




Departamento de Ingeniería Gráfica y Geomática
TESIS DOCTORAL

ANÁLISIS Y ESTUDIO DE INDEPENDENCIA ESPECTRAL
ENTRE SENSORES ESPACIALES Y AEROTRANSPORTADOS:
INTEGRACIÓN CON LIDAR

Francisco Javier Mesas Carrascosa
Córdoba, 2012



TÍTULO: *Análisis y estudio de independencia espectral entre sensores espaciales y
aerotransportados: integración con LiDAR*

AUTOR: *Francisco Javier Mesas Carrascosa*

© Edita: Servicio de Publicaciones de la Universidad de Córdoba. 2012
Campus de Rabanales
Ctra. Nacional IV, Km. 396 A
14071 Córdoba

www.uco.es/publicaciones
publicaciones@uco.es

UNIVERSIDAD DE CORDOBA

Departamento de Ingeniería Gráfica y Geomática

TESIS DOCTORAL

ANÁLISIS Y ESTUDIO DE INDEPENDENCIA ESPECTRAL
ENTRE SENSORES ESPACIALES Y
AEROTRANSPORTADOS: INTEGRACIÓN CON LIDAR

Director: Dr. D. Alfonso García Ferrer Porras

Autor: **Francisco Javier Mesas Carrascosa**

Córdoba, Mayo 2012



TÍTULO DE LA TESIS:

Análisis y estudio de independencia espectral entre sensores espaciales y aerotransportados: integración con LiDAR.

DOCTORANDO: Francisco Javier Mesas Carrascosa

INFORME RAZONADO DEL DIRECTOR DE LA TESIS

Alfonso García-Ferrer Porras, como director de la Tesis titulada "*Análisis y estudio de independencia espectral entre sensores espaciales y aerotransportados: integración con LiDAR*" realizada por **Francisco Javier Mesas Carrascosa**,

INFORMA:

Que dicha Tesis Doctoral ha sido realizada bajo mi dirección.

Que ha tenido como principal objetivo analizar un conjunto de técnicas de análisis de datos aplicados sobre imágenes procedentes de plataformas aéreas o espaciales con el objetivo de mejorar los procesos de clasificación así como la integración con datos de sensores LiDAR aéreos. Se han evaluado métodos basados en el análisis de componentes independientes frente a técnicas como el análisis de componentes principales, evaluando los resultados de la aplicación del concepto independencia frente al de correlación. Por otra parte se ha diseñado una metodología para trasladar el espacio generado por las bandas espectrales de un sensor hacia un espacio ortogonal caso de que tales bandas aparezcan solapadas. Se ha estudiado la explotación de la variable intensidad LiDAR para la discriminación de usos de suelo una vez esta información es integrada con los datos registrados por sensores aerotransportados, aplicando por último las técnica de análisis de componentes independientes en la combinación de sensores multiespectrales y LiDAR.

Que tanto la metodología como el trabajo de investigación, las conclusiones y los resultados obtenidos son satisfactorios.

Que derivado de esta Tesis Doctoral se han publicado los siguientes trabajos:

Revistas incluidas en el SCI:

Mesas Carrascosa, F.J., Castillejo-González, I.L., Sánchez de la Orden, M., García-Ferrer Porras, A., 2012. Combining LiDAR intensity with aerial camera data to discriminate agricultural land uses. *Computers and Electronics in Agriculture*, 84, 36-46.

Aportaciones a congresos:

Mesas Carrascosa, F.J., Castillejo-González, I.L., Sánchez de la Orden, M., García-Ferrer Porras, A., 2011. Modelado de la respuesta espectral relativa de sensores hacia espacios ortogonales. XIV Congreso de la Asociación Española de Teledetección, Mieres del Camino (Principado de Asturias), España, pp 537-540.

Mesas Carrascosa, F.J., Castillejo-González, I.L., García-Ferrer Porras, A., Sánchez de la Orden, M., 2010. Independent Component Analysis application to multispectral sensors. *Third Recent Advances in Quantitative Remote Sensing*, Torrent (Valencia), España, pp 158-162.

Que se considera que el trabajo realizado cumple con los requisitos necesarios para su presentación y lectura.

Por todo ello, se autoriza la presentación de la tesis doctoral.

Córdoba, 14 de Mayo de 2012

Firma del director

Fdo.: Alfonso García-Ferrer Porras

Agradecimientos

Me gustaría emplear estas líneas para poder expresar mi más profundo y sincero agradecimiento a todas aquellas personas que con su ayuda han colaborado de uno u otro modo en la realización de este trabajo.

En primer lugar quiero agradecer a D. Alfonso García-Ferrer Porras, director de esta investigación, por su orientación, seguimiento y asesoramiento, pero sobre todo por la motivación y el apoyo humano recibido desde el mismo momento en que nos conocimos.

Agradecer a D. Manuel Sánchez de la Orden por el interés mostrado a lo largo de estos años y por el ánimo recibido diariamente para llevar adelante este trabajo. A D^a. Isabel Castillejo González por su apoyo, colaboración e inestimable ayuda para hacer frente al difícil reto de escribir por primera vez un *paper*.

Igualmente y no menos importante a toda mi familia. En particular a mis padres, sin duda alguna este trabajo no habría sido posible sin su apoyo, educación y valores recibidos desde niño. Quiero agradecerlos a todos el cariño y apoyo que me habéis dado, mandando un recuerdo muy especial a Cecilia y Vicente.

Por último, mi más sincera gratitud y todo mi amor a Sonia, mi esposa, compañera y amiga, por su inestimable apoyo, comprensión y generosidad para sobrellevar las horas de trabajo que he dedicado a esta Tesis. También gracias una y mil veces a mis niños Curro, Nacho y a ti que no te pongo nombre, espero que entendáis algún día el motivo por el que durante tantas horas no os he prestado la atención que os merecéis.

Lo que tenemos que aprender a hacer, lo aprendemos haciéndolo.

Aristóteles

Índice

ÍNDICE.....	I
LISTA DE FIGURAS.....	V
LISTA DE TABLAS	XI
LISTA DE ACRÓNIMOS	XIII
CAPÍTULO 1 INTRODUCCIÓN.....	1
1.1 Sistema de Teledetección.....	3
1.1.1 Sensores.....	5
1.1.1.1 Sensores pasivos: Cámaras aéreas.....	6
1.1.1.2 Sensor activos: LiDAR.....	10
1.1.2 Generación de conocimiento.....	15
1.2 Combinación de sensores	18
1.3 Objetivos y estructura de la tesis.....	20
1.4 Rererencias.....	22
CAPÍTULO 2 ANÁLISIS DE COMPONENTES INDEPENDIENTES.....	35
2.1 Introducción.....	36
2.2 Materiales	38
2.3 Metodología	40
2.3.1 Análisis de componentes independientes	40
2.3.1.1 ¿Qué es independencia?.....	43
2.3.1.2 Definición de ICA.....	47

2.3.1.3 Algoritmos ICA	49
2.3.2 Evaluación ICA frente a PCA	50
2.4 Resultados	51
2.4.1 Análisis de independencia	51
2.4.2 Clasificación no supervisada.....	55
2.4.3 Clasificación supervisada.....	58
2.5 Conclusión.....	60
2.6 Referencias	61

CAPÍTULO 3 INTRODUCCIÓN DE LA CURVA DE RESPUESTA ESPECTRAL RELATIVA EN LOS PROCESOS DE CLASIFICACIÓN 65

3.1 Introducción	66
3.1.1 Operadores de clasificación.....	69
3.1.2 Análisis de sensores.....	71
3.2 Materiales y métodos	74
3.2.1 Sensores	74
3.2.1.1 Advanced Spaceborne Thermal Emission and Reflection Radiometer: ASTER	75
3.2.1.2 Sensor IKONOS	77
3.2.1.3 Digital Mapping Camera: DMC	79
3.2.2 Modelo matemático	81
3.2.3 Reconstrucción de los valores de energía.....	85
3.2.4 Minimización de la correlación causada por el solape espectral	88
3.2.5 Modelo de evaluación	93
3.3 Resultados y discusión.....	98

3.3.1 Simulación de sensores	98
3.3.2 Clasificación.....	100
3.3.2.1 Zonas de estudio.....	100
3.3.2.2 Clasificación no supervisada.....	102
3.3.2.3 Clasificación supervisada	104
3.4 Conclusión	108
3.5 Referencias.....	109
CAPÍTULO 4 COMBINACIÓN INTENSIDAD LIDAR CON IMÁGENES MULTIESPECTRALES PARA DISCRIMINAR USOS DE SUELO AGRÍCOLA	117
4.1 Introducción.....	118
4.2 Materiales	122
4.3 Métodos	127
4.3.1 Combinación de información vectorial LiDAR con imágenes digitales	127
4.3.2 Normalización de la intensidad.....	132
4.3.3 Evaluación del efecto de la normalización	135
4.3.4 Clasificación y calidad	137
4.4 Resultados.....	139
4.4.1 Evaluación del efecto de la normalización	139
4.4.2 Clasificación de usos de suelo	143
4.5 Conclusiones	149
4.6 Referencias.....	151
CAPÍTULO 5 EVALUACIÓN DE LAS TÉCNICAS DE ANÁLISIS DE COMPONENTES PRINCIPALES Y PROJECTION PURSUIT EN LA COMBINACIÓN DE LA INTENSIDAD LIDAR CON IMÁGENES MULTIESPECTRALES	157

5.1 Introducción	159
5.2 Materiales y métodos	162
5.2.1 Flujo de trabajo.....	162
5.2.2 Projection pursuit	165
5.2.3 Análisis de componentes principales.....	170
5.3 Resultados	171
5.4 Conclusiones.....	177
5.5 Referencias	178
CAPÍTULO 6 CONCLUSIONES GENERALES.....	185
ANEXOS	189
Anexo 1 Matrices de confusión.....	191
Anexo 1.1 Sensor ASTER	191
Anexo 1.2 Sensor IKONOS	195
Anexo 1.3 Cámara DMC.....	199
Anexo 2 Código desarrollos para tratamiento datos LiDAR.....	203
Anexo 2.1 Módulo lectura formato LAS.....	203
Anexo 2.2 Procedimiento para el filtrado de puntos	208
Anexo 2.3 Procedimiento para la normalización de la intensidad LiDAR	211

Lista de Figuras

Figura 1-1 Paquetes UML estructura sistema de Teledetección.....	4
Figura 1-2 Cámaras de área: (a) DMC, (b) UltraCam y (c) DigiCam. Cámaras de barrido: (d) ADS, (e) 3-DAS-1 y (f) JAS-150.....	7
Figura 1-3 Productos generados a partir de imágenes obtenidas con la cámara HRSC-AX: Modelo digital de elevaciones, imagen en falso color, imagen en modo pancromático e imagen en verdadero color.....	10
Figura 1-4 Sistemas de georreferenciación y medida de distancia sistema LiDAR...	13
Figura 1-5 Comparativa funcionamiento LiDAR basado en pulsos y LiDAR basado en medición continua de onda.....	14
Figura 2-1 Zona de estudio correspondiente a fragmento escena IKONOS.....	39
Figura 2-2 Diferencias señales independientes versus señales mezcla: I. Independencia, II normalidad y III complejidad.....	42
Figura 2-3 Análisis correlación: (a) Péndulos en movimiento con desfase 90°, (b) velocidad péndulos con misma frecuencia y desfasados 90°.....	46
Figura 2-4 Esquema general para la solución ICA.....	48
Figura 2-5 Esquema general metodología comparación PCA con técnicas ICA.....	51
Figura 2-6 Función densidad de probabilidad conjunta bandas imagen sensor IKONOS.....	53
Figura 2-7 Comparativa bandas originales sensor IKONOS y bandas obtenidas mediante procesamiento PCA, FastICA y JADE.....	55

Figura 2-8 Comparativa resultados clasificación no supervisada ISODATA sobre imagen IKONOS (a): (b) imagen original, (c) imagen con tratamiento PCA, (d) imagen con tratamiento FastICA y (e) imagen con tratamiento JADE.....	57
Figura 2-9 Comparativa porcentaje máxima probabilidad clasificación supervisada operador máxima probabilidad.....	59
Figura 2-10 Comparativa porcentaje pixel sin clasificar clasificación supervisada operador máxima probabilidad.....	59
Figura 3-1 Diagrama de bloque de un sistema de reconocimiento de patrones.....	67
Figura 3-2 Relación entre las bandas de un sensor y el cálculo de la distancia Euclídea: (a) bandas no solapadas, (b) bandas solapadas.....	71
Figura 3-3 RSR sensor MODIS. Banda 1 a 10.....	72
Figura 3-4 Comparativa evolución RSR sensor Landsat correspondientes a las bandas del espectro visible.....	73
Figura 3-5 Comparativa evolución de la RSR a nivel de banda del sensor Landsat ..	74
Figura 3-6 Subsistemas ASTER: (a) VNIR, (b) SWIR y (c) TIR.....	76
Figura 3-7 RSR de las bandas en modo multiespectral del sensor IKONOS.....	78
Figura 3-8 RSR de las bandas multiespectral de la cámara aérea DMC.....	80
Figura 3-9 Flujo de trabajo para la evaluación de la metodología propuesta para la reconstrucción de la energía sobre sensores sin solape espectral (a) y con solape espectral (b) en sus bandas.....	94
Figura 3-10 Esquema de validación metodología propuesta en procesos de clasificación supervisada y no supervisada.....	95

Figura 3-11 RSR de sensores simulados: (a) sin solape espectral en sus bandas y (b) con solape espectral en sus bandas.	98
Figura 3-12 Radiancia que alcanza a los sensores simulados, distribución (a) línea recta y (b) parabólica.	99
Figura 3-13 Comparativa de la reconstrucción de la energía en el sensor con solape en sus bandas. Distribución radiancia: (a) línea recta y (b) curva parabólica.	100
Figura 3-14 Imágenes registradas por los sensores ASTER, IKONOS y DMC.	101
Figura 3-15 Comparativa resultados ISODATA para: (I) ASTER, (Carter et al.) IKONOS y (III) cámara DMCM; (a) imagen original, (b) clasificación imagen sin procesar y (c) clasificación procesada.	104
Figura 3-16 Comparativa resultados clasificador mínima distancia: (a) porcentaje de acuerdo, (b) coeficiente Kappa y (c) porcentaje de píxeles sin clasificar en (I) ASTER, (Carter et al.) IKONOS y (III) cámara DMC.	107
Figura 4-1 Vista general de la zona de estudio registrada por la cámara DigiCam H39.	122
Figura 4-2 Distribución de los centroides de las áreas muestreadas: (a) muestreo de entrenamiento y (b) muestreo de validación.	126
Figura 4-3 Análisis de la diferencia de altura entre puntos dentro de un mismo píxel en la etapa de filtrado. Puntos LiDAR pertenecientes a (a) una única clase de uso de suelo y (b) dos clases de suelo diferente.	128
Figura 4-4 Diagrama de flujo para el filtrado de puntos teniendo en cuenta máximo umbral en altura entre puntos contenidos en un mismo píxel.	131
Figura 4-5 Relación entre el ángulo de incidencia del rayo y el ángulo de escaneo del sensor LiDAR.	134

Figura 4-6 Comparativa de los resultados de rasterización de los valores de intensidad LiDAR. (a) ortofoto y rasterización de la intensidad en modo (b) bruto, (c) normalizada por la distancia y (d) normalizada por la distancia y el ángulo.	140
Figura 4-7 Comparativa del coeficiente de variación en los valores de intensidad LiDAR de distintas pasadas sobre los usos de suelo: (a) cultivos herbáceos, (b) cultivos leñosos, (c) suelos agrícolas, (d) caminos, (e) carreteras y (f) edificaciones.	142
Figura 4-8 Comparación de la habilidad para distinguir entre cultivos herbáceos y leñosos; (a) ortofoto, clasificación: (b) ortofoto (Escenario 1), (c) ortofoto e intensidad LiDAR original (Escenario 2), (d) ortofoto e intensidad LiDAR normalizada por la distancia (Escenario 3) y (e) ortofoto e intensidad LiDAR normalizada por distancia y ángulo (Escenario 4).	148
Figura 5-1 Flujo de trabajo para la evaluación de la explotación de la combinación ortofotografía y LiDAR.	164
Figura 5-2 Esquema general del planteamiento del problema.	167
Figura 5-3 Diagrama de flujo para el cálculo de la matriz de separación W mediante el modelo PP.	169
Figura 5-4 Correlación entre los niveles digitales de dos bandas m y n .	171
Figura 5-5 Comparativa de resultados del clasificador no supervisado ISODATA.	173
Figura 5-6 Comparativa Porcentaje de acuerdo según tratamiento de las imágenes A: ortofoto, B: Ortofoto mas intensidad LiDAR bruta, C: Ortofoto mas intensidad LiDAR normalizada por distancia y D: ortofoto mas LiDAR normalizada por distancia y ángulo.	175
Figura 5-7 Comparativa exactitud productor sobre las imágenes: A: Ortofoto; B: Ortofoto + LiDAR sin tratamiento; C: Ortofoto + LiDAR normalizado por	

distancia; D: Ortofoto + LiDAR normalizado por distancia y ángulo para los usos de suelo (a) vegetación, (b) edificaciones, (c) suelos claros; y (d) suelos oscuros y (e) carreteras176

Figura 5-8 Comparativa exactitud usuario sobre las imágenes: A: Ortofoto; B: Ortofoto+ LiDAR sin tratamiento; C: Ortofoto + LiDAR normalizado por distancia; D: Ortofoto+LiDAR normalizado por distancia y ángulo para los usos de suelo (a) vegetación, (b) edificaciones, (c) suelos claros; (d) suelos oscuros y (e) carreteras.....177

Lista de tablas

Tabla 1-1 Características de cámaras digitales.....	8
Tabla 2-1 Comparación momentos bandas individuales y momentos función de densidad de probabilidad conjunta.....	52
Tabla 3-1 Características subsistemas ASTER.....	75
Tabla 3-2. Información de las muestras de entrenamiento y validación de cada clase en las imágenes ASTER, IKONOS y DMC.....	102
Tabla 4-1: Resumen de las muestras usadas en los procesos de entrenamiento y validación en los procesos de clasificación.	125
Tabla 4-2 Comparativa matrices de confusión obtenidas de las clasificaciones de los escenarios 1, 2, 3 y 4	144
Tabla 4-3: Comparación de exactitud usuario y exactitud productor.....	147
Tabla 5-1. Porcentaje de acuerdo en las clasificaciones según tipo de información y tratamiento (%).	174

Lista de acrónimos

ALS	Aerial Laser Scanner
ASTER	Advanced Spaceborne Thermal Emission and Reflection Radiometer
BSS	Blind Source Separation
CCD	Charge Coupled Device
CMOS	Complementary Metal Oxid Semiconductor
CW	Continuos Wave
DEM	Digital Elevation Model (Modelo Digital de Elevaciones)
DMC	Digital Mapping Camera
DSM	Digital Surface Model (Modelo Digital de Superficies)
EP	Exactitud Productor
EU	Exactitud Usuario
FA	Factorial Analysis
GNSS	Global Navigation Satellite System
ICA	Independent Component Analysis
ISODATA	Iterative Self-Organizing Data Analysis
JADE	Joint Approximate Diagonalization of Eigenmatrices
LASER	Light Amplification by Stimulated Emission of Radiation)
LIDAR	Light Detection And Ranging
MD	Mínima Distancia
MDE	Modelo Digital de Elevaciones
MDS	Modelo Digital de Superfices
MLC	Maximun Likelihood Classifier
MLS	Mobile Laser Scanner
NIR	Near InfraRed
Pa	Porcentaje de Acuerdo
PCA	Principal Component Analysis
PDF	Probability Density Function
PP	Projection Pursuit
RSR	Relative Spectral Response
SVD	Singular Value Descomposition
TLS	Terrestrial Laser Scanner

Capítulo 1

Introducción

La sociedad de la información y del conocimiento se caracteriza por una globalización económica y cultural alcanzada gracias al continuo avance científico y tecnológico que permiten una continua renovación del conocimiento. Dicha sociedad es una sociedad tecnificada basada en las tecnologías de la información y de las comunicaciones así como en el consecuente avance de las ciencias. De este modo nos encontramos con una abundante información a nuestro alcance, aumentando los servicios basados sobre esta información así como ante la posibilidad de creación de conocimiento. A este marco, sin duda alguna, se ha unido la democratización de la cartografía y de los productos y servicios apoyados y basados en la información geográfica. La información geográfica ha pasado de ser un producto consumido por un perfil de usuario muy especializado como ingenieros, científicos o militares, a ser empleada y solicitada por el gran público. Sin duda esta revolución ha venido impulsada y apoyada por la creación de globos virtuales como Google Earth o Virtual Earth o navegadores GNSS. En este marco el columnista del periódico *The Times*, Ben Macintyre escribió en 2008 una columna titulada "*Whatever next: a map of Utopia?*", describiendo que la cartografía está viviendo una edad de oro.

El Federal Geographic Data Committee, en su informe anual de 2006, indica que entre el 80% y el 90% de la información gestionada por los gobiernos presenta una componente espacial, indicando que estos necesitan datos exactos, actuales, accesibles, fáciles de usar y manipular. Tal hecho pone de manifiesto que la información geográfica presenta un valor político a tener en cuenta, siendo integrada esta en políticas de diferentes sectores como agricultura, transporte o desarrollo regional.

El desarrollo de servicios y productos ha ido acompañado del desarrollo y puesta en funcionamiento de nuevos sensores, plataformas y modos de trabajo. Hemos asistido como en los últimos años ciencias tales como la fotogrametría han migrado hacia un entorno totalmente digital, comenzando con el propio registro de las imágenes. Así mismo los principios de esta ciencia se han exportado desde plataformas aéreas a plataformas espaciales e incluso plataformas no tripuladas. Igualmente la información recogida en vuelos fotogramétricos ha ampliado sus usos y aprovechamientos, las imágenes registradas ya no solo sirven para producir cartografía. Además de productos como bases cartográficas vectoriales u ortofotografías es posible ya hoy día pensar en realizar una explotación desde un punto de vista radiométrico de la información a partir de un vuelo fotogramétrico, aumentando por tanto los servicios y productos generados.

Al igual que hemos asistido a la proliferación de servicios, productos, sensores y nuevos métodos de explotación de la información geográfica se hace necesario por parte de la comunidad científica y universitaria seguir explorando nuevas formulas de explotación de los datos, analizando el comportamiento y características de los sensores empleados, mejorar los flujos de trabajo, aumentando la calidad de productos y procesos.

El uso extendido de la tecnología digital junto con los grandes avances en sensores a finales del siglo XX han asentado las bases de la nueva ruta trazada en el campo de la geomática. La evolución hacia sistemas de captura digital, el empleo de sensores activos como LiDAR o la posibilidad cada vez mayor de automatizar procesos y tareas hace que claramente se esté trazando una tendencia hacia el empleo y explotación de forma combinada de múltiples sensores. Bajo este marco,

los grandes avances en la tecnología geoespacial, sobre todo en lo que a sensores se refiere, se han visto reflejados en una mejora de la resolución en todas sus dimensiones: espacial, espectral, radiométrica y temporal. En la línea de combinación de sensores puede observarse como cualquier vuelo fotogramétrico se realiza hoy día bajo el apoyo de un sistema GNSS y de orientación para poder obtener orientación directa de todos y cada uno de los centros de proyección de las imágenes. En el caso de las cámaras de área tal combinación no es necesaria si bien su uso está extendido dado los beneficios obtenidos en producción de esta combinación de sensores. En el caso de cámaras de barrido tal combinación se hace obligatoria y necesaria para el empleo de este sensor.

La combinación de sensores está mejorando los flujos de trabajo, tal es el caso de vuelos realizados con cámara y LiDAR. Este tipo de vuelos permite mejorar los tiempos de respuesta en la producción así como los resultados en cuanto a calidad posicional de productos como ortofotografías (Barazzetti et al. 2007; Günay et al. 2007). La puesta en marcha de nuevos sensores ha coincidido con la mejora en hardware (aumento de la capacidad de almacenamiento y de la velocidad en el procesamiento de información, etc.) así como en software y servicios (servicios web, infraestructuras de datos espaciales, servicios de localización, etc.). Ante esta situación el usuario cuenta con una sobreabundancia de información aportada por diferentes sensores generada por parte de numerosas agencias, organismos y administraciones.

1.1 Sistema de Teledetección

Los posibles sensores que se pueden emplear para el levantamiento de información geográfica se montan en plataformas terrestres, aéreas o espaciales. En el caso particular del registro de imágenes para ser explotadas mediante técnicas de teledetección, los sensores se encontraban a bordo de plataformas espaciales si bien con el paso del tiempo las plataformas se han ido aproximando cada vez más a la superficie terrestre siendo hoy día una realidad la explotación de imágenes obtenidas a bordo de plataformas aéreas como avioneta así como a bordo de vehículos no tripulados. Frente a todo esto el modelo conceptual en un entorno de producción es

independiente del tipo de plataforma y sensor empleados. Atendiendo al modelo establecido por Open Geospatial Consortium (OGC, 2004), basado en la norma ISO (ISO 19101-2, 2008), el sistema aparece compuesto por cuatro paquetes (Figura 1-1) relacionados entre sí. El sistema comienza con la captura de información por parte de un sensor el cual producirá un conjunto de datos a modo de imágenes. Sobre estas imágenes se desarrollarán un conjunto de procesos los cuales generarán conocimiento que servirá de ayuda y apoyo a la toma de decisiones. Además las imágenes, ya de por sí, pueden contener información que de visu pueden servir de entrada a este último paquete.

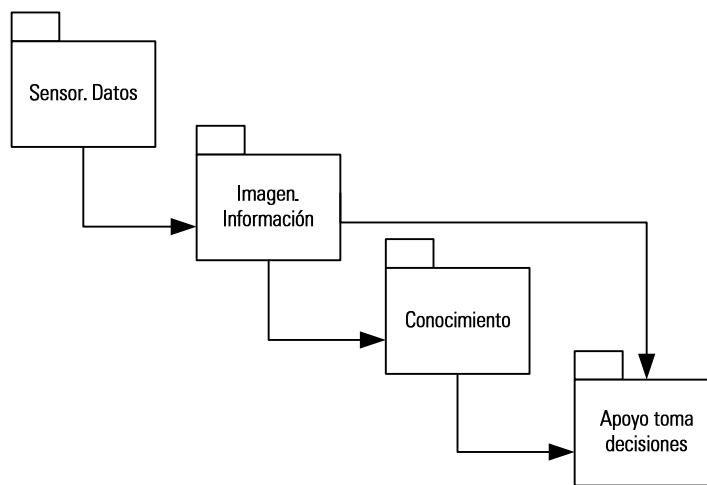


Figura 1-1 Paquetes UML estructura sistema de Teledetección.

Todo proyecto que implemente el modelo descrito en la Figura 1-1 tendrá que comenzar forzosamente con la definición de unos objetivos. Según sean estos se seleccionará el sensor más conveniente para adquirir información, definiendo las condiciones de captura más adecuadas a los objetivos del proyecto. En lo que respecta a la elección del sensor, generalmente se seleccionará aquel sensor que permita obtener información con una determinada resolución espacial y espectral. El empleo simultáneo de información obtenida por distintos sensores o el trabajo con imágenes procedentes de un solo sensor implica la elección de un determinado algoritmo de clasificación. En el manejo de imágenes, sobre todo en aquellas de elevada dimensión espectral procedentes de sensores hiperespectrales, se busca suprimir la redundancia de información, manejando un conjunto de bandas

independientes con el fin de poder discriminar o distinguir los distintos fenómenos presentes en una imagen. Procesos como el análisis de componentes principales se basan en encontrar un conjunto de nuevas bandas decorreladas que permitan definir un espacio donde expresar de una mejor manera el contenido de la imagen. De este modo el objetivo es encontrar un conjunto de bandas lo más independientes posibles. Se observa como aparecen conceptos como correlación e independencia. Puede pensarse que ambos términos indican la misma idea o que son lo mismo sin bien cada uno de ellos implica características bien distintas al ser aplicados sobre una imagen, en el **Capítulo 2** se presenta una comparativa sobre ambos conceptos y sus efectos al ser aplicados sobre imágenes sobre las que posteriormente se ha realizado una clasificación.

1.1.1 Sensores

El conjunto de sensores que pueden ser empleados en un proyecto de Teledetección conforman un amplio abanico de posibilidades. Si bien en un principio solo se pensaba en sensores a bordo de plataformas espaciales, el desarrollo tecnológico ha propiciado que podamos emplear un número de sensores a bordo de plataformas aéreas e incluso terrestres. Cámaras métricas digitales o la intensidad registrada mediante un sensor LiDAR terrestre son dos claros ejemplos de cómo la Teledetección ha ampliado sus fronteras en cuanto a herramientas de captura de información se refiere.

El conjunto de sensores a emplear pueden ser clasificados atendiendo a distintos aspectos como su resolución (espacial, temporal, radiométrica y/o espectral). Independiente de estas propiedades podemos diferenciar entre sensores pasivos y activos dependiendo si registran la energía emitida por una fuente de energía externa o detectan la energía emitida por ellos mismos. Dentro del primer grupo encontramos un numeroso grupo de sensores, tanto en plataformas espaciales (SPOT, Landsat, IKONOS, Quickbird, MODIS, etc.) como en plataformas aéreas (DMC, UltraCam DigiCam, ADS80, etc.) En el caso de sensores activos el número de sensores es más reducido, destacando el RADAR y LiDAR.

1.1.1.1 Sensores pasivos: Cámaras aéreas

Desde la puesta en marcha del programa Landsat hasta nuestros días se han ido poniendo en órbita numerosos sensores a bordo de plataformas espaciales con características y fines diversos. Al programa Landsat, iniciado y promovido por la National Aeronautics and Space Administration (NASA) se han ido añadiendo proyectos de agencias de otros países como Francia con el programa SPOT, India con el sistema IRS o el satélite europeo ERS-1 entre otros. Todos ellos han permitido el desarrollo de proyectos de muy diversa índole y áreas temáticas como geología, agricultura, urbanismo, etc. El número de misiones se ha ido incrementando a lo largo de los años, sumándose a estas agencias iniciativas de otros países aprovechando su desarrollo tecnológico tales como Israel, China, Canadá o Brasil. Por último, iniciativas privadas han tomado este modelo de negocio, participando de forma activa en el diseño y puesta en funcionamiento de este tipo de sistemas. Plataformas como IKONOS ha marcado un punto de inflexión no solo en el modelo de negocio sino también en la forma de procesamiento y aprovechamiento de la información. Esta plataforma o QuickBird hacen posible la aplicación de técnicas fotogramétricas sobre las escenas registradas con la consecuente ampliación de productos a generar. Además dado su elevada resolución espacial ha tenido como consecuencia el desarrollo de nuevas metodologías y algoritmos en el modo de explotación de la imagen, trabajando no solo a nivel de pixel sino también a nivel de objeto.

Junto con el desarrollo de sensores espaciales, en los últimos años han ido apareciendo grandes avances en todos los aspectos relacionados con los sensores empleados para adquirir imágenes geospaciales a bordo de plataformas aéreas. Probablemente el más importante de todos ellos haya sido la transición desde los sistemas analógicos a los sistemas digitales (Honkavaara et al. 2006). Las ventajas aportadas por los nuevos sensores permiten eliminar fases de trabajo como el revelado o el escaneo de negativos, tener un número ilimitado de copias de las imágenes sin pérdida de calidad, la información es cuantitativa, los niveles digitales son medidas y no simples niveles de gris, obteniendo una mejor información radiométrica en las imágenes.

La introducción de sensores digitales además ha modificado la configuración de cámara con un único objetivo que se emplea tradicionalmente para trabajar en modo analógico a sensores con múltiples objetivos. La limitación del tamaño de los sensores CCD (charge-coupled device) y CMOS (complementary metal oxide semiconductor) con su equivalente a lo que sería el tamaño del plano focal de una imagen en una cámara analógica ha tenido como consecuencia justamente la necesidad de integrar en un mismo dispositivo diferentes sensores. Este cambio en el concepto del sensor ha propiciado la aparición de cámaras con diferente arquitectura, encontrando dos posibles alternativas en cámaras aéreas (Figura 1-2).



Figura 1-2 Cámaras de área: (a) DMC, (b) UltraCam y (c) DigiCam. Cámaras de barrido: (d) ADS, (e) 3-DAS-1 y (f) JAS-150.

Sea cual sea el tipo de arquitectura, aparecen distintas soluciones tanto para gran formato como para medio formato, con un único objetivo o multi-objetivo y con distintas resoluciones radiométricas (Tabla 1-1). Por una parte se encuentran las cámaras de área basadas en el registro de datos sobre matrices bidimensional empleando uno o varios objetivos como es el caso de las cámaras DMC de

Intergraph (Hinz et al. 2001), UltraCam de Microsoft (Leberl y Gruen 2003), entre las cámaras con un único objetivo destaca la DigiCam de IGI (Grenzdörffer 2008) entre otras. Esta arquitectura emula la perspectiva de cámara central que presentan las cámaras analógicas tradicionales (Ferrano y Feix 2003; Leberl y Gruber 2003). El otro tipo de arquitectura, cámara de barrido o línea, emplea un triple scanner correspondientes a las vista de atrás, nadir y hacia delante; empleando un array unidimensional para el registro de información (Hoffmann et al. 2000; Sandau y Ralf Reulke 2000). Dentro de este grupo se encuentran la familia de cámaras ADS de la casa Leica Geosystems (Sandau et al. 2000), la 3-DAS-1 de Wehrli (Petrie y Walker 2007) o la JAS-150 de Jena Optronik (Georgi et al. 2005).

Tabla 1-1 Características de cámaras digitales

Sensor	Arquitectura	Tamaño imagen	Tamaño sensor	Focal	Rango dinámico
DMC	Área CCD	13824 x 7680	12	120	12
UltraCam X	Área CCD	14430 x 9420	7.2	100	14
UltraCam XP	Área CCD	17310 x 11310	6	100	14
DigiCam	Área CCD	7216 x 5428	6.8	35/50/80	16
DSS	Área CCD	5436 x 4092	9	40/60/250	12
RCD-105	Área CCD	7162 x 5389	6.8	35/60/100	12
ADS40	Línea CCD	12000 x 2	6.5	62.7	14
ADS80	Línea CCD	12000 x 2	6.5	65	12
JAS-150	Línea CCD	12000 x 2	6.5	150	12
3-DAS-1	Línea CCD	8023 x 2	9	110	14
SI-250	Línea CCD	14400 x 2	5		9
HRSC-AX	Línea CCD	12000 x 2	6.5	151	12

Tamaño imagen: pixel

Tamaño sensor: micras

Distancia focal: milímetros

Rango dinámico: bits

La transición desde cámaras analógicas a digitales ha propiciado el desarrollo de nuevos flujos de trabajo, automatizando parte de los procesos. Además, comparándolo con los sistemas analógicos, las cámaras digitales destacan por su alto potencial para una explotación desde un punto de vista radiométrico (Honkavaara et al. 2006; Markelin et al. 2008). Tales características están aumentando el interés por explorar nuevas alternativas de explotación de los datos. Los requisitos para tener una información radiométrica exacta pasan forzosamente por conocer el comportamiento del sensor, comparando y evaluando los resultados

obtenidos frente a patrones y valores de referencia (Johnson et al. 2004). Los procesos de calibración y explotación de la información desde un punto de vista radiométrico a partir de imágenes procedentes de sensores espaciales están bien definidos y desarrollados (Lillesand y Kiefer 2008; Weng 2011). Tales procesos no son aplicables directamente a la información obtenida en un flujo de trabajo puramente fotogramétrico donde las condiciones del registro de información están enfocadas hacia aspectos como la resolución espacial, la estereoscopia o la calidad posicional. Autores como Honkavaara et al. (2009) consideran que un tratamiento riguroso de la información radiométrica mejorará notablemente la automatización de los procesos de producción como generación de modelos digitales, ortofotografías e incluso abrir nuevas líneas de negocio y explotación de la información registrada (Fricker et al. 1999; Schiewe 2005) (Figura 1-3). Las mejoras radiométricas que presentan las imágenes adquiridas con este tipo de sensores no solo refuerzan la calidad posicional de los procesos a desarrollar sobre estas y por tanto de los productos clásicos generados a partir de ellas, además es posible una mejor distinción y separación de regiones representadas sobre las imágenes pudiéndose obtener una mejora en la explotación temática de su contenido. Además, a diferencia de las cámaras analógicas, a partir de las bandas multiespectrales es posible determinar índices como por ejemplo el NDVI. (Laliberte et al. 2010; Sasagawa et al. 2004). Prueba del interés en la explotación de este tipo de información se pone de manifiesto en organismos como el European Spatial Data Research, donde desde el año 2008 están estudiando los aspectos radiométricos que atañen a las imágenes obtenidas mediante cámaras métricas digitales (EuroSDR 2008). En el **capítulo 2** se muestran los resultados en procesos de clasificación de distintos sensores pasivos, pudiendo analizarse los resultados de la explotación desde un punto de vista radiométrico de la información recogida por una cámara de área.




Figura 1-3 Productos generados a partir de imágenes obtenidas con la cámara HRSC-AX: Modelo digital de elevaciones, imagen en falso color, imagen en modo pancromático e imagen en verdadero color.

1.1.1.2 Sensor activos: LiDAR

Si bien los sensores pasivos vistos hasta ahora han experimentado una importante evolución en los últimos años no menos importante ha sido la consolidación y puesta en producción de sensores activos, destacando entre todos el sistema LASER (Light Amplification by Stimulated Emission of Radiation). Desde su aparición en los años 60, la tecnología LASER ha tenido un notable progreso, proliferando con éxito su empleo en las técnicas cartográficas a través de numerosas aplicaciones mediante su instalación en distintas plataformas: terrestre o aérea. En este sentido autores como Baltsavias (1999) califican la tecnología LiDAR (Light Detection and Ranging) como uno de los grandes avances del siglo anterior. Trabajos como los del profesor Ackermann (1999) exponen las bondades de esta tecnología, iniciándose desde entonces una intensa labor de investigación que ha tenido su resultado en la puesta en funcionamiento de forma generalizada de números proyectos con objetivos muy variados tales como metrología (Fidera et al. 2004; Ingensand 2006), estimación de parámetros forestales (Andersen et al. 2005; Clark et al. 2011), mantenimiento y control de líneas eléctricas (Liu et al. 2009; Sithole y

Vosselman 2006) o detección de cambios (Im et al. 2008; Vu et al. 2004) entre otros.

La tecnología LiDAR, dependiendo de la plataforma en la que se integra la podemos clasificar en LiDAR terrestre (en adelante TLS, Terrestrial Laser Scanner) y LiDAR aéreo (en adelante ALS, Airborne LiDAR System). De la combinación del concepto TLS pero aplicando el concepto de movimiento de los sistemas ALS desde plataformas terrestres encontramos además Mobile LiDAR. Independientemente de la plataforma sobre la que se instala el sensor LiDAR el modelo conceptual es siempre el mismo, un sensor activo que ofrece medidas directas de distancias entre el scanner LASER y la superficie topográfica o los objetos sobre esta. A partir de la observación de la distancia, la posición del sensor y la orientación del vector medido, el sistema determina las coordenadas tridimensionales del punto observado, ofreciendo nubes de puntos tridimensionales con una exactitud altimétrica elevada.

En el caso de plataformas terrestres, el TLS está siendo empleado en geología (Abellán et al. 2010; Armesto et al. 2009), patrimonio y conservación (Arayici 2007; Armesto-González et al. 2010), determinación de parámetros estructurales de árboles (Maltamo et al. 2005; Seidel et al. 2011), reconstrucción de escenario en criminología (Se y Jasiobedzki 2005; Topol et al. 2008) o medicina (Kovacs et al. 2006; Shahrom et al. 1996). En el caso de plataformas Mobile TLS los datos permiten mejorar los inventarios de carreteras a partir de la definición de los parámetros que definen planimétrica y altiméricamente el trazado recorrido (Chunhe y Danping 2006; Takagi et al. 2006). Proyectos como el European Road Safety Inspection (Mc Elhinney et al. 2010) tienen como objetivos la aplicación de esta tecnología con el objetivo de reducir el riesgo de accidentes de tráfico al tiempo que mejorar los trabajos de conservación de las vías de comunicación.

En el caso de sistemas ALS, la primera y principal aplicación ha sido la extracción de información de la superficie topográfica, obteniendo una mayor exactitud frente a otras técnicas (Kraus y Pfeifer, 1998; Lohr, 1998). La gestión del agua, determinación de zonas inundables o el control de la erosión de las costas a partir del Modelo Digital de Elevaciones (en adelante MDE) obtenidos mediante ALS, permiten generar modelos y estimación de parámetros (Brügelman et al. 2004). La generación de

modelos tridimensionales de ciudades permite optimizar la localización de antenas de telecomunicaciones, orientación de paneles fotovoltaicos e incluso realizar planeamiento urbanístico (Weidner 1997; Vosselman and Dijkmann 2001; Hofmann et al. 2002; Vögtle and Steinle 2004; Rottensteiner et al. 2005), daños estructurales en edificaciones frente a desastres naturales o como caso extremo ataques terroristas como los acontecidos en 2001 en el World Trade Center de New York (Steinle and Bähr 2002; Bähr et al. 2004). La gestión forestal es quizás la que de una manera más intensa está estudiando y explotando la información procedente de sensores ALS en su labor diaria; la estimación de biomasa, altura de arboles o la estimación en el volumen de madera son un claro ejemplo (Hyppa et al. 2001; Nässet 2002; Morsdorf 2003).

En un sistema LiDAR donde la plataforma se encuentra en movimiento, bien sea ALS o Mobile LiDAR, encontramos tres subsistemas. El primero lo conforma el subsistema encargado del escaneado, el cual se encargará de medir la distancia. En segundo lugar aparece el subsistema de georreferenciación compuesto de la unidad para determinar la posición y la unidad para determinar la orientación (Figura 1-4) y por último encontramos el subsistema de almacenamiento y control de los subsistemas. Como se observa el sistema ALS como tal ofrece nada más que distancias siendo necesario el empleo de sistemas GNSS e inerciales para su explotación. El primer dispositivo ALS a bordo de plataformas aéreas o espaciales fue diseñado a principios de los años setenta (Zarzycki 1972). Inicialmente la posición de las plataformas no era determinada con la suficiente exactitud siendo este el principal problema por el que el sistema no se emplearía en este periodo de tiempo. Con el desarrollo de los sistemas de navegación GNSS así como de los sistemas inerciales de navegación la georreferenciación precisa y exacta es hoy día una realidad, siendo posible la obtención de nubes de puntos 3D a partir de la georreferenciación directa del sensor laser y la orientación del vector de medida (Heipke et al., 2002).




Figura 1-4 Sistemas de georreferenciación y medida de distancia sistema LiDAR.

La tecnología LiDAR presenta dos modos de trabajar con la señal LASER (Ackermann 1999): dispositivos que trabajan con pulsos y dispositivos de onda continua (en adelante CW, Continuous Wave) (Figura 1-5). El sistema basado en la medida de pulsos mide el tiempo que tarda un pulso desde que es emitido por el sistema, impacta con la superficie de trabajo y vuelve al sistema. En el caso de LiDAR CW la medida de la distancia se realiza midiendo la diferencia de fase entre la señal emitida y recibida.




Figura 1-5 Comparativa funcionamiento LiDAR basado en pulsos y LiDAR basado en medición continua de onda.

Los primeros sistemas LiDAR de pulso registraban un solo retorno por pulso emitido. En este tipo de sistemas ALS, si la huella del rayo emitido impactase con el terreno, la información de un único pulso sería suficiente para caracterizar las coordenadas del punto de impacto. Sin embargo, aunque la huella del rayo emitido sea muy pequeña, la trayectoria del rayo puede encontrar a lo largo del recorrido distintos elementos que van a interactuar con el propio rayo. A consecuencia de esto se trabaja con sensores LiDAR multi-retorno o multi-eco, estos dispositivos son

capaces de discriminar hasta seis retornos individuales a partir de un pulso (Thiel y Wehr 2004). Los sensores LiDAR CW aparecieron en 1999 mostrando que la observación de la onda permite un correcto análisis de la vegetación (Blair et al. 1999). No obstante hasta el año 2004 no aparecería el primer sistema comercial (Hug et al. 2004). En esta clase, la señal puede ser descompuesta como la suma de distintos ecos generando una nube de puntos 3D y sobre esta se pueden aplicar los distintos algoritmos de clasificación que podemos emplear con sistemas LiDAR de pulsos. Por otro lado, sobre la información registrada es posible aplicar otros tipos de procesos apoyados en la topología 1D de señales.

La tecnología LiDAR por sus características presenta una alternativa en el registro de información al poder registrar información a distintos niveles dada la posibilidad de penetración de la señal. Tal aspecto resulta inviable empleando sensores pasivos como imágenes aéreas o de satélite. Por tal motivo el empleo de LiDAR está permitiendo generar utilidades en escenarios antes inimaginables como por ejemplo zonas forestales.

La inmensa mayoría de las aplicaciones desarrolladas mediante el empleo de información LiDAR se basan en la explotación de esta desde un punto de vista geométrico. Sin embargo el sensor LiDAR registra información de intensidad de señal la cual puede ser empleada desde un punto de vista radiométrico. En el **Capítulo 3** y **4** de la Tesis se explota esta variable con el objetivo de caracterizar e identificar usos de suelo.

