del Plan Nacional de Investigación Científica, Desarrollo e Innovación Tecnológica 2008-2011 y por el Fondo Europeo de Desarrollo Regional (FEDER).

Los datos LIDAR tienen las siguientes características:

Características LIDAR	
Superficie	4100 ha
Fecha de adquisición	Noviembre de 2008
Densidad nominal	4.05 ptos/m^2
Recubrimiento	50%
Pasadas	53
Alturas	1500 m
Ficheros	106 (*.las)
Ángulo Fov	21º

Tabla 2.1. Características de los datos LIDAR.
(INFOREST -II)

El sistema de referencia de los datos LIDAR es UTM huso 30 con datum ED50 y a pesar de que su densidad de puntos sea de 4.05 ptos/m^2 el recubrimiento entre pasada y pasada es del 50%, lo hace que la densidad de puntos real sea de 8 ptos/m^2. A continuación se muestra un esquema de las zonas LIDAR de las que se disponen así como un croquis de las zonas con sus diferentes densidades (Figuras 2.2 y 2.3).

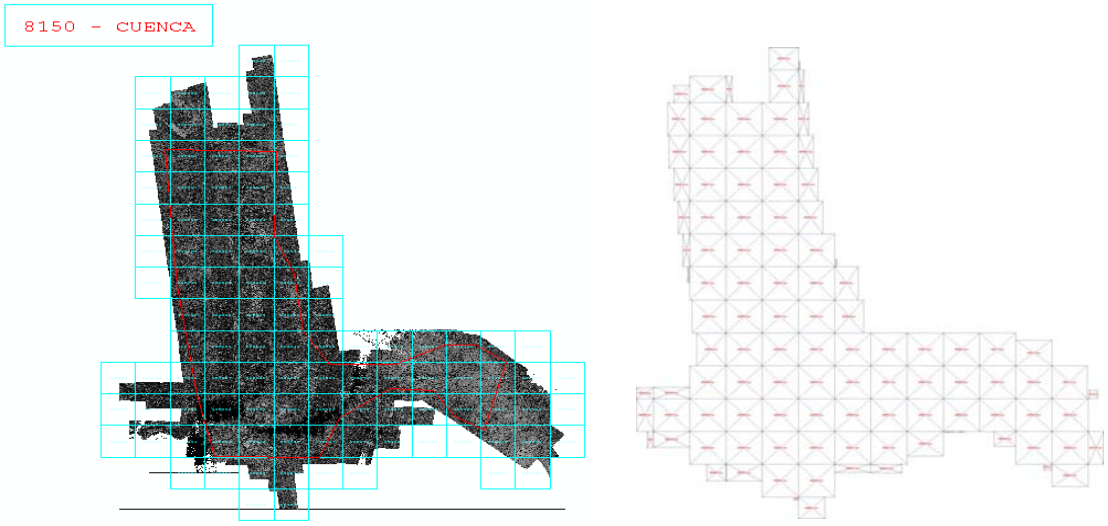

Figura 2.2. Detalle de zonas de datos LIDAR (INFOREST-II).

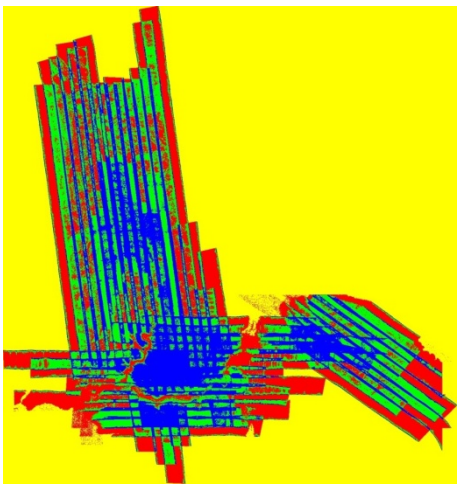

Color	*Descripción*	*Área (%)*
	Zona sin cobertura de puntos (Fuera del área de trabajo)	NA
	Densidad inferior a 5 ptos/m^2	33.4
	Densidad entre 5 y 10 ptos/m^2	33.8
	Densidad superior a 10 ptos/m^2	32.7

Figura 2.3. Detalle de la densidad de puntos LIDAR con levenda. (INFOREST-II).

Las imágenes de la zona de estudio de las que se dispone provienen de dos fuentes diferentes como son las imágenes del satélite IKONOS y las imágenes del PNOA. En ambos casos son imágenes multiespectrales.

Las imágenes IKONOS de las que se dispone son las siguientes:

- Imagen IKONOS fusionada RGB e IR con resolución espacial de 1 metro.
- Imagen IKONOS multiespectral RGB e IR con resolución espacial de 4 metros.

Las imágenes del PNOA de las que se dispone son las siguientes:

- Imagen ortorectificada RGB con resolución espacial de 0.5 metros.
- Imagen ortorectificada IR RG con resolución espacial de 0.5 metros.

Estas imágenes del PNOA fueron obtenidas a partir de la IDEE de Castilla la Mancha así como los modelos digitales del terreno con un tamaño de píxel de 5 metros. (http://ide.jccm.es/).

También se dispone de información de campo tomada en varias campañas por el grupo de la ETSI Montes de la UPM (Universidad Politécnica de Madrid) dentro del marco del mismo proyecto antes mencionado para un control e inventariado de 150 parcelas (Anejo I). Estas parcelas tienen dimensiones circulares de 25 metros de radio tomadas con GPS de las que se dispone de sus coordenadas centrales así como el número y posición de los árboles situados dentro de sus límites.

Tanto las imágenes como los datos LIDAR se preprocesaron antes de comenzar con la metodología de segmentación seguida en este trabajo. Este preprocesado de los datos está detallado en uno de los apartados de la metodología que se verá más adelante.

Capítulo III
METODOLOGÍA DE TRABAJO

3.1. Introducción

El objetivo principal, como ya se ha comentado, es el establecimiento de una metodología de segmentación de árboles localizados en zonas forestales. Esta metodología desarrollada se centró en la localización y el conteo de éstos, y se divide en varias fases. Comienza con el preprocesado de las imágenes y los datos LIDAR que implica la generación y estudio de los modelos digitales necesarios para la segmentación, tras el preprocesado, se continúa con una primera fase de segmentación para la que se desarrolló una aplicación en IDL con uno de los algoritmos estudiados. Tras esta primera segmentación, se realiza una clasificación por píxel y otra orientada a objeto utilizando los resultados de la primera fase de segmentación. En una última fase de la metodología tiene lugar una segunda segmentación (o post-segmentación) para la que se desarrolló otra aplicación en IDL utilizando otro tipo de algoritmos para una segmentación más exhaustiva. Tras la post-segmentación se evalúan los resultados con los datos de campo de la zona de trabajo así como con los resultados de la primera fase.

El esquema de la metodología se puede observar en la figura 3.1.

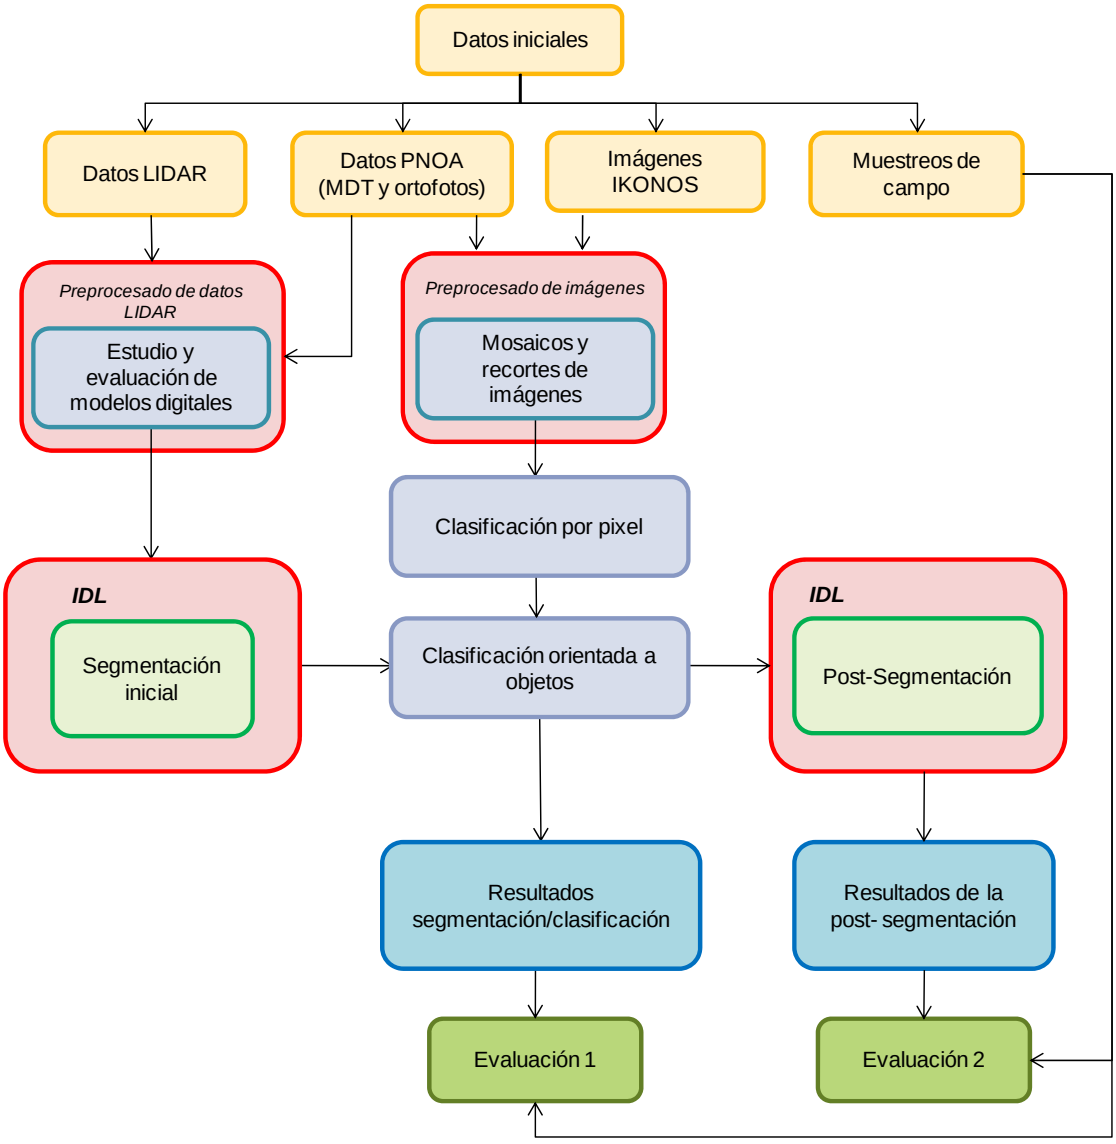

Figura 3.1. Esquema general de la metodología seguida.

3.2. Software empleado

En el trabajo realizado tanto para el tratamiento previo de los datos y la metodología seguida se emplearon varios software de tipo libre, comercial y científico dependiendo de las necesidades que han surgido a lo largo del proyecto.

El software empleado es el siguiente:

- ***FUSION/LDV.***

El software FUSION es un software libre desarrollado por el Servicio Forestal de los Estados Unidos (US FOrest Service – Department of Agriculture) originalmente para ayudar a los investigadores a entender, explorar y analizar los datos LIDAR. (McGaughey, 2010). La enorme cantidad de datos producidos por la tecnología LIDAR no se puede procesar en software SIG comercial o en entornos de procesamiento de imágenes sin un preprocesado muy extenso. Este software permite escoger zonas de datos y visualizarlas de forma interactiva, una tarea aparentemente sencilla pero muy complicada para otro software.

Figura 3.2. Logo FUSION.

Este software se puede dividir en tres sistemas diferentes como análisis, visualización (FUSION y LDV) y una biblioteca de comandos de ejecución sobre línea de comandos. La biblioteca de comandos son programas independientes que se ejecutan directamente sobre MS-Dos. El sistema FUSION es el interface primario consistente en una interfaz gráfica y un panel de control. En este se presentan todos los datos del proyecto en uso en un *display* 2D similar a los *displays* de otros sistemas de información geográfica. Este puede visualizar gran variedad de formato de datos incluidos ficheros *shapes*, imágenes modelos digitales, datos LIDAR, etc. El sistema LDV (LIDAR *Data Viewer*) visualiza en 3D un entorno de datos seleccionados para su estudio y medida. Los comandos sobre la línea de comandos proveen de análisis y procesados que han sido diseñador para que FUSION sea adecuado para procesar un alto volumen de datos LIDAR.

- ***ENVI + IDL***

ENVI es un software para el procesamiento y análisis de imágenes geospaciales. Este combina procesamientos de las imágenes espectrales más recientes con la tecnología de análisis de imagen mediante una interfaz intuitiva y fácil de usar para ayudarle a obtener información significativa de sus imágenes.

Figura 3.3. Logo ENVI.

Con ENVI se pueden preparar, explorar y analizar imágenes para la realización de trabajos. Este es fácilmente personalizable para satisfacer las necesidades del usuario gracias

al lenguaje de programación IDL con el que se podrán personalizar, modificar y desarrollar nuevas herramientas para optimizar el trabajo que se está realizando.

- ***ArcGis Desktop***

ArcGis Desktop es un conjunto de aplicaciones SIG que permiten al usuario realizar todo tipo de análisis espaciales. Incluye herramientas avanzadas de análisis espacial, tratamiento de datos y aplicaciones cartográficas. Este se suele utilizar con cualquier aspecto relacionado con la generación de información, modelización, análisis y representación de mapas. Este a su vez es personalizable y programable a partir de ArcObject y se pueden añadir barras de herramientas externas como es el ejemplo de herramientas de análisis "Hawth's Tools" (*http://www.spatialecology.com/htools/tooldesc.php*) que se ha utilizado en este trabajo.

Figura 3.4. Logo ArcGis.

- ***FETEX 2.0***

FETEX 2.0 (FEaTure EXtraction) es un programa interactivo para la extracción automática de elementos orientada a objetos. Este software ha sido creado por el grupo de investigación de CGAT (Cartografía GeoAmbiental y Teledetección) del Departamento de Ingeniería Cartográfica, Geodésica y Fotogrametría de la Universidad Politécnica de Valencia, programado en IDL 6.2 y puede ser utilizado en ENVI 4.2 o en versiones superiores (Ruiz, L.A. et al. 2010).

Figura 3.5. Logo CGAT (Cartografía GeoAmbiental y Teledetección).

FETEX está diseñado para trabajar con bases de datos de coberturas de suelo para ayudar en el proceso de la clasificación de las parcelas existentes o incluso determinar cambios que han ocurrido en las bases de datos comparando la actual con bases más antiguas.

- ***LIDEX***

LIDEX (LIDAR EXtraction) es un software para la a extracción de variables y tratamiento de datos LIDAR creado por el grupo de investigación de CGAT (Cartografía GeoAmbiental y Teledetección) del Departamento de Ingeniería Cartográfica, Geodésica y Fotogrametría de la Universidad Politécnica de Valencia.

Este permite tratar todo tipo de datos LIDAR así como crear modelos de superficie a partir de estos. Los algoritmos de interpolación que emplea han sido desarrollados por el propio departamento y han sido utilizados en otros trabajos de investigación (Estornell et al. 2009).

3.3. Preprocesado de los datos

En muchas ocasiones los datos no se encuentran en el estado adecuado con el que trabajar. Es por esto que los datos necesitan un tratamiento previo para poder trabajar correctamente con ellos. El preprocesado se realizó sobre las imágenes de la zona de estudio y sobre los datos LIDAR para la obtención de los modelos digitales del terreno.

3.3.1. Preprocesado de las imágenes

Las imágenes iniciales disponibles eran de dimensiones geográficas superiores a los límites de la zona de estudio, como es el caso de la imagen IKONOS, o se disponía de ellas en varias imágenes, como es el caso de las ortofotos del PNOA.

Para la imagen fusionada IKONOS se realizó un recorte de la zona deseada eliminando parte de la imagen fuera de los límites del área de estudio. El corte de la zona se realizó utilizando los límites geográficos de los propios datos LIDAR. De esta forma se obtuvo una imagen de menor tamaño que la anterior centrada sobre la zona de estudio. Este mismo recorte se realizó sobre la imagen multiespectral IKONOS.

Para las ortofotos del PNOA (tanto RGB como IR) se disponía de una extensión menor que la anterior pero dividida en varias imágenes, por lo que hubo que realizar un mosaico georreferenciado con una interpolación de vecino más cercano para el solape entre imágenes. Una vez hecho el mosaico no fue necesario realizar el recorte como en el caso de las imágenes IKONOS.

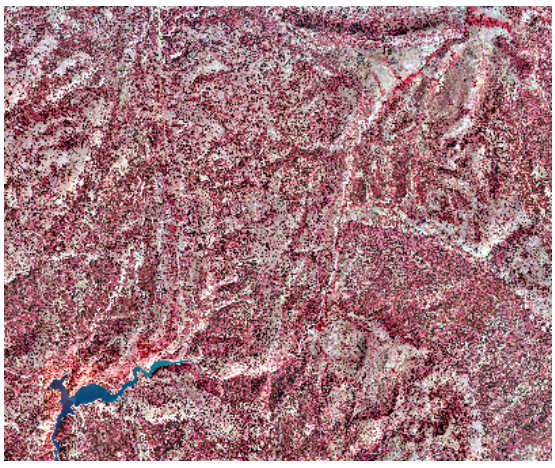

Figura 3.6. Mosaico ortofoto PNOA en falso color infrarrojo.

Figura 3.7. Mosaico ortofoto PNOA en RGB.

Con los recortes y mosaicos de las imágenes concluye esta parte del preprocesado. El siguiente preprocesado es el tratamiento del los datos LIDAR para la obtención de los modelos digitales.

3.3.2. Preprocesado de datos LIDAR (cálculo de modelos digitales)

El preprocesado de datos LIDAR se realiza con el objetivo de calcular los modelos digitales. Este preprocesado sigue el esquema mostrado en la figura 3.8. A continuación se explica detalladamente la generación de los modelos.

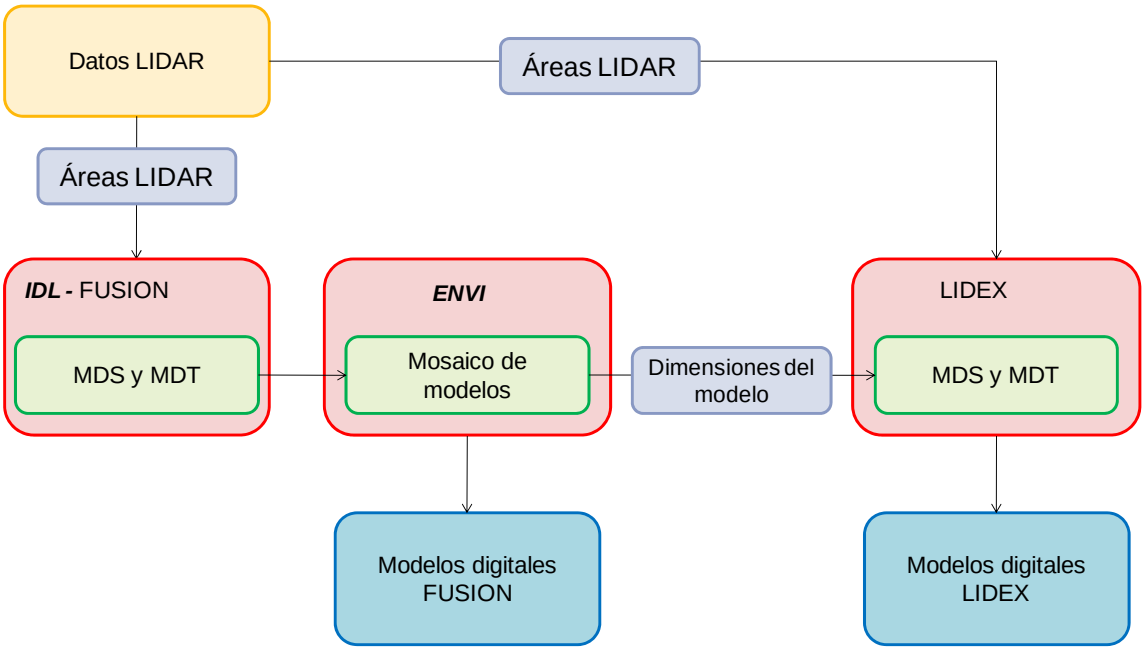

Figura 3.8. Esquema de generación de modelos digitales.

Para comenzar con la generación de los modelos digitales se creó una cuadrícula en formato vectorial que sirvió como guía para los ficheros de puntos distribuyendo estos en ficheros del tamaño de esa cuadrícula. La cuadrícula que se realizó fue de 500 x 500 metros tomando un solape de 50 metros a cada lado de cada cuadrado para evitar errores a la hora de realizar el mosaico posterior.

Una vez divididos los puntos LIDAR en los ficheros mencionados, se realizó la interpolación de cada uno de ellos para el cálculo de los modelos digitales: modelo del terreno (MDT) y modelos de superficie (MDS) o de vegetación (CHM).

Para este trabajo se realizaron dos interpolaciones con diferente software para poder realizar una evaluación de los resultados obtenidos. Ambos modelos fueron de 1 metro de resolución espacial, una precisión que se puede conseguir debido a la densidad de los datos LIDAR que se tienen de la zona. Una vez elegido el método que mejor se ajustó a las necesidades del proyecto, se generó un modelo de mayor resolución (0.5 metros) para el apartado de detección de árboles y segmentación.

Una primera interpolación se realizó con el software FUSION. La interpolación de FUSION se genera a partir de comandos en Ms-DOS por lo que se implementó un pequeño programa para la automatización de este proceso en IDL.

Los comandos FUSION que se emplearon son los siguientes:

- *GroundFilter*.

Este comando está diseñado para filtrar la nube de puntos LIDAR e identificar aquellos retornos que tienen mayor probabilidad de pertenecer a la superficie del terreno (*bare-earth points*). Este procedimiento no filtra un conjunto perfecto de puntos terreno ya que no elimina por completo los retornos de elevadas, extensas y planas superficies como pueden ser los tejados de los edificios. Muchos de los retornos de vegetación pueden ser eliminados con los coeficientes sobre la función de pesos apropiados y con varias iteraciones. Algunas pruebas con este comando demostraron que los parámetros y coeficientes por defecto dan buenos resultados en nubes con gran densidad de puntos (más de 4 ptos/m^2). Aún así el programa puede usarse con menor densidad de puntos utilizando otra serie de parámetros más adecuados. En general, el comando *GroundFilter* produce un conjunto de puntos adecuados para calcular alturas de vegetación. El conjunto de puntos resultado y los resultados de modelos digitales pueden ser no adecuados cuando se pretende el cálculo de un modelo de superficie de los puntos terreno, es por eso que para calcular un modelo digital del terreno se debe utilizar otro comando adicional conocido como *GridSurfaceCreate*.

El algoritmo de filtrado (Kraus y Pfeifer, 1998) está basado en una predicción linear con una precisión individual para cada una de las medidas. Está implementado como un proceso iterativo en el que en un primer paso, una superficie es procesada con los mismos pesos para todos los puntos LIDAR. Este resultado consiste en una superficie situada entre los puntos verdad-terreno y el modelo de superficie. La distancia y la dirección a la superficie se utilizan para calcular los pesos para cada punto LIDAR a partir de la siguiente función de pesos (figura 3.9):

$$p_i = \begin{cases} 1 & v_i \le g \\ \dfrac{1}{1+(a(v_i-g)^b)} & g < v_i \le g+w \\ 0 & g+w < v_i \end{cases}$$

Figura 3.9. Función de pesos. (McGaughey, 2010).

Los parámetros a y b determinan los pasos o distancias de la función de pesos. Unos valores de 1 y 4 para a y b respectivamente, han sido probados obteniendo buenos resultados para la mayoría de aplicaciones que se probaron. El valor de g determina a qué puntos es asignado el valor de peso máximo, siendo 1 este valor. A los puntos por debajo de la superficie superiores al valor g, se les asigna el valor del peso máximo. El parámetro de distancia de

puntos situados sobre la superficie, w, se utiliza para establecer un valor máximo de altura para los puntos que tengan una influencia sobre la superficie intermedia. Los puntos sobre el nivel definido por (g + w) se les asigna un peso 0. En el comando implementado, los valores de g y w no varían una vez se ha lanzado el comando. Hay referencias en las que el parámetro g varía para cada iteración (Kraus y Pfeifer 1998). Tras la iteración final, los puntos verdad-terreno son seleccionados utilizando la superficie intermedia. Todos los puntos con elevaciones que satisfagan las dos condiciones de la función de pesos son considerados puntos terreno.

Los parámetros del comando utilizados son:

- output file – archivo de salida
- píxel size – tamaño de píxel de salida
- data file – ficheros de datos
- median – filtro de media para los datos
- wparam – valor del parámetro *w* para la ecuación de pesos del algoritmo
- aparam – valor del parámetro *a* de la ecuación de los pesos del algoritmo
- bparam – valor del parámetro *b* de la ecuación de los pesos del algoritmo

Un ejemplo de una línea de comando es la siguiente:

```
C:\FUSION\groundFilter /median:3 /wparam:2.5 /aparam:4 /bparam:4 C:\fichero_salida 1 fichero_entrada
```

En la línea de comando anterior se observan los parámetros utilizados para cada uno de los ficheros interpolados. Estos parámetros mostrados son los que mejor se adaptan para la zona de trabajo.

- *GridSurfaceCreate*.

GridSurfaceCreate crea un modelo de superficie grid utilizando una nube de puntos irregular. Este genera ficheros en formato .dtm con valores de elevación flotante, generalmente provistos del comando anterior *GroundFilter*. Por defecto, *GridSurfaceCreate* procesa las elevaciones de cada celda grid utilizando la altura media de todos los puntos que se encuentran dentro de la propia celda. Este método parece que funciona bien con los datos LIDAR ya filtrados o clasificados como puntos terreno. Normalmente los retornos LIDAR de alturas presentan errores debido a los sistemas GPS-IMU. Utilizando la media de todos los retornos de las alturas en la celda, aceptando este error, se crea una superficie situada dentro de la nube de puntos terreno (McGaughey, 2010).

Los parámetros que se han utilizado son:

- surfacefile – fichero de salida de la superficie
- cellsize – tamaño de píxel de salida
- xyunits – unidades de los datos XY LIDAR (M para metros)
- zunits – unidades de los datos Z LIDAR (M para metros)
- coordsys – sistema de coordenadas de la superficie (1 para UTM)
- zone – zona del sistema de referencia (huso en UTM)
- horizdatum - datum horizontal
- vertdatum - datum vertical para la superficie

Un ejemplo de la línea de comando se muestra a continuación:

```
C:\FUSION\gridSurfaceCreate C:\fichero_salida.dtm 1 M M 1 30 0 0 C:\fichero_entrada
```

En esta línea de comando se observa que se ha escogido un tamaño de celda de un metro, las unidades XY y Z están en metros (M), el sistema de coordenadas es el UTM en huso 30 y al no tener programado el datum ED50, se introduce datum desconocido.

Para generar los MDTs es necesario utilizar los dos comandos (en primer lugar el comando *GorundFilter* y en segundo lugar *GridSurfaceCreate*), mientras que para generar los modelos de superficie o de vegetación solo es necesario utilizar el segundo comando.

Otra forma de generar el modelo de superficie o modelo de vegetación es mediante el siguiente comando:

- *CanopyModel*

CanopyModel crea un modelo de superficie utilizando la nube de puntos LIDAR. Por defecto, este comando asigna a cada punto el valor de elevación más alto de los retornos de los puntos situados dentro de la celda de tamaño seleccionado. Este comando también podrá crear una superficie de terreno utilizando una nube de puntos terreno, pero en vez de utilizar los puntos de menor elevación (como es el caso de *GridSuraceCreate*), utiliza los puntos con mayor elevación (McGaughey, 2010).

Los parámetros utilizados para este comando son los siguientes:

- surfacefile – fichero de salida de la superficie
- cellsize – tamaño de píxel de salida
- xyunits – unidades de los datos XY LIDAR (M para metros)
- zunits – unidades de los datos Z LIDAR (M para metros)
- coordsys – sistema de coordenadas de la superficie (1 para UTM)
- zone – zona del sistema de referencia (huso en UTM)
- horizdatum - datum horizontal
- vertdatum - datum vertical para la superficie

Un ejemplo de comando se muestra a continuación:

```
C:\FUSION\CanopyModel C:\fichero_salida.dtm 1 M M 1 30 0 0 C:\fichero_entrada
```

Como se puede observar, son los mismos parámetros que se han utilizado anteriormente para el comando *GridSurfaceCreate*. Entre ambos no existe diferencia alguna a efectos tanto visuales como estadísticos o al menos en la zona de trabajo.

Para la automatización del procedimiento de generación de los modelos digitales, como se ha comentado, se programó un código en IDL que realiza este proceso automáticamente con todos los ficheros de datos LIDAR de 500 x 500 metros. El código toma uno a uno los ficheros de datos existentes y va ejecutando en cada uno de ellos los comandos necesarios para realizar en primer lugar el MDT, en segundo lugar el MDS o CHM y como paso final los exporta a un formato compatible con ENVI.

```
pro calculo_modelos_FUSION

dir= 'C:\Cuenca\Datos_filtrados\Nueva_carpeta\'
ficheros = file_search (dir, '*.las')
nombresbase=file_basename(ficheros,'.las')

salida = 'C:\Cuenca\Procesado\modelos'

for i = 0.,n_elements(ficheros)-1 do begin
       ;MDT
       comando_filter = 'C:\FUSION\groundFilter /median:3 /wparam:2.5' $
              + ' /aparam:4 /bparam:4 '+salida+'\MDTptos'+nombresbase(i)+'.las 1
       '+ ficheros(i)
       spawn, comando_filter,result_fitler, ErrResult_filter,/HIDE

              comando_grid            =            'C:\FUSION\gridSurfaceCreate
       '+salida+'\MDT\MDT_'+nombresbase(i)+'.dtm ' $
              +'1         M         M         1         30         0         0
       C:\Cuenca\Procesado\modelos\MDTptos'+nombresbase(i)+'.las'
       spawn, comando_grid,result_grid, ErrResult_ground,/HIDE

       ;Modelo de vegetacion
              comando_canopy              =              'C:\FUSION\canopymodel
       '+salida+'\CHM\CHM_'+nombresbase(i)+'.dtm ' $
       +'1 M M 1 30 0 0 ' +ficheros(i)
       spawn, comando_canopy,result_canopy, ErrResult_canopy,/HIDE

       ;Exportacion a envi
              j_dtm2envi,              salida+'\MDT\MDT_'+nombresbase(i)+'.dtm',
       salida+'\envi\MDT\MDT_envi_' + nombresbase(i)+'.img'
              j_dtm2envi,              salida+'\CHM\CHM_'+nombresbase(i)+'.dtm',
       salida+'\envi\CHM\CHM_envi_' + nombresbase(i)+'.img'

endfor
end
```

Los ficheros de salida proporcionados al final de la ejecución son ficheros en formato '.mdt' y formato ENVI tanto de modelos del terreno como de superficie. Con los modelos resultantes se crea un mosaico de todas las imágenes para obtener un único modelo en una sola imagen. El modelo final del terreno se muestra en la figura 3.10.

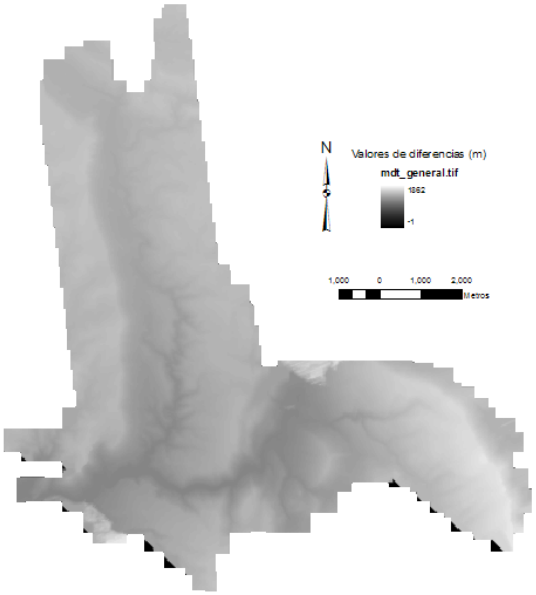

Figura 3.10. Mosaico de modelo digital de superficie FUSION.

Teniendo en una sola imagen todo el modelo digital, se puede realizar la interpolación con el software LIDEX utilizando la extensión del modelo realizado por FUSION. Si se desea, LIDEX calcula simultáneamente los modelos de superficie y del terreno. Para este trabajo a pesar de solo realizar la comparativa entre modelos FUSION y LIDEX del modelo digital del terreno se calcularon los dos tipos de modelos.

La metodología de interpolación que utiliza LIDEX (Estornell et al. 2009) es diferente a la empleada anteriormente por FUSION. LIDEX filtra en un primer paso los puntos que no pertenecen al suelo a partir de un proceso iterativo para la selección de puntos mínimos. Para ello, se seleccionan los puntos de altura mínima dentro de una ventana inicial que recorre toda la zona de estudio. A partir de estos puntos, se calcula un primer modelo del terreno. Luego se realiza una nueva búsqueda de puntos mínimos a partir de los datos originales pero utilizando una nueva ventana de tamaño inferior al anterior. De entre todos los puntos seleccionados en este segundo paso, se escogen aquellos cuya diferencia con respecto al modelo del terreno calculado anteriormente es inferior al umbral establecido. Los puntos superiores a este umbral se descartan. Este proceso se realiza una vez más con una ventana de tamaño inferior, eliminando de nuevo los puntos superiores a un segundo umbral introducido. Con los puntos seleccionados al final del proceso, se calcula el modelo de terreno final.

El modelo digital del terreno calculado por LIDEX se muestra en la figura (figura 3.11).

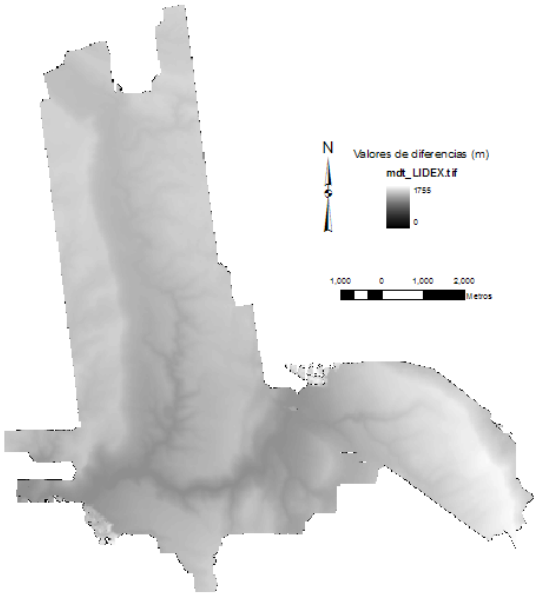

Figura 3.11. Modelo digital del terreno LIDEX.

3.3.2.1. Comparación y evaluación de los métodos

En primer lugar, para poder comparar unos modelos con otros de forma correcta, se necesita hacer una máscara para obtener únicamente las zonas interiores del modelo y así eliminar el efecto producido por los bordes. Los errores que se comenten en los bordes son debidos generalmente a la falta de puntos o a la baja densidad de estos al estar en los límites de la zona tomada por datos LIDAR. Es por esto mismo que siempre que se realice un levantamiento utilizando datos LIDAR hay que tomar datos de sobra en los márgenes de la zona de estudio para evitar errores.

Una primera máscara se creó eliminando sólo aquellos píxeles que tenían un valor introducido en aquellas zonas donde no hay datos de -9999, pero no eliminaba el efecto de los bordes. Como se ha comentado anteriormente, se puede reducir la máscara para eliminar estos defectos sin alterar la zona de estudio.

Para reducir la máscara se pueden utilizar diversas operaciones como filtros de erosión (haciendo más pequeña la máscara binaria). La solución que se tomó fue la más eficaz. Esta consiste en dibujar la zona en un *shape* para posteriormente crear la máscara. De esta forma, se escogieron las

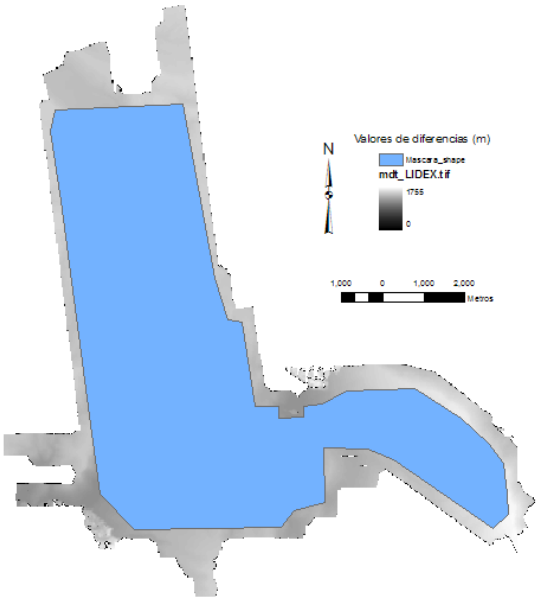

Figura 3.12. Máscara *shape* sobre modelo digital de elevaciones.

zonas que se deseaban incluir para el cálculo eliminado los bordes. La figura 3.12 muestra la máscara y el enmascaramiento producido sobre el modelo digital del terreno.

Una vez creada la máscara, se aplicó sobre los modelos para continuar con su evaluación. Para la evaluación de los modelos se realizaron varios análisis y así evaluar tanto los algoritmos de filtrado como los datos LIDAR tomados.

3.3.2.1.1. Diferencia entre modelos LIDEX y FUSION

El primer estudio que se realizó fue la diferencia básica entre los modelos restando los MDTs de LIDEX y de FUSION. Los datos que se muestran a continuación son las estadísticas básicas del fichero de diferencias entre los modelos digitales enmascarados (Tabla 3.1) y el histograma en el rango de valores de -20 a 20 metros donde se encuentra en 99.9% de píxeles.

	MÍNIMO	***MÁXIMO***	***MEDIA***	***DESVIACION STD.***
LIDEX-FUSION	-100.532227	213.301636	0.32034	1.172997

Tabla 3.1. Estadísticas básicas de diferencias LIDEX-FUSION.

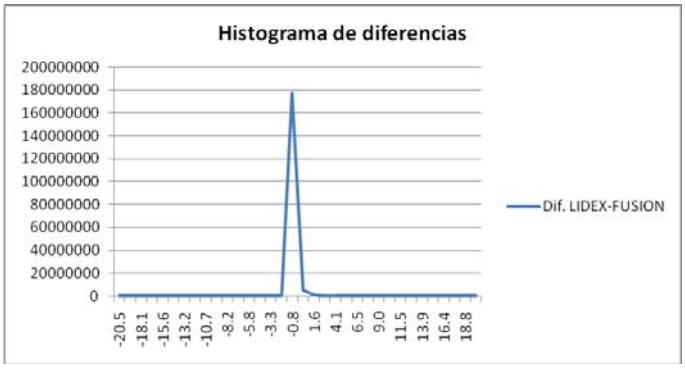

Figura 3.13. Histograma de diferencias e imagen de diferencias entre modelos digitales de terreno LIDEX-FUSION.

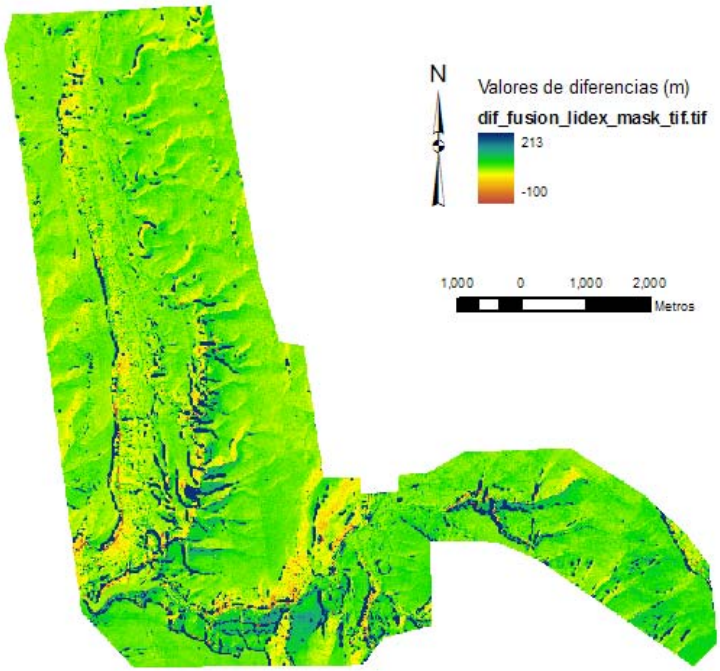

Figura 3.14. Diferencias entre modelos digitales del terreno LIDEX-FUSION.

Analizando a fondo el histograma y las estadísticas observaron diferencias considerables tanto de valores positivos como negativos. La diferencia entre modelos tiene un rango de valores de -100 hasta 213. Esto es debido a que sobre la zona de estudio hay un área de datos de menor densidad en la que los algoritmos de interpolación no pueden salvar el error. Las figuras que se muestran a continuación contemplan dicho error (Figuras 3.15 y 3.16):

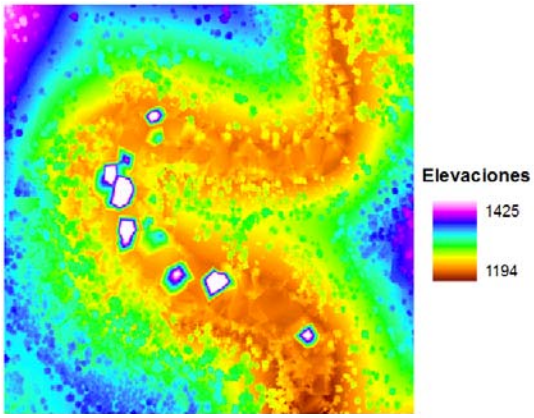

Figura 3.15. Detalle de modelo digital de superficie LIDEX con errores poligonales.

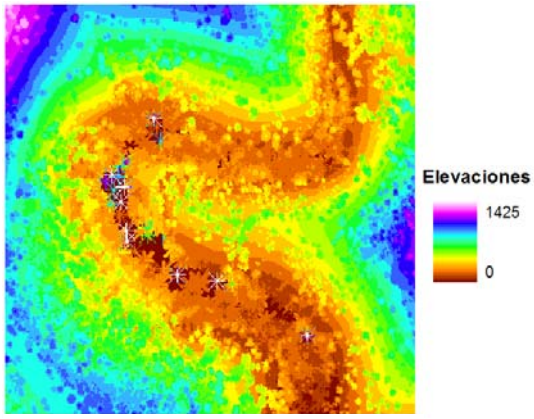

Figura 3.16. Detalle de modelo digital de superficie FUSION con errores estrellados.

Las imágenes se corresponden con una zona del río (zona de color naranja) en la que se producen esos efectos poligonales (con LIDEX) o efecto estrella (con FUSION) generados por el algoritmo que se utilizó por la falta de datos LIDAR al interpolar.

Para observar mejor las diferencias se creó un mapa de diferencias continuo con un rango de valores desde -5 a 5 metros para su mejor visualización donde se encuentra el 99.8% del número de píxeles de la imagen (Figura 3.17).

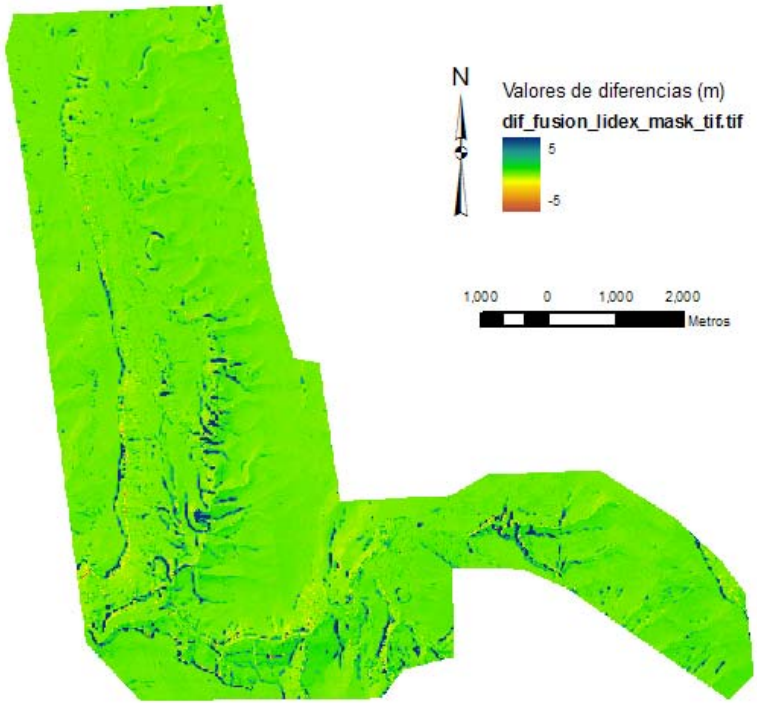

Figura 3.17. Mapa de diferencias entre modelos digitales del terreno LIDEX-FUSION en rango -5 a 5 metros.