1.1.2 Generación de conocimiento

Dentro de este conjunto de actividades se recogen todas y cada una de las actividades desarrolladas sobre el conjunto de imágenes registradas por un sensor con objeto de obtener un producto. Probablemente para muchos usuarios la fase final tras realizar un análisis digital de la imagen resulte ser una clasificación de esta. En cualquier caso las imágenes aportan la suficiente información para calcular índices de vegetación, estudios multitemporales y de detección de cambios o la determinación de estados de cultivos entre otros. De este modo a partir de las imágenes

registradas es posible realizar análisis espacio temporales del medio ambiente y del impacto de la actividad humana (Zhou y Robson 2001).

La explotación de la imagen en la mayoría de las ocasiones aparece centrada en la localización y caracterización de distintas variables de interés. La obtención de dicha información se consigue entre otros procesos mediante la clasificación digital de la imagen. De este modo se realiza una conversión donde se genera una nueva imagen de las mismas dimensiones que la original, realizando una conversión del valor de la energía almacenado en un pixel por una etiqueta que define a cada una de las clases o categorías presentes en la escena (Chuvienco 2008). Existen un amplio abanico de métodos y algoritmos de clasificación que se han desarrollado a lo largo del tiempo. En un primer momento, dado que las imágenes no son más que matrices de elementos, clasificaciones a nivel de pixel, tanto supervisadas como no supervisadas, han sido los métodos convencionales de clasificación (Dean y Smith 2003). Estos métodos basados en pixel, empleando la información multispectral, asignan cada uno de los pixeles que componen una imagen a la clase con la que comparten mayor similitud (Casals-Carrasco et al. 2000; Gong et al. 1992; Jensen 2005). En ocasiones la información espectral no es suficiente para caracterizar los distintos elementos y/o fenómenos presentes en una imagen, siendo necesario la aplicación de métodos basados en objetos donde variables como la textura o la información de contexto entran en juego (Giada et al. 2003; Yan et al. 2006; Zhou et al. 2004b).

En el caso de los métodos de clasificación basados en pixel podemos clasificar estos atendiendo al conocimiento previo que tenga el operador clasificador a la hora de realizar la clasificación de la imagen. En este sentido se distinguen métodos supervisados y no supervisados. En el caso de los métodos supervisados es necesario acumular un conocimiento previo sobre las características de las clases que se van a establecer en la leyenda. El operador define sobre la escena un conjunto de muestras a modo de campos de entrenamiento. El vector de medias y la matriz de covarianza de las celdillas que pertenecen a cada uno de los campos de entrenamiento definirán las características de cada clase, siendo utilizados posteriormente en la fase de asignación del resto de píxeles de la imagen. La selección y determinación de los campos de entrenamiento es una tarea delicada

pues de ella dependerá la calidad de los resultados de clasificación. Es necesario que las muestras se correspondan con celdas puras, no contaminadas por la presencia de varias clases, pero al mismo tiempo deben recoger toda la variabilidad de cada clase. Es aconsejable recoger muestras de tamaño pequeño y distribuidas por toda la imagen. Dentro de estos métodos encontramos diferentes algoritmos tales como mínima distancia, paralelepípedo, máxima probabilidad o spectral angle mapper bien documentados (Chuvieco 2008; Pinilla 1995). Este tipo de operadores han sido empleados en numerosas aplicaciones con objetivos bien diferentes.

En cuanto a los métodos no supervisados, el objetivo del clasificador es la agrupación de los datos de la imagen en grupos homogéneos atendiendo a similitudes espectrales de los fenómenos u objetos presentes en la escena sin que exista información previa de la realidad presente en la escena. Los algoritmos de este tipo siguen un triple proceso siendo necesaria la determinación de las características de las celdillas, medida de la similaridad o distancia estadística entre casos y la aplicación de algún tipo de agrupación. En esta categoría destacan dos algoritmos ISODATA y K-means. El resultado de estas clasificaciones obliga al operador en una fase posterior a relacionar las clases obtenidas de la clasificación con las clases de una posible leyenda. En ocasiones este tipo de algoritmos es empleado como fase previa a la aplicación de métodos supervisados, de tal manera que el operador llega a conocer las distintas clases presentes en la escena y el nivel de desagregación posible de las mismas (Walsh et al. 2008; Zhang et al. 2008).

La elección de un determinado operador de clasificación no tiene que ser un proceso estandarizado. Este tiene que ser definido en base a las particularidades del sensor, de la escena, del objetivo del proyecto y de los recursos tanto de software como de hardware. En lo referente al sensor, la resolución que presente será importante a la hora de seleccionar el clasificador. Independientemente de la resolución, y centrándonos en técnicas de clasificación a nivel de pixel, lo deseable es que la información registrada a modo de bandas espectrales por parte de un sensor se ajuste a las especificaciones del fabricante. En base a esto podemos observar como analizando la respuesta espectral relativa de la mayoría de los sensores espaciales y aerotransportados presentan recubrimientos en sus anchos de banda. Si bien tal hecho pasa desapercibido para el usuario, es importante indicar

que dependiendo de la base estadística empleada por el operador de clasificación seleccionado tal efecto puede originar resultados no del todo deseados. Markelin et al (2008) destacan como propiedad importante de la cámara ADS40 el hecho de no presentar sus bandas espectrales solapadas, indicando que este sensor está diseñado para ser empleado en procesos de Teledetección. El **capítulo 3** de la Tesis estudia como un correcto modelado de la respuesta espectral relativa de un sensor en los procesos de clasificación basados en estadística de primer orden mejora los resultados en la exactitud temática.

1.2 Combinación de sensores

Como se ha podido comprobar existen un número amplio de sensores con objetivos bien distintos. Si bien la mayoría de ellos producen información geográfica por sí mismos, otros necesitan de la información de otros sensores para una adecuada explotación de la información registrada. De este modo aparecen sensores vinculados como puede ser el caso por ejemplo de sensores LiDAR o cámaras áreas de barrido; estos no funcionan adecuadamente si simultáneamente no trabajan con sistemas GNSS e inerciales. En otras ocasiones el empleo de sensores de forma combinada produce sinergias que tienen como consecuencia una mejora de los trabajos de producción, exploración y explotación de los datos. En el caso del uso combinado de sensores multiespectrales y sensores ALS las ventajas en la producción se reflejan directamente en la calidad de los productos generados. La obtención de MDE y Modelos Digitales de Superficies (en adelante MDS) mediante sensores ALS es mucho más rápida, exacta y precisa que mediante procesos de correlación de imágenes obtenidas por sensores multiespectrales. En primer lugar la empresa productora mejora los procesos pues reduce considerablemente los tiempos de producción. Simultáneamente el usuario recibe un producto de mejor calidad, mejorando la exactitud posicional y temporal. Igualmente además de la producción de ortofotografías convencionales pueden generarse ortofotografías ortogonales verdaderas o true-orthophotos ante la posibilidad de obtener MDS de una forma más ágil que frente al trabajo solo con imágenes.

Desde el punto de vista de la exploración y análisis de los datos la combinación entre sensores multiespectrales y sistemas ALS permite enfocar las tareas de identificación de objetos, usos o fenómenos desde nuevos puntos de vista. Mientras que la información obtenida mediante sensores multiespectrales nos aporta información sobre la composición de los objetos observados la información espacial obtenida a partir de los puntos registrados por ALS nos ofrecerá información sobre la estructura geométrica de estos. La combinación de ambos sensores permitirá ampliar el modelo de conocimiento y de comprensión, pudiendo definir relaciones entre ambas fuentes de información. De este modo aquellos aspectos que no puedan ser interpretados o detectados mediante información espectral pueden ser evaluados mediante información geométrica. Igualmente tales tareas de interpretación pueden verse mejoradas mediante la combinación de ambos sensores. A partir de la información multiespectral y la altura es posible la identificación de árboles individuales (Popescu et al. 2002; Rees 2007), clasificación de usos de suelos agrícolas (Bork y Su 2007), estimación de biomasa (Popescu 2007), detección de cambios en el territorio (Walter 2004), policía urbanística (Awrangjeb et al. 2010; Rottensteiner et al. 2005).

Tal combinación de sensores es una realidad teniendo en cuenta plataformas aéreas y espaciales. De este modo, además de la combinación con cámaras multiespectrales, se encuentran aplicaciones de ALS con sensores como IKONOS (Erdody y Moskal 2010; Sohn y Dowman 2003), Landsat (Hudak et al. 2002; Wulder et al. 2007) o QuickBird (Cook et al. 2009; Chen y Hay 2011; Ke et al. 2010).

Los trabajos expuestos están basados en la explotación geométrica de la información ALS. Muchos autores han desarrollado algoritmos para la clasificación automática de puntos (Filin 2002; Filin y Pfeifer 2006; Sithole y Vosselman 2005), reconstrucción y detección de edificaciones (Alharthy y Bethel 2002; Haala y Brenner 1999; Rottensteiner y Briesse 2002) o la gestión forestal (Andersen et al. 2005; Goodwin et al. 2006; Morsdorf et al. 2004).

Un sistema LiDAR además registra información radiométrica a partir de la intensidad del rayo LASER que regresa al sensor. Dado que los mayores esfuerzos de investigación realizados con este sensor se han centrado en la información

geométrica y no en la radiométrica, las características de la intensidad LASER no son bien comprendidas y explotadas (Yoon et al. 2008). Sin embargo, el tener una densa información de puntos con información radiométrica puede ser interesante en procesos de clasificación de puntos o servir de fuente de información para ser explotada con técnicas de clasificación propias de teledetección (Chust et al. 2008; Donoghue et al. 2007; Song et al. 2002). En tal caso, la combinación de sensores sería entendida como la generación de nuevas bandas radiométricas a incluir en los procesos de trabajo donde participan las nuevas bandas de sensores multispectrales o hiperespectrales. En el **Capítulo 4** de la presente Tesis, con el objetivo de buscar nuevas alternativas de combinación de sensores se estudian posibles alternativas para emplear el sensor LiDAR junto con datos de cámara aérea.

Es posible emplear de forma simultánea distintas imágenes procedentes del mismo sensor o de sensores diferentes. En cualquier caso el entorno de trabajo en un proyecto de Teledetección invita a emplear información no redundante y lo más independiente posible. En este sentido y realizando una explotación de la variable intensidad LiDAR junto con imágenes procedentes de la cámara aérea se observa como el canal infrarrojo próximo y la intensidad LiDAR trabajan sobre las mismas longitudes de onda. Si bien tal combinación es adecuada la información aparece de forma redundante al trabajar sobre la misma región del espectro electromagnético. Tal aspecto hace que ambas fuentes de información sean dependientes. En el **Capítulo 5** se aplican procesos de análisis de componentes principales como fase previa a los procesos de clasificación cuando se emplean estos sensores de forma combinada. Además se aplica una transformación projection pursuit a fin de trasladar las bandas hacia un espacio de nuevas bandas independientes.

1.3 Objetivos y estructura de la tesis

Ante la situación planteada en los apartados anteriores, el objetivo de esta Tesis Doctoral ha sido analizar un conjunto de nuevas técnicas de explotación de la información recogida por sensores espaciales y aerotransportados, estudiando las ventajas de una explotación combinada entre sensores. Este planteamiento general se concreta en los siguientes objetivos:

- Analizar el concepto independencia en el procesado y explotación de imágenes.
- Evaluar la influencia de la curva de respuesta espectral relativa de un sensor multiespectral en los procesos de clasificación mediante operadores basados en estadística de primer orden.
- Analizar el parámetro intensidad registrado por sensores ALS para valorar métodos y procesos que permitan una mejor explotación y aprovechamiento.
- Estudiar la combinación de sensores multiespectrales y ALS estudiando su influencia en los procesos de clasificación de usos de suelo.

Esta Tesis Doctoral aparece estructurada en 6 capítulos. El **Capítulo 1**, capítulo actual, presenta el estado del arte en cuanto a sensores y procesos se refiere. En los siguientes capítulos se presentan y desarrollan los trabajos que fundamentan el núcleo de la presente Tesis. En este sentido, en el **Capítulo 2** se presenta las implicaciones de trabajar en un marco de independencia con las bandas de un sensor multiespectral, presentando los beneficios de trabajar con técnicas basadas en el análisis de componentes independientes frente a técnicas más convencionales en Teledetección como el análisis de componentes principales. El **Capítulo 3** presenta una metodología diseñada para mitigar los efectos del comportamiento solapado de las bandas de sensores multiespectrales en los procesos de clasificación mediante operadores de clasificación apoyados en estadística de primer orden. A lo largo del **Capítulo 4** se estudia como poder aprovechar la información registrada por sensores ALS mediante técnicas de clasificación, estudiando métodos para la normalización de la variable intensidad y sus beneficios con la combinación de información multiespectral registrada por sensores aéreos. En el **Capítulo 5** se aplica el concepto de independencia estudiado en el Capítulo 2 en la explotación combinada de sensores multiespectrales y ALS y sus repercusiones en los procesos de clasificación de imágenes. Por último, en el **Capítulo 6** se presentan unas conclusiones generales sobre la viabilidad del uso combinado de sensores para la explotación de la información desde el punto temático.

1.4 Rererencias

ISO 19101-2, I., 2008. Geographic information -- Reference model -- Part 2: Imagery.

Abellán, A., Calvet, J., Vilaplana, J.M., Blanchard, J., 2010. Detection and spatial prediction of rockfalls by means of terrestrial laser scanner monitoring. *Geomorphology*, 119, 162-171.

Ackermann, F., 1999. Airborne laser scanning-present status and future expectations. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 64-67.

Alharthy, A., Bethel, J., 2002. Heuristic filtering and 3D feature extraction from LIDAR data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 34, 29-34.

Andersen, H.E., McGaughey, R.J., Reutebuch, S.E., 2005. Estimating forest canopy fuel parameters using LIDAR data. *Remote sensing of Environment*, 94, 441-449.

Arayici, Y., 2007. An approach for real world data modelling with the 3D terrestrial laser scanner for built environment. *Automation in Construction*, 16, 816-829.

Armesto-González, J., Riveiro-Rodríguez, B., González-Aguilera, D., Rivas-Brea, M.T., 2010. Terrestrial laser scanning intensity data applied to damage detection for historical buildings. *Journal of Archaeological Science*, 37, 3037-3047.

Armesto, J., Ordóñez, C., Alejano, L., Arias, P., 2009. Terrestrial laser scanning used to determine the geometry of a granite boulder for stability analysis purposes. *Geomorphology*, 106, 271-277.

Awrangjeb, M., Ravanbakhsh, M., Fraser, C.S., 2010. Automatic detection of residential buildings using LIDAR data and multispectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 457-467.

Bähr, H.P., Hering Coelho, A., Leebmann, J., Steinle, E., Tóvari, D., 2004. Geospatial Data Acquisition by Advanced Sensors in Disaster Environments, *International Conference "Disasters and Society - From Hazard Assessment to Risk Reduction*.

Baltsavias, E.P., 1999. A comparison between photogrammetry and laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 83-94.

Barazzetti, L., Brovelli, M., Scaioni, M., 2007. Problems related to the generation of true-orthophotos with LiDAR DDSMs, *ISPRS Workshop on Laser Scanning*, 20-25.

Blair, J.B., Rabine, D.L., Hofton, M.A., 1999. The Laser Vegetation Imaging Sensor: a medium-altitude, digitisation-only, airborne laser altimeter for mapping vegetation and topography. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 115-122.

Bork, E.W., Su, J.G., 2007. Integrating LIDAR data and multispectral imagery for enhanced classification of rangeland vegetation: A meta analysis. *Remote sensing of Environment*, 111, 11-24.

Brügelmann, R. and Bollweg, A. E., 2004. Laser Altimetry for River Management. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 35, 234-239.

Casals-Carrasco, P., Kubo, S., Madhavan, B.B., 2000. Application of spectral mixture analysis for terrain evaluation studies. *International Journal of Remote Sensing*, 21, 3039-3055.

Clark, M.L., Roberts, D.A., Ewel, J.J., Clark, D.B., 2011. Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. *Remote sensing of Environment*, 15, 2931-2942.

Cook, B.D., Bolstad, P.V., Næsset, E., Anderson, R.S., Garrigues, S., Morisette, J.T., Nickeson, J., Davis, K.J., 2009. Using LiDAR and quickbird data to model plant production and quantify uncertainties associated with wetland detection and land cover generalizations. *Remote sensing of Environment*, 113, 2366-2379.

Chen, G., Hay, G.J., 2011. An airborne lidar sampling strategy to model forest canopy height from Quickbird imagery and GEOBIA. *Remote sensing of Environment* 15,1532-1542.

Chunhe, Y., Danping, Z., 2006. Road Curbs Detection Based on Laser Radar, *Signal Processing, 2006 8th International Conference on*.

Chust, G., Galparsoro, I., Borja, Á., Franco, J., Uriarte, A., 2008. Coastal and estuarine habitat mapping, using LIDAR height and intensity and multi-spectral imagery. *Estuarine, Coastal and Shelf Science*, 78, 633-643.

Chuvieco, E., 2008. Teledetección ambiental: La observación de la tierra desde el espacio. Editorial Ariel.

Dean, A., Smith, G., 2003. An evaluation of per-parcel land cover mapping using maximum likelihood class probabilities. *International Journal of Remote Sensing*, 24, 2905-2920.

Donoghue, D.N.M., Watt, P.J., Cox, N.J., Wilson, J., 2007. Remote sensing of species mixtures in conifer plantations using LiDAR height and intensity data. *Remote sensing of Environment*, 110, 509-522.

Erdody, T.L., Moskal, L.M., 2010. Fusion of LiDAR and imagery for estimating forest canopy fuels. *Remote sensing of Environment* 114, 725-737.

EuroSDR, 2008. EuroSDR project: Radiometric Aspects of Digital Photogrammetric Images. <http://www.fgi.fi/EuroSDR/>.

Ferrano, G., Feix, C., 2003. The Z/I Imaging DMC—Digital Mapping Camera system status, configuration and calibration, *ASPRS 2003 Annual Conference Proceedings*.

Fidera, A., Chapman, M.A., Hong, J., 2004. Terrestrial LiDAR for industrial metrology applications: Modelling, enhancement and reconstruction, *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 880-883.

Filin, S., 2002. Surface clustering from airborne laser scanning data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 34, 119-124.

Filin, S., Pfeifer, N., 2006. Segmentation of airborne laser scanning data using a slope adaptive neighborhood. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60, 71-80.

Fricker, P., Sandau, R., Walker, A., 1999. Digital photogrammetric cameras: possibilities and problems, *Photogrammetric Week '99, Heidelberg, Germany*, 71-82.

Georgi, C., Stognienko, R., Knuth, S., Albe, G., 2005. JAS: The next generation digital aerial scanner, *Photogrammetric week'05, Germany*, 147-154.

Giada, S., De Groot, T., Ehrlich, D., Soille, P., 2003. Information extraction from very high resolution satellite imagery over Lukole refugee camp, Tanzania. *International Journal of Remote Sensing*, 24, 4251-4266.

Gong, P., Marceau, D.J., Howarth, P.J., 1992. A comparison of spatial feature extraction algorithms for land-use classification with SPOT HRV data. *Remote sensing of Environment*, 40, 137-151.

Goodwin, N.R., Coops, N.C., Culvenor, D.S., 2006. Assessment of forest structure with airborne LiDAR and the effects of platform altitude. *Remote sensing of Environment*, 103, 140-152.

Grenzdörffer, G., 2008. Medium format digital cameras—a EuroSDR project. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3-11.

Günay, A., Arefi, H., Hahn, M., 2007. Semi-automatic true orthophoto production using LiDAR data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36, 2873-2876.

Haala, N., Brenner, C., 1999. Extraction of buildings and trees in urban environments. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 130-137.

Heipke, C., Jacobsen, K., Wegmann, H., (2002). Analysis of the results of the OEEPE test "Integrated Sensor Orientation". *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 33, B3/1, 295-302.

Hinz, A., Dörstel, C., Heier, H., 2001. DMC-The digital sensor technology of Z/I-Imaging. *D. Fritsch and R. Spiller Photogrammetric Week '01*, 93-103.

Hoffmann, A., Van Der Vegt, J.W., Lehmann, F., 2000. Towards automated map updating: is it feasible with new digital data-acquisition and processing techniques? *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 33, 295-302.

Hofmann, A. D., Maas, H.G., Streilein, A., 2002. Knowledge-Based Building Detection Based on Laser Scanner Data and Topographic Map Information. *ISPRS comission III*, 34, Part 3A, A169-174

Honkavaara, E., Ahokas, E., Hyyppä, J., Jaakkola, J., Kaartinen, H., Kuitinen, R., Markelin, L., Nurminen, K., 2006. Geometric test field calibration of digital photogrammetric sensors. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60, 387-399.

Honkavaara, E., Arbiol, R., Markelin, L., Martinez, L., Cramer, M., Bovet, S., Chandelier, L., Ilves, R., Klonus, S., Marshal, P., 2009. Digital airborne photogrammetry—A new tool for quantitative remote sensing?—A state-of-the-Art review on radiometric aspects of digital photogrammetric images. *Remote Sensing*, 1, 577-605.

Hudak, A.T., Lefsky, M.A., Cohen, W.B., Berterretche, M., 2002. Integration of lidar and Landsat ETM+ data for estimating and mapping forest canopy height. *Remote sensing of Environment*, 82, 397-416.

Hug, C., Ullrich, A., Grimm, A., 2004. Litemapper-5600-A waveform-digitizing lidar Terrain and vegetation mapping system. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36, 24-29.

Hyypä, J., Kelle, O., Lehtinen, M., Inkinen, M., 2001. A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. *IEEE Transactions on Geoscience and Remote Sensing*, 39, 969-975.

Im, J., Jensen, J., Tullis, J., 2008. Object-based change detection using correlation image analysis and image segmentation. *International Journal of Remote Sensing*, 29, 399-423.

Ingensand, H., 2006. Metrological aspects in terrestrial laser-scanning technology, *12th FIG Symposium*, Badem.

Jensen, J., 2005. *Introductory Digital Image Processing: A Remote Sensing Perspective*. Prentice-Hall PTR, Upper Saddle River, NJ.

Johnson, B., Brown, S., Rice, J., 2004. Metrology for remote sensing radiometry, *Proceedings of the International Workshop on Radiometric and Geometric Calibration*. Taylor & Francis: London, UK, Gulfport, MS, USA.

Ke, Y., Quackenbush, L.J., Im, J., 2010. Synergistic use of QuickBird multispectral imagery and LIDAR data for object-based forest species classification. *Remote sensing of Environment*, 114, 1141-1154.

Kovacs, L., Zimmermann, A., Brockmann, G., Baurecht, H., Schwenzer-Zimmerer, K., Papadopoulos, N., Papadopoulos, M., Sader, R., Biemer, E., Zeilhofer, H., 2006. Accuracy and precision of the three-dimensional assessment of the facial surface using a 3-D laser scanner. *Medical Imaging, IEEE Transactions on*, 25, 742-754.

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

Laliberte, A., Browning, D., Herrick, J., Gronemeyer, P., 2010. Hierarchical object-based classification of ultra-high-resolution digital mapping camera (DMC) imagery for rangeland mapping and assessment. *Journal of Spatial Science*, 555, 101-115.

Leberl, F., Gruber, M., 2003. Economical large format aerial digital camera. *GIM International*, 17, 1-5.

Leberl, F., Gruen, A., 2003. Flying the new large format digital aerial camera Ultracam, *Photogrammetric Week'03*, Germany, 67-76.

Lillesand, T.M., Kiefer, R.W., 2008. Remote sensing and image interpretation. 6th edition, 6 ed. New York. Wiley & Sons.

Liu, Y., Li, Z., Hayward, R., Walker, R., Jin, H., 2009. Classification of airborne lidar intensity data using statistical analysis and Hough transform with application to power line corridors, *Digital Image Computing: Techniques and Applications*, 2009. *DICTA '09.*, 462-467.

Lohr, U., 1998. Digital elevation models by laser scanning. *Photogrammetric Record*, 16, 105-109.

Maltamo, M., Packalén, P., Yu, X., Eerikäinen, K., Hyyppä, J., Pitkänen, J., 2005. Identifying and quantifying structural characteristics of heterogeneous boreal forests using laser scanner data. *Forest Ecology and Management*, 216, 41-50.

Markelin, L., Honkavaara, E., Peltoniemi, J., Ahokas, E., Kuittinen, R., Hyyppä, J., Suomalainen, J., Kukko, A., 2008. Radiometric calibration and characterization of large-format digital photogrammetric sensors in a test field. *Photogrammetric engineering and remote sensing*, 74, 1487-1500.

Mc Elhinney, C., Kumar, P., Cahalane, C., McCarthy, T., 2010. Initial results from European Road Safety Inspection (EURSI) mobile mapping project. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38, 440-445.

Morsdorf, F., Meier, E., Allgöwer, B., Nüesch, D., 2003. Clustering in Airborne Laser Scanning Raw Data for Segmentation of Single Trees. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34, 3/W13.

Morsdorf, F., Meier, E., Kotz, B., Itten, K.I., Dobbertin, M., Allgower, B., 2004. LIDAR-based geometric reconstruction of boreal type forest stands at single tree level for forest and wildland fire management. *Remote sensing of Environment*, 92, 353-362.

Naësset, E., 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment*, 80, 88-99.

OGC, 2004. Topic 7: The earth imagery case. version 5.

Petrie, G., Walker, A.S., 2007. Airborne digital imaging technology: a new overview. *Photogrammetric Record*, 22, 203-225.

Pinilla, C., 1995. Elementos de teledetección. Editorial RA-MA.

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

Popescu, S.C., Wynne, R.H., Nelson, R.F., 2002. Estimating plot-level tree heights with lidar: local filtering with a canopy-height based variable window size. *Computers and Electronics in Agriculture*, 37, 71-95.

Rees, W., 2007. Characterisation of Arctic treelines by LiDAR and multispectral imagery. *Polar Record*, 43, 345-352.

Rottensteiner, F., Briese, C., 2002. A new method for building extraction in urban areas from high-resolution LIDAR data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 34, 295-301.

Rottensteiner, F., Trinder, J., Clode, S., Kubik, K., 2005. Automated delineation of roof planes from LIDAR Data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36, 3/W19, 221 - 226.

Rottensteiner, F., Trinder, J., Clode, S., Kubik, K., 2005. Using the Dempster-Shafer method for the fusion of LIDAR data and multi-spectral images for building detection. *Information Fusion*, 6, 283-300.

Sandau, R., Braunecker, B., Driescher, H., Eckardt, A., Hilbert, S., Hutton, J., Kirchhofer, W., Lithopoulos, E., Reulke, R., Wicki, S., 2000. Design principles of the LH systems ADS40 airborne digital sensor, *International Archives of Photogrammetry and Remote Sensing, Proceedings of the XIX ISPRS Congress, Amsterdam*, 258-265.

Sandau, R., Ralf Reulke, S.W., 2000. Design principles of the LH Systems ADS40 airborne digital sensor. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 33, 258-268.

Sasagawa, T., Madhavan, B.B., Ozawa, A., Tachibana, K., 2004. Capability for data fusion by airborne sensing. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 35, 901–905.

Schiewe, J., 2005. Status and future perspectives of the application potential of digital airborne sensor systems. *International Journal of Applied Earth Observation and Geoinformation*, 6, 215-228.

Se, S., Jasiobedzki, P., 2005. Instant Scene Modeler for Crime Scene Reconstruction, Computer Vision and Pattern Recognition - Workshops, 2005. CVPR Workshops. IEEE Computer Society Conference on, 123-123.

Seidel, D., Leuschner, C., Müller, A., Krause, B., 2011. Crown plasticity in mixed forests—Quantifying asymmetry as a measure of competition using terrestrial laser scanning. *Forest Ecology and Management*, 261, 2123-2132.

Shahrom, A., Vanezis, P., Chapman, R., Gonzales, A., Blenkinsop, C., Rossi, M., 1996. Techniques in facial identification: computer-aided facial reconstruction using a laser scanner and video superimposition. *International journal of legal medicine*, 108, 194-200.

Sithole, G., Vosselman, G., 2005. Filtering of airborne laser scanner data based on segmented point clouds. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36, 66-71.

Sithole, G., Vosselman, G., 2006. Bridge detection in airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 61, 33-46.

Sohn, G., Dowman, I., 2003. Building extraction using Lidar DEMs and Ikonos images. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34, 3-10.

Song, J.H., Han, S.H., Yu, K., Kim, Y.I., 2002. Assessing the possibility of land-cover classification using lidar intensity data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 34, 259-262.

Steinle, E., Bähr, H.P., 2002. Potential of laser scanning derived height models for the recognition of earthquake caused building damages. *International Conference on Earthquake Loss Estimation and Risk Reduction*, 24 – 26.

Takagi, K., Morikawa, K., Ogawa, T., Saburi, M., 2006. Road Environment Recognition Using On-vehicle LIDAR. *Intelligent Vehicles Symposium, 2006 IEEE*, 120-125.

Thiel, K., Wehr, A., 2004. Performance Capabilities of Laser-Scanners-An Overview and Measurement Principle Analysis. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36, 14-18.

Topol, A., Jenkin, M., Gryz, J., Wilson, S., Kwietniewski, M., Jasiobedzki, P., Ng, H.K., Bondy, M., 2008. Generating Semantic Information from 3D Scans of Crime Scenes. *Computer and Robot Vision, 2008. CRV '08. Canadian Conference on*, 333-340.

Vögtle, T., Steinle, E., 2003. On the quality of object classification and automated building modelling based on laser scanning data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 34, 3/W13, 8-10.

Vosselman, G., Dijkman, S., 2001. 3D building model reconstruction from point clouds and ground plans. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 33, III/W4, 37-43.

Vu, T.T., Matsuoka, M., Yamazaki, F., 2004. LIDAR-based change detection of buildings in dense urban areas. *Geoscience and Remote Sensing Symposium, 2004. IGARSS '04. Proceedings. 2004 IEEE International*, 3413-3416

Walsh, S.J., McCleary, A.L., Mena, C.F., Shao, Y., Tuttle, J.P., González, A., Atkinson, R., 2008. QuickBird and Hyperion data analysis of an invasive plant species in the Galapagos Islands of Ecuador: Implications for control and land use management. *Remote sensing of Environment*, 112, 1927-1941.

Walter, V., 2004. Object-based evaluation of LIDAR and multispectral data for automatic change detection in GIS databases. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 23-23.

Weidner, U., Förstner W., 1995. Towards automatic building extraction from high resolution digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing*, 53, 38-49.

Weng, Q., 2011. Advances in environmental remote sensing : sensors, algorithms, and applications. CRC Press.

Wulder, M.A., Han, T., White, J.C., Sweda, T., Tsuzuki, H., 2007. Integrating profiling LIDAR with Landsat data for regional boreal forest canopy attribute

estimation and change characterization. *Remote sensing of Environment*, 110, 123-137.

Yan, G., Mas, J.F., Maathuis, B., Xiangmin, Z., Van Dijk, P., 2006. Comparison of pixel-based and object-oriented image classification approaches—a case study in a coal fire area, Wuda, Inner Mongolia, China. *International Journal of Remote Sensing*, 27, 4039-4055.

Yoon, J.S., Shin, J.I., Lee, K.S., 2008. Land cover characteristics of airborne LiDAR intensity data: a case study. *Geoscience and Remote Sensing Letters, IEEE* 5, 801-805.

Zarzycki, J., 1972. The use of auxiliary data in aerial triangulation, *ISPRS Congress. Commission III*, Ottawa.

Zhang, X., Sun, R., Zhang, B., Tong, Q., 2008. Land cover classification of the North China Plain using MODIS_EVI time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63, 476-484.

Zhou, Q., Li, B., Zhou, C., 2004. Detecting and modelling dynamic land-use change using multi-temporal and multi-sensor imagery. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34, 697-702.

Zhou, Q., Robson, M., 2001. Automated rangeland vegetation cover and density estimation using ground digital images and a spectral-contextual classifier. *International Journal of Remote Sensing*, 22, 3457-3470.

Capítulo 2

Análisis de componentes independientes

Resumen: Las imágenes registradas por sensores a bordo de plataformas aéreas o espaciales aportan una gran cantidad de información sobre los fenómenos que acontecen en la Tierra. Cada sensor mide la radiación electromagnética emitida o reflejada por los elementos o superficies objeto de estudio. Al analizar la estructura de datos generada, esta es entendida como un conjunto de bandas espectrales obtenidas a partir de la combinación de distintos elementos independientes. De este modo un pixel es considerado como la mezcla de distintos elementos fuentes. En este proceso influyen tanto el propio modo de registrar información el sensor como la mezcla de coberturas en un pixel. Antes de desarrollar cualquier proceso de clasificación en ocasiones se hace necesario realizar un pre-procesado de la imagen. Uno de los métodos más comúnmente empleado en Teledetección es realizar un análisis de componentes principales en tareas como la reducción del número de bandas. Métodos menos conocidos como el análisis de componentes independientes, planteados como una posible solución a la separación ciega de señales están poco a poco empleándose en este terreno. Tales técnicas presentan

una base conceptual más consistente que el análisis de componentes principales al estar basadas las primeras en el concepto de independencia estadística frente al concepto de correlación las cuales serán estudiadas en el presente capítulo. El análisis de componentes independientes se puede desarrollar empleando distintos algoritmos. En este capítulo se ha trabajado con los algoritmos FastICA y JADE. La aplicación práctica de estos conceptos se ha desarrollado sobre imágenes de alta resolución procedentes del sensor IKONOS aplicando ambos tipos de análisis como fase previa a una clasificación. Sobre las nuevas bandas generadas procedentes de cada análisis así como sobre la imagen original se han realizado clasificaciones mediante métodos no supervisados y supervisados. En el caso de la clasificación no supervisada se empleó el operador ISODATA. Los resultados mostraron como se identificaban de manera más cómoda y ágil los distintos elementos y fenómenos una vez aplicadas las técnicas de análisis de componentes independientes. En el caso de la clasificación supervisada se usó el clasificador máxima probabilidad. De nuevo los mejores resultados se obtuvieron en las imágenes donde se aplicaron las técnicas ICA quedando demostrado como este tipo de análisis es una herramienta muy útil en el campo de la Teledetección.

Palabras clave: Correlación, independencia, análisis componentes principales, análisis componentes independientes.

2.1 Introducción

El incremento en el número de imágenes multiespectrales e hiperespectrales hace necesario métodos efectivos a la hora de analizar y explotar estos datos. Sin duda alguna, uno de los procesos más empleados para extraer información de una imagen es a través de la clasificación de dicha imagen. Una clasificación eficiente y exacta es clave en el control, evaluación y predicción de cambios medioambientales, análisis del territorio, etc. Para ello se cuenta con una gran variedad de algoritmos con distintos tipos de automatización, estrategia de cálculo y estadística empleada.

Previa a la clasificación, en algunas ocasiones, sobre la imagen se desarrollan un conjunto de procesos y análisis con el fin de ayudar al algoritmo empleado en el desarrollo de la clasificación. Ejemplo de ellos podemos encontrarlo en el análisis de componentes principales (en adelante PCA), el cual cambia la disposición de la información de una imagen en distintos componentes que incluirán más del 99% de la información recogida por la imagen original. PCA es una transformación ortogonal que permite reducir la influencia de la correlación entre bandas ayudando a mejorar la exactitud en los resultados de la clasificación (Chuvieco 1998). Tradicionalmente este es el método empleado a tales efectos, no obstante en la literatura se pueden encontrar otros métodos con los mismos propósitos y con una base matemática mucho más consistente. Ejemplo de lo anterior es el análisis de componentes independientes (en adelante ICA). Este un método desarrollado para la separación ciega de señales (Blind Source Separation, en adelante BSS). ICA es un método de análisis multivariante el cual dado un conjunto componentes de datos independientes que han sido mezclados siguiendo un modelo lineal recupera estos a partir de la determinación de una matriz de separación. Puede advertirse como la diferencia en las componentes obtenidas entre PCA e ICA se basa en la diferencia de los conceptos de correlación e independencia, términos que con frecuencia se entienden como iguales pese a existir claras diferencias entre ellas.

La aplicación de técnicas ICA son empleadas con éxito en numerosos campos. En acústica es empleada para separar distintas fuentes de sonido, permitiendo aislar señales acústicas (Kinnunen y Li 2010; Kwon y Lee 2004; Zuo et al. 2005). En medicina tales técnicas son aplicadas en resonancias magnéticas (Calhoun et al. 2005; Ma et al. 2007; Sui et al. 2009) o encefalogramas (Akhtar et al. 2012), permitiendo ser un soporte a la hora de realizar diagnósticos. Desde un punto de vista económico autores como Vermorken et al. (2010) clasifican y catalogan empresas a partir de las relaciones de sus valores en stock. Lizieri et al. (2007) establecen estrategias de mercado determinando el riesgo a través de este tipo de análisis. De este modo puede observarse como estas herramientas son muy versátiles permitiendo una mejor explotación de los datos. En el campo de la Teledetección los estudios y aplicaciones de ICA aparecen centrados principalmente en la reducción de la dimensión de imágenes hiperespectrales (Nascimento y Dias 2005; Wang y Chang 2006a, b). Otros autores como He et al. (2006) aplican ICA

sobre imágenes Landsat ETM para mejorar la calidad de clasificaciones temáticas realizadas. Farah y Ahmed (2002) y Karoui et al. (2009) trabajando con imágenes SPOT mejoraron la calidad de la clasificación aplicando tanto el algoritmo FastICA como JADE frente a los resultados obtenidos con la imagen original sin procesar. Karvonen y Similä (2003) aplicaron estas técnicas sobre imágenes SAR empleando algoritmos de clasificación no supervisada. Por tanto, estas técnicas son de gran utilidad como fase previa a la aplicación y uso de operadores de clasificación tanto supervisados como no supervisados (Du et al., 2004 ; Zhang et al., 2006).

Los objetivos a cubrir en el presente capítulo son:

- Analizar y estudiar el concepto de independencia aplicado a imágenes multiespectrales.
- Aplicar algoritmos que desarrollen ICA sobre imágenes de alta resolución así como PCA.
- Analizar y evaluar los resultados de la aplicación de clasificadores supervisados y no supervisados sobre imágenes registradas por el sensor IKONOS así como imágenes pre-procesadas mediante análisis ICA y PCA.

2.2 Materiales

Se ha seleccionado como área de trabajo una zona agrícola de Andalucía correspondiente al término municipal de Montilla, provincia de Córdoba, en el Sur de España (coordenadas centrales 37°35'07"N, 4°38'20"O, WGS84) Dicha zona presenta un relieve muy suave con una altura respecto al nivel del mar igual a 380 metros, caracterizada por un clima Mediterráneo continental. El sensor empleado fue IKONOS, realizando los ensayos sobre una muestra de la imagen completa de dimensiones 750 × 850 píxeles (Figura 2-1). La escena fue adquirida el 01 de Marzo de 2001. Se trabajó con la imagen en modo multiespectral, con una resolución espacial igual a 4 metros y con una resolución espectral igual a 4 correspondientes a las bandas del Rojo, Verde, Azul e Infrarrojo próximo. Se trabajó directamente sobre

la imagen adquirida sin realizar ningún tipo de corrección dado que el objetivo del trabajo fue discriminar ciertos usos de suelo respecto de otros presentes en la imagen, y por tanto actuando de forma relativa. Los usos de suelo que se han tenido en cuenta son los correspondientes a cultivos herbáceos, cultivos leñosos, suelos con cubierta vegetal, suelos desnudos y carreteras.




Figura 2-1 Zona de estudio correspondiente a fragmento escena IKONOS.

2.3 Metodología

2.3.1 Análisis de componentes independientes

Considérese el problema del “cocktail party” donde en una habitación se encuentran distintas personas hablando entre ellas. En el caso de que hablasen simultáneamente sus voces no podrían ser diferenciadas aunque para ello se empleasen varios micrófonos. Esto es debido a que la señal que se registra en cada uno de los micrófonos empleados es el resultado de la mezcla de un conjunto de señales fuentes, en este caso las voces. La manera en que estas voces se han mezclado no se puede conocer y depende de diferentes factores tales como la distancia del orador al micrófono. Ante esta situación queda definido un problema donde se pretende recuperar un conjunto de señales desconocidas que aparecen mezcladas de forma también desconocida. El objetivo consiste en distinguir la conversación realizada por cada orador dentro de la habitación. Generalmente, este problema se denomina separación ciega de señales (Blind Source Separation, en adelante BSS). Tiene por objeto la estimación de un conjunto de señales fuente, de las cuales a priori no se conoce su naturaleza, a partir de una serie de medidas que son una función desconocida de dicha señal fuente. Inicialmente tal planteamiento fue propuesto por Héroult et al. (1985) como solución matemática a un proceso biológico del sistema nervioso central cuando se transmiten informaciones mezcladas por distintas fibras nerviosas. Las diferencias entre señales fuente y señales mezcladas son descritas por tres propiedades y/o comportamientos:

- Independencia: Mientras que las señales fuentes son estadísticamente independientes, sus mezclas no lo son. En la Figura 2-2.1 se representa dos situaciones que ponen de manifiesto las relaciones entre variables. En el primero de los casos Figura 2-2.1.a no es posible definir la relación existente entre ambas variables. En el caso de la Figura 2-2.1.b si se pone de manifiesto dicha relación. Podría decirse a priori que en el primero de los casos las variables son independientes y en el segundo caso no lo son. Tal aspecto será estudiado en el presente capítulo de la Tesis.

- Normalidad: Mientras que las señales mezcla presentan una distribución normal o gaussiana no ocurre lo mismo con señales fuentes. Las Figura 2-2.II.a y Figura 2-2.II.c representan dos variables cuyos histogramas se alejan de una distribución normal, por tanto es posible afirmar que ambas variables se corresponde con señales fuente. En el caso de la variable representada en la Figura 2-2.II.b, su histograma se asemeja a una distribución normal y por tanto dicha variable es el resultado de la mezcla de distintas fuentes independientes. Tal propiedad es puesta en valor en el **Capítulo 5** de la Tesis.

Tal condición es definida a partir de la aplicación del teorema de límite central, el cual establece:

Si un conjunto de señales $s = (s_1, s_2, \dots, s_n)$ son independientes y con media $(\mu_1, \mu_2, \dots, \mu_n)$ y varianza $(\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2)$ entonces, para un número elevado de N , la suma de tales señales

$$x = \sum_{i=1}^N s_i$$

tiene un pdf aproximadamente igual a una distribución gaussiana.

- Complejidad: La mezcla de señales presenta una estructura más compleja que las señales fuente. Las señales representadas en la Figura 2-2.III.a y la Figura 2-2.III.b presentan una estructura sencilla, cíclica y simple. Por el contrario la señal representada en la Figura 2-2.III.c presenta una estructura más compleja. Así pues, en este último caso, la estructura indica que la variable es el resultado de la combinación de varias variables independientes.

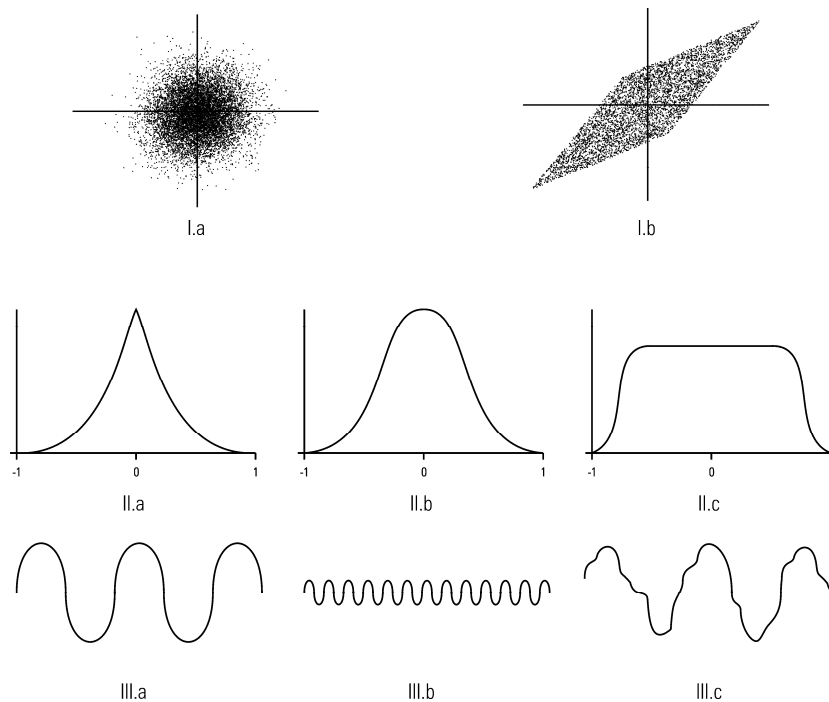


Figura 2-2 Diferencias señales independientes versus señales mezcla: I. Independencia, II normalidad y III complejidad.

A la vista de lo expuesto anteriormente se puede observar como a partir de un conjunto de señales mezcla podemos extraer las señales fuente a partir de potenciar al máximo algunas de las tres características anteriores.

ICA es un tipo de método BSS empleado en la separación de datos en componentes estadísticamente independientes o lo más independientes posibles. Estos datos pueden tener una naturaleza muy variada tales como imágenes, sonidos o movimiento de los precios en los mercados. ICA está relacionado con otros métodos de análisis de datos tales como PCA o el análisis factorial (Factorial analysis, en adelante FA). La diferencia entre estas técnicas radica en que mientras que ICA busca un conjunto de datos independientes, PCA y FA tiene como objeto establecer un conjunto de datos incorreladas unas respecto de los otros. En el contexto de desarrollo del trabajo el conjunto de datos será entendido como un conjunto de bandas espectrales obtenidas mediante uno o varios sensores.

PCA es una técnica empleada en muy diversas áreas de la ciencia. Fue desarrollada originalmente por Pearson en 1901 en un contexto biológico, y de forma independiente por Hotteling en 1903. Dicha técnica también es conocida como la transformación de Karhunen-Loève. El objetivo de PCA es describir la variación producida por la observación de p variables aleatorias x_j en términos de un conjunto de nuevas variables incorreladas entre sí, cada una de las cuales es combinación lineal de las variables originales.

Las técnicas ICA proceden de una generalización del término PCA. En PCA se descomponen las variables observadas x_0, x_1, \dots, x_n como combinaciones lineales de las variables incorreladas y_0, y_1, \dots, y_n . La no correlación no implica que sean independientes, existiendo por tanto infinitas descomposiciones en componentes de las cuales PCA es solo un caso particular. De este modo se establece como la independencia implica la no correlación pero la situación recíproca no tiene porque cumplirse. Es posible establecer que cuanto más independientes sean las bandas espectrales que componen una escena o conjuntos de escenas mejor aprovechamiento de la información podrá realizarse; de ahí el interés de estas técnicas en el campo de la Teledetección.

2.3.1.1 ¿Qué es independencia?

Como se ha mencionado anteriormente, el concepto correlación es empleado a menudo ligado al término independencia si bien son dos términos diferentes. En ocasiones se establece que si dos variables no están correladas entonces dichas variables no guardan relación alguna, siendo independientes. Tal afirmación no es cierta en todos los casos. La definición de independencia aparece relacionada con los momentos de la función densidad de probabilidad (en adelante pdf) de una señal. La pdf de una señal puede ser caracterizada en términos de sus momentos:

- Primer momento: El primer momento de la pdf de una variable x se corresponde con el valor de la media \bar{x} . También es conocido como valor esperado o esperanza $E[x]$ de la variable x .

- Segundo momento: Respecto de la media de una variable x aparece relacionado con su varianza $E[x^2]$. La varianza mide la dispersión de los valores de la variable x respecto de su valor central.
- Tercer momento: $E[x^3]$ define la simetría de una variable x .
- Cuarto momento: Aparece definido mediante la kurtosis $E[x^4]$ de una variable x .

Para definir el concepto de independencia se van a considerar dos variables aleatorias x e y . Dichas variables tienen una pdf igual a p_x y p_y respectivamente y una pdf conjunta igual a p_{xy} . De este modo Comon (1994) establece que:

Dos variables x e y son independientes si y solo si

$$p_{xy}(x, y) = p_x(x) \cdot p_y(y) \quad \text{Ec. 2-1}$$

De tal modo que:

Si x e y son independientes entonces, para cualquier valor de p y q se tiene que cumplir

$$E[x^p y^q] = E[x^p] \cdot E[y^q] \quad \text{Ec. 2-2}$$

Siendo p y q los índices de los momentos de uno a cuatro de una variable.

Si $p = q = 1$ entonces $E[x^p y^q] = E[xy]$, siendo este el primer momento de la pdf conjunta p_{xy} . La esperanza $E[x, y]$ es definida como la covarianza entre las

variables x e y . La covarianza aparece íntimamente relacionada con la correlación $\rho(x, y)$, la cual es una versión normalizada de la covarianza igual a:

$$\rho(x, y) = \frac{E[xy]}{\sigma_x \sigma_y} \quad \text{Ec. 2-3}$$

Siendo σ_x y σ_y las desviaciones estándar de las variables x e y respectivamente.

Puede observarse como la correlación es una medida de la cantidad de covariación entre las variables x e y que depende solamente del primer momento de la pdf de p_{xy} , no cumpliendo la condición general establecida en la Ec. 2-2. Por el contrario, el concepto independencia depende de todos los momentos de la pdf de p_{xy} , cumpliendo en todo momento la Ec. 2-2.

La aplicación práctica de las implicaciones de los conceptos de correlación e independencia puede analizarse en el comportamiento de dos péndulos los cuales presentan una diferencia en su fase de 90° (Figura 2-3.a). En este caso ambos péndulos presentan una correlación clara, mientras que uno de ellos se encuentre en la parte inferior el otro se encontrará en una posición ortogonal a la línea que sostiene al primero, por tanto la velocidad de ambos péndulos aparece relacionada tal y como puede observarse en Figura 2-3.b, siendo por tanto dependientes del tiempo. Al calcular la correlación entre ambos péndulos resultará un valor igual a cero, es decir, no es capaz de ponerse de manifiesto la relación entre ambos péndulos. En este estado se habrán tomado como valores $p = q = 1$, correspondientes al primer momento.




Figura 2-3 Análisis correlación: (a) Péndulos en movimiento con desfase 90°, (b) velocidad péndulos con misma frecuencia y desfasados 90°.

La principal diferencia que se establece a tenor de lo expuesto entre PCA y las técnicas ICA se basa en el hecho de que mientras que PCA descompone la información en un conjunto de señales incorreladas, ICA las descompone en señales independientes.

Desde el punto de vista de los momentos, PCA determinará una matriz que transformará la información mezcla $x = (x_1, x_2)$, con una pdf conjunta $p_x(x_1, x_2)$ en un nuevo conjunto de datos $y = (y_1, y_2)$ de tal forma que se asegura:

$$E[y_1 y_2] = E[y_1] E[y_2] \quad \text{Ec. 2-4}$$

Por el contrario, la aplicación de ICA implica satisfacer:

$$E[y_1^p, y_2^q] = E[y_1^p] E[y_2^q] \quad \text{Ec. 2-5}$$

Para cualquier p y q definidos enteros y positivos.

Con respecto a la varianza, PCA extrae un nuevo conjunto de datos ordenados según este parámetro mientras que ICA es un proceso ciego respecto a esta.

2.3.1.2 Definición de ICA

Una definición rigurosa de ICA asume un modelo estadístico de variables latentes, es decir, variables que no pueden ser observadas directamente (Common, 1994). Tal modelo asume que se observan n mezclas lineales x_1, x_2, \dots, x_n de n componentes independientes. En esta línea, el modelo descrito será de tipo generativo al describir como los datos que se observan son generados a partir de un proceso de mezcla de distintos componentes.

$$x_j = a_{j1} \cdot s_{j1} + a_{j2} \cdot s_{j2} + \dots + a_{jn} \cdot s_{jn} \quad \text{Ec. 2-6}$$

Siendo:

- x_j los valores de las señales observadas.
- a_{ji} los pesos de las mezclas.
- s_{ji} los valores de las señales originales.

De forma simplificada el modelo queda planteado como:

$$x = A \cdot s \quad \text{Ec. 2-7}$$

De Ec. 2-7 solo se conoce el vector de observaciones x , estimando tanto la matriz de mezcla A como las señales originales s . Para ello solo se empleará x bajo una serie de condiciones.

El primer paso para la solución del problema pasa por establecer que la información contenida en s es estadísticamente independiente. A partir de la estimación de la matriz de mezcla A será posible determinar su inversa W , tal que permita obtener s de la forma:

$$s = W \cdot x \quad \text{Ec. 2-8}$$

De este modo como refleja la Figura 2-4, el objetivo es determinar s a partir de los valores de un conjunto de observaciones x . Para ello, bajo un conjunto de restricciones se estimará y como la mejor aproximación posible de s .




Figura 2-4 Esquema general para la solución ICA.

Como fase previa y antes de proceder directamente a aplicar este tipo de análisis sobre un conjunto de datos es conveniente preprocesar estos a fin de garantizar los resultados obtenidos. Para ello se procederá a centrar los datos y a blanquearlos (whitening):

- Centrado: El objetivo es tener un nuevo conjunto de datos cuyo vector de medias $E\{x\}$ sea igual a cero. De este modo los algoritmos a manejar posteriormente se verán simplificados en su desarrollo.
- Blanqueo o Whitening: Una vez centrados los datos, y antes de la aplicación ICA se transforma el vector de observaciones x linealmente para obtener un nuevo vector \tilde{x} que es blanco, es decir, sus componentes aparecen incorrelados y sus varianzas son iguales a la unidad, por tanto su matriz de covarianza resulta

igual a la unidad. La aplicación de esta etapa permite reducir el número de parámetros estimados en el proceso.

2.3.1.3 Algoritmos ICA

La solución ICA es abordada por numerosos tipos de algoritmos. Cardoso y Souloumiac (1993) proponen un método para el tratamiento de señales empleando un estadístico de primer orden denominado Joint Approximate Diagonalization of Eigenmatrices (en adelante JADE). Puntonet et al. (1995) proponen una solución basada en algoritmos geométricos, explotando las propiedades geométricas y algebraicas de las señales originales y las observaciones. Amari et al. (1996) presentan el algoritmo Infomax, trabajando con redes neuronales y la entropía. Hyvärinen y Oja (1997) presentan la primera versión del algoritmo FastICA, abriendo un nuevo campo del análisis de componentes independientes enfocado a problemas de mayor dimensionalidad. Todos estos algoritmos suelen basarse en una regla de aprendizaje iterativo, la cual tiene su base en una adaptación de la matriz de separación W . De entre todos ellos el presente estudio ha empleado los algoritmos FastICA y Jade.

FastICA, propuesto por Hyvärinen y Oja (1997), es uno de los algoritmos que con más éxito se han desarrollado para resolver el problema ICA, recibiendo su nombre por la rapidez con la que trabaja. Tal algoritmo busca componentes independientes basándose en conceptos como la estimación de la máxima verosimilitud, maximización de la no gaussianidad mediante la kurtosis, minimización de la información mutua, etc. Por otro lado el algoritmo de JADE está basado en el cálculo de estadísticos de alto orden y en la diagonalización de la descomposición de los autovalores de las mezclas.

2.3.2 Evaluación ICA frente a PCA

En primer lugar se ha analizado si la información registrada por un sensor genera unas bandas espectrales independientes o no. Para ello se ha determinado la pdf de cada banda así como la pdf conjunta entre ellas, evaluando si presentan un comportamiento normal y por tanto si estas son el resultado de la suma de distintas fuentes independientes. De este modo se ha verificado si se cumple las condiciones establecidas en 2.3.1.1. Una vez evaluada la dependencia entre bandas se procedió a analizar las posibles mejoras en los procesos de clasificación sobre imágenes una vez aplicado ICA sobre estas. Para ello se trató la imagen de trabajo mediante el algoritmo FastICA y JADE. Igualmente se aplicó PCA sobre dicha imagen. Tal acción generó distintos escenarios sobre los que se desarrolló todo el trabajo presentado (Figura 2-5):

- Set Original: Imagen original sin tratamiento.
- Set PCA: Escenario donde se ha desarrollado PCA sobre la imagen original
- Set FastICA: Generado a partir de la aplicación del algoritmo FastICA sobre la imagen.
- Set JADE: Resultante de aplicar el algoritmo JADE sobre dicha imagen.

Sobre cada uno de estos escenarios se ha realizado una clasificación no supervisada. Los resultados obtenidos con este operador serán evaluados mediante comparación visual para ver el comportamiento de este sobre cada escenario. Igualmente se desarrolló una clasificación supervisada mediante el algoritmo de máxima probabilidad sobre cada escenario. Se calculó la matriz de confusión, permitiendo determinar el porcentaje de acuerdo. Tal parámetro permitirá cuantificar las posibles mejoras de ICA sobre PCA. Estas clasificaciones se desarrollaron teniendo en cuenta distintos porcentajes de probabilidad. Tal condición origina la presencia de píxeles sin clasificar en la imagen siempre que este porcentaje sea inferior al 100%; permitiendo estudiar la relación entre el porcentaje de píxeles sin

clasificar en los distintos escenarios y el porcentaje de acuerdo obtenido en cada uno de ellos.

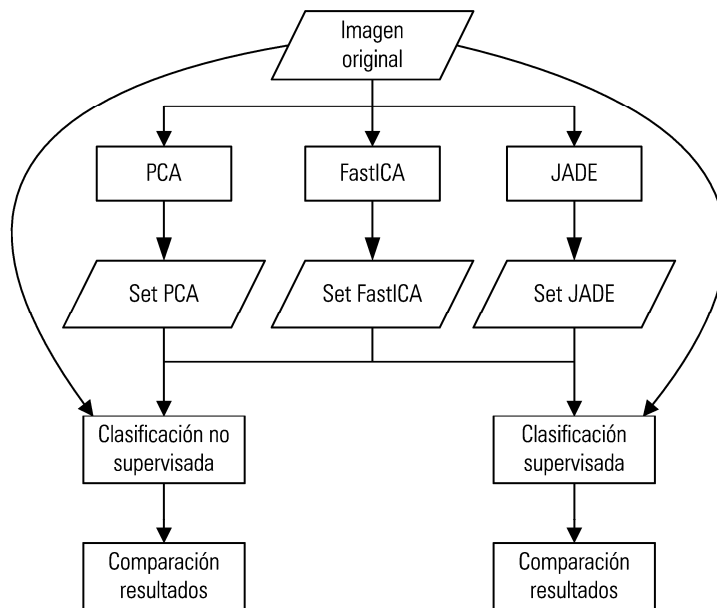


Figura 2-5 Esquema general metodología comparación PCA con técnicas ICA.

2.4 Resultados

2.4.1 Análisis de independencia

En primer lugar se evaluó si las bandas espectrales que componen la imagen IKONOS son o no independientes. Para ello se calcularon los momentos de cada una de las bandas. Con estos valores se determinó el producto de los momentos entre cada dos bandas. Paralelamente se determinó la pdf conjunta entre cada dos bandas para posteriormente calcular los momentos de esta. En el caso de ser las bandas independientes ambos productos serán iguales cumpliéndose lo establecido en 2.3.1. Los resultados obtenidos (Tabla 2-1) muestran como el resultado de los momentos de cada banda individualmente no es igual al momento de la pdf conjunta entre bandas. Tal aspecto queda claramente evidenciado al representar gráficamente la

pdf conjunta resultante entre dos bandas (Figura 2-6). Tal y como se observa en la representación 3D de la pdf conjunta, las superficies generadas presentan una forma próxima a una forma acampanada o gaussiana, lejos de superficies picudas con elevado valor de la variable kurtosis. Tal aspecto tiene su reflejo en la representación bidimensional de la distribución, apreciándose como a partir de un punto central de la distribución aparecen círculos concéntricos respecto de este punto.

A la vista de los resultados obtenidos se establece como las bandas generadas por el sensor IKONOS no son fuentes independientes, siendo por tanto útil el desarrollo de técnicas basadas en ICA para una mejor explotación de los datos.

Tabla 2-1 Comparación momentos bandas individuales y momentos función de densidad de probabilidad conjunta

Combinaciones de todas las bandas con la banda 1						
Momento	E[B1B2]	E[B1]E[B2]	E[B1B3]	E[B1]E[B3]	E[B1B4]	E[B1]E[B4]
1	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2	0,9992	0,9992	0,9992	0,9992	0,9992	0,9992
3	-0,0012	-0,0012	0,0018	0,0018	-0,0101	-0,0101
4	1,9793	0,5708	1,9081	0,5902	3,4565	0,1674
Combinaciones de todas las bandas con la banda 2						
Momento	E[B2B3]	E[B2]E[B3]	E[B2B4]	E[B2]E[B4]		
1	0,0000	0,0000	0,0000	0,0000		
2	0,9992	0,9992	0,9992	0,9992		
3	-0,0003	-0,0003	0,0015	0,0015		
4	1,4009	0,8136	2,7893	0,2307		
Combinaciones de todas las bandas con la banda 3						
Momento	E[B3B4]	E[B3]E[B4]				
1	0,0000	0,0000				
2	0,9992	0,9992				
3	-0,0021	-0,0021				
4	2,7066	0,2386				

Banda 1: B1; Banda 2: B2; Banda 3: B3; Banda 4: B4.
Siendo E igual al momento 1, 2, 3 o 4.

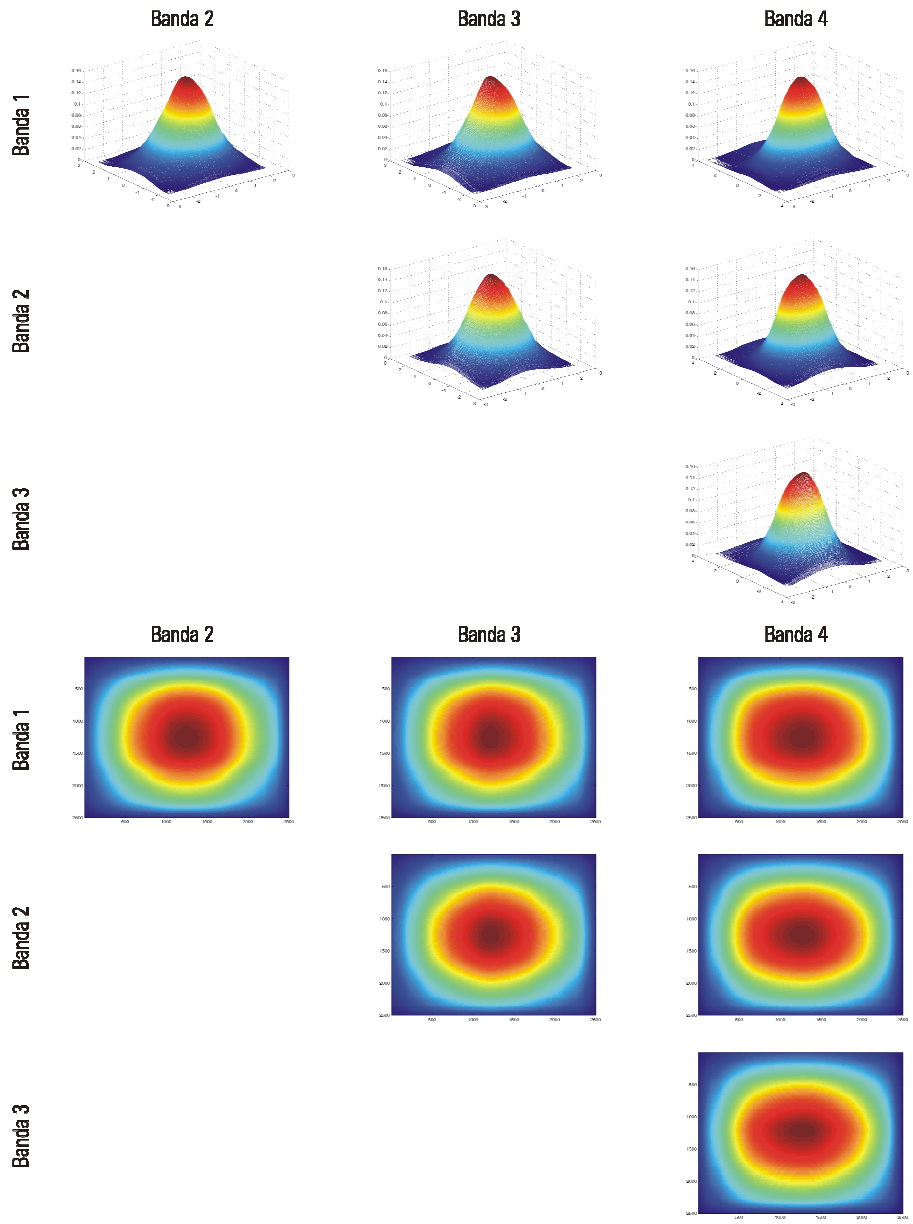


Figura 2-6 Función densidad de probabilidad conjunta bandas imagen sensor IKONOS.

Sobre las bandas de la imagen original se aplicaron PCA, FastICA y JADE (Figura 2-7). En el análisis PCA se empleó el software Envi 4.7. Para la aplicación de los algoritmos FastICA y JADE se ha empleado el paquete para Matlab "The FastICA package for Matlab" desarrollado por el Departamento de Información y Ciencias de la Computación de la Universidad de Aalto, Finlandia (ics.aalto.fi/en/). Para su uso fue necesario desarrollar las herramientas necesarias para la lectura y escritura de imágenes en formato Envi por parte del software de cálculo.

Observando la Figura 2-7 las bandas obtenidas mediante PCA aparecen ordenadas según la varianza de tal modo que la primera componente presentará el mayor valor de varianza, es decir, la mayor cantidad de información presente en la imagen. En el caso de las nuevas bandas obtenidas mediante FastICA y JADE no aparecen ordenadas como puede advertirse en dicha figura.

Mediante un análisis visual los distintos procesamientos desarrollados no presentan otra diferencia más que el orden en el que se presentan las bandas con más información. A consecuencia de esto se realizó una clasificación no supervisada y otra supervisada a fin de poder determinar la contribución de cada uno de los procesamientos en los procesos de clasificación respecto a los resultados obtenidos a partir de la imagen original.




Figura 2-7 Comparativa bandas originales sensor IKONOS y bandas obtenidas mediante procesamiento PCA, FastICA y JADE.

2.4.2 Clasificación no supervisada

Sobre la imagen original y las nuevas imágenes obtenidas de la aplicación de PCA, FastICA y JADE se realizó un clasificación no supervisada mediante el clasificador ISODATA. Como resultado de una primera inspección visual de la imagen se definieron cuatro clases como universo de discurso correspondientes a suelos desnudos, cultivos herbáceos, cultivos leñosos y cubierta vegetal.

La clasificación del set original (Figura 2-8.b) presentó cierta confusión a la hora de discriminar entre cultivos herbáceos y leñosos, acentuándose tal aspecto en el caso que el cultivo herbáceo estuviese en fase de senescencia más avanzada. Por otro lado la confusión entre suelos desnudos y suelos con cubierta vegetal fue grande, no pudiéndose diferenciar entre ambos usos adecuadamente. Puede verse como el suelo con cultivos leñosos aparece caracterizado por ambas clases de forma aleatoria como se aprecia en el caso de la parcela de olivar en la zona central de la (Figura 2-8.a). En el caso del Set PCA (Figura 2-8.c) las parcelas de cultivos herbáceos aparecieron mejor caracterizadas al reducirse su confusión con la clase cultivos leñosos independiente del estado fenológico del cultivo. Sin embargo en el caso de los suelos desnudos y con cubierta vegetal sigue presente la confusión, advirtiéndose como indistintamente sobre parcelas con suelo desnudo aparecen ambos tipos de usos, al igual que en el caso de parcelas con cubierta vegetal. En este caso puede verse como las parcelas presentan una fuerte presencia de la clase suelo desnudo. Sobre el escenario FastICA (Figura 2-8.d) el comportamiento del operador de clasificación ha sido más exacto. En el caso de las parcelas con cultivos herbáceos estas aparecen perfectamente caracterizadas, no presentando píxeles pertenecientes a la clase cultivos leñosos. Igualmente estos cultivos aparecen mejor representados. Los suelos con cubierta vegetal aparecen bien definidos, permitiendo distinguir de forma amigable y sencilla entre píxeles correspondientes a las copas de cultivos leñosos de los pertenecientes a la cubierta vegetal. Las parcelas con suelo desnudo aparecen caracterizadas por una gran mayoría de píxeles pertenecientes a esta clase, mejorando los resultados respecto a los obtenidos en los dos escenarios anteriores. Por último en el caso del Set JADE (Figura 2-8.e) los resultados siguen el mismo patrón de comportamiento que el set FastICA.

Mediante operadores de clasificación no supervisada, los resultados obtenidos en clasificaciones no supervisadas sobre imágenes preprocesadas mediante técnicas ICA resultaron más exactos que los obtenidos mediante análisis PCA o la propia imagen sin tratamiento alguno.

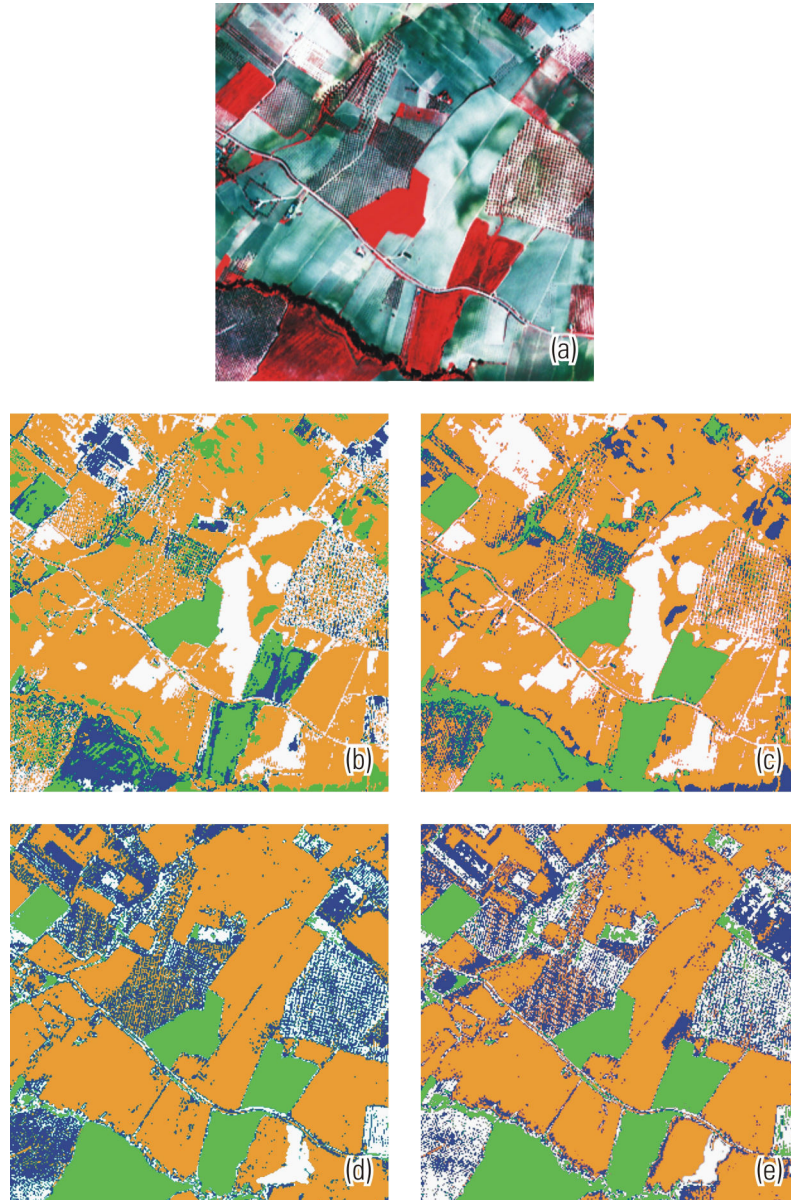


Figura 2-8 Comparativa resultados clasificación no supervisada ISODATA sobre imagen IKONOS (a): (b) imagen original, (c) imagen con tratamiento PCA, (d) imagen con tratamiento FastICA y (e) imagen con tratamiento JADE.

2.4.3 Clasificación supervisada

Una vez evaluada la presencia de diferencias en los resultados del operador de clasificación no supervisado se procedió sobre cada uno de los escenarios definidos en el presente trabajo a clasificarlos mediante el operador máxima probabilidad teniendo en cuenta para ello distintos porcentajes de probabilidad de pertenencia a una clase. Los porcentajes empleados se correspondieron con 100, 99, 95 y 90. El valor igual a 100% implica asignar un píxel a una clase de entre todas las definidas por el analista, no apareciendo por tanto píxeles sin clasificar. En el momento en que este valor sea distinto del 100% el píxel no tiene porque ser forzosamente asignado a una clase, apareciendo por tanto píxeles sin clasificar en la escena. El propósito de emplear clasificadores supervisados fue poder determinar numéricamente si procedimientos ICA mejoran la caracterización de usos de suelo.

La Figura 2-9 representa los porcentajes de acuerdo obtenidos en cada escenario. Teniendo en cuenta un umbral del 100% en la clasificación los escenarios correspondientes al Set original y Set PCA presentaron los peores resultados frente a los escenarios donde se aplicó alguna técnica ICA, encontrándose las diferencias en torno al 1.75%. Estas diferencias aumentaron considerablemente en cuanto se rebajó el porcentaje de probabilidad de pertenencia a una clase. De nuevo se establecieron dos tendencias bien definidas. La primera de ellas de nuevo recoge a los escenarios Set Original y Set PCA, ambos presentan un porcentaje de acuerdo (en adelante P_a) medio del 48% teniendo en cuenta las probabilidades del 90, 95 y 99%. Por otro lado los escenarios Set FastICA y Set JADE presentan un P_a medio igual a 65%. Ambas tendencias mantienen prácticamente constante el valor de P_a independientemente de la probabilidad empleada.

Analizando los resultados de P_a obtenidos en los distintos escenarios con el porcentaje de píxeles sin clasificar de estos (Figura 2-10) puede observarse como ambos aparecen relacionados. De este modo los escenarios Set Original y Set PCA presentan un porcentaje elevado de píxeles sin clasificar, próximo al 50% mientras que Set FastICA y Set JADE presenta valores medios iguales al 23%.

De este modo las mejoras en cuanto a P_a obtenidos en las clasificaciones de los escenarios donde se aplicó algún algoritmo de análisis ICA frente al análisis PCA, o simplemente la imagen sin tratamiento, se deben a que el clasificador es capaz de asignar más píxeles a una de las clases definidas por el operador, siendo realizada tal asignación además de forma correcta.




Figura 2-9 Comparativa porcentaje máxima probabilidad clasificación supervisada operador máxima probabilidad.




Figura 2-10 Comparativa porcentaje pixel sin clasificar clasificación supervisada operador máxima probabilidad.

2.5 Conclusión

En el presente capítulo se ha presentado el fundamento de las técnicas ICA, planteándolas como un posible alternativa de pre-proceso de la información al igual que se realiza con técnicas más populares en el campo de la Teledetección como PCA. En un primer momento se ha podido comprobar cómo las bandas de un sensor multiespectral como IKONOS no son independientes, por tanto es posible aplicar este tipo de técnicas.

El estudio de la validez de estas técnicas se ha llevado a cabo mediante la realización de clasificaciones sobre la imagen IKONOS en distintos escenarios. Los resultados muestran como tanto operadores no supervisados como supervisados mejoran sus resultados en el caso de la aplicación de ICA. En el caso de los operadores no supervisados, es posible una identificación más exacta de los fenómenos presentes en la imagen. En el caso de los operadores supervisados se pone de manifiesto que cuando se utiliza el operador máxima probabilidad se obtienen mejores resultados al aplicar técnicas ICA frente a PCA o simplemente la imagen original. Tales diferencias aumentan en cuanto se permite al algoritmo dejar píxeles sin clasificar. En tales circunstancia en los escenarios donde se ha aplicado ICA se han caracterizado mas píxeles y de una manera adecuada frente a los otros escenarios.

En el presente capítulo se ha aplicado las técnicas ICA a la información obtenida por un único sensor. Sin embargo hoy día es posible encontrar numerosos conjuntos de datos a modo de imágenes de un territorio adquirido por distintos sensores en distintos momentos. Además de operaciones más estandarizadas de detección de cambios donde se trabaja generalmente con información procedente del mismo sensor, es posible combinar información procedente de distintos sensores. Dada la gran cantidad de información a la que se puede acceder hoy día, es posible que el usuario maneje información procedente de sensores diferentes pero con regiones espectrales comunes. Las técnicas mostradas en el presente capítulo constituyen un marco de trabajo alternativo a metodologías clásicas basadas en PCA. En el **Capítulo 5** de la Tesis se aplicarán estas técnicas en la combinación de información espectral

recogida por una cámara digital y la intensidad LiDAR. En el caso de la información registrada por la cámara las bandas espectrales se corresponden con Rojo, Verde e Infrarrojo Cercano. En el caso del sensor LiDAR la intensidad se registra en valores de longitud de onda del Infrarrojo Cercano. En un primer momento la información es redundante al registrar datos en la misma región del espectro electromagnético en el mismo instante de tiempo. La aplicación de técnicas ICA frente a otros procesos proporcionan un conjunto de herramientas que ayudan a una mejor explotación de la información.

2.6 Referencias

Akhtar, M.T., Mitsuhashi, W., James, C.J., 2012. Employing spatially constrained ICA and wavelet denoising, for automatic removal of artifacts from multichannel EEG data. *Signal processing* 92, 401-416.

Amari, S., Cichocki, A., Yang, H.H., 1996. A new learning algorithm for blind signal separation. *Advances in neural information processing systems* 8, 757-763.

Calhoun, V.D., Adali, T., Stevens, M.C., Kiehl, K.A., Pekar, J.J., 2005. Semi-blind ICA of fMRI: A method for utilizing hypothesis-derived time courses in a spatial ICA analysis. *NeuroImage* 25, 527-538.

Cardoso, J.F., Soudoukiac, A., 1993. Blind beamforming for non-Gaussian signals, *Radar and Signal Processing, IEEE Proceedings*, 362-370.

Chuvieco, E., 1998. El factor temporal en teledetección: Evolución fenomenológica y análisis de cambio. *Revista de Teledetección* 10, 39-48.

Comon, P., 1994. Independent component analysis, a new concept? *Signal processing* 36, 287-314.

Du, Q., Kopriva, I., Szu, H., 2004. Independent component analysis for classifying multispectral images with dimensionality limitation. *International Journal of Information Acquisition* 1, 201-216.

Farah, I.R., Ahmed, M.B., 2002. Satellite image analysis based on the method of blind separation of sources for the extraction of information, *Geoscience and Remote Sensing Symposium, 2002. IGARSS '02. 2002 IEEE International IEEE*, 919-921.

He, H., Zhang, T., Yu, X.C., Peng, W., 2006. Application of fast independent component analysis on extracting the information of remote sensing imagery, *Proceedings of the Fifth International Conference on Machine Learning and Cybernetics*,. IEEE, Dalian, 1066-1071.

Hérault, J., Jutten, C., Ans, B., 1985. Détection de grandeurs primitives dans un message composite par une architecture de calcul neuromimétique en apprentissage non supervisé. *GRETSI, Groupe d'Etudes du Traitement du Signal et des Images*, 1017-1022.

Hyvärinen, A., Oja, E., 1997. A fast fixed-point algorithm for independent component analysis. *Neural computation* 9, 1483-1492.

Karoui, M., Deville, Y., Hosseini, S., Ouamri, A., Ducrot, D., 2009. Improvement of remote sensing multispectral image classification by using independent component analysis, *Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2009. WHISPERS '09. First Workshop on IEEE, Grenoble*, 1-4.

Karvonen, J., Similä, M., 2003. ICA-Based Classification of Sea Ice SAR Images, *Remote Sensing in Transition*, 211-217.

Kinnunen, T., Li, H., 2010. An overview of text-independent speaker recognition: From features to supervectors. *Speech Communication* 52, 12-40.

Kwon, O.-W., Lee, T.-W., 2004. Phoneme recognition using ICA-based feature extraction and transformation. *Signal processing* 84, 1005-1019.

Lizieri, C., Satchell, S., Zhang, Q., 2007. The Underlying Return-Generating Factors for REIT Returns: An Application of Independent Component Analysis. *Real Estate Economics* 35, 569-598.

Ma, L., Wang, B., Chen, X., Xiong, J., 2007. Detecting functional connectivity in the resting brain: a comparison between ICA and CCA. *Magnetic Resonance Imaging* 25, 47-56.

Nascimento, J.M.P., Dias, J.M.B., 2005. Does independent component analysis play a role in unmixing hyperspectral data? *Geoscience and Remote Sensing, IEEE Transactions on* 43, 175-187.

Puntonet, C., Prieto, A., Jutten, C., Rodriguez-Alvarez, M., Ortega, J., 1995. Separation of sources: a geometry-based procedure for reconstruction of n-valued signals. *Signal processing* 46, 267-284.

Sui, J., Adali, T., Pearlson, G.D., Calhoun, V.D., 2009. An ICA-based method for the identification of optimal fMRI features and components using combined group-discriminative techniques. *NeuroImage* 46, 73-86.

Vermorken, M., Szafarz, A., Pirotte, H., 2010. Sector classification through non-Gaussian similarity. *Applied Financial Economics* 20, 861-878.

Wang, J., Chang, C.I., 2006a. Applications of independent component analysis in endmember extraction and abundance quantification for hyperspectral imagery. *Geoscience and Remote Sensing, IEEE Transactions on* 44, 2601-2616.

Wang, J., Chang, C.I., 2006b. Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis. *Geoscience and Remote Sensing, IEEE Transactions on* 44, 1586-1600.

Zhang, J., Chen, Y.W., Nakao, Z., Tateyama, T., 2006. Independent component analysis for classification of remotely sensed images *International Journal of Innovative Computing, Information and Control* 2, 659-666.

Zuo, M.J., Lin, J., Fan, X., 2005. Feature separation using ICA for a one-dimensional time series and its application in fault detection. *Journal of Sound and Vibration* 287, 614-624.

Capítulo 3

Introducción de la curva de respuesta espectral relativa en los procesos de clasificación

Resumen: Muchos sensores presentan sus bandas solapadas de manera que no establecen un espacio normal tal y como se puede pensar en un primer momento. Si una distancia espectral es medida en el caso de un clasificador de estadística de primer orden, la consecuencia directa será que el resultado de tal medición no será exacto. En este sentido se advierte como los procesos de clasificación de imágenes son independientes de la respuesta espectral relativa del sensor empleado. Es posible afirmar que el solapamiento espectral entre bandas es ignorado durante el procesamiento de la imagen. En este capítulo se presentan una metodología que introduce la respuesta espectral relativa de un sensor en los procesos de clasificación con el objetivo de mejorar los resultados. Tal proceso es llevado a cabo en dos etapas: en primer lugar se reconstruyen los valores de energía incidentes en el sensor y en una segunda etapa la energía de cada banda es trasladada a un espacio ortonormal mediante el empleo de la descomposición de matrices a valores singulares. El proceso completo se ha implementado sobre tres tipos de sensores con resolución

espacial media, alta y muy alta: ASTER, IKONOS y la cámara DMC respectivamente. Las imágenes registradas por estos sensores han sido clasificadas empleando los clasificadores ISODATA y Mínima Distancia. El clasificador ISODATA mostró elementos y objetos bien definidos en las imágenes procesadas con la metodología propuesta. Al mismo tiempo, el clasificador Mínima Distancia mejoró el porcentaje de acuerdo y el coeficiente Kappa en las clasificaciones sobre las imágenes procesadas frente a las imágenes originales.

Palabras clave: Solape espectral entre bandas, ISODATA, Mínima Distancia, Respuesta espectral relativa.

3.1 Introducción

Un sistema de reconocimiento de patrones destinado al estudio de recursos y fenómenos terrestres en el campo de la Teledetección esta formado de tres componentes (Figura 3-1): escena, sensor y procesos (Wiersma y Landgrebe 1980). La escena se corresponde con la porción de superficie terrestre observada por el sensor. Tal sensor detecta y registra la radiación electromagnética que es reflejada o emitida desde la superficie terrestre, siendo esta empleada para detectar fenómenos (Bailey et al. 2001). La función de respuesta espectral relativa (en adelante RSR) de un sensor electro-óptico describe la respuesta para cada longitud de onda para la señal de salida del sensor por unidad de flujo incidente (Schott 1997). Por último, los procesos consisten en el tratamiento de los datos recogidos, generalmente en un entorno digital mediante la implementación de algoritmos con fines variados y diversos tales como clasificación, fusión o detección de cambios.

Un sensor tiene una o varias bandas espectrales. Cada una de estas bandas por lo general la describimos de forma generalizada mediante una anchura dentro del espectro electromagnético y la longitud de onda donde se produce el mayor valor de respuesta (Liang 2004). Tal descripción por si sola puede resultar engañosa. Las posibles variaciones en la RSR de un sensor dentro de cada banda pueden tener un efecto significativo sobre los datos medidos y los valores derivados de métricas

incluso cuando los valores del ancho de banda y de longitud de onda central sean similares, por tanto, su uso en ocasiones puede resultar ser no apropiado (Liang 2004). En este contexto, se puede establecer que el efecto de la RSR no se ha considerado de forma adecuada en algunos tratamientos realizados sobre imágenes (Trishchenko et al. 2002).

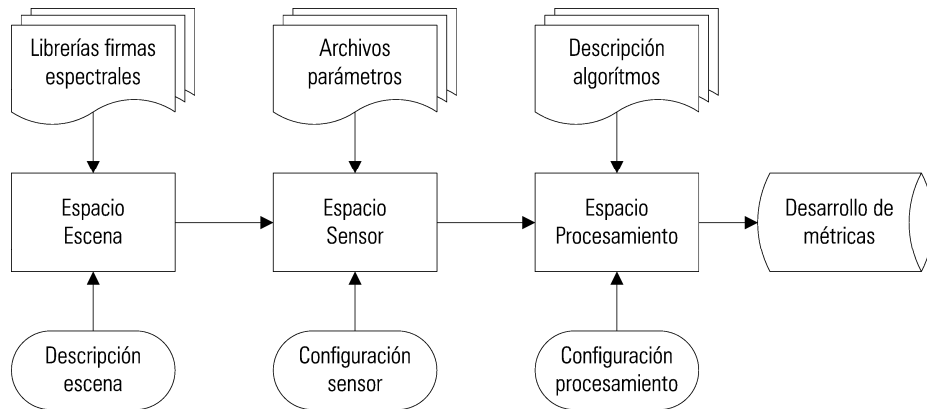


Figura 3-1 Diagrama de bloque de un sistema de reconocimiento de patrones.

Con carácter general, el primer análisis que se realiza en torno a las características o propiedades de un sensor se ubica en un contexto geométrico. El objetivo de un sensor es caracterizar lo que se encuentra en el interior de cada uno de los píxeles que componen una imagen. Aparecen dos fuentes de redundancia espectral en la información registrada en este proceso. El primero de ellos se debe al sobremuestreo de la escena; aunque los fenómenos aparecen registrados por muchas bandas espectrales, a priori solo con unas pocas de estas sería suficiente para poder ser caracterizados. La segunda fuente de redundancia es debida al solapamiento de estas bandas dentro del espectro electromagnético. De este modo, algunas de las bandas del sensor recogen datos pertenecientes al mismo intervalo de longitud de onda. El primero de los problemas planteados puede resolverse mediante la aplicación de procesos enfocados hacia la reducción de la dimensionalidad de los datos. Una gran variedad de métodos han sido desarrollados en este sentido como "projection pursuit" (Jimenez y Landgrebe 1999), análisis de componentes principales (Farrel 2005) o la transformación "wavelet" (Kaewpijit et al. 2003). En cuanto a la segunda fuente de redundancia, tal efecto es ignorado, probablemente debido a que la cantidad de solapamiento entre bandas es con frecuencia pequeño.

Por otra parte, el poder obtener clasificaciones con valores aceptables de exactitud en el caso de imágenes de media, alta o muy alta resolución espacial en ocasiones resulta difícil de lograr (Foody 2002). Tales tareas de clasificación son difíciles por diversos motivos como variaciones atmosféricas, incertidumbre en la información empleada como entrenamiento e incluso una incorrecta elección del algoritmo de clasificación (Congalton 1991). En esta sentido, cualquier mejora en los procesos de clasificación es siempre importante. Para resolver estos inconvenientes, muchos investigadores han realizado grandes esfuerzos para desarrollar y diseñar algoritmos destinados a la clasificación de imágenes (Tso y Mather 2001). Pese a ello, ninguno de ellos tiene en cuenta la RSR del sensor que captura la imagen. La gran cantidad de algoritmos de clasificación desarrollados pueden agruparse según diferentes criterios por ejemplo supervisados o no supervisados o paramétricos y no paramétricos. Los algoritmos paramétricos son aquellos que están basados en la medida de una distancia definida sobre un espacio. Tal distancia puede ser la distancia Euclídea, empleada por el clasificador supervisado Mínima Distancia (en adelante MD) o el clasificador no supervisado Iterative Self-Organizing Data Analysis (en adelante ISODATA) (Sohn y Rebello 2002) o la distancia de Mahalanobis, empleada por el clasificador supervisado de Máxima Probabilidad (en adelante MLC) (Carr 1996). En el caso de los primeros hay que tener en cuenta que si estas bandas aparecen solapadas espectralmente hablando, el espacio generado no es ortogonal y por tanto la distancia Euclídea medida no es correcta. De esta manera se advierte como la base del clasificador no aparece bien establecida. El presente trabajo presenta una metodología basada completamente en clasificadores de primer orden para reducir los efectos del solapamiento espectral entre bandas. Clasificadores basados en estadísticas de segundo orden como puede ser MLC no se ven afectados y sus resultados no aparecen alterados debido a que son invariantes a las transformaciones propuestas en la presente metodología.

Muchos estudios han empleado clasificadores basados en estadística de primer orden con objetivos muy variados. El clasificador ISODATA es empleado generalmente como una clasificación preliminar (Goetz et al. 2003; Walsh et al. 2008), aunque también puede ser empleado como un clasificador final como MD o MLC. Ramesh y Scott (2010) usan el clasificador ISODATA para discriminar cuerpos

de agua, (Hiroyuki et al. 2010) lo emplean para medir la estructura espacial de zonas urbanas mientras que (Llopis et al. 2007) identifican patrones de riego.

El objetivo de este estudio es:

- Analizar la influencia de la RSR de un sensor en el uso de clasificadores de primer orden estadístico al clasificar imágenes.
- Desarrollar una metodología para incluir la RSR en los procesos de clasificación, minimizando su influencia.

Para ello se han empleado tres sensores: ASTER, IKONOS y la cámara métrica DMC. Si bien presentan arquitecturas y resoluciones bien diferentes presentan como característica común el tener solapamiento espectral en sus bandas.

3.1.1 Operadores de clasificación

Probablemente dentro del análisis de imágenes, los procesos de clasificación de la imagen suponen el último paso de los trabajos. El resultado de esta fase consiste en la transformación de una imagen numérica en una imagen descriptiva donde quedan categorizados diferentes superficies, materiales y/o condiciones. Por tanto se pasará de una imagen constituida por n bandas a una imagen de una banda, con las mismas dimensiones y resolución espacial que la original, donde la información de partida ha quedado categorizada en un conjunto de clases c . Los algoritmos de clasificación desarrollados pueden ser agrupados según distintos criterios:

- Clasificador supervisado / no supervisado: En el primero de los casos el operador de clasificación cuenta con información previa de las distintas clases presentes en la escena a partir de unas aéreas de entrenamiento definidas por el analista. En el caso de ser un proceso no supervisado es el propio algoritmo el encargado de agrupar los píxeles en grupos homogéneos sin contar con información a priori de las distintas clases presentes en la imagen.