En la figura se pueden ver claramente las zonas en las que se producen mayores diferencias. En estas zonas está situado el río con las respectivas vaguadas que acaban en él. También una línea bien diferenciable es la divisoria situada al oeste del río a lo largo de todo el modelo digital. Con estas diferencias tanto en divisorias como en vaguadas, se puede llegar a pensar que los algoritmos, a pesar de que se utilicen los mismos datos, introducen un desplazamiento a la hora del filtrado e interpolación. Es por esto que se realizó un estudio de posibles desplazamientos entre las diferencias.

3.3.2.1.2. Estudio de orientaciones de modelos LIDEX y FUSION

El estudio de orientaciones sobre los modelos, como se ha comentado antes, se realiza para ver si hay algún tipo de desplazamiento entre los dos tipos de modelos del terreno. No suele realizarse entre modelos calculados con los mismos datos ya que el objetivo de este suele ser el de encontrar desplazamientos de coordenadas entre los diferentes modelos calculados a partir de diferentes datos. En este apartado se utiliza para buscar desplazamientos producidos por los algoritmos empleados.

En un primer paso se crearon los mapas de orientaciones de los modelos digitales. Las imágenes de orientaciones se corresponden con las figuras 3.18 y 3.19 que se muestran a continuación.

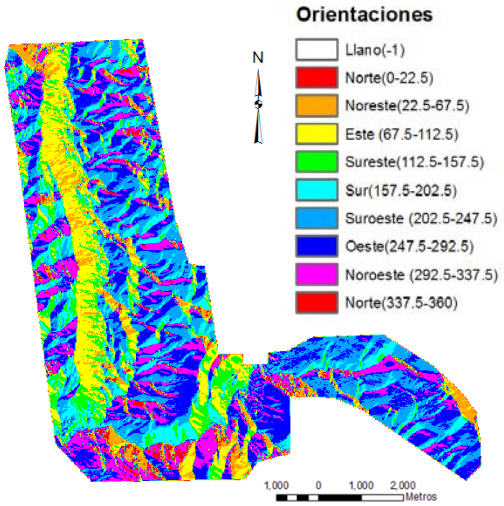

Figura 3.18. Mapa de orientaciones LIDEX.

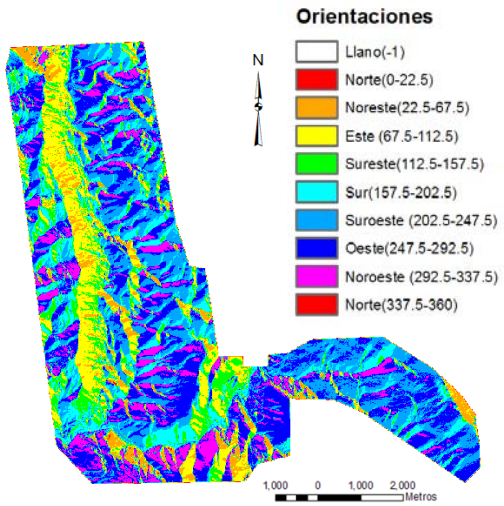

Figura 3.19. Mapa de orientaciones FUSION.

El procedimiento consiste en relacionar el mapa de orientaciones de un modelo de terreno con la diferencia que hay entre los dos modelos del terreno que se desean estudiar.

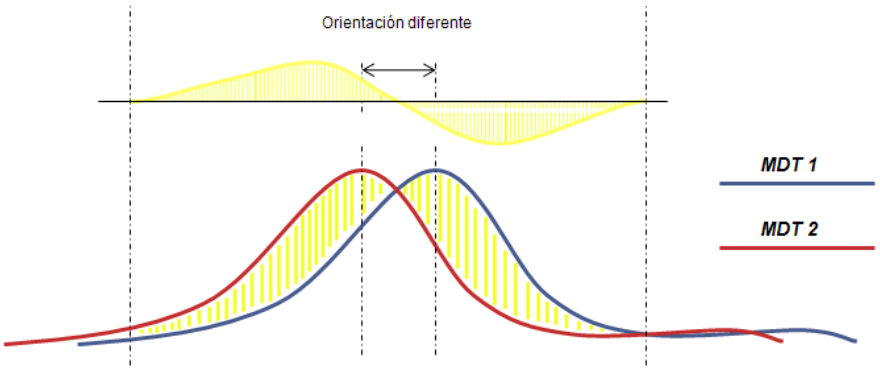

Figura 3.20. Gráfica de relación entre diferencias y orientaciones. En la parte superior se muestran las diferencias entre modelos (color amarillo). En la parte inferior se muestra un ejemplo de desplazamiento entre modelos en una única dirección.

En las gráficas de dispersión que se obtuvieron o 'scatters', (Figuras 3.21 y 3.22), relacionando las orientaciones con las diferencias se puede ver una tendencia de línea recta horizontal muy marcada a lo largo de todo el modelo digital descartando así el posible desplazamiento existente entre los dos modelos. Ambas gráficas de dispersión son claramente diferentes, pero la tendencia marcada predomina en las dos. Se ven zonas de puntos dispersos en varias direcciones. Estas zonas dispersas pueden deberse a la diferencia que hay entre los mapas de orientaciones calculados con los modelos digitales. Ambos modelos son muy parecidos pero no iguales a causa de que los algoritmos de interpolación son independientes y

cada uno utiliza una metodología diferente. Por esto, la dispersión de las gráficas es mínima y no reflejan ningún tipo de desplazamiento.

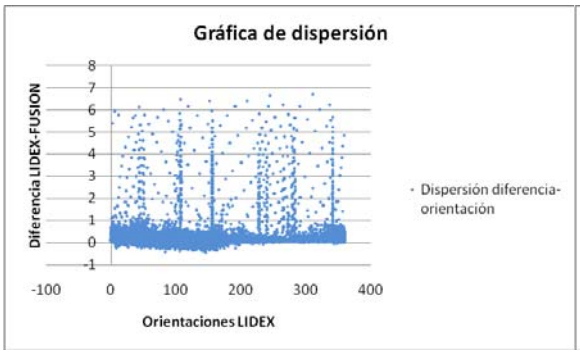

Figura 3.21. Dispersión LIDEX: Orientaciones en eje X y diferencias en eje Y.

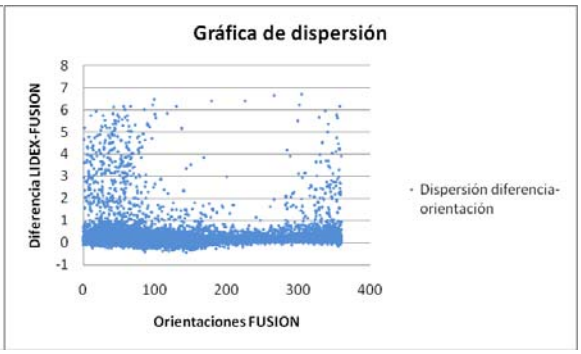

Figura 3.22. Dispersión FUSION: Orientaciones en eje X y diferencias en eje Y.

Eliminada la posibilidad del desplazamiento, se realizó otra comparación de modelos del terreno calculados y el MDT oficial del PNOA calculado a partir de métodos fotogramétricos.

3.3.2.1.3. Comparación punto-imagen con MDT del PNOA

Para poder validar un modelo digital final se compararon los modelos digitales obtenidos con el modelo digital del terreno del PNOA. Este modelo obtenido por fotogrametría tiene una resolución espacial de 5 metros. A pesar de esto se tomaron puntos de la malla de este modelo para compararlos con los modelos calculados ya que no se tenía un modelo digital del terreno oficial de mejor resolución con el que poder comparar.

El procedimiento consiste en comparar punto a punto de la malla del PNOA con el modelo ráster de los otros modelos digitales. Esto es, cada punto que caiga dentro de la celda ráster es comparado con el valor de ese píxel del modelo correspondiente. De esta forma sólo se comparan los puntos del PNOA que coinciden con el modelo digital en formato tif.

Antes de poder realizar este proceso de comparación, los puntos del MDT del PNOA, que estaban en ETRS89, se cambiaron al sistema de referencia ED50 ya que los datos LIDAR con lo que estaba trabajando, al igual que los modelos digitales creados, estaban en ED50. Debido al no tener una aplicación específica para el cambio de coordenadas entre sistemas de referencia, la transformación se realizó con la última versión de ArcGis (ArcGis 9.3). Para realizar esta transformación se importaron los datos LIDAR a ArcMap cargando los datos por sectores o zonas en las que estaba dividido este modelo digital trabajando las zonas una por una. Una vez cargados los puntos en ArcGis y cambiados de sistema de referencia con la máscara en formato *shape* creada para eliminar los bordes y evitar introducir errores que estos provocaban, se realizó un recorte de cada una de las zonas de puntos que estaban dentro de los límites de la máscara para evitar posteriores errores de memoria. Todos los

puntos que estaban dentro de la máscara se unieron en una única capa y se realizó la intersección punto-imagen PNOA y modelo LIDAR. De esta forma sobre la capa de puntos se generó una nueva columna con las cotas correspondientes a los pixeles coincidentes con los puntos del MDT. Sobre la misma tabla se generó un nuevo campo y se realizó la diferencia entre estos.

Como resultado final se obtuvo un fichero *shape* con cinco columnas: X, Y, Z, cota imagen del modelo del terreno y la diferencia entre Z y cota imagen del modelo del terreno. Sobre la columna de las diferencias se calcularon las estadísticas básicas para poder evaluar el modelo digital del terreno. Para ello se creó un código en IDL que calculaba estas estadísticas y que mostraba el histograma por pantalla directamente leyendo el fichero *shape*.

El código en IDL es el siguiente:

```
pro histograma_shape

shape= OBJ_NEW('IDLffShape')
       status=shape-
>Open('C:\Cuenca\Procesado\MDT_Cuenca\diferencias\pruebas\dif_PNOA-
FUSION_ED502.dbf',/DBF_ONLY)
atributos = shape->getAttributes(/ALL)

array=atributos.ATTRIBUTE_4
b = array[SORT(array)]

histo =histogram(b,MAX = 10, MIN = -10, binsize=0.25, locations=loc)
plot, loc,histo
media=mean(b,/DOUBLE)
st_deviation=stddev(b,/DOUBLE)
maximo = max(b,MIN = minimo)
       elementos =N_ELEMENTS(b)
RMS=SQRT(total(diferencias[b]^2)/n_elements(b))

;Salida por pantalla
print, 'numero de puntos =', elementos
print, 'media =', media
print, 'desviacion =', st_deviation
print, 'maximo =', maximo
print, 'minimo =', minimo
print ,'RMS =', RMS
end
```

El código escrito carga la columna de las diferencias y visualiza un histograma del "array" o cadena de diferencias. Luego calcula la media, la desviación típica, los valores máximo y mínimo y el error medio cuadrático.

Este procedimiento de diferencia punto-imagen y cálculo de estadísticas se realizó con las dos imágenes de los modelos de datos LIDAR: el modelo calculado con LIDEX y el modelo calculado con FUSION.

Los resultados para la diferencia entre el PNOA y LIDEX son los que se muestran a continuación:

Número de puntos = 2071247

	MíNIMO	*MÁXIMO*	*MEDIA*	*DESVIACION STD.*	*RMS*
PNOA-LIDEX	-79.006	1719.006	1.497	15.845	15.9151

Tabla 3.2. Estadísticas básicas de diferencias punto-imagen LIDEX-FUSION.

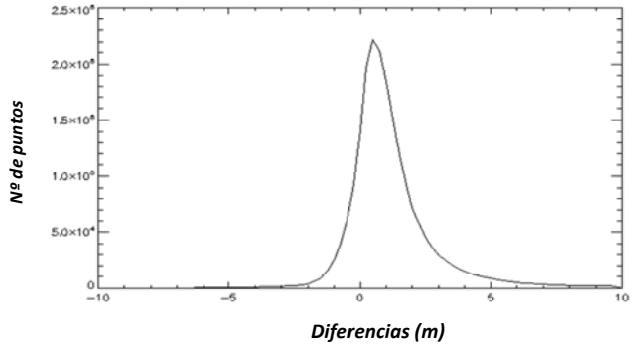

Figura 3.23. Histograma de diferencias entre modelos del terreno PNOA-LIDEX.

Los resultados para la diferencia entre el PNOA y FUSION son los que se muestran a continuación:

Número de puntos = 2071247

	MíNIMO	*MÁXIMO*	*MEDIA*	*DESVIACION STD.*	*RMS*
PNOA-FUSION	-110.528	1630.521	1.497	25.842	25.884

Tabla 3.3. Estadísticas básicas de diferencias punto-imagen LIDEX-FUSION.

Figura 3.24. Histograma de diferencias entre modelos del terreno PNOA-FUSION.

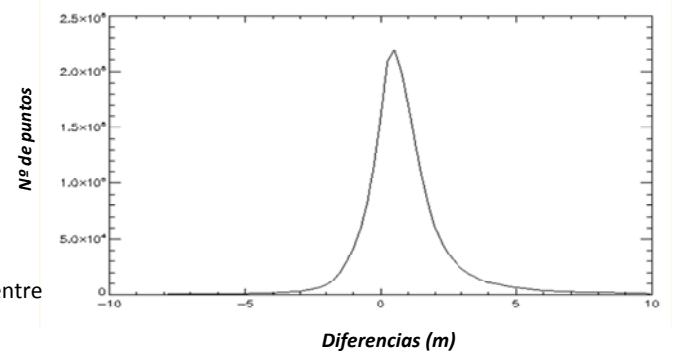

Si se analizan las diferencias para ambos casos se pueden observar valores máximos y mínimos muy elevados entre los modelos del terreno PNOA y los calculados. Estas grandes diferencias se deben en parte a errores de interpolación comentados anteriormente (Figura 3.15 y 3.16) por falta de puntos en ciertas zonas del río y se consideró que podría haber otro tipo de error en los modelos, como pueda ser alguna gran diferencia en alguna parte del modelo cometida por un fallo en el propio modelo o algún gran desnivel sobre el terreno.

Vistos los resultados anteriores y el sistema de comparación realizado, se puede decir que este proceso de comparación no es el más preciso ni adecuado debido a que por cada punto que compara cada 5 metros del modelo de menor resolución, deja sin comparar 24 de cada modelo digital de mayor resolución centrándose en el píxel central de la ventana de 5 x 5 pixeles (cada píxel de 1 metro en modelos FUSION y LIDEX).

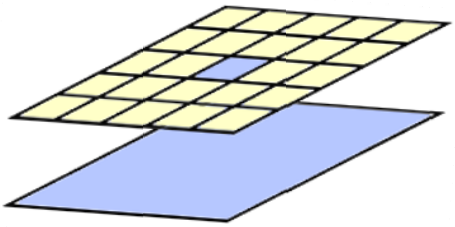

Figura 3.25. Píxel central de 1 metro (azul) comparado con píxel de 5 metros en el proceso de diferencias punto-imagen.

Debido a lo anterior se decidió realizar una mejor comparación entre estos modelos digitales de diferentes resoluciones. El método consistió en una comparación imagen a imagen.

3.3.2.1.4. Comparación imagen-imagen con MDT del PNOA

Se propuso un nuevo procedimiento más visual para la comparación entre los modelos digitales del terreno. Este consistía en interpolar un modelo digital del terreno a partir de los puntos del PNOA con el software LIDEX. De esta forma se creó una nueva imagen para poder comparar los datos directamente entre los modelos digitales sin tener en cuenta el procedimiento de interpolación y así poder evaluar la calidad del los datos LIDAR con los datos fotogramétricos del PNOA.

Para crear las imágenes de los modelos, los datos X, Y, Z en ED50 se transformaron a formato 'las' para poder cargarlos en LIDEX y crear dicha imagen con los límites de una de las otras imágenes ya creadas. Tras la obtención de la imagen del MDT del PNOA para evitar cometer el mismo error que se comete al comparar punto-imagen del proceso anterior, sobre los modelos digitales de mayor resolución (FUSION y LIDEX) se realizó un remuestreo para pasar de una resolución de píxel de 1 metro a una resolución de 5 metros y comparar píxel a píxel los modelos. Tras el remuestreo se calcularon las diferencias restando el modelo del PNOA con los dos modelos de datos LIDAR calculando sus estadísticas enmascaradas.

En las estadísticas se encontraron valores máximos y mínimos elevados. Esto se atribuye a defectos en los datos LIDAR iniciales que no se pueden filtrar, produciendo errores sobre los estadísticos parecidos a los que producen los efectos de los bordes, es por eso que el análisis estadístico se centra en un cierto umbral máximo y mínimo donde se encuentran la mayoría de los píxeles. El umbral escogido fue de -20 a 20 niveles digitales conteniendo el 99.6% de los píxeles de la imagen.

En los siguientes datos se puede observar lo comentado anteriormente:

Niveles Digitales	*Nº puntos*	*Total*	*Porcentaje*	*Porcentaje Actual*
-20.102628	52	3310	0.0026	0.1686
-19.631677	42	3352	0.0021	0.1708
-19.160725	52	3404	0.0026	0.1734
…	…	…	…	…
19.457304	905	1955189	0.0461	99.6032
19.928256	859	1956048	0.0438	99.6470
20.399207	885	1956933	0.0451	99.6921

Tabla 3.4. Resumen de porcentajes de niveles digitales de la diferencia PNOA-LIDEX.

Dentro de este umbral, los valores estadísticos de las diferencias muestran mejores resultados con el modelo del terreno calculado por LIDEX. El resumen de las diferencias PNOA-LIDEX se muestra a continuación:

	MíNIMO	*MÁXIMO*	*MEDIA*	*DESVIACION STD.*	*RMS*
PNOA-LIDEX	-20.000	20.000	0.328	1.546	3.854

Tabla 3.5. Estadísticas básicas de la diferencia imagen-imagen PNOA-LIDEX.

Figura 3.26. Histograma de diferencias entre modelo PNOA y LIDEX imagen –imagen de 5 metros sobre rango de valores -20 a 20 metros.

Lo mismo se muestra para la diferencia entre el modelo PNOA-FUSION en los siguientes datos:

	MíNIMO	*MÁXIMO*	*MEDIA*	*DESVIACION STD.*	*RMS*
PNOA-FUSION	20.000	20.000	0.863	3.391	3.854

Tabla 3.6. Estadísticas básicas de la diferencia imagen-imagen PNOA-FUSION.

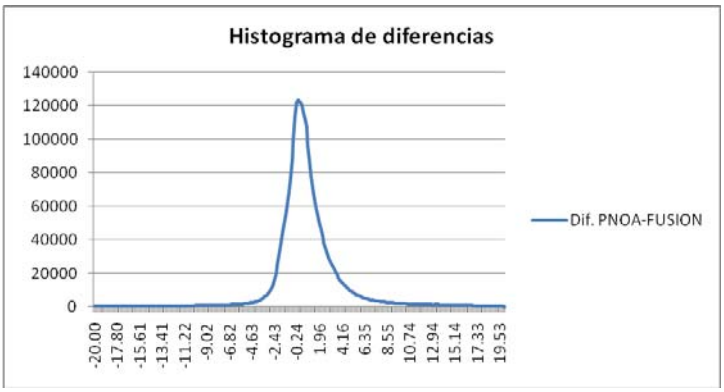

Figura 3.27. Histograma de diferencias entre modelo PNOA y FUSION de 5 metros sobre rango de valores -20 a 20 metros.

Los histogramas presentan valores diversos para las dos diferencias que se realizaron. Las diferencias PNOA-FUSION, a pesar de tener un error medio cuadrático algo menor que la diferencia entre PNOA-LIDEX, tiene una media y una desviación típica mayores y por lo tanto un histograma algo más disperso del eje de la media, mientras que en el histograma PNOA-LIDEX se puede observar una concentración mayor en este mismo eje.

Para una mejor visualización de las diferencias se generaron mapas de diferencias entre el modelo del PNOA y los modelos de datos LIDAR clasificando los valores de diferencias según una escala de colores continuos. La figura 3.28 muestra las diferencias entre PNOA y LIDEX y la figura 3.29 las diferencias entre PNOA y FUSION.

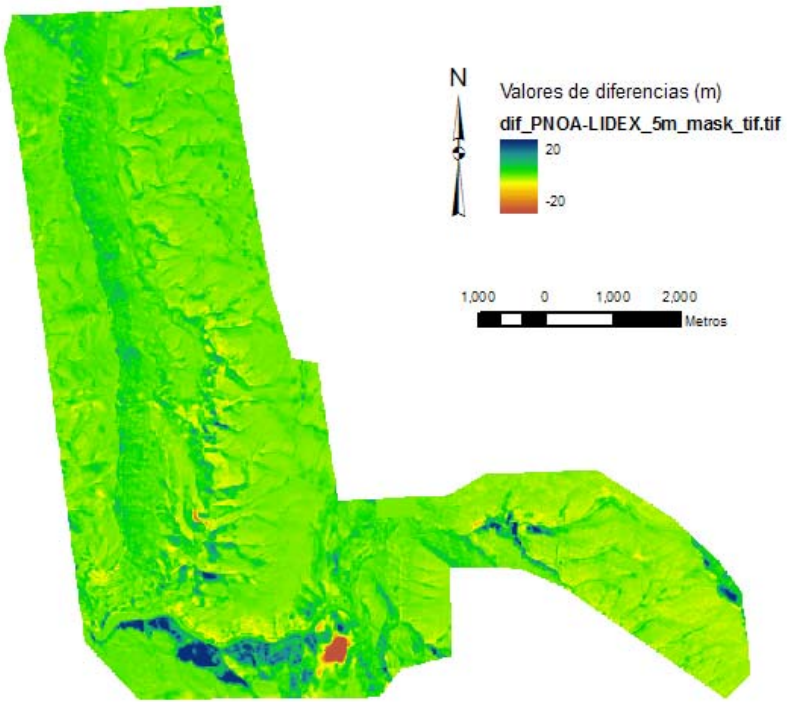

Figura 3.28. Mapa de diferencias entre PNOA y LIDEX en rango de valores de -20 a 20 metros.

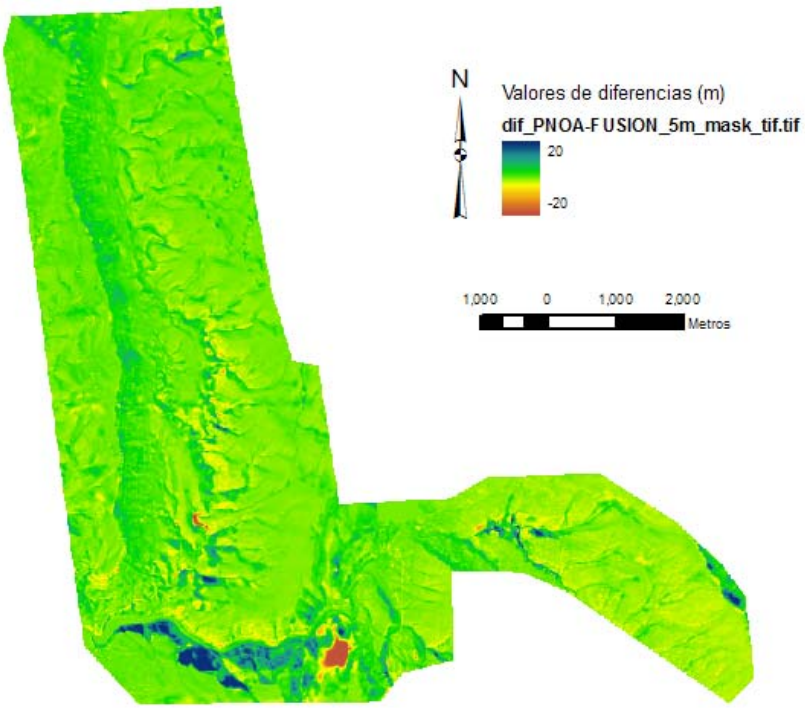

Figura 3.29. Mapa de diferencias entre PNOA y FUSION en rango de valores de -20 a 20 metros.

Realizado el análisis de las diferencias con la resolución de 5 metros de tamaño de píxel se pudo observar que los resultados obtenidos eran mejores que en el anterior procedimiento. Aún así, los errores cuadráticos seguían siendo elevados.

Si se analizan los mapas de diferencias se puede observar visualmente las mayores discrepancias entre los modelos en colores azul y naranja en ambos modelos sobre las mismas zonas. Una de las zonas corresponde con la baja densidad de datos LIDAR comentado anteriormente donde se producen los efectos poligonales y estrellados. Otra de las zonas conflictivas es una zona en la hay una gran desnivel (como pueda ser una pared vertical) en la cual los algoritmos de interpolación cometen ciertos fallos. La zona en la que se ha encontrado un error con respecto al modelo digital del terreno oficial del PNOA es la mancha de color naranja situada al sur del modelo. A continuación se muestra el detalle de dicha zona en las siguientes figuras (Figura 3.30, 3.31 y 3.32).

En la figura 3.30 se observa la diferencia entre el modelo digital del PNOA y del LIDEX en la que se observa cierta discrepancia entre modelos. Analizando los modelos por separado se encontró una anomalía sobre el modelo digital del PNOA (Figura 3.31) inexistente en el modelo digital LIDEX (Figura 3.32). Esta anomalía consiste en la ausencia de una marcada línea divisoria sobre una ladera en la que se puede observar un extraño comportamiento de ciertos píxeles.

Tras cotejar estos modelos con la ortofoto propia del PNOA se pudo afirmar que hay un cierto error en el modelo oficial del PNOA.

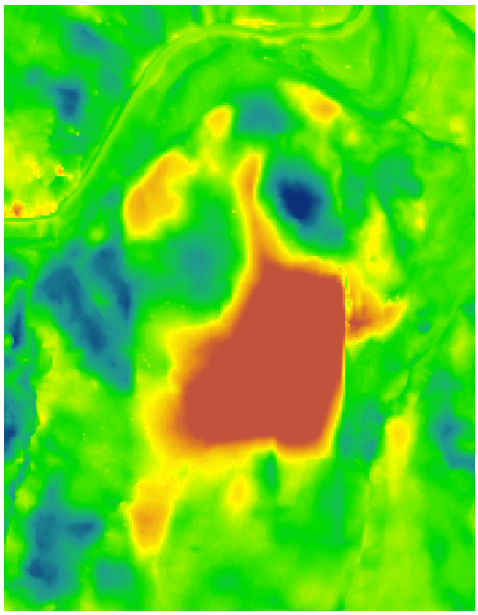

Figura 3.30. Detalle de anomalía sobre imagen de diferencias PNOA-LIDEX.

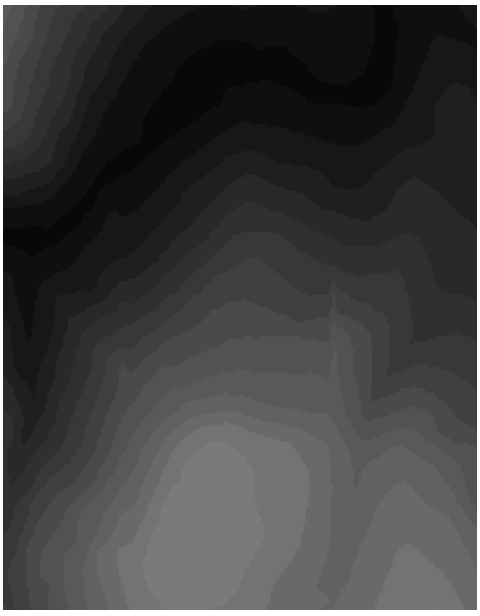

Figura 3.31. Detalle de anomalía sobre MDT PNOA.

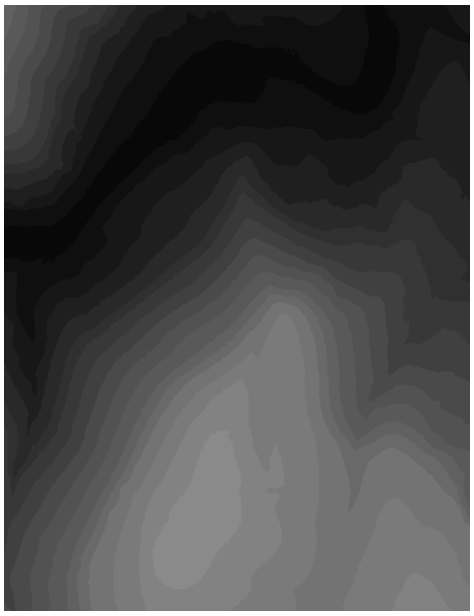

Figura 3.32. Detalle sobre MDT FUSION.

Analizando los datos gráficos visualmente se encontró explicación a los datos numéricos y estadísticos. También ayudó a una mejor comprensión de los valores máximos y mínimos elevados y de los errores cuadráticos.

Para concluir con el estudio de los modelos digitales del terreno se realizó un último procedimiento para comprobar si existía algún tipo de discordancia con los datos en lo que refiere a un cierto desplazamiento que pueda haber entre estos.

3.3.2.1.5. Estudio de orientaciones del modelo del PNOA

Para este modelo se realizó el estudio de orientaciones antes mencionado en el estudio de orientaciones entre modelos LIDEX y FUSION con la diferencia de que al aplicar de nuevo este estudio con estos nuevos modelos se están evaluando los datos y no el método de interpolación como antes.

Las diferencias de modelos PNOA-LIDEX y PNOA-FUSION se relacionaron con las orientaciones a partir de los "scatters". Las siguientes figuras muestran estas relaciones (Figura 3.33 y 3.34).

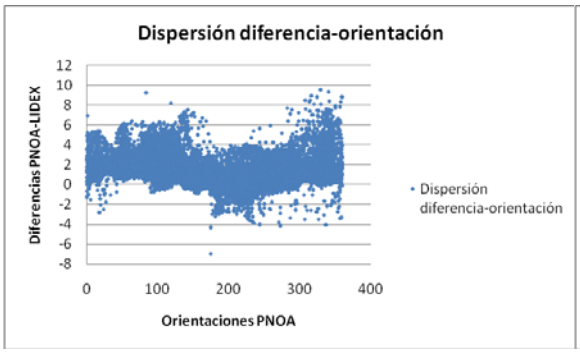

Figura 3.33. Relación de orientaciones y diferencias PNOA-LIDEX.

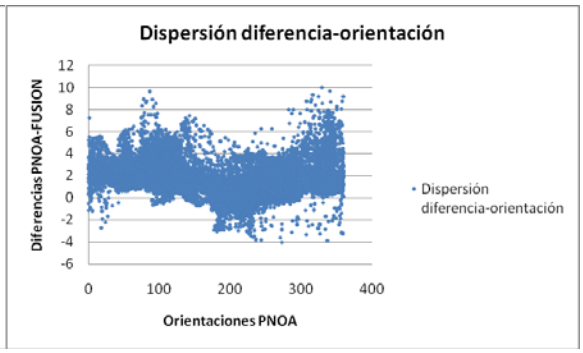

Figura 3.34. Relación de orientaciones y diferencias PNOA-FUSION.

Las gráficas anteriores muestran mayor dispersión de los datos en este estudio de orientaciones que en el estudio realizado para los algoritmos de interpolación. Es por esto que se encontró un pequeño desplazamiento entre los datos LIDAR y los datos del PNOA. A pesar de que se encuentre un pequeño desplazamiento no es significativo pero aún así puede ser en parte causa de los valores estadísticos que se calcularon. Este desplazamiento es difícil de cuantificar sobre las gráficas de dispersión pero analizándolas, se puede observar que el punto donde se produce el desplazamiento está situado sobre los 180 grados, esto es, los datos se encuentran desplazados en dirección Sur de acuerdo con la leyenda de los mapas de pendientes (figuras 3.18 y 3.19). La posible causa de este desplazamiento puede ser variada, pero si se encuentra un desplazamiento no producido por algún algoritmo de interpolación, probablemente se deba a un error en la metodología de trabajo o incluso un error introducido en la toma de puntos (mala calibración del sistema GPS o en el sistema inercial).

Tras el análisis de los resultados obtenidos al realizar estas pruebas se puede decir que los datos LIDAR presentan una zona inestable debido a la baja densidad de puntos que hay sobre la zona del río, donde se produjo una menor densidad de retornos debido a la presencia del agua y de las zonas donde suceden grandes desniveles bruscos como paredes verticales,

donde los algoritmos de interpolación producen errores en la interpolación. Estas anomalías se pueden observar en los modelos digitales de superficies y en el mapa de diferencias realizados con los modelos y el PNOA. Por otra parte, se encontró una zona de diferencias máximas con el modelo oficial del PNOA y los modelos calculados. Analizando la zona se observó que hay buena densidad de datos LIDAR y que estos son coherentes, por lo que se descartó la mala interpolación de los datos. En cambio, visualizando el modelo digital del PNOA se puede ver cierta irregularidad de este, por lo que se asumió un error en el MDT oficial del PNOA debido probablemente a la menor resolución espacial que presenta este modelo.

Como consecuencia del análisis de los datos anteriores según la metodología seguida se tomó como modelo digital de vegetación el modelo calculado por LIDEX para continuar con el trabajo y con el desarrollo de la metodología.

3.4. Segmentación inicial

Esta segmentación inicial se realiza para una primera localización de las unidades de árbol a partir de la detección de las copas basándose en el principio de sumideros o *watershed*. El algoritmo básico de *watershed* se basa en la detección de contornos como cuencas cerradas basándose en las variaciones de la función (módulos de los gradientes) de los valores de intensidad (Beucher y Lantuejoul, 1979; Vincent y Soille, 1991), en la que los contornos son aquellos valores de intensidad mayor. Este algoritmo es rápido y genera contornos cerrados. El gradiente de la imagen se puede ver como una sección de terreno con relieve, donde los límites de las montañas son los contornos de los objetos a segmentar. Se simula un proceso iterativo de inundación de esta sección de terreno a partir de los mínimos locales detectados en la que los contornos de los objetos a segmentar se definen como los puntos donde las diferentes zonas inundadas se unen. Un límite entre las diferentes zonas inundadas marca los contornos de los objetos (Roundier et all., 2008).

En la figura 3.35 se muestra un ejemplo del funcionamiento del algoritmo *watershed* en una dirección.

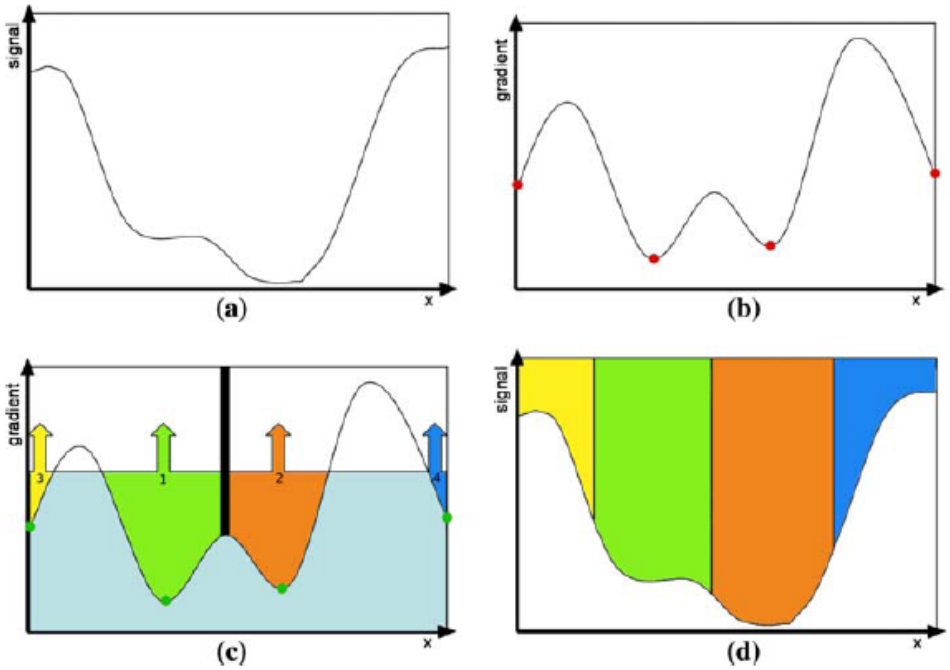

Figura 3.35. Ilustración de la segmentación watershed en una dirección. (Roundier, P. et all. 2008) (a) Señal a segmentar. (b) El correspondiente gradiente de la señal. (c) Inundación de los niveles digitales de intensidad (o escala de grises) a partir de los mínimos locales detectados. Cuando dos zonas inundadas se tocan, se crea el límite entre ellas. Estos límites son los contornos de la segmentación. (d) Resultado de la segmentación de la señal.

Este método al estar basado en el gradiente de la intensidad de la imagen, es muy sensible al ruido, por lo que se puede llegar a producir una sobresegmentación que es el mayor inconveniente del algoritmo *watershed*. Debido a este inconveniente, la imagen a procesar utilizando la función *watershed* de IDL debe de ser correctamente filtrada (Persson et

al., 2002). Esta función que se empleó se basa en el algoritmo *watershed* reflejado en Dougherty, 1992.

El algoritmo watershed ha sido utilizado como método de segmentación en otros trabajos centrados en la información multiespectral (Tarabalka et al., 2010), pero también ha sido utilizado con datos LIDAR (Popescu y Wayne, 2004; Andersen et al., 2005) en forma de modelo de vegetación. El presente método de segmentación inicial pretende combinar información multiespectral con el modelo de vegetación, tomando como imágenes de partida una imagen calculada a partir de datos multiespectrales y una imagen del modelo de vegetación sobre la cual se realizará la segmentación.

La información espectral se introduce en forma de índice de vegetación normalizado (NDVI) calculado a partir de las imágenes del PNOA debido a que su resolución espacial es de 0.5 metros acorde con la resolución de los modelos digitales.

El índice de vegetación normalizado (NDVI) relaciona la banda IR con la visible correspondiente al rojo, creando una imagen cuyos niveles de gris son directamente proporcionales a la biomasa y/o al vigor vegetativo de la superficie correspondiente a cada píxel.

$$NDVI = (IR - R)/(IR + R)$$

Figura 3.36. Fórmula del NDVI.

La imagen a segmentar es el modelo de vegetación normalizado (CHM) calculado a partir del modelo digital del terreno (MDT) y del modelo digital de superficie (MDS). Para el cálculo del modelo de vegetación se resta el modelo de superficie menos el modelo del terreno (MDS-MDT), de esta forma se obtienen todas las alturas de los árboles sobre una misma superficie de nivel. Las figuras que se muestran a continuación se corresponden a una misma zona de datos LIDAR, una sin normalizar y otra normalizada.

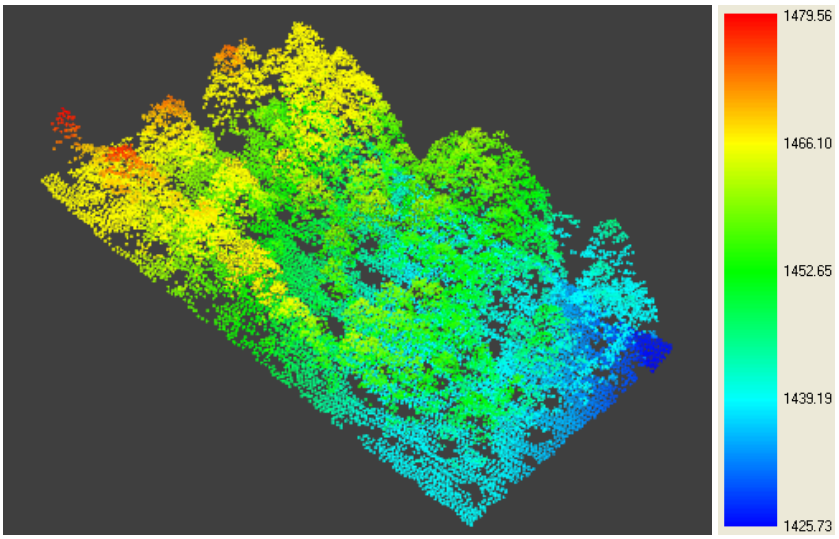

Figura 3.37. Modelo de vegetación no normalizado (leyenda en metros).

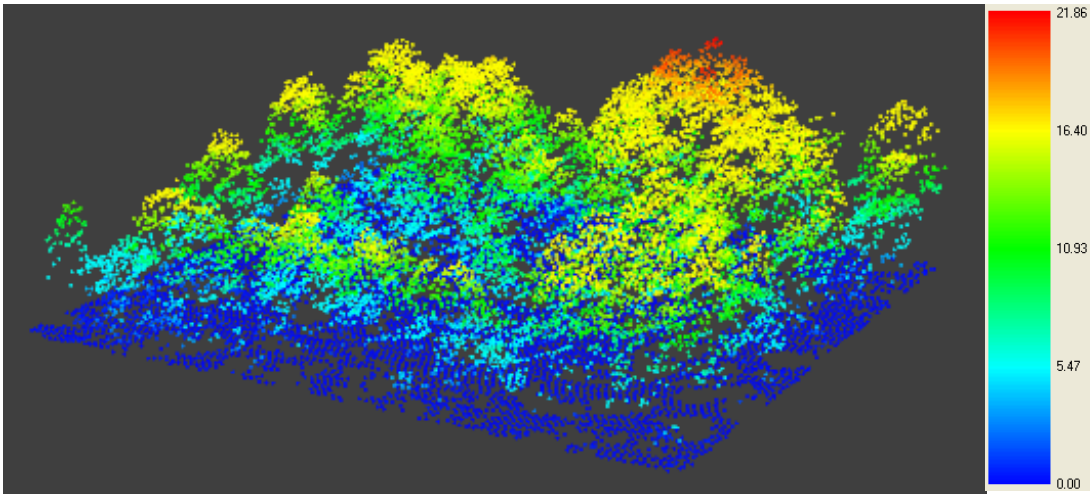

Figura 3.38. Modelo de vegetación normalizado (leyenda en metros).

Una vez calculados el NDVI y el CHM se comenzó con la ejecución de la segmentación. El código implementado para esta primera segmentación sigue el siguiente esquema (figura 3. 39):

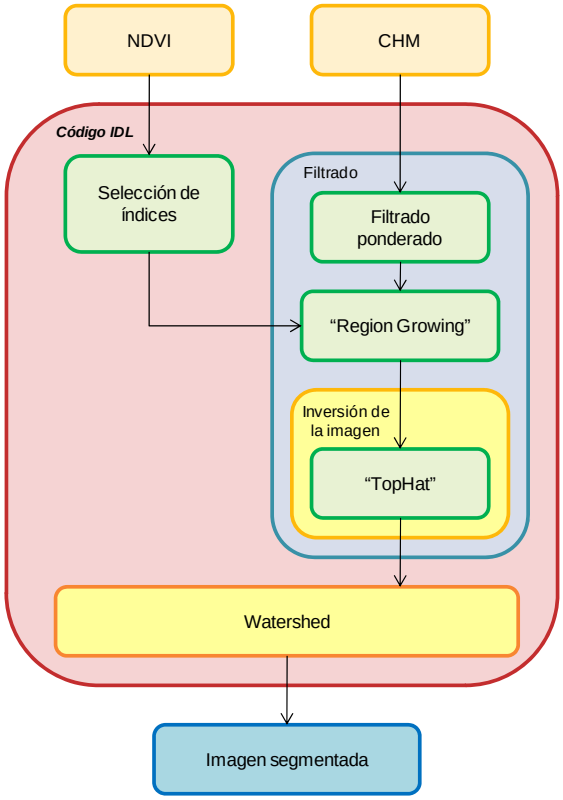

Figura 3.39. Esquema general del código implementado.

En resumen, el código implementado lee las imágenes y aplica filtros que facilitan el trabajo a la función *watershed* para después aplicarla.

En un primer paso el programa toma la imagen NDVI y realiza una selección de puntos cuyo índice es superior a 0.4. El programa toma este valor debido a las pruebas que se realizaron sobre los índices de vegetación. El índice NDVI tomaba valores superiores a 0.4 en zonas con vegetación forestal mientras que en zonas de matorral y de suelo, el valor era inferior a este.

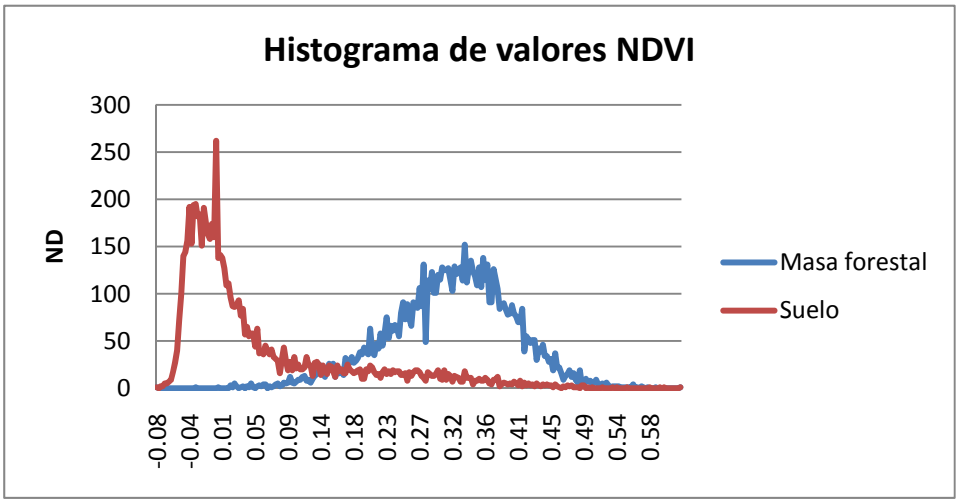

Figura 3.40. Histogramas de valores NDVI en zona de suelo y masa forestal.

Una vez el programa ha detectado dichos puntos sobre la imagen, se realiza un crecimiento de regiones utilizando dichos puntos como puntos semilla sobre la imagen del modelo de vegetación filtrada. El filtro que se le aplica al modelo es un filtro basado en un filtrado de media ponderada. Este actúa ponderando los píxeles asignando diferentes pesos a los píxeles vecinos en función inversa a la distancia espectral existente entre un vecino y el píxel central de la ventana. Aquellos píxeles que tengan niveles digitales similares al del píxel sobre el que se aplica el filtro, tendrán una influencia mayor en el valor resultante del píxel de la nueva imagen (Recio, 2009).

Para el crecimiento de regiones se utilizó una función programada en IDL. Esta función realiza un crecimiento de regiones a partir de unos píxeles dados como semillas sobre una imagen. Este encuentra todos los píxeles vecinos conectados a las semillas y que tienen un valor dentro de un rango dado (figura 3.41). Este rango se puede especificar indicando un valor máximo y mínimo o como un multiplicador de la desviación estándar de los valores de la región. La especificación del rango implementada es la de valores máximos y mínimos. Utilizando esta especificación, la región sobre la imagen crece hasta que incluye todos los pixeles conectados entre sí que tienen un valor entre el mínimo y el máximo especificado (Ayuda técnica IDL).Realizado el crecimiento de regiones, los pixeles correspondientes al crecimiento son ponderados con un valor mayor con respecto del resto de píxeles de la imagen, destacando así su valor de elevación sobre el resto.

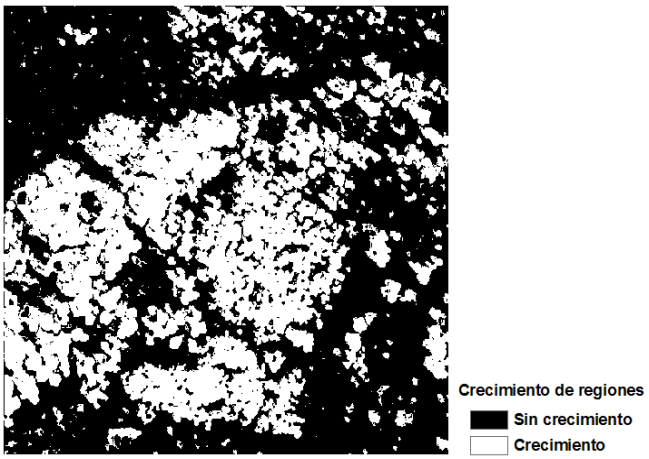

Figura 3.41. Crecimiento de regiones sobre la imagen.

Una vez que se tiene la imagen ponderada, se realiza la inversión de los valores de la imagen, esto es, los valores correspondientes a las zonas más altas (si se concreta para los modelos de vegetación) pasan a ser las zonas más bajas, de esta forma, los valores del suelo de la imagen pasan a ser las zonas más elevadas y los árboles las más bajas.

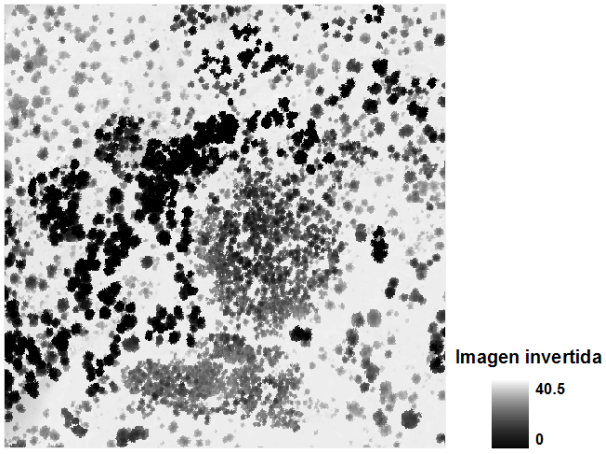

Figura 3.42. Imagen invertida.

Esta imagen invertida (figura 3.42) se somete a un filtrado de realce de intensidades más altas, o lo que es lo mismo, un realce del suelo al ser ahora la zona más elevada de la imagen. Este filtro es conocido como *TopHat*, y está implementado en una función de IDL. El operador *TopHat* también es conocido como detector de picos. Este extrae solo los píxeles más intensos de una imagen en escala de grises aplicando un operador abierto sobre la imagen y sustrayendo el resultado de la imagen original. Este operador es especialmente útil para identificar pequeños elementos sobre la imagen con elevados niveles de intensidad (Ayuda técnica IDL). Para el caso del código implementado, este actúa detectando y destacando las zonas con mayor intensidad (que es el suelo). Éste último filtrado pretende realzar las zonas de suelo. Esto se debe a que la función *watershed* utiliza los mínimos locales de la imagen para la detección de las cuencas, por lo que al invertir la imagen, las copas de los árboles se convierten en los mínimos, y al realzar el suelo, se realzan los bordes de las cuencas facilitando así la segmentación y la detección de los bordes elevados.

Como último paso, se utiliza la función *watershed* antes explicada con la imagen filtrada con *TopHat*. El programa devuelve una imagen de contornos que son los límites de las cuencas y otra imagen con las cuencas completas en escala de grises.

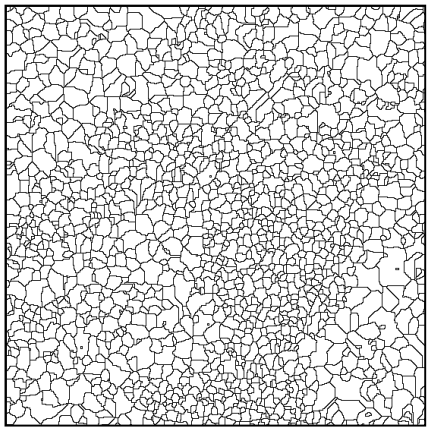

Figura 3.43. Contornos de la segmentación.

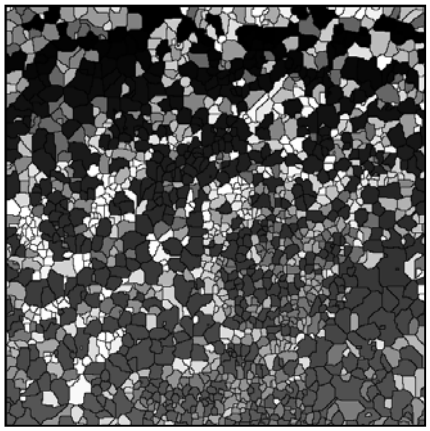

Figura 3.44. Segmentación por polígonos.

Una vez que se tienen los contornos, de forma externa al programa implementado en IDL, se vectorizan los contornos y se generan polígonos a partir de estos. De la misma forma, los polígonos se pueden autogenerar a partir de la imagen en escala de grises, el problema que surgió al realizar esta generación es que entre polígono y polígono se dejaban huecos en blanco, por lo que se decidió realizar directamente la vectorización lineal y luego la generación de polígonos a partir de los contornos.

Analizando los resultados gráficamente se puede observar que los contornos se ajustan bastante bien a las zonas donde existe una densidad media de árboles, encontrando defectos de segmentación en aquellas zonas más densas de árboles o en aquellas zonas donde se encuentran árboles dispersos, donde los polígonos son más grandes con mayor superficie de suelo o matorral.

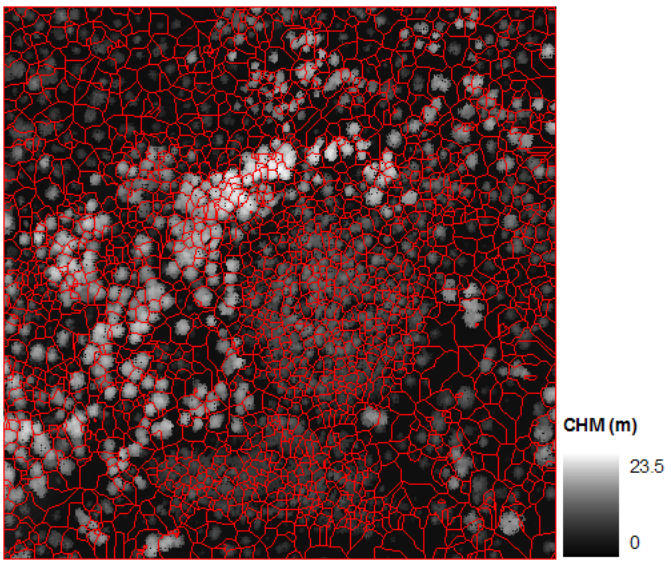

Figura 3.45. Segmentos sobre modelo digital.

A pesar de encontrar este tipo de errores en la segmentación inicial, para conseguir la clasificación de cada uno de ellos se tuvo que realizar una clasificación orientada a objeto para lo que se realizó en un primer lugar una clasificación por píxel de la zona de estudio y posteriormente la clasificación por objeto, asignando a cada polígono la información espectral de segmentación espacial.

3.5. Clasificación por píxel

La clasificación que se realizó se utilizó, como se ha comentado anteriormente, para poder asignar a cada una de las parcelas segmentadas un valor diferente entre suelo, matorral o árbol siendo este último el que interesa especialmente para el trabajo.

En un primer paso se escogieron las muestras para realizar la clasificación. Estas muestras se tomaron sobre la ortofoto RGB del PNOA para poder distinguir bien las diferentes clases. Con estas muestras se realizaron varias clasificaciones con varias combinaciones de bandas para poder evaluar cuál de todas las combinaciones entre bandas proporcionaban mejores resultados en la clasificación.

Antes de comenzar el estudio de separabilidades y poder comparar las gráficas así como los resultados finales, se normalizaron las bandas. Los valores entre algunas de las bandas eran muy diferentes y no estaban en un mismo rango de valores, lo que posteriormente habría dificultado la evaluación entre estas. La normalización de las bandas es muy sencilla ya que solo hay que dividir todos los valores de los píxeles entre el valor máximo menos mínimo que presenta cada una de las bandas.

A continuación se muestra un ejemplo de normalización para la banda IR del recorte de la muestra que se está utilizando para el desarrollo de la metodología.

Como se puede observar en la figura del histograma de la banda IR, el rango de valores de la imagen oscila entre 19 y 255 niveles digitales (figura 3.46). Para realizar la normalización se dividen todos los valores de la banda IR por el valor máximo-mínimo de esta, que para este ejemplo es el valor de 236. El resultado se muestra en la figura 3.47.

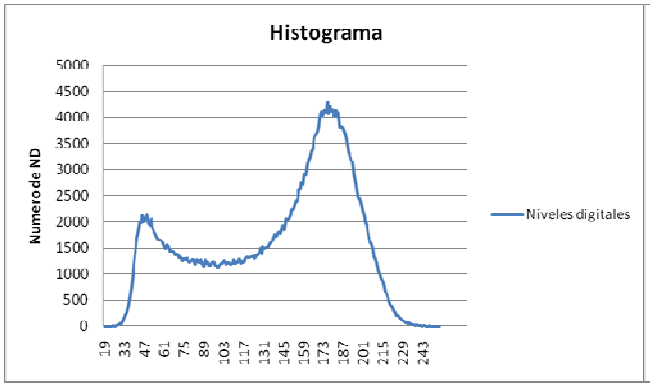

Figura 3.46. Histograma de la banda IR del recorte de estudio.

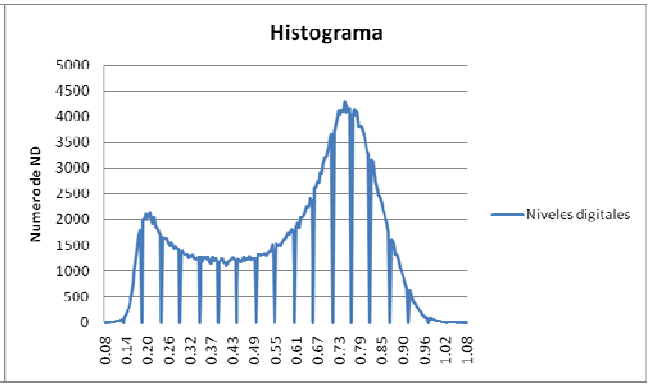

Figura 3.47. Histograma de la banda IR del recorte de estudio normalizada.

Una vez normalizadas todas las bandas se calculó la separabilidad entre estas para ver cuál de ellas es la que mejores resultados ofrecía.

Para la clasificación es muy importante realizar la toma de muestras de forma rigurosa sobre todo para la clase árbol ya que éstos se pueden ver algo desplazados en la imagen RGB

debido a los procesos fotogramétricos en comparación con los modelos digitales, como el modelo normalizado de vegetación, que no presentará desplazamiento debido a la naturaleza de sus datos (datos LIDAR) a no ser que haya algún error en los sistemas de posicionamiento. En otros trabajos se realiza una corrección geométrica (Viñas et al., 2009) que no se realizó en este debido a que las imágenes de partida ya estaban ortorectificadas por el PNOA. A pesar de esto, se puede seguir cometiendo un pequeño desplazamiento al no trabajar con los mismos datos base. Las muestras de las clases no tienen por qué ser muy grandes sino que deben ser significativas.

Los dos estudios de separabilidad y clasificación que se muestran a continuación son imágenes independientes de datos multiespectrales diferentes: unas imágenes corresponden al PNOA con una resolución espacial de 0.5 metros y otras son imágenes IKONOS con una resolución de 1 metro. A partir de estas se estudió la separabilidad que muestran las bandas y las estadísticas de las clasificaciones para poder realizar una buena clasificación final y continuar con la metodología.

3.5.1. Clasificación BGR-IR-NDVI-CHM PNOA

En una primera clasificación se tomaron como bandas las tres bandas del espectro visible, la banda infrarroja, el índice de vegetación normalizado o NDVI calculado a partir de las ortofotos IR del PNOA y como última banda el modelo de vegetación normalizado al suelo o CHM. Las muestras que se tomaron para esta clasificación fueron las mismas para todas las clasificaciones que se realizaron. De esta forma se evaluaron las mismas muestras para las diferentes combinaciones de bandas realizadas.

Las regiones tomadas para la primera clasificación muestran la siguiente separabilidad utilizando el método de Jeffries-Matusita modificado para obtener unos resultados entre 2 y 0:

		Suelo	***Matorral***	***Árbol***
BGR-IR-NDVI-CHM PNOA	***Suelo***	-	1.98449163	1.99999851
	Matorral	1.98449163	-	1.9818867
	Árbol	1.99999851	1.9818867	-

Tabla 3.7. Tabla de separabilidad Jeffries-Matusita entre muestras PNOA.

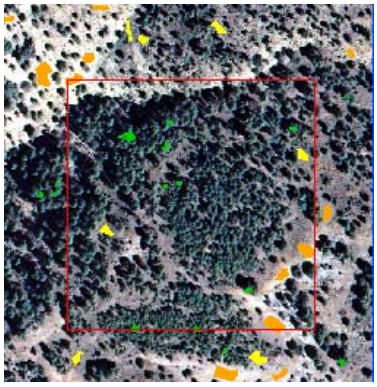

Figura 3.48. Zona de estudio con muestras de estudios de las diferentes clases.

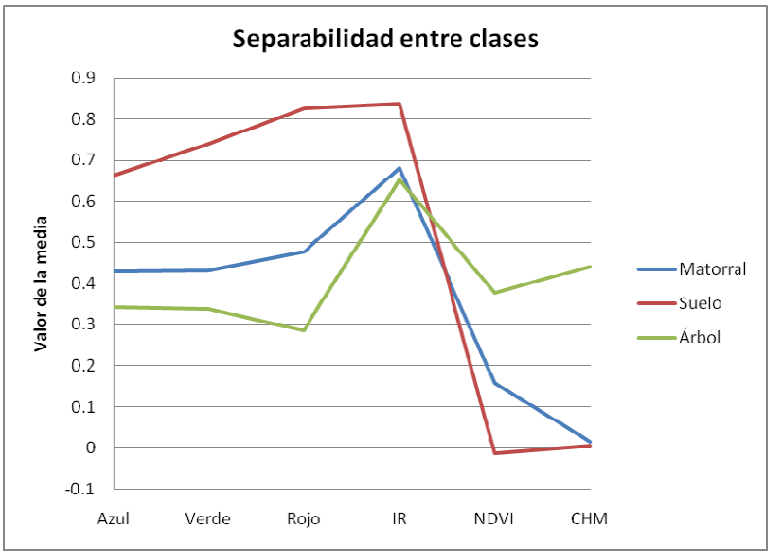

Figura 3.49. Tabla de separabilidad bandas azul, verde, rojo, IR, NDVI del PNOA y CHM.

Se puede ver que los valores de separabilidad entre los diferentes tipos de muestras son elevados (valor máximo de 2) y por lo tanto aceptables. Las separabilidades entre las muestras en las diferentes bandas utilizadas también son apreciables en la figura 3.49. Las bandas que menor separabilidad tienen entre las muestras estudiadas son las bandas del infrarrojo (IR) y la banda del modelo de vegetación (CHM). En el caso del infrarrojo la separabilidad es pequeña entre la clase matorral y árbol, lo cual perjudica a la metodología ya que el interés principal de la clasificación es separar claramente los árboles del resto de cubiertas. En el caso del modelo de vegetación, la menor separabilidad se produce entre suelo y matorral, y con respecto a estas, la clase árbol está bien diferenciada. Vista la separabilidad entre las clases, se realizó una clasificación supervisada de máxima probabilidad en la que se obtuvo la clasificación que se muestra en la siguiente figura (figura 3.50):

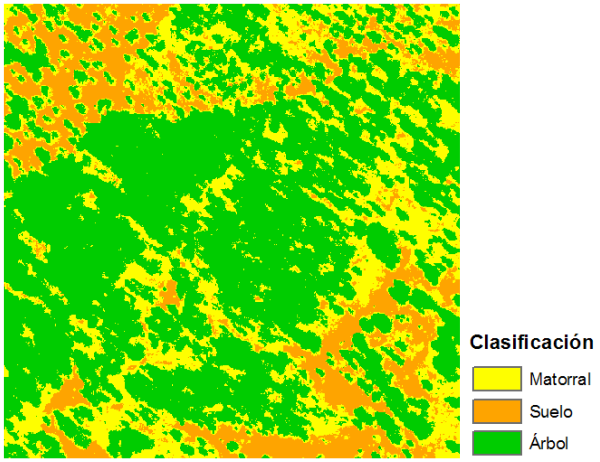

Figura 3.50. Clasificación BGR-IR-NDVI PNOA y CHM.

Figura 3.51. Recorte RGB-PNOA.

Tras la realización de un estudio visual de la clasificación obtenida con las imágenes en RGB, IR y con el CHM se calculó la matriz de confusión utilizando muestras o ROIs "verdad terreno" considerando estas como muestras veraces sobre la realidad del terreno. Estas muestras son las que también se utilizaron para las posteriores clasificaciones que se realizaron. La matriz de confusión resultante es la siguiente:

		Ground Truth (Pixeles)				*Ground Truth (Porcentajes)*			
		Matorral	**Suelo**	**Árbol**	**Total**	**Matorral**	**Suelo**	**Árbol**	**Total**
Clases	**Suelo**	803	66	0	969	9.9%	9.1%	0.0%	9.1%
	Matorral	1	1631	1	1633	0.1%	9.2%	.1%	2.4%
	Árbol	0	32	404	1436	0.0%	1.8%	99.9%	28.5%
	Total	1804	1829	1405	5038	-	-	-	100.0%

Tabla 3.8. Matriz de confusión clasificación BGR-IR-NDVI PNOA y CHM.

Los errores y estadísticas se muestran en las tablas 3.9, 3.10 y 3.11:

		Píxeles		*Porcentajes*	
		Exceso	**Defecto**	**Exceso**	**Defecto**
Clases	**Suelo**	166/1969	1/1804	8.4%	0.1%
	Matorral	2/1633	198/1829	0.1%	10.8%
	Árbol	32/1436	1/1405	2.2%	0.1%

Tabla 3.9. Tabla de errores defecto/exceso de la clasificación BGR-IR-NDVI PNOA y CHM.

		Píxeles		*Porcentajes*	
		Productor	**Usuario**	**Productor**	**Usuario**
Clases	**Suelo**	1803/1804	1803/1969	99.9%	91.6%
	Matorral	1631/1829	1631/1633	89.2%	99.9%
	Árbol	1404/1405	1404/1436	99.9%	97.8%

Tabla 3.10. Tabla de fiabilidades de productor y usuario de la clasificación BGR-IR-NDVI PNOA y CHM.

Fiabilidad Global	(4838/5038) 96.0%
Coeficiente Kappa	0.94

Tabla 3.11. Estadísticos de la clasificación CHM y NDVI PNOA.

Tras analizar los resultados se observó una fiabilidad global de un 96%, lo que significa que se cometieron muy pocos errores en la clasificación indicando una relación alta entre los píxeles clasificados correctamente y los píxeles totales de la imagen.

El coeficiente Kappa con valor en la clasificación de 0.94 expresa la reducción del error al aplicar la clasificación respecto al error que se hubiera producido realizando una asignación aleatoria. Se utiliza como parámetro de calidad y sus valores van desde 0 a 1 siendo 1 el valor que indica el máximo acuerdo con la clasificación, por lo que se puede decir que la clasificación que se realizó es de gran calidad.

La fiabilidad del productor relaciona los píxeles asignados a una clase y los totales existentes de esa clase, es decir, la probabilidad de que un píxel perteneciente a una clase sea clasificado correctamente. Las fiabilidades del productor en la clasificación son elevadas, siendo la menor probabilidad un 89.2% en la clase matorral y la mayor un 99.94% en la clase suelo.

En la fiabilidad del usuario se relacionan los píxeles asignados a una clase con los píxeles totales clasificados como esa clase, es decir, indica la probabilidad de que un píxel clasificado en la imagen le corresponda realmente esa clase en la realidad. En esta columna seguimos encontrando unos valores elevados de probabilidades siendo la menor de 91.57% para la clase suelo y la mayor del 99.9% la de la clase matorral.

Por último se tienen los valores de error por exceso y por omisión. El error por comisión o exceso es aquel que hace referencia a los píxeles que sin pertenecer a una clase en las muestras de partida se han clasificado dentro de esa clase. El error por omisión indica los píxeles que perteneciendo a una clase se han asignado en la clasificación a otras. Ambos errores para las diferentes clases creadas son pequeños salvo el error por exceso de la clase suelo de 8.4% y el error por exceso de la clase matorral con un valor de 10.83%.

Los resultados que se obtuvieron para esta primera clasificación son muy aceptables con errores bajos y probabilidades elevadas de ambas fiabilidades así como una fiabilidad global y un coeficiente kappa muy buenos. Esta clasificación se mejoró eliminando algunas de las bandas que presentaban poca separabilidad.

3.5.2. Clasificación BGR-IR-NDVI-CHM IKONOS

Para esta segunda clasificación se utilizaron las mismas bandas que para la clasificación anterior pero con origen en el satélite IKONOS. Estas bandas presentaban una menor resolución espacial que las del PNOA por lo que para poder estudiarlas a un mismo nivel junto con el modelo de vegetación a 0.5 metros, se realizó un remuestreo a las imágenes IKONOS. Como se ha comentado anteriormente, las muestras utilizadas son las mismas que se que se utilizaron para la anterior clasificación.

A continuación se pueden ver los resultados de la separabilidad de las clases entre las dos bandas (Tabla 3.12).

BGR-IR-NDVI-CHM IKONOS		Suelo	Matorral	Árbol
	Suelo	-	1.78993161	1.95656233
	Matorral	1.78993161	-	1.42902407
	Árbol	1.95656233	1.42902407	-

Tabla 3.12. Tabla de separabilidad Jeffries-Matusita entre muestras IKONOS.

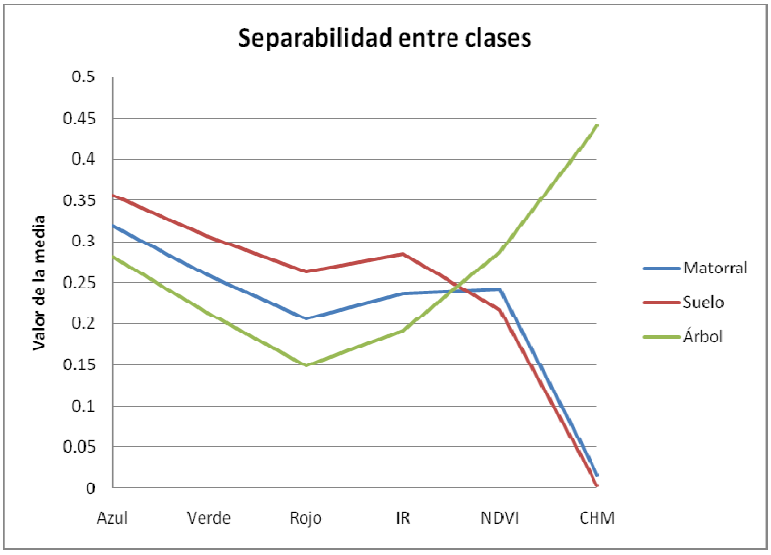

Figura 3.52. Tabla de separabilidad bandas azul, verde, rojo, IR, NDVI de IKONO y CHM.

En este caso, se puede ver que la separabilidad entre clases es inferior que en el caso anterior. La separabilidad entre la clase de matorral y árbol es demasiado baja, cosa que no interesa para este trabajo, en cambio se puede observar que la separabilidad entre matorral y árbol es elevada cuando se utiliza el CHM. La banda en la que menor separabilidad hay es en la banda del índice de vegetación (NDVI). Para la banda correspondiente al modelo de vegetación, la clase árbol está bien diferenciada, como en el caso anterior, pero para suelo y matorral no lo es. Esto es debido a que el matorral, a pesar de tener una respuesta espectral más parecida a la clase árbol, no presenta la altura suficiente como estos, y es por esto que presenta poca separabilidad con el suelo.

La matriz de confusión se muestra en la tabla 3.13. Si se analiza se puede ver que la clase mejor clasificada es la clase de matorral mientas que la peor clasificada es la clase suelo. Para este trabajo se debe buscar una buena clasificación para las diferentes clases escogidas ya que la propia clasificación puede introducir errores en la posterior clasificación orientada a objetos que se realizó como paso previo a una segunda parte de segmentación.

Los errores por comisión de la clase matorral son muy elevados aunque tengan un alto porcentaje de acierto en la fiabilidad del productor. A pesar de que la clase árbol muestre valores correctos en ambas tablas, esta clasificación no se dio por válida debido a estos datos estadísticos.

No se deben olvidar los estadísticos globales como la fiabilidad global que resulta baja así como el índice de calidad.

		Ground Truth (Pixeles)				*Ground Truth (Porcentajes)*			
		Matorral	*Suelo*	*Árbol*	*Total*	*Matorral*	*Suelo*	*Árbol*	*Total*
Clases	***Matorral***	1642	1219	59	2920	91.0%	66.7%	4.2%	58.0%
	Suelo	160	579	126	865	8.9%	31.7%	9.0%	17.2%
	Árbol	2	31	1220	1253	0.1%	1.7%	86.8%	24.9%
	Total	1804	1829	1405	5038	-	-	-	100.0%

Tabla 3.13. Matriz de confusión clasificación BGR-IR-NDVI IKONOS y CHM.

		Píxeles		*Porcentajes*	
		Exceso	Defecto	Exceso	Defecto
Clases	**Suelo**	1278/2920	162/1804	43.8%	9.0%
	Matorral	286/865	1250/1829	33.1%	68.3%
	Árbol	33/1253	185/1405	2.6%	13.2%

Tabla 3.14. Tabla de errores omisión/comisión de la clasificación BGR-IR-NDVI IKONOS y CHM.

		Píxeles		*Porcentajes*	
		Productor	Usuario	Productor	Usuario
Clases	**Suelo**	1642/1804	1642/2920	91.0%	56.2%
	Matorral	579/1829	579/865	31.7%	66.9%
	Árbol	1220/1405	1220/1253	86.8%	97.4%

Tabla 3.15. Tabla de fiabilidades de productor y usuario de la clasificación BGR-IR-NDVI IKONOS y CHM.

Fiabilidad Global	(3441/5038) 68.3%
Coeficiente Kappa	0.52

Tabla 3.16. Estadísticos de la clasificación BGR-IR-NDVI IKONOS y CHM.

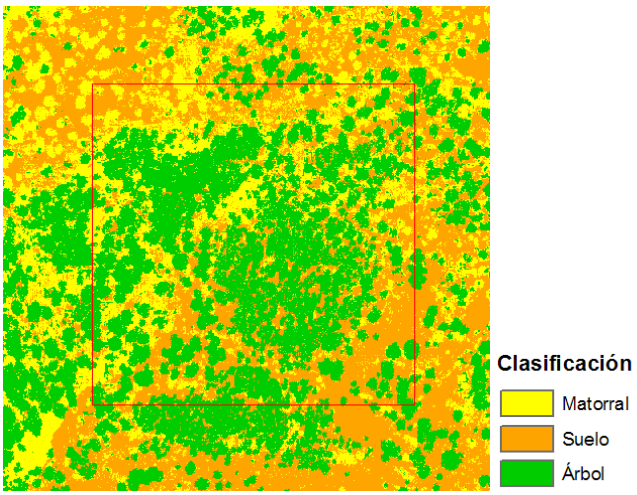

Figura 3.53. Clasificación BGR-IR-NDVI IKONOS y CHM

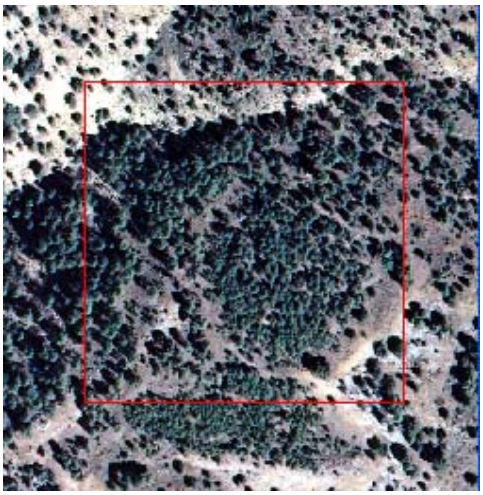

Figura 3.54. Recorte RGB-PNOA.

A pesar de que visualmente parezca que se haya realizado una buena clasificación, hay muchas zonas clasificadas como suelo o matorral en vez de ser clasificadas como árbol sobre todo en aquellas zonas fuera de las masas forestales donde hay mayor número de árboles dispersos.

Los resultados de esta clasificación se atribuyen en gran parte al remuestreo realizado por la necesidad de tener una resolución espacial de 0.5 metros para una posterior mejor segmentación.

3.5.3. Clasificación GR-NDVI-CHM PNOA

Vista la clasificación realizada con todas las bandas del PNOA con su respectivo índice de vegetación y el modelo digital de vegetación normalizado, se realizó otra clasificación utilizando aquellas bandas más propicias (cuya separabilidad es mayor en los tres tipos de muestras) para conseguir una mejor clasificación así como unos mejores resultados estadísticos.

Las bandas utilizadas son las bandas del verde (G), el rojo (R), el índice de vegetación (NDVI) y el modelo digital de vegetación normalizado (CHM). La separabilidad que presentan estas es muy aceptable para las tres clases que se desea clasificar. La única banda que presenta una separabilidad algo diferente es la del modelo digital de vegetación pero esta no fue eliminada ya que introducía una fuerte separabilidad entre árbol y las demás clases. Nunca hay que olvidar que el objetivo de esta clasificación es la de diferenciar de forma correcta la clase árbol para la posterior segmentación.

		Suelo	*Matorral*	*Árbol*
BGR-IR-NDVI-CHM IKONOS	*Suelo*	-	1.96755057	1.99999183
	Matorral	1.96755057	-	1.93335473
	Árbol	1.99999183	1.93335473	-

Tabla 3.17. Tabla de separabilidad Jeffries-Matusita entre muestras GR-NDVI PNOA y CHM.

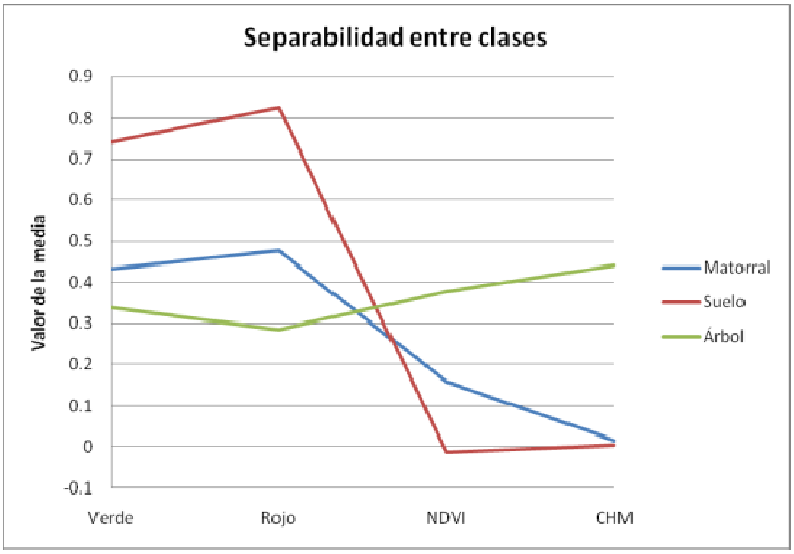

Figura 3.55. Tabla de separabilidad bandas verde, rojo, NDVI del PNOA y CHM.

Las separabilidades resultantes de combinar estas bandas son algo menores que en el primer estudio que se realizó al utilizar todas las bandas del PNOA, pero analizando los estadísticos y la matriz de errores se observaron mejores resultados.

		Ground Truth (Pixeles)				*Ground Truth (Porcentajes)*			
		Suelo	**Matorral**	**Árbol**	**Total**	**Suelo**	**Matorral**	**Árbol**	**Total**
Clases	**Suelo**	1802	98	0	1900	99.9%	5.4%	0.0%	37.7%
	Matorral	2	1700	1	1703	0.1%	93.0%	0.1%	33.8%
	Árbol	0	31	1404	1435	0.0%	1.7%	99.9%	28.5%
	Total	1804	1829	1405	5038	-	-	-	100.0%

		Píxeles		Porcentajes	
		Exceso	Defecto	Exceso	Defecto
Clases	Suelo	98/1900	2/1804	5.2%	0.1%
	Matorral	3/1703	129/1829	0.2%	7.1%
	Árbol	31/1435	1/1405	2.2%	0.1%

Tabla 3.19. Tabla de errores omisión/comisión de la clasificación GR-NDVI PNOA y CHM.

		Píxeles		Porcentajes	
		Productor	Usuario	Productor	Usuario
Clases	Suelo	1802/1804	1802/1900	99.9%	94.8%
	Matorral	1700/1829	1700/1703	93.0%	99.8%
	Árbol	1404/1405	1404/1435	99.9%	97.8%

Tabla 3.20. Tabla de fiabilidades de productor y usuario de la clasificación GR-NDVI PNOA y CHM.

Fiabilidad Global	(4906/5038) 97.4%
Coeficiente Kappa	0.96

Tabla 3.21. Estadísticos de la clasificación GR-NDVI PNOA y CHM.

Los resultados en la matriz de confusión son muy buenos en los tres tipos de muestras con el valor más pequeño en la clase matorral con un 93% (tabla 3.20). Las otras dos han sido bien clasificadas casi el 100%. Los errores cometidos son bajos tanto por omisión como por exceso y las fiabilidades de usuario y productor son bastante altas. La fiabilidad de esta clasificación es superior a las dos anteriores así como el índice de calidad o coeficiente kappa.

En la siguiente tabla se comparan los resultados de fiabilidad global y coeficiente kappa de las tres clasificaciones que se realizaron.

	Fiabilidad global	Coeficiente Kappa
BGR-IR-NDVI-CHM PNOA	(4838/5038) 96.0%	0.94
BGR-IR-NDVI-CHM IKONOS	(3441/5038) 68.3%	0.52
GR-NDVI-CHM PNOA	(4906/5038) 97.4%	0.96

Tabla 3.22. Tabla resumen de fiabilidades Jeffries-Matusita y coeficientes Kappa.

Comparando todas las fiabilidades globales de las clasificaciones así como el índice de calidad, y las fiabilidades del productor y del usuario por clases, se obtuvo que la mejor clasificación que se realizó fue esta última con la que se obtuvieron, como era de esperar, los mejores resultados al escoger las bandas que mejor se adecuaban al trabajo una vez estudiada su separabilidad. Esta tercera clasificación (clasificación con las bandas verde, roja, índice de vegetación pertenecientes al PNOA y el modelo de vegetación normalizado) es con la que se continuó para el desarrollo de la metodología por los resultados obtenidos en comparación con las anteriores.

Al considerar la clasificación GR-NDVI-CHM del PNOA como la mejor clasificación calculada, se realizó el proceso de suavizado en la post-clasificación utilizando una ventana de

cálculo de 3 x 3 píxeles. El filtro que se utilizó fue un filtro de moda, de esta forma, se eliminaron los píxeles aislados que pudieran haber sido mal clasificados. No se escogió otro tipo de filtro ya que consideró que otro filtro podría haber realizado una generalización más fuerte que el filtro de moda. El resultado de la post-clasificación se puede observar en la siguiente figura (figura 3.56):

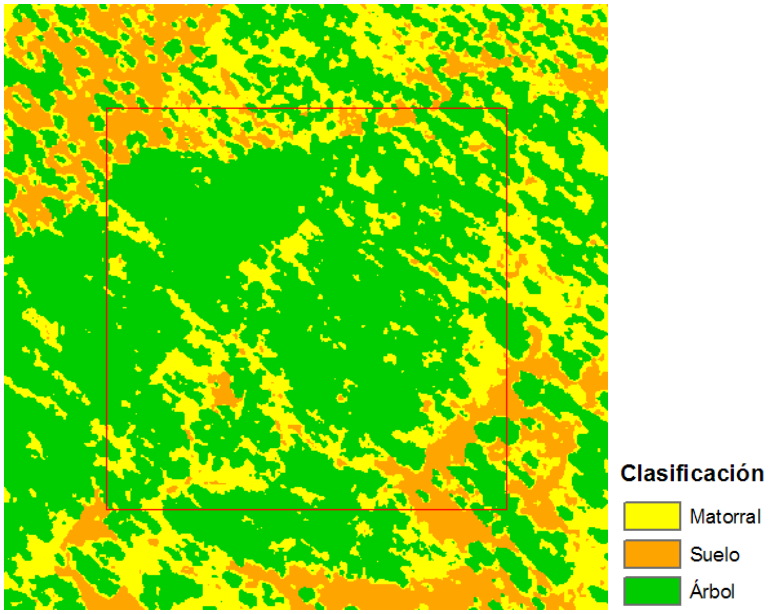

Figura 3.56. Post-clasificación GR-NDVI PNOA y CHM

3.6. Clasificación orientada a objeto

La clasificación orientada a objeto a realizar consiste en la asignación de las variables multiespectrales calculadas en la clasificación por píxel a los resultados poligonales de la primera segmentación. De esta forma se asignaron a cada uno de los polígonos segmentados la clase de suelo, matorral o árbol.

Para la realización de este procedimiento se utilizó el software FETEX 2.0 del grupo de investigación de Cartografía GeoAmbiental y Teledetección (CGAT). El software toma la imagen de la clasificación anterior por píxel para dar valores a los polígonos que están en formato *shape* calculando el mínimo, el máximo y la moda (entre otras variables) de los valores de los píxeles para asignarlos a cada uno de los segmentos (Ruiz et al. 2009). Para clasificar los polígonos se utiliza la moda, as otras variables se adjuntan en la tabla del *shape* resultante.

Los resultados de la clasificación orientada a objeto son un nuevo *shape* con los segmentos en el que se ha asignado a cada polígono las anteriores variables y por lo tanto clasificado como suelo, matorral o árbol y una tabla con los identificadores de segmento o parcela y las nuevas variables asignadas a cada una de ellas.

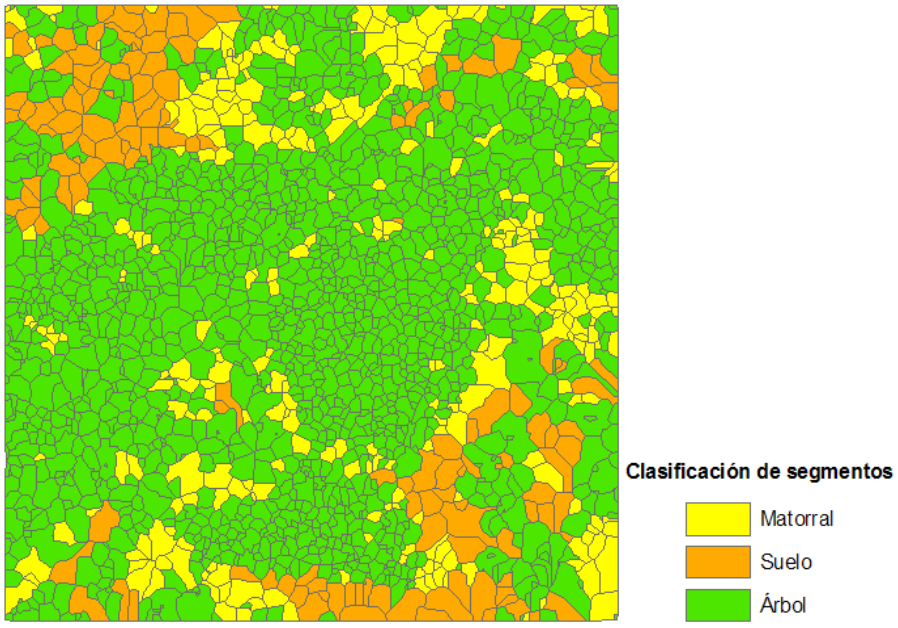

Figura 3.57. Clasificación objeto de los segmentos.

Para poder evaluar la clasificación por objeto se tomaron alrededor de 30 muestras de cada una de las clases y se les asignó manualmente la clase a la que pertenecía observando una a una en la ortofoto. Los resultados que se obtuvieron se muestran en la tabla 3.23.

		Evaluación			
		Matorral	Suelo	Árbol	Total general
Clasificación	Matorral	22	7		29
	Suelo	5	25	2	32
	Árbol	3		28	31
	Total general	30	32	30	92
					81.5%

Tabla 3.23. Matriz de confusión de la clasificación por objeto.

La fiabilidad total de la clasificación orientada a objeto es del 81.5%. De la matriz de confusión también se calcularon los siguientes porcentajes de probabilidad:

Fiabilidad del productor	
Matorral	73.3%
Suelo	78.1%
Árbol	93.3%

Tabla 3.24. Fiabilidades del productor.

Fiabilidad del usuario	
Matorral	75.9%
Suelo	78.1%
Árbol	90.3%

Tabla 3.25. Fiabilidades del usuario.

Como se puede observar, se obtienen valores altos en ambas tablas de fiabilidades. La clase mejor clasificada fue la clase árbol un 93.3% y una fiabilidad de usuario también elevada. Esta es la clase que más interesa para este trabajo. A pesar de ello, las clases matorral y suelo no presentaron una fiabilidad tan alta como la anterior pero si aceptable tanto en la fiabilidad del productor como en la del usuario.

Aun teniendo valores estadísticos aceptables para la clasificación realizada, se considera que estos valores son orientativos, ya que hay muchas parcelas y de tamaños muy grandes, en las que puede haber un árbol y haber sido clasificado como suelo o matorral. A pesar de ello, esta clasificación aportó una idea general para la clasificación de cada segmento.