- Clasificadores paramétricos / no paramétricos: Los algoritmos paramétricos asumen una distribución estadística de la información, por ejemplo la distribución normal, empleando estimaciones de los parámetros de tal distribución como pueden ser la media y la matriz de covarianza. En el otro sentido, los algoritmos no paramétricos no asumen distribución alguna.
- Clasificación a nivel de píxel / orientada a objetos: En el primero de los casos la técnica empleada hace que el operador de clasificación trabaje con la información de cada píxel como unidad de información. En el segundo caso, dado que los fenómenos representados en una imagen son continuos la información recogida en un píxel no es suficiente para caracterizar una clase, necesitando de la evaluación y análisis de las relaciones de un píxel con los colindantes.

De entre todos los posibles operadores de clasificación desarrollados el presente trabajo se ha centrado en dos de ellos: mínima distancia e ISODATA. De este modo se ha trabajado con un clasificador supervisado y otro no supervisado. Ambos operadores son de tipo paramétrico y basados en el análisis a nivel de píxel individual. Los clasificadores de tipo paramétrico utilizan algún tipo de medida a la hora de caracterizar cada uno de los píxeles, media y desviación. En un primer momento se establece la necesidad de definir una medida de distancia. Tal distancia ha de ser entendida en un sentido amplio y no centrándose en un contexto métrico, por tanto hay que entenderla como similaridad. De este modo el operador clasifica un píxel a la clase más similar de entre todas las posibles. La filosofía del clasificador es fácil de interpretar, a mayor distancia entre un píxel y el conjunto de píxeles que definen una clase menor es la posibilidad de pertenecer a esa clase. La distancia será calculada en un espacio n-dimensional. Matemáticamente queda definidos distintos tipos de distancias como la distancia de Mahalanobis, Euclídea y Manhattan.

El operador de clasificación MD trabaja con la distancia Euclídea. Dicho operador determina la distancia Euclídea de cada uno de los píxeles de la imagen con el resto de las clases asignándolo a la clase más cercana (Figura 3-2.a). Tal proceso en la determinación sería válido si las bandas que componen el sensor son independientes, generando un espacio ortogonal. En el caso de que estas bandas estuvieran solapas

no estarían formando tal espacio ortogonal, el cálculo de forma directa de la distancia Euclídea (Figura 3-2.b) a partir de los datos almacenados en un píxel y los valores característicos de la clases no sería adecuado. Se hace necesario por tanto tener en cuenta tal condición a la hora de afrontar un proceso de clasificación basado en este tipo de distancias.




Figura 3-2 Relación entre las bandas de un sensor y el cálculo de la distancia Euclídea: (a) bandas no solapadas, (b) bandas solapadas.

3.1.2 Análisis de sensores

Con carácter general, en el tratamiento y explotación de los datos procedentes de un sensor aéreo o espacial no se tiene en cuenta el comportamiento y la naturaleza de las propias características internas del sensor a nivel espectral de tal modo que el usuario evalúa el número de bandas, ancho espectral y/o la resolución radiométrica sin analizar la posible interacción de unas bandas con otras. Analizando con detenimiento la matriz de RSR de un sensor quedaría patente como la consecuencia directa es que un rango del espectro electromagnético es registrado por más de una banda espectral apareciendo por tanto información redundante. Como ejemplo el sensor MODIS; con una resolución radiométrica de 12-bits, tiene una resolución espectral igual a 36. Si se observa la RSR de algunas de las bandas de dicho sensor (Figura 3-3) se puede ver como una misma región del espectro electromagnético es registrado por más de dos bandas, suponiendo esto una importante redundancia de información.

Tal comportamiento es común y generalizado al resto de sensores. A la vista de la evolución en el diseño y puesta en valor de algunos de los programas con gran tradición en el campo de la Teledetección se advierte que tal aspecto no ha pasado inadvertido. La Figura 3-4 representa la RSR de las tres primeras bandas del sensor Landsat a lo largo de sus distintas misiones (Landsat 7 Science data users handbook). Puede observarse como las tres primeras bandas a lo largo de las distintas misiones han ido presentando un ancho de banda cada vez más estrecho y ajustado a las especificaciones técnicas que se ofrecen al usuario. La banda dos presentaba las longitudes de onda correspondientes a los extremos de la banda compartidos por las bandas una y tres en las misiones cuatro y cinco (Figura 3-4.a y Figura 3-4.b). Tal solapamiento se ve drásticamente reducido en la misión siete (Figura 3-4.c). Tal evolución a lo largo del tiempo ocurre en todas las bandas del sensor Landsat. Realizando una comparativa banda a banda (Figura 3-5) se observa como las curvas de las bandas correspondientes a la misión siete se van estrechando, reduciendo al menos uno de los extremos de la banda. Este efecto de forma encadenada da lugar a que las bandas tengan menos redundancia de información al presentar menos solape espectral entre ellas, estando más cerca de generar un espacio ortogonal.




Figura 3-3 RSR sensor MODIS. Banda 1 a 10

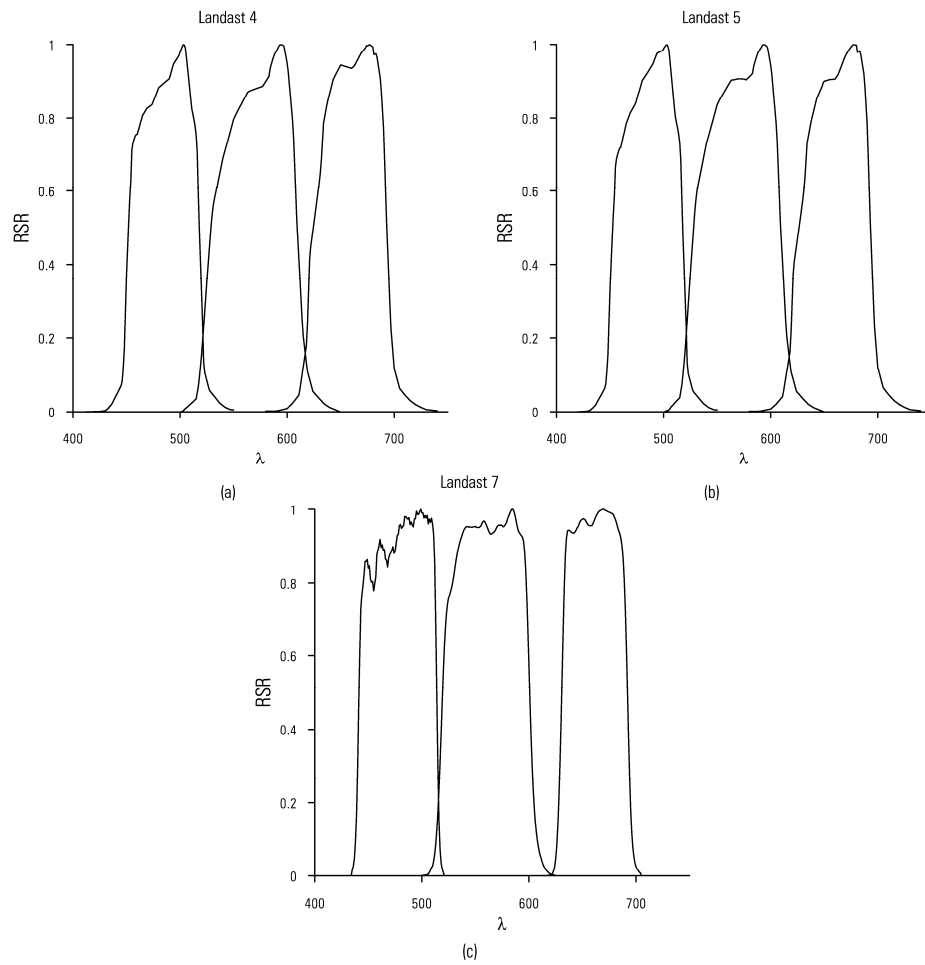
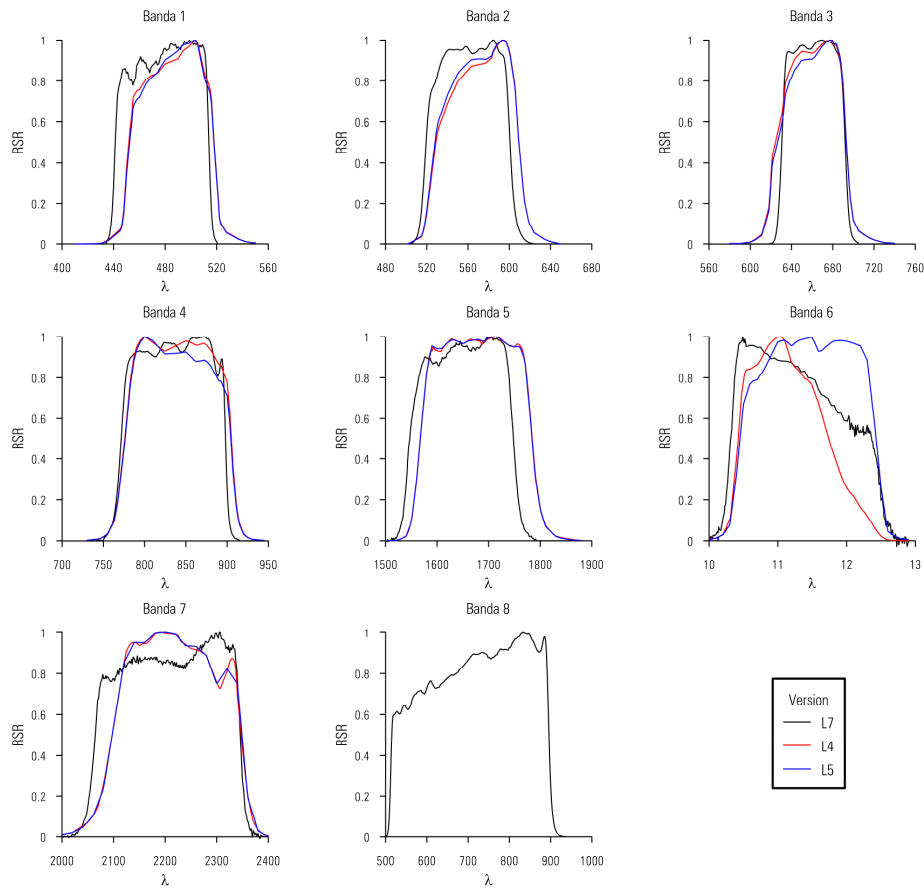


Figura 3-4 Comparativa evolución RSR sensor Landsat correspondientes a las bandas del espectro visible.



3.2 Materiales y métodos

3.2.1 Sensores

Para el desarrollo del presente trabajo se han empleado tres sensores de características y arquitecturas diferentes pero con la particularidad de que todos ellos presentan sus bandas en mayor o menor medida solapadas: ASTER, IKONOS y la cámara DMC, siendo sus resoluciones espaciales media, alta y muy alta respectivamente.

3.2.1.1 Advanced Spaceborne Thermal Emission and Reflection Radiometer: ASTER

El sensor multiespectral Advanced Spaceborne Thermal Emission and Reflection Radiometer (en adelante ASTER) es el resultado de la cooperación del Sistema de Observación de la Tierra de la NASA (EEUU), del Ministerio de Economía, Comercio e Industria de Japón y del Centro de Análisis de Datos de Teledetección de Japón. Lanzado en Diciembre de 1999, cubre una amplia región espectral desde la región del espectro visible hasta la región del infrarrojo térmico. Presenta una resolución espectral igual a 14 bandas con una resolución espacial variable en función de longitud de onda consecuencia de la propia arquitectura del sistema. ASTER tiene tres subsistemas diferentes compuestos por sus propios objetivos, cada uno de ellos con distintas resoluciones (Abrams et al. 2003) (Tabla 3-1). Observando las curvas de RSR publicadas por ASTER Science Project (Figura 3-6) se puede ver como las bandas contenidas en los subsistemas SWIR (Figura 3-6.b) y TIR (Figura 3-6.c) aparecen solapadas de forma muy acusada y en menor medida el subsistema VNIR (Figura 3-6.a).

Tabla 3-1 Características subsistemas ASTER

Subsistema	Resolución espacial	Resolución espectral	Región espectro
VNIR	15 m.	3 bandas	Visible – IR próximo
SWIR	30 m.	6 bandas	Infrarrojo de onda corta
TIR	90 m.	5 bandas	Infrarrojo térmico

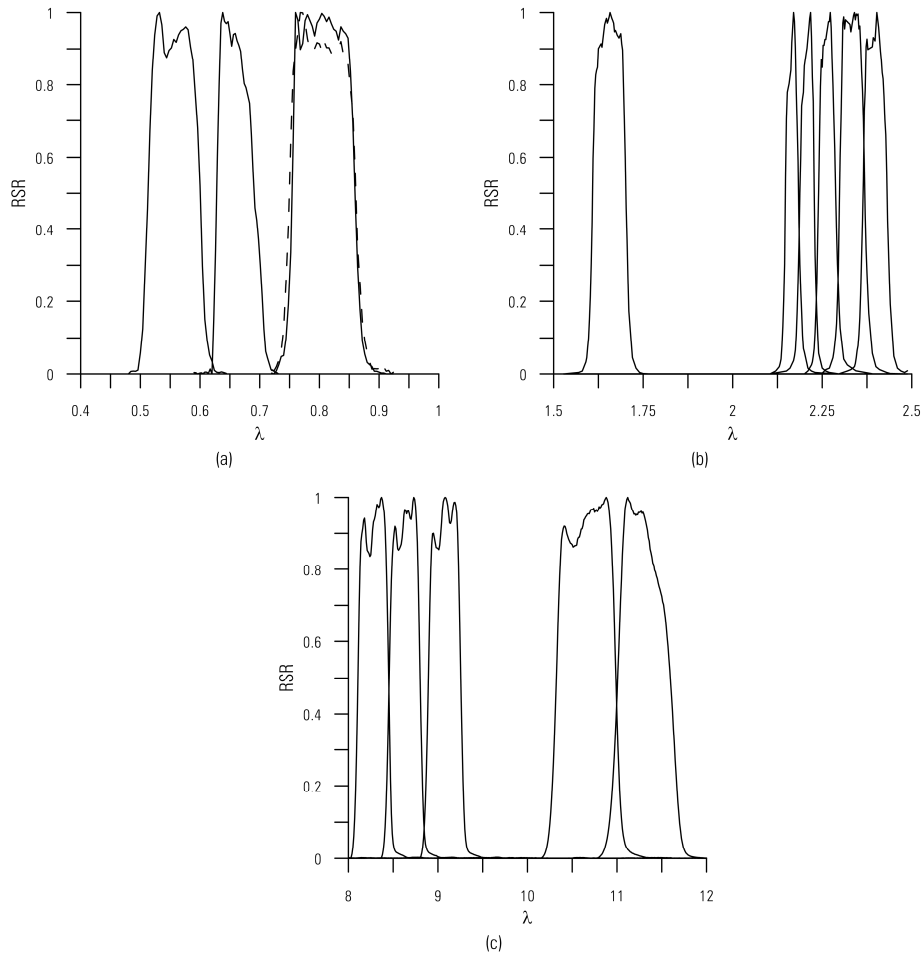


Figura 3-6 Subsistemas ASTER: (a) VNIR, (b) SWIR y (c) TIR.

A consecuencia de su resolución espectral, la información recogida por ASTER es empleada con fines muy variados como agricultura, vulcanología, mineralogía o forestal. Desde un punto de vista agronómico es posible determinar índices de estrés hídrico (Galleguillos et al. 2011; Sepulcre-Cantó et al. 2007), índices de degradación de suelos (Chikhaoui et al. 2005) o índices de vegetación empleados en la evaluación de riesgos de incendios (Falkowski et al. 2005) o para estudiar la emisividad de superficies agrícolas (Jimenez-Muñoz et al. 2006). En el campo de la geología, la información recogida por el sensor es empleada para la confección de mapas de suelos (Hubbard y Crowley 2005; Vicente y de Souza 2011), estudios de alteración de minerales (Pour y Hashim 2012; Zhang et al. 2007). La capacidad que tiene dicho

sensor de registrar imágenes estereoscópicas es empleada en estudios de vulcanología (Carter et al. 2008; Pieri y Abrams 2004; Stevens et al. 2004), o el seguimiento y control de los efectos de las mareas en zonas costeras (John 2005).

3.2.1.2 Sensor IKONOS

Lanzado el 24 de Septiembre de 1999 el objetivo de la plataforma es registrar de manera global imágenes precisas y de alta resolución espacial para ser empleadas por la comunidad científica, gobiernos y empresas para el control, seguimiento y cartografiado de fenómenos naturales o producidos por el hombre (Dial y Grodecki 2003). Con su puesta en órbita comenzó una nueva línea de negocio siendo este el primer satélite comercial. El sensor en modo pancromático registra imágenes con una resolución espacial de 0.82 m sobre el nadir mientras que el sensor multiespectral presenta 3.28 m de tamaño de píxel (Dial et al. 2003). Las imágenes en modo multiespectral tienen una resolución espectral igual a 4, siendo las bandas las correspondientes al azul (445-514 nm), verde (506-595 nm), rojo (632-698 nm) e infrarrojo próximo (757-853 nm).

La RSR del sensor (Geoye 2012), Figura 3-7, se determinó mediante observaciones en laboratorio, determinando la relación entre la respuesta del telescopio y del plano focal. La respuesta del espectro del telescopio se determinó empíricamente a partir de medidas de reflectividad espectral sobre distintas muestras de espejos. Las medidas sobre el plano focal incluyeron tanto los filtros espectrales como los detectores. La respuesta espectral en este caso se determinó mediante medidas de laboratorio (Cook et al. 2001). Tal y como se puede observar en la Figura 3-7 las bandas en modo espectral aparecen solapadas, siendo de forma muy acusada entre los canales azules y verde.

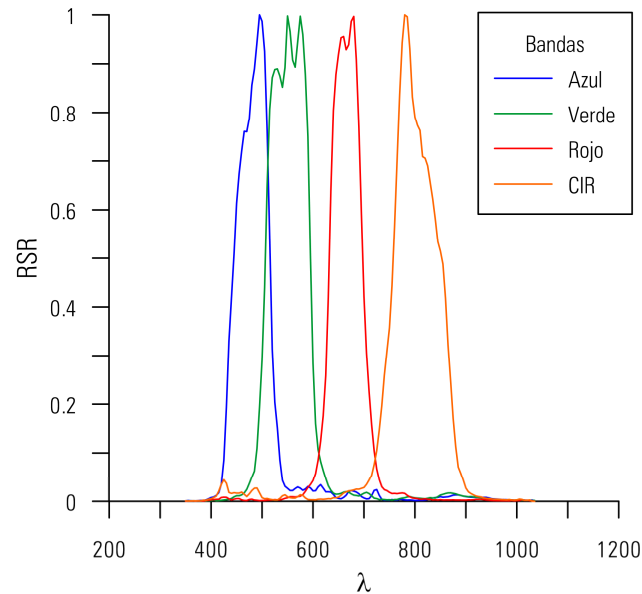


Figura 3-7 RSR de las bandas en modo multispectral del sensor IKONOS.

Al igual que el sensor ASTER, el sistema fue diseñado para permitir tener visión estereoscópica. Tal característica junto a su alta resolución espacial incrementan las funcionalidades y explotación de la información registrada, permitiendo la generación de imágenes ortorectificadas o modelos digitales de elevaciones (Dial et al. 2003). La aplicación de metodologías y flujos de trabajo fotogramétricos son aplicados con éxito en la obtención de productos cartográficos. Es posible generar Modelos Digitales de Superficies (en adelante DSM) mediante la aplicación de procesos de matching (Zhang y Gruen 2006), alcanzando valores de exactitud cercanos al metro en zonas despejadas y de 2 a 3 metros en zonas forestales. Además la producción de ortofotos con resolución espacial igual a 1 metro mediante la combinación de imágenes procedentes de IKONOS y Modelos Digitales de Elevaciones (en adelante DEM) generados mediante sensores LiDAR es una opción válida para la confección de bases cartográficas a escala 1:5.000 (Elaksher 2009).

Desde un punto de vista de gestión del espacio natural este sensor ofrece un marco ideal de trabajo y de desarrollo de utilidades. La aplicación de modelos hidrológicos, estudios de erosión, toma de decisiones o la detección de cambios entre otros son aplicaciones desarrolladas con éxito mediante la explotación de este

tipo de imágenes, conformando una alternativa apropiada dada la relación coste beneficio. Goetz et al. (2003) y Song et al. (2010) miden copas de árboles individuales con el objetivo de estimar modelos de tamaño de copa los cuales son aplicados para el análisis y estudio de procesos biofísicos en masas forestales. La realización de clasificaciones de imágenes empleando distintos tipos de técnicas, operadores y clasificadores permiten obtener mapas de usos de suelo (Agüera y Liu 2009; Dikshit y Behl 2009; Fiorentino et al. 2011). Con un enfoque de planificación y control urbanístico del territorio es posible la detección de cambios a nivel de edificaciones gracias a su alta resolución espacial, alimentando y manteniendo actualizadas bases de datos geográficas (Bouziani et al. 2010; Fraser et al. 2002; Huiping et al. 2011).

3.2.1.3 Digital Mapping Camera: DMC

Durante décadas la compañía Carl Zeiss ha estado vinculada al desarrollo de cámaras métricas. Cámaras como la RMK o la RMK-TOP han sido empleadas en la realización de vuelos fotogramétricos por empresas de todo el mundo. Con la importante evolución tanto en procesos de producción como en la explotación de la información geográfica los sensores también se han visto afectados en su diseño conceptual y funcional. De este modo la transición de cámaras analógicas a digitales se realizó en relativamente poco tiempo. En el caso de Carl Zeiss la continuidad en el desarrollo de nuevos sensores aerotransportados se ha visto asegurada en el tiempo con la participación de la compañía Z/I Imaging, apareciendo en el mercado la cámara Digital Mapping Camera (en adelante DMC), evolución natural de la cámara RMK-TOP (Hinz et al. 2001). Esta cámara, introducida en el mercado a principios de 2003, consta de ocho sensores, cuatro de ellos pancromáticos y cuatro multiespectrales, registrando información en el canal rojo (590-675 nm), verde (500-650 nm), azul (400-580 nm) e infrarrojo próximo (675-850 nm). Dichas bandas tal y como se aprecia en la Figura 3-8 aparecen también solapadas, por tanto el sensor reúne las condiciones necesarias para ser analizado en el presente trabajo. Las imágenes registradas por la cámara van pasando por distintos niveles de procesamiento con diferentes resoluciones radiométricas (Madani y Shkolnikov

2008). En los ensayos realizados se emplearon imágenes con una resolución radiométrica igual a 11-bits.

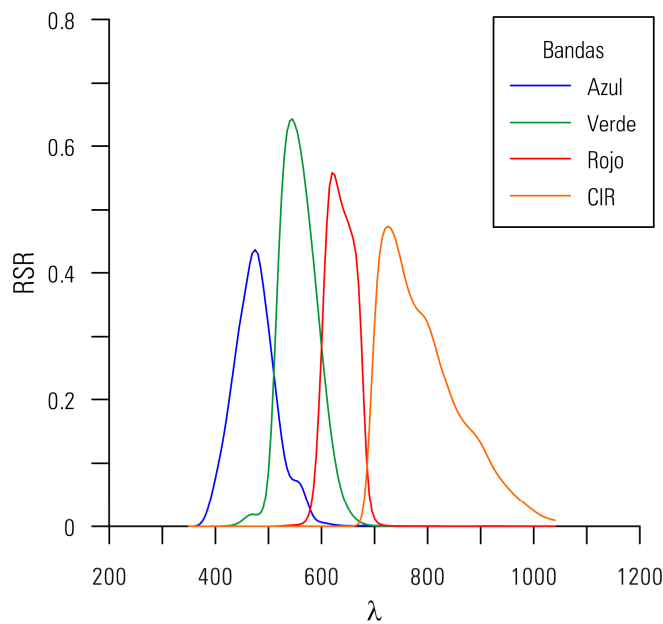


Figura 3-8 RSR de las bandas multiespectral de la cámara aérea DMC.

El uso de este tipo de sensores aéreos en los procesos de producción de conjuntos de datos geográficos es un hecho contrastado, máxime desde que se produjo una reconversión total de la tecnología hacia el entorno digital. La experiencia pone de manifiesto que la generación de productos como ortofotografías han mejorado tanto en resolución espacial, espectral, radiométrica y temporal, por tanto se puede afirmar que este tipo de sensores desde un punto de vista geométrico son pieza fundamental para el levantamiento de información geográfica.

La mejora tanto de la resolución espectral como radiométrica permite emplear la información recogida con otros fines mas enfocados a la práctica y aplicación de procesos de teledetección. La información registrada es posible emplearla en un amplio abanico de aplicaciones tales como inventarios forestales (Morgan et al. 2010; Quackenbush et al. 2000), detección de cambios usando índices como NDVI (Ehlers et al. 2006; Sánchez et al. 2007) o la evaluación de daños causados por desastres naturales (Duan et al. 2010; Suzuki y Yamazaki 2008).

3.2.2 Modelo matemático

Generalmente, el primer paso a la hora de realizar un análisis digital sobre una imagen consiste en convertir los valores que devuelve el sensor a unidades de energía, normalmente radiancia. La relación existente entre la salida del sensor y la radiancia incidente sobre él se denomina calibración radiométrica absoluta del sensor.

Toda salida de un sensor (X), es una función de la radiancia espectral (L_λ) que alcanza a este y la respuesta espectral absoluta (R_λ) (Ec. 3-1)

$$X = F(L_\lambda, R_\lambda) \quad \text{Ec. 3-1}$$

La salida obtenida por parte de la mayoría de los sensores es lineal o casi lineal, de este modo lo establecido en la Ec. 3-1 es una representación válida. No obstante, la realidad es que tal relación es más complicada de lo que se puede establecer en un primer momento dado que hay que tener en cuenta las dependencias con las condiciones espaciales, espectrales y medioambientales en el momento de la adquisición de la información así como las propias características tanto del sensor como de la escena registrada. Como aproximación en la Ec. 3-1 se asume que la radiancia es espacialmente uniforme y que tanto el sensor como la escena son independientes a los cambios temporales. Por tanto, la Ec. 3-1 puede resumirse en la expresión Ec. 3-2 (Wiersma y Landgrebe 1980).

$$X = k \int_{d\lambda} L_\lambda r_\lambda d\lambda + O \quad \text{Ec. 3-2}$$

Siendo:

- O , offset del sensor.

- k , mayor valor de respuesta del sensor.
- r_{λ} , la respuesta espectral relativa del sensor.
- d_{λ} , longitud de onda determinada en la banda espectral.

A su vez la Ec. 3-2 puede ser aproximada a la Ec. 3-3.

$$X = k \sum_{i=1}^n I_i r_i + O \quad \text{Ec. 3-3}$$

Donde:

- n , se corresponde con el número de longitudes de onda de la respuesta espectral absoluta del sensor.

Finalmente, la Ec. 3-3 puede ser expresada en modo matricial de la forma:

$$X = R^T \cdot L \quad \text{Ec. 3-4}$$

Siendo:

- R , la matriz de respuesta espectral relativa del sensor.
- L , radiancia que recibe el sensor.

Como puede observarse en la formulación anterior aparecen dos espacios, de una parte se tiene el espacio espectral (L) y por otra parte el espacio sensor (X), siendo la matriz RSR la encargada de transformar de uno a otro espacio. Por tanto, de igual manera que se ha detallado como se obtiene el valor que se almacena en el sensor puede plantearse reconstruir el valor de la energía, L , que llega a este. Para ello, en primer lugar establecer que el presente trabajo aparece centrado en la relación entre

el sensor y la energía que llega a él, descartando otras influencias como efectos atmosféricos. Atendiendo a esta premisa y partiendo de la información registrada por el sensor y su RSR el valor de la energía que incide en este queda establecida en Ec. 3-5:

$$L' = R \cdot X = \sum_{j=1}^n r_j X_j \tag{Ec. 3-5}$$

Siendo:

- L' , radiancia reconstruida que recibe el sensor.

La Ec. 3-5 implica que la información almacenada en un píxel x_j representa la cantidad de respuesta por parte del sensor para un ancho de banda determinado y único. A la vista de las RSR de los distintos sensores presentados en el presente trabajo, la Ec. 3-5 no puede entenderse como una expresión válida debido a que la RSR de las distintas bandas que componen un sensor no cubren un ancho de banda único al aparecer solapadas de modo que no establecen un espacio ortonormal. Tal condición implica que las columnas de la matriz RSR, es decir, la respuesta de cada banda tiene que ser linealmente independientes. Para ello la condición de dependencia o independencia lineal queda establecida en las siguientes definiciones y teoremas:

Sean v_1, v_2, \dots, v_n n vectores de un espacio vectorial V . Entonces se dice que los vectores son linealmente dependientes si existen n escalares c_1, c_2, \dots, c_n no todos cero, tales que

$$c_1 \cdot v_1 + c_2 \cdot v_2 + \dots + c_n \cdot v_n = 0 \tag{Ec. 3-6}$$

Si los vectores no son linealmente dependientes, se dice que son

linealmente independientes.

Un conjunto de vectores $\{v_1, v_2, \dots, v_n\}$ son una base del espacio vectorial V si:

i. $\{v_1, v_2, \dots, v_n\}$ es linealmente independiente

Ec. 3-7

ii. $\{v_1, v_2, \dots, v_n\}$ genera V

Por tanto, todo conjunto de n vectores linealmente independientes en \mathfrak{R}^n es una base de \mathfrak{R}^n .

El conjunto de vectores $S = \{u_1, u_2, \dots, u_k\}$ en \mathfrak{R}^n se denomina conjunto ortonormal si cumple:

$$u_i \cdot u_j = 0 \text{ si } i \neq j$$

$$u_i \cdot u_i = 1$$

Ec. 3-8

Si solo satisface la primera condición se establece que el conjunto de vectores es un conjunto ortogonal.

Si $S = \{u_1, u_2, \dots, u_k\}$ es un conjunto ortogonal de vectores no nulos, entonces S es linealmente independiente.

Como ha quedado establecido, tal condición no se cumple por parte de la RSR. El planteamiento que a continuación se desarrolla queda descompuesto en dos etapas:

- Procesar la información almacenada en cada una de las bandas a fin de obtener la mejor reconstrucción posible de la energía incidente en el sensor, L' .

- Reducir la redundancia de información a consecuencia del solapamiento de la respuesta espectral de cada una de las bandas del sensor.

3.2.3 Reconstrucción de los valores de energía

El proceso de la reconstrucción de la energía, L' , tiene como fin minimizar la distancia entre el valor de la energía reconstruido y el valor real, minimizando por consiguiente la norma $\|L - L'\|$ a partir de una solución mínimo cuadrática la cual cumplirá:

$$X \in D(R), \|L - RX\|_p = \min \{ \|L - RX\|_p, \forall X \in D(R) \} \quad \text{Ec. 3-9}$$

De este modo X se corresponde con la solución que hace mínima en L la forma cuadrática:

$$(L - RX)^T P (L - RX) \quad \text{Ec. 3-10}$$

Siendo P igual a la matriz de pesos. En este punto el modelo funcional de la aplicación resulta igual a:

$$RX - L = v \quad \text{Ec. 3-11}$$

Correspondiéndose v con el vector de error resultado de la diferencia entre los valores reconstruidos de la energía y los valores reales. El vector de parámetros X se determina bajo la condición de mínimo en el espacio de observaciones de tal modo que:

$$T(v) = v^T \cdot P \cdot v = \text{mínimo} \quad \text{Ec. 3-12}$$

Una expresión de la forma cuadrática $T(v, X)$ en función de los parámetros se obtiene sustituyendo la Ec. 3-11 en la Ec. 3-12, obteniendo

$$\begin{aligned} T(X) &= (RX - L)^T P (RX - L) = (X^T R^T - L^T) (PXR - PL) = \\ &X^T R^T PRX - X^T R^T PL - L^T PRX + L^T PL = \\ &X^T R^T PRX - 2L^T PRX + L^T PL \end{aligned} \quad \text{Ec. 3-13}$$

Determinando las derivadas parciales de $T(X)$ con respecto a X e igualando a cero queda determinada la solución mínima

$$\frac{\partial T(X)}{\partial X} = 2 \cdot X^T \cdot R^T \cdot P \cdot R - 2 \cdot L^T \cdot P \cdot R = 0 \quad \text{Ec. 3-14}$$

Considerando las transposiciones de las matrices de la Ec. 3-14 se obtiene

$$R^T \cdot P \cdot R \cdot X - R^T \cdot P \cdot L = 0 \quad \text{Ec. 3-15}$$

Los sumandos de la Ec. 3-15 quedan definidos como

$$\begin{aligned} N &= R^T \cdot P \cdot R \\ d &= R^T \cdot P \cdot L \end{aligned} \quad \text{Ec. 3-16}$$

Con dimensiones $\dim(N) = (n \times n)$ y $\dim(d) = (n \times 1)$, siendo n igual al número de bandas.

De este modo Ec. 3-15 queda escrita como

$$N \cdot X - d = 0 \quad \text{Ec. 3-17}$$

Mediante la Ec. 3-17 queda establecido un sistema de ecuaciones normales de n ecuaciones n incógnitas. Si la matriz RSR, R , no es deficiente de rango, es decir, sus vectores son linealmente independientes y la matriz de pesos P es definida positiva queda asegurado que la matriz N es cuadrada y por tanto invertible, siendo su inversa única. Tal hecho permite resolver el sistema de ecuaciones establecido en Ec. 3-17, siendo el vector solución de parámetros X igual a

$$X = N^{-1} \cdot d = (R^T \cdot P \cdot R)^{-1} \cdot R^T \cdot P \cdot L \quad \text{Ec. 3-18}$$

Sustituyendo el resultado de la Ec. 3-18 en la Ec. 3-5 se obtiene

$$L' = R(R^T P R)^{-1} R^T P L \quad \text{Ec. 3-19}$$

Considerando que todas las bandas presentan la misma importancia, es decir $P = I$, la Ec. 3-19 resulta igual a

$$L' = R(R^T R)^{-1} R^T L = R(R^T R)^{-1} X \quad \text{Ec. 3-20}$$

Por tanto, queda establecido como la Ec. 3-20 representa la mejor reconstrucción de la energía que incide en el sensor al hacer mínima la norma $\|L-L'\|$. Tal resultado es aplicable tanto a sensores con o sin solape espectral entre sus bandas. En este último caso la matriz R sería una matriz ortogonal de manera que satisface la igualdad $R^T \cdot R = I$ y por tanto

$$L' = R(R^T R)^{-1} X = R \cdot I \cdot X = R \cdot X \quad \text{Ec. 3-21}$$

3.2.4 Minimización de la correlación causada por el solape espectral

A la hora de trabajar con imágenes digitales, cualquier procesamiento que se realice sobre los niveles digitales que componen una imagen es equivalente a trabajar sobre los valores de energía que inciden y registra un sensor. De este modo en numerosas tareas que se realizan sobre imágenes resulta indiferente trabajar con tales niveles digitales (X) o con valores de energía (L).

En el caso de emplear sensores con solape espectral entre sus bandas se ha demostrado como solo es posible operar sobre L' , siendo necesaria la reconstrucción de la energía haciendo mínima la norma entre la energía real y la estimada.

En este sentido, en el caso de emplear algoritmos de clasificación basados en distancias o productos inerciales el resultado de operar sobre X resulta igual a operar sobre L , de manera que

$$f(X) = f(R^T L) = f(L) \quad \text{Ec. 3-22}$$

Sean f y f' operadores de clasificación aplicados sobre X y L implica que la Ec. 3-22 devuelve resultados dependientes del sensor. En este sentido, como ha quedado demostrado anteriormente solamente se podrá actuar sobre L' y por tanto

$$f(X) = f(R^T L') = f''(L') \quad \text{Ec. 3-23}$$

Teóricamente, los resultados de la Ec. 3-22 deberían ser idénticos a los obtenidos por Ec. 3-23. En el caso de trabajar por ejemplo con el clasificador mínima distancia Euclídea, el operador f se aplicará sobre X . El criterio de clasificación de dicho operador sobre el espacio imagen queda definido como $\|X - Y_i\|$, siendo Y_i el valor medio de la clase i . Si el mismo criterio es aplicado en el espacio espectral la condición quedará como $\|L - I_i\|$, siendo I_i el valor medio de la clase i . En el supuesto de emplear el operador mínima distancia Euclídea en un sensor con sus bandas no solapadas se cumplirá la condición

$$\|X - Y_i\| = \|L - I_i\| \quad \text{Ec. 3-24}$$

En el caso de sensores con bandas solapadas, y dado que la matriz R no es una matriz ortonormal la condición de la Ec. 3-24 no es válida de forma que

$$f'(L'): \|X - Y_i\| = \|R^T (L' - I_i)\| \neq g(L'): \|L' - I_i\| \quad \text{Ec. 3-25}$$

Es decir, mediante la Ec. 3-25 queda establecido que el resultado del operador g será diferente al obtenido mediante el operador f . Además g generará mejores resultados al modelizar el comportamiento de las bandas, aspecto que no contempla f .

La transformación del espacio imagen al espacio de la energía queda definida como $T : \mathfrak{R}^m \rightarrow \mathfrak{R}^n$, de tal modo que se pasará de un espacio de m bandas de la imagen a un espacio de n fracciones de longitud de onda de la matriz RSR. La alta dimensionalidad de la nueva imagen dificultará enormemente los procesos de clasificación a desarrollar sobre ella. En este punto el siguiente desarrollo presentado va dirigido hacia la consecución de una nueva imagen que cumpla todos los requisitos descritos anteriormente pero con un número de bandas igual a la resolución espectral del sensor.

El planteamiento propuesto pasa por la descomposición de la matriz RSR. En esta descomposición de la matriz RSR se va a ir buscando una matriz que dé lugar a que en el sistema planteado aparezca una isometría.

Una transformación lineal $T : \mathfrak{R}^n \rightarrow \mathfrak{R}^n$ recibe el nombre de isometría si, siendo x cualquier vector de \mathfrak{R}^n se cumple:

$$\|T \cdot x\| = \|x\| \quad \text{Ec. 3-26}$$

Para que tal definición se cumpla la matriz T tiene que cumplir el siguiente teorema:

Una transformación lineal $T : \mathfrak{R}^n \rightarrow \mathfrak{R}^n$ es una isometría si y solo si la representación matricial de T es una matriz ortogonal.

Como quedó establecido en la Ec. 3-21, la matriz RSR será ortogonal solo en el caso de no presentar sus bandas solapadas, manteniéndose la norma entre los dos espacios. El espacio imagen y el espacio sensor serán isométricos si existe una isometría del espacio sensor sobre el espacio imagen.

El planteamiento matemático presentado va encaminado a lograr tales condiciones de ortogonalidad. A tal efecto se empleará la descomposición de matrices de manera que una matriz quedará expresada como el producto de dos matrices más sencillas. Tal descomposición o factorización permite resolver ecuaciones lineales, determinar matrices inversas o evaluar potencias. Los métodos que pueden ser aplicados para tal objetivo son muy variados, como la descomposición a valores singulares, la factorización LU, la descomposición de Cholesky o la factorización QR. Cada uno de ellos será aplicado en virtud de las características de la matriz que queramos descomponer. La intención en este punto es descomponer la matriz RSR. La factorización LU fue descartada al no ser la matriz RSR una matriz cuadrada, la descomposición de Cholesky igualmente se desechó al no ser la matriz RSR una matriz simétrica mientras que la factorización QR fue desestimada por no ser la matriz RSR una matriz triangular superior.

La descomposición de la matriz RSR (R) se descompondrá aplicando la descomposición a valores singulares (en adelante SVD).

Sea A una matriz de $m \times n$ ($m \geq n$) entonces existen matrices ortogonales U y V tales que siendo D una matriz diagonal de orden $m \times n$ cuya diagonal son los valores singulares de la matriz A apareciendo estos en orden creciente. U es una matriz cuadrada de $m \times m$ cuyas columnas contiene los vectores singulares izquierdos y V una matriz de $n \times n$ cuyas columnas contiene los vectores singulares derechos. De este modo U y V son matrices ortogonales y S una matriz diagonal.

Aplicando SVD sobre la matriz RSR se obtiene:

$$R = U \cdot S \cdot V^T \quad \text{Ec. 3-27}$$

Observando la definición de la transformación lineal isométrica se advierte como interviene una matriz ortogonal, característica que aparece en el resultado una vez descompuesta la matriz RSR.

Desarrollando la Ec. 3-27 sobre la pseudoinversa de la matriz RSR, R^+ se obtiene en primer lugar que:

$$R^T \cdot R = (U \cdot S \cdot V^T)^T \cdot U \cdot S \cdot V^T = V \cdot S^{-1} \cdot S^{-1} \cdot V^{-1} \quad \text{Ec. 3-28}$$

De tal manera que

$$R \cdot (R^T \cdot R) = (U \cdot S \cdot V^T) \cdot (V \cdot S^{-1} \cdot S^{-1} \cdot V^{-1}) = U \cdot S^{-1} \cdot V^T \quad \text{Ec. 3-29}$$

Aplicando Ec. 3-29 en Ec. 3-20 se obtiene que

$$L' = R(R^T R)^{-1} X = U \cdot S^{-1} \cdot V^T \cdot X = U \cdot (S^{-1} \cdot V^T \cdot X) = U \cdot \tilde{X} \quad \text{Ec. 3-30}$$

Como se ha visto anteriormente, la matriz U es una matriz ortogonal que es considerada una isometría por definición entre L' y \tilde{X} de tal modo que es posible aplicar un operador de clasificación a una u otra imagen asegurando que los resultados serán idénticos.

Queda demostrada la definición de un operador igual a $D^{-1}V^T$, dependiente del sensor el cual es calculado a partir de la matriz RSR de este. Este operador es aplicable a todas las imágenes obtenidas por él, independientemente de las características de la escena de manera que contiene la mejor reconstrucción de la energía incidente en el sensor y además reduce la correlación entre bandas debido al solape espectral entre ellas. Este operador será calculado exclusivamente una sola vez para un sensor determinado siempre y cuando la matriz RSR no varíe.

3.2.5 Modelo de evaluación

La metodología propuesta en el presente capítulo se ha evaluado en dos etapas:

- Analizar el resultado de la reconstrucción de la energía planteado en el apartado 3.2.3.
- Evaluar el efecto de la introducción de la matriz RSR dentro del proceso de clasificación aplicando lo expuesto en el apartado 3.2.4.

En la evaluación de la metodología propuesta para la reconstrucción de la energía se ha seguido un flujo de trabajo idéntico tanto para sensores sin solape espectral entre sus bandas (Figura 3-9.a) y con solape espectral entre sus bandas (Figura 3-9.b). Para ello se ha modelizado una hipotética cantidad de energía que ha incidido en sendos sensores de tal manera que cada uno de ellos a partir de la Ec. 3-3 han generado sus respectivas salidas en forma de niveles digitales. Tales salidas han sido empleadas para calcular el valor de energía inicial que llegó al sensor. Para ello se ha empleado la metodología convencional que aparece recogida en la Ec. 3-5 así como la metodología propuesta de reconstrucción expuesta en la Ec. 3-20. De este modo de cada sensor se tendrán dos versiones de energía incidente. Cada uno de ellos se contrastará con los valores originales con el fin de poder determinar el error cometido en cada longitud de onda, permitiendo a su vez el cálculo de la desviación estándar de cada metodología. La comparación entre los valores de desviación estándar determinará la bondad del planteamiento presentando en 3.2.3.

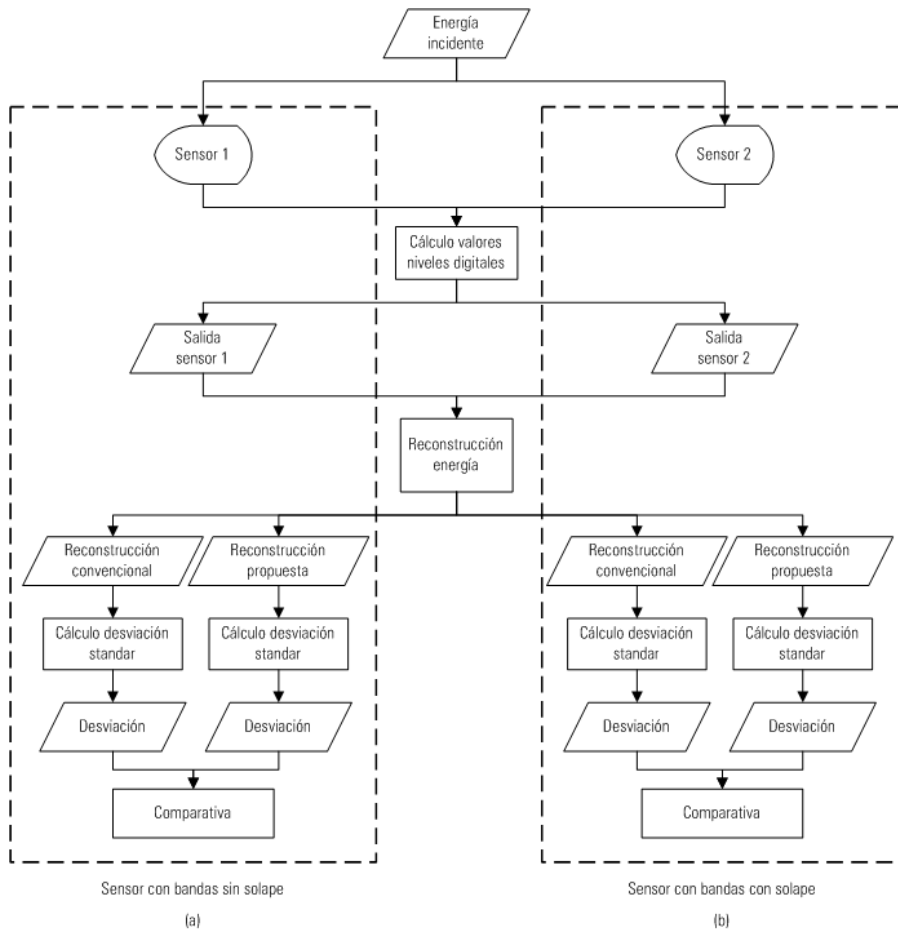


Figura 3-9 Flujo de trabajo para la evaluación de la metodología propuesta para la reconstrucción de la energía sobre sensores sin solape espectral (a) y con solape espectral (b) en sus bandas.