Tras esta clasificación, se obtuvo una primera segmentación en la que se podía diferenciar los diferentes segmentos y sus clases de una forma generalizada, como se ha comentado anteriormente. Analizando la segmentación gráficamente y junto con los datos estadísticos calculado, parece que la segmentación da buenos resultados, pero este método no especifica la posición exacta del árbol y hay segmentos demasiado grandes para que estos fueran árboles. La solución del primer error tenía fácil solución como el de calcular los geocentros de cada polígono y situar así cada árbol, pero el segundo problema seguía presente.

A pesar de situar los geocentros y considerarlos como árboles, surgieron varias incógnitas al realizar un análisis de la imagen a nivel de parcela ya que se encontraron casos en los que las parcelas más grandes presentaban varios árboles en su interior o incluso parcelas

en las que había algún árbol pero que debido a la mayoría de los píxeles vecinos habían sido clasificadas con otra clase (figuras 3.58 y 3.59).

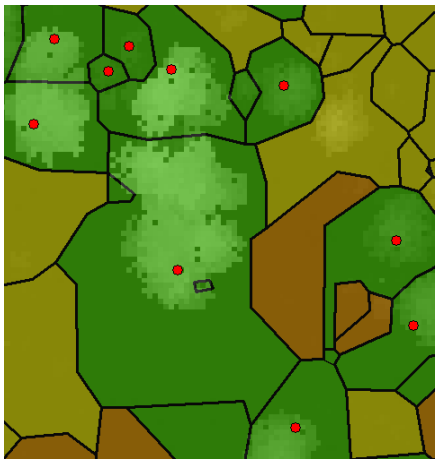

Figura 3.58. Error de segmentación. Varios árboles en una parcela no detectados y mal localización de árbol.

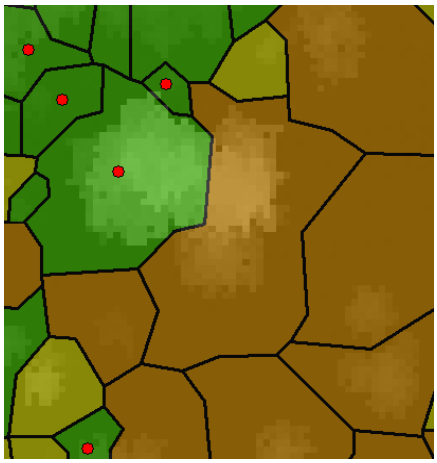

Figura 3.59. Error de segmentación. Árbol no detectado en una parcela clasificada como suelo y mal localización de árbol.

En la figura 3.58 se observa una gran parcela o segmento clasificado como un único árbol (color verde) en el que se pueden diferenciar más árboles produciéndose así un error por defecto. En la figura 3.59 se puede ver otros errores diferentes como es la mala clasificación de un segmento en el que hay claramente un árbol y el segmento es clasificado como matorral (color naranja) y el error del mal posicionamiento de un árbol en la parcela contigua, en la que el punto rojo que marca el árbol está desplazado debido a que este se ha calculado a partir de su geocentro.

Detectados estos tipos de errores se propuso una nueva metodología de segmentación a partir de la ya realizada a la que se le llamó post-segmentación que tenía como objetivo la mejor determinación de la situación y conteo de los árboles.

3.7. Post-segmentación

El proceso de post-segmentación consiste en la detección de los árboles y de sus copas a nivel de segmento calculado en la primera segmentación y de esta forma, mejorar los resultados obtenidos.

Para la post-segmentación se plantearon varias alternativas a partir de los resultados de la primera segmentación. En un principio se propuso una nueva segmentación *watershed* a nivel de parcela, ya que muchos trabajos realizados calculaban una segmentación por *watershed* a partir de una primera detección de árboles realizada por otro tipo de algoritmos con el fin de encontrar el contorno de los árboles (Hirata et al., 2009). Los resultados de trabajar con watershed a nivel de parcela no fueron satisfactorios ya que se producía una falta de segmentación en zonas densas de árboles y una sobresegmentación en aquellas zonas más dispersas.

A diferencia de la forma general de trabajo de detección de unidad de árbol y posterior delineación de copas (Yu et al., 2010), la post-segmentación propuesta realiza la detección de árboles y la delineación sin utilizar el algoritmo *watershed* partiendo de la base de la primera segmentación, es decir, a partir de la segmentación inicial, detecta la unidad de árbol trabajando a nivel de segmento y realiza la posterior delineación de las copas.

Esta segmentación a nivel de segmento o post-segmentación sigue una metodología más compleja que la segmentación inicial. En un primer momento, esta post-segmentación trabajaba sobre toda la imagen aplicando los filtros necesarios sobre su extensión total. Posterior a este filtrado se trabajaba a nivel de segmento para la detección de los árboles. Una vez programada toda la aplicación y desarrollada toda la metodología, la imagen de la zona de estudio no podía procesarse debido a sus grandes dimensiones, por lo que fue necesario el desarrollo de una nueva metodología que trabajara en su totalidad a nivel de segmento. Esta nueva metodología se resume en la siguiente figura (figura 3.60):

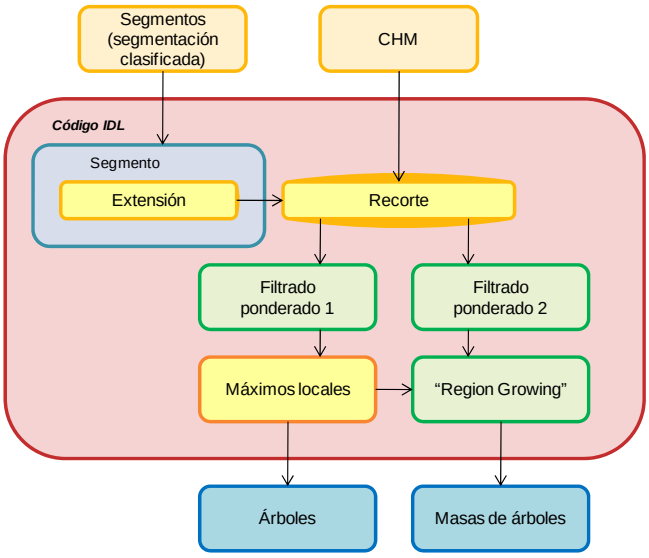

Figura 3.60. Esquema general de la post-segmentación.

El esquema muestra los procedimientos seguidos para la post-clasificación en la que se introduce la imagen del modelo de vegetación y el fichero *shape* con los segmentos y su tabla de atributos. Para cada segmento se aplica un filtrado y posteriormente el algoritmo detección de árboles que, para esta segunda clasificación es el algoritmo de máximos locales. Tras la detección de los máximos se detecta la extensión aproximada de las masas forestales. La aplicación devuelve como resultado los árboles en forma de puntos y las masas forestales detectadas en forma de polígonos.

En la detección de la unidad de árbol, uno de los algoritmos más empleados es el algoritmo de máximos locales. El algoritmo de máximos locales es una forma de aislar y caracterizar la unidad de árbol. Este está basado en la suposición de que la reflectancia, o en este caso la altura, 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 nivel digital mayor al resto de sus vecinos de la ventana (Recio, J.A., 2009). El problema que presenta este algoritmo de máximos locales es el tamaño relacionado con la ventana de búsqueda. El algoritmo cometerá un error por exceso en la detección de los árboles si la ventana de búsqueda es demasiado pequeña en comparación con las copas de los árboles, mientas que si la ventana es demasiado grande, se cometerá un error por defecto u omisión. Muchos autores utilizan este algoritmo para la detección y situación de la unidad de árbol (Wulder et al., 2000; Pouliot et al., 2002; Leckie et al., 2005) como paso inicial de la segmentación utilizando estos como puntos semilla. Para este trabajo, se realiza como parte final de la detección de árboles tras realizar una segmentación inicial.

La aplicación programada comienza leyendo la imagen completa del modelo de vegetación y posteriormente cargando el fichero *shape* con los polígonos o segmentos y sus atributos. Dependiendo de los atributos del registro o segmento, este continúa o no con la segmentación del registro o segmento.

Cada registro/segmento contiene varias columnas de atributos calculadas en la clasificación orientada a objeto. El código lee el atributo de la variable dependiendo del caso máximo o mínimo en busca del valor correspondiente al árbol. Si la parcela contenía un píxel clasificado como árbol, se continúa con el proceso de segmentación para dicha parcela. En caso contrario el código pasa al siguiente registro. Una vez detectado el valor de árbol se toma la extensión de cada registro para realizar un recorte sobre la imagen completa y evitar así problemas de memoria del ordenador. Una vez realizado el recorte correspondiente al registro, se le aplica el filtro de ponderación de bordes utilizado en la primera segmentación (Recio, 2009), y sobre este recorte se aplicaba la detección de máximos locales. En el caso de que no se detecte ningún máximo local, el programa continúa con otro registro nuevo.

Una vez detectados los máximos locales del segmento, estos valores se almacenan con sus coordenadas para posteriormente exportarlos a un fichero *shape*. Con estos máximos locales se realiza un crecimiento de regiones para la detección de las masas forestales utilizando como puntos semilla los propios máximos locales calculados. Para la detección de

las áreas o masa arbóreas se implantó una nueva condición para evitar errores en los casos de que las parcelas fueran muy pequeñas. Para esto, se utilizó el área de cada parcela como filtro y decidir si la parcela era lo suficientemente grande o pequeña para realizar o no la detección de las masas arbóreas. La imagen sobre la que se realiza dicho crecimiento de regiones o detección de masas forestales, es la propia imagen del modelo de vegetación filtrada con el filtro ponderado con un número mayor de iteraciones. Para limitar el crecimiento de regiones se utilizó de nuevo el rango definido a partir del mínimo y del máximo, tomando esta vez como máximo el valor del máximo local del segmento, y en el caso de que hubiera más de un máximo local, se tomó el valor del mayor máximo local. El valor mínimo dependía del valor máximo detectado, ya que dependiendo de la altura detectada del máximo, se escogía un umbral menor o mayor para restar sobre la altura máxima y así tener el valor mínimo de crecimiento. Para el crecimiento de regiones se utilizó la misma función que para la segmentación inicial.

Una vez calculado el crecimiento de regiones, se utilizó una función para la detección de los límites del crecimiento. Esta detecta los bordes de objetos en una imagen binaria utilizando los contornos de estos. Una vez detectados los contornos, se guardan en un fichero para después poder exportarlos a formato *shape*.

El proceso de post-segmentación se realiza tantas veces como registros/segmentos haya en el fichero *shape* de entrada e independientemente del tamaño de la imagen siempre y cuando los límites de los registros se sitúen dentro de dicha imagen.

Las imágenes que se muestran a continuación son resultados de la parte de la post-segmentación.

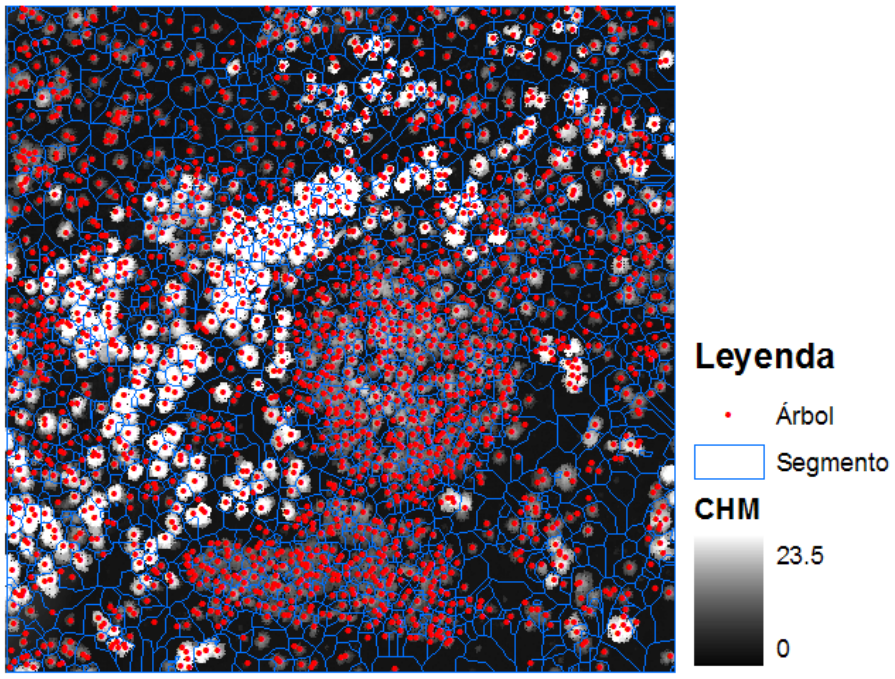

Figura 3.61. Resultado Post-segmentación (Posición de los árboles).

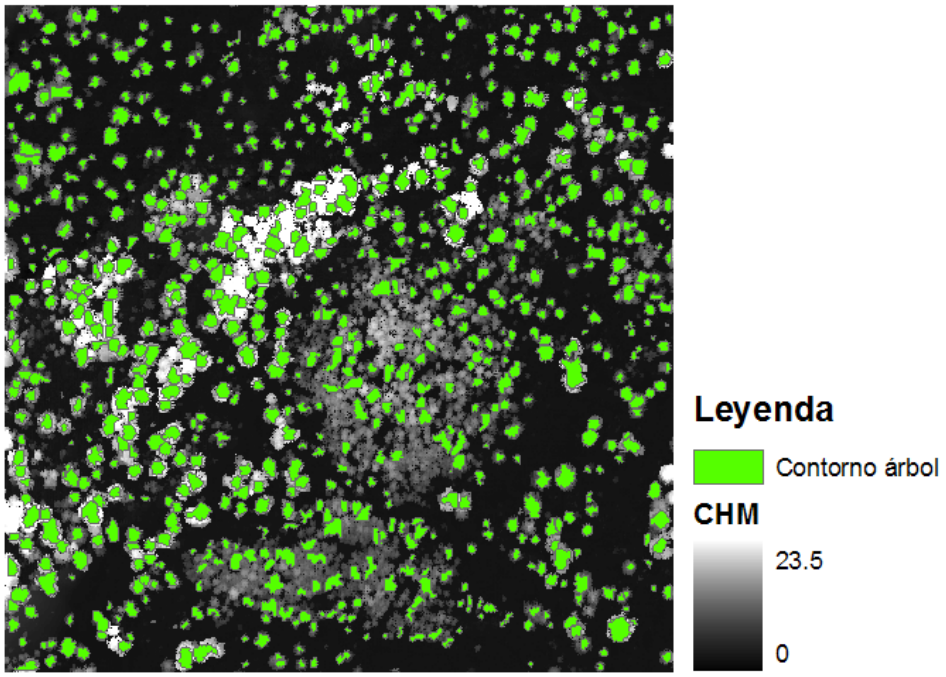

Figura 3.62. Resultado Post-segmentación (Contorno de árboles).

Como se puede ver en las imágenes, el resultado son los contornos de los árboles así como la situación de cada uno. Cada árbol se ve reflejado como un punto y su contorno como polígonos alrededor de estos. Debido a la naturaleza de la segmentación, no todos los contornos de los árboles pudieron ser calculados ya que se producían errores debido al pequeño tamaño de los segmentos.

Una vez calculados el número de árboles y sus coordenadas, se procedió con la evaluación. Esta se centraba en el conteo y en el posicionamiento de los árboles.

3.8. Evaluación

Toda la metodología anterior fue evaluada en una subzona de la imagen. Para la evaluación de todo el procedimiento se ejecutó toda la metodología sobre las parcelas de estudio de las que se tenía información veraz sobre la posición de los árboles.

La evaluación se basó principalmente en dos aspectos. El primero fue el conteo de árboles por parcela y así poder calcular el número de árboles por exceso o por defecto. El segundo método consistía en la precisión con la que se habían detectado dichos árboles. Es decir, a partir de las coordenadas de posición X e Y del árbol, se comparó cada uno con el X e Y de los árboles de referencia y así poder ver las diferencias de posicionamiento.

Para el primer método de evaluación con el identificador de la parcela correspondiente, se contaron los árboles detectados y los de referencia. Los resultados se mostraron en una tabla con los números de árboles calculados, los de referencia y un resumen total de los resultados.

Para comprobar el posicionamiento de los árboles detectados se utilizó un sistema de dianas en el que cada árbol era medido con respecto a su árbol de referencia y así poder observar gráficamente el desplazamiento que había entre ellos. También se calculó para cada parcela la media del desplazamiento producido entre los árboles detectados, la desviación típica, la mediana, el valor de la distancia mínima y el valor de la distancia máxima.

Al comenzar la evaluación de las diferentes parcelas se obtuvieron unos resultados que no estaban acordes con los resultados que se esperaban de la metodología. Analizando los resultados gráficamente no se observaba tanta diferencia entre los resultados obtenidos y la situación de los árboles sobre las ortofotos. Al analizar los datos de referencia tomados en campo se encontraron errores en las parcelas. Los árboles contenidos en estas no coincidían con los datos observados en las ortofotos en cuanto a conteo y a posicionamiento, por lo que se optó por revisar y mejorar dicha información mediante fotointerpretación de las imágenes apoyada con la visualización 3D de los datos LIDAR. Durante el proceso de fotointerpretación se encontraron parcelas en las que los datos no coincidían con la información visual, por lo que se tuvo que situar en estas los árboles manualmente. En otras parcelas se encontró que el conteo de árboles era correcto, pero existía cierto desplazamiento. Este desplazamiento pudo ser debido probablemente a una mala calibración del GPS cuando se realizó la toma de los datos o a cualquier error metodológico producido en cualquier momento del levantamiento de las parcelas. Al final se calcularon un total de 56 parcelas con las que se realizó la evaluación final (Anejo II).

Las siguientes imágenes muestran algunos ejemplos de los errores que se encontraron en las parcelas tomadas en las campañas de campo (figuras 3.63, 3.64, 3.65 y 3.66).

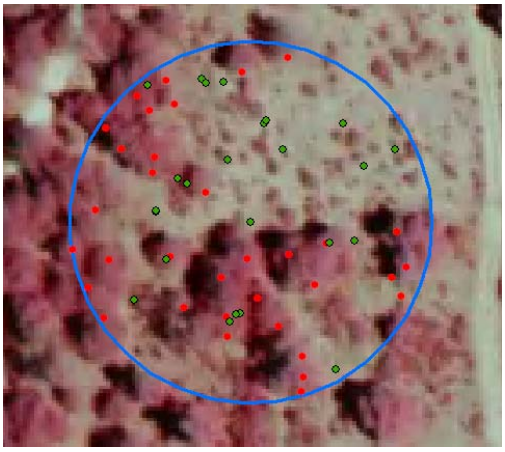

Figura 3.63. Ejemplos de posicionamiento erróneo de los árboles sobre la parcela 3 (los puntos verdes son los datos tomados en campo y los puntos rojos los árboles situados manualmente a partir de los datos LIDAR e imágenes multiespectrales).

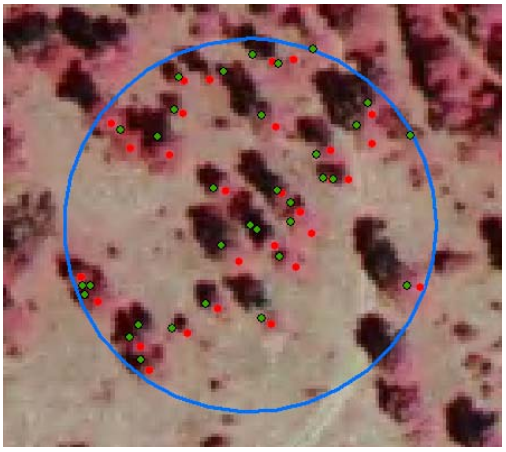

Figura 3.64. Ejemplos de desplazamiento de la situación de los árboles sobre la parcela 6 (los puntos verdes son los datos tomados en campo y los puntos rojos los árboles situados manualmente a partir de los datos LIDAR e imágenes multiespectrales).

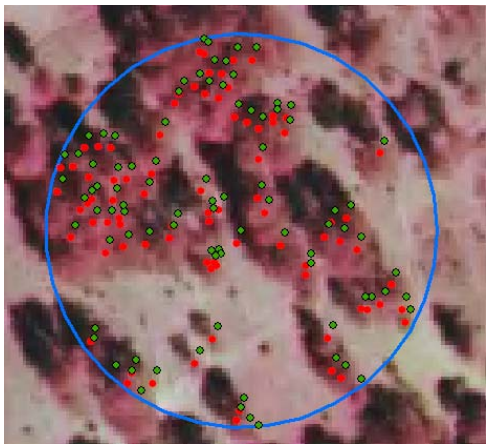

Figura 3.65. Ejemplos de desplazamiento de la situación de los árboles sobre la parcela 11 (los puntos verdes son los datos tomados en campo y los puntos rojos los árboles situados manualmente a partir de los datos LIDAR e imágenes multiespectrales).

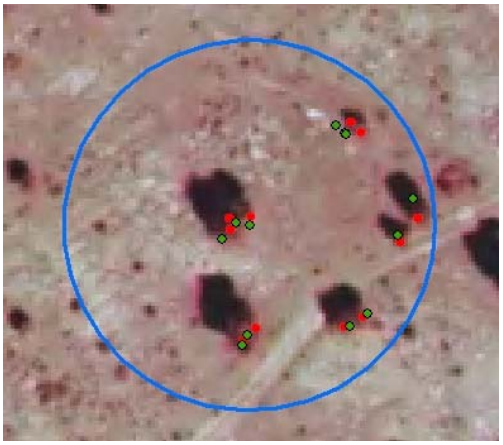

Figura 3.66. Ejemplos de desplazamiento de la situación de los árboles sobre la parcela 63 (los puntos verdes son los datos tomados en campo y los puntos rojos los árboles situados manualmente a partir de los datos LIDAR e imágenes multiespectrales).

Los puntos de color que se observan en las figuras se situaron, como se ha comentado con la visualización 3D de las parcelas. A continuación se muestra una imagen LIDAR 3D de la parcela 3 (figura 3.67).

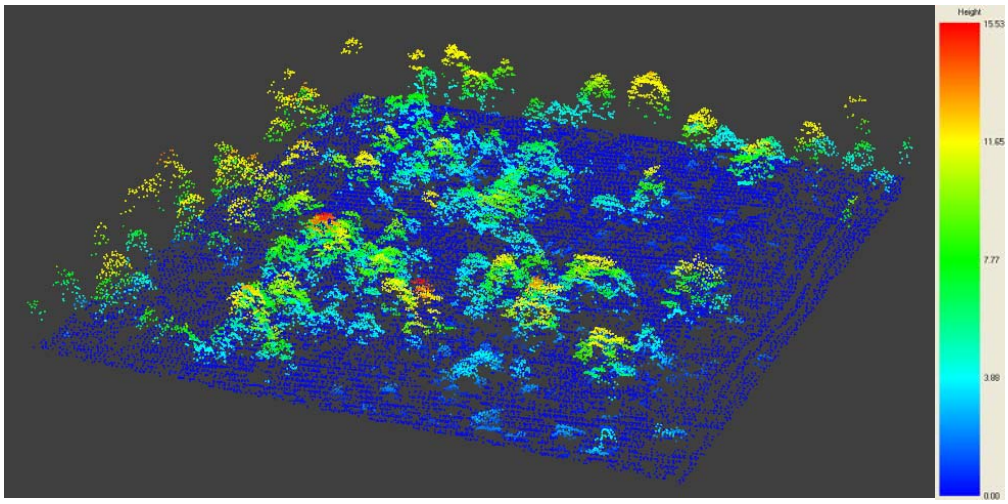

Figura 3.67. Parcela 3 visualizada en 3D a partir de los datos LIDAR.

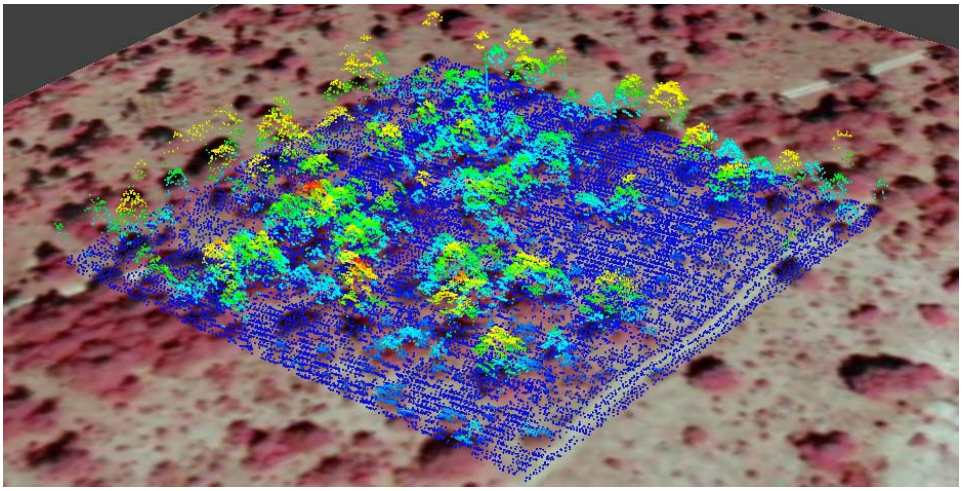

Figura 3.68. Parcela 3 visualizada en 3D de datos LIDAR sobre imagen en falso color infrarrojo.

Gracia a estas visualizaciones conjuntas de los datos LIDAR y las imágenes multiespectrales se pudieron controlar las parcelas estudiadas y posicionar manualmente los árboles en aquellas que presentaban errores de posicionamiento y localización.

Capítulo IV
RESULTADOS

4.1. Introducción a los resultados

Los resultados que se muestran a continuación son globales a la zona de estudio. Los resultados antes mostrados en el apartado de metodología han ido condicionando el desarrollo del trabajo por lo que no se repetirán en este apartado. Este capítulo se divide en resultados que se obtuvieron en la clasificación por píxel, resultados de la clasificación orientada a objeto, resultados en cuanto al conteo de árboles, resultados de localización de árboles y un último aparatado en el que se muestra la segmentación realizada a partir de la post-segmentación.

4.2. Resultados de la clasificación por píxel

Para la clasificación por píxel de la imagen total, se utilizaron las bandas del verde, rojo, el índice de vegetación y el modelo de vegetación, extraído de los datos LIDAR, como se había estudiado anteriormente. Se tomaron nuevas muestras para toda la imagen tanto de aprendizaje como de evaluación. Estas muestras se utilizaron para el cálculo de la clasificación por píxel a la zona de estudio y para la posterior clasificación orientada a objetos en la que se utilizaron los segmentos resultantes de la primera segmentación.

Los resultados del análisis de la separabilidad realizada utilizando las nuevas muestras se recogen en la tabla 4.1.

		Suelo	***Matorral***	***Árbol***
GR-NDVI-CHM PNOA	***Suelo***	-	1.92114815	1.99734476
	Matorral	1.92114815	-	1.86125193
	Árbol	1.99734476	1.86125193	-

Tabla 4.1. Separabilidades de Jeffries-Matusita de las clases
(Clasificación de la imagen completa).

La separabilidad entre las muestras en las diferentes bandas sigue siendo elevada (como en el estudio previo), a pesar de que la entre las clases árbol y matorral haya empeorado algo. Esto es debido a que en la zona de terreno se encuentran matorrales de alturas parecidas a las de los árboles más pequeños y por lo tanto, puede haber matorrales clasificados como árboles, reduciendo así la separabilidad entre las clases.

Vistos los valores de separabilidad ente las muestras, se realizó la clasificación de toda la imagen (figura 4.1).

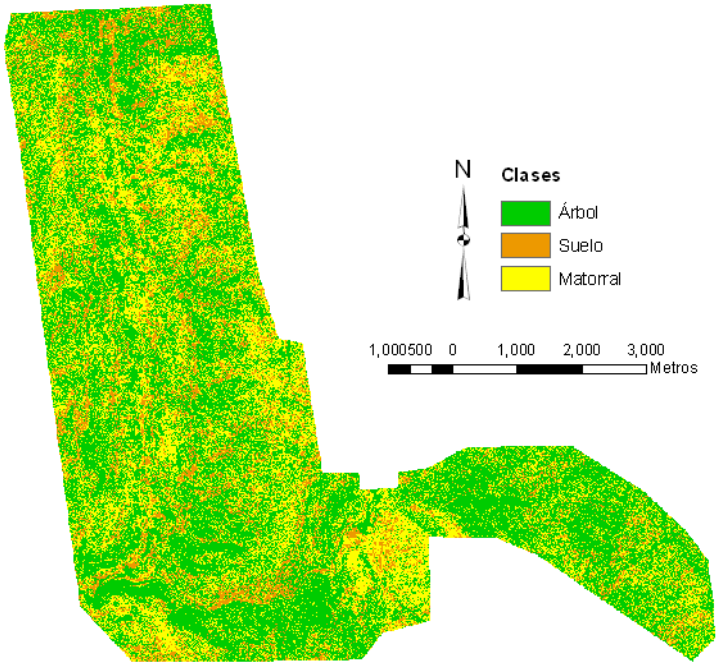

Figura 4.1. Clasificación de la zona de estudio.

En la clasificación de la zona de estudio se obtuvieron los siguientes resultados estadísticos y la siguiente matriz de confusión (tabla 4.2):

		Ground Truth (Pixeles)			*Ground Truth (Porcentajes)*		
		Suelo	**Matorral**	**Árbol**	**Suelo**	**Matorral**	**Árbol**
Clases	**Suelo**	1829	4	0	94.1%	0.2%	0.0%
	Matorral	51	2041	12	2.6%	99.1%	0.5%
	Árbol	63	15	2394	3.2%	0.7%	99.5%
	Total	1943	2060	2406	-	-	-

Tabla 4.2. Matriz de confusión (Imagen completa).

Fiabilidad Global	(6264/6409) 97.7%
Coeficiente Kappa	0.97

Tabla 4.3. Fiabilidad global y coeficiente kappa (imagen completa).

		Píxeles		*Porcentajes*	
		Productor	**Usuario**	**Productor**	**Usuario**
Clases	**Suelo**	1829/1943	1829/1833	94.1%	99.8%
	Matorral	2041/2060	2041/2104	99.1%	97.0%
	Árbol	2394/2406	2394/2472	99.5%	96.8%

Tabla 4.4. Fiabilidades del productor y del usuario (imagen completa).

Como se puede observar, los resultados calculados indican que se ha realizado una buena clasificación. La fiabilidad y el coeficiente Kappa son elevados (ambos valores en torno al 97%). Las fiabilidades del productor y del usuario son elevadas para todas las clase calculadas, y los errores por exceso y por omisión son pequeños salvo para la clase suelo, que tiene un error por omisión próximo al 6%. Estos valores son muy aceptables considerando las dimensiones de la imagen. Con esta clasificación se realizó una post-clasificación utilizando el filtro de media comentado en la parte de metodología.

Con la post-clasificación ya realizada se comenzó con la clasificación orientada a objeto, tomando como polígonos los segmentos calculados tras la primera clasificación sobre las parcelas de estudio.

4.3. Resultados de la clasificación orientada a objetos

Como se ha comentado, los objetos considerados para esta clasificación fueron los segmentos resultantes de la primera segmentación aplicada sobre las parcelas de estudio. De la misma forma que se realizó en la metodología antes explicada, se tomaron muestras de diferentes parcelas de estudio de los tres tipos de clases para poder evaluar la clasificación a objeto realizada sobre todas las parcelas de estudio.

		Evaluación			
	Clasificación	***Matorral***	***Suelo***	***Árbol***	**Total general**
Clasificación	***Matorral***	21	19	2	42
	Suelo	2	8		10
	Árbol	7	3	28	38
	Total general	30	30	30	90
					63.3%

Tabla 4.5. Matriz de confusión para la clasificación orientada a objeto. (Imagen completa).

Analizando los datos se pudo observar que para esta clasificación se obtuvieron unos resultados inferiores que en el apartado de metodología correspondiente a la clasificación por píxel con una fiabilidad global del 63.3%. Las muestras habían sido tomadas de la misma forma aleatoria, seleccionando 30 segmentos por clase. La fiabilidad global no se considera demasiado baja pero se observa un resultado general inferior que en el caso anterior. Las fiabilidades calculadas se muestran en las tablas 4.6 y 4.7.

Fiabilidad del productor	
Matorral	70.0%
Suelo	26.7%
Árbol	93.3%

Tabla 4.6. Fiabilidad del productor de la clasificación por objeto. (Imagen completa).

Fiabilidad del usuario	
Matorral	50.0%
Suelo	80.0%
Árbol	73.7%

Tabla 4.7. Fiabilidad del usuario de la clasificación por objeto. (Imagen completa).

Las fiabilidades del productor son elevadas salvo la clase suelo, mientras que la mayor es la clase árbol, que es la que interesa para el trabajo. Analizando las tablas de fiabilidades y la matriz de confusión (tablas 4.5, 4.6 y 4.7) se observa que sobre la clase suelo se comete un gran error por defecto/omisión, en la que solo se han clasificado como suelo 8 de las 30 parcelas. A pesar de que la calidad de la clasificación de la clase suelo no haya sido satisfactoria, llegado a este punto, el error cometido no es considerado como importante viendo el resto de probabilidades. Si se observa la matriz de confusión, las clases matorral y suelo son en las que mayor confusión hay, mientras que en la clase árbol se comenten pocos

errores. En cualquier caso, el posible error que se puede cometer en la clase árbol es una sobreclasificación, lo que produce una sobresegmentación para el método de la primera segmentación, pero al ejecutar el método de post-segmentación, este error se elimina. Este tipo de errores son los que se producen al haber parcelas o segmentos de grandes superficies (figuras 4.2, 4.3, 4.4 y 4.5), en la que se pueden encontrar los tres tipos de clase (incluso un árbol), pero debido a la predominancia de otra clase, todo el segmento es clasificado como tal. Los resultados obtenidos de la clasificación de los segmentos se muestran en el capítulo de evaluación de los resultados, donde se comparan los resultados obtenidos para las parcelas de estudio en los diferentes métodos empleados.

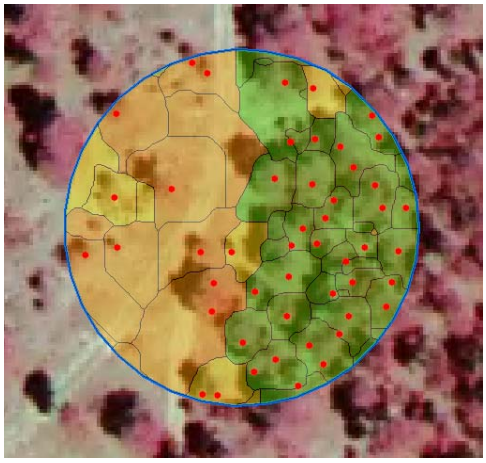

Figura 4.2. Ejemplo de la clasificación orientada a objeto de la parcela 5 (los puntos rojos son los árboles detectados visualmente, en amarillo los segmentos clasificados como matorral, en naranja los clasificados como suelo y en verde los clasificados como árbol).

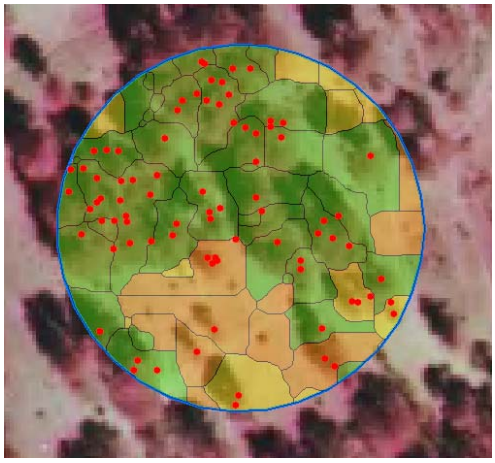

Figura 4.3. Ejemplo de la clasificación orientada a objeto de la parcela 11 (los puntos rojos son los árboles detectados visualmente, en amarillo los segmentos clasificados como matorral, en naranja los clasificados como suelo y en verde los clasificados como árbol).

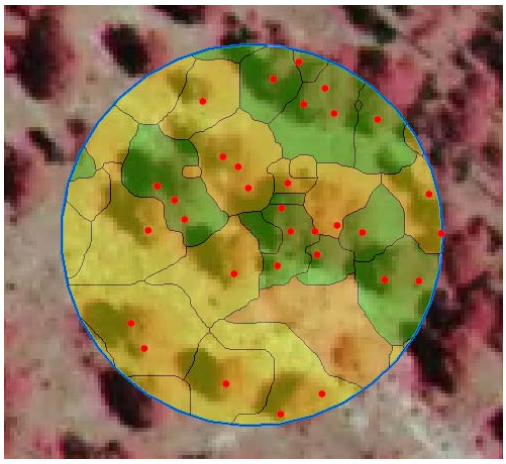

Figura 4.4. Ejemplo de la clasificación orientada a objeto de la parcela 19 (los puntos rojos son los árboles detectados visualmente, en amarillo los segmentos clasificados como matorral, en naranja los clasificados como suelo y en verde los clasificados como árbol).

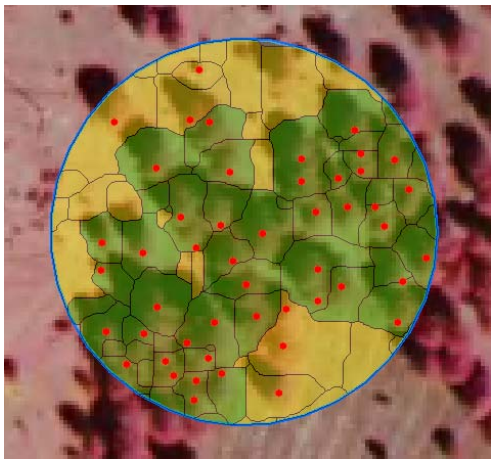

Figura 4.5. Ejemplo de la clasificación orientada a objeto de la parcela 51(los puntos rojos son los árboles detectados visualmente, en amarillo los segmentos clasificados como matorral, en naranja los clasificados como suelo y en verde los clasificados como árbol).

En los ejemplos anteriores se pueden observar parcelas en las que hay segmentos con árboles y que han sido clasificadas como suelo o matorral, introduciendo así un error por defecto de árboles localizados en el proceso de la primera segmentación.

4.4. Resultado del conteo de árboles

4.4.1. Conteo por el método de la primera segmentación

Una vez desarrollada toda la metodología de trabajo (incluyendo la programación y ambas clasificaciones) fue aplicada las parcelas para su evaluación. La tabla 4.9 refleja la relación de árboles detectados por parcela en comparación con los de referencia para la segmentación inicial y el porcentaje de aciertos. La tabla 4.8 muestra las estadísticas de todas las parcelas.

Máximo exceso	15
Máximo defecto	80
Media de aciertos por parcela	67.0%

Tabla 4.8. Errores máximos de conteo por exceso y por defecto en unidad de árbol en primera segmentación.

El conteo de árboles realizado es orientativo, ya que el error en el conteo de árboles por parcela se puede equilibrar entre árboles no detectados y árboles detectados por exceso y viceversa. Para el primer método, se ha obtenido un total de 1875 árboles en comparación con los 2387 que hay de referencia (78.4% árboles detectados con respecto del total, lo que indica un 21.6% de detección por defecto). El porcentaje de aciertos general por parcela es del 67%, indicando que la media de aciertos en cada parcela es este valor. El máximo error por defecto en el conteo de parcela es de 80 árboles, y por exceso de 15.

Las diferencias del conteo de los árboles por parcela se observan gráficamente en la figura 4.6.

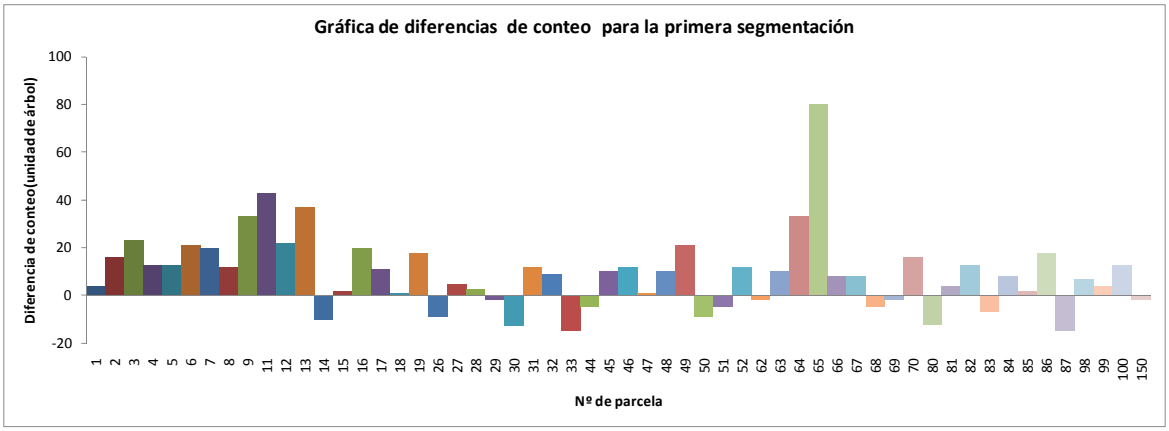

Figura 4.6. Diferencias de conteo de árboles de las parcelas evaluadas por el método de la primera segmentación.

Id Parcela	*Arb. Ref.*	*Arb. Segm.*	*Dif. Segm.*	*% aciertos*
1	28	24	4	85.7%
2	25	9	16	36.0%
3	34	11	23	32.4%
4	44	31	13	70.5%
5	49	36	13	73.5%
6	29	8	21	27.6%
7	32	12	20	37.5%
8	40	28	12	70.0%
9	88	55	33	62.5%
11	83	40	43	48.2%
12	45	23	22	51.1%
13	62	25	37	40.3%
14	29	39	-10	65.5%
15	56	54	2	96.4%
16	80	60	20	75.0%
17	50	39	11	78.0%
18	34	33	1	97.1%
19	32	14	18	43.8%
26	19	28	-9	52.6%
27	12	7	5	58.3%
28	39	36	3	92.3%
29	2	4	-2	50.0%
30	27	40	-13	51.9%
31	53	41	12	77.4%
32	110	101	9	91.8%
33	60	75	-15	75.0%
44	22	27	-5	77.3%
45	25	15	10	60.0%
46	28	16	12	57.1%
47	12	11	1	91.7%
48	30	20	10	66.7%
49	48	27	21	56.3%
50	49	58	-9	81.6%
51	49	54	-5	89.8%
52	24	12	12	50.0%
62	43	45	-2	95.3%
63	11	1	10	9.1%
64	60	27	33	45.0%
65	175	95	80	54.3%
66	24	16	8	66.7%
67	29	21	8	72.4%
68	56	61	-5	91.1%
69	43	45	-2	95.3%
70	38	22	16	57.9%
80	28	40	-12	57.1%
81	39	35	4	89.7%
82	26	13	13	50.0%
83	46	53	-7	84.8%
84	53	45	8	84.9%
85	38	36	2	94.7%
86	51	33	18	64.7%
87	54	69	-15	72.2%
98	35	28	7	80.0%
99	42	38	4	90.5%
100	20	7	13	35.0%
150	27	29	-2	92.6%
Total	2387	1872	515	-

Tabla 4.9.Conteo de árboles y aciertos segmentación inicial (Unidades de árbol).

Los resultados obtenidos en esta primera segmentación son un buen punto de partida para el proceso de la post-segmentación, consiguiendo segmentos que se aproximan a la naturaleza de las masas forestales. No hay que olvidar que el conteo realizado para este primer método es aproximado y su objetivo principal es proporcionar segmentos adecuados para la siguiente fase de la metodología. Las figuras mostradas a continuación muestran los resultados obtenidos para varias de las parcelas evaluadas.

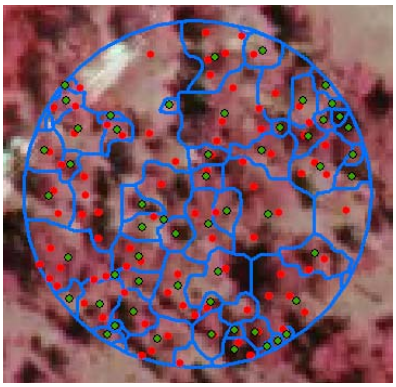

Figura 4.7. Primera segmentación sobre parcela 9. (Los puntos verdes muestran geocentros calculados, los puntos rojos árboles de referencia).

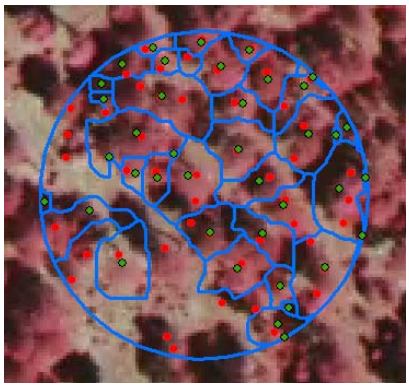

Figura 4.8. Primera segmentación sobre parcela 17. (Los puntos verdes muestran geocentros calculados, los puntos rojos árboles de referencia).

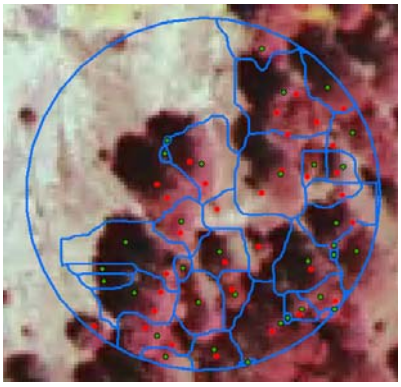

Figura 4.9. Primera segmentación sobre parcela 18. (Los puntos verdes muestran geocentros calculados, los puntos rojos árboles de referencia).

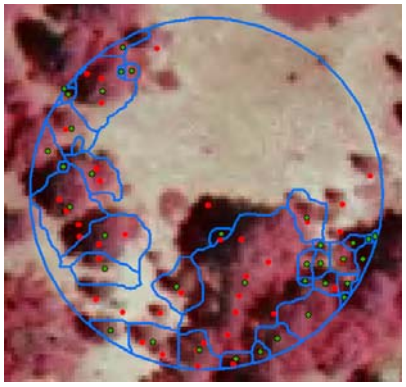

Figura 4.10. Primera segmentación sobre parcela 28. (Los puntos verdes muestran geocentros calculados, los puntos rojos árboles de referencia.)

En la figura 4.6 así como en la gráfica 4.9, se puede comprobar que en esta primera segmentación se encuentran parcelas con errores elevados en la detección tanto por exceso como por defecto. Al analizar las parcelas donde los valores indican un mayor exceso de árboles se observa que la zona tiene una densidad media en la que hay polígonos clasificados como árboles de pequeño tamaño, produciendo así una sobresegmentación. Cuando las copas de los árboles de las masas son de gran tamaño, el algoritmo no puede detectar de forma correcta de los árboles ya que se basa en la forma de las copas buscando las cuencas existentes. Se ha demostrado que en ocasiones la forma de las copas de los árboles

(generalmente las más redondeadas) produce un mayor número de cuencas, sobre todo en aquellos árboles que son de gran tamaño, con una respuesta espectral de la clase árbol y por lo tanto, clasificado como tal en este primer método. En la figura donde se muestra el ejemplo en el que se produce un conteo por exceso (figura 4.11), se puede observar que hay polígonos de pequeño tamaño alrededor de polígonos de mayor tamaño y en los bordes en los que no consta ningún árbol si se comparan con los árboles de referencia produciendo así el error por exceso.

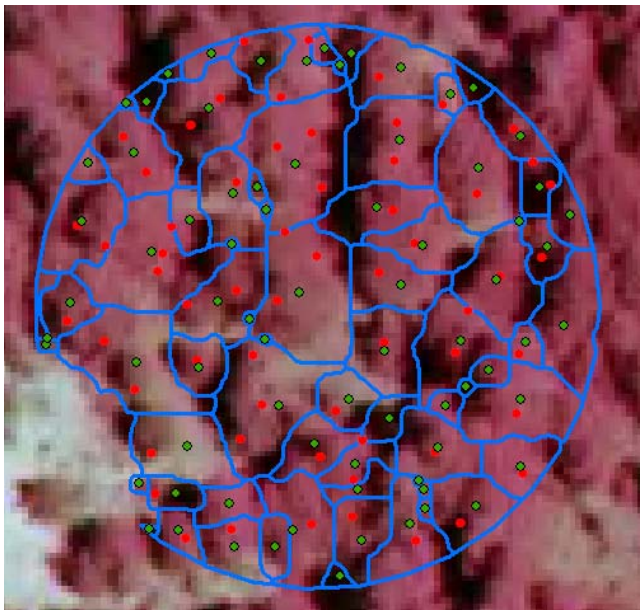

Figura 4.11. Error por exceso de la primera segmentación sobre parcela de evaluación. (Los puntos en verde muestran los geocentros de los segmentos, los puntos rojos muestran los árboles de referencia).

Las parcelas en las que se produce una detección de árboles por defecto, son zonas con una gran densidad de vegetación. En estas parcelas, los polígonos resultantes son de mayores dimensiones, en los que se pueden localizar varios árboles situados en su interior. Esto se debe al poco espaciado que hay entre los árboles produciendo en la segmentación cuencas de mayor tamaño y por lo tanto un defecto en el conteo de estos. En la imagen tomada como ejemplo (figura 4.12) se observan polígonos en los que se sitúan varios árboles en cada uno de ellos. La no detección de algunos de estos árboles también es debida a que hay muchos que no son identificables con las imágenes multiespectrales y de alta resolución utilizadas para la segmentación, ya que estos son de pequeño tamaño y están situado bajo copas más elevadas impidiendo así su detección de estos por la naturaleza de los datos tomados y por la metodología empleada.

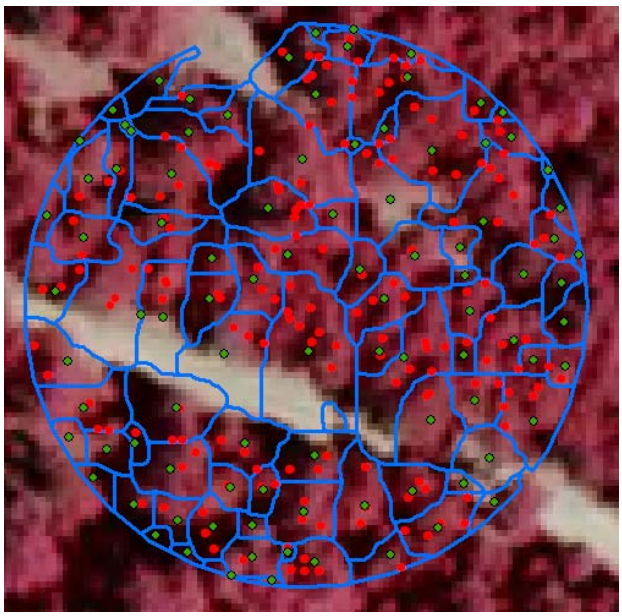

Figura 4.12. Error por defecto de la primera segmentación sobre parcela de evaluación. (Los puntos verdes muestran los geocentros de los segmentos, los puntos rojos muestran los árboles de referencia).

Aún así, los parámetros y filtrados utilizados en la metodología de esta primera segmentación son adecuados para la gran mayoría de las parcelas, consiguiendo un porcentaje bastante elevado de acierto por parcela, del 67%. Cabe recordar, que la metodología en esta primera segmentación tiene como objetivo, no el de la localización final de los árboles sino de conseguir segmentos para la siguiente metodología. A pesar de esto, los resultados obtenidos influirán en el método de post-segmentación.

4.4.2. Conteo por el método de la post-segmentación

Los resultados de este método se resumen en la tabla (4.10).

Id Parcela	Arb. Ref.	Arb. Segm.	Dif. Segm.	% aciertos
1	28	35	-7	75.0%
2	25	32	-7	72.0%
3	34	44	-10	70.6%
4	44	48	-4	90.9%
5	49	50	-1	98.0%
6	29	30	-1	96.6%
7	32	39	-7	78.1%
8	40	41	-1	97.5%
9	88	76	12	86.4%
11	83	48	35	57.8%
12	45	33	12	73.3%
13	62	53	9	85.5%
14	29	31	-2	93.1%
15	56	68	-12	78.6%
16	80	78	2	97.5%
17	50	45	5	90.0%
18	34	38	-4	88.2%
19	32	37	-5	84.4%
26	19	21	-2	89.5%
27	12	11	1	91.7%
28	39	34	5	87.2%
29	2	4	-2	50.0%
30	27	31	-4	85.2%
31	53	53	0	100.0%
32	110	102	8	92.7%
33	60	59	1	98.3%
44	22	20	2	90.9%
45	25	33	-8	68.0%
46	28	23	5	82.1%
47	12	16	-4	66.7%
48	30	37	-7	76.7%
49	48	48	0	100.0%
50	49	37	12	75.5%
51	49	50	-1	98.0%
52	24	30	-6	75.0%
62	43	40	3	93.0%
63	11	14	-3	72.7%
64	60	49	11	81.7%
65	175	84	91	48.0%
66	24	32	-8	66.7%
67	29	33	-4	86.2%
68	56	60	-4	92.9%
69	43	45	-2	95.3%
70	38	42	-4	89.5%
80	28	30	-2	92.9%
81	39	42	-3	92.3%
82	26	33	-7	73.1%
83	46	50	-4	91.3%
84	53	64	-11	79.2%
85	38	36	2	94.7%
86	51	61	-10	80.4%
87	54	69	-15	72.2%
98	35	41	-6	82.9%
99	42	60	-18	57.1%
100	20	25	-5	75.0%
150	27	49	-22	18.5%
Total	2387	2394	-7	-

Tabla 4.10.Conteo de árboles y aciertos post-segmentación (Unidades de árbol).

Máximo exceso	22
Máximo defecto	91
Media de aciertos por parcela	81.7%

Tabla 4.12. Errores máximos de conteo por exceso y por defecto en unidad de árbol en primera post-segmentación.

Lo mismo que sucede en la primera segmentación, el conteo de árboles es relativo, ya que árboles por exceso y por defecto se pueden compensar. Para el segundo método se ha calculado un total de 2394, lo que diferencia en 7 árboles por exceso a las parcelas de referencia. En estas parcelas se observa, para la mayoría de los casos, errores de conteo no muy elevados salvo alguna excepción, en la que la diferencia entre parcelas puede llegar a ser de hasta 91 árboles por defecto y de 22 por exceso. A pesar de esto la fiabilidad global de acierto por parcela resulta del 81.7%, un porcentaje muy superior al primer método y consiguiendo unos resultados aceptables en el método de la detección. Las figuras 4.12, 4.13, 4.14 y 4.15 muestran varias parcelas con el resultado obtenido en la detección de árboles.

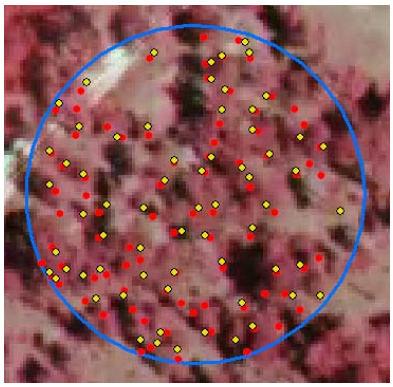

Figura 4.12. Post-segmentación sobre parcela 9. (Los puntos amarillos muestran los árboles detectados, los puntos rojos árboles de referencia).

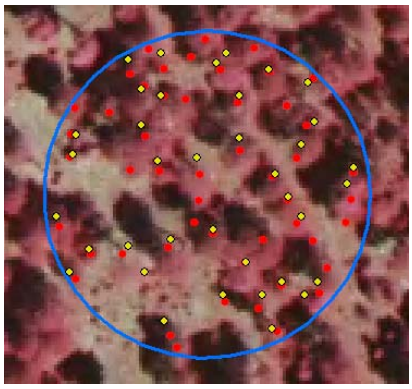

Figura 4.13. Post-segmentación sobre parcela 17. (Los puntos amarillos muestran los árboles detectados, los puntos rojos árboles de referencia).

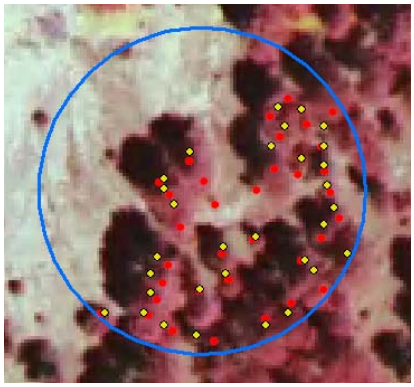

Figura 4.14. Post-segmentación sobre parcela 18. (Los puntos amarillos muestran los árboles detectados, los puntos rojos árboles de referencia).

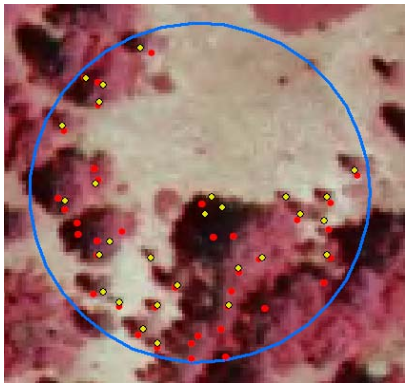

Figura 4.15. Post-segmentación sobre parcela 28. (Los puntos amarillos muestran los árboles detectados, los puntos rojos árboles de referencia).

La figura 4.16 muestra de forma gráfica las diferencias entre el conteo de los árboles de referencia y los árboles calculados. En esta se pueden ver las parcelas en las que se producen los mayores errores.

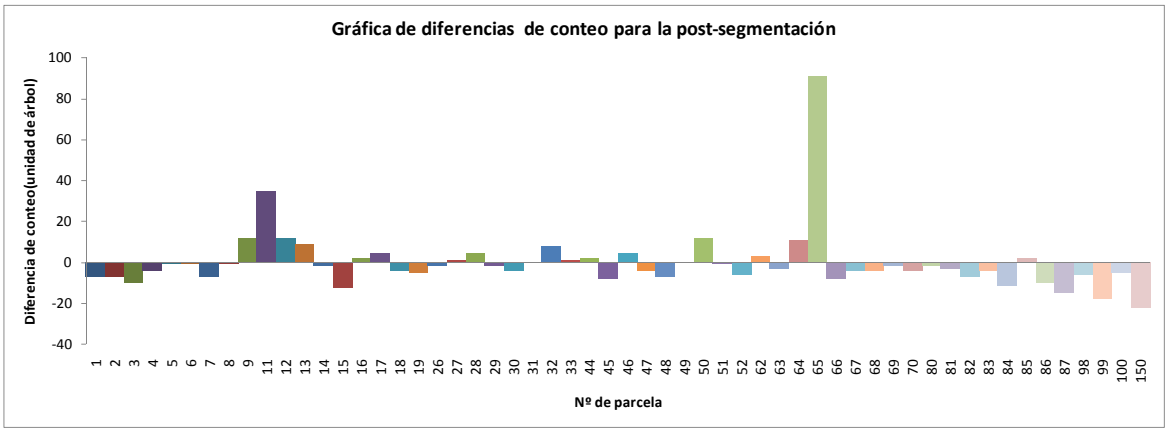

Figura 4.16. Diferencias de conteo de árboles de las parcelas evaluadas por el método de post-segmentación.

Hay varias parcelas puntuales donde existen errores marcados tanto por exceso como por defecto. Si se analizan las parcelas donde se ha producido un exceso, se encuentran zonas dispersas de árboles con ejemplares de gran tamaño en las que los máximos detectan varios puntos en las copas más grandes. Hay puntos detectados también sobre matorrales de gran tamaño superiores a los 2 metros, no considerados como árboles y por eso no situados como referencia. En estas zonas de grandes copas, la sobresegmentación suele ser normal cuando se utiliza el algoritmo de máximos locales. A pesar de ello, con la metodología empleada, se evita en gran parte esta sobresegmentación producida al actuar a nivel de parcela o segmento resultante de la primera segmentación. En la figura 4.17 se muestra un ejemplo de la sobresegmentación ocurrida sobre una de las parcelas de evaluación.

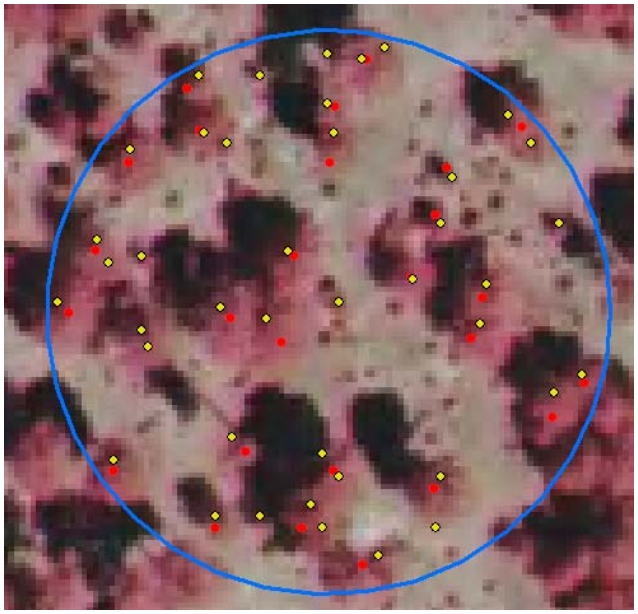

Figura 4.17. Error por exceso de post-segmentación sobre parcela de evaluación. (Los puntos en amarillo muestran los árboles detectados, los puntos rojos muestran los árboles de referencia).

Hay casos en los que la falta de árboles detectados es notable, con máximos errores por defecto de 91 árboles. Estas zonas son, como en el caso de la primera segmentación, zonas muy densas (figura 4.18) en las que la detección de árboles resulta muy difícil no sólo por su densidad sino también por la naturaleza de los datos, ya que es muy difícil diferenciar los árboles situados bajo las copas más grandes si no es por sondeos o campañas de campo o con otro tipo de información LIDAR en la que se trata con datos continuos (*full wave LIDAR*). Es en estas parcelas donde los resultados de la primera segmentación afectan gravemente a la metodología de la post-segmentación.

A pesar de los errores comentados, la post-clasificación consigue resultados muy buenos y produce una mejora considerable con respecto a la metodología de la primera segmentación, sin llegar a producirse una sobresegmentación exagerada, típica de los algoritmos de segmentación y de detección de árboles. Con esta segmentación se consiguió también un posicionamiento adecuado para cada uno de los árboles detectados. Esto se puede ver en el siguiente apartado de resultados relativos al posicionamiento.

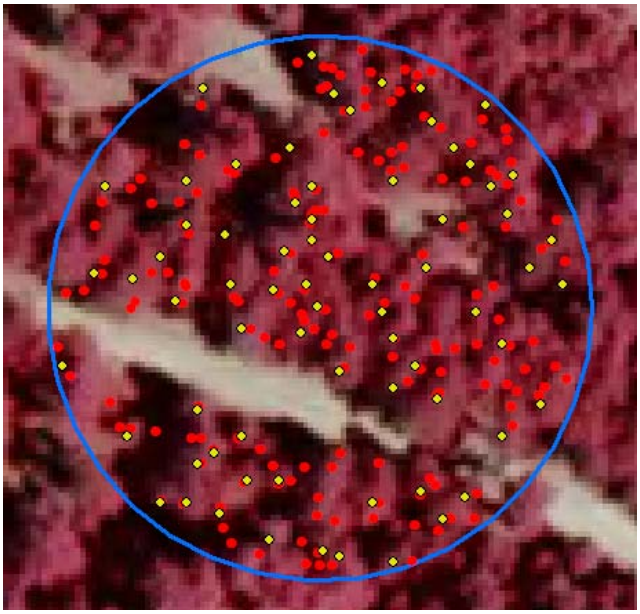

Figura 4.18. Error por defecto de post-segmentación sobre parcela de evaluación. (Los puntos en amarillo muestran los árboles detectados, los puntos rojos muestran los árboles de referencia).

4.5. Resultados de la localización

Los resultados de la localización, como en el caso de los resultados del conteo de árboles, se muestran por separado en función del método empleado.

4.5.1. Localización por el método de la primera segmentación

Para la visualización del posicionamiento de los árboles se utilizaron gráficas tipo "diana" anteriormente descritas en el apartado de metodología. A pesar de que los geocentros no indican correctamente la posición de los árboles, visto el conteo realizado y las imágenes, se realiza el estudio de estas posiciones para poder evaluar de alguna forma la calidad de la localización de los segmentos proporcionados por la primera segmentación.

Dada la posición de los árboles, se calcularon las estadísticas sobre cada parcela. Los estadísticos estudiados fueron la media de las distancias entre los árboles calculados y los de referencia, la desviación típica y las distancias máxima y mínima de entre todos los árboles calculados.

La tabla 4.13 muestra los valores generales de las estadísticas y la tabla 4.14 muestra las estadísticas calculadas por parcela.

Media del desplazamiento total	4.14
Desviación típica general	3.22
Mínima distancia encontrada	0.05
Máxima distancia	38.87

Tabla 4.13. Estadísticas generales del posicionamiento de la detección de árboles en la primera segmentación (unidades en metros).

La media del desplazamiento producido entre los árboles calculados y los árboles de referencia para todas las parcela se sitúa en algo más de 4 metros, con una desviación de 3.22 metros. La localización para este procedimiento es aproximado, ya que lo que se está comparando son los geocentros de cada uno de los segmentos calculados. Considerando el objetivo principal de la primera segmentación, el desplazamiento medio entre el árbol de referencia y el centro del polígono calculado de 4 metros (8 píxeles) es un buen resultado.

Comparando la localización a nivel de parcela, se encuentran valores de desplazamientos muy elevados. Analizando estas parcelas, se observa que son las mismas en las que se han producido el menor porcentaje de aciertos para este primer procedimiento.

Si se observa el indicador de las diferencias de la localización (figura 4.19) se puede observar la tendencia general de las diferencias de posicionamiento para ambos ejes.

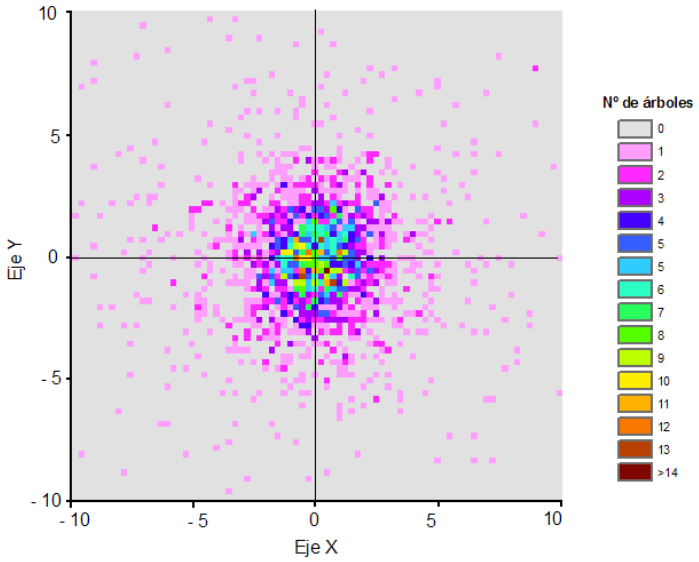

Figura 4.19. Indicador de desplazamiento en la detección de los árboles con respecto a los árboles de referencia.

Tras la visualización de la dispersión que se produce no se encuentra ninguna tendencia marcada en la situación de los árboles. Se produce una acumulación de árboles en la zona periférica de los 3 metros. Los datos estadísticos calculan la media en 4 metros, pero gráficamente se observa que hay varios valores que hacen que la media calculada sea algo elevada (como las parcelas en las que se producen mayores distancias).

Parcela	*Media*	*Mediana*	*Desv.*	*Min*	*Max*
1	3.561	2.682	2.709	0.331	9.253
2	5.625	4.724	4.448	0.449	15.848
3	4.824	4.345	4.181	0.407	20.169
4	2.844	2.423	2.022	0.224	9.062
5	4.696	1.734	6.313	0.187	25.454
6	7.297	6.521	3.946	0.747	14.898
7	6.554	3.916	6.215	0.517	22.820
8	3.371	2.328	3.127	0.303	12.906
9	2.436	2.110	1.516	0.084	7.885
11	2.948	2.362	2.434	0.397	13.279
12	2.559	1.764	1.898	0.080	7.804
13	3.610	2.324	3.695	0.175	18.445
14	2.184	1.692	1.531	0.161	5.900
15	2.130	1.676	2.015	0.110	11.797
16	2.248	2.065	1.362	0.294	6.158
17	3.050	2.154	3.062	0.126	15.114
18	2.662	2.302	1.714	0.182	6.532
19	6.365	3.674	6.286	0.773	21.524
26	3.846	2.208	5.381	1.080	25.039
27	16.491	15.161	13.180	2.989	38.871
28	2.497	2.010	1.740	0.227	8.720
29	4.510	6.833	3.286	2.186	6.833
30	2.250	1.398	2.076	0.363	10.208
31	2.649	2.379	1.571	0.233	5.852
32	1.585	1.517	0.806	0.166	4.265
33	1.815	1.731	0.880	0.396	4.475
44	2.629	2.099	1.663	0.541	5.400
45	3.901	3.395	3.239	0.383	11.855
46	5.774	4.307	5.287	0.777	20.633
47	4.128	4.416	3.029	0.624	11.220
48	3.124	2.476	2.927	0.244	15.128
49	5.700	3.084	6.427	0.328	24.758
50	2.048	1.531	1.587	0.274	7.408
51	1.941	1.381	1.641	0.297	7.395
52	10.609	13.963	7.097	0.263	22.637
62	2.246	1.881	1.117	0.411	4.837
63	19.858	19.971	9.757	8.108	31.745
64	3.037	1.994	2.797	0.440	12.468
65	1.837	1.760	0.929	0.129	4.180
66	3.754	2.613	2.980	0.375	9.784
67	3.963	2.791	3.502	0.326	15.145
68	1.868	1.788	1.048	0.331	4.849
69	3.233	2.383	2.412	0.660	11.701
70	4.291	3.003	3.684	0.619	18.725
80	2.046	1.874	1.217	0.519	5.386
81	3.183	2.003	3.299	0.049	14.828
82	6.538	3.821	7.017	0.756	28.464
83	2.033	1.860	1.333	0.151	8.058
84	1.998	1.618	1.255	0.371	6.226
85	2.378	2.310	1.391	0.073	5.550
86	2.805	2.478	1.752	0.096	7.571
87	1.900	1.861	1.121	0.207	5.109
98	3.044	2.295	2.112	0.619	9.409
99	2.117	1.824	1.318	0.130	5.341
100	12.873	13.675	7.936	2.743	25.897
150	2.470	1.894	1.922	0.435	7.621
Total	4.14	3.51	3.22		

Tabla 4.14. Estadísticas por parcela del posicionamiento de la detección de árboles en la primera segmentación (unidades en metros).

A continuación se muestran varios ejemplos de dianas calculadas en el proceso que permiten calcular los desplazamientos de cada árbol con respecto a los árboles de referencia.

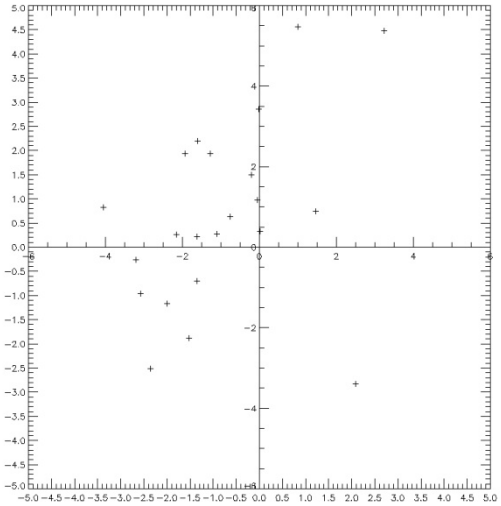

Figura 4.20. “Diana” de posiciones relativas a los árboles de referencia de la parcela 1 en la primera segmentación. (Unidades en metros).

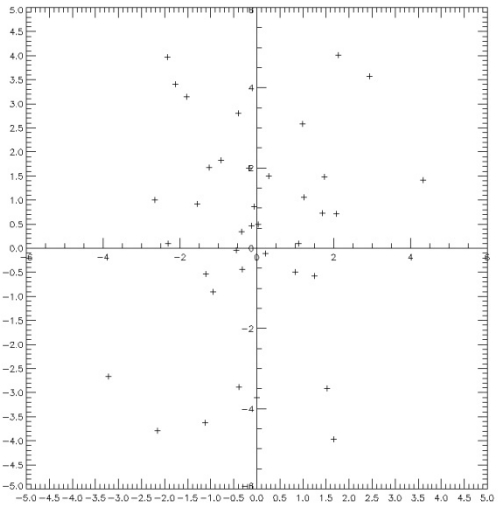

Figura 4.21. “Diana” de posiciones relativas a los árboles de referencia de la parcela 4 en la primera segmentación. (Unidades en metros).

Con de la determinación de la posición relativa entre los árboles calculados y de referencia también se genera un histograma de frecuencias en el que se observa para cada parcela la cantidad de árboles en cada una de las distancias cada 0.5 metros. Los siguientes histogramas muestran la cantidad de árboles en función de la distancia al árbol de referencia de las parcelas correspondientes a las dianas anteriores.

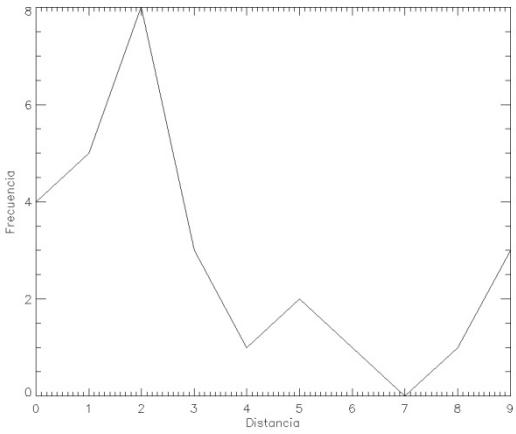

Figura 4.22 Histograma del número de árboles en función de la distancia a los árboles de referencia de la parcela 1. (Unidades en metros).

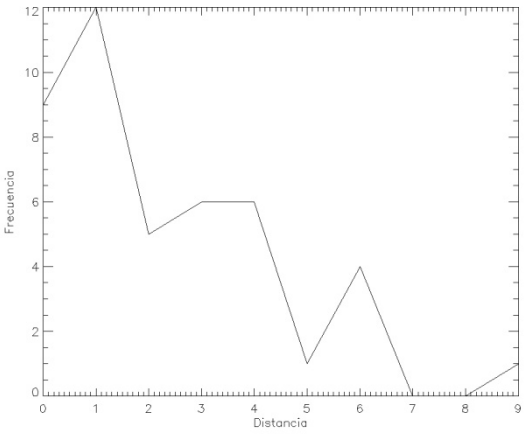

Figura 4.23. Histograma del número de árboles en función de la distancia a los árboles de referencia de la parcela 4. (Unidades en metros).

Gracias al estudio de las “dianas” se pudieron interpretar detalladamente los errores cometidos en el posicionamiento de los árboles calculados en las parcelas. En este caso de posicionamiento de los geocentros, como se ha comentado antes, no parece que se tienda a un desplazamiento en ninguna dirección determinada, solo que la media de desplazamiento de cada parcela se sitúa entre los 3 y los 4 metros de distancia a los árboles de referencia.

4.5.2. Localización por el método de post-segmentación

Para el estudio del posicionamiento de los árboles obtenidos a partir de la segunda segmentación se realiza el procedimiento de las dianas de la misma forma que en el caso anterior. Las tablas 4.15 y 4.16 muestran los resultados obtenidos.

Media del desplazamiento total	1.57
Desviación típica general	1.18
Mínima distancia encontrada	0.02
Máxima distancia	14.83

Tabla 4.15. Estadísticas generales del posicionamiento de la detección de árboles en la post-segmentación (unidades en metros).

Para este caso se obtuvieron unos resultados con mejores estadísticas que el primer método. La media del desplazamiento total de los árboles está en torno al metro y medio, con una desviación típica ligeramente superior a un metro. La distancia máxima entre árbol calculado y su referencia es de casi 15 metros, que en comparación con la primera segmentación, es muy buen resultado.

Si se analiza la imagen de dispersión (figura 4.24) se observa que hay una gran concentración de valores en torno al metro y medio. En esta gráfica se puede observar un pequeño desplazamiento o tendencia igual en los dos ejes de -1 un metro. En general, la dispersión que se produce en función de la distancia no se considera elevada.

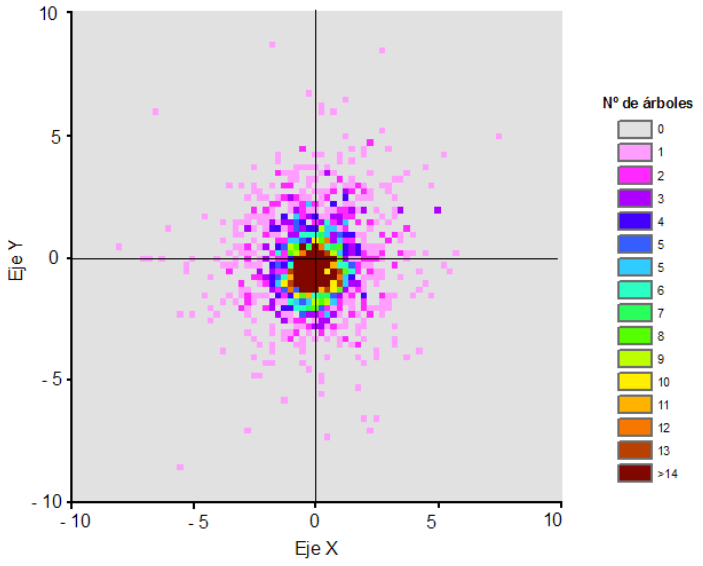

Figura 4.24. Indicador de desplazamiento en la detección de los árboles con respecto a los árboles de referencia en la post-segmentación.

Parcela	*Media*	*Mediana*	*Desv.*	*Min*	*Max*
1	1.796	1.751	0.978	0.353	4.424
2	1.864	1.628	0.841	0.623	3.756
3	1.331	1.208	0.842	0.131	3.532
4	1.441	1.334	0.942	0.168	4.875
5	1.760	1.208	2.161	0.171	12.388
6	1.544	1.214	1.159	0.363	5.260
7	1.888	1.219	2.141	0.346	10.381
8	1.892	1.663	1.085	0.432	5.680
9	1.436	1.073	1.061	0.110	4.249
11	1.507	1.338	0.974	0.105	4.523
12	2.132	2.025	1.333	0.367	6.751
13	1.288	1.132	0.770	0.147	4.189
14	1.257	1.039	1.118	0.085	4.811
15	1.536	1.408	0.939	0.203	4.583
16	1.713	1.364	1.211	0.207	6.043
17	2.133	1.736	1.562	0.183	5.748
18	2.019	1.662	1.605	0.175	7.099
19	1.903	1.180	2.256	0.534	10.914
26	1.583	1.244	1.265	0.299	4.394
27	2.717	1.527	3.977	0.314	14.834
28	2.092	1.276	1.943	0.119	7.470
29	0.667	0.912	0.347	0.422	0.912
30	1.315	1.163	0.914	0.269	4.188
31	1.389	1.087	0.973	0.111	3.707
32	1.585	1.360	1.116	0.213	7.454
33	1.426	1.072	1.213	0.153	5.628
44	1.406	1.357	0.753	0.269	2.990
45	1.112	0.884	0.671	0.018	2.468
46	1.418	1.272	1.101	0.211	4.856
47	1.454	1.141	1.177	0.685	4.918
48	1.091	0.823	0.751	0.139	3.433
49	1.531	1.202	1.112	0.250	5.502
50	1.900	1.532	1.115	0.414	5.517
51	1.445	1.198	0.886	0.341	3.568
52	1.427	1.003	1.260	0.063	5.411
62	2.040	1.355	1.631	0.480	8.730
63	1.321	1.001	0.814	0.378	3.079
64	1.502	1.205	1.291	0.079	8.938
65	1.730	1.555	1.054	0.112	5.327
66	1.129	1.215	0.659	0.217	2.894
67	1.941	1.562	1.822	0.219	8.165
68	1.575	1.279	0.997	0.117	4.230
69	2.486	2.166	1.831	0.317	8.877
70	1.090	0.933	0.848	0.277	4.393
80	1.426	1.382	0.821	0.114	3.600
81	1.495	1.231	1.111	0.092	5.749
82	1.222	1.104	0.671	0.135	3.288
83	1.677	1.194	1.398	0.227	5.657
84	1.456	1.158	1.184	0.100	7.092
85	1.565	1.214	1.294	0.205	5.210
86	1.481	1.255	1.038	0.146	4.262
87	1.702	1.445	1.257	0.055	5.355
98	1.696	1.604	1.165	0.122	6.847
99	1.302	1.229	0.724	0.228	3.763
100	1.154	1.124	0.491	0.309	2.125
150	1.173	1.083	0.638	0.186	2.683
Total	4.14	3.51	3.22		

Tabla 4.16. Estadísticas por parcela del posicionamiento de la detección de árboles en la post-segmentación (unidades en metros).

En las siguientes figuras se muestran ejemplos de las dianas calculadas para esta post-segmentación de las mismas parcelas mostradas anteriormente en las dianas de la primera segmentación.

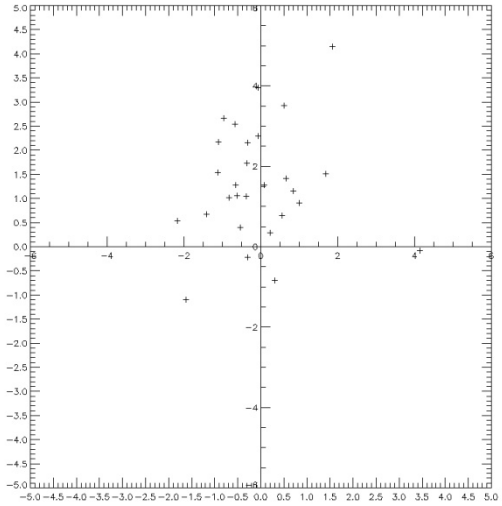

Figura 4.25. Diana de posiciones relativas a los árboles de referencia de la parcela 1 en el proceso de post-segmentación. (Unidades en metros).

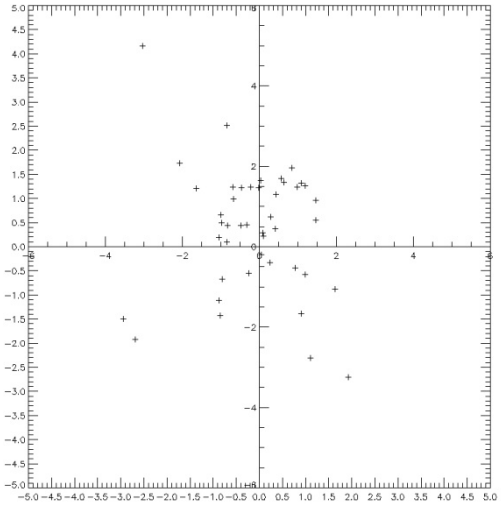

Figura 4.26. Diana de posiciones relativas a los árboles de referencia de la parcela 4 en el proceso de post-segmentación. (Unidades en metros).

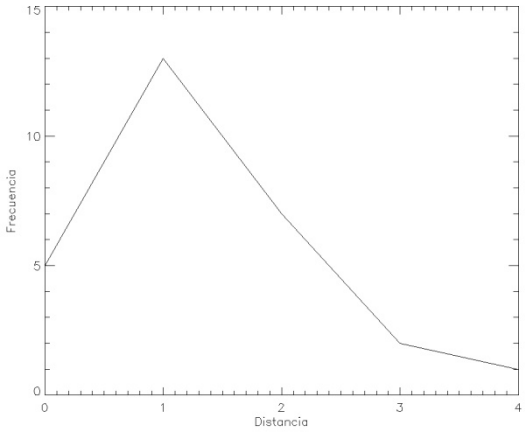

Figura 4.27. Histograma del número de árboles en función de la distancia a los árboles de referencia de la parcela 1. (Unidades en metros).

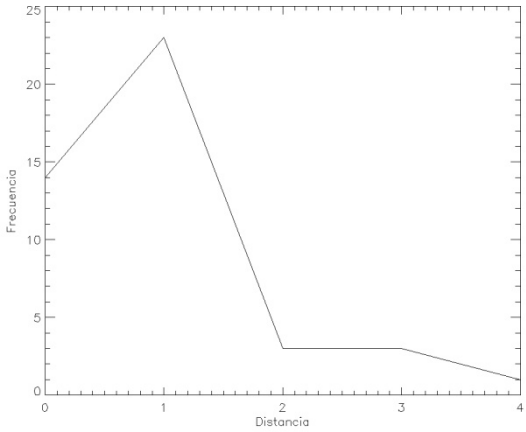

Figura 4.28. Histograma del número de árboles en función de la distancia a los árboles de referencia de la parcela 4. (Unidades en metros).

Como se puede observar en los histogramas, se producen picos máximos en la zona situada entre el metro y metro y medio.

Los resultados obtenidos en cuanto al posicionamiento en la post-segmentación son muy satisfactorios, ya que un error de posicionamiento de 1.5 metros es aceptable contando que la mayoría de los árboles se han situado de forma manual, pudiendo cometer un error al colocar estos de un dos o tres píxeles (0.5 metros cada píxel) más el posible error que pueda cometer el método en su posicionamiento.

4.6. Resultados de copas de la post-segmentación

En el método de post-segmentación se consiguieron detectar las copas de los árboles de forma aproximada. Las figuras 4.29, 4.30, 4.31 y 4.32 muestran ejemplo del resultado de éste método.

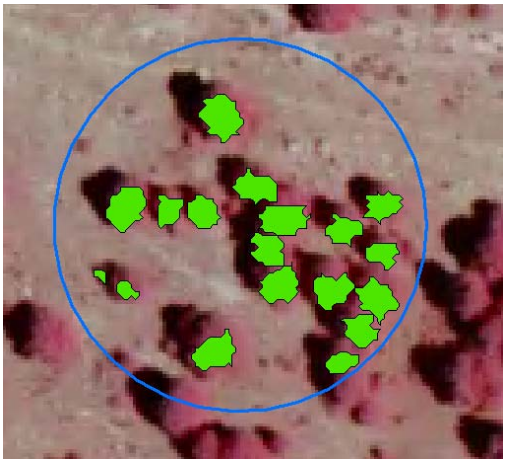

Figura 4.29. Segmentación resultante de la post-segmentación. Parcela 46.

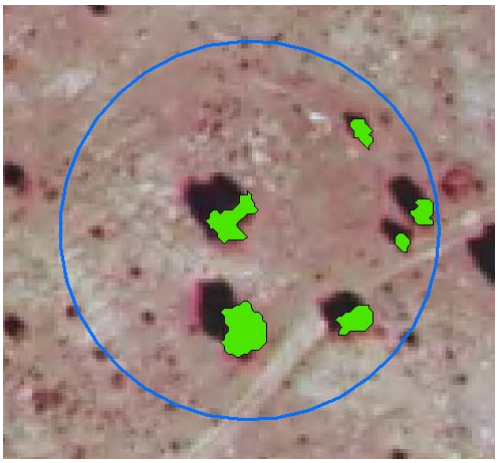

Figura 4.30. Segmentación resultante de la post-segmentación. Parcela 63.

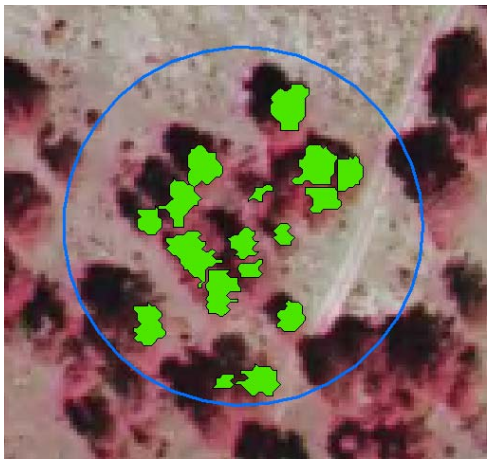

Figura 4.31. Segmentación resultante de la post-segmentación. Parcela 80.

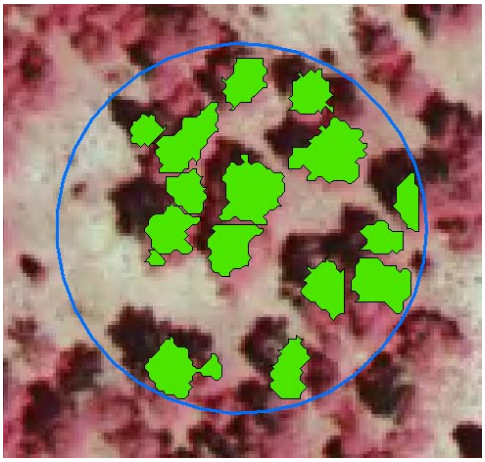

Figura 4.32. Segmentación resultante de la post-segmentación. Parcela 80.

A simple vista, se puede observar los polígonos segmentados se ajustan a la forma de las copas de los árboles. A pesar de que no se hayan podido calcular todos los segmentos de todos los árboles por errores en la metodología, los segmentos que si se han podido calcular son correctos como para afirmar que la metodología empleada es válida y que depurando el método se pueden conseguir mejores resultados.