En una segunda etapa, para evaluar y analizar la validez de la transformación realizada sobre las imágenes siguiendo el planteamiento de 3.2.4 se han empleado sensores cuyas matrices RSR son conocidas: ASTER, IKONOS y DMC. El flujo de trabajo (Figura 3-10) consistió en coger cada una de las imágenes originales de cada sensor y procesarlas para generar una nueva imagen tras la aplicación de su correspondiente matriz-factor de conversión dependiente del sensor. Tanto las imágenes originales como las procesadas fueron clasificadas empleando para ello un clasificador no supervisado y otro supervisado, apoyados ambos en la medida de distancia Euclídea.

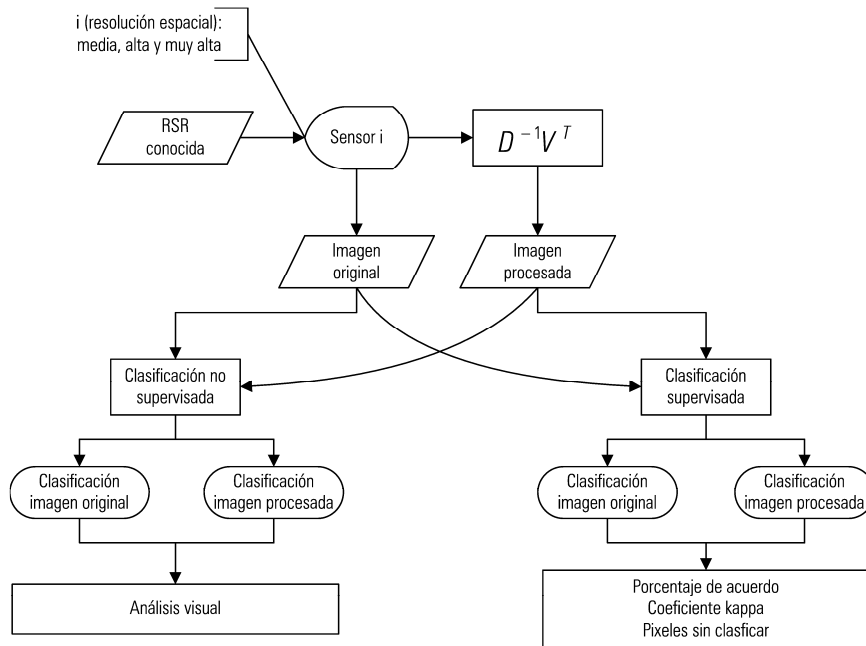


Figura 3-10 Esquema de validación metodología propuesta en procesos de clasificación supervisada y no supervisada.

Como clasificador no supervisado se empleó el algoritmo ISODATA. Este algoritmo es uno de los más empleados en clasificaciones no supervisadas. Tal algoritmo se basa en un procedimiento de agrupación no jerárquico incluido dentro de los métodos de centroide más próximos a partir de la medida de la distancia Euclídea, asignando cada uno de los píxeles que componen una imagen a una de las clases establecidas siguiendo para ello un proceso iterativo (Jensen 1996). En un primer momento el algoritmo selecciona unos valores iniciales que caracterizan a cada una de las clases caso que el usuario no haya definido estos. La imagen completa queda clasificada asignando cada píxel a la clase más cercana en términos estadísticos. En cada iteración, con los píxeles clasificados se determinan unos nuevos valores que caracterizan a cada una de las clases. El usuario en este proceso puede establecer restricciones como el número mínimo de píxeles que tiene que contener una clase para ser considerada como tal. Todo el proceso se irá reiterando hasta que el porcentaje de cambios determinado por el usuario no supere cierto umbral o bien se haya llegado al número máximo de repeticiones. Los resultados de

las clasificaciones obtenidas fueron analizadas visualmente permitiendo determinar posibles mejoras en los resultados.

Como clasificador supervisado se empleó MD, basado también en estadística de primer orden. Este operador emplea el valor medio de los píxeles recogidos en una clase como valor de referencia para caracterizar a esta. Sea $m_i (i = 1, \dots, c)$ el vector de medias obtenidas en el entrenamiento de la clase i . La distancia Euclídea al cuadrado de un píxel x a la clase i queda definido por:

$$d_i^2(x) = \|x - m_i\|^2 \quad \text{Ec. 3-31}$$

Si la distancia entre x y la clase i es la mínima del conjunto de clases c , la decisión del clasificador MD será que el píxel x pertenece a la clase i . Aplicando esta lógica todos los píxeles de la imagen quedarán clasificados. Es posible controlar esta situación estableciendo una distancia máxima de error. Si la distancia entre x con cada uno de los valores de referencia es superior a esta distancia máxima de error x no será asignado a una de las clases. De este modo sobre la escena clasificada aparecerán píxeles sin clasificar. A medida que esta distancia máxima de error aumente, las condiciones serán menos restrictivas y por tanto el porcentaje de píxeles sin clasificar será menor.

Se establecieron a tal efecto distintas distancias máximas de error teniendo en cuenta el rango de valores de las imágenes procesadas y sin procesar. Una vez que las imágenes se clasificaron se emplearon dos parámetros para evaluar los resultados, el porcentaje de acuerdo y el coeficiente de Kappa.

El porcentaje de acuerdo (Pa) es considerado como la probabilidad global de estar bien clasificada la imagen, por lo que se puede considerar distribuido según una binomial. Sus valores se encuentran en el intervalo $[0,100]$ (al ser expresado como porcentaje), siendo el valor 100 el caso de total acuerdo. Queda definido como la suma de los píxeles correctamente clasificados dividido por el número total de píxeles empleados en el contraste:

$$Pa = \frac{1}{N} \sum_{i=1}^M x_{i,i} \quad \text{Ec. 3-32}$$

Siendo:

- N el número total de píxeles
- M el número de clases.
- $x_{i,i}$ elemento de la diagonal de la matriz correspondiente a la clase M .

El coeficiente Kappa (K) informa del porcentaje de acuerdo obtenido en una clasificación una vez se haya eliminado la parte correspondiente al azar. Se basa en la probabilidad a posteriori de pertenencia a un grupo. Sus valores se encuentran en el intervalo $[0,1]$, siendo el valor 1 el caso de total acuerdo. Queda definido como:

$$K = \frac{Pa - Ca_{ps}}{1 - Ca_{ps}} \quad \text{Ec. 3-33}$$

Siendo:

- Pa el porcentaje de acuerdo
- Ca_{ps} el coeficiente de acuerdo aleatorio a posteriori. Este está basado en la probabilidad a posteriori de cada clase. Representa el porcentaje de acuerdo que cabe esperar al azar por cruce de clases.

Junto a Pa y K se determinó el porcentaje de píxeles sin clasificar.

3.3 Resultados y discusión

En esta sección se muestra como el trabajo fue llevado a cabo. En primer lugar se simularon las RSR de dos sensores, con y sin solape en sus bandas, para verificar el modelo propuesto. Posteriormente, las imágenes recogidas por diferentes sensores fueron clasificadas empleando el clasificador no supervisado ISODATA y el clasificador supervisado MD.

3.3.1 Simulación de sensores

Se emplearon sensores simulados a fin de poder evaluar la mejora de la metodología propuesta. Se diseñaron a tal efecto dos sensores con comportamiento espectral diferente. Ambos presentaban una resolución espectral igual a 6. El primero de ellos no tenía sus bandas espectrales solapadas (Figura 3-11.a) mientras que el segundo presentó todas sus bandas solapadas (Figura 3-11.b).

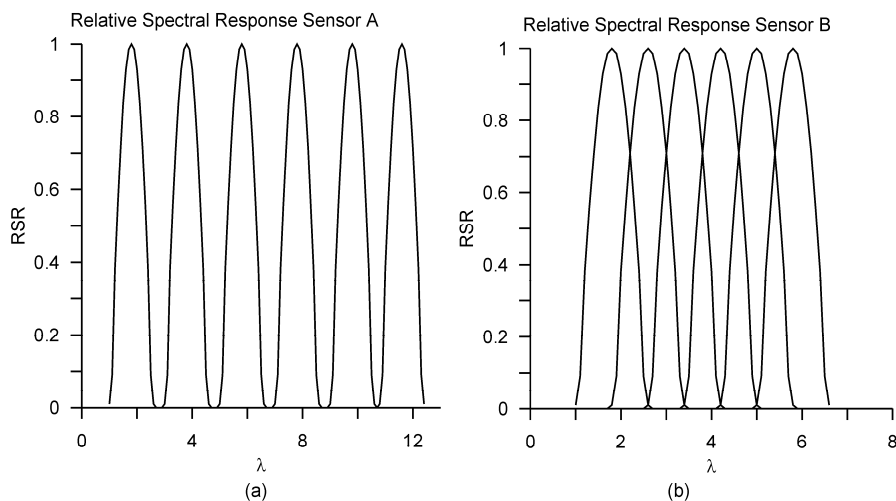


Figura 3-11 RSR de sensores simulados: (a) sin solape espectral en sus bandas y (b) con solape espectral en sus bandas.

Se tomó como caso hipotético que en dos momentos diferentes sobre ambos sensores incidió una cantidad de energía con las mismas características. En la primera ocasión la distribución de la energía siguió una línea recta (Figura 3-12.a)

mientras que en la segunda ocasión la distribución de la energía siguió una curva parabólica (Figura 3-12.b).




Figura 3-12 Radiancia que alcanza a los sensores simulados, distribución (a) línea recta y (b) parabólica.

En este marco de trabajo en primer lugar se calculó la respuesta del sensor para cada banda empleando para ello la RSR de cada sensor. Los valores de las bandas se emplearon para reconstruir los valores de radiancia que incidieron inicialmente en el sensor. En el sensor sin solape espectral la reconstrucción de la energía fue exactamente la misma independiente de la aplicación del modelo general (Ec. 3-5) o el modelo propuesto (Ec. 3-20). No hubo ninguna diferencia entre ambas reconstrucciones dado que la matriz RSR al no estar solapada se corresponde con una matriz ortogonal. En el caso del sensor con sus bandas solapadas se realizó la misma comprobación, contrastando la reconstrucción de la radiancia empleando la metodología convencional y empleando la metodología propuesta. En ambos casos aparecieron diferencias con respecto a la distribución de la radiancia original, tanto para el caso de la distribución en modo de recta (Figura 3-13.a) como con la distribución parabólica (Figura 3-13.b). En ambas gráficas se observa como la reconstrucción de la energía empleando la metodología convencional (Ec. 3-5) no se ajusta correctamente a los valores originales, estando ambos valores, original y reconstruido, en los dos casos muy separados. Por contra, en el caso de la aplicación de la metodología propuesta empleando un ajuste mínimo cuadrático (Ec. 3-20), los valores originales y los reconstruidos aparecen mucho más cercanos. La desviación

estándar aplicando mínimos cuadrados fue de 0.14 y 1.10 para la distribución de la radiancia en línea recta y en modo parabólico respectivamente. La desviación estándar empleando la metodología convencional resulto ser igual a 4.10 y 23.4 en ambas situaciones. Por tanto, en un entorno de simulación, la mejor reconstrucción de la energía se obtuvo tras realizar un ajuste mínimo cuadrático tal y como se propone en el presente capítulo.

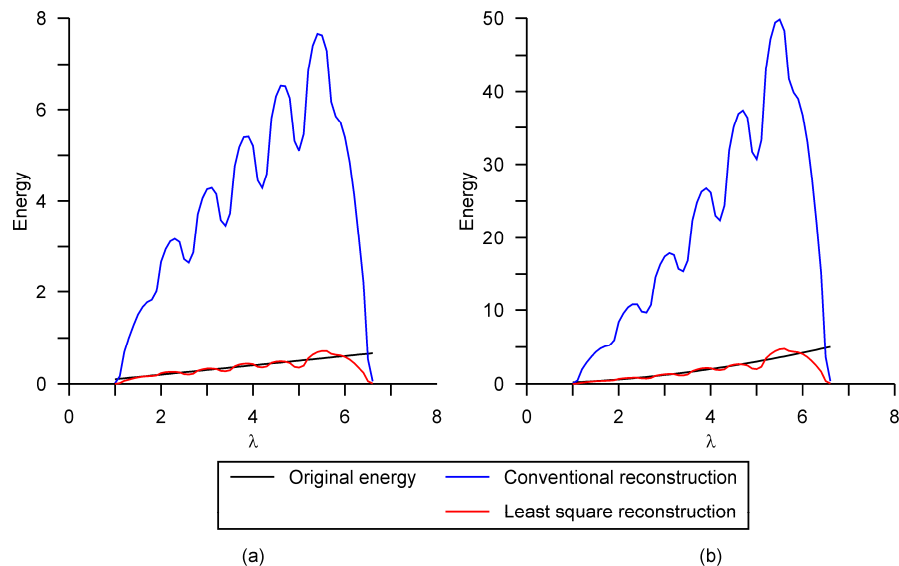


Figura 3-13 Comparativa de la reconstrucción de la energía en el sensor con solape en sus bandas. Distribución radiancia: (a) línea recta y (b) curva parabólica.

3.3.2 Clasificación

3.3.2.1 Zonas de estudio

En la realización del trabajo se empleó una imagen de cada uno de los siguientes sensores: ASTER, IKONOS y DMC (Figura 3-14). La zona de estudio de la imagen ASTER correspondió al término municipal de Andujar, provincia de Jaén, en el sur de España (coordenadas centrales 36°00'36"N, 3°58'06"O, WGS84). Se trabajo con una muestra de la escena de dimensiones correspondientes a 750×750 píxeles y una resolución espacial igual a 15 metros. La imagen IKONOS fue tomada en Montilla,

provincia de Córdoba, en el sur de España (coordenadas centrales 37°35'07"N, 4°38'20"O, WGS84). La imagen empleada para los ensayos fue una muestra de la imagen completa de dimensiones 750×850 píxeles, presentando una resolución espacial igual a 4 metros. Finalmente, para el caso del sensor DMC se empleó un fotograma de un vuelo realizado en Collado Villalba, Comunidad de Madrid, (coordenadas centrales 40°37'47"N, 4°00'33"O, WGS84). La zona seleccionada fue un fragmento de un fotograma de dimensiones 700×700 píxeles y una resolución espacial de 10 cm. En el caso de la imagen ASTER se establecieron siete clases de interés, seis para la imagen IKONOS, mientras que para la imagen de la cámara DMC se establecieron cinco clases. Toda la información de cada una de las clases consideradas para cada una de las imágenes aparece detallada en la Tabla 3-2. Cada imagen fue fotointerpretada identificando sobre ella elementos pertenecientes a cada una de las clases que se emplearían posteriormente en las fases de entrenamiento y validación en los procesos de clasificación. El método de muestreo empleado para tomar las muestras fue estratificado aleatorio.




Figura 3-14 Imágenes registradas por los sensores ASTER, IKONOS y DMC.

Tabla 3-2. Información de las muestras de entrenamiento y validación de cada clase en las imágenes ASTER, IKONOS y DMC.

Imagen 1. ASTER			Imagen 2. IKONOS			Imagen 3. DMC		
Clase	Muestra (píxel)		Clase	Muestra (píxel)		Clase	Muestra (píxel)	
	Entreno	Test		Entreno	Test		Entreno	Test
Suelo desnudo	380	16847	Edificación	1305	5140	Edificación	2460	79560
Edificación	195	2350	Suelo desnudo	1080	46512	Carretera	1560	11240
Herbáceos	1410	37672	Herbáceos	1080	47991	Sombras	600	4182
Carretera	180	1325	Carretera	540	2350	Árboles	180	1030
Olivar	1568	32334	Olivar	585	12138	Fachada	1530	3702
Rastrojo	770	14120	Nave industrial	675	1040			
Agua	140	1400						

3.3.2.2 Clasificación no supervisada

Se aplicó el algoritmo ISODATA teniendo en cuenta el mismo número de iteraciones y de clases tanto en las imágenes originales como en las procesadas. La Figura 3-15 muestra una comparativa de los resultados obtenidos para cada uno de los sensores de trabajo según el tipo de procesado. La clasificación de la imagen sin procesar ASTER (Figura 3-15.I.a) no mostró diferencias significativas entre la clasificación de la imagen sin procesar (Figura 3-15.I.b) y la imagen procesada (Figura 3-15.I.c). En este tipo de imágenes resultó difícil distinguir clases como edificaciones o carreteras en ambos tipos. Al mismo tiempo, clases con fenómenos de mayores dimensiones y homogéneas espectralmente como parcelas de herbáceos resultaron igualmente difíciles de distinguir.

Por el contrario, la imagen del sensor IKONOS (Figura 3-15.II.a) reflejó claras diferencias entre la imagen procesada (Figura 3-15.II.c) y la imagen sin procesar (Figura 3-15.II.b). La vertebración de la trama urbana es posible interpretarla sobre la imagen procesada gracias a que los elementos individuales aparecen mejor definidos mientras que el resultado de la imagen sin procesar es más borroso y confuso. Ejemplos claros de esta situación pueden observarse sobre las naves industriales o el trazado de la carretera presente en la imagen de muestra.

La clasificación del fotograma de la cámara DMC (Figura 3-15.III.a) siguió la misma tendencia marcada por el sensor IKONOS. Un ejemplo claro puede apreciarse sobre la imagen procesada (Figura 3-15.III.c) donde los edificios aparecen mejor definidos que en la imagen sin procesar (Figura 3-15.III.b). Elementos poligonales pudieron ser identificados de forma más cómoda y ágil sobre la imagen procesada dado que los fenómenos edificios, sombras y fachadas se dispusieron en tres clases bien diferenciadas en contraste con la imagen sin procesar.

Por tanto, realizando un análisis visual los resultados obtenidos de la aplicación del clasificador ISODATA fueron idénticos comparando las clasificaciones de las imágenes procesadas y sin procesar en el sensor de resolución espacial media. Una de las causas podemos encontrarla en la elevada proporción de píxeles mezcla resultantes en este rango de resolución espacial, lo cual pone de manifiesto la dificultad de este tipo de procesos a estos niveles de resolución. Resulta complicado obtener resultados con cierta garantía cuando se aplican clasificadores como ISODATA. Aunque los datos fueron dispuestos en un espacio ortogonal no resultó suficiente para mejorar los resultados. En imágenes con resolución espacial alta o muy alta el clasificador ISODATA sí presentó mejores resultados. El concepto de píxeles mezcla en IKONOS y DMC aparece ligado principalmente al efecto borde. En este caso, comenzaron a aparecer diferencias apreciables visualmente entre las imágenes procesadas y sin procesar. Las mejoras fueron debido a que los fenómenos presentes en la imagen aparecían mejor definidos, facilitando la interpretación de los resultados obtenidos.




Figura 3-15 Comparativa resultados ISODATA para: (I) ASTER, (Carter et al.) IKONOS y (III) cámara DMCM; (a) imagen original, (b) clasificación imagen sin procesar y (c) clasificación procesada.

3.3.2.3 Clasificación supervisada

Las imágenes ASTER, IKONOS y DMC se clasificaron empleando el algoritmo de clasificación MD. Cada clasificación se realizó teniendo en cuenta tanto la imagen procesada como sin procesar. Además se establecieron distintas distancias máximas de error a la hora de clasificar estas imágenes. El rango de los datos cambiaba cuando las imágenes eran procesadas. Este aspecto fue tenido en cuenta de tal manera que los nuevos rangos fueron considerados para establecer unas distancias

máximas de error sobre las imágenes procesadas, escalados al nuevo rango de los datos. Tal forma de actuar hizo posible poder comparar los resultados obtenidos para las imágenes procesadas y sin procesar. En la imagen ASTER las distancias máximas de error establecidas fueron iguales a 0 (equivalente a no establecer distancia máxima de error), 5, 10, 20 y 25. Las distancias máximas de error correspondientes a los sensores IKONOS y DMC fueron iguales a 0 (igual a no establecer distancia máxima de error), 100, 200, 300 y 400. Las distancias fueron diferentes entre ASTER e IKONOS y DMC debido a que la imagen ASTER tenía una resolución radiométrica igual a 8-bits mientras que en los otros dos sensores la resolución era de 11-bits, siendo por tanto necesario establecer tramos de distancias distintos, acordes a la resolución radiométrica de las imágenes. Los resultados obtenidos en la clasificación (P_a y K) así como el porcentaje de píxeles sin clasificar aparecen representados en la Figura 3-16.

Los resultados de P_a y K en las imágenes procesadas y sin procesadas del sensor ASTER fueron similares, no apreciándose diferencias significativas. La Figura 3-16.I.a y Figura 3-16.I.b muestra como los resultados de las clasificaciones no presentan diferencias independientemente de la distancia máxima de error definida. Al mismo tiempo la Figura 3-16.I.c refleja que el porcentaje de píxeles sin clasificar también resultó idéntico independientemente de la distancia máxima de error establecida y de si la imagen es procesada o no procesada. Estos resultados parecen lógicos debido a que el valor de P_a esta directamente relacionado con el porcentaje de píxeles sin clasificar. Como era previsible, P_a y K mejoraron sus resultados a medida que la distancia máxima de error aumentaba, con el efecto directo de que el porcentaje de píxeles sin clasificar decrecía en sendas imágenes. De este modo, la imagen procesada no reflejó ningún tipo de mejora en los resultados del sensor ASTER. Tal comportamiento coincide con los resultados obtenidos con el clasificador ISODATA.

En el caso del sensor IKONOS, los resultados tanto de P_a como K en las imágenes procesadas y sin procesadas resultaron prácticamente iguales en el caso de no establecer distancia máxima de error (igual a 0) o cuando el valor de la distancia de error no era muy estricta (igual a 400) (Figura 3-16.II.a y Figura 3-16.II.b). A medida que la tolerancia, a modo de distancia máxima de error, era más exigente

comenzaron a aparecer las diferencias, sobre todo cuando esta distancia era pequeña, es decir, ante situaciones más exigentes. Mientras que en el caso de la imagen procesada tanto P_a como K presentó valores estables en el caso de la imagen sin procesar estos decrecían conforme la tolerancia era menor. La Figura 3-16.II.c refleja cómo, en la imagen IKONOS, el porcentaje de píxeles sin clasificar depende del tratamiento sobre la imagen. Si la imagen aparece procesada, el porcentaje de píxeles sin clasificar presentó valores muy bajos y muy similares, relacionados con el comportamiento de P_a . En el caso de la imagen sin procesar el porcentaje era mucho mayor y dependiente de la distancia máxima de error. Se puede afirmar que en este caso el clasificador MD clasificó la mayoría de los píxeles de la imagen independientemente de la distancia máxima de error y además lo hizo de manera correcta sobre la imagen procesada. Tal efecto puede tener su base en el hecho de que las clases fueron dispuestas muy separadas unas de otras en el espacio del sensor de tal manera que la desviación entre los píxeles pertenecientes a una misma clase fuera baja.

Finalmente, los resultados obtenidos con la cámara DMC mostraron un comportamiento bien diferente al sensor IKONOS. En primer lugar, si no se fijaba una distancia máxima de error las diferencias en los parámetros P_a y K entre las imágenes procesadas y sin procesar resultaron insignificantes (Figura 3-16.III.a y Figura 3-16.III.b). Las diferencias aparecieron cuando se empleó la distancia máxima de error. Las imágenes sin procesar tuvieron peor P_a y K que las imágenes sin procesar y mayor porcentaje de píxeles sin clasificar (Figura 3-16.III.c). La imagen procesada estabilizó sus resultados a partir de una distancia máxima de error igual a 300; a partir de este valor los resultados fueron prácticamente idénticos. Por el contrario, en la imagen sin procesar empleando un valor de distancia igual a 400 (valor poco restrictivo) el P_a se encontraba próximo al 60% y K inferior a 0.5. Esto muestra que este algoritmo presenta dificultades para clasificar imágenes de muy alta resolución espacial. Cuando las imágenes son procesadas, estas dificultades se reducen aunque el comportamiento de los resultados no es estable como el caso del sensor IKONOS.

El Anexo 1 recoge las matrices de confusión obtenidas de cada una de las clasificaciones atendiendo a tipo de sensor, tipo de procesamiento y distancia máxima de error.

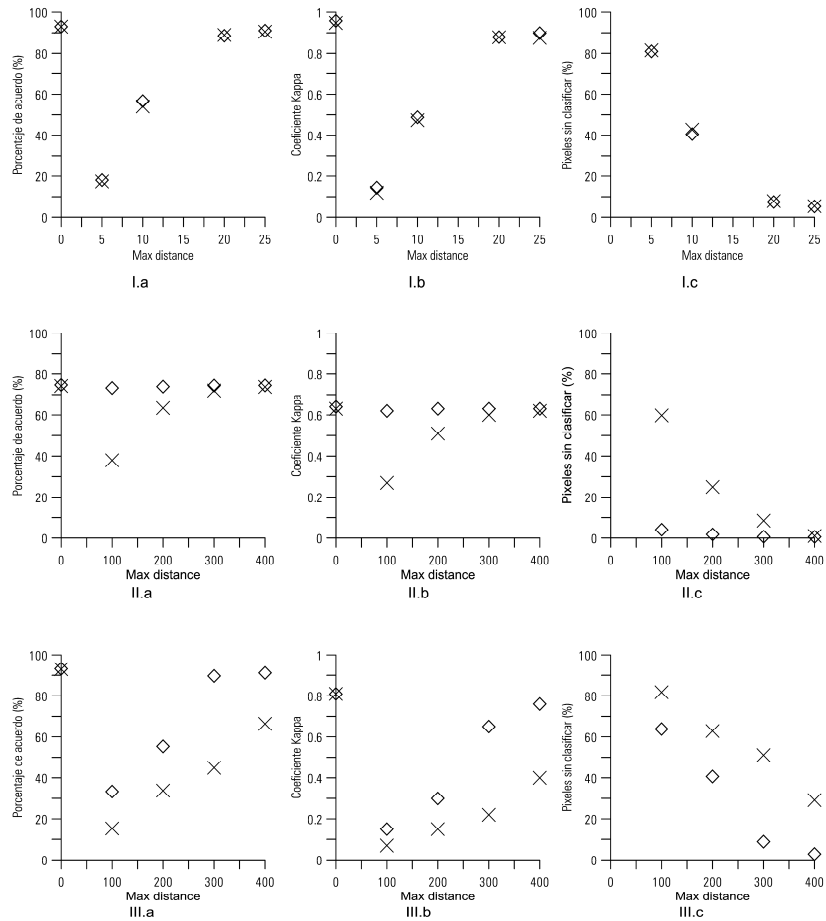


Figura 3-16 Comparativa resultados clasificador mínima distancia: (a) porcentaje de acuerdo, (b) coeficiente Kappa y (c) porcentaje de píxeles sin clasificar en (I) ASTER, (Carter et al.) IKONOS y (III) cámara DMC.

3.4 Conclusión

Hoy día, aparece en aumento el número de satélites de Teledetección presentando diversas características, arquitecturas y configuraciones mediante los cuales se están tomando datos de la superficie terrestre. Este conjunto de datos permiten ser analizados y explotados en muchas y variadas aplicaciones. En este procesado de la información, un factor que pasa inadvertido es comprobar y analizar la disposición de las bandas del sensor a través del estudio de la RSR del mismo. Como se ha podido comprobar este factor es importante a la hora de aplicar operadores y procesamientos basados en estadística de primer orden donde la distancia Euclídea es usada como métrica. Tal es el caso de los operadores de clasificación ISODATA o MD.

La principal contribución de este trabajo es el diseño de una metodología para reducir el efecto causado por el solapamiento espectral entre las bandas de un sensor. El método propuesto dispone las bandas en un espacio ortogonal aumentando la eficacia de los clasificadores basados en medidas de la distancia Euclídea. Todo el procedimiento queda reducido a una operación de multiplicación de matrices.

La metodología fue validada en primer lugar a través de sensores cuya RSR se simularon teniendo en cuenta las dos posibles soluciones (bandas solapadas o sin solapar). Sobre estos sensores los valores de energía reconstruidos mostraron valores mejor ajustados a los valores originales empleando un ajuste mínimo cuadrático. Trasladada la metodología a sensores reales, las imágenes procesadas por el método propuesto mostraron mejores resultados tanto en clasificadores no supervisados, como ISODATA, como en clasificadores supervisados como MD. Los experimentos realizados mostraron como la metodología planteada mejoraba los resultados en sensores de alta o muy alta resolución espacial. Sin embargo, no se apreciaron mejoras significativas en el caso de sensores con resolución espacial media debido en parte a la mezcla espectral presente en cada píxel.

Las mejoras en los resultados de clasificación estuvieron relacionadas con el porcentaje de píxeles sin clasificar. Esta metodología, consistente en trasladar las

bandas espectrales hacia un espacio ortogonal, permitiendo clasificar más píxeles y de una forma más exacta.

Por tanto, la metodología propuesta es adecuada para sensores de alta o muy alta resolución con bandas solapadas cuando estos son explotados mediante clasificadores basados en estadística de primer orden.

3.5 Referencias

Abrams, M., Hook, S., Ramachandram, B. (2003). Aster User Handbook, Jet Propulsion Laboratory. Pasadena CA: EROS Data Center.

Agüera, F., Liu, J. (2009). Automatic greenhouse delineation from QuickBird and Ikonos satellite images. *Computers and Electronics in Agriculture*, 66, 191-200.

ASTER Science Project. ASTER Science Project In: ASTER Science Project Office.

Bailey, G.B., Lauer, D.T., Carneggie, D.M. (2001). International collaboration: the cornerstone of satellite land remote sensing in the 21st Century. *Space Policy*, 17, 161-169.

Bouziani, M., Goïta, K., He, D.-C. (2010). Automatic change detection of buildings in urban environment from very high spatial resolution images using existing geodatabase and prior knowledge. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 143-153.

Carr, J.R. (1996). Spectral and textural classification of single and multiple band digital images. *Computers and Geoscience*, 22, 849-865.

Carter, A.J., Girina, O., Ramsey, M.S., Demyanchuk, Y.V. (2008). ASTER and field observations of the 24 December 2006 eruption of Bezymianny Volcano, Russia. *Remote sensing of Environment*, 112, 2569-2577.

Congalton, R.G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote sensing of Environment*, 37, 35-46.

Cook, M.K., Peterson, B.A., Dial, G., Gerlach, F., Hutchins, K., Kudola, R., Bowen, H. (2001). IKONOS technical performance assessment. *Proceedings of SPIE 4381*, 94-108.

Chikhaoui, M., Bonn, F., Bokoye, A.I., Merzouk, A. (2005). A spectral index for land degradation mapping using ASTER data: Application to a semi-arid Mediterranean catchment. *International Journal of Applied Earth Observation and Geoinformation*, 7, 140-153.

Dial, G., Bowen, H., Gerlach, F., Grodecki, J., Oleszczuk, R. (2003). IKONOS satellite, imagery, and products. *Remote sensing of Environment*, 88, 23-36.

Dial, G., Grodecki, J. (2003). Applications of IKONOS imagery. In

Dikshit, O., Behl, V. (2009). Segmentation-assisted classification for IKONOS imagery. *Journal of the Indian Society of Remote Sensing*, 37, 551-564.

Duan, F., Gong, H., Zhao, W. (2010). Collapsed houses automatic identification based on texture changes of post-earthquake aerial remote sensing image. In, *Geoinformatics, 2010 18th International conference on*, Beijing, 1-5.

Ehlers, M., Gaehler, M., Janowsky, R. (2006). Automated techniques for environmental monitoring and change analyses for ultra high-resolution remote sensing data. *Photogrammetric engineering and remote sensing*, 72, 835-840.

Elaksher, A.F. (2009). Using LIDAR-based DEM to orthorectify Ikonos panchromatic images. *Optics and Lasers in Engineering*, 47, 629-635.

Falkowski, M.J., Gessler, P.E., Morgan, P., Hudak, A.T., Smith, A.M.S. (2005). Characterizing and mapping forest fire fuels using ASTER imagery and gradient modeling. *Forest Ecology and Management*, 217, 129-146.

Farrel, M.D. (2005). On the impact of PCA dimension reduction for hyperspectral detection of difficult targets. *IEEE Geoscience and Remote Sensing letters*, 2, 192-195.

Fiorentino, C., Tarantino, C., Pasquariello, G., Basso, B. (2011). Improved method for discriminating agricultural crops using geostatistics and remote sensing. *Journal of Applied Remote Sensing*, 5, 535-536.

Foody, G.M. (2002). Status of land cover classification accuracy assessment. *Remote sensing of Environment*, 80, 185-201.

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

Galleguillos, M., Jacob, F., Prévot, L., French, A., Lagacherie, P. (2011). Comparison of two temperature differencing methods to estimate daily evapotranspiration over a Mediterranean vineyard watershed from ASTER data. *Remote sensing of Environment*, 115, 1326-1340.

Geoye (2012). In: www.geoeeye.com (último acceso 05-05-2012).

Goetz, S.J., Wright, R.K., Smith, A.J., Zinecker, E., Schaub, E. (2003). IKONOS imagery for resource management: Tree cover, impervious surfaces, and riparian buffer analyses in the mid-Atlantic region. *Remote sensing of Environment*, 88, 195-208.

Hinz, A., Dörstel, C., Heier, H. (2001). DMC-The digital sensor technology of Z/I-Imaging. In, D. Fritsch and R. Spiller (eds) *Photogrammetric Week '01*.

Hiroyuki, M., Xiaowei, S., Koki, I., Ryosuke, S. (2010). Global urban area mapping in high resolution using aster satellite images. *International archives of the photogrammetry, remote sensing and spatial information science*, 38, 847-852.

Hubbard, B.E., Crowley, J.K. (2005). Mineral mapping on the Chilean–Bolivian Altiplano using co-orbital ALI, ASTER and Hyperion imagery: Data dimensionality issues and solutions. *Remote sensing of Environment*, 99, 173-186.

Huiping, Z., Hong, J., Qinghua, H. (2011). Landscape and Water Quality Change Detection in Urban Wetland: A Post-classification Comparison Method with IKONOS Data. *Procedia Environmental Sciences*, 10, Part B, 1726-1731.

Jensen, J.R. (1996). *Introductory digital image processing: a remote sensing perspective*. Upper Saddle River, NJ: Prentice Hall.

Jimenez-Muñoz, J.C., Sobrino, J.A., Gillespie, A., Sabol, D., Gustafson, W.T. (2006). Improved land surface emissivities over agricultural areas using ASTER NDVI. New York, NY, ETATS-UNIS: Elsevier.

Jimenez, L.O., Landgrebe, D.A. (1999). Hyperspectral data analysis and feature reduction via projection pursuit. *IEEE Transactions on Geoscience and Remote Sensing*, 37, 2653-2667.

John, M. (2005). Stereo observation of lakes and coastal zones using ASTER imagery. *Remote sensing of Environment*, 99, 16-30.

Kaewpajit, S., Moigne, J.L., El-Ghazawi, T. (2003). Automatic wavelet spectral analysis for reduction of hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 41, 863-871.

Landsat 7 Science data users handbook. In <http://landsathandbook.gsfc.nasa.gov/> (último acceso 05-05-2012).

Liang, S. (2004). *Quantitative remote sensing of land surfaces*. New Jersey: John Wiley & Sons.

Llopis, M., Vidal, A., Hoyos, B. (2007). Multi-temporal classification for irrigation detection in the Vinalopó region in Spain using ASTER images. *Geoscience and Remote Sensing Symposium*, 3659-3662.

Madani, M., Shkolnikov, I. (2008). Increasing geometric accuracy of DMC's virtual images. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37, 19-26.

Morgan, J.L., Gergel, S.E., Coops, N.C. (2010). Aerial photography: a rapidly evolving tool for ecological management. *BioScience*, 60, 47-59.

Pieri, D., Abrams, M. (2004). ASTER watches the world's volcanoes: a new paradigm for volcanological observations from orbit. *Journal of Volcanology and Geothermal Research*, 135, 13-28.

Pour, A.B., Hashim, M. (2012). Identifying areas of high economic-potential copper mineralization using ASTER data in the Urumieh–Dokhtar Volcanic Belt, Iran. *Advances in Space Research*, 49, 753-769.

Quackenbush, L.J., Hopkins, P.F., Kinn, G.J. (2000). Developing forestry products from high resolution digital aerial imagery. *PE & RS- Photogrammetric Engineering & Remote Sensing*, 66, 1337-1346.

Ramesh, S., Scott, N.M. (2010). Improvements in mapping water bodies using ASTER data. *Ecological Informatics*, 5, 73-78.

Sánchez, C., Gladstone, C., Holland, D. (2007). Classification of urban features from Intergraph's Z/I Imaging DMC high resolution images for integration into a change detection flowline within Ordnance Survey. In, *Urban remote sensing joint event*, 1-8.

Schott, J.R. (1997). *Remote Sensing, the Image Chain Approach*. New York: Oxford University Press.

Sepulcre-Cantó, G., Zarco-Tejada, P.J., Jiménez-Muñoz, J.C., Sobrino, J.A., Soriano, M.A., Fereres, E., Vega, V., Pastor, M. (2007). Monitoring yield and fruit quality parameters in open-canopy tree crops under water stress. Implications for ASTER. *Remote sensing of Environment*, 107, 455-470.

Sohn, Y., Rebello, S. (2002). Supervised and unsupervised spectral angle classifiers. *Photogrammetric Engineering & Remote Sensing*, 68, 1271-1280.

Song, C., Dickinson, M.B., Su, L., Zhang, S., Yaussey, D. (2010). Estimating average tree crown size using spatial information from Ikonos and QuickBird images: Across-sensor and across-site comparisons. *Remote sensing of Environment*, 114, 1099-1107.

Stevens, N.F., Garbeil, H., Mouginis-Mark, P.J. (2004). NASA EOS Terra ASTER: Volcanic topographic mapping and capability. *Remote sensing of Environment*, 90, 405-414.

Suzuki, D., Yamazaki, F. (2008). Extraction of building damages in the 2007 Niigata-Ken Chuetsu-Oki earthquake using digital aerial images. In, *Asian Conference on Remote Sensing*, 12–16.

Trishchenko, A.P., Smacihlar, J., Li, Z. (2002). Effects of spectral response function on surface reflectance and NDVI measured with moderate resolution satellite sensors. *Remote sensing of Environment*, 81, 1-18.

Tso, B., Mather, P.M. (2001). *Classification Methods for Remotely Sensed Data*. London: Taylor and Francis.

Vicente, L.E., de Souza Filho, C.R. (2011). Identification of mineral components in tropical soils using reflectance spectroscopy and advanced spaceborne thermal emission and reflection radiometer (ASTER) data. *Remote sensing of Environment*, 115, 1824-1836.

Walsh, S.J., McCleary, A.L., Mena, C.F., Shao, Y., Tuttle, J.P., González, A., Atkinson, R. (2008). QuickBird and Hyperion data analysis of an invasive plant species in the Galapagos Islands of Ecuador: Implications for control and land use management. *Remote sensing of Environment*, 112, 1927-1941.

Wiersma, D.J., Landgrebe, D.A. (1980). Analytical design of multispectral sensors. *IEEE Transactions on Geoscience and Remote Sensing*, 18, 180-189.

Zhang, L., Gruen, A. (2006). Multi-image matching for DSM generation from IKONOS imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60, 195-211.

Zhang, X., Pazner, M., Duke, N. (2007). Lithologic and mineral information extraction for gold exploration using ASTER data in the south Chocolate Mountains (California). *ISPRS Journal of Photogrammetry and Remote Sensing*, 62, 271-282.

Capítulo 4

Combinación intensidad LiDAR con imágenes multiespectrales para discriminar usos de suelo agrícola

Resumen: En los últimos años estamos asistiendo a un aumento en el uso de nuevos dispositivos como cámaras aéreas digitales o sensores LiDAR aplicados a estudios de Teledetección. Esta situación ha favorecido el desarrollo de nuevas posibilidades en el uso de la información. Hoy día es una práctica común realizar vuelos combinados donde la cámara digital va registrando información espectral mientras que el sensor LiDAR produce nubes de puntos con información posicional, espectral y de ecos. El objetivo del trabajo presentado consiste en evaluar la posibilidad de combinar la intensidad LiDAR con la información espectral aportada por la cámara digital con la intención de incrementar la exactitud en los procesos de clasificación y detección de cultivos. A consecuencia de las características geométricas en el registro de datos LiDAR, la intensidad LiDAR se ha normalizado antes de combinarla con la información de la cámara para su posterior explotación. Para este propósito se emplearon dos métodos diferentes, ambos métodos se basaron en la posición relativa entre cada punto registrado y el sensor en el momento de la medición.

Para analizar los efectos de la normalización, se tomaron distintas muestras con distintos comportamientos radiométricos. Tales muestras se emplearon para evaluar el grado de variación de la intensidad para la misma zona geográfica registrada por distintas pasadas fotogramétricas a través de la comparación de los valores de intensidad iniciales y los normalizados. Posteriormente se empleó el clasificador de máxima probabilidad para analizar la adecuación de la combinación de la información de los dos sensores. Los resultados obtenidos se compararon con los obtenidos empleando solamente la información de la cámara, observándose como aumentaba la exactitud de la clasificación más de un 40% una vez introducida la intensidad LiDAR normalizada. La combinación de ambos sensores permitió la discriminación de ocho tipos de usos de suelo con una exactitud del 92%.

Palabras clave: cámara aérea digital, clasificación, intensidad, ortofoto, LiDAR.

4.1 Introducción

En los últimos años hemos asistido a numerosos avances tecnológicos en la forma de adquisición de información mediante el empleo de plataformas aéreas. Sin duda alguna uno de los desarrollos más notables ha sido la evolución de las cámaras fotogramétricas analógicas hacia soluciones digitales (Gruber et al. 2004), mejorando y cambiando flujos de trabajo, reduciendo los tiempos de respuesta en la producción y mejorando desde un punto de vista geométrico la exactitud posicional de los productos generados. A estas mejoras y beneficios de naturaleza geométrica y espacial hay que añadir la mejora en la radiometría de los datos facilitados, haciendo posible su empleo aplicando técnicas de teledetección (Markelin et al. 2010). No obstante, todavía no existen procedimientos estandarizados para calibrar y validar la información radiométrica en sistemas aerotransportados (Honkavaara et al. 2009; Markelin et al. 2008). Las imágenes obtenidas mediante cámaras digitales en la mayoría de los casos tienen una resolución espacial más alta que la resolución espacial de imágenes de satélite, siendo esta una de las mayores ventajas de las

cámaras aéreas. Sin embargo, la elevada resolución espacial de estas imágenes no siempre permite alcanzar buenos resultados en los procesos de clasificación, especialmente cuando se aplican técnicas de clasificación a nivel de píxel (Hsieh et al. 2001). A pesar de este inconveniente, estudios apoyados en datos procedentes de cámaras aéreas han permitido la discriminación de zonas forestales estudiando su estructura (Bunting et al. 2010; Pasher and King 2010) o discriminando usos de suelo tales como viñedos (Delenne et al. 2010).

Por otro parte, el sensor LiDAR (Light Detection and Ranging) ha llegado a consolidarse como uno de los sistemas más adecuados para la adquisición de información de la superficie topográfica. A partir de estudios de la propia tecnología LiDAR (Wehr and Lohr 1999), de su exactitud y precisión (Baltsavias 1999) así como de la calidad de los productos generados (Kraus et al. 2004) ha sido posible que la información obtenida mediante estos sensores se estén aplicando en un amplio y variado tipo de proyectos y aplicaciones. Los primeros estudios con datos LiDAR se centraron en la generación de modelos digitales del terreno (Kraus and Pfeifer 1998). Más adelante, las aplicaciones donde participa la explotación de datos LiDAR han ido aumentando, incluyendo inventarios forestales (Antonarakis et al. 2008; Bortolot and Wynne 2005; Harding et al. 2001; Popescu et al. 2002), generación de modelos de ciudades con fines de planificación urbanística (Zhou et al. 2004) o detección de edificaciones mediante técnicas de segmentación (Miliaresis y Kokkas 2007).

La combinación de los sensores LiDAR y cámara fotogramétrica ha mejorado notablemente los procesos de producción de ortofotografías (Habib et al. 2007; Kato et al. 2010; Keinan y Doytsher 2008). Debido a esto, cada vez es más frecuente el registro de información mediante vuelos combinados LiDAR-cámara digital. En cierto modo, el uso combinado de estos sensores invita a la aplicación de técnicas de teledetección sobre los datos obtenidos. Bajo este entorno de trabajo, el sensor LiDAR aportaría información sobre la geometría del fenómeno estudiado mientras que los datos de la cámara ofrecerían información sobre su comportamiento espectral (Persson et al. 2004). Algunos autores han combinado imágenes aéreas con medidas de altura aportadas por el sensor LiDAR para poder identificar árboles individuales en masas forestales (Suárez et al. 2005), clasificar zonas de pasto (Bork and Su 2007) o la determinación de parámetros biofísicos en coberturas de uso de

suelo (Arroyo et al. 2010). Estos trabajos ponen de manifiesto la sinergia existente entre la elevada resolución óptica de las cámaras digitales y los datos LiDAR (Hyppä et al. 2004), la cual puede ser dirigida hacia procesos de clasificación donde se mejoren los resultados de exactitud temática obtenidos.