4.7. Discusión de resultados

Ambas clasificaciones presentaron valores adecuados para la metodología planteada. Estos resultados se podrían haber mejorado con la primera segmentación en la parte correspondiente a la clasificación orientada a objeto ya que, la clasificación por píxel, depende de la información multiespectral de la que se parte y de las muestras tomadas.

En la primera segmentación se han obtenido unos resultados aproximados en cuanto a conteo y localización de árboles, mientras que los contornos de estos no se pudieron obtener correctamente. Aún así, los datos obtenidos han sido muy satisfactorios para continuar con su procesado en la post-segmentación. Los resultados de la primera segmentación se podrían haber mejorado tratando los parámetros de forma individual para cada una de las parcelas variando estos dependiendo de las características de densidad. En la evaluación se pudo observar que los resultados obtenidos eran próximos a la realidad salvo excepciones. El problema que presentaba el conteo sobre la primera segmentación era que este era dependiente de la clasificación orientada a objeto. Se han dado casos en los que a pesar de haber píxeles clasificados dentro del segmento como árbol, la moda era de otra clase, clasificándose así todo el segmento como una clase que no era árbol, produciendo en cierta medida un error por defecto. Otro error por defecto que se ha observado se producía en zonas de densidad alta, que debido a la disposición de los árboles, se generaron grandes polígonos pudiéndose situar dentro de estos más de un árbol. En cambio, el conteo por exceso se producía en aquellas zonas de densidad media, en la que se generaron polígonos o segmentos de pequeño tamaño debido a las características de aquellas copas más redondeadas de los árboles. La localización de los árboles fue de manera aproximada, ya que esta se basaba en los geocentros de los segmentos y no en la situación real de los árboles. Con mejora de este procedimiento se habrían obtenido resultados más satisfactorios en la post-segmentación.

Para la post-segmentación se obtuvieron unos valores resultantes muy aceptables tanto en conteo como en localización. Esta dependía básicamente de los segmentos obtenidos en la primera segmentación los cuales se trataban individualmente para un conteo y localización más precisos. Los errores cometidos por exceso y por defecto se basaban principalmente en la densidad de la masa forestal presente en la parcela de evaluación, produciéndose un exceso de conteo en aquellas parcelas de baja densidad arbórea y un defecto en las que mayor densidad se presentaba. La delimitación de copas conseguidas en la post-segmentación fue satisfactoria en aquellos casos en los que se pudo calcular. La desventaja principal del trabajo a nivel de parcela es que la zona está en ocasiones muy limitada y en ocasiones se pueden producir por los cuales no será posible realizar la delimitación correcta de las copas. Debido a esto, la post-segmentación, pese a presentar valores aceptables, se puede mejorar trabajando por fuera de los límites de los segmentos calculados y así obtener una visión más amplia de la unidad de segmento.

Los mayores errores en el conteo se produjeron como una gran excepción para ambos métodos en la parcela 65, la cual, se utilizó a forma de prueba debido a que presentaba un gran número de árboles casi imperceptibles en la visualización LIDAR en 3D e imágenes multiespectrales debido a la gran densidad de la zona, guiándose únicamente por la localización aproximada de los datos de campo, que como se ha comentado en varias ocasiones, se producían errores de desplazamiento en la localización.

Otro error cometido fue en el estudio de la localización de los árboles, aunque más que error de localización, es un error de identificación a la hora del cálculo de las distancias entre árboles calculados y árboles de referencia, ya que se han dado casos en las parcelas en los que un árbol calculado, a falta de un árbol de referencia cercano, ha sido identificado con otro situado en otro extremo de la parcela por la misma razón. Esto mostraba resultados en los que se encontraba como distancia máxima de localización entre los árboles superior a los 15 metros. Esto ocurre en situaciones muy concretas.

Se puede decir que los resultados parciales dentro del apartado de metodología han ido condicionando ésta para conseguir al final del procedimiento unos resultados satisfactorios, que como se ha observado, son resultados que indican que los procesos de automatización en el campo de la segmentación y detección de árboles es viable así como la segmentación o detección de límites de copas para el posterior estudio de las características dendrométricas.

Capítulo V
CONCLUSIONES

5.1. Conclusiones

Los resultados obtenidos a lo largo del proyecto han ido condicionando el desarrollo de la metodología sobre todo aquellos que impedían procesar los datos debido al volumen de estos. Debido a estos problemas encontrados, la metodología que se propuso en un principio, fue variando ajustándose a las necesidades de procesado y evaluación de los resultados consiguiendo así un método que es capaz de evaluar grandes cantidades de información (como son gran volumen de datos LIDAR e incluso imágenes de gran tamaño) en un tiempo de procesado relativamente corto.

Para la metodología también se fueron proponiendo y desarrollando métodos necesarios para elaborar funciones o tareas más complicadas necesarias para una buena segmentación de árboles. Muchas de las ideas propuestas para la metodología no se llegaron a desarrollar del todo en el proyecto debido a la complejidad que estas presentaban teniendo que idear nuevos caminos para conseguir un mismo objetivo. Estas metodologías de mayor complejidad, se pretenden desarrollar en nuevos proyectos de investigación.

En el preprocesado de los datos se utilizaron varios algoritmos de trabajo para la generación de los modelos digitales. Tras los resultados se concluyó que con ambos algoritmos realizaban una correcta interpolación o modelado de los MDT. En el trabajo se utilizaron parámetros que fueron adecuados para la zona de estudio, y al final se optó por el modelo que mejor satisfacía las necesidades del trabajo. En la comparación de los modelos calculados con los modelos oficiales del PNOA, se detectaron errores en los datos oficiales debido probablemente a la resolución del modelo, que era inferior a los modelos calculados. También se encontraron desplazamientos en la localización de los árboles en las parcelas tomadas en campo además de errores en los sistemas de coordenadas que, una vez detectados, se corrigieron para continuar con el desarrollo de la metodología.

Los resultados obtenidos para ambos métodos de segmentación han sido satisfactorios teniendo en cuenta los objetivos de cada uno. En el caso de la primera segmentación se consiguieron buenos resultados para continuar la detección de árboles con la post-segmentación. Muchos de los segmentos conseguidos en esta, a pesar de presentar ciertos errores, fueron corregidos gracias al método de la post-segmentación que mejoraba en gran cantidad los resultados de la primera segmentación. La primera segmentación se ve muy afectada por los parámetros utilizados tanto para el filtrado de las imágenes como para la función de detección de las cuencas, pudiendo conseguir mejores resultados variando los valores des estos parámetros dependiendo de la zona en la que se fuera a emplear. Los datos obtenidos tras la post-segmentación fueron satisfactorios tanto para el conteo como para la localización, pudiendo haber mejorado estos resultados si se hubiera mejorado la primera segmentación. A pesar de haber utilizado algoritmos propensos a la sobresegmentación de árboles, la metodología propuesta no producía una gran sobresegmentación debido a la forma de trabajo a nivel de parcela. En aquellas zonas donde se encontraron grandes errores por falta de detección de árboles en parte fue debido a la metodología empleada, pero en mayor parte fue debido a la naturaleza tanto de la zona como de los datos utilizados. En estas zonas de gran densidad arbórea, había árboles bajo las copas de aquellos más grandes, impidiendo la toma de datos LIDAR sobre estos, por lo que era imposible su identificación a partir de imágenes multiespectrales o de alta resolución. La única forma de detectar este tipo de árboles habría sido utilizando datos LIDAR continuos (*full wave*) o métodos de detección más costosos basados en la detección de tallos o troncos o a partir de campañas en campo que es como se realizó.

La metodología planteada en dos partes, a pesar de tener muchos procesos dependientes de muchos factores como las clasificaciones, es una metodología que ha presentado resultados satisfactorios. La segmentación en dos pasos mejoró y mucho la detección y localización de los árboles, y vistos los resultados obtenidos se plantea la posibilidad en un futuro de incorporar progresivamente la automatización en la segmentación forestal. A pesar de estos resultados esperanzadores para la segmentación automática, todavía queda mucho trabajo para conseguir una correcta automatización para la localización de los árboles mejorando no solo las metodologías sino que también la forma de la toma de datos.

La metodología planteada parte de la ventaja de que independientemente del tamaño de la zona de estudio, puede utilizarse, por lo que tiene ventajas en este aspecto sobre ortos métodos de localización de árboles (Kini y Popescu, 2004) que no se pueden realizar sobre grandes áreas de trabajo debido a una limitación de memoria tanto del hardware como del software. Esto se debe al tipo de trabajo por unidad de segmento que, en otros aspectos, presenta inconvenientes en cuanto a la delimitación de las copas.

Los puntos que se podrían mejorar en esta metodología serían en una primera parte, la aplicación del algoritmo *watershed* que, al estar implementada directamente sobre IDL, no permitía mucha libertad en los parámetros a introducir. Dadas estas restricciones, se puede mejorar el algoritmo para su mejor control sobre dichos parámetros así como la introducción

directa sobre el *watershed* varias imágenes o variables a considerar, ya que los filtrados anteriores al algoritmo están ideados para destacar sobre la imagen la información necesaria para conseguir la primera segmentación. Tras la aplicación de toda la metodología se observó que, si se mejorara este primer método, con las post-segmentación se obtendrían mejores resultados en cuanto al conteo de los árboles.

En la segunda segmentación o post-segmentación, los resultados obtenidos en cuanto al conteo pueden ser mejorables como ya se ha comentado anteriormente, o quizás introduciendo un mayor número de condiciones en las que se trataran en mayor medida las variables dimensionales y espectrales de cada uno de los segmentos introducidos como datos de partida en esta post-segmentación. En cuanto a la localización de la situación de los árboles, el método responde con resultados muy satisfactorios, en los que los defectos de localización de los árboles, como las estadísticas presentadas en los resultados de localización, se deben a los errores por defecto o por exceso en el conteo de los árboles. Un aspecto importante a mejorar en esta post-segmentación, es la delimitación de las copas de los árboles de forma individual. La delimitación de las copas en zonas densas es una tarea costosa debido a la disposición de los árboles. El presente método en estas zonas presentaba áreas en las que se encontraban varios árboles produciendo así un error por defecto en la segmentación de las copas. Este error se intentó solucionar a partir de un sistema de rectas entre los árboles localizados que delimitaran los límites de cada una de las copas a lo largo de estas restas detectando los cambios de alturas. Debido al sistema de trabajo por parcela, no se obtuvieron buenos resultados por lo que este método no se consideró oportuno para el proyecto. Una manera de mejorar la segmentación de las copas, sería desarrollar el mismo método descrito anteriormente que trabajara, en vez de a nivel de parcela, a nivel de imagen eliminando así las restricciones de los límites de los segmentos calculados. Otra de las alternativas para la delimitación o segmentación de las copas sería el estudio o segmentación de estas a partir de una nueva combinación de datos LIDAR con los datos multiespectrales, en los que intervinieran varias variables para decidir si un píxel pertenece a una copa o a otra.

Como se puede observar, a pesar de que la tecnología LIDAR provee de grandes resoluciones así como de grandes precisiones, la información multiespectral aporta gran cantidad de variables necesarias para realizar una buena segmentación, por lo que el estudio de las masas forestales no se puede centrar únicamente en un tipo de datos.

Las técnicas que se están desarrollando para la detección de árboles son la única forma de conseguir características y variables a nivel de árbol importantes para estudios forestales. Las características dendrométricas son necesarias para la estimación de las densidades del posterior cálculo de la biomasa, las estructuras de los árboles, la especie de estos, etc., que no se podrían calcular si no es por campañas de campo muy costosas. La metodología para la segmentación de árboles evitaría la mayor parte del trabajo de campo y podría realizar un cálculo inmediato de estas variables. Hoy día se ha demostrado que los estudios de segmentación y localización de árboles son necesarios así como su automatización y que existen metodologías cuyos resultados hacen que estos métodos tengan vistas hacia el futuro.

REFERENCIAS

Andersen, H.E., McGaughey, R.J. y Reutebuch, S.E. (2005). Estimating forest canopy fuel parameters using LiDAR data. *Remote Sensing of Environment* 94, 441–449.

Baltsavias, E.P. (1999). Airborne laser scanning: basic relations and formulas. *ISPRS Journal of Photogrammetry & Remote Sensing* 54, 199–214.

Beucher, B. y Lantuejoul, C. (1979). Use of watersheds in contour detection. In Proceedings of theInternational Workshop on Image Processing: Real-Time and Motion Detection/Estimation (Rennes,France). Available online: http://cmm.ensmp.fr/*beucher/publi/watershed.pdf. Last accessed 06/11/2008.

Castilla, G. y Hay, G.G. (2007). AN AUTOMATED DELINEATION TOOL FOR ASSISTED INTERPRETATION OF DIGITAL IMAGERY. ASPRS 2007 Annual Conference. Tampa, Florida.

Dougherty (1992). An introduction to Morphological Image Procesing. *SPIE Optical Engineering Press*, Bellingham, WA.

Estornell, J., L.A. Ruiz y T. Hermosilla. (2009). Generación de un MDT a partir de datos LIDAR utilizando procesos iterativos basados en la selección de alturas mínimas en una zona de montaña. *Publicación del XIII Congreso de la Asociación Española de Teledetección* "Agua y Desarrollo Sostenible". Calatayud. pp. 481-484.

Heinzel, J.H., Weinacker, H. y Kock, B. (2008). Full automatic detection of tree species base don delineated single tree crowns – a data fusión approach for airborne laser scanning data and aerial photographs. *SilviLaser*. Edinburgh. UK.

Hirata, Y., Furuya, N., Suzuki, M. y Yamamoto, H. (2009). Airborne laser scanning in forest management: Individual tree identification and laser pulse penetration in a stand with different levels of thinning. *Forest Ecology and Management* 258, 752–760.

Hudack, A.T., Evans, J.E. y Smith, A.M.S. (2009). LIDAR utility for natural resource managers. *Remote Sensing* 1, 934-951

Kini, A. y S.C. Popescu (2004). TreeVaW: a versatile tool for analyzing forest canopy LIDAR data: A preview with an eye towards future. In CD-ROM Proceedings, ASPRS 2004 Fall Conference, Kansas City , Missouri.

Kraus, K., y N. Pfeifer (1998). Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing*. 53, 193-203.

Leckie, D.G., Gougeon, F.A., Tinis, S., Nelson, T., Burnett, C.N. y Paradine, D. (2005). Automated tree recognition in old growth conifer stands with high resolution digital imagery. *Remote Sensing of Environment* 94, 311-326.

McGaughey, R.J. (2010). FUSION/LDV: Software for LIDAR Data Analysis and Visualization. *USDA, Forest Service. Pacific Northwest Research Station.*

Persson, A˚., Holmgren, J. y Söderman, U. (2002). Detecting and measuring individual trees using an airborne laser scanner. *Photogrammetric Engineering and Remote Sensing* 68, 925–932.

Popescu, S.C. (2007). Estimating biomass of individual pine tres using airborne lidar. *Biomass and Bioenergy* 31, 646-655.

Popescu, S.C. y Wynne, R.H. (2004). Seeing the trees in the forest: using LiDAR andmultispectral data fusion with local filtering and variable window size for estimating tree height. *Photogrammetric Engineering & Remote Sensing* 70, 589–604.

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. *Remote Sensing of Environment* 82, 322–334

Pouliot, D.A, King, D.J. y Pitt, D.G. (2005). Development and evaluation of an automated tree detection–delineation algorithm for monitoring regenerating coniferous forests. *NRC Research Press*.

Recio, J.A. (2009). 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, Universidad Politécnica de Valencia, Valencia (España).

Roudier, P., Tisseyre, B., Poilvé, H. y Roger, J-M. (2008). Management zone delineation using a modified watershed algorithm. Precision Agric 9, 233-250.

Ruiz, L.A., Porres, Mª.J., Recio, J.A. y Fernández-Sarría, A (2003). Prácticas de teledetección. Ed. Universidad Politécnica de Valencia - 4033.

Ruiz, L.A., Recio, J.A., Fernández-Sarría, A. y Hermosilla, T. (2010). A tool for objetc descriptive feature extraction: application to image classification and map updating. Geographic Object-Based Image Analysis, GEOBIA 2010. Ghent, Belgium.

Scott, J.H. y Burgan, R.E. (2005). Standard fire behaviour fuel models: a comprehensive set for use with rothermel's surface fire spread model. Gen. Tech. Rep. RMRS-GTR-153. Fort Collinsm CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. 72p.

Suárez, J.C., Ontiveros, C., Smithm S. y Snape, S. (2005). Use of airborne LIDAR and aerial photography in the estimation of individual tree heights in forestry. *Computer & Geosciences* 31, 253-262.

Tarabalka, Y., Chanossot, J. y Benediktsson, J.A. (2010). Segmentation and classification of hyperspectral images using watershed transformation. *Elsevier- ScienceDirect -Pattern Recognition* 43, 2367–2379.

Vincent, L. y Soille, P. (1991). Watersheds in digital spaces: An efficient algorithm based on immersionsimulations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(6), 583–598.

Viñas, O., Ruiz, A., Palà, V., Soler, E., Domingo, A. y Marco, V. (2009). Análisis de la sinergia de LIDAR con DCM y CASI para diferenciar olivos, algarrobos y almendros. *Revista de teledetección* 32, 86-105.

Wulder, M., Nieman, K.O. y Goodenough, D.G. (2000). Local Maximum Filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. *Remote Sensing of Environment* 73, 103-114.

Yu, X., Hyyppä, J., Holopainen, M. y Vastaranta, M. (2010). Comparison of Area-Based and Individual Tree-Based Methods for Predicting Plot-Level Forest Attributes. *Remote Sensing* 2, 1481-1495.

Anejo I
SITUACIÓN Y NUMERACIÓN DE PARCELAS

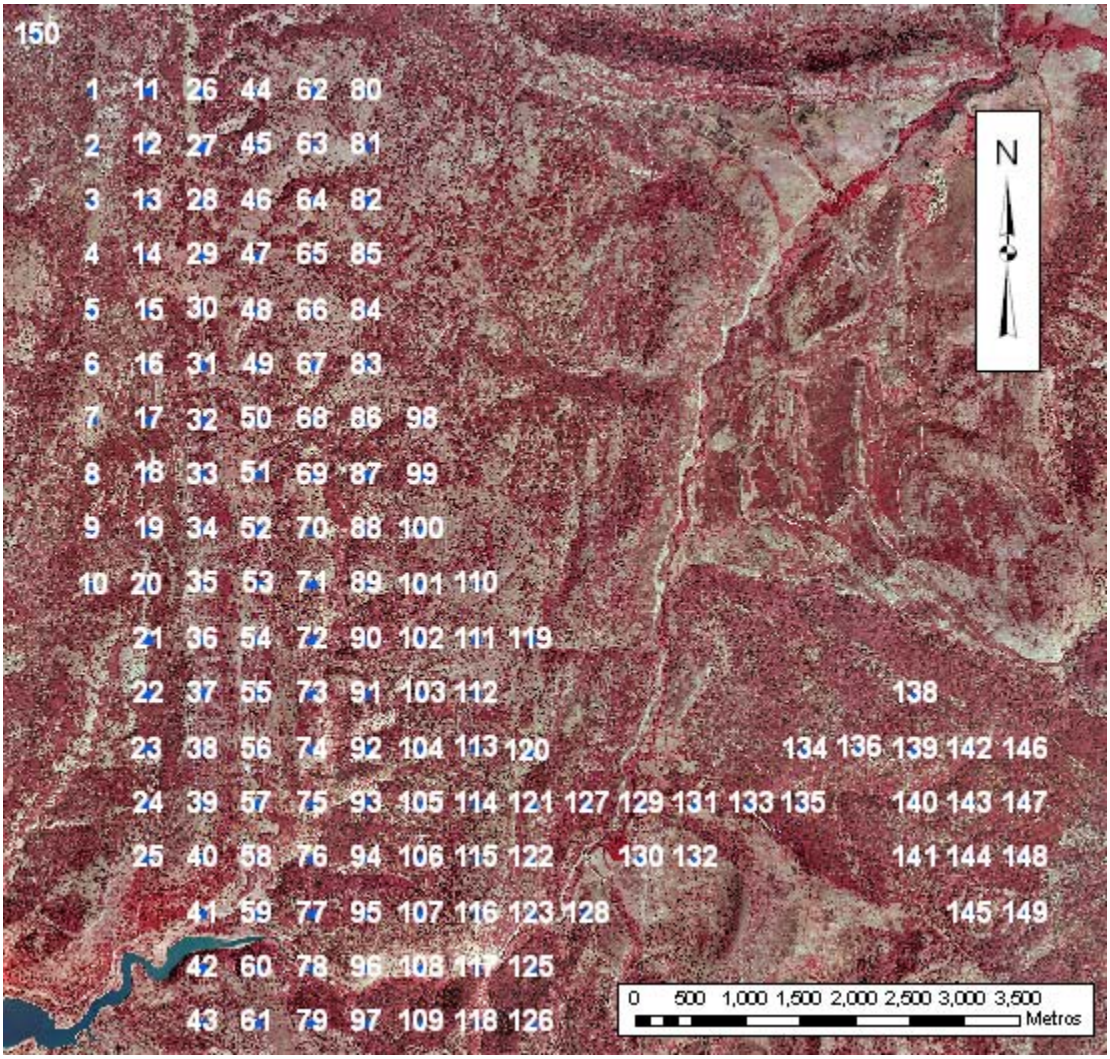

Figura A-I, 1. Situación de las parcelas de referencia.

Anejo II

PARCELAS DE EVALUACIÓN

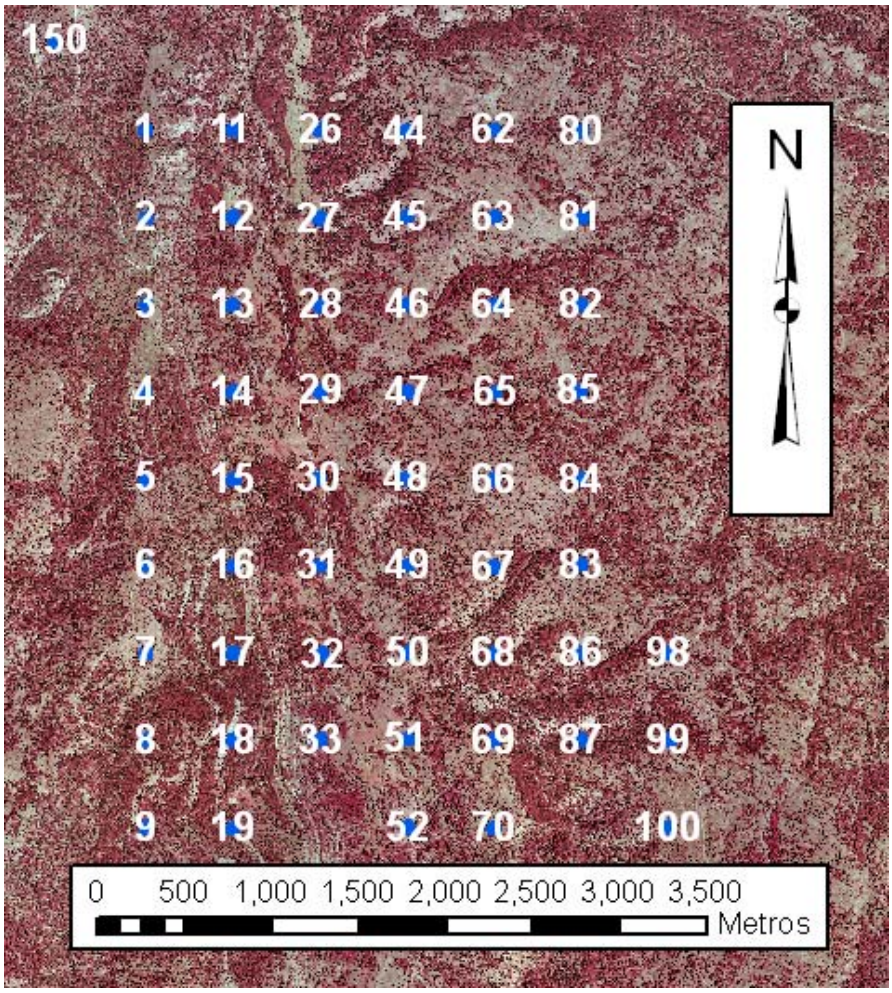

Figura A-II, 1. Parcelas de referencia tomadas para la evaluación.

Anejo III

RESULTADOS DE LAS “DIANAS” DEL MÉTODO DE LA PRIMERA SEGMENTACIÓN

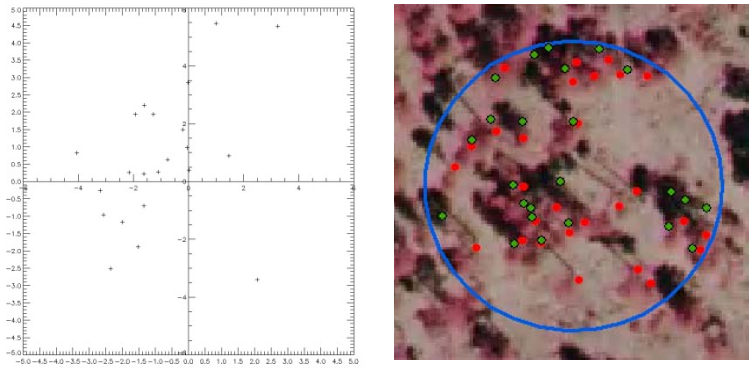

Figura A-III, 1. Parcela 1.

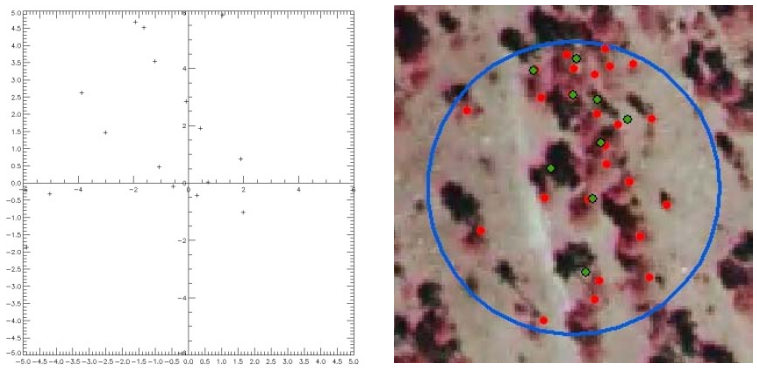

Figura A-III, 2. Parcela 2.

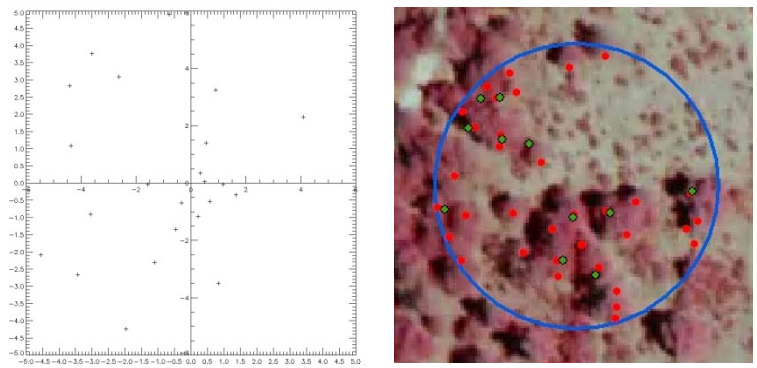

Figura A-III, 3. Parcela 3.

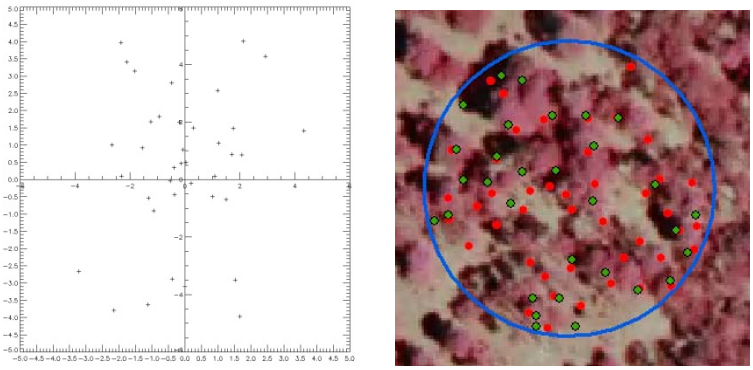

Figura A-III, 4. Parcela 4.

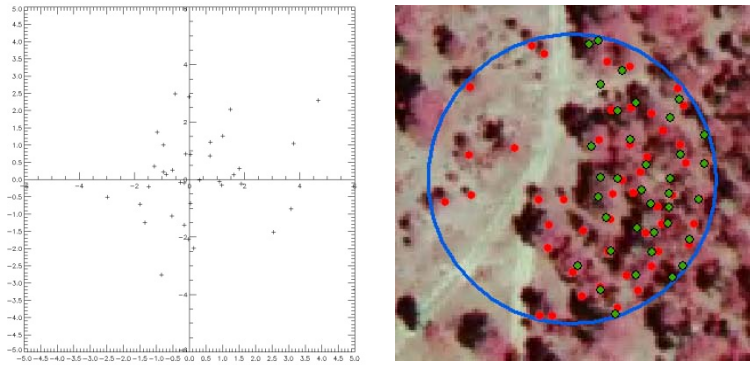

Figura A-III, 5. Parcela 5.

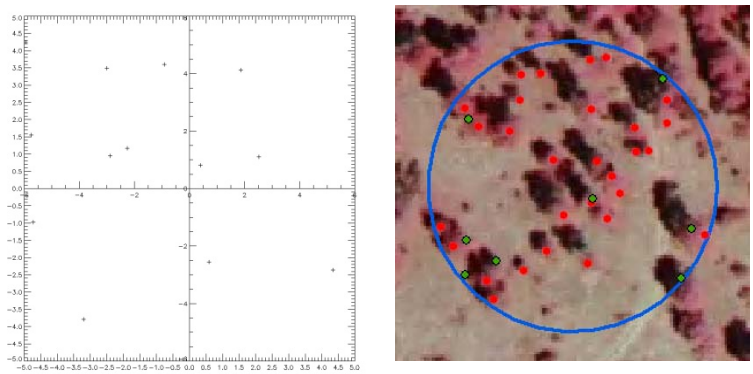

Figura A-III, 6. Parcela 6.

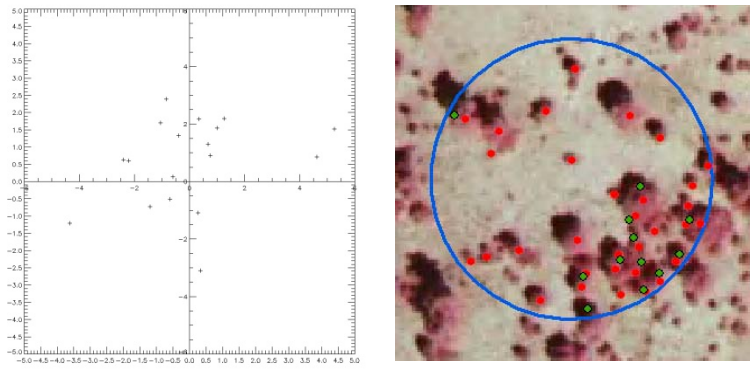

Figura A-III, 7. Parcela 7.

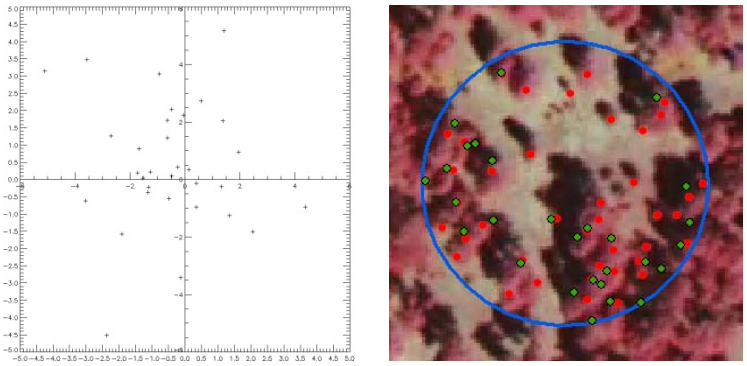

Figura A-III, 8. Parcela 8.

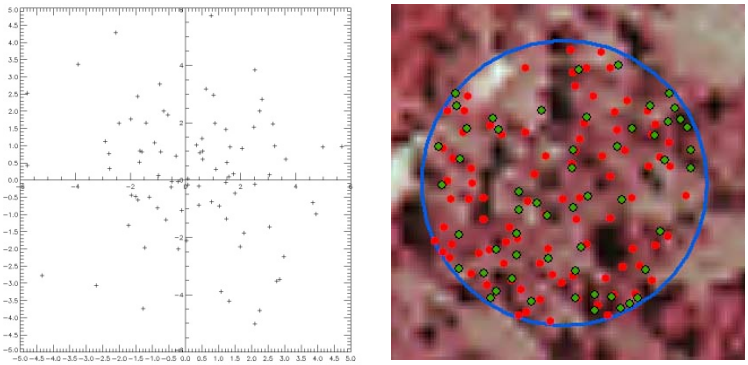

Figura A-III, 9. Parcela 9.

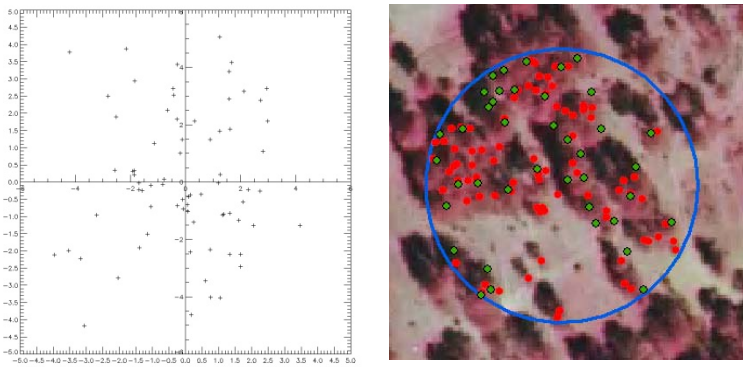

Figura A-III, 10. Parcela 11.

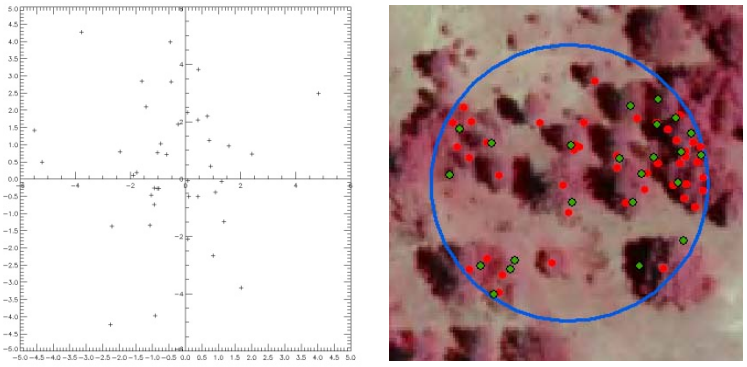

Figura A-III, 11. Parcela 12.

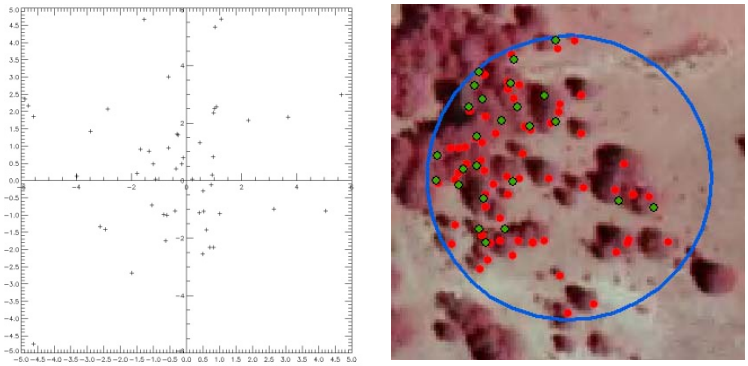

Figura A-III, 12. Parcela 13.

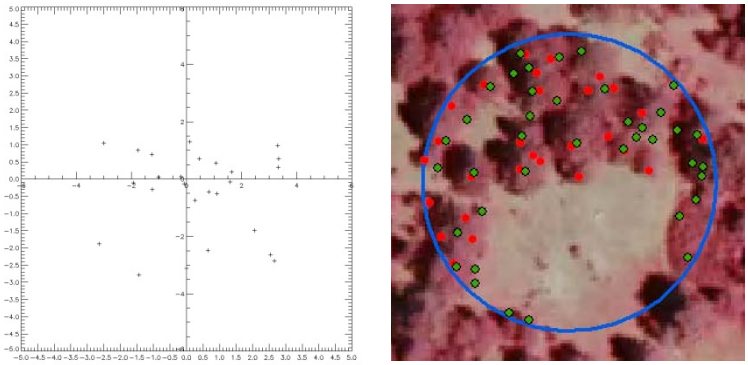

Figura A-III, 13. Parcela 14.

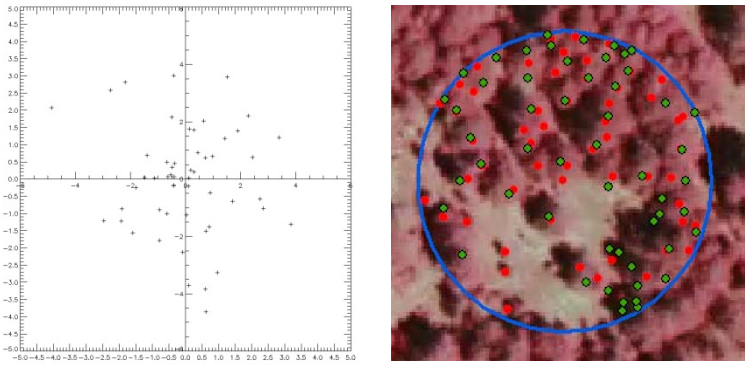

Figura A-III, 14. Parcela 15.

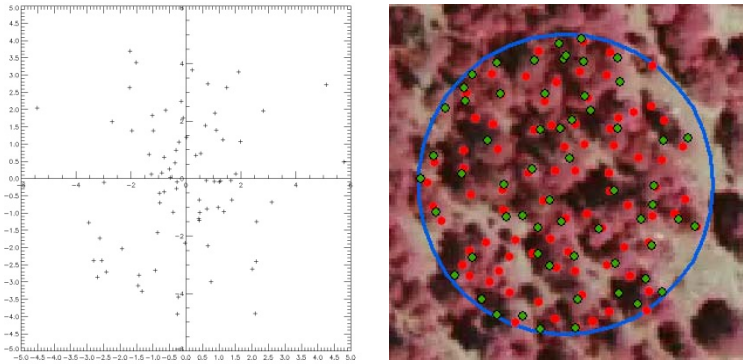

Figura A-III, 15. Parcela 16.

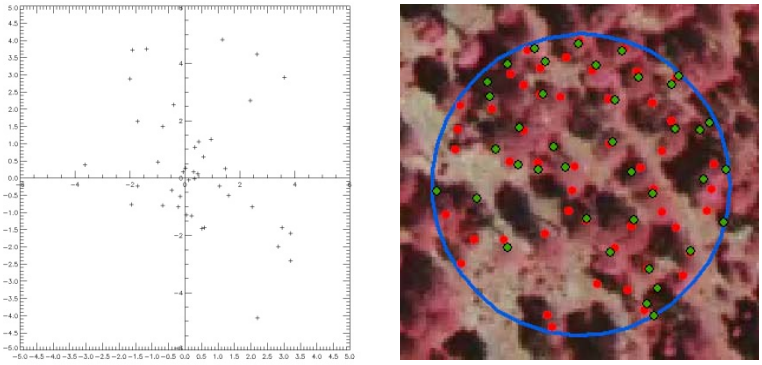

Figura A-III, 16. Parcela 17.

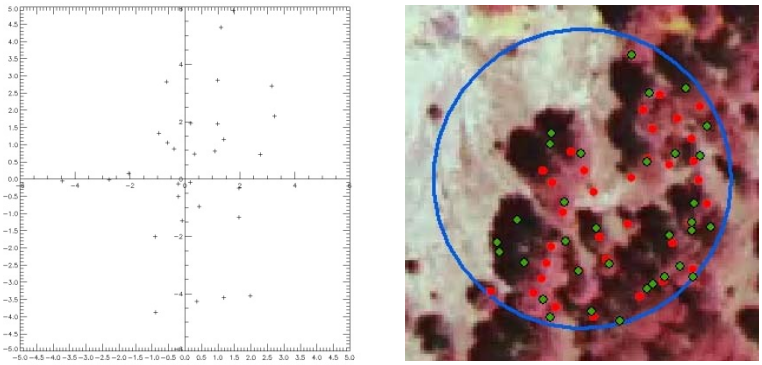

Figura A-III, 17. Parcela 18.

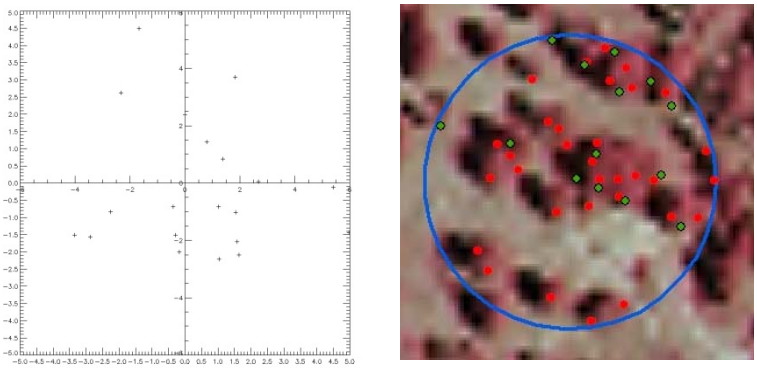

Figura A-III, 18. Parcela 19.

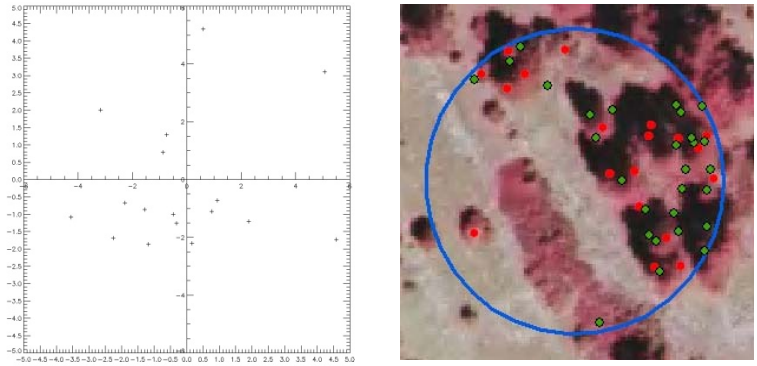

Figura A-III, 19. Parcela 26.

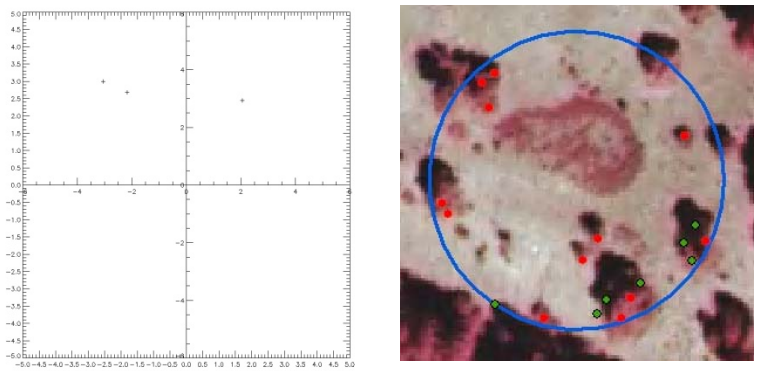

Figura A-III, 20. Parcela 27.

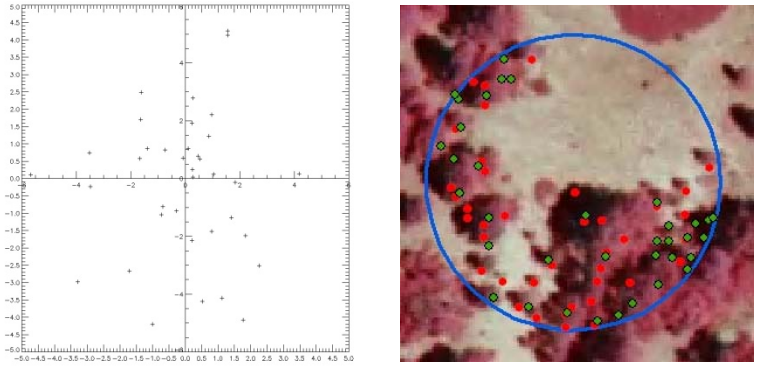

Figura A-III, 21. Parcela 28.

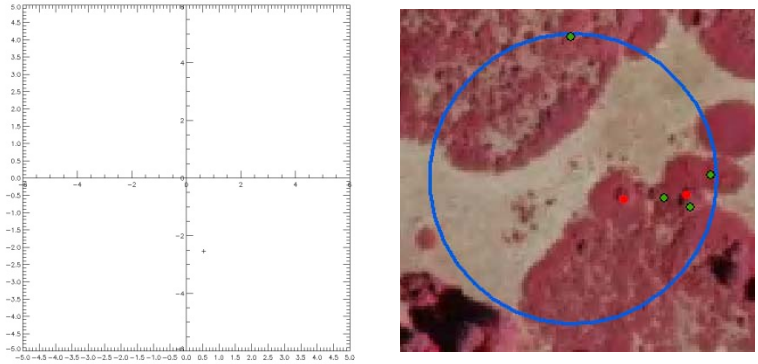

Figura A-III, 22. Parcela 29.

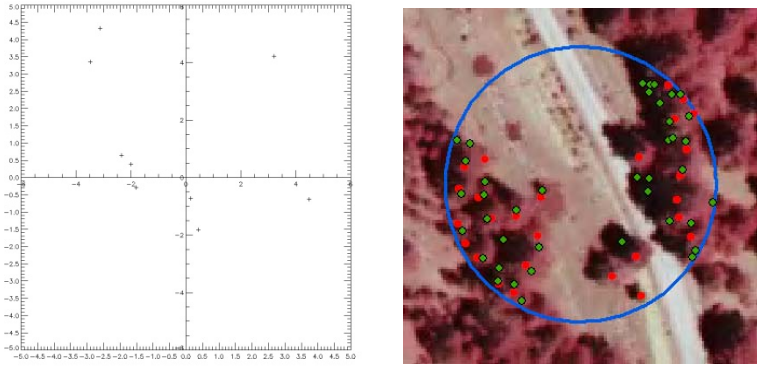

Figura A-III, 23. Parcela 30.

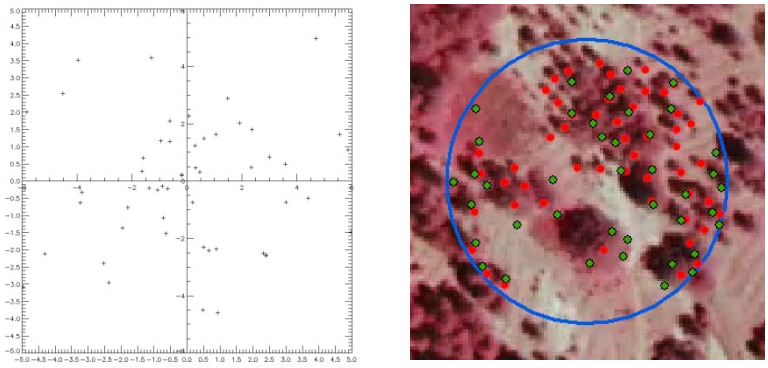

Figura A-III, 24. Parcela 31.

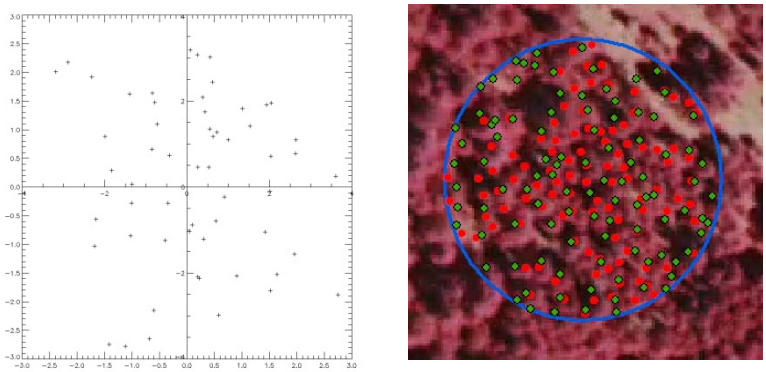

Figura A-III, 25. Parcela 32.

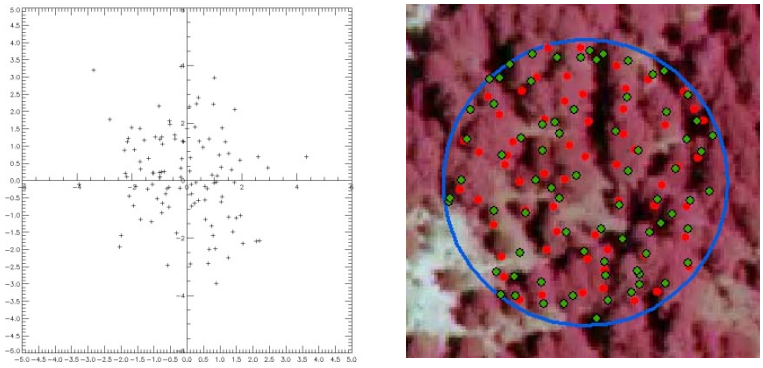

Figura A-III, 26. Parcela 33.

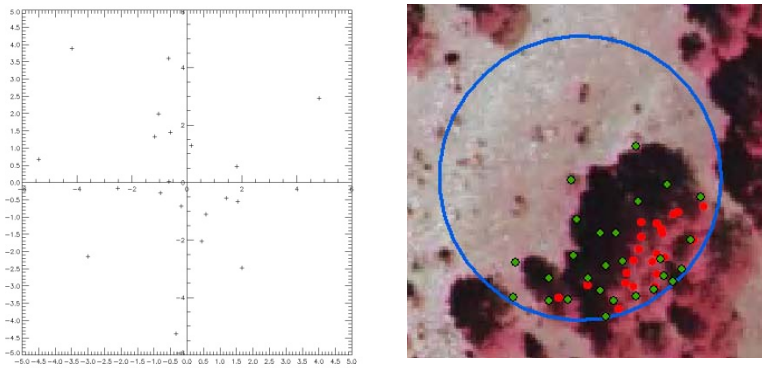

Figura A-III, 27. Parcela 44.

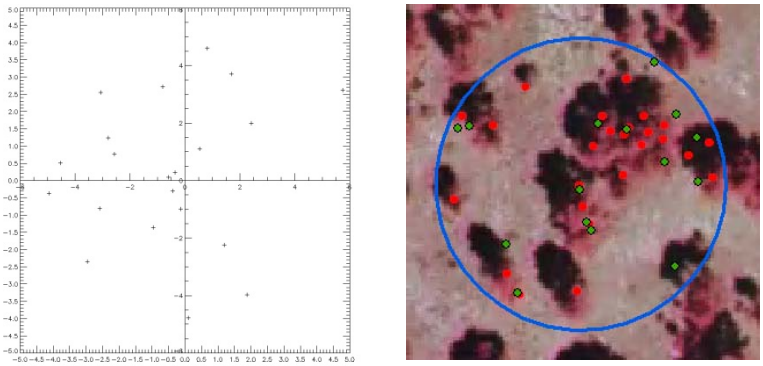

Figura A-III, 28. Parcela 45.

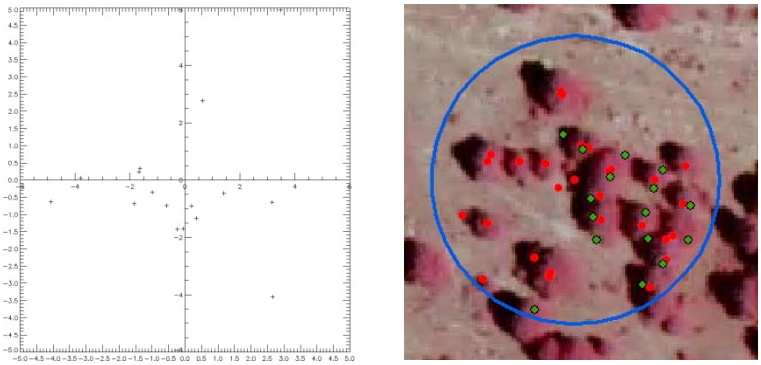

Figura A-III, 29. Parcela 46.

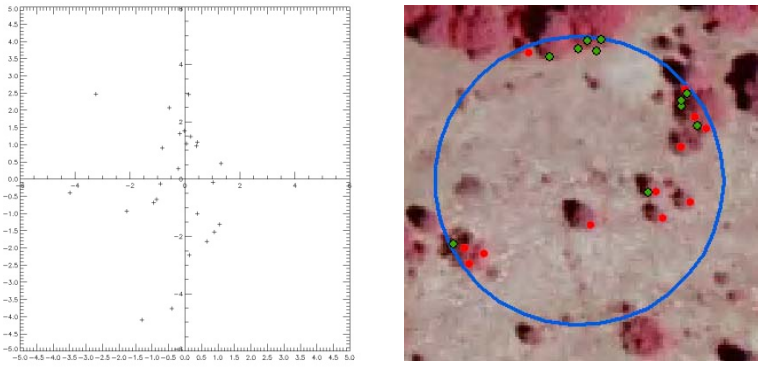

Figura A-III, 30. Parcela 47.

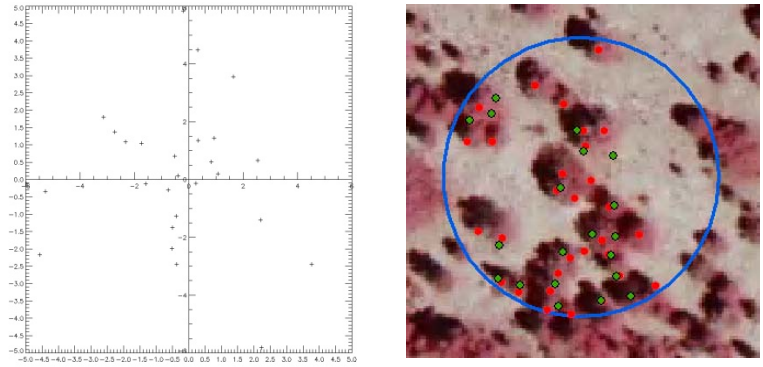

Figura A-III, 31. Parcela 48.

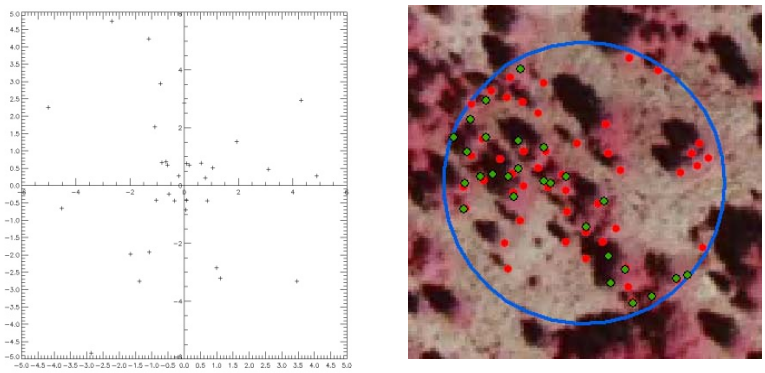

Figura A-III, 32. Parcela 49.

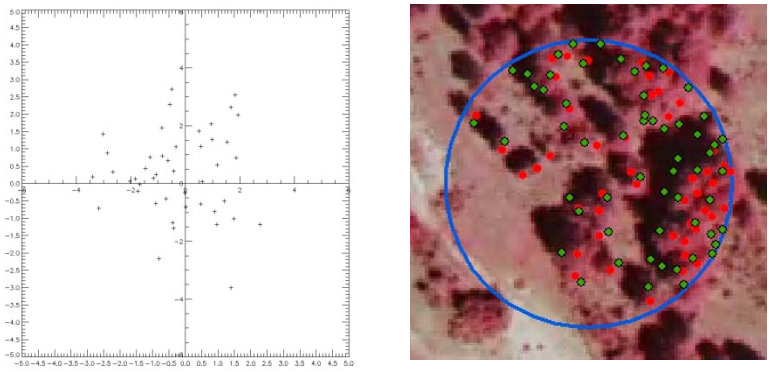

Figura A-III, 33. Parcela 50.

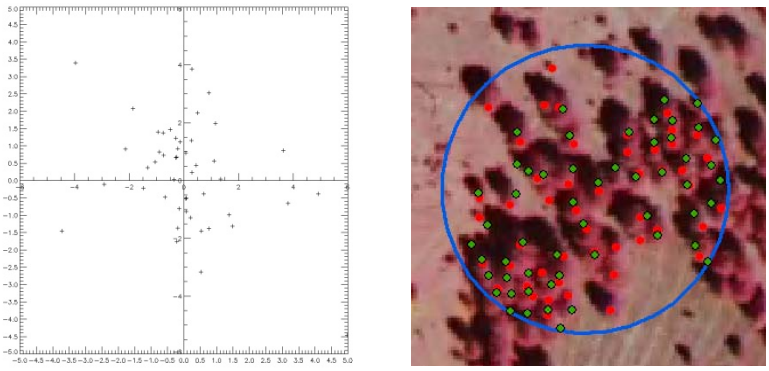

Figura A-III, 34. Parcela 51.

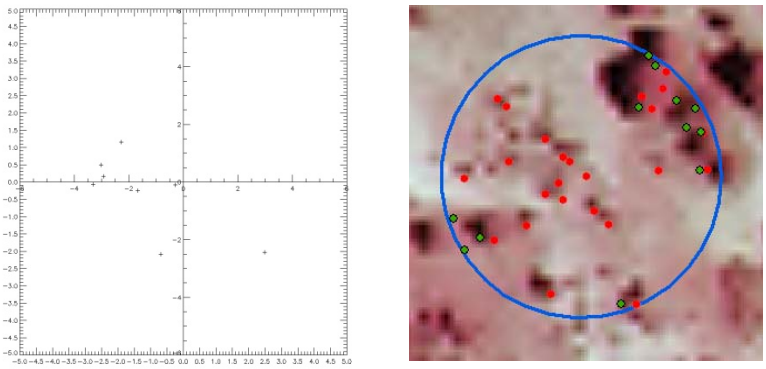

Figura A-III, 35. Parcela 52.

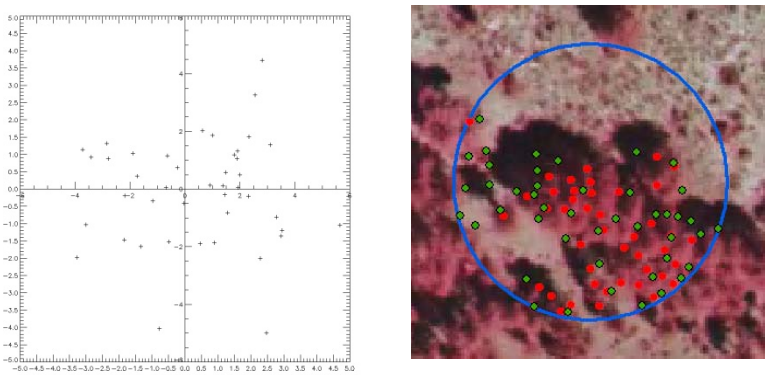

Figura A-III, 36. Parcela 62.

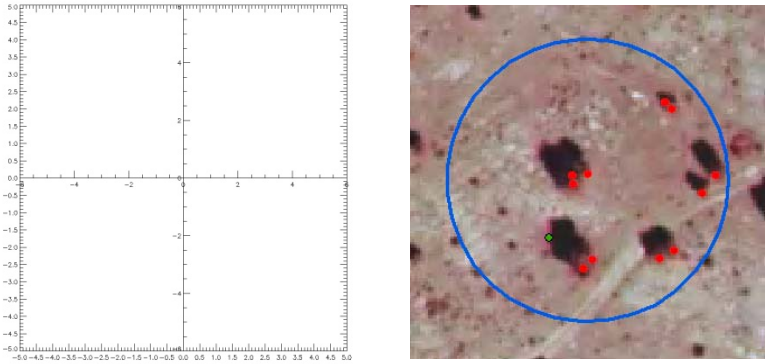

Figura A-III, 37. Parcela 63.

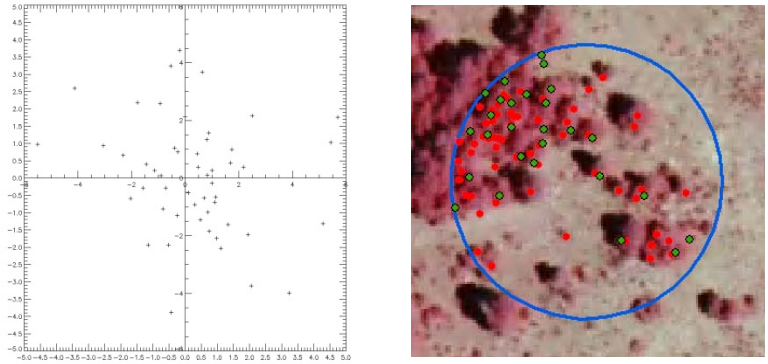

Figura A-III, 38. Parcela 64.

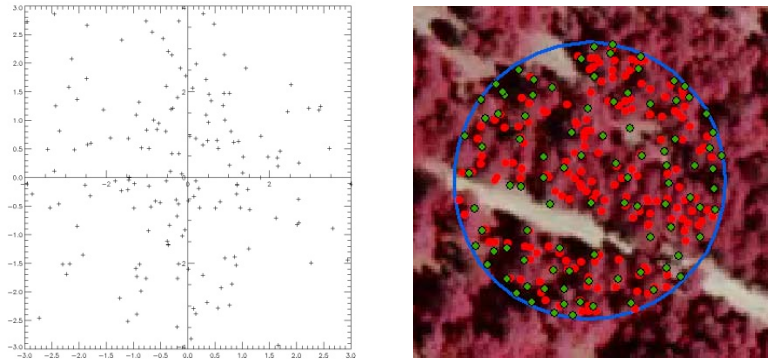

Figura A-III, 39. Parcela 65.

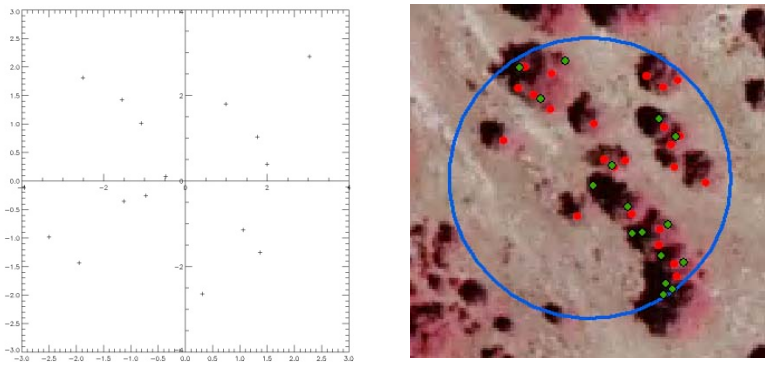

Figura A-III, 40. Parcela 66.

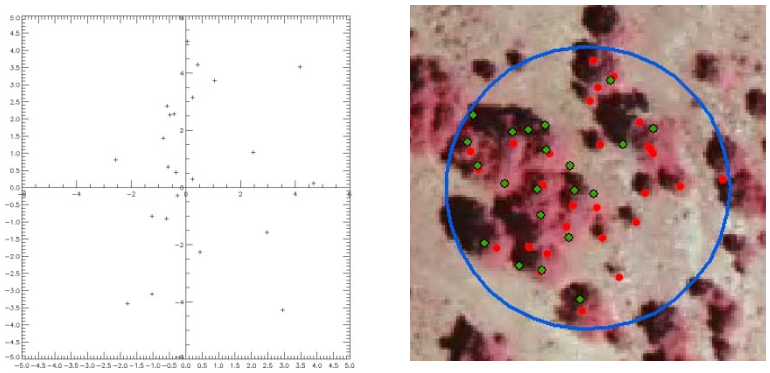

Figura A-III, 41. Parcela 67.

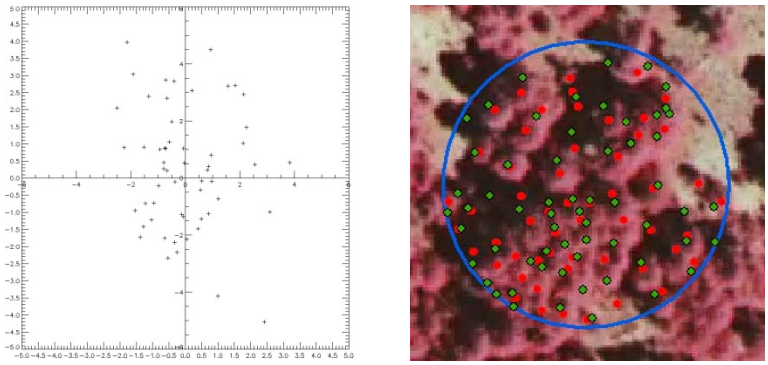

Figura A-III, 42. Parcela 68.

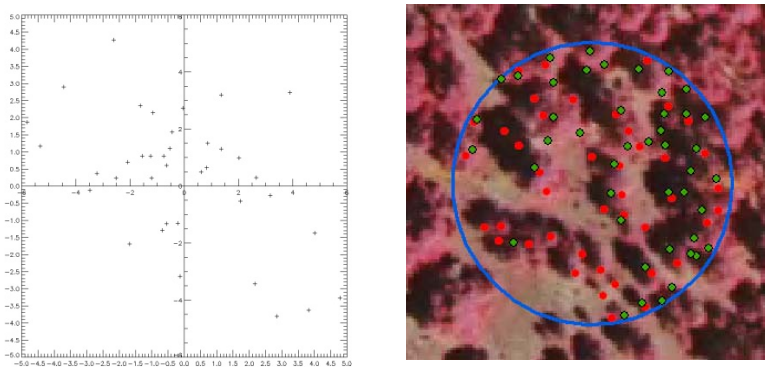

Figura A-III, 43. Parcela 69.

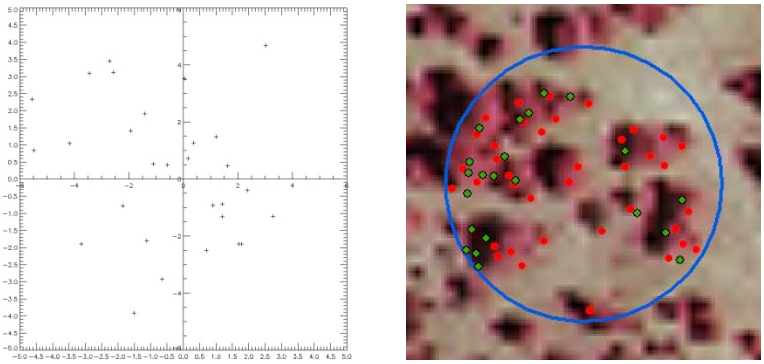

Figura A-III, 44. Parcela 70.

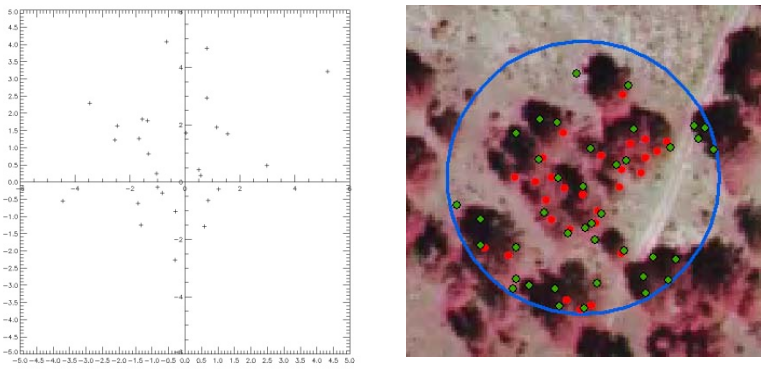

Figura A-III, 45. Parcela 80.

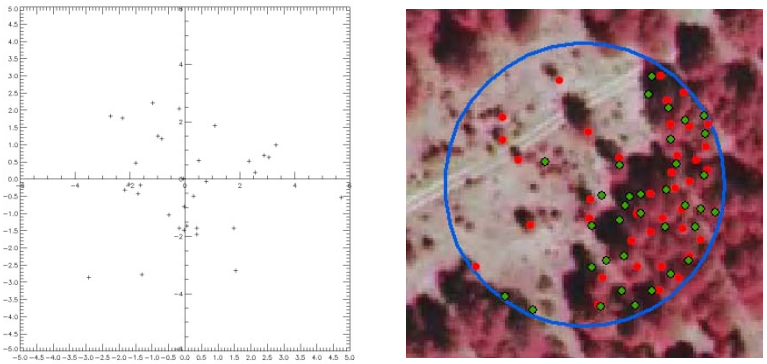

Figura A-III, 46. Parcela 81.

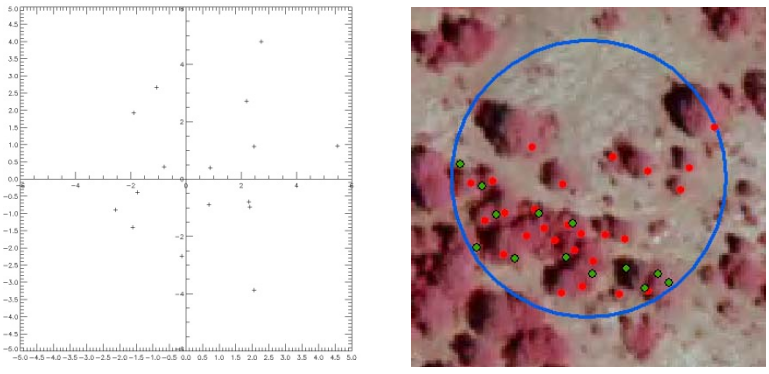

Figura A-III, 47. Parcela 82.

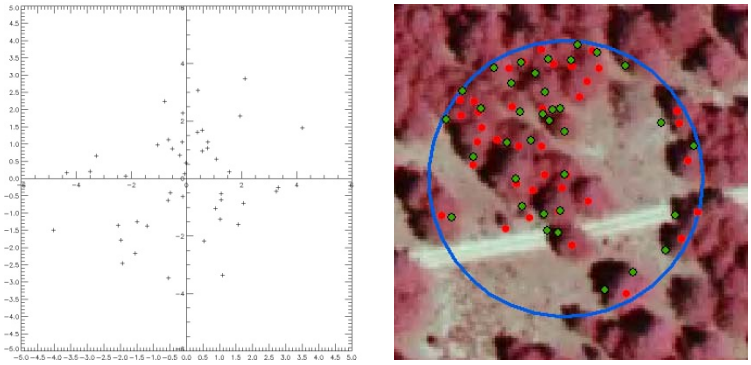

Figura A-III, 48. Parcela 83.

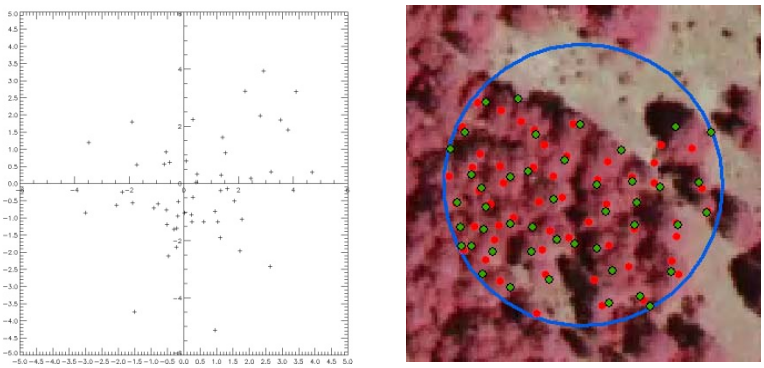

Figura A-III, 49. Parcela 84.

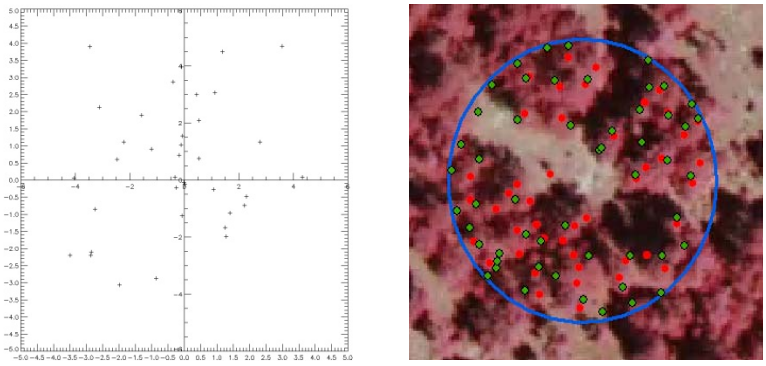

Figura A-III, 50. Parcela 85.

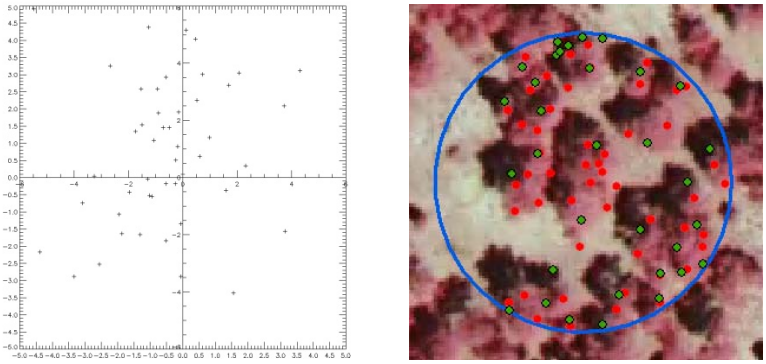

Figura A-III, 51. Parcela 86.

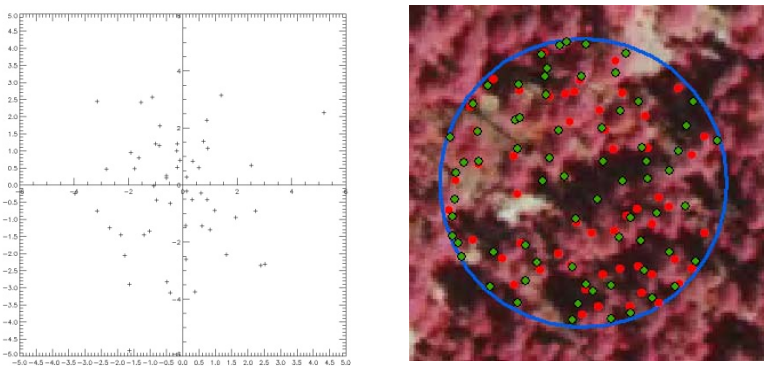

Figura A-III, 52. Parcela 87.

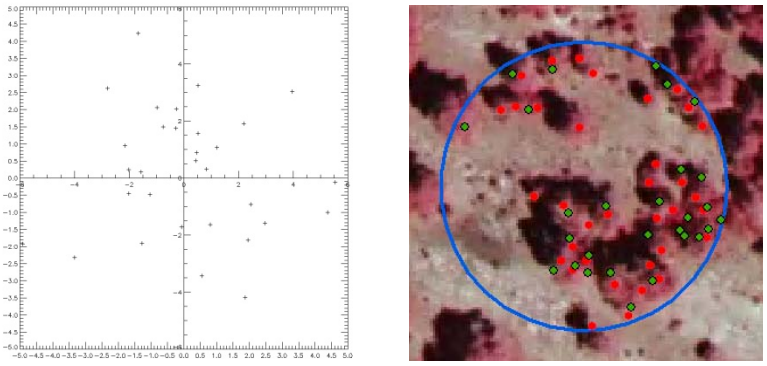

Figura A-I, 53. Parcela 98.

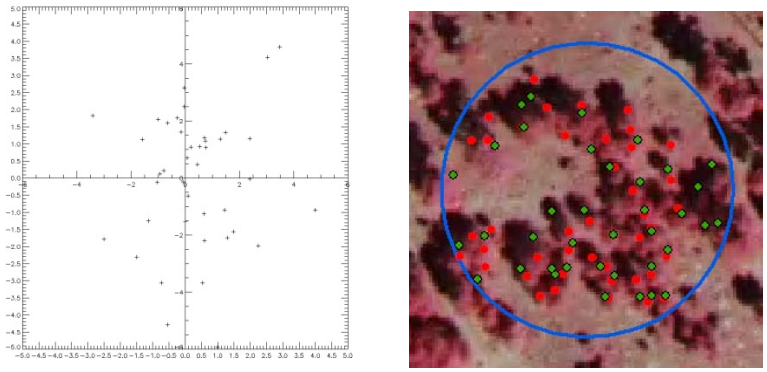

Figura A-III, 54. Parcela 99.

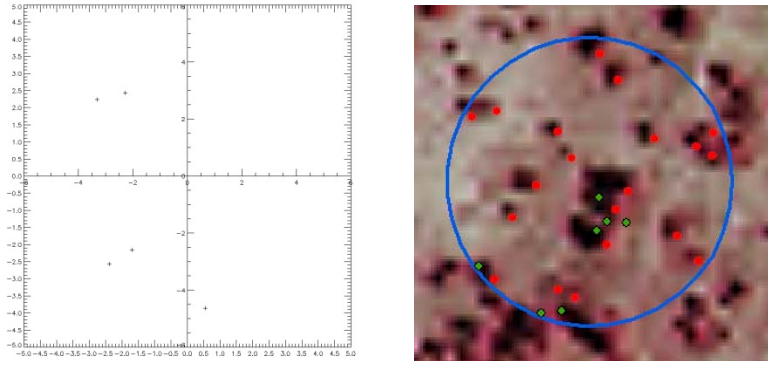

Figura A-III, 55. Parcela 100.

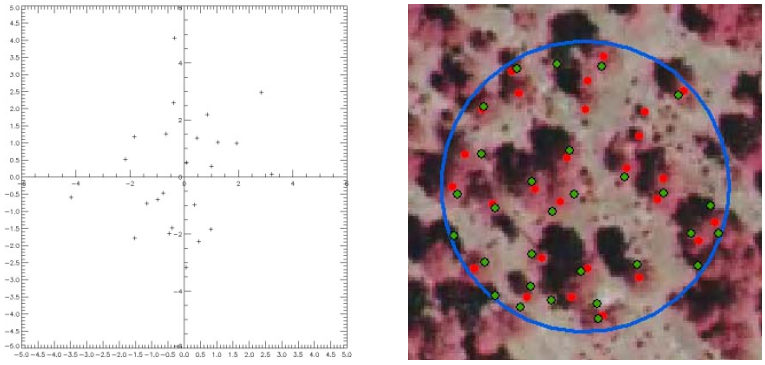

Figura A-III, 56. Parcela 150.

Anejo IV

RESULTADOS DE LAS “DIANAS” DEL MÉTODO DE LA POST-SEGMENTACIÓN

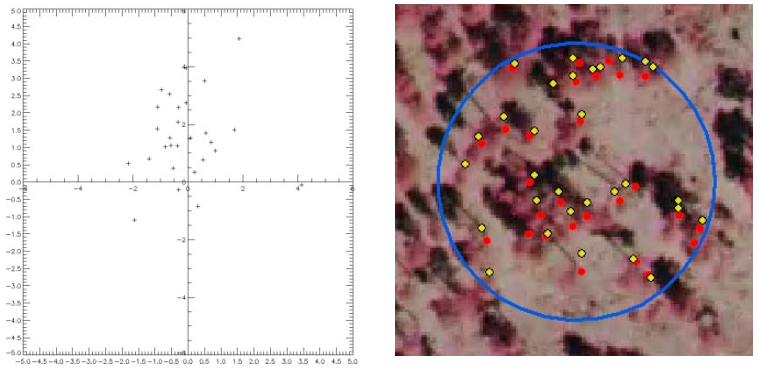

Figura A-IV, 1. Parcela 1.

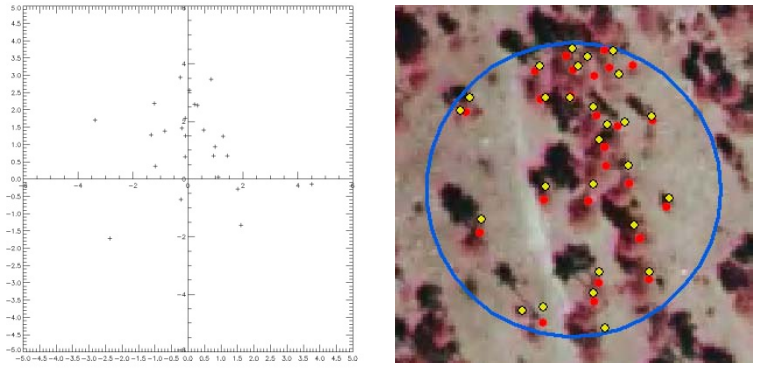

Figura A- IV, 2. Parcela 2.

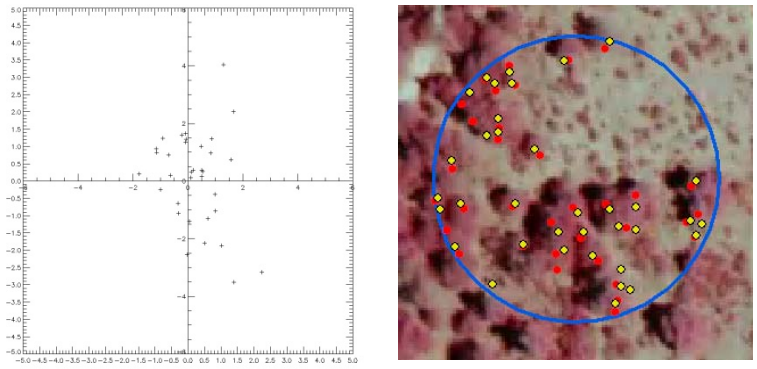

Figura A- IV, 3. Parcela 3.

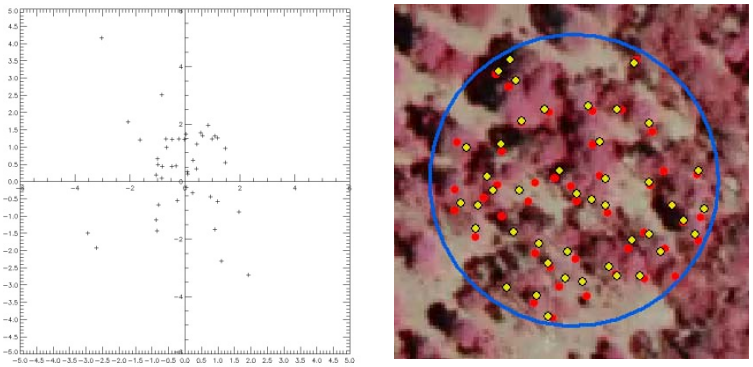

Figura A- IV, 4. Parcela 4.

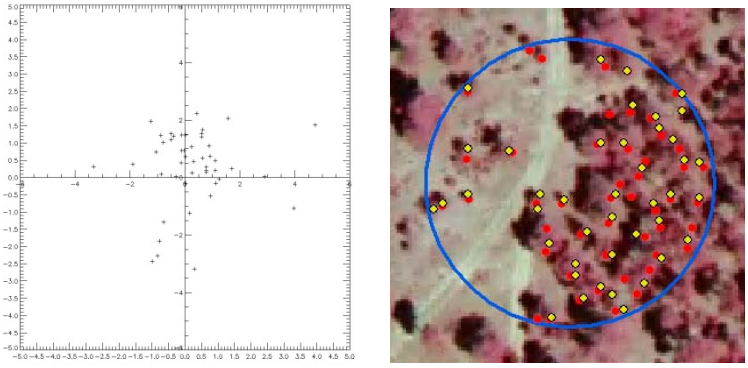

Figura A- IV, 5. Parcela 5.

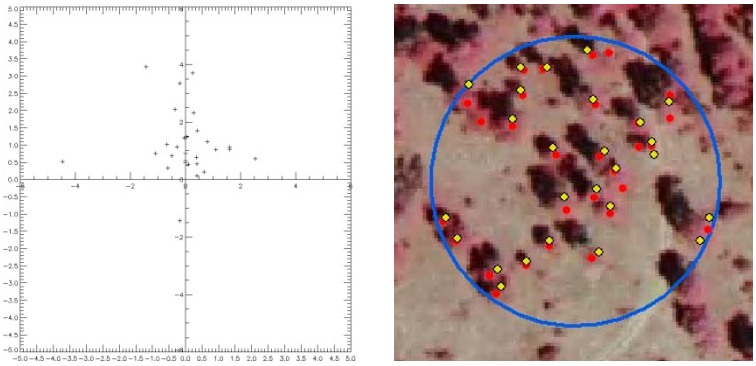

Figura A- IV, 6. Parcela 6.

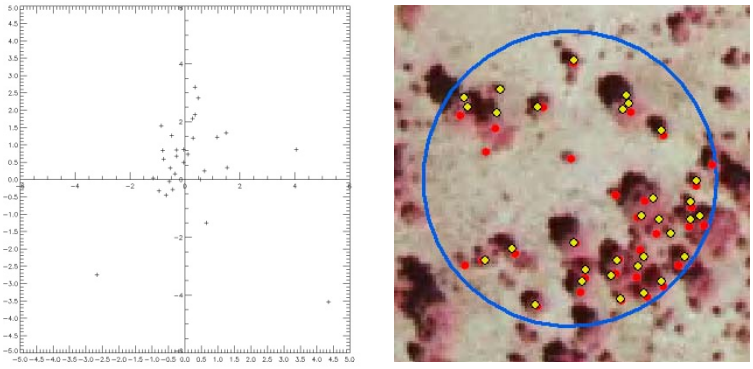

Figura A- IV, 7. Parcela 7.

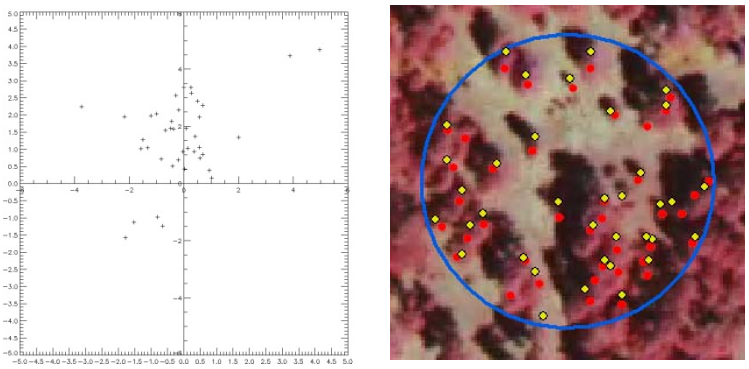

Figura A- IV, 8. Parcela 8.

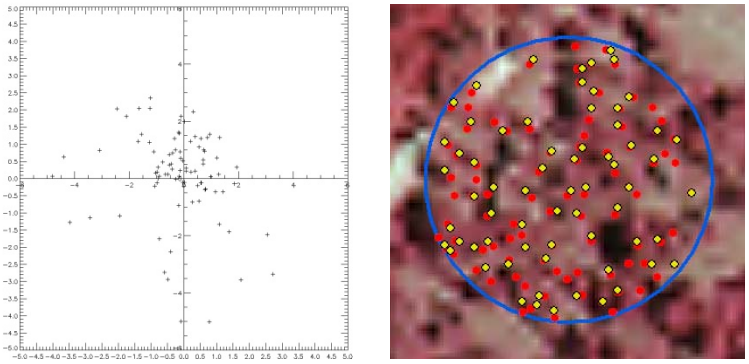

Figura A- IV, 9. Parcela 9.

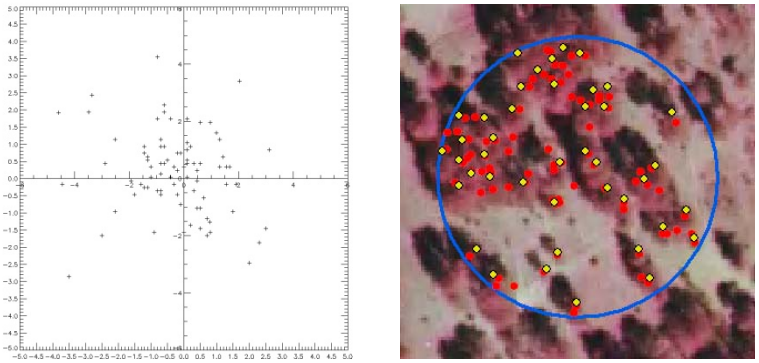

Figura A- IV, 10. Parcela 11.

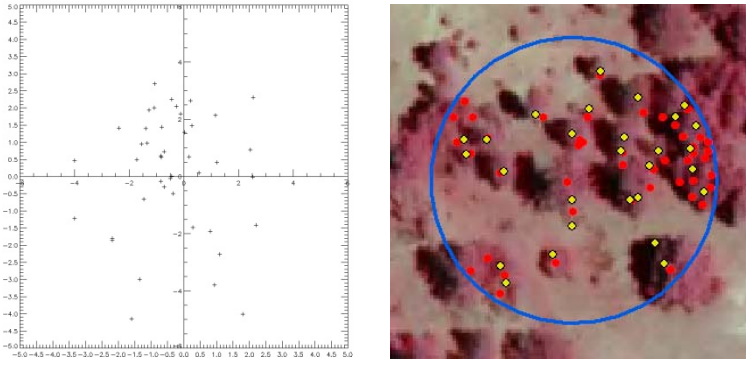

Figura A- IV, 11. Parcela 12.