Además de la información espacial un sensor LiDAR registra información relacionada con la reflectancia de los objetos; a este respecto la intensidad de la señal, también denominada intensidad reflejada, es equivalente a la energía de cada uno de los ecos registrados por el sensor. Desde un punto de vista técnico resulta compleja la transformación de los valores registrados por el sensor en valores de energía, entre otras muchas cosas debido a que la intensidad LiDAR no aparece descrita en detalle por los fabricantes. Este es uno de los posibles motivos por los que la mayoría de los trabajos de investigación se han centrado en la explotación de los datos desde un punto de vista geométrico mientras que las propiedades radiométricas no han sido bien comprendidas del todo (Yoon et al. 2008). Song et al. (2002) estudiaron la posibilidad de emplear la intensidad LiDAR en la clasificación de usos de suelo concluyendo que la normalización de los datos mejoró los resultados. Este estudio puso de manifiesto que valores de intensidad registrados en objetos similares presentaban diferencias apreciables posiblemente causadas por el ángulo de incidencia. Otros estudios se han dirigido hacia el estudio y análisis de la influencia de las características geométricas de las condiciones de la toma en la calidad de los datos registrados. Jutzi y Stilla (2006) establecieron una relación proporcional entre la intensidad LiDAR y el coseno del ángulo de incidencia y Coren y Sterzai (2006) determinaron que el efecto de ángulos de incidencia pequeños, próximos a 10° , es prácticamente inapreciable sobre la intensidad LiDAR. Luzum et al. (2004) previamente desarrollaron un método para corregir los valores iniciales de intensidad mediante la relación entre la altura de vuelo y los valores de altura de la superficie topográfica registrada.

La señal LiDAR cubre un intervalo de longitud de onda entre 800 nm y 1550 nm, el cual como puede observarse corresponde con el rango de longitud de onda del infrarrojo próximo (en adelante NIR). Gracias a esta información espectral, la intensidad LiDAR es útil para estudiar el comportamiento espectral de los fenómenos y elementos objeto de estudio. Debido al rango de longitud de onda en el que se

registra la intensidad, el sensor LiDAR es potencialmente útil para ser usado en el análisis de vegetación debido a que por una parte trabaja en la región del espectro del NIR y además es independiente a las condiciones de iluminación, nubes y sombras. Algunos estudios emplean la intensidad LiDAR para discriminar y clasificar copas de árboles individuales (Moffiet et al. 2005), para clasificar en una primera fase la nube de puntos LiDAR distinguiendo entre puntos terreno y puntos vegetación (Yunfei et al. 2008b) o para caracterizar zonas forestales a partir de la combinación de la información de intensidad y elevación (Wang y Glenn 2009). Sin embargo, no se ha aplicado la combinación de cámaras aéreas y LiDAR en zonas agrícolas del Mediterráneo.

El objeto del presente trabajo fue obtener mapas exactos de usos de suelo en zonas agrícolas del Mediterráneo. Para ello se establecieron tres objetivos:

- Evaluar los efectos de la normalización de la intensidad de cada punto empleando las características geométricas en el momento de la toma de estos. Los parámetros tenidos en cuenta fueron la distancia entre cada punto y el sensor así como el ángulo de barrido para su adquisición.
- Desarrollar una metodología para determinar los valores de intensidad a asignar a cada píxel en el proceso de rasterización de la nube de puntos LiDAR y de este modo poder combinarla como una nueva banda con las bandas espectrales registradas por la cámara aérea.
- Analizar los efectos de la combinación de la intensidad LiDAR con imágenes multiespectrales obtenidas mediante una cámara digital para identificar y cartografiar usos agrícolas empleando técnicas de clasificación a nivel de píxel.

4.2 Materiales

La zona de estudio se localizó en Lora del Río, en la provincia de Sevilla, Sur de España (coordenadas centrales 37°38'18.61"N, 5°32'03.57"W; WGS84). Dicha zona presenta un clima continental mediterráneo, caracterizado por largos veranos secos e inviernos moderadamente suaves. La zona de estudio presenta un relieve bastante suave, es una zona agrícola de cultivos de secano propios de Andalucía, con predominancia de cultivos herbáceos y en menor medida cultivos leñosos (Figura 4-1).




Figura 4-1 Vista general de la zona de estudio registrada por la cámara DigiCam H39.

El 15 de Junio de 2008 se realizó un vuelo combinado sobre la zona de trabajo con un total de diez pasadas. Los sensores, cámara y LiDAR, trabajaron de forma simultánea y sincronizada de tal modo que no se produjeron diferencias entre los dos conjuntos de datos registrados. La altura de vuelo fue de 1000 metros y el tamaño de píxel sobre el terreno fue igual a 12 cm. Los datos LiDAR se registraron empleando el sensor IGI LiteMapper 5600 (mbH 2012), sensor de múltiple retorno empleado para

el levantamiento de alta resolución de grandes superficies. El sensor fue configurado para registrar datos con un ángulo de escaneo de $\pm 30^\circ$ respecto del nadir. Las coordenadas x, y, z (este, norte y elevación) se fueron registrando junto con la intensidad de cada pulso en la región del NIR (1550 nm) con una resolución radiométrica de 16 bits. Adicionalmente, toda la información auxiliar registrada por el sensor también se almacenó (ángulo de escaneo, tiempo GPS, pasada, etc.) Las exactitudes de cualquier punto de la superficie topográfica, horizontal / vertical, al margen de los errores introducidos por el sistema GPS, fueron de 0.08 m y 0.03 m respectivamente. La densidad de puntos fue igual a 3.5 puntos por metro cuadrado. La cámara empleada fue una DigiCam H39 (mbH 2012) la cual puede trabajar con dos posibles configuraciones desde un punto de vista espectral: Rojo-Verde-Azul (RGB) y en modo falso color (CIR). Para el presente estudio se empleó la configuración en modo CIR, registrando la información entre bandas espectrales correspondientes con el canal verde (de 500 a 620 nm), rojo (de 580 a 800 nm) e infrarrojo próximo (de 800 a 1000 nm). Se seleccionó el modo CIR debido al alto porcentaje de vegetación presente en los usos de suelo estudiados. El vuelo se realizó con un solape longitudinal del 60 % y uno transversal igual al 50 %. Además de los dos conjuntos de datos registrados por ambos sensores no menos importante fue el registro de la trayectoria del avión, la cual fue empleada posteriormente en los procesos de normalización para determinar la relación entre cada punto LiDAR y el sensor en el momento de su registro.

El vuelo combinado fue realizado por parte de la Consejería de Agricultura y Pesca de la Junta de Andalucía. El objetivo por el cual se realizó dicho vuelo fue para el control en el cumplimiento de las medidas adoptadas según la política agraria comunitaria. Cada uno de los fotogramas del vuelo se ortorectificó con un tamaño de píxel igual a 0.5 m. Posteriormente se procedió al mosaicado y balanceado radiométrico con el fin de obtener una única ortofotografía. Todo el proceso fotogramétrico se realizó con Match-AT, Orthomaster y Orthovista (Inpho 2012). Match-AT se empleó para el cálculo de la aerotriangulación. Orthomaster se usó para la ortorectificación de cada uno de los fotogramas y Orthovista se utilizó para ajustar y mosaicar las distintas ortofotografías individuales. Todo el proceso y tratamiento realizado sobre las imágenes tiene como consecuencia que la información espectral recogida por la cámara se vaya degradando a lo largo de la producción de una

ortofotografía, perdiendo todo significado físico la información almacenada en un píxel. La consecuencia de esto es que la clasificación de usos de suelo se verá dificultada en cierto modo debido a que el mismo uso de suelo no tiene por que mostrar el mismo comportamiento sobre la imagen. Sin embargo, los valores de intensidad LiDAR con los que se trabaja son directamente los registrados por el sensor.

A consecuencia de la gran cantidad de puntos registrados por el sensor LiDAR, el trabajo se desarrolló sobre un área reducida de toda la zona de vuelo. Se manejaron un total de cinco millones de puntos LiDAR, correspondientes a una sección de la ortofotografía de dimensiones equivalentes a 1700×2940 píxeles, equivalentes a 125 hectáreas del total del área volada. Del total de la superficie de estudio los cultivos herbáceos ocuparon el 40% de esta área, cultivos leñosos, concretamente plantaciones de naranjos (*Citrus sinensis*) ocuparon el 25% del total de la superficie y un 33% de la superficie correspondieron con otros suelos agrícolas. La categoría de suelos agrícolas comprendieron tanto rastrojos como suelos desnudos. En el caso de los suelos desnudos estos mostraron diferentes características radiométricas debido a diferencias en su composición química, orgánica o sus propiedades geológicas. Debido a esto, esta clase fue descompuesta en dos categorías: suelos desnudos claros y oscuros. El resto de la zona de estudio, correspondiente al 2% del área de la zona de trabajo recogió las clases carreteras, caminos y edificaciones. Bajo este escenario se consideraron ocho usos de suelo diferentes:

- Cultivos herbáceos, siendo estos maíz (*Zea mays*), girasol (*Helianthus annuus*) y algodón (*Glossypium hirsutum*).
- Cultivos leñosos correspondientes con plantaciones de naranjos (*Citrus sinensis* L.).
- Rastrojos de cereales de invierno (principalmente trigo, *Triticum durum* L.).
- Suelo desnudo oscuro.
- Suelo desnudo claro.

- Caminos.
- Carreteras.
- Edificios.

Mediante análisis visual se reconocieron los distintos usos de suelo presentes en la zona de trabajo. Se realizó un muestreo estratificado aleatorio para poder determinar la verdad terreno, permitiendo validar posteriormente los procesos de clasificación. Para ello en primer lugar se fotointerpretó la ortofotografía dividiendo esta en estratos los cuales fueron muestreados aleatoriamente con posterioridad. Un total de 20 hectáreas fueron marcadas e identificadas en alguna de las clases definidas. 9 hectáreas de esta superficie (Figura 4-2.a) se emplearon para recoger las firmas espectrales para la fase de entrenamiento. Las 11 hectáreas restantes se emplearon para determinar la exactitud de las clasificaciones realizadas (Figura 4-2.b) El número de muestras obtenidas satisfizo el número mínimo de muestras en el peor de los escenarios siguiendo una distribución multinomial (Congalton y Green 2009). Las muestras fueron polígonos cuyo tamaño y forma dependieron de las propias características de los usos de suelo. En el caso de los cultivos leñosos se muestrearon empleando un clúster de 3×3 píxeles a fin de facilitar los trabajos de muestreo.

Tabla 4-1: Resumen de las muestras usadas en los procesos de entrenamiento y validación en los procesos de clasificación.

	Muestras de entrenamiento		Muestras de validación	
	Núm. muestras	Tamaño medio (m^2)	Núm. muestras	Tamaño medio (m^2)
Cultivos herbáceos	34	1279	61	1412
Cultivos leñosos	399	2,25	548	2,25
Rastrojos	12	21	20	19
Suelos desnudos oscuros	4	1825	8	1950
Suelos desnudos claros	10	254	14	351
Caminos	4	400	6	350
Carreteras	4	301	5	400
Edificaciones	4	271	7	189

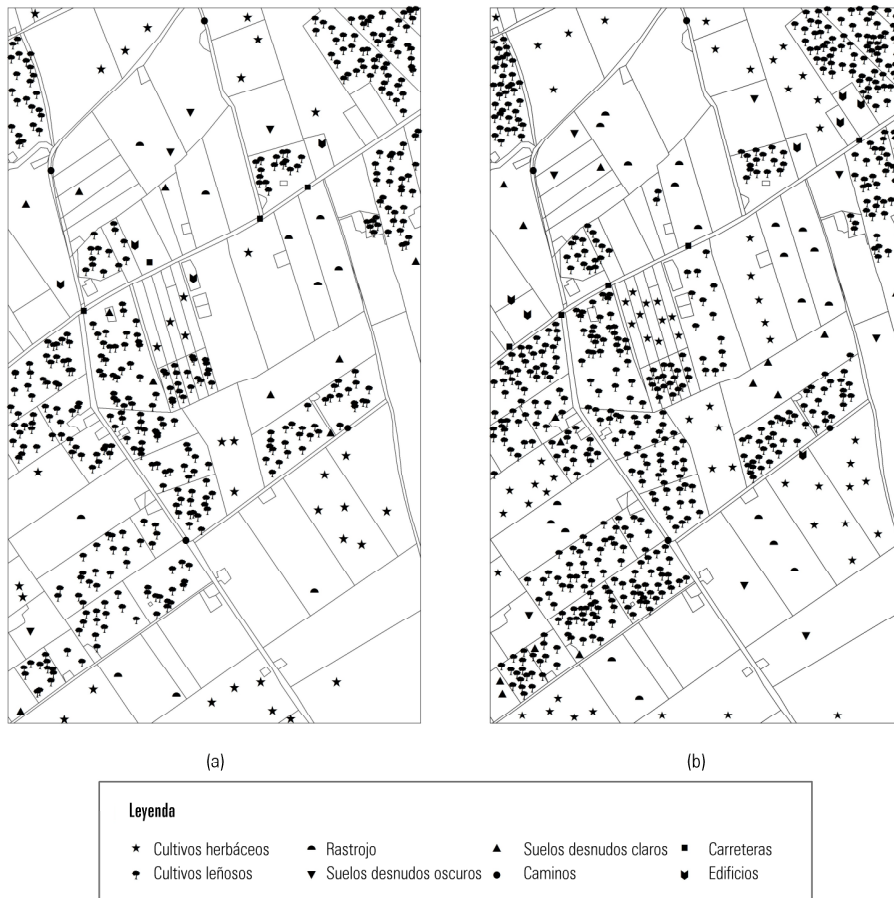


Figura 4-2 Distribución de los centroides de las áreas muestreadas: (a) muestreo de entrenamiento y (b) muestreo de validación.

4.3 Métodos

4.3.1 Combinación de información vectorial LiDAR con imágenes digitales

Debido a que el último objetivo de este estudio era la combinación de nubes de puntos LiDAR (datos vectoriales) con ortofotografías (datos raster) a modo de nueva banda, los datos LiDAR se sometieron a un proceso de rasterización teniendo en cuenta la misma resolución espacial de la ortofotografía 0.5 metros. Esta combinación se llevó a cabo en dos etapas considerando que la información empleada procede de un sensor LiDAR de retorno discreto el cual registra de uno a cuatro ecos por punto durante el vuelo. Con este tipo de sistemas, un pulso origina un único retorno el cual será entendido como el primero y el último eco simultáneamente. Retornos múltiples consistirán en un primer, último e intermedios retornos (Korhonen et al. 2011). En la primera etapa, se eliminaron todos aquellos puntos no pertenecientes a un primer retorno o a retornos únicos (Donoghue et al. 2007). El motivo de esta decisión quedó fundamentada en el hecho de que los puntos más bajos aparecen ocultos por los puntos más altos y por tanto su información no se corresponde con la registrada por la cámara digital durante el vuelo al no tener esta la capacidad de penetración. Con los puntos seleccionados se realizó un segundo procedimiento de filtrado. En este caso se analizaría la altura de los puntos pertenecientes al mismo píxel con el objetivo de determinar si pertenecían al mismo uso de suelo o no. Si hubiera distintos puntos recogidos en el interior de un píxel y todos ellos pertenecieran al mismo uso de suelo la diferencia de altura entre el punto más alto y más bajo será pequeña. Este requisito implica el establecimiento de un umbral como medida para definir la máxima diferencia en altura entre los puntos del interior de un píxel para ser considerados del mismo uso de suelo. El procedimiento empleado para cada píxel consistió en calcular la diferencia de altura entre el punto más alto y el punto más bajo. Si esta diferencia era menor que el umbral predeterminado se consideraba que estos pertenecían al mismo uso de suelo, empleando el valor medio de las intensidades como valor del píxel (Figura 4-3.a). En

caso contrario, el punto de menor altura era eliminado de forma progresiva hasta que la diferencia de alturas fuera menor que el umbral establecido (Figura 4-3.b). El umbral establecido resultó igual a 0.5 metros, coincidente con la altura media del algodón en el momento de la realización del vuelo. En el proceso de rasterización aparecieron píxeles sin ningún punto LiDAR en su interior. A estos píxeles se les asignó como valor el valor medio de los ocho píxeles más cercanos usando para ello un filtro de 3×3 .




Figura 4-3 Análisis de la diferencia de altura entre puntos dentro de un mismo píxel en la etapa de filtrado. Puntos LiDAR pertenecientes a (a) una única clase de uso de suelo y (b) dos clases de suelo diferente

Para la realización del proceso de filtrado y rasterización de la nube de puntos se desarrolló una aplicación a tal efecto en Visual Studio 2005. En primer lugar fue necesario desarrollar una módulo de entrada / salida de datos. El formato seleccionado para la manipulación y tratamiento de los datos fue el formato LAS v 1.0. Este formato de archivo consiste en un formato público para el intercambio de nubes de puntos tridimensionales. El Anexo 2.1 presenta el código para la lectura de

dicho tipo de formato. A fin de optimizar el código desarrollado se definieron tres estructuras de datos. La primera de ellas contiene la definición de los variables referentes a la cabecera del archivo. La segunda estructura de datos contiene la definición de las variables referentes a la información de un punto. En ella aparecen definidas variables como las coordenadas, el número de retornos, ángulo de escaneado o el tiempo GPS entre otros. La última estructura definida estuvo dedicada a los posibles registros de longitud variable que pueden aparecer en un archivo de datos. El procedimiento READ_LAS contiene el código para la lectura del fichero de puntos en formato LAS, dicho procedimiento es empleado por las distintas rutinas de filtrado y normalización desarrolladas.

En el Anexo 2.2 se presenta el código para el filtrado de puntos según la lógica establecida anteriormente. El proceso aparece representado en el diagrama de flujo de la Figura 4-4. El primer paso consiste en ordenar los puntos según su posición sobre una matriz de datos regular. Para ello se optó porque el usuario definiera en pantalla las coordenadas del rectángulo envolvente así como la resolución espacial de la matriz. Se optó por esta opción en vez de trabajar con las coordenadas máximas y mínimas de las componentes x e y de los puntos presentes en la nube de puntos a fin de garantizar que posteriormente en la rasterización de la nube de puntos, la nueva banda generada presentase exactamente las mismas dimensiones y coordenadas que las presentadas por la ortofotografía empleada. De este modo el proceso recorre la lista de puntos presentes en el fichero, para cada punto se consulta si este se corresponde con un primer retorno o es un único retorno. En caso de no cumplir ninguna de las características anteriores el punto es descartado, por el contrario si cumple alguna de estas condiciones se mantiene. Una vez terminado este proceso el producto obtenido es una nueva nube de puntos con tan solo puntos de primer retorno o único retorno. Esta nube de puntos es recorrida en su totalidad determinando para cada punto la fila y columna a la que pertenece a partir de la relación de las coordenadas de la esquina superior izquierda de la imagen y el tamaño de pixel definidos por el usuario en pantalla. Previamente se habrá inicializado una lista de listas de dimensiones igual a las dimensiones de la imagen. Cada punto se irá almacenando en cada una de las listas a partir de su posición. Como resultado cada lista contendrá un conjunto de puntos que se corresponde con los puntos presentes dentro de cada pixel de la imagen. El último paso consiste en determinar el

valor de intensidad de cada pixel. Tal valor se corresponderá con el valor medio de intensidad determinado a partir de la media de intensidad de cada una de las listas determinadas anteriormente. Se recorrerán todas las listas generadas. Para cada lista se determina los puntos de cota máxima y mínima, calculando el desnivel entre estos. Si este desnivel supera el umbral definido por el usuario se descarta el punto de cota mínima y se localiza el siguiente punto de cota mínima. El proceso se repetirá hasta que el desnivel entre los puntos extremos sea igual o inferior al valor definido por el usuario. Cada lista contendrá uno o más de un punto. Con cada conjunto de puntos se determina el valor de intensidad medio. La salida es un fichero ASCII con el formato *x,y e intensidad*. Las coordenadas *x,y* se corresponden con las coordenadas del pixel de la imagen. Este tipo de formato es leído por cualquier software de Sistemas de Información Geográfica.

La información generada se procedió a rasterizarla. En este proceso directamente se asigna como valor de pixel el valor almacenado en el fichero. Puede darse el caso que aparezcan píxeles que no presenten valor de intensidad que se les pueda asignar. Este tipo de píxeles en un primer momento se les asigna el valor *nodata*. De esta forma se podrá localizar estos para posteriormente tratarlos. Sobre la imagen de intensidades generada se aplicó un filtro de media. Esta imagen es empleada para asignar valor a aquellos píxeles que presenta un valor *nodata*, realizando tal proceso mediante la aplicación de una máscara.

El resultado de todo el proceso es una imagen de intensidades LiDAR con las mismas dimensiones y coordenadas que la ortofotografía empleada. Los valores de intensidades LiDAR de cada pixel serán iguales a los valores medios de los puntos más elevados, correspondiéndose estos con los fenómenos registrados con la cámara.

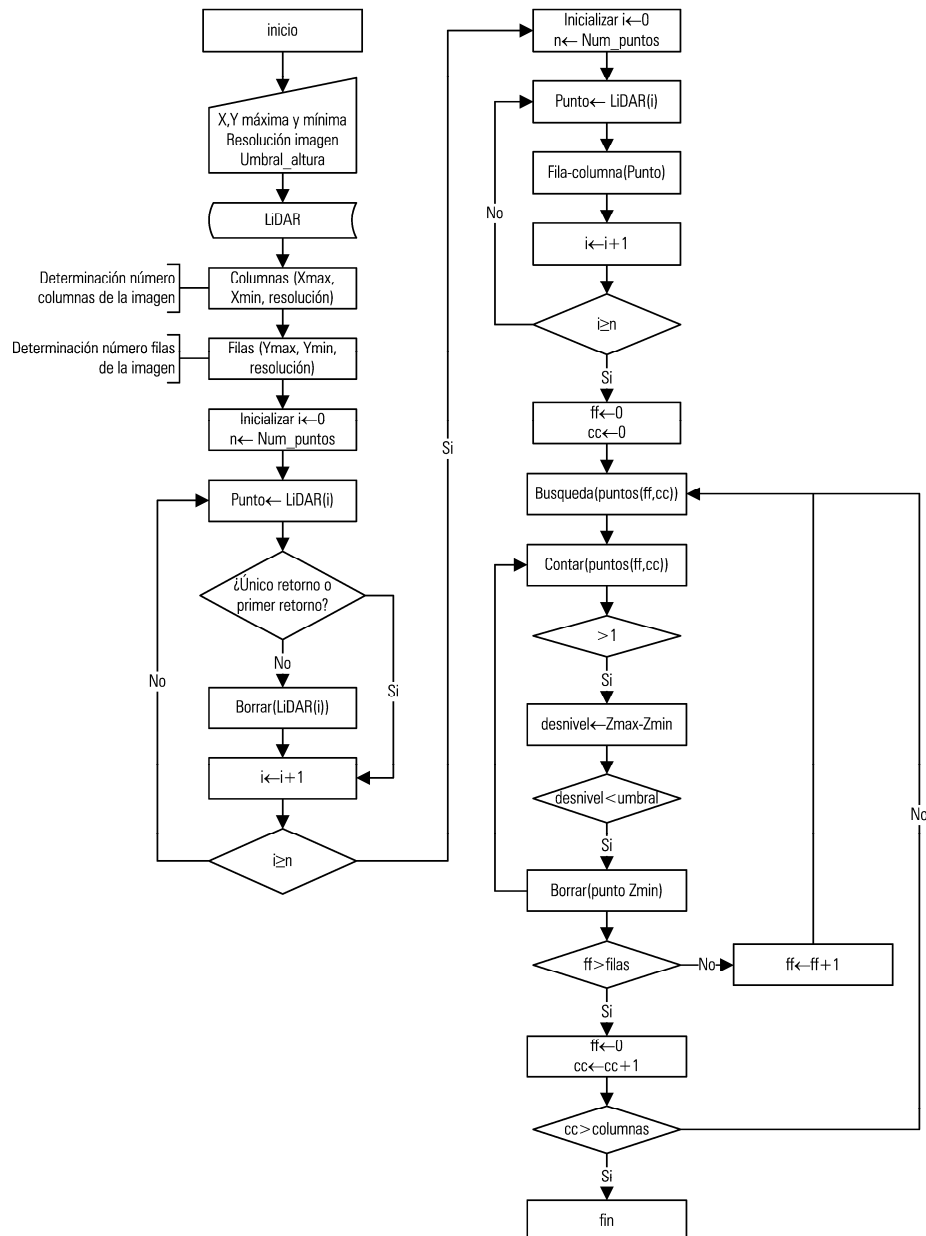


Figura 4-4 Diagrama de flujo para el filtrado de puntos teniendo en cuenta máximo umbral en altura entre puntos contenidos en un mismo píxel.

4.3.2 Normalización de la intensidad

La intensidad registrada por el sistema LiDAR se corresponde con la cantidad de energía reflejada por la huella del haz de rayo al contacto con la superficie del terreno o de un objeto sobre esta. Esta intensidad es función de muchas variables tales como la potencia del láser, la reflectividad del objeto, la absorción atmosférica y la distancia entre el sensor y el objeto (Coren y Sterzai 2006). El sistema LiDAR registra variaciones en los valores de intensidad tomados para un mismo punto dependiendo de las condiciones de captura. Debido a esto se hace necesario normalizar los valores de intensidad para poder comparar y explotar la información registrada por el sistema LiDAR en las distintas pasadas de un vuelo fotogramétrico. El método más sencillo consiste en aplicar una normalización teniendo en cuenta la distancia sensor-objeto, esta normalización se basa en el hecho de que la intensidad registrada por el sensor LiDAR está directamente relacionada con la intensidad y la reflectividad del objeto registrado. Para un objeto homogéneo, la intensidad registrada es inversamente proporcional al cuadrado de la distancia entre el punto y el sensor (Baltasvias 1999). Por tanto, cuando se compara esta con una distancia de referencia el resultado es:

$$I(R)_{normalizada} = I \cdot \frac{R^2}{R_{referencia}^2} \quad \text{Ec. 4-1}$$

Siendo:

- $I(R)_{normalizada}$ el valor de la intensidad normalizada.
- I la intensidad registrada por el sensor LiDAR.
- R la distancia entre el punto y el sensor LiDAR
- $R_{referencia}$ la distancia de referencia. Como distancia de referencia se empleó la altura de vuelo.

Este método de normalización fue aplicado por (Donoghue et al. 2007) eliminando el efecto de la trayectoria de vuelo y obteniendo valores equivalentes de la intensidad si todos los puntos hubieran sido registrados a la misma distancia del sensor. Tal estudio consideró la geometría de la nube de puntos, determinando la distancia exacta entre el objeto y el sensor a partir de la trayectoria de vuelo. Dicho proceso se desarrolló empleando el tiempo GPS que aparece junto con otra información auxiliar cuando el sistema LiDAR almacena un punto. Empleando este parámetro, se localiza en la trayectoria de vuelo las dos posiciones del sensor LiDAR que cubren el intervalo de tiempo en el que registra el punto. La determinación exacta del sensor se obtiene mediante la interpolación de las dos posiciones del sensor. Para cada punto, empleando su posición y la posición interpolada del sensor se determina la distancia R . En el caso de no tener información de la trayectorias de vuelo se puede tomar como aproximación la determinación de R empleando la diferencia entre la altura media de vuelo y la altura de cada punto (García et al. 2010).

El ángulo de incidencia del rayo es otro factor a tener en cuenta también en el proceso de normalización de los valores de intensidad LiDAR. La ley del coseno de Lambert (Burgess et al. 2011) establece que la emisión total de una superficie en cualquier dirección es directamente proporcional al coseno del ángulo de incidencia, por ejemplo, el ángulo entre la normal a la superficie y el rayo de incidencia. El efecto del ángulo de incidencia sobre el valor de la intensidad es denominado efecto topográfico. Höfle y Pfeifer (2007) detallan los principios físicos de la intensidad LiDAR teniendo en cuenta el efecto topográfico, estableciendo:

$$I(R)_{normalizada} = I \cdot \frac{R^2}{R_{referencia}^2} \cdot \cos \alpha \quad \text{Ec. 4-2}$$

Siendo:

- $I(R)_{normalizada}$ el valor de la intensidad normalizada.
- I la intensidad registrada por el sensor LiDAR.

- R la distancia entre el punto y el sensor LiDAR
- $R_{referencia}$ la distancia de referencia.
- α el ángulo de incidencia.

Como puede observarse en la Figura 4-5, si la superficie es completamente horizontal, el ángulo de escaneo coincidirá con el ángulo de incidencia tal y como muestra el rayo R_1 . Sin embargo, si la superficie presenta una determinada inclinación, como ocurre con R_2 , ambos ángulos no serán iguales. La zona de estudio presentaba un relieve muy suave con una pendiente media alrededor del 1%, de este modo el ángulo de escaneo y el ángulo de incidencia fueron prácticamente iguales. Por este motivo, el ángulo de escaneo se consideró igual al ángulo de incidencia, no teniéndose en cuenta la orientación de la superficie.




Figura 4-5 Relación entre el ángulo de incidencia del rayo y el ángulo de escaneo del sensor LiDAR.

El Anexo 2-3 recoge el código desarrollado para realizar la normalización de los valores de intensidad LiDAR de un conjunto de puntos. El procedimiento comienza solicitando al usuario el fichero que contiene los puntos LiDAR así como la ruta donde se almacena la trayectoria seguida por el avión durante el vuelo. De forma automática se realizan dos copias del fichero inicial LiDAR, siendo renombrados

según el tipo de normalización a desarrollar: distancia o distancia y ángulo. Una vez leída la cabecera del archivo LAS se procede a leer cada uno de los puntos. En cada punto se buscan las dos posiciones del avión que cubren temporalmente el instante en el que fue tomado el punto. Todo ello se realizará mediante la comparación de la lectura del tiempo GPS almacenado en el punto y los tiempos GPS de la trayectoria del avión. A partir del conocimiento de estas dos posiciones se determina mediante interpolación la posición exacta del avión en relación al tiempo GPS en el que se registra el punto. A partir de la determinación de las coordenadas del avión y del punto es posible determinar la distancia entre ambos. A partir de esto el algoritmo ya puede determinar el valor de la intensidad normalizada. Para ello en el caso de la determinación de la intensidad normalizada en base a la distancia el procedimiento empleará como distancia de referencia para la normalización la altura de vuelo, la cual es introducida en pantalla por el usuario. En el caso de la normalización por el ángulo el procedimiento además de los datos anteriores empleará el valor del ángulo de escaneado almacenado también para cada punto en el archivo de puntos. Cada valor de intensidad normalizado será almacenado en su correspondiente copia realizada al inicio del archivo original, reemplazando el valor original por el calculado. Este proceso se lleva a cabo en paralelo de modo que se consigue minimizar los tiempos de procesado.

4.3.3 Evaluación del efecto de la normalización

Una vez normalizados los valores de intensidad se procedió inicialmente a realizar una inspección visual, la cual aportaría una primera impresión y valoración de los efectos del proceso de normalización. Después de esta inspección, se realizó un análisis estadístico calculando el coeficiente de variación de la intensidad de un conjunto de puntos localizados sobre el mismo área geográfica y pertenecientes a diferentes pasadas. Se determinaron seis usos de suelo con diferente comportamiento espectral de los ocho establecidos sobre la zona. Se tomaron muestras sobre la zona de trabajo con el objeto de confirmar si la variación en los valores de intensidad era menor en los valores normalizados que en los valores originales registrados por el sensor. Tales usos se correspondieron con cultivos herbáceos, cultivos leñosos, suelos agrícolas, caminos, carreteras y edificaciones. En

esta fase las clases rastrojo, suelo desnudo oscuro y suelo desnudo claro fueron agrupadas en la misma categoría denominada suelos agrícolas debido a que presentaban unos valores de intensidad LiDAR muy parecidos. Las seis clases quedaron agrupadas en dos grupos en función de su variabilidad espectral interna. El primero de los grupos recogió aquellas muestras tomadas en categorías con una baja variación de los valores de intensidad debido a que no presentaban mezcla de usos de suelo. El otro grupo incluyó muestras tomadas en la categoría de usos agrícolas, englobando las clases rastrojo y suelos desnudos oscuros y claros. Los valores de intensidad de estas muestras a priori presentaban valores más elevados de desviación estándar debido a que presentaban sombras o mezcla de usos de suelos. El análisis se llevó a cabo empleando un total de veinte muestras por uso de suelo, con una superficie de diez metros cuadrados por muestra, repartidas de forma homogénea por la zona de trabajo. Las muestras fueron evaluadas teniendo en cuenta las tres modalidades en las que se puede presentar la intensidad: original del sensor, normalizada por la distancia y normalizada por la distancia y el ángulo. En este análisis siempre se emplearon los mismos puntos en cada modalidad. Cada muestra estuvo compuesta por puntos pertenecientes a distintas pasadas. Se calculó el coeficiente de variación de cada muestra como la razón entre la media y la desviación estándar de los valores de intensidad. Se llevó a cabo un primer análisis para determinar si el coeficiente de variación era más bajo en los valores de intensidad normalizados por la distancia (Ec. 4-1) o normalizada por los valores de distancia y ángulo (Ec. 4-2).

El objetivo de este análisis fue comparar los coeficientes de variación de las muestras dependiendo si estas estaban o no normalizadas y mostrar si el coeficiente de variación era menor si los datos eran normalizados. En caso afirmativo tal aspecto podría sugerir, a priori, que los valores de intensidad normalizados eran más homogéneos y podrían mejorar la caracterización e identificación de usos de suelo.

4.3.4 Clasificación y calidad

Cada escenario se clasificó empleando el algoritmo de máxima probabilidad (Strahler 1980) para poder determinar la idoneidad de la combinación de la intensidad LiDAR con imágenes digitales. El algoritmo de máxima probabilidad asigna un píxel a la clase más probable, todo ello minimizando la probabilidad de cometer un error usando la teoría bayesiana. Para ello el algoritmo trabaja usando el vector de medias y la matriz de covarianza calculados a partir de las firmas espectrales de las muestras de entrenamiento tomadas para cada clase. Para esta evaluación se emplearon todas las categorías, ocho, presentadas anteriormente en la zona de estudio. No fue posible diferenciar determinadas características en suelos agrícolas tales como materia orgánica, minerales o restos de cultivos empleando datos LiDAR dado que presentaron una respuesta muy similar. Sin embargo, la información espectral de la cámara, configurada en modo CIR, hizo posible dividir la categoría de suelos en tres categorías más específicas.

El análisis de los resultados de las clasificaciones consistió en evaluar la habilidad por parte del clasificador para diferenciar y caracterizar usos de suelo considerando cuatro escenarios diferentes. En cada escenario, la información procedente de la cámara digital, a modo de ortofotografía, fue empleada como base para todas las clasificaciones. A esta imagen de partida se añadió los datos de intensidad LiDAR con distintos grados de tratamiento. Los escenarios definidos fueron:

- Escenario 1: Formada solamente por la ortofotografía.
- Escenario 2: Constituida por la ortofotografía y los datos de intensidad LiDAR brutos.
- Escenario 3: Comprende la ortofotografía y los datos de la intensidad LiDAR normalizados en base a la distancia.
- Escenario 4: Compuesto de la ortofotografía y los datos de intensidad LiDAR normalizados por ángulo y distancia.

Sobre cada uno de los resultados de clasificación obtenidos se aplicó un filtro de mayoría de 3×3 a fin de reducir el efecto de sal y pimienta sobre los resultados.

Cualquier estimación subjetiva de la clasificación se evitó, determinando y analizando a tal efecto la matriz de confusión. A partir de ella se determinó la calidad de los resultados comparando el porcentaje de píxeles clasificados de cada clase con los determinados por la verdad terreno, obteniendo en consecuencia una correcta valoración del proceso así como los errores de las clases estudiadas (Congalton 1991). La matriz de confusión permite determinar el porcentaje de acuerdo (en adelante Pa), la exactitud usuario (en adelante EU) y la exactitud productor (en adelante EP) (Rogan et al. 2002). El Pa de una clasificación indica el porcentaje de píxeles correctamente clasificados (Ec. 3-32). La EU indica la pureza de la clase, correspondiéndose con el porcentaje de píxeles de una clase que aparecen correctamente clasificados:

$$EU(i) = \frac{x_{i,i}}{n_{i+}} \quad \text{Ec. 4-3}$$

Siendo:

- $x_{i,i}$ número de píxeles clasificados en la clase i .
- n_{i+} el total de casos de la clase i .

La EP refleja el porcentaje de píxeles de muestreo de verificación que se han clasificado correctamente dentro de una clase determinada:

$$EP(j) = \frac{x_{j,j}}{n_{+j}} \quad \text{Ec. 4-4}$$

Siendo:

- $x_{j,j}$ número de píxeles clasificados en la clase j .
- n_{+j} total de casos verdad terreno de la clase j .

El análisis de estos parámetros permitió cuantificar el grado de coincidencia entre cada una de las clasificaciones realizadas y la realidad.

4.4 Resultados

4.4.1 Evaluación del efecto de la normalización

En primer lugar se analizaron visualmente las imágenes de intensidad LiDAR en sus tres modalidades: original obtenida por el sensor, normalizada por distancia y normalizada por distancia y ángulo. La zona seleccionada fue un área donde aparecían distintas pasadas solapadas (Figura 4-6.a). La imagen correspondiente a los valores de intensidad originales claramente mostró la línea de separación correspondiente al contacto entre dos pasadas, remarcándose un cambio en la tonalidad debido a la variación entre los valores registrados en distintas pasadas (Figura 4-6.b). Sin embargo, cuando los valores de intensidad fueron normalizados por la distancia o la distancia y el ángulo (Figura 4-6.c y Figura 4-6.d), la línea de corte anteriormente mencionada apareció más desvanecida y con menor contraste. A priori, los valores de intensidad mostraron menor variación entre pasadas.




Figura 4-6 Comparativa de los resultados de rasterización de los valores de intensidad LiDAR. (a) ortofoto y rasterización de la intensidad en modo (b) bruto, (c) normalizada por la distancia y (d) normalizada por la distancia y el ángulo.

La Figura 4-7 presenta los coeficientes de variación de los valores de intensidad LiDAR para cada una de las veinte muestras analizadas por uso de suelo. El gráfico de barra representa el coeficiente de variación obtenido en el caso de manejar los datos originales obtenidos directamente del sensor LiDAR. Los gráficos de líneas reflejan los valores de intensidad normalizada empleando los dos métodos de normalización considerados (distancia y distancia – ángulo). En el caso de las carreteras (Figura 4-7.e) y edificaciones (Figura 4-7.f), los coeficientes de variación de cada muestra fueron siempre más bajos una vez que la intensidad era normalizada, no observándose diferencias en cuanto el método de normalización empleado. Las clases caminos (Figura 4-7.d) y suelos agrícolas (Figura 4-7.c) presentaron de forma general una reducción en el coeficiente de variación una vez que la intensidad era normalizada, sin bien algunas muestras en particular mostraron un ligero aumento. Este grupo de usos de suelo, caminos y suelos agrícolas, mostraron valores de coeficiente de variación superiores a los obtenidos en las clases edificaciones y carreteras. La causa la encontramos en el hecho de que las muestras de las primeras implican la presencia de elementos que pueden pertenecer

a distintas clases, lo cual provoca que los valores de intensidad sean más heterogéneos. En el caso de la clase de cultivos leñosos (Figura 4-7.b) los coeficientes de variación calculados se mantuvieron constantes, independientemente si la intensidad era normalizada o no. Tal explicación la encontramos en el hecho de la heterogeneidad de las muestras con una presencia muy acusada de distintos elementos que origina que aparezcan valores de desviación estándar que enmascaran los posibles efectos de la normalización. Por el contrario, en el caso de los cultivos herbáceos (Figura 4-7.a) se obtuvieron valores de coeficiente de variación más bajos de los esperados. En este caso la explicación reside en el hecho de que las muestras se localizaron sobre zonas con una elevada densidad del cultivo, aspecto representativo de estos cultivos sobre la zona de estudio. De este modo, las muestras presentaron una respuesta muy uniforme.

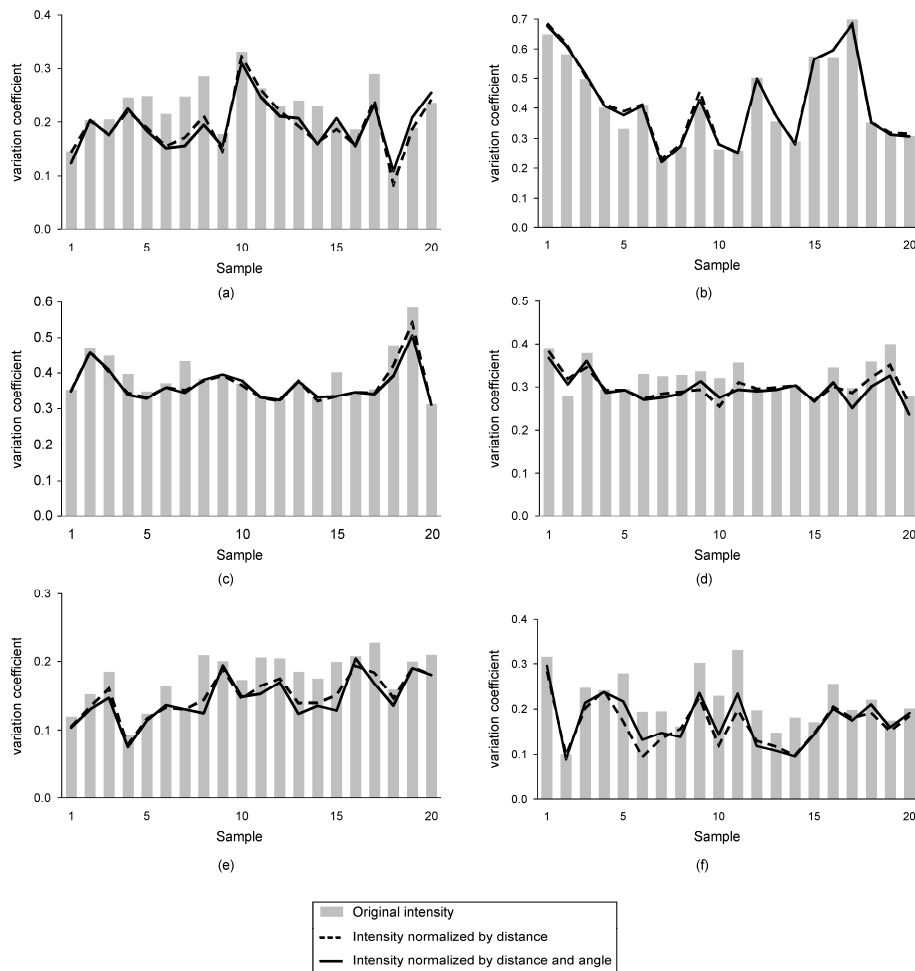


Figura 4-7 Comparativa del coeficiente de variación en los valores de intensidad LiDAR de distintas pasadas sobre los usos de suelo: (a) cultivos herbáceos, (b) cultivos leñosos, (c) suelos agrícolas, (d) caminos, (e) carreteras y (f) edificaciones.

Estos resultados mostraron como tanto desde un punto de vista visual como analítico, comparando los valores de coeficientes de variación, los valores de intensidad a priori resultaron ser más homogéneos entre pasadas de un vuelo una vez que estos eran normalizados. Al mismo tiempo se puso de manifiesto que no se apreciaban diferencias significativas entre los dos métodos posibles de normalización de la intensidad.

4.4.2 Clasificación de usos de suelo

Una vez estudiados los efectos de los procesos de normalización sobre los valores de intensidad LiDAR, cada uno de los escenarios generados se clasificaron, empleando para el ello el algoritmo de máxima probabilidad, a fin de determinar los usos de suelo presenten en la zona de estudio. La realización de estas clasificaciones tuvo un doble propósito:

- Evaluar si la incorporación de la intensidad LiDAR a los datos multiespectrales procedentes de una cámara aporta información útil para la caracterización de usos de suelo.
- Verificar si la normalización de los valores de intensidad además mejoran los resultados.

Las matrices de confusión obtenidas en estas clasificaciones y sus Pa aparecen recogidas en la Tabla 4-2. El peor resultado, Pa igual al 52.68%, se obtuvo cuando se clasificó solamente la ortofotografía (escenario-1). Por el contrario los valores de Pa en las clasificaciones mejoraron entre el 30 y el 40% cuando la intensidad LiDAR fue combinada con la ortofotografía en su explotación. Esta mejora fue más acentuada en aquellas clasificaciones donde la intensidad estaba normalizada, resultando un Pa igual a 92.26% en el caso de normalizar la intensidad en base a la distancia y del 93.16% normalizando en base a la distancia y el ángulo.