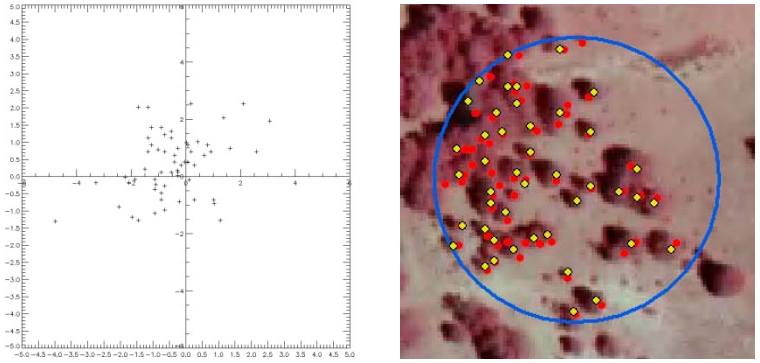

Figura A- IV, 12. Parcela 13.

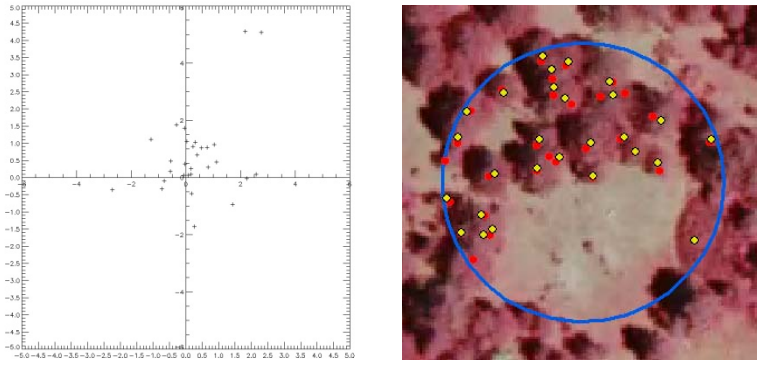

Figura A- IV, 13. Parcela 14.

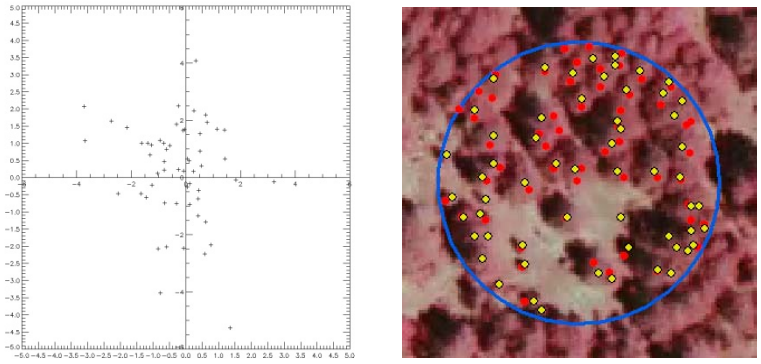

Figura A- IV, 14. Parcela 15.

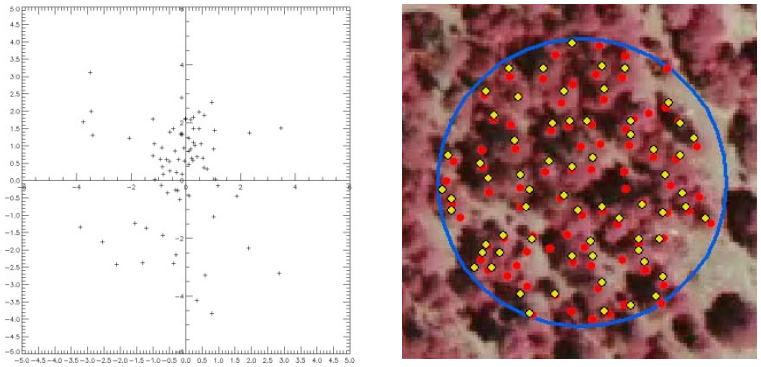

Figura A- IV, 15. Parcela 16.

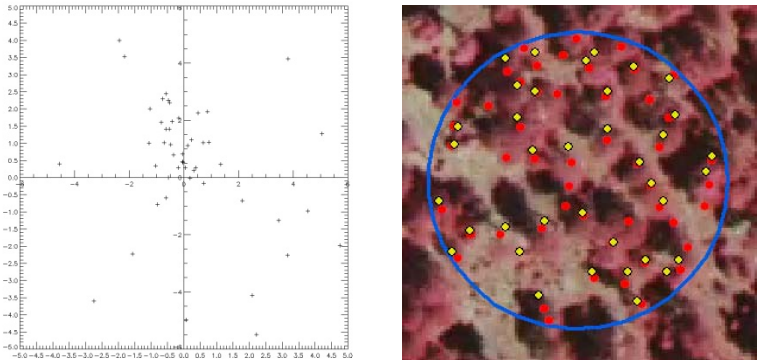

Figura A- IV, 16. Parcela 17.

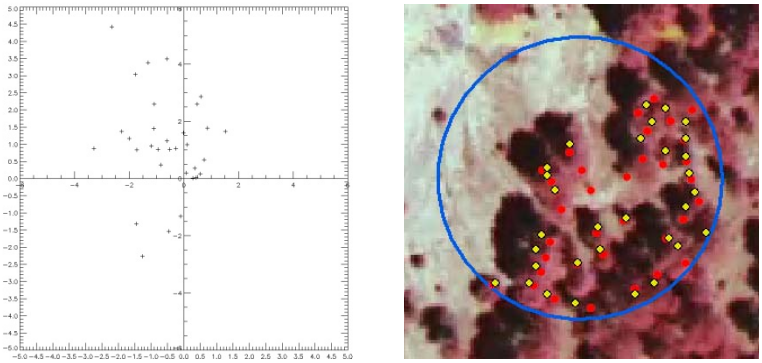

Figura A- IV, 17. Parcela 18.

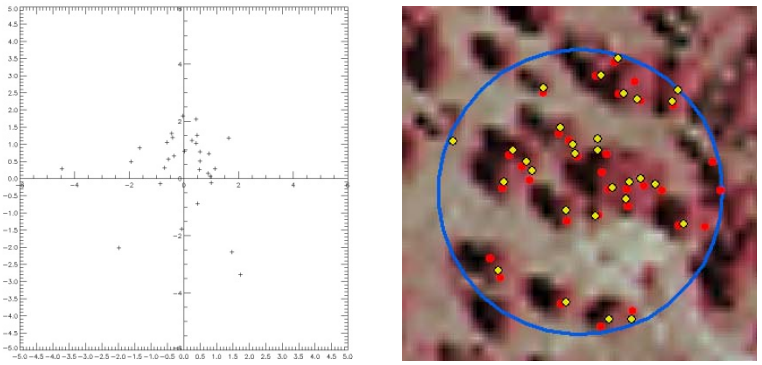

Figura A- IV, 18. Parcela 19.

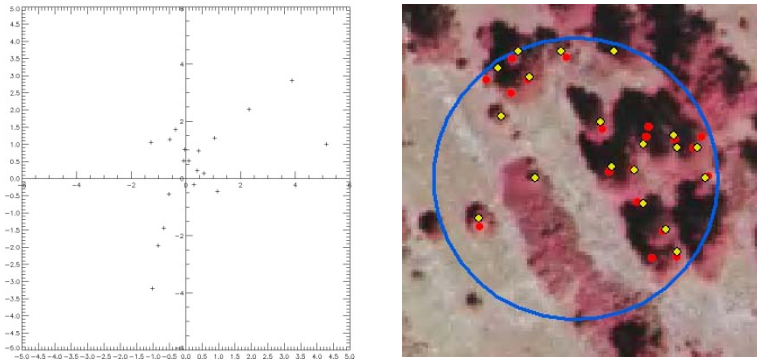

Figura A- IV, 19. Parcela 26.

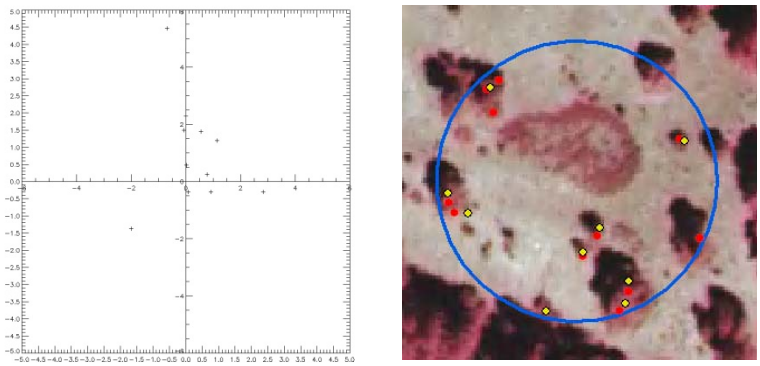

Figura A- IV, 20. Parcela 27.

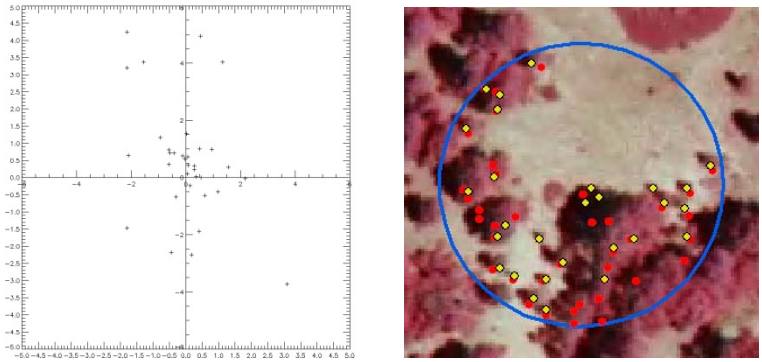

Figura A- IV, 21. Parcela 28.

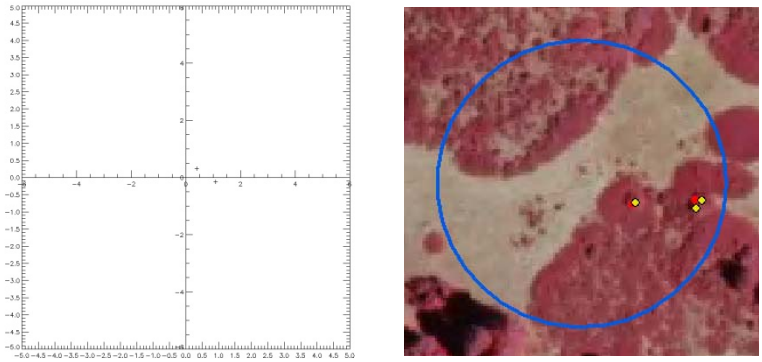

Figura A- IV, 22. Parcela 29.

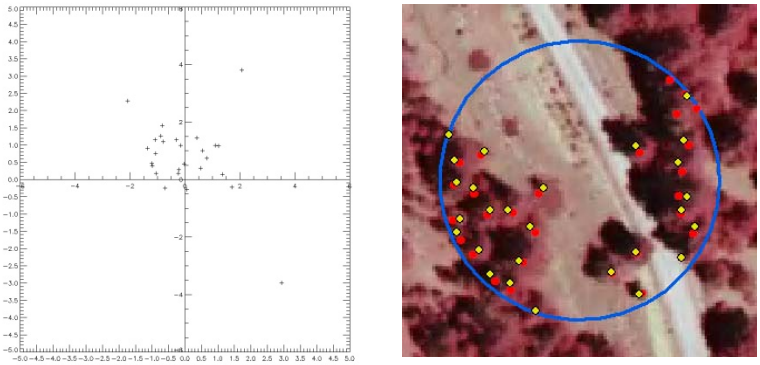

Figura A- IV, 23. Parcela 30.

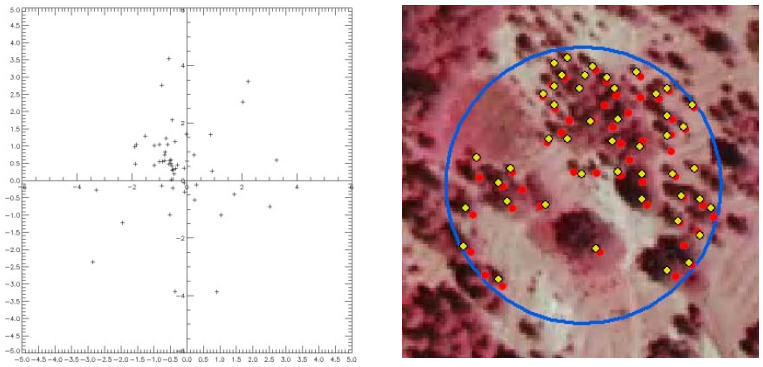

Figura A- IV, 24. Parcela 31.

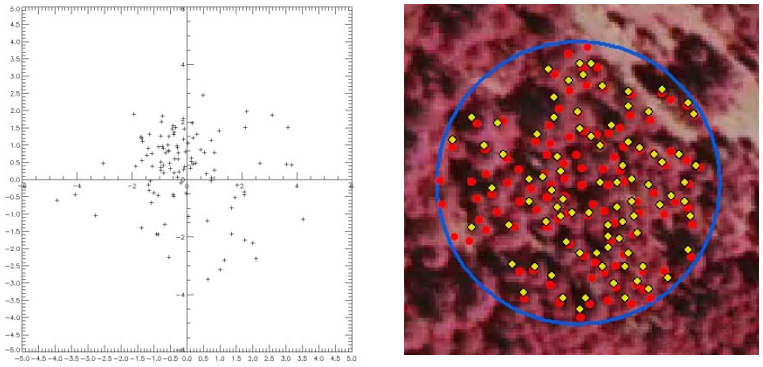

Figura A- IV, 25. Parcela 32.

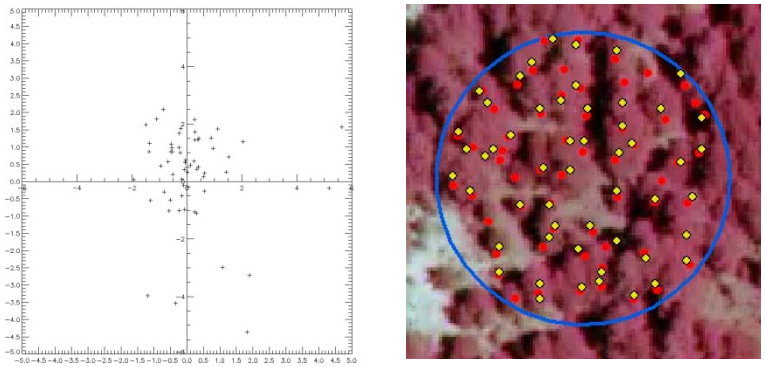

Figura A- IV, 26. Parcela 33.

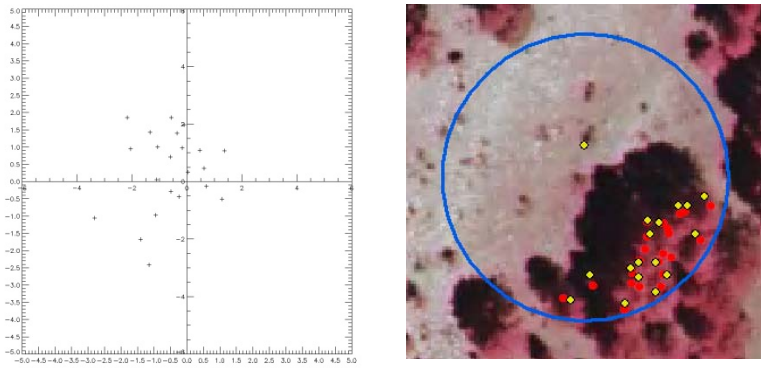

Figura A- IV, 27. Parcela 44.

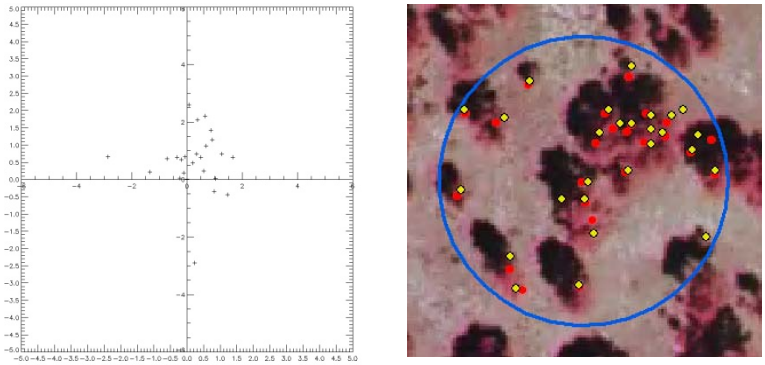

Figura A- IV, 28. Parcela 45.

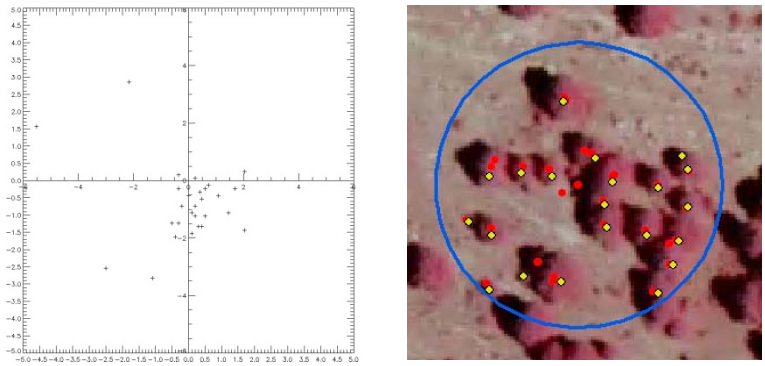

Figura A- IV, 29. Parcela 46.

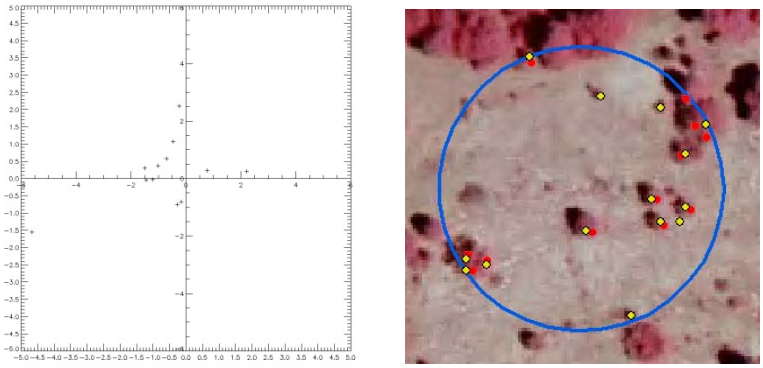

Figura A- IV, 30. Parcela 47.

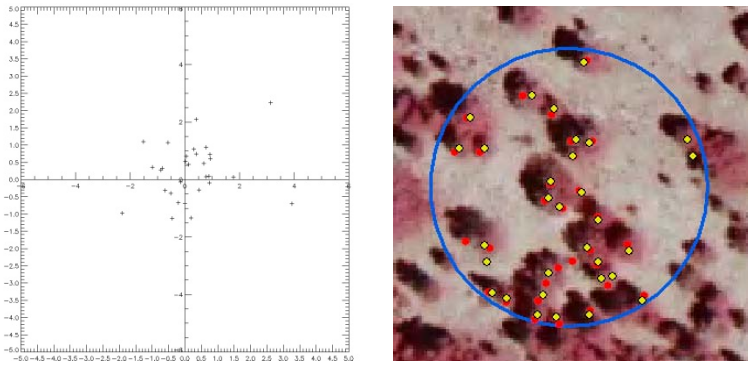

Figura A- IV, 31. Parcela 48.

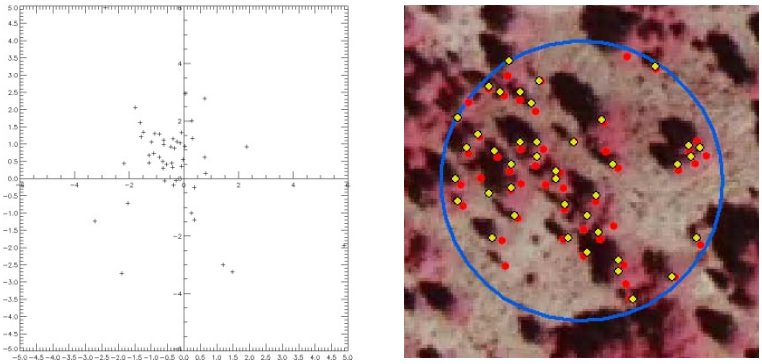

Figura A- IV, 32. Parcela 49.

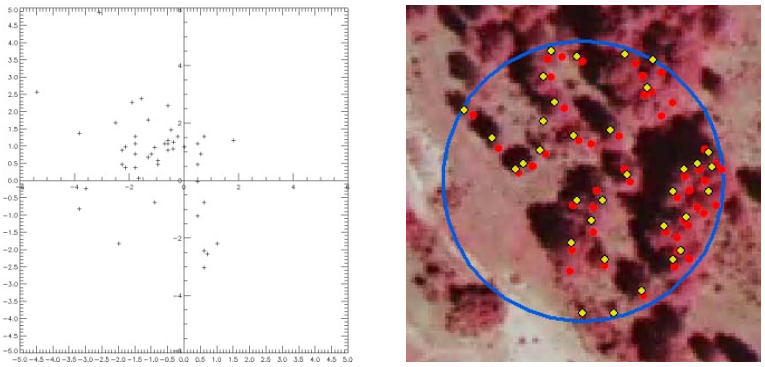

Figura A- IV, 33. Parcela 50.

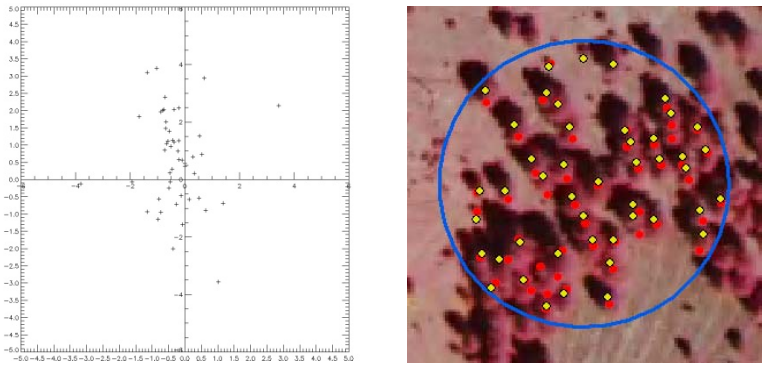

Figura A- IV, 34. Parcela 51.

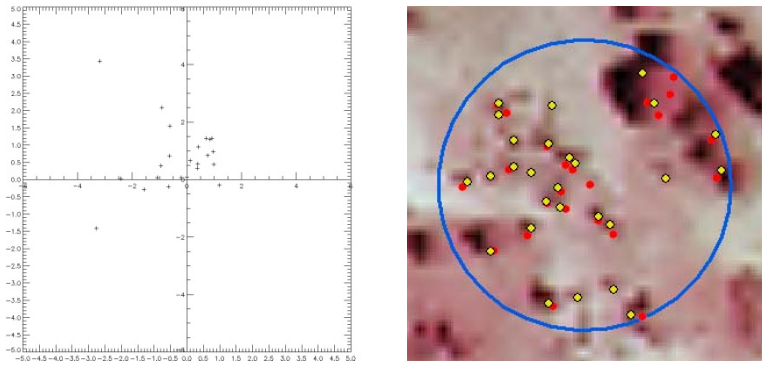

Figura A- IV, 35. Parcela 52.

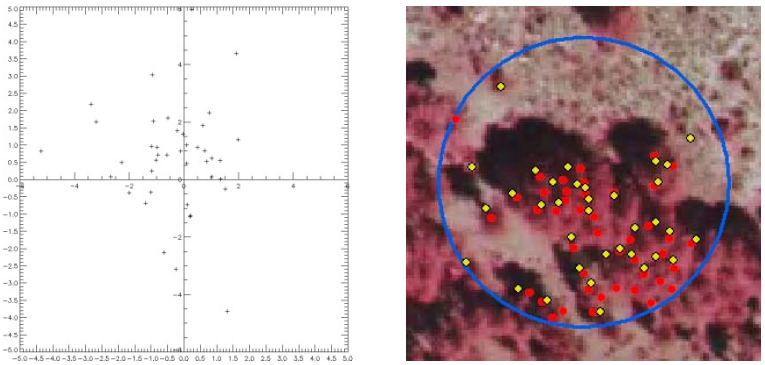

Figura A- IV, 36. Parcela 62.

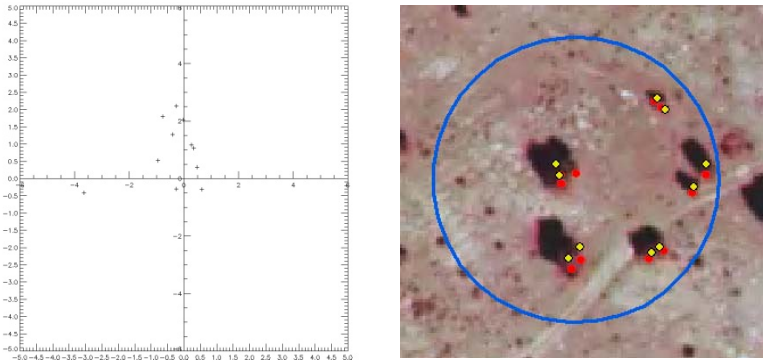

Figura A- IV, 37. Parcela 63.

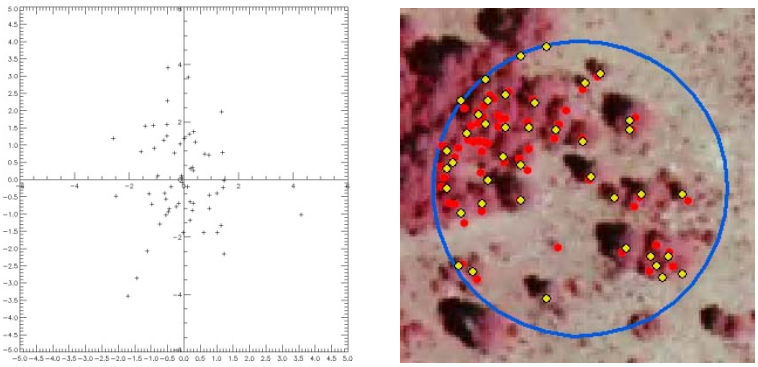

Figura A- IV, 38. Parcela 64.

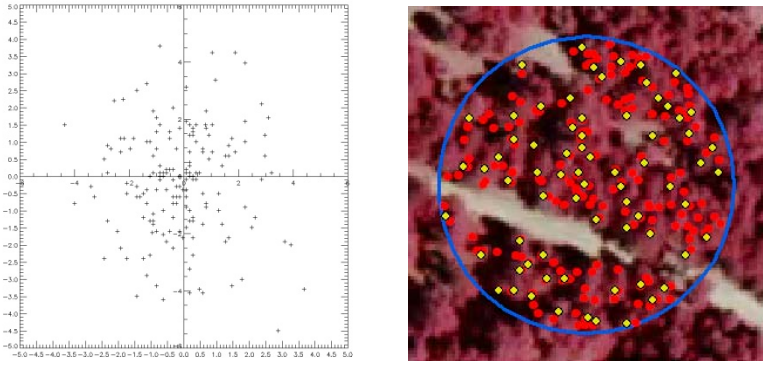

Figura A- IV, 39. Parcela 65.

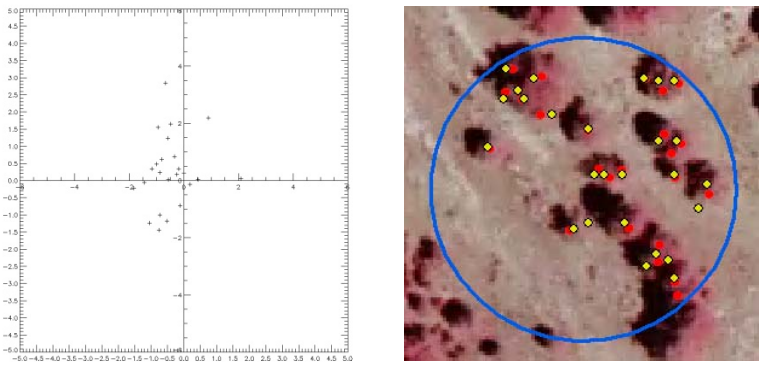

Figura A- IV, 40. Parcela 66.

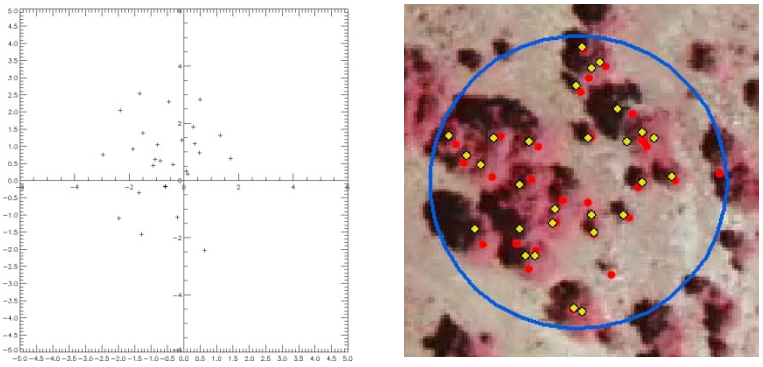

Figura A- IV, 41. Parcela 67.

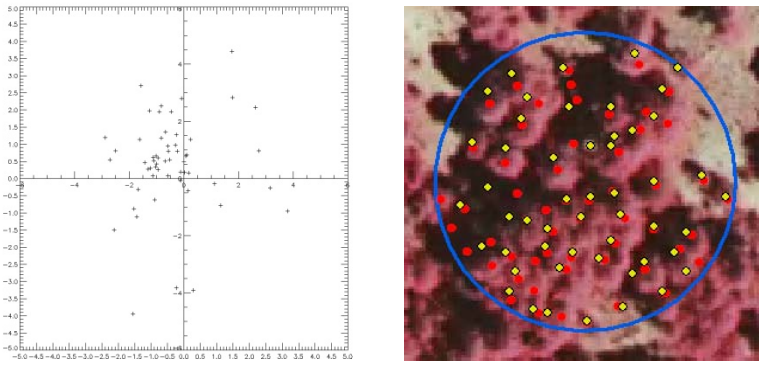

Figura A- IV, 42. Parcela 68.

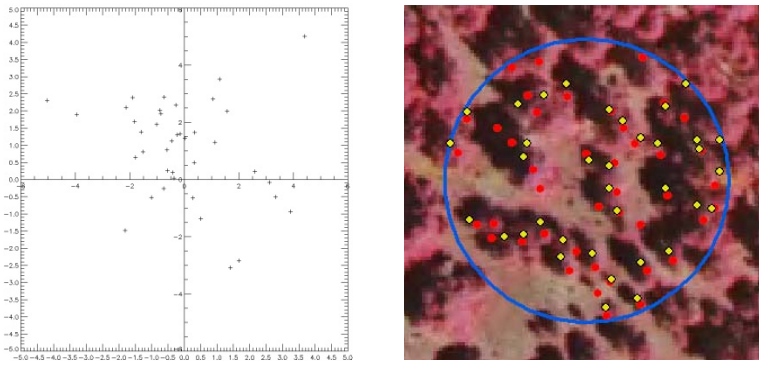

Figura A- IV, 43. Parcela 69.

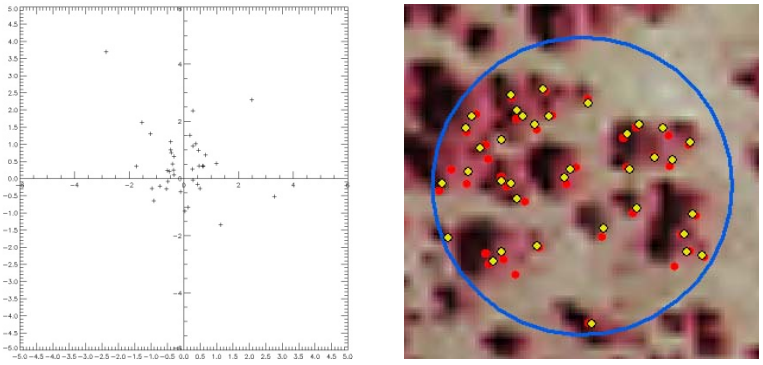

Figura A- IV, 44. Parcela 70.

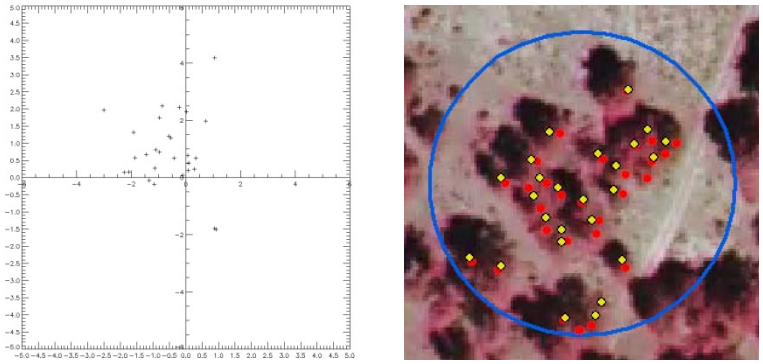

Figura A- IV, 45. Parcela 80.

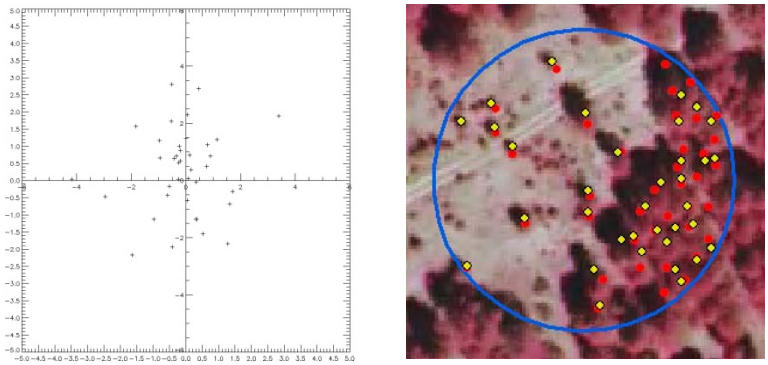

Figura A- IV, 46. Parcela 81.

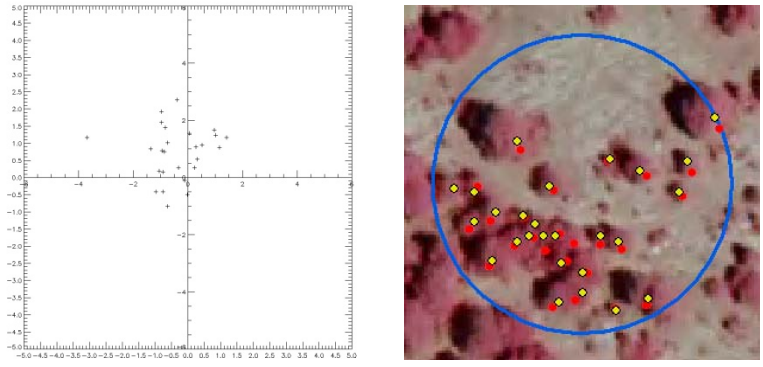

Figura A- IV, 47. Parcela 82.

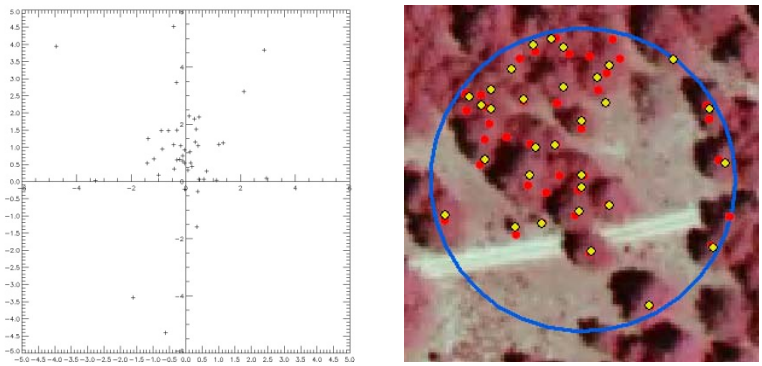

Figura A- IV, 48. Parcela 83.

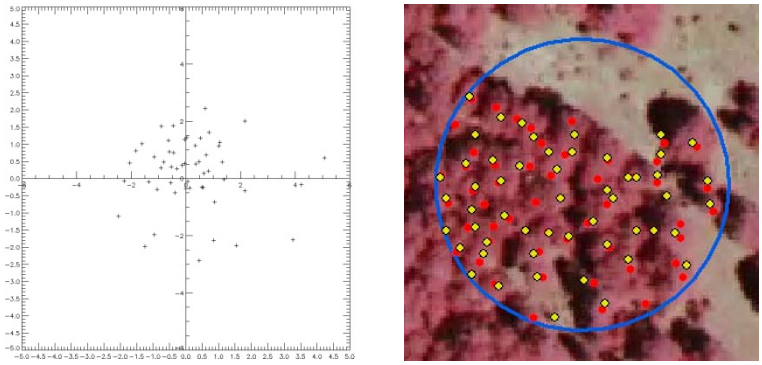

Figura A- IV, 49. Parcela 84.

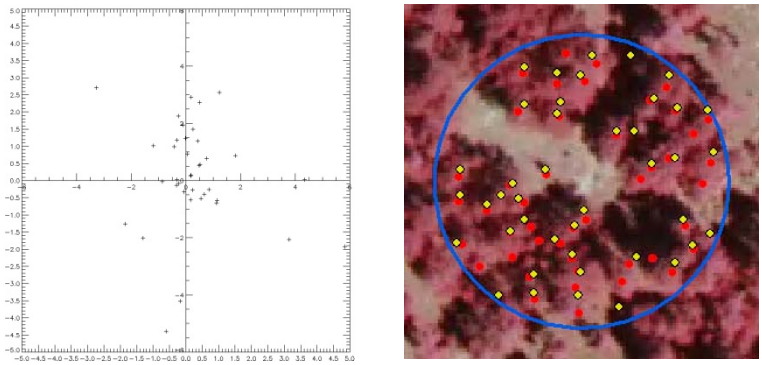

Figura A- IV, 50. Parcela 85.

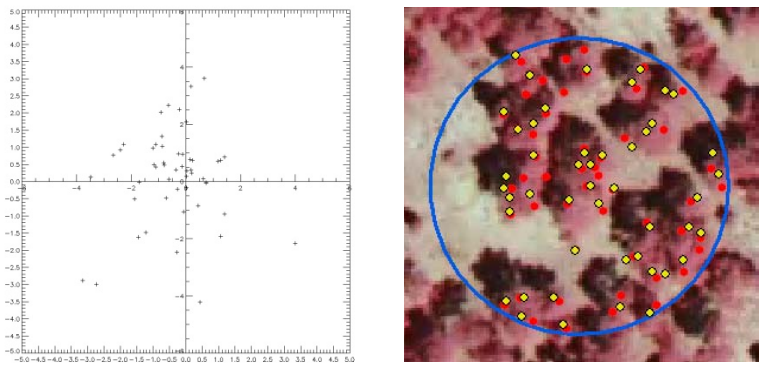

Figura A- IV, 51. Parcela 86.

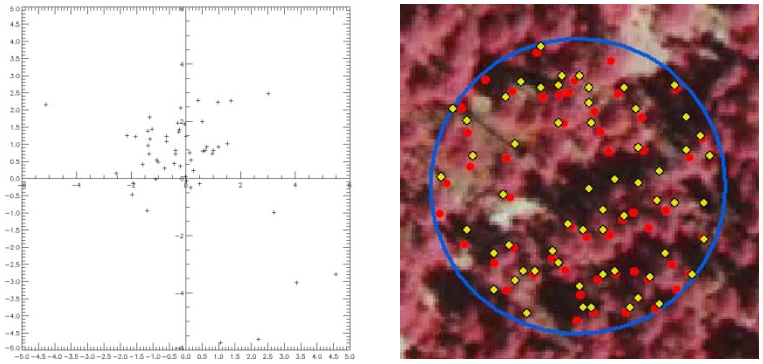

Figura A- IV, 52. Parcela 87.

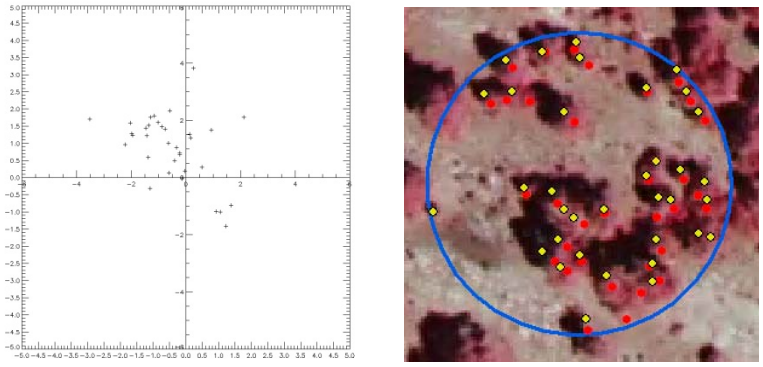

Figura A- IV, 53. Parcela 98.

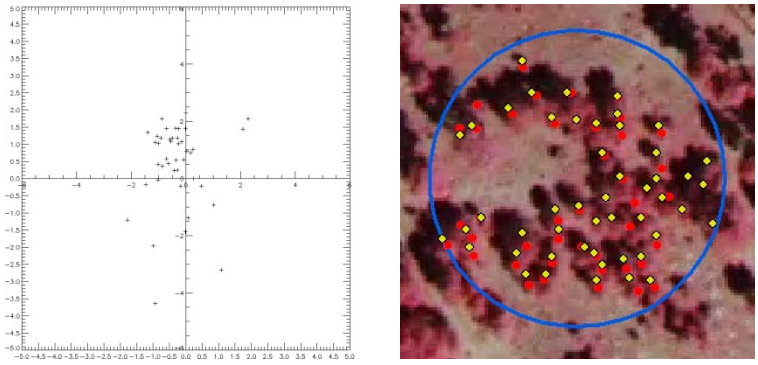

Figura A- IV, 54. Parcela 99.

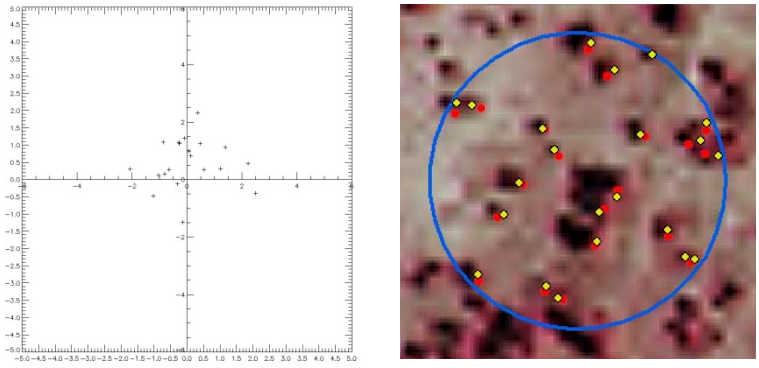

Figura A- IV, 55. Parcela 100.

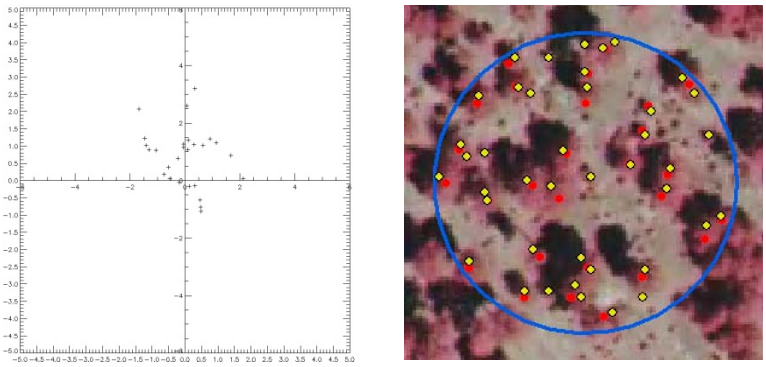

Figura A- IV, 56. Parcela 150.