Tabla 4-2 Comparativa matrices de confusión obtenidas de las clasificaciones de los escenarios 1, 2, 3 y 4

Escenario 1: Ortofoto

Clase	CH	CL	R	SO	SC	C	CA	E	Total
CH	121687	741	0	0	0	0	0	0	122428
CL	203987	3859	8	138	0	0	0	0	207992
R	19	19	1115	115	160	0	0	0	1428
SO	0	64	0	67303	4	0	692	12	68075
SC	0	0	0	17	24331	204	0	795	25347
C	0	0	0	0	0	6561	0	206	6767
CA	664	242	0	617	0	0	6676	0	8199
E	0	0	0	3	658	2195	0	3957	6813
Total	326357	4925	1123	68193	25153	8960	7368	4970	447049

P_a 52.68%

(%)

Escenario 2: Ortofoto+ intensidad LiDAR bruto

Clase	CH	CL	R	SO	SC	C	CA	E	Total
CH	262696	220	0	0	0	0	0	0	262916
CL	63029	4327	4	255	0	0	0	0	67615
R	0	104	1118	34	208	0	0	0	1464
SO	0	63	0	67553	1	0	736	9	68362
SC	0	0	1	0	23513	470	0	673	24657
C	0	0	0	0	0	6050	0	90	6140
CA	632	211	0	350	0	0	6632	0	7825
E	0	0	0	1	1431	2440	0	4198	8070
Total	326357	4925	1123	68193	25153	8960	7368	4970	447049

P_a 84.13%

(%)

Escenario 3: Ortofoto+ intensidad LiDAR normalizada por distancia

Clase	CH	CL	R	SO	SC	C	CA	E	Total
CH	296256	150	0	0	0	0	0	0	296406
CL	29950	4557	4	105	0	0	0	0	34616
R	0	2	1118	17	198	0	0	0	1335
SO	1	35	0	67757	2	0	520	9	68324
SC	0	0	1	0	24402	185	0	693	25281
C	0	0	0	0	0	7275	0	39	7314
CA	150	181	0	313	0	0	6848	0	7492
E	0	0	0	1	551	1500	0	4229	6281
Total	326357	4925	1123	68193	25153	8960	7368	4970	447049

P_a 92.26%

(%)

Cultivos herbáceos (CH), Cultivos leñosos (CL), Rastrojos (R), Suelos desnudos oscuros (SO), Suelos desnudos claros (SC), Caminos (C), Carreteras (CA) y Edificaciones (E)

Unidades: Pixel.

Tabla 4.2 (Continuación) Comparativa matrices de confusión obtenidas de las clasificaciones de los escenarios 1, 2, 3 y 4

Escenario 4: Ortofoto+ intensidad LiDAR normalizada por distancia y ángulo

Clase	CH	CL	R	SO	SC	C	CA	E	Total
CH	299952	110	0	0	0	0	0	0	300062
CL	26252	4620	4	99	0	0	0	0	30975
R	0	5	1119	0	160	0	0	0	1284
SO	1	15	0	67812	2	0	486	8	68324
SC	0	0	0	0	24506	379	0	625	25510
C	0	0	0	0	0	7265	0	40	7305
CA	152	175	0	282	0	0	6882	0	7491
E	0	0	0	0	485	1316	0	4297	6098
Total	326357	4925	1123	68193	25153	8960	7368	4970	447049
<i>Pa</i> (%)	93.16%								

Cultivos herbáceos (CH), Cultivos leñosos (CL), Rastrojos (R), Suelos desnudos oscuros (SO), Suelos desnudos claros (SC), Caminos (C), Carreteras (CA) y Edificaciones (E)
Unidades: Píxel.

La Tabla 4-3 muestra los valores de *EU* y *EP* obtenidos para cada uso de suelo en cada uno de los escenarios. Esta tabla complementa a la Tabla 4-2. Analizando los resultados obtenidos en cada uno de los usos de suelo se observa como la mejora en los resultados de la distintas clasificaciones una vez es introducida la intensidad LiDAR se debe principalmente a la mejor caracterización de los cultivos herbáceos. Aunque la *EU* fue similar en todas las clasificaciones realizadas, la *EP* mostró una mejora del 43.2% cuando la intensidad sin tratar era introducida en la clasificación. Cuando esta variable era incorporada al proceso de clasificación una vez era normalizada por la distancia la *EP* alcanzó un valor igual a 53.49% y 54.62% si se normalizaba por la distancia y el ángulo. Estas mejoras principalmente fueron debidas a la mejora en la discriminación entre cultivos leñosos y cultivos herbáceos, los cuales ocupan algo más del 65% de la superficie objeto de estudio. Si se observa la Figura 4-8.a, los cultivos herbáceos y leñosos presentan la misma respuesta espectral en la ortofotografía. La clase cultivos leñosos mostró un elevado grado de confusión con la categoría cultivos herbáceos, obteniendo una *EP* muy baja. Los peores resultados para esta categoría se obtuvieron en la clasificación del escenario 1, (Figura 4-8.b). Cuando se introdujo la intensidad LiDAR en el proceso de clasificación, la confusión entre cultivos herbáceos y leñosos se redujo (Figura 4-8.c). El valor de *EP* se incrementó hasta casi un 15% cuando además la intensidad fue normalizada (Figura 4-8.d y Figura 4-8.e).

Debido a una similitud en el comportamiento espectral sobre la ortofotografía, la categoría edificación también reflejó un cierto grado de confusión con la categoría caminos en las clasificaciones correspondientes al escenario 1 y escenario 2. Tal efecto de confusión quedó reducido cuando la intensidad normalizada era introducida en el proceso de clasificación (escenario 3 y escenario 4). En estas clasificaciones, la categoría caminos arrojó una mejora de casi el 3% en los valores de *EU*, quedando mejor caracterizada del resto de las clases. A su vez la clase edificación mejoró su *EU* algo más del 12%.

La categoría carreteras obtuvo de partida unos excelentes resultados, empleando solo la ortofotografía, con un valor de *EU* superior al 80% en el escenario 1. No obstante, su identificación mejoró cuando la intensidad LiDAR participó en el proceso de clasificación, alcanzando unos valores de mejora en la *EU* en torno al 10% cuando era normalizada.

La clase rastrojos tuvo un comportamiento similar al resto de las clases en lo que se refiere a la exactitud en la clasificación, mostrando mejoras mayores del 5% en los valores de *EU* cuando la intensidad era normalizada (escenario 3 y escenario 4), reduciendo su confusión con las categorías tanto de suelo desnudo oscuro como claro.

Por último, las clases de suelo desnudo claro y oscuro no presentaron diferencias significativas en los valores de exactitud en cada uno de los escenarios considerados (escenarios 1-4).

Tabla 4-3: Comparación de exactitud usuario y exactitud productor

Exactitud usuario(%)				
	Escenario 1	Escenario 2	Escenario 3	Escenario 4
Cultivos herbáceos	99.39	99.92	99.95	99.96
Cultivos leñosos	1.86	6.40	13.16	14.92
Rastrojos	78.08	76.37	83.75	87.15
Suelos denudos oscuros	98.87	98.82	99.17	99.25
Suelos desnudos claros	95.99	95.36	96.52	96.06
Caminos	96.96	98.53	99.47	99.45
Carreteras	81.42	84.75	91.40	91.87
Edificaciones	58.08	52.02	67.33	70.47
Exactitud productor (%)				
	Escenario 1	Escenario 2	Escenario 3	Escenario 4
Cultivos herbáceos	37.29	80.49	90.78	91.91
Cultivos leñosos	78.36	87.86	92.53	93.81
Rastrojos	99.29	99.55	99.55	99.64
Suelos denudos oscuros	98.69	99.06	99.36	99.44
Suelos desnudos claros	96.73	93.48	97.01	97.43
Caminos	73.23	67.52	81.19	81.08
Carreteras	90.61	90.01	92.94	93.40
Edificaciones	79.62	84.47	85.09	86.46

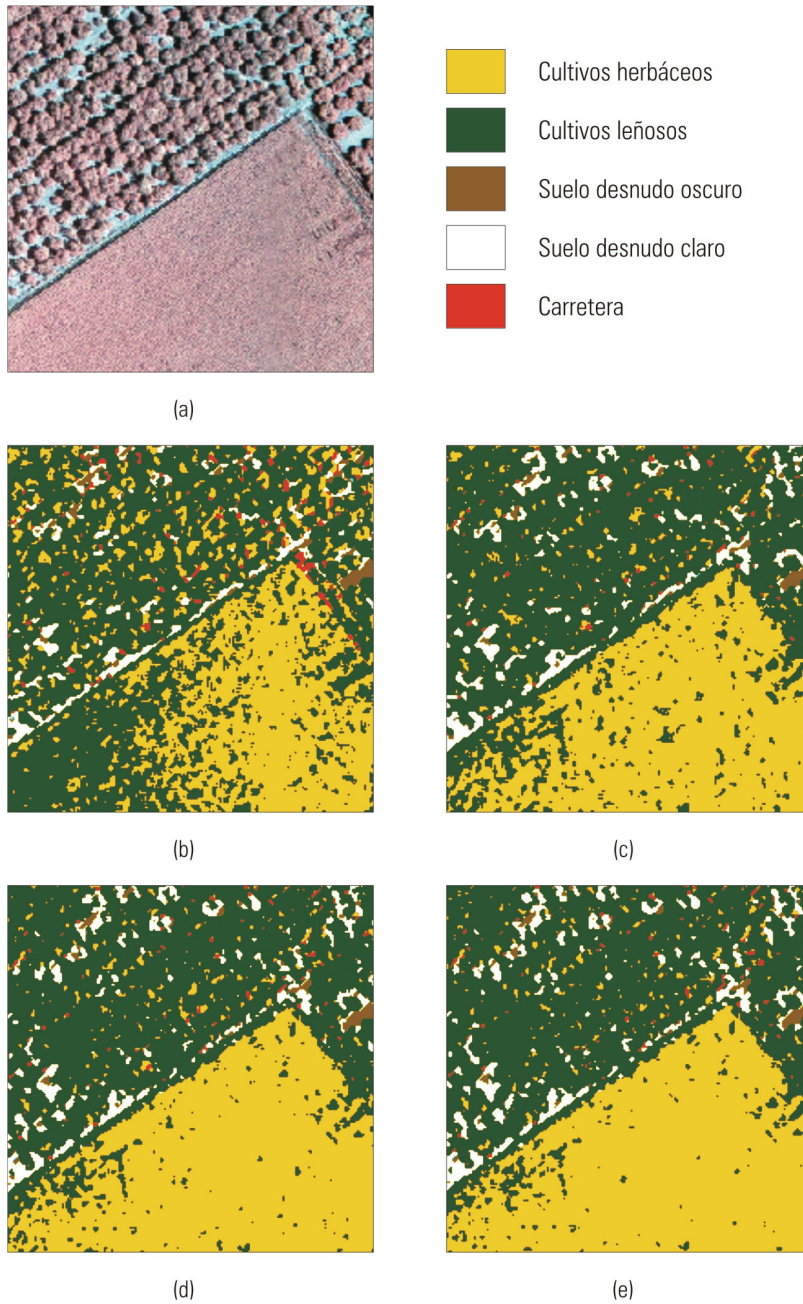


Figura 4-8 Comparación de la habilidad para distinguir entre cultivos herbáceos y leñosos; (a) ortofoto, clasificación; (b) ortofoto (Escenario 1), (c) ortofoto e intensidad LiDAR original (Escenario 2), (d) ortofoto e intensidad LiDAR normalizada por la distancia (Escenario 3) y (e) ortofoto e intensidad LiDAR normalizada por distancia y ángulo (Escenario 4).

4.5 Conclusiones

El presente estudio pone de manifiesto como la intensidad LiDAR es una fuente de información que aporta muchas ventajas en la discriminación de usos de suelo. Tal afirmación es posible realizarla a partir de las mejoras en el porcentaje de acuerdo de las clasificaciones realizadas una vez la intensidad LiDAR era combinada con imágenes multiespectrales procedentes de una cámara fotogramétrica. Hay que tener en cuenta que en productos como ortofotografías, el valor almacenado en cada píxel pierde su sentido físico en favor de que el producto tenga una buena presencia visual tras la realización de las tareas de mosaicado. De este modo la información contenida en un píxel está relacionada con tonos, alejándose esta de la representación espectral de fenómenos. Este aspecto incide negativamente en la identificación y caracterización de cultivos y usos de suelo. De este modo, la posibilidad de combinar estas imágenes con otras fuentes de información procedentes de otros sensores puede resultar una buena alternativa en la explotación de la información.

En la actualidad, vuelos combinados donde intervienen los sensores LiDAR y cámara se desarrollan con éxito, mejorando flujos de trabajo y producción de productos como ortofotografías. Esta simbiosis es entendida desde un punto de vista geométrico. No obstante, el sensor LiDAR además de registrar la información espacial en forma de coordenadas de cada uno de los puntos, almacena valores de intensidad susceptibles de ser explotados empleando técnicas de teledetección.

El porcentaje de acuerdo de la clasificación realizada sobre ortofotografía empleando técnicas de clasificación supervisadas a nivel de píxel fue solo del 52.68%. Este estudio muestra como solo añadiendo en el proceso de clasificación los valores de intensidad LiDAR sin ningún tipo de tratamiento, junto con la información procedente de una ortofotografía, los resultados de exactitud de la clasificación mejoran. A nivel global el porcentaje de acuerdo muestra una mejoría del 30% cuando ambas fuentes de información aparecen combinadas en el proceso de clasificación.

La normalización de los valores de intensidad LiDAR tiene como primera consecuencia una reducción de la variabilidad en la respuesta de este parámetro en la mayoría de los usos de suelo estudiados. A partir de una inspección visual de la rasterización de intensidad LiDAR se apreció como la línea de separación entre distintas pasadas se presentaba menos contrastada si este parámetro era normalizado. Mediante un análisis analítico se comprobó como los valores de intensidad LiDAR de puntos pertenecientes a distintas pasadas presentaban menor coeficiente de variación si estos valores eran normalizados. Ambos test indicaron que la normalización en base a la distancia o la distancia y el ángulo tiene que ser tenida en cuenta en aquellos procesos donde este parámetro intervenga.

En el caso de clasificaciones de imágenes se observó como a nivel global el porcentaje de acuerdo mejoró casi un 10% cuando la intensidad estaba normalizada en vez de emplearla tal y como es registrada por el sensor. Más aún, el porcentaje de acuerdo global mejoró más de un 40% caso de incluir la intensidad normalizada en vez de emplear solo la información recogida en la ortofotografía en los procesos de clasificación. Los mejores resultados de P_a , 93.10%, se obtuvieron cuando se normalizaron los valores teniendo en cuenta la distancia y el ángulo. No obstante, las diferencias no fueron significativas en comparación con el uso de la normalización por la distancia. Solamente se mejoraron los resultados en un 1%. Por tanto, puede establecerse que la distancia es el principal factor a tener en cuenta en el proceso de normalización, siendo el valor del ángulo un factor menos crítico. Esta distancia entre el sensor LiDAR y el objeto tiene que ser determinada de un modo correcto, teniendo en cuenta la trayectoria del avión.

En lo que respecta a los usos de suelo, la incorporación de la intensidad LiDAR a los datos multiespectrales en los procesos de clasificación mejoró tanto la exactitud usuario como productor. Mientras que empleando solo ortofotografía las clases correspondientes a cultivos herbáceos y leñosos presentaron un elevado grado de confusión debido a su similitud en el comportamiento espectral a consecuencia de lo establecido anteriormente, la incorporación de la intensidad LiDAR en el proceso de clasificación resultó fundamental a la hora de diferenciar ambos usos. La clase de cultivos leñosos presentó un elevado grado de confusión debido entre otros aspectos a los efectos de la iluminación y la mezcla de los píxeles. Tales aspectos vieron

mermados sus efectos al introducir la intensidad LiDAR. Junto a esta mejora, todo el resto de usos de suelo establecidos vieron mejorados sus resultados, particularmente si la intensidad era normalizada.

Las mejoras obtenidas en los procesos de clasificación pone de manifiesto que la combinación de los sensores cámara multiespectral y LiDAR permiten discriminar con un elevado nivel de exactitud usos de suelo.

4.6 Referencias

Antonarakis, A., Richards, K.S., Brasington, J. (2008). Object-based land cover classification using airborne LiDAR. *Remote sensing of Environment*, 112, 2988-2998.

Arroyo, L.A., Johansen, K., Armston, J., Phinn, S. (2010). Integration of LiDAR and QuickBird imagery for mapping riparian biophysical parameters and land cover types in Australian tropical savannas. *Forest Ecology and Management*, 259, 598-606.

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

Bork, E.W., Su, J.G. (2007). Integrating LIDAR data and multispectral imagery for enhanced classification of rangeland vegetation: A meta analysis. *Remote sensing of Environment*, 111, 11-24.

Bortolot, Z.J., Wynne, R.H. (2005). Estimating forest biomass using small footprint LiDAR data: An individual tree-based approach that incorporates training data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59, 342-360.

Bunting, P., Lucas, R.M., Jones, K., Bean, A.R. (2010). Characterisation and mapping of forest communities by clustering individual tree crowns. *Remote sensing of Environment*, 114, 2536-2547.

Burgess, G., Shortis, M., Scott, P. (2011). Photographic assessment of retroreflective film properties. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, 743-750.

Congalton, R.G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote sensing of Environment*, 37, 35-46.

Congalton, R.G., Green, K. (2009). *Assesing the accuracy of remotely sensed data: Principles and practices*. Boca Raton, Florida.

Coren, F., Sterzai, P. (2006). Radiometric correction in laser scanning. *International Journal of Remote Sensing*, 27, 3097-3104.

Delenne, C., Durrieu, S., Rabatel, G., Deshayes, M. (2010). From pixel to vine parcel: A complete methodology for vineyard delineation and characterization using remote-sensing data. *Computers and Electronics in Agriculture*, 70, 78-83.

Donoghue, D.N.M., Watt, P.J., Cox, N.J., Wilson, J. (2007). Remote sensing of species mixtures in conifer plantations using LiDAR height and intensity data. *Remote sensing of Environment*, 110, 509-522.

García, M., Riaño, D., Chuvieco, E., Danson, F.M. (2010). Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. *Remote sensing of Environment*, 114, 816-830.

Gruber, M., Perko, R., Ponticelli, M. (2004). The all digital photogrammetric workflow: redundancy and robustness. In, *ISPRS Commission I W-G I/6: Sensors, Platforms and Imagery*, 232-234.

Habib, A.F., Kim, E., Kim, C. (2007). New methodologies for true orthophoto generation. *Photogrammetric engineering and remote sensing*, 73, 25-30.

Harding, D., Lefsky, M., Parker, G., Blair, J. (2001). Laser altimeter canopy height profiles: Methods and validation for closed-canopy, broadleaf forests. *Remote sensing of Environment*, 76, 283-297.

Höfle, B., Pfeifer, N. (2007). Correction of laser scanning intensity data: Data and model-driven approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 62, 415-433.

Honkavaara, E., Arbiol, R., Markelin, L., Martinez, L., Cramer, M., Bovet, S., Chandelier, L., Ilves, R., Klonus, S., Marshal, P. (2009). Digital airborne photogrammetry—A new tool for quantitative remote sensing?—A state-of-the-Art review on radiometric aspects of digital photogrammetric images. *Remote Sensing*, 1, 577-605.

Hsieh, P.F., Lee, L.C., Chen, N.Y. (2001). Effect of spatial resolution on classification errors of pure and mixed pixels in remote sensing. *Geoscience and Remote Sensing, IEEE Transactions on*, 39, 2657-2663.

Hyypä, J., Hyypä, H., Litkey, P., Yu, X., Haggrén, H., Rönholm, P., Pyysalo, U., Pitkänen, J., Maltamo, M. (2004). Algorithms and methods of airborne laser-scanning for forest measurements. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVI, 82-89

Jimenez-Muñoz, J.C., Sobrino, J.A., Gillespie, A., Sabol, D., Gustafson, W.T. (2006). Improved land surface emissivities over agricultural areas using ASTER NDVI. New York, NY, ETATS-UNIS.

Jutzi, B., Stilla, U. (2006). Range determination with waveform recording laser systems using a Wiener Filter. *ISPRS Journal of Photogrammetry and Remote Sensing*, 61, 95-107.

Kato, A., Moskal, L., Schiess, P., Calhoun, D., Swanson, M. (2010). True orthophoto creation through fusion of LiDAR derived digital surface model and aerial photos. In, *ISPRS TC VII Symposium – 100 Years ISPRS*, Viena, Austria, 88-93.

Keinan, E., Doytsher, Y. (2008). Automatic Methods Toward Generating Digital True Orthophoto By Using Dense LiDAR Data. In, *ASPRS 2008, Annual Conference*. Portland, Oregon.

Korhonen, L., Korpela, I., Heiskanen, J., Maltamo, M. (2011). Airborne discrete-return LIDAR data in the estimation of vertical canopy cover, angular canopy closure and leaf area index. *Remote sensing of Environment*, 115, 1065-1080.

Kraus, K., Briese, C., Attwenger, M., Pfeifer, N. (2004). Quality measures for digital terrain models. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 35, 113-118.

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

Luzum, B., Starek, M., Slatton, K.C. (2004). Normalizing ALSM intensities. In, *Geosensing Engineering and Mapping (GEM) Civil and Coastal Engineering Department, University of Florida*.

Markelin, L., Honkavaara, E., Hakala, T., Suomalainen, J., Peltoniemi, J. (2010). Radiometric stability assessment of an airborne photogrammetric sensor in a test field. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 409-421.

Markelin, L., Honkavaara, E., Peltoniemi, J., Ahokas, E., Kuittinen, R., Hyyppä, J., Suomalainen, J., Kukko, A. (2008). Radiometric calibration and characterization of large-format digital photogrammetric sensors in a test field. *Photogrammetric engineering and remote sensing*, 74, 1487-1500.

Miliaresis, G.C., Kokkas, N. (2007). Segmentation and object-based classification for the extraction of the building class from lidar DEMs. *Computers and Geosciences*, 33, 1076-1087.

Moffiet, T., Mengersen, K., Witte, C., King, R., Denham, R. (2005). Airborne laser scanning: Exploratory data analysis indicates potential variables for classification of individual trees or forest stands according to species. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59, 289-309.

Pasher, J., King, D.J. (2010). Multivariate forest structure modelling and mapping using high resolution airborne imagery and topographic information. *Remote sensing of Environment*, 114, 1718-1732.

Persson, A., Holmgren, J., Söderman, U., Olsson, H. (2004). Tree species classification of individual trees in Sweden by combining high resolution laser data with high resolution near-infrared digital images. *Proceedings of the ISPRS working group VIII/2, Laser-Scanners for Forest and Landscape Assessments, Freiburg, Germany*, 36, 204-207.

Popescu, S.C., Wynne, R.H., Nelson, R.F. (2002). Estimating plot-level tree heights with lidar: local filtering with a canopy-height based variable window size. *Computers and Electronics in Agriculture*, 37, 71-95.

Rogan, J., Franklin, J., Roberts, D.A. (2002). A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. *Remote sensing of Environment*, 80, 143-156.

Song, J.H., Han, S.H., Yu, K., Kim, Y.I. (2002). Assessing the possibility of land-cover classification using lidar intensity data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 34, 259-262.

Strahler, A.H. (1980). The use of prior probabilities in maximum likelihood classification of remotely sensed data. *Remote sensing of Environment*, 10, 135-163

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

Wang, C., Glenn, N.F. (2009). Integrating LIDAR intensity and elevation data for terrain characterization in a forested area. *Geoscience and Remote Sensing Letters, IEEE*, 6, 463-466.

Wehr, A., Lohr, U. (1999). Airborne laser scanning--an introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 68-82.

Yoon, J.S., Shin, J.I., Lee, K.S. (2008). Land cover characteristics of airborne LiDAR intensity data: a case study. *Geoscience and Remote Sensing Letters, IEEE*, 5, 801-805.

Yunfei, B., Guopingb, L., Chunxiang, C., Xiaowen, L., Haoa, Z., Qishenga, H., Linyana, B., Chaoyia, C. (2008). Classification of Lidar Point Cloud and Generation of DTM from LiDAR Height and Intensity Data in Forested Area. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences: International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 313-318.

Zhou, G., Song, C., Simmers, J., Cheng, P. (2004). Urban 3D GIS from LiDAR and digital aerial images. *Computers & Geosciences*, 30, 345-353.

Capítulo 5

Evaluación de las técnicas de Análisis de Componentes Principales y Projection Pursuit en la combinación de la intensidad LiDAR con imágenes multiespectrales

Resumen: Como se ha podido ver en capítulos anteriores, el uso combinado de cámaras aéreas digitales y LiDAR presenta nuevas formas de explotación de la información registrada de forma combinada tanto a nivel geométrico como radiométrico. En este trabajo se continúan analizando nuevas metodologías que refuerzan tal combinación empleando para ello tanto técnicas basadas en el análisis de componentes principales como el análisis de componentes independientes con la información procedente de ambos sensores. Concretamente la combinación de sensores se ha realizado teniendo en cuenta el parámetro intensidad LiDAR. La principal consecuencia de trabajar con tal variable es la redundancia de información y por tanto dependencia estadística entre la

intensidad LiDAR y la banda del infrarrojo registrado por la cámara. Tal relación puede influir en la calidad de los resultados obtenidos en los procesos de clasificación. La eliminación de la correlación de información se realizó mediante la aplicación de técnicas de Análisis de Componentes Principales, mientras que para la eliminación de la independencia se empleó el método Projection Pursuit, un tipo de análisis basado en las técnicas Blind Source Separation. La evaluación de los efectos de la combinación de información de sensores, así como de los distintos tipos de tratamientos que se aplicaron sobre los datos, se realizó mediante el clasificador no supervisado ISODATA. Este clasificador genera de forma automática clusters de píxeles con comportamiento estadísticamente homogéneo. Los resultados obtenidos mostraron como la combinación de los valores de intensidad LiDAR junto con las bandas registradas por la cámara digital produjeron un aumento del 2.5-3% del porcentaje de acuerdo en la clasificación de los usos del suelo. Sin embargo, el incremento de la exactitud en la clasificación debida a la normalización de la intensidad LIDAR no superó el 0.3% respecto a la inclusión de estos datos sin normalizar, siendo este tratamiento poco significativo en el estudio. Finalmente, sin tener en cuenta el tipo de información analizada, los mejores resultados se alcanzaron tras la eliminación de la dependencia estadística entre bandas con la técnica Projection Pursuit, con incrementos del porcentaje de acuerdo de aproximadamente el 2% frente al incremento del 1% obtenido al eliminar la redundancia con un Análisis de Componentes Principales.

Palabras clave: cámara aérea digital, clasificación, intensidad, ortofoto, LiDAR, projection pursuit, análisis de componentes principales.

5.1 Introducción

Como se ha visto anteriormente la evolución de la fotogrametría con cámaras métricas desde un entorno analógico hacia uno digital ha propiciado un incremento en el número de aplicaciones (Gruber et al. 2004). Además de las mejoras geométricas, trabajar en un entorno digital ha mejorado notablemente la radiometría, lo que favorece también la explotación de la información mediante técnicas de teledetección (Markelin et al. 2010), siendo el principal inconveniente actualmente la falta de calibración de los sensores desde un punto de vista radiométrico (Honkavaara et al. 2009; Markelin et al. 2008). Baltsavias (1996) apuntaba el uso potencial de productos como las ortofotos tanto desde su tradicional punto de vista métrico como para la caracterización de cubiertas y usos de suelo. Esta última afirmación ha tenido su reflejo en trabajos de caracterización de usos de suelo mediante la explotación de la información registrada con cámaras áreas digitales en estudios forestales (Bunting et al. 2010; Erikson 2004; Pasher and King 2010; Waser et al. 2008a) y agrarios (Delenne et al. 2010; Hall et al. 2003). Simultáneamente, hoy día el interés por el empleo de estos sensores para la discriminación de usos de suelos también se hace patente por parte de las agencias cartográficas y medioambientales, analizando y evaluando procesos de certificación y estandarización (Stensaas y Lee 2008).

Paralelo al desarrollo tecnológico de las cámaras digitales, en los últimos años también se ha evolucionado en la forma de explotación de la información, dando lugar al uso combinado de sensores de arquitectura y propósitos diferentes. Tal es el caso de la explotación combinada de información geométrica y radiométrica procedente de LiDAR y de cámaras aéreas. Desde un punto de vista geométrico, el LiDAR permite generar modelos digitales de la realidad que son empleados principalmente en el proceso de producción de ortofotografías (Braun 2005; Ettarid et al. 2005). Otras aplicaciones cada vez mas empleadas se centran en la detección de cambios en zonas forestales (Waser et al. 2008), estimaciones de altura de árboles (Erdody y Moskal 2010; Suárez et al. 2005), inventarios forestales (Ali et al. 2008; Hollaus et al. 2006), clasificaciones de usos de suelo (Bork y Su 2007) o gestión urbanística (Yu et al. 2010). En esta línea Hyyppä et al. (2004) concluyen que hay una

alta sinergia entre la alta resolución espacial y espectral de las imágenes y los datos del sensor LiDAR para la extracción de información de usos de suelo. Por tanto, mientras el sensor LiDAR aporta información detallada de la estructura geométrica de los elementos, la información espectral registrada por las cámaras digitales informa de su composición, consiguiendo un mejor entendimiento del ecosistema (Hudak et al. 2009).

En el **Capítulo 4** de la presente Tesis se ha estudiado como el sensor LIDAR, además de registrar coordenadas tridimensionales de puntos que permiten estudiar geometrías, registra valores de intensidad que son factibles de ser explotados mediante técnicas de teledetección. Tal información es poco utilizada mediante técnicas de teledetección pese a que puede ser un factor importante para la extracción de fenómenos y clasificación de usos de suelo (Flood 2001). El uso de la intensidad LiDAR puede emplearse en estudios de clasificación conjuntamente con la altura de la nube de puntos (Antonarakis et al. 2008; Charaniya et al. 2004; Yunfei et al. 2008) o junto con la información espectral de imágenes áreas o de satélite (Bartels et al. 2006; Moffiet et al. 2005). La intensidad LiDAR sufre alteraciones debido a las características geométricas de la toma de datos. Tal y como se ha podido comprobar y advierten Song et al. (2002), los valores de intensidad registrados en objetos similares presentan diferencias notables en función del ángulo de incidencia. Para la normalización de los valores en la presente Tesis se han empleado dos métodos diferentes. En primer lugar se ha tenido en cuenta la proporcionalidad con el coseno del ángulo y la distancia (Jutzi y Stilla 2006), y por otro lado se ha empleado solamente la variable distancia tal y como apuntan Luzum et al. (2004).

El mapeo de los distintos usos del suelo se suele realizar mediante técnicas de clasificación supervisada o no supervisada. Para ello, y tal como establecen (Rajagopalan y Robb 2003), cuanto más independientes sean las bandas estadísticamente, mejores resultados se obtendrán al aplicar un operador de clasificación no supervisada. Sin embargo, el sensor LiDAR registra valores de intensidad en un ancho de banda de longitud de onda entre los 800nm y 1550nm, correspondiente al Infrarrojo Próximo (NIR), y simultáneamente tanto si trabajamos con imágenes de satélite como con imágenes aéreas, éstas suelen presentar una

banda en la misma región del espectro. Tal aspecto provoca que la información que se explota sea redundante y dependiente. Tradicionalmente para solventar este problema de correlación de información se emplean técnicas como el Análisis de Componentes Principales (PCA) (Li y Yeh 1998; Ribed y Lopez 1995). Los resultados obtenidos son un conjunto de bandas donde se ha eliminado la correlación entre ellas, lo cual no implica que dichas bandas sean independientes. Para la obtención de la condición de independencia será necesaria la aplicación de técnicas Blind Source Separation (BSS), las cuales han sido introducidas en el **Capítulo 2** de la Tesis. La aplicación de BSS devolverá un conjunto de bandas con información subyacente, extrayendo la información útil de los datos de entrada (Stone 2004). De las diferentes técnicas a aplicar en BSS destaca el análisis Projection Pursuit (en adelante PP). El término fue introducido por Friedman y Tukey (1974) como técnica estadística para encontrar proyecciones de interés de datos multidimensionales. Este tipo de técnicas es de gran interés a la hora de trabajar con sensores hyperespectrales en teledetección ya que estos recogen información del espectro con un elevado número de bandas con un ancho de banda muy pequeño. La continuidad espectral que presentan implica una redundancia de información muy elevada. Tal aspecto requiere de una reducción del volumen de información (Jimenez and Landgrebe 1999; Lin y Bruce 2003). También se recomienda la aplicación de estas técnicas en imágenes multiespectrales, donde algunos estudios han mostrado una mejoría en los porcentajes de acuerdo tanto en clasificaciones supervisadas (Karoui et al. 2009) como en clasificaciones no supervisadas (Shah et al. 2007).

Bajo este contexto los objetivos del presente capítulo son:

- Evaluar el efecto de la normalización de la intensidad en una clasificación no supervisada mediante el operador ISODATA.
- Analizar el efecto de los resultados de clasificación al aplicar PCA y PP.

5.2 Materiales y métodos

El vuelo realizado sobre Lora del Río, descrito en el apartado 4.2 de la presente Tesis, se ha empleado para realizar todos los ensayos desarrollados en el presente capítulo, siguiendo la metodología descrita a continuación.

5.2.1 Flujo de trabajo

Una vez realizado el vuelo combinado se tuvieron dos conjuntos de datos de naturaleza bien distinta. De una parte la cámara digital aportó información multiespectral a partir de la colección de fotogramas registrados. Simultáneamente el sensor LiDAR registró un conjunto de puntos tridimensionales con información auxiliar como intensidad, ángulo de barrido, etc. La Figura 5-1 representa el flujo de trabajo empleado para la evaluación de la explotación de la información de la cámara digital y la intensidad LiDAR. La primera etapa del tratamiento consistió en combinar la información de ambos sensores para posteriormente poder desarrollar una clasificación no supervisada. Sobre la información LiDAR se realizó un primer tratamiento de los datos donde se prepararon estos para su correcta integración. Siguiendo la metodología propuesta en Figura 4-4 del capítulo anterior se filtraron aquellos puntos que no se correspondían con fenómenos representados en la ortofotografía. A continuación se procedió a normalizar los valores de la intensidad eliminando el efecto de la relación espacial entre cada uno de los puntos y el sensor. Para ello se empleó el procedimiento planteado en el apartado 4.3.2. De esta forma, a raíz del proceso de normalización se pasó de tener una única nube de puntos a tener tres, la primera coincidente con los puntos originales y las otras dos resultantes de la normalización. Cada uno de estos conjuntos de puntos se rasterizó a fin de tener una imagen a modo de banda que poder ser incorporada a las bandas de la ortofoto.

En este estado se obtuvieron cuatro imágenes las cuales fueron denominadas:

- Set 1: Coincidente con la ortofoto obtenida a partir de los fotogramas registrados con la cámara.
- Set 2: Formada por la ortofoto y la imagen de intensidades sin normalizar.
- Set 3: Constituida por la ortofoto y la imagen de intensidades normalizadas por la distancia.
- Set 4: Combinación de la ortofoto y la imagen de intensidades normalizada por la distancia y el ángulo.

A consecuencia de que la intensidad LiDAR registra información en el rango de longitudes de onda cercana a la banda CIR de la cámara digital, existe duplicidad de información. De este modo las imágenes fueron sometidas a distintas técnicas a fin de reducir estos efectos. En primer lugar sobre cada imagen se realizó un PCA a fin de reducir la redundancia de información. Además sobre las imágenes se aplicó PP con el objetivo de tener un conjunto de nuevas bandas independientes. Como resultado de este análisis cada set definido anteriormente quedó descompuesto en tres sub-set en función de la técnica empleada:

- Set X_{ST} : Se corresponde con aquellos escenarios donde no se han aplicado ni PCA ni PP.
- Set X_{PCA} : Recoge aquellos escenarios donde se ha aplicado la técnica PCA
- Set X_{PP} : Coincide con aquellos escenarios donde se ha procesado PP.

Siendo X el índice del set, en el rango entre 1 y 4.

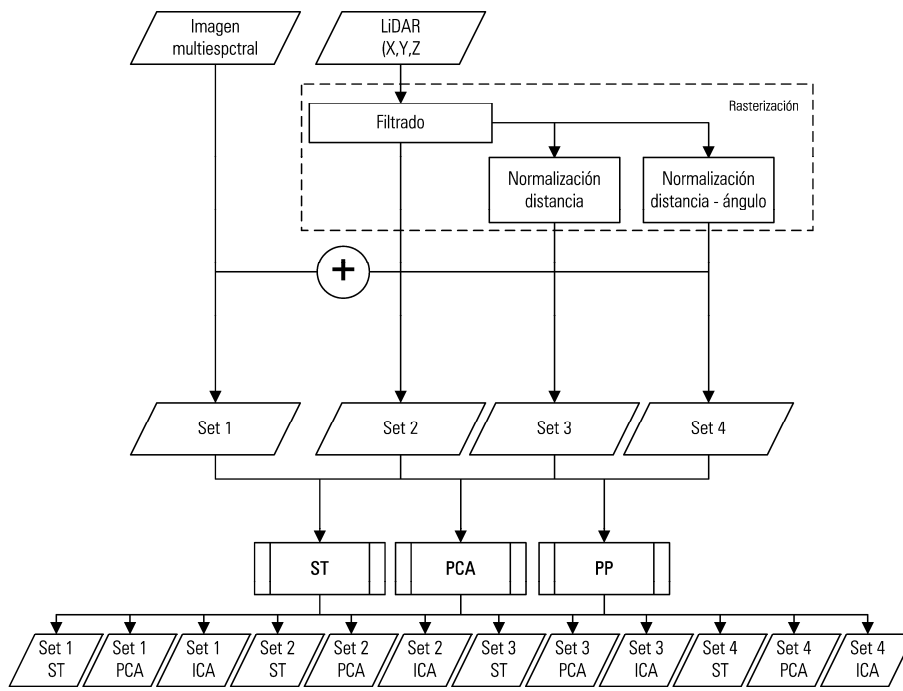


Figura 5-1 Flujo de trabajo para la evaluación de la explotación de la combinación ortofotografía y LiDAR.

Sobre los doce set obtenidos se realizó una clasificación no supervisada con el operador ISODATA. La comparación de las distintas clasificaciones permitirá:

- Evaluar si la incorporación de la intensidad LiDAR aporta información útil en la caracterización de usos de suelo en procesos de clasificación no supervisados.
- Analizar si la normalización de los datos LiDAR influye en los resultados de este tipo de clasificadores.
- Verificar si procesamientos como PP facilitan al operador de clasificación la discriminación de usos de suelo.

Sobre los resultados obtenidos de cada una de las clasificaciones se aplicó un filtro de mayoría de 3x3 a fin de homogeneizar las clasificaciones y eliminar el posible ruido introducido en el proceso. Sobre cada una de las clasificaciones se determinó

su correspondiente matriz de confusión, permitiendo calcular el porcentaje de acuerdo (en adelante Pa) de la clasificación junto con los índices de exactitud usuario (en adelante EU) y exactitud productor (en adelante EP). La comparación del índice global como de los índices por clase obtenidos en cada una de las clasificaciones permitió evaluar los distintos escenarios definidos dependiendo de la combinación de información clasificada así como el efecto de las técnicas de disminución de la redundancia de información PCA y PP.

5.2.2 Projection pursuit

La técnica PP fue originalmente propuesta por Kruskal (1969) si bien la primera implementación con éxito la realizaron Friedman y Tukey (1974). En PP se busca un conjunto de proyecciones lineales concretas. En el Capítulo 2 se vio como las señales que presentan mezcla tienden a tener una función de densidad de probabilidades (en adelante fdp) normal o gaussiana, mientras que las señales fuente tienden a tener una fdp no gaussiana. En este sentido el método PP tiende a buscar una nueva proyección de los datos al tiempo que la nueva información sea lo menos gaussiana posible.

El objetivo de PP es encontrar un conjunto de direcciones tales que las proyecciones de los datos sobre estas presenten la distribución lo más independiente posible. De todas las direcciones posibles, aquellas que contengan la distribución menos gaussiana será la más adecuada a consecuencia de que la información independiente presentará una distribución no gaussiana. La medida clásica para determinar el grado de gaussianidad de un conjunto de datos es la kurtosis, siendo definida para una variable como:

$$Kurtosis = \frac{\frac{1}{N} \sum_{i=1}^N (\bar{y} - y_i)^4}{\left(\frac{1}{N} \sum_{i=1}^N (\bar{y} - y_i)^2 \right)^2} \quad \text{Ec. 5-1}$$

Siendo:

- N el número de elementos de la variable y .
- \bar{y} el valor medio de la variable y .

En el caso que el valor de la kurtosis sea igual a cero, entonces la variable medida tendrá un comportamiento gaussiano, si la kurtosis es mayor de cero la variable será de tipo super-gaussiana, mientras que si presenta valores negativos es definida como sub-gaussiana.

El análisis PP está basado en el modelo general BSS (Figura 5-2), de tal manera que un conjunto de señales independientes s se mezclan linealmente mediante una matriz desconocida A , siendo x el vector que almacena la información registrada por el sensor (Ec. 5-2).

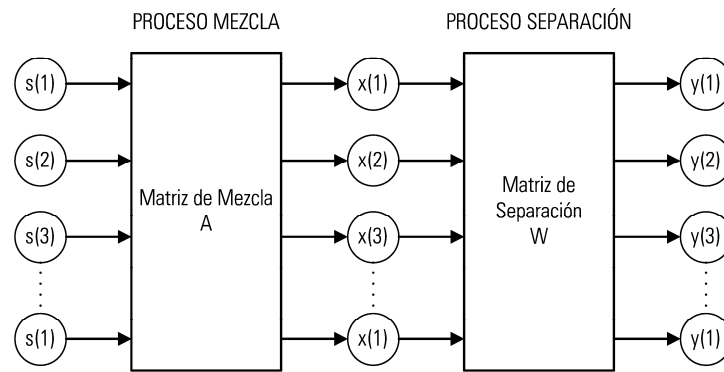
$$x = A \cdot s \quad \text{Ec. 5-2}$$

Para recuperar el conjunto de información inicial se realizará una estimación a partir de la matriz W , denominada matriz de separación la cual invertirá el proceso de mezcla (Ec. 5-3).

$$y = W \cdot x \quad \text{Ec. 5-3}$$

En la determinación de mezcla y siguiendo los requisitos definidos por el modelo se tendrán en cuenta los siguientes aspectos:

- El conjunto de datos s es estadísticamente independiente.
- La distribución de s no es gaussiana
- La información se mezcla siguiendo un modelo lineal.



Información original
Información observada
Estimación información original

Figura 5-2 Esquema general del planteamiento del problema.

Si se consigue determinar una matriz W que maximice el valor de la kurtosis de los nuevos valores estimados asumiremos que estos se corresponden con la información original y por tanto serán independientes o lo más independientes posibles.

El primer paso realizado sobre los datos fue un pre-procesamiento de la información consistente en un centrado de las bandas restándole a cada una de ellas su valor medio, obteniendo por tanto un conjunto de bandas de media igual a cero. Posteriormente se realizó un blanqueo de las bandas centradas con objeto de eliminar la relación de segundo orden entre ellas, siendo sus varianzas por tanto iguales a la unidad e incorreladas. En este punto se estuvo en disposición de calcular la matriz W siguiendo el diagrama de flujo planteado en Figura 5-3. El proceso comenzó con una inicialización aleatoria de la matriz W , a continuación mediante un proceso iterativo se forzó que la kurtosis de los datos fuera aumentando en cada

iteración tras la actualización de la matriz W . Una vez alcanzado el máximo número de iteraciones o bien que la variación de W no fuera mayor de una determinada tolerancia, se obtuvo una matriz final W tal que aplicando Ec. 5-3 devolviera un conjunto de nuevas bandas lo más independientes posibles al haber maximizado la kurtosis.

Para la realización del proceso se desarrolló en Matlab una aplicación donde mediante un proceso iterativo se fue maximizando el parámetro kurtosis. El resultado de la aplicación devolvió el valor de la matriz W , la cual fue aplicada sobre la imagen para poder obtener los valores correspondientes a y .

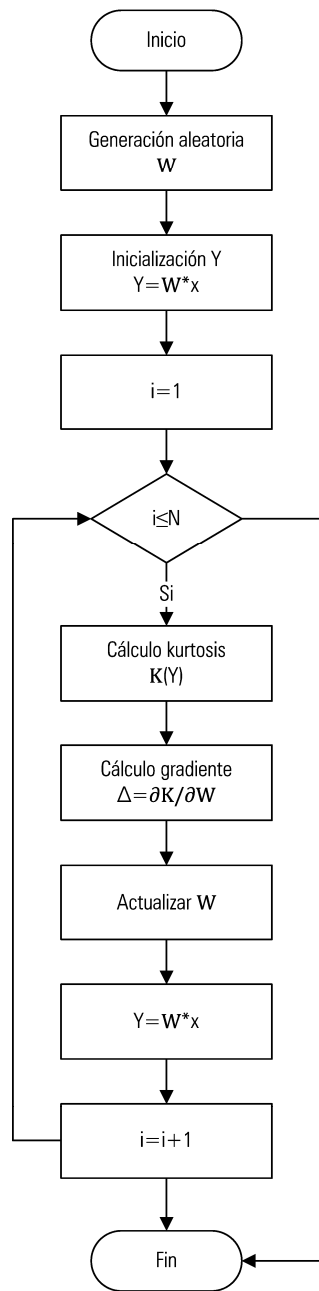


Figura 5-3 Diagrama de flujo para el cálculo de la matriz de separación W mediante el modelo PP.

5.2.3 Análisis de componentes principales

Esta técnica fue inicialmente desarrollada por Pearson a finales del siglo XIX y posteriormente estudiada por Hotelling en los años 30 del siglo XX. Para estudiar las relaciones que se presentan en p variables correlacionadas, es decir, que presentan información común, se puede transformar el conjunto original de variables en otro conjunto de nuevas variables incorreladas entre sí, eliminando por tanto la redundancia de información, llamado conjunto de componentes principales.

El análisis de componentes principales (PCA) puede ser interpretado en términos de la separación ciega de señales en la medida que PCA es una versión del análisis de componentes independientes (ICA) en el que las señales fuente son asumidas gaussianas. Sin embargo, la principal diferencia entre ICA y PCA reside en el hecho de que PCA descompone un conjunto de señales mezcla en un nuevo conjunto de señales incorreladas, mientras que ICA descompone tal conjunto en un conjunto de señales independientes.

PCA en esa transformación de la información no solo genera unas nuevas variables incorreladas, al mismo tiempo las presenta ordenadas según su varianza, por tanto las señales vinculadas a valores de varianza altos son consideradas más importantes respecto de aquellas que son vinculadas a varianzas bajas.

Al igual que ICA, las variables en un primer momento fueron centradas. Sobre ellas se determinará la matriz W_{PCA} de tal forma que:

$$y = W_{PCA} \cdot x \quad \text{Ec. 5-4}$$

Cada fila de la matriz W_{PCA} se corresponde con un vector propio de módulo igual a la unidad que extrae un único componente principal a partir de la información de partida x . La varianza de cada componente principal es conocida como valor propio (λ). La transformación es una transformación ortogonal de manera que la varianza se redistribuye sin pérdidas sobre los distintos componentes principales.

PCA se basa en la correlación entre las bandas de una imagen, esta puede representarse mediante un sistema de coordenadas donde cada eje representa los niveles digitales de cada una de las bandas comparadas. Si se representan los valores de una banda en función de los de otra, el resultado será una nube de puntos cuya forma dependerá de la forma de la relación entre las dos bandas. (Figura 5-4). Mediante PCA se encuentra un nuevo sistema de referencia que explicará de una manera más adecuada la variabilidad de la imagen.

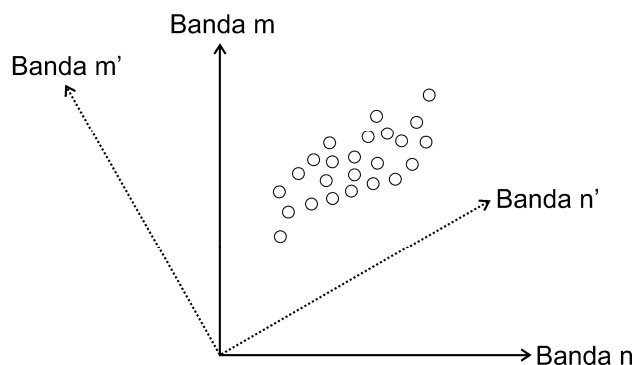


Figura 5-4 Correlación entre los niveles digitales de dos bandas m y n .

La aplicación PCA permite reducir el número de bandas presentes en una imagen (Du y Fowler 2007; Li et al. 2011; Plaza et al. 2009; Thenkabail et al. 2004). Además permite la identificación de información dominante y recurrente en series temporales, siendo empleado con éxito en análisis de cambios (Lasaponara 2006; Lhermitte et al. 2011).

La transformación PCA sobre las imágenes se ha realizado mediante el software Envi 4.7 de ITT Visual Information Solutions.

5.3 Resultados

Una vez normalizada la intensidad LiDAR y rasterizada se generaron un total de cuatro imágenes; (a) Set 1: ortofotografía CIR, (b) Set 2: ortofotografía CIR junto con la intensidad LiDAR bruta, (c) Set 3: ortofotografía CIR y la intensidad LiDAR normalizada por la distancia y (d) Set 4: ortofotografía CIR e intensidad LiDAR con la

intensidad normalizada por distancia y ángulo. Sobre cada uno de estos escenarios se aplicó un tratamiento PCA y un PP, obteniendo al final un total de 12 set de análisis correspondientes a cuatro set sin tratamiento (set X_{ST}), otros cuatro con análisis PCA (set X_{PCA}) y otros cuatro con análisis PP (set X_{PP}) con características diferentes en cuanto a tipo de información y procesamiento aplicado. Sobre cada escenario se realizó una clasificación de los usos de suelo presentes en la imagen empleando el operador de clasificación no supervisado ISODATA.

En primer lugar se realizó un análisis visual, comparando los resultados de todas las clasificaciones. En la Figura 5-5 se muestra un recorte de la zona de trabajo recogiendo diferentes usos de suelo presentes en la imagen (Figura 5-5.a) y el resultado de la clasificación para cada uno de los escenarios analizados según el nivel de tratamiento empleado: sin tratamiento (Figura 5-5.b, c, d y e), PP (Figura 5-5.f, g, h e i) y PCA (Figura 5-5.j, k, l y m). Los resultados correspondientes al escenario set 1_{ST} presentaron resultados difusos en cuanto a la discriminación de los distintos usos, aspecto que mejoró notablemente con la incorporación de la intensidad LiDAR. En el caso de la aplicación de PCA a las imágenes, se siguió el mismo comportamiento, el set 1_{PCA} presentó peores resultados que los escenarios donde intervino la intensidad LiDAR. No se apreciaron diferencias reseñables entre los resultados obtenidos a partir de los escenario sin tratamiento y aplicando PCA. En el caso de la aplicación PP el comportamiento fue muy distinto a los dos anteriores. El escenario set 1_{PP} presentó mejores resultados que los anteriores tratamientos. Además la incorporación de la intensidad LiDAR en los procesos mejoró la categorización de la imagen, presentando grupos más homogéneos en la representación de los distintos fenómenos.




Figura 5-5 Comparativa de resultados del clasificador no supervisado ISODATA. Los porcentajes de acuerdo obtenidos en cada uno de los doce escenarios clasificados se recogen en la

Tabla 5-1. Dicha información aparece representada gráficamente en la Figura 5-6. Observando dicha gráfica se observa como aparece un salto cualitativo de la exactitud de las clasificaciones en todas las imágenes al incorporar la intensidad LiDAR en los procesos de clasificación. Al evaluar el nivel de tratamiento realizado a los datos lo peores resultados se obtuvieron sobre aquellas imágenes donde no se realizó ningún tratamiento de las bandas. El procesado de estos datos mejoró los resultados de las clasificaciones, observándose mejoras en la exactitud tras la aplicación del análisis PP y PCA, siendo el tratamiento PP el que mejores resultados mostró. Analizando la combinación de bandas empleadas en el análisis, los peores resultados se obtuvieron al clasificar solamente la ortofotografía CIR (Set 1). Por el contrario, en aquellas imágenes donde se incorporó la intensidad LiDAR (Set 2, 3 y 4) siempre se produjo una mejora en el porcentaje de acuerdo. En cuanto al nivel de procesamiento de la intensidad LiDAR, aparece una pequeña mejora si esta variable es normalizada, si bien esta no es significativa con respecto a los valores originales. Además no se advierten diferencias entre los dos tipos de normalización de la intensidad. Por tanto los peores resultados se obtuvieron al clasificar la ortofotografía CIR sin tratamiento (Set 1_{ST}) con un Pa del 88.13%. En el otro extremo, los mejores resultados se obtuvieron al clasificar la imagen fruto de la combinación ortofotografía mas intensidad LiDAR normalizada por distancia y ángulo, aplicando la técnica PP (Set 4_{PP}) con un Pa igual al 93.23%. Con carácter general, la inclusión de la información LiDAR en las clasificaciones junto con la información procedente de la ortofotografía permitió mejorar la exactitud global de las clasificaciones entre un 2.5 y un 3%, mientras que los incrementos debidos a los tratamientos oscilan entre el 1% aplicando PCA y el 2% aplicando PP.

Tabla 5-1. Porcentaje de acuerdo en las clasificaciones según tipo de información y tratamiento (%)

Imagen	None	PP	PCA
Ortofoto	88.13	90.09	89.26
Ortofoto+ LiDAR sin tratamiento	90.87	92.92	91.75
Ortofoto+ LiDAR intensidad normalizada por distancia	91.05	93.23	91.87
Ortofoto+ LiDAR intensidad normalizada por distancia y ángulo	91.05	93.20	91.89




Figura 5-6 Comparativa Porcentaje de acuerdo según tratamiento de las imágenes A: ortofoto, B: Ortofoto mas intensidad LiDAR bruta, C: Ortofoto mas intensidad LiDAR normalizada por distancia y D: ortofoto mas LiDAR normalizada por distancia y ángulo.

Las Figura 5-7 y Figura 5-8 representan una comparativa de la *EP* y *EU* de cada uso de suelo según las combinaciones de información y tratamiento aplicado. En el uso de suelo vegetación (Figura 5-7.a y Figura 5-8.a), la incorporación de la intensidad LIDAR en sus distintos niveles de normalización no presentó diferencias significativas a nivel de *EP* y *EU* respecto al análisis de la ortofotografía CIR. En el momento que se aplicó el tratamiento PP, las mejoras aparecieron en la *EP* debido a la reducción en la confusión con la clase suelos oscuros, mejorando en menor cuantía en el caso de aplicar PCA. En el uso edificaciones (Figura 5-7.b y Figura 5-8.b), el empleo de la intensidad LIDAR resultó determinante para su discriminación pasando de un 30.22% de *EP* en el escenario con solo la ortofografía original a un 59% de media cuando se empleó combinada con la intensidad LIDAR, y alcanzándose valores próximos al 65% cuando se realizó un procesamiento PP. Un resultado análogo se obtuvo en el uso suelos claros (Figura 5-7.c y Figura 5-8.c), debido al elevado porcentaje de confusión entre este tipo de suelo y las edificaciones, confusión que quedó reducida con el uso simultáneo de la intensidad LIDAR con o sin normalizar y tratamiento PP, llegando a alcanzar precisiones de *EU* próximas al 90%. En el caso del uso suelos oscuros (Figura 5-7.d y Figura 5-8.d), la variación de *EP*

fue poco significativa en los dos tratamientos PP y PCA en todas las imágenes clasificadas, si bien la *EU* presentó una mejora próxima al 9% al emplear la intensidad LIDAR normalizada por distancia y aplicando PP. Un incremento muy destacado también se observó en el uso asfalto (Figura 5-7.e y Figura 5-8.e), donde se pasó de un valor mínimo de 51.22 % de *EU* en el Set 1_{ST} a un valor máximo de *EU* del 70.63%. La mejora de *EU* en ambas clase se debió a la reducción de la confusión a nivel de clase entre ambas.

En la comparativa de índices tanto globales como por clase obtenidos en las clasificaciones, las exactitudes aumentan al incorporar la intensidad LIDAR a la ortofotografía CIR, siendo variables los efectos de la normalización en función de los usos del suelo. Por su parte, pese al incremento de la exactitud que se produce al aplicar técnicas que reduzcan el efecto de la redundancia de información, los valores obtenidos en imágenes donde se realizó un PCA siempre fueron peores que aplicando PP.

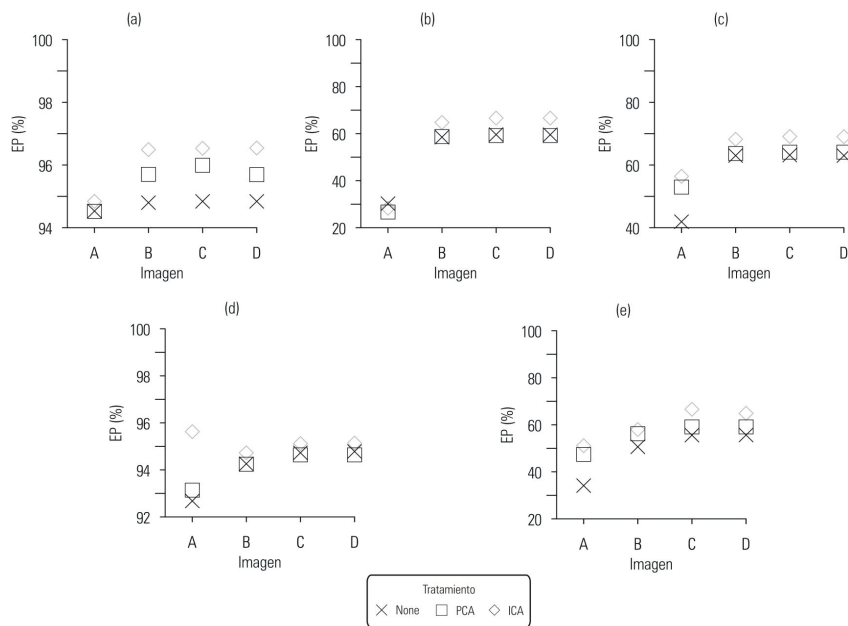


Figura 5-7 Comparativa exactitud productor sobre las imágenes: A: Ortofoto; B: Ortofoto + LiDAR sin tratamiento; C: Ortofoto + LiDAR normalizado por distancia; D: Ortofoto + LiDAR normalizado por distancia y ángulo para los usos de suelo (a) vegetación, (b) edificaciones, (c) suelos claros; y (d) suelos oscuros y (e) carreteras

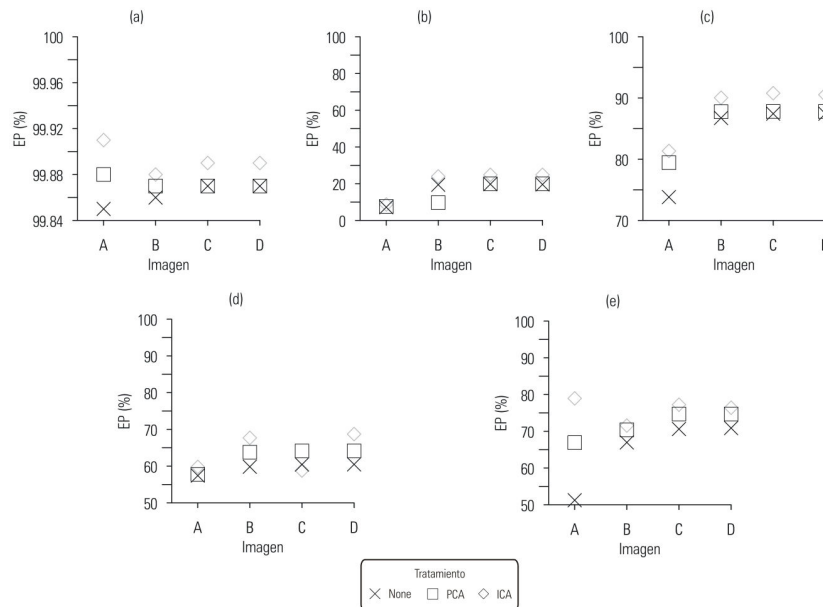


Figura 5-8 Comparativa exactitud usuario sobre las imágenes: A: Ortofoto; B: Ortofoto+ LiDAR sin tratamiento; C: Ortofoto + LiDAR normalizado por distancia; D: Ortofoto+LiDAR normalizado por distancia y ángulo para los usos de suelo (a) vegetación, (b) edificaciones, (c) suelos claros; (d) suelos oscuros y (e) carreteras

5.4 Conclusiones

Este trabajo muestra como la integración de la información multispectral procedente de cámaras digitales junto con la intensidad LIDAR es un extra a la hora de discriminar los diferentes usos de suelo presentes en una imagen. La intensidad LiDAR fue normalizada con el fin de homogeneizar la respuesta de los objetos independientemente de las condiciones geométricas de la captura de información. Los métodos empleados en la normalización fueron criterios geométricos, en primer lugar se consideró la distancia entre cada punto y el sensor en el instante de registro y en segundo lugar junto con esta distancia el ángulo de escaneo.

Analizando la combinación de cámara con intensidad LIDAR se observó cómo se maneja información redundante al tener por un lado la banda del infrarrojo cercano registrada por la cámara y por otra parte la intensidad del sensor LIDAR la cual se registra en los mismos intervalos de longitud de onda. Para la eliminación de esta

redundancia de información entre bandas se aplicó un PCA el cual devolvió como resultado un conjunto de bandas decorreladas. Al mismo tiempo se aplicaron técnicas BSS, concretamente PP, con el objetivo de obtener un conjunto de bandas independientes las cuales a priori ayudarían aun más al operador de clasificación a discriminar los usos presentes.

Para analizar las ventajas de la aplicación de técnicas BSS se realizó una clasificación no supervisada empleando el operador ISODATA. Los resultados mostraron como las imágenes donde solo se empleo la ortofotografía CIR fueron los peores mientras que la incorporación de la intensidad LIDAR ayudó a mejorar los resultados obtenidos tanto a nivel global como de clase. Al mismo tiempo los resultados arrojaron como, si bien se mejoró en algo las clasificaciones donde la intensidad apareció normalizada no eran mejoras significativas, no siendo relevante tal tratamiento en clasificaciones no supervisadas.

A nivel de procesamiento de la información los peores resultados en la clasificación aparecieron sobre las clasificaciones realizadas en las imágenes sin tratar seguidas de aquellas donde se realizó previamente un PCA. Los mejores resultados se presentaron siempre en aquellas clasificaciones donde se realizó un PP previo a la clasificación.

5.5 Referencias

Ali, S., Dare, P., Jones, S., 2008. Fusion of remotely sensed multispectral imagery and Lidar data for forest structure assessment at the tree level, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Beijing, 1089-1094.

Antonarakis, A., Richards, K.S., Brasington, J., 2008. Object-based land cover classification using airborne LiDAR. Remote sensing of Environment 112, 2988-2998.

Baltsavias, E.P., 1996. Digital ortho-images--a powerful tool for the extraction of spatial-and geo-information. *ISPRS Journal of Photogrammetry and Remote Sensing* 51, 63-77.

Bartels, M., Wei, H., Ferryman, J., 2006. Analysis of LiDAR data fused with co-registered bands, Annual conference of the remote sensing and photogrammetry society. *IEEE*, 1-9.

Bork, E.W., Su, J.G., 2007. Integrating LIDAR data and multispectral imagery for enhanced classification of rangeland vegetation: A meta analysis. *Remote sensing of Environment* 111, 11-24.

Braun, J., 2005. Aspects on true-orthophoto production. *Proceedings, 49th Photogrammetric Week, Stuttgart, Germany, September 1-5, 2003.*

Bunting, P., Lucas, R.M., Jones, K., Bean, A.R., 2010. Characterisation and mapping of forest communities by clustering individual tree crowns. *Remote sensing of Environment* 114, 2536-2547.

Coren, F., Sterzai, P., 2006. Radiometric correction in laser scanning. *International Journal of Remote Sensing* 27, 3097-3104.

Charaniya, A.P., Manduchi, R., Lodha, S.K., 2004. Supervised parametric classification of aerial lidar data, *Proceedings of the IEEE 2004 Conference on computer vision and pattern recognition workshop. IEEE, Baltimore, 1-8.*

Delenne, C., Durrieu, S., Rabatel, G., Deshayes, M., 2010. From pixel to vine parcel: A complete methodology for vineyard delineation and characterization using remote-sensing data. *Computers and Electronics in Agriculture* 70, 78-83.

Du, Q., Fowler, J.E., 2007. Hyperspectral image compression using JPEG2000 and principal component analysis. *Geoscience and Remote Sensing Letters, IEEE* 4, 201-205.

Erdody, T.L., Moskal, L.M., 2010. Fusion of LiDAR and imagery for estimating forest canopy fuels. *Remote sensing of Environment* 114, 725-737.

Erikson, M., 2004. Species classification of individually segmented tree crowns in high-resolution aerial images using radiometric and morphologic image measures. *Remote sensing of Environment* 91, 469-477.

Ettarid, M., Ait M'hand, A., Aloui, R., 2005. Digital true orthophotos generation Proceedings of FIGWW III WG3 Symposium, Annapolis, Maryland.

Flood, M., 2001. LiDAR activities and research priorities in the commercial sector. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 34, 3-8.

Friedman, J.H., Tukey, J.W., 1974. A projection pursuit algorithm for exploratory data analysis. *Computers, IEEE Transactions on* 100, 881-890.

Gruber, M., Perko, R., Ponticelli, M., 2004. The all digital photogrammetric workflow: redundancy and robustness, *ISPRS Commission I W-G I/6: Sensors, Platforms and Imagery*, 232-234.

Hall, A., Louis, J., Lamb, D., 2003. Characterising and mapping vineyard canopy using high-spatial-resolution aerial multispectral images. *Computers & Geosciences* 29, 813-822.

Hollaus, M., Wagner, W., Eberhofer, C., Karel, W., 2006. Accuracy of large-scale canopy heights derived from LiDAR data under operational constraints in a complex alpine environment. *ISPRS Journal of Photogrammetry and Remote Sensing* 60, 323-338.

Honkavaara, E., Arbiol, R., Markelin, L., Martinez, L., Cramer, M., Bovet, S., Chandelier, L., Ilves, R., Klonus, S., Marshal, P., 2009. Digital airborne photogrammetry—A new tool for quantitative remote sensing?—A state-of-the-Art review on radiometric aspects of digital photogrammetric images. *Remote Sensing* 1, 577-605.

Hudak, A.T., Evans, J.S., Stuart Smith, A.M., 2009. LiDAR utility for natural resource managers. *Remote Sensing* 1, 934-951.

Hyyppä, J., Hyyppä, H., Litkey, P., Yu, X., Haggrén, H., Rönholm, P., Pyysalo, U., Pitkänen, J., Maltamo, M., 2004. Algorithms and methods of airborne laser-scanning for forest measurements. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36, 82-89.

Jensen, J., 2005. *Introductory Digital Image Processing: A Remote Sensing Perspective*. Prentice-Hall PTR, Upper Saddle River, NJ.

Jimenez, L.O., Landgrebe, D.A., 1999. Hyperspectral data analysis and supervised feature reduction via projection pursuit. *Geoscience and Remote Sensing, IEEE Transactions on* 37, 2653-2667.

Jutzi, B., Stilla, U., 2006. Range determination with waveform recording laser systems using a Wiener Filter. *ISPRS Journal of Photogrammetry and Remote Sensing* 61, 95-107.

Karoui, M., Deville, Y., Hosseini, S., Ouamri, A., Ducrot, D., 2009. Improvement of remote sensing multispectral image classification by using independent component analysis, *Hyperspectral image and signal processing: Evolution in remote sensing, 2009. Whispers'09. First WorkShop on. IEEE, Grenoble*, 1-4.

Kruskal, J.B., 1969. Toward a practical method wich helps uncover the structure of a set of multivariate observations by finding the linear transformation with optimizes a new index of condensation. *Statistical Computation*.

Lasaponara, R., 2006. On the use of principal component analysis (PCA) for evaluating interannual vegetation anomalies from SPOT/VEGETATION NDVI temporal series. *Ecological Modelling* 194, 429-434.

Lhermitte, S., Verbesselt, J., Verstraeten, W.W., Coppin, P., 2011. A comparison of time series similarity measures for classification and change detection of ecosystem dynamics. *Remote sensing of Environment* 115, 3129-3152.

Li, J., Rao, X., Ying, Y., 2011. Detection of common defects on oranges using hyperspectral reflectance imaging. *Computers and Electronics in Agriculture* 78, 38-48.

Li, X., Yeh, A., 1998. Principal component analysis of stacked multi-temporal images for the monitoring of rapid urban expansion in the Pearl River Delta. *International Journal of Remote Sensing* 19, 1501-1518.

Lin, H.D., Bruce, L.M., 2003. Parametric projection pursuit for dimensionality reduction of hyperspectral data, *Geoscience and Remote Sensing Symposium. IGARSS '03. Proceedings. IEEE*, 3483-3485.

Luzum, B., Starek, M., Slatton, K.C., 2004. Normalizing ALSM intensities, *Geosensing Engineering and Mapping (GEM) Civil and Coastal Engineering Department, University of Florida*.

Markelin, L., Honkavaara, E., Hakala, T., Suomalainen, J., Peltoniemi, J., 2010. Radiometric stability assessment of an airborne photogrammetric sensor in a test field. *ISPRS Journal of Photogrammetry and Remote Sensing* 65, 409-421.

Markelin, L., Honkavaara, E., Peltoniemi, J., Ahokas, E., Kuittinen, R., Hyyppä, J., Suomalainen, J., Kukko, A., 2008. Radiometric calibration and characterization of large-format digital photogrammetric sensors in a test field. *Photogrammetric engineering and remote sensing* 74, 1487-1500.

Moffiet, T., Mengersen, K., Witte, C., King, R., Denham, R., 2005. Airborne laser scanning: Exploratory data analysis indicates potential variables for classification of individual trees or forest stands according to species. *ISPRS Journal of Photogrammetry and Remote Sensing* 59, 289-309.

Pasher, J., King, D.J., 2010. Multivariate forest structure modelling and mapping using high resolution airborne imagery and topographic information. *Remote sensing of Environment* 114, 1718-1732.

Plaza, A., Benediktsson, J.A., Boardman, J.W., Brazile, J., Bruzzone, L., Camps-Valls, G., Chanussot, J., Fauvel, M., Gamba, P., Gualtieri, A., Marconcini, M., Tilton, J.C., Trianni, G., 2009. Recent advances in techniques for hyperspectral image processing. *Remote sensing of Environment* 113, Supplement 1, 110-122.

Rajagopalan, S., Robb, R.A., 2003. Independent component analysis assisted unsupervised multispectral classification, *Proc. SPIE* 5029.

Ribed, P.S., Lopez, A.M., 1995. Monitoring burnt areas by principal components analysis of multi-temporal TM data. *International Journal of Remote Sensing* 16, 1577-1587.

Shah, C.A., Anderson, I., Gou, Z., Hao, S., Leason, A., 2007. Towards the development on next generation remote sensing technology – erdas image incorporates a higher order feature extraction technique based on ICA, *ASPRS 2007 Annual Conference*, Tampa, Florida.

Song, J.H., Han, S.H., Yu, K., Kim, Y.I., 2002. Assessing the possibility of land-cover classification using lidar intensity data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 34, 259-262.

Stensaas, G., Lee, G., 2008. Driving toward a worldwide acceptance procedure for digital airborne sensors, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, 561-566.

Stone, J.V., 2004. Independent component analysis: a tutorial introduction. The MIT Press.

Suárez, J.C., Ontiveros, C., Smith, S., Snape, S., 2005. Use of airborne LiDAR and aerial photography in the estimation of individual tree heights in forestry. *Computers & Geosciences* 31, 253-262.

Thenkabail, P.S., Enclona, E.A., Ashton, M.S., Van Der Meer, B., 2004. Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications. *Remote sensing of Environment* 91, 354-376.

Waser, L.T., Baltsavias, E., Ecker, K., Eisenbeiss, H., Feldmeyer-Christe, E., Ginzler, C., Küchler, M., Zhang, L., 2008b. Assessing changes of forest area and shrub encroachment in a mire ecosystem using digital surface models and CIR aerial images. *Remote sensing of Environment* 112, 1956-1968.

Yu, B., Liu, H., Wu, J., Hu, Y., Zhang, L., 2010. Automated derivation of urban building density information using airborne LiDAR data and object-based method. *Landscape and Urban Planning* 98, 210-219.

Yunfei, B., Guopingb, L., Chunxiang, C., Xiaowen, L., Haoa, Z., Qishenga, H., Linyana, B., Chaoyia, C., 2008. Classification of Lidar Point Cloud and Generation of DTM from LiDAR Height and Intensity Data in Forested Area, *The international archives of the photogrammetry, remote sensing and spatial information sciences*, Beijing 313-318.

Capítulo 6

Conclusiones generales

En esta Tesis Doctoral se han estudiado técnicas para una mejor explotación de sensores espaciales y aerotransportados así como el establecimiento de metodologías de integración y combinación de información procedente de diferentes sensores. Los procedimientos propuestos han sido diseñados para una mejora en los resultados de clasificación de imágenes de manera que:

- Se han analizado las ventajas de emplear técnicas robustas basadas en el concepto de independencia en los procesos de explotación temática en sensores de alta resolución (Capítulo 2).
- Se ha diseñado una metodología para introducir el comportamiento espectral de sensores espaciales y aerotransportados en los procesos de clasificación empleando operadores basados en estadística de primer orden (Capítulo 3).
- La intensidad LiDAR ha sido introducida en los procesos de clasificación junto con la información procedente de sensores multiespectrales aerotransportados (Capítulo 4).

- La separación ciega de señales ha sido empleada en la explotación de la combinación de la intensidad LiDAR y cámaras digitales (Capítulo 5).

De los estudios anteriores se extraen las siguientes conclusiones:

1. El volumen de información geográfica y mas concretamente en forma de imágenes geoespaciales es cada vez mayor. El aumento del número de sensores en funcionamiento así como el avance tecnológico acontecido en los últimos años ha tenido como consecuencia la explotación de información desde nuevas perspectivas. La explotación radiométrica de cámaras áreas digitales, la orientación directa de imágenes o la combinación de sensores tienen como primera consecuencia el aumento de los servicios así como de los productos generados.
2. Las mejoras introducidas en la arquitectura y diseño de sensores son tanto espaciales como radiométricas y espectrales. En el caso de sensores aerotransportados, como cámaras métricas digitales, se pone de manifiesto la opacidad por parte de los fabricantes a la hora informar sobre el comportamiento espectral de estos. Una de las posibles explicaciones se debe a que la explotación de la información capturada desde este punto de vista se aleja de los fines y objetivos para los que este tipo de sensores han sido diseñados, siendo la parte métrica lo importante.
3. Los procesos de clasificación de imágenes digitales se desarrollan en la mayoría de los casos sin tener en cuenta el comportamiento interno del sensor empleado. Analizando la curva de respuesta espectral relativa se observa como la inmensa mayoría de los sensores presentan determinados rangos espectrales compartidos por distintas bandas espectrales. En el caso de emplear operadores basados en estadística de primer orden tal comportamiento tiene como consecuencia que las bandas no generen un espacio ortogonal propio para determinar la distancia Euclidea entre cada pixel y las clases de la leyenda. La modelización de la respuesta espectral relativa mediante la aplicación de mínimos cuadrados y la descomposición a valores

singulares permite generar un operador que traslada la información hacia espacios vectoriales, mejorando la aplicación de este tipo de operadores.

4. Desde un punto de vista geométrico la combinación del sensor LiDAR con cámaras digitales es una realidad hoy día. Los flujos de producción de ortofotografías así como los tiempos de producción de este producto se han visto mejorados. Igualmente la explotación radiométrica del sensor LiDAR es posible mediante la variable intensidad registrada para cada punto. Tal explotación puede desarrollarse directamente con la información recogida en vuelo, no obstante el diseño de metodologías y estrategias en la explotación permiten un mejor aprovechamiento de esta combinación de sensores.
5. La combinación LiDAR con cámaras digitales con fines radiométricos implica en primer lugar la definición de un esquema de filtrado de puntos según las necesidades del proyecto. En el caso de tareas de clasificación de imágenes el filtrado de puntos puede ser enfocado hacia la búsqueda de aquellos puntos que representen fenómenos o elementos que aparezcan también en las imágenes tomadas por la cámara en vuelo.
6. El empleo de la variable intensidad LiDAR ha de ser normalizada atendiendo a la posición relativa entre el sensor y cada uno de los puntos medidos. De este modo los parámetros a tener en cuenta serán la distancia al sensor de forma individual para cada punto y el ángulo de escaneado. La normalización de la intensidad LiDAR permite tener la información de forma más homogénea entre las distintas pasadas que componen un vuelo. Tal homogeneización permite una mejora en los procesos de clasificación al ser combinada con las bandas espectrales de una cámara. Se advierte como no se presentan diferencias apreciables entre los dos métodos de normalización, tal comportamiento invita a emplear procesos donde solo se tenga en cuenta la distancia al reducirse los tiempos de procesamiento dado la gran cantidad de puntos a manipular.
7. La combinación intensidad LiDAR - cámara aérea multispectral se realiza teniendo en cuenta que se están manipulando dos bandas que operan en la misma región del espectro electromagnético, el infrarrojo próximo. La

consecuencia directa es la manipulación información redundante. Tradicionalmente en teledetección se emplea el análisis de componentes principales para trasladar la información hacia espacios donde la información pueda ser explotada de una forma mas adecuada. Si bien este tipo de análisis es ampliamente empleado en teledetección es aconsejable emplear técnicas análisis mas robustas basadas en el concepto de independencia, desarrollando técnicas de separación ciega de señales. Los ensayos realizados muestran como los resultados de clasificación se ven mejorados al aplicar este tipo de técnicas tanto en sensores espaciales y aerotransportados así como en la combinación de estos últimos con LiDAR.

Anexos

Anexo 1 Matrices de confusión

Anexo 1.1 Sensor ASTER

- Resultados imágenes ASTER sin procesar

Distancia error = 0

Class	Ground Truth		Olive tree	Bare soil	Herbaceous	Stubble	Building	Total
	Water	Highway						
Unclassified	0	0	0	0	0	0	0	0
Water	1295	0	0	0	0	0	0	1295
Highway	0	803	0	601	0	36	189	1629
Olive tree	0	172	31900	975	0	53	118	33218
Bare soil	0	350	232	13285	501	366	208	14942
Herbaceous	105	0	0	379	36572	451	0	37507
Stubble	0	0	144	1129	599	13064	150	15086
Building	0	0	58	478	0	150	1685	2371
Total	1400	1325	32334	16847	37672	14120	2350	106048

Distancia error = 5

Class	Ground Truth		Olive tree	Bare soil	Herbaceous	Stubble	Building	Total
	Water	Highway						
Unclassified	1006	1084	27003	14954	29998	10365	1987	86397
Water	289	0	0	0	0	0	0	289
Highway	0	189	0	63	0	1	27	280
Olive tree	0	35	5112	91	0	35	10	5283
Bare soil	0	17	150	1685	35	105	35	2027
Herbaceous	105	0	0	14	7541	199	0	7859
Stubble	0	0	50	35	98	3415	50	3648
Building	0	0	19	5	0	0	241	265
Total	1400	1325	32334	16847	37672	14120	2350	106048

Distancia error = 10

Class	Ground	Truth							Total
	Water	Highway	Olive tree	Bare soil	Herbaceous	Stubble	Building		
Unclassified	690	584	12851	7493	16106	5138	1450	44312	
Water	605	0	0	0	0	0	0	605	
Highway	0	524	1	101	0	10	89	725	
Olive tree	0	79	19199	150	0	33	75	19536	
Bare soil	0	138	146	8581	105	150	116	9236	
Herbaceous	105	0	0	81	21211	250	0	21647	
Stubble	0	0	96	301	250	8468	59	9174	
Building	0	0	41	140	0	71	561	813	
Total	1400	1325	32334	16847	37672	14120	2350	106048	

Distancia error = 20

Class	Ground	Truth							Total
	Water	Highway	Olive tree	Bare soil	Herbaceous	Stubble	Building		
Unclassified	15	150	2180	740	3004	1587	507	8183	
Water	1290	0	0	0	0	0	0	1290	
Highway	0	795	0	291	0	15	98	1199	
Olive tree	0	70	29775	951	0	41	88	30925	
Bare soil	0	310	210	13323	201	315	121	14480	
Herbaceous	95	0	0	310	34001	399	0	34805	
Stubble	0	0	128	850	466	11650	78	13172	
Building	0	0	41	382	0	113	1458	1994	
Total	1400	1325	32334	16847	37672	14120	2350	106048	

Distancia error = 25

Class	Ground	Truth							Total
	Water	Highway	Olive tree	Bare soil	Herbaceous	Stubble	Building		
Unclassified	7	140	1547	601	2254	984	105	5638	
Water	1290	0	0	0	0	0	0	1290	
Highway	0	801	0	501	0	21	108	1431	
Olive tree	0	74	30402	951	0	49	118	31594	
Bare soil	0	310	210	13109	490	366	201	14686	
erbaceous	103	0	0	310	34418	405	0	35236	
Stubble	0	0	131	974	510	12150	140	13905	
Building	0	0	44	401	0	145	1678	2268	
Total	1400	1325	32334	16847	37672	14120	2350	106048	

- Resultados imágenes ASTER procesadas

Distancia error = 0

Class	Ground	Truth							Total
	Water	Highway	Olive tree	Bare soil	Herbaceous	Stubble	Building		
Unclassified	0	0	0	0	0	0	0	0	
Water	1297	0	0	0	0	0	0	1297	
Highway	0	803	0	701	0	25	198	1727	
Olive tree	0	179	31939	972	0	59	101	33250	
Bare soil	0	343	214	13304	502	371	187	14921	
Herbaceous	103	0	1	358	36570	415	0	37447	
Stubble	0	0	128	1118	600	13078	194	15118	
Building	0	0	52	394	0	172	1670	2288	
Total	1400	1325	32334	16847	37672	14120	2350	106048	

Distancia error = 5

Class	Ground	Truth							Total
	Water	Highway	Olive tree	Bare soil	Herbaceous	Stubble	Building		
Unclassified	984	1069	26841	14851	29984	10143	2001	85873	
Water	298	0	0	0	0	0	0	298	
Highway	0	205	0	45	0	10	11	271	
Olive tree	0	25	5288	98	0	21	23	5455	
Bare soil	0	26	105	1796	41	98	30	2096	
Herbaceous	118	0	0	18	7612	150	0	7898	
Stubble	0	0	75	34	35	3698	41	3883	
Building	0	0	25	5	0	0	244	274	
Total	1400	1325	32334	16847	37672	14120	2350	106048	

Distancia error = 10

Class	Ground	Truth							Total
	Water	Highway	Olive tree	Bare soil	Herbaceous	Stubble	Building		
Unclassified	684	579	12571	7358	15486	5025	1358	43061	
Water	598	0	0	0	0	0	0	598	
Highway	0	581	14	98	0	1	124	818	
Olive tree	0	85	19484	161	0	41	122	19893	
Bare soil	0	80	265	8601	53	199	124	9322	
Herbaceous	118	0	0	95	21859	261	0	22333	
Stubble	0	0	0	401	274	8494	34	9203	
Building	0	0	0	133	0	99	588	820	
Total	1400	1325	32334	16847	37672	14120	2350	106048	

Distancia error = 20

Class	Ground Truth		Olive tree	Bare soil	Herbaceous	Stubble	Building	Total
	Water	Highway						
Unclassified	14	135	1830	870	2991	1407	495	7742
Water	1295	0	0	0	0	0	0	1295
Highway	0	801	0	288	0	15	74	1178
Olive tree	0	85	30152	941	0	38	81	31297
Bare soil	0	304	199	13275	105	269	99	14251
Herbaceous	91	0	0	298	34367	311	0	35067
Stubble	0	0	101	861	209	11985	85	13241
Building	0	0	52	314	0	95	1516	1977
Total	1400	1325	32334	16847	37672	14120	2350	106048

Distancia error = 25

Class	Ground Truth		Olive tree	Bare soil	Herbaceous	Stubble	Building	Total
	Water	Highway						
Unclassified	6	140	1541	582	2210	974	99	5552
Water	1295	0	0	0	0	0	0	1295
Highway	0	801	0	498	0	18	198	1515
Olive tree	0	74	30502	941	0	51	101	31669
Bare soil	0	310	203	13285	491	275	175	14739
Herbaceous	99	0	1	299	34486	341	0	35226
Stubble	0	0	72	951	485	12360	107	13975
Building	0	0	15	291	0	101	1670	2077
Total	1400	1325	32334	16847	37672	14120	2350	106048

Anexo 1.2 Sensor IKONOS

- Resultados imágenes IKONOS sin procesar

Distancia error = 0

Class	Ground	Truth					
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	Total
Unclassified	0	0	0	0	0	0	0
Building	4561	204	7500	101	0	0	12366
Highway	341	1635	5148	297	1742	0	9163
Soil	147	145	29180	23	2713	2217	34425
Warehouse	50	15	1450	512	1425	0	3452
Olive tree	31	351	1784	107	4998	1140	8411
Herbaceous	10	0	1450	0	1260	44634	47354
Total	5140	2350	46512	1040	12138	47991	115171

Distancia error = 100

Class	Ground	Truth					
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	Total
Unclassified	4105	1851	26514	741	8541	27145	68897
Building	964	3	169	83	0	0	1219
Highway	15	425	59	39	124	0	662
Soil	10	65	19151	10	214	369	19819
Warehouse	5	1	231	82	154	0	473
Olive tree	31	5	195	85	2951	323	3590
Herbaceous	10	0	193	0	154	20154	20511
Total	5140	2350	46512	1040	12138	47991	115171

Distancia error = 200

Class	Ground	Truth					
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	Total
Unclassified	1952	741	10965	388	4152	10524	28722
Building	2995	152	2001	101	0	0	5249
Highway	101	1155	1854	51	984	0	4145
Soil	36	98	28885	11	1524	750	31304
Warehouse	15	3	981	398	1001	0	2398
Olive tree	31	201	825	91	3521	633	5302
Herbaceous	10	0	1001	0	956	36084	38051
Total	5140	2350	46512	1040	12138	47991	115171

Distancia error = 300

Class	Ground Truth						Total
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	
Unclassified	450	650	4952	130	2514	1101	9797
Building	4405	156	5068	101	0	0	9730
Highway	115	1165	3965	201	1254		6700
Soil	88	99	28935	19	2145	2015	33301
Warehouse	41	6	1009	488	1168	0	2712
Olive tree	31	274	1452	101	4052	1007	6917
Herbaceous	10	0	1131	0	1005	43868	46014
Total	5140	2350	46512	1040	12138	47991	115171

Distancia error = 400

Class	Ground Truth						Total
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	
Unclassified	83	100	152	67	577	190	1169
Building	4510	200	7425	101	0	0	12236
Highway	339	1610	5163	254	1547	0	8913
Soil	125	124	29054	23	2598	2207	34131
Warehouse	42	15	1520	488	1354	0	3419
Olive tree	31	301	1750	107	4852	1102	8143
Herbaceous	10	0	1448	0	1210	44492	47160
Total	5140	2350	46512	1040	12138	47991	115171

- Resultados imágenes IKONOS procesadas

Distancia error = 0

Class	Ground	Truth					Total
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	
Unclassified	0	0	0	0	0	0	0
Building	4614	198	7489	84	0	0	12385
Highway	331	1609	5110	298	1749		9097
Soil	141	241	29480	19	2775	2201	34857
Warehouse	38	13	1398	580	1410	0	3439
Olive tree	15	289	1684	59	5014	1015	8076
Herbaceous	1	0	1351	0	1190	44775	47317
Total	5140	2350	46512	1040	12138	47991	115171

Distancia error = 100

Class	Ground	Truth					Total
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	
Unclassified	185	177	1254	225	1152	1698	4691
Building	4681	170	6985	71	0	0	11907
Highway	150	1521	4951	152	1652	0	8426
Soil	75	201	29230	12	2418	1783	33719
Warehouse	38	7	1152	541	1198	0	2936
Olive tree	10	274	1589	39	4851	989	7752
Herbaceous	1	0	1351	0	867	43521	45740
Total	5140	2350	46512	1040	12138	47991	115171

Distancia error = 200

Class	Ground	Truth					Total
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	
Unclassified	40	151	502	152	452	739	2036
Building	4610	106	7352	78	0	0	12146
Highway	301	1598	5021	215	1710		8845
Soil	141	205	29381	15	2551	2195	34488
Warehouse	37	9	1295	531	1352	0	3224
Olive tree	10	281	1610	49	4951	1005	7906
Herbaceous	1	0	1351	0	1122	44052	46526
Total	5140	2350	46512	1040	12138	47991	115171

Distancia error = 300

Class	Ground Truth						Total
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	
Unclassified	10	144	150	36	201	251	792
Building	4610	98	7413	83	0	0	12204
Highway	326	1600	5109	281	1725	0	9041
Soil	141	213	29479	17	2631	2198	34679
Warehouse	38	10	1325	571	1403	0	3347
Olive tree	14	285	1685	52	4998	1014	8048
Herbaceous	1	0	1351	0	1180	44528	47060
Total	5140	2350	46512	1040	12138	47991	115171

Distancia error = 400

Class	Ground Truth						Total
	Building	Highway	Soil	Warehouse	Olive tree	Herbaceous	
Unclassified	10	138	82	33	188	210	661
Building	4610	101	7425	83	0	0	12219
Highway	326	1600	5110	282	1731	0	9049
Soil	141	213	29480	19	2631	2201	34685
Warehouse	38	13	1379	571	1410	0	3411
Olive tree	14	285	1685	52	4998	1015	8049
Herbaceous	1	0	1351	0	1180	44565	47097
Total	5140	2350	46512	1040	12138	47991	115171

Anexo 1.3 Cámara DMC

- Resultados imágenes DMC sin procesar

Distancia error = 0

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	0	0	0	0	0	0
Tree	680	0	0	0	0	680
Shadows	0	4032	0	0	1515	5547
Wall	0	0	3622	210	0	3832
Building	350	0	80	75740	1061	77231
Highway	0	150	0	3610	8664	12424
Total	1030	4182	3702	79560	11240	99714

Distancia error = 100

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	985	3514	2985	69521	4527	81532
Tree	31	0	0	0	0	31
Shadows	0	616	0	0	931	1547
Wall	0	0	646	110	0	756
Building	14	0	71	9152	941	10178
Highway	0	52	0	777	4841	5670
Total	1030	4182	3702	79560	11240	99714

Distancia error = 200

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	785	3151	2104	53036	3581	62657
Tree	101	0	0	0	0	101
Shadows	0	966	0	0	975	1941
Wall	0	0	1526	174	0	1700
Building	144	0	72	25365	991	26572
Highway	0	65	0	985	5693	6743
Total	1030	4182	3702	79560	11240	99714

Distancia error = 300

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	614	2185	1852	44809	1524	50984
Tree	201	0	0	0	0	201
Shadows	0	1906	0	0	1401	3307
Wall	0	0	1785	198	0	1983
Building	215	0	65	33563	998	34841
Highway	0	91	0	990	7317	8398
Total	1030	4182	3702	79560	11240	99714

Distancia error = 400

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	401	1581	785	25415	851	29033
Tree	521	0	0	0	0	521
Shadows	0	2459	0	0	1421	3880
Wall	0	0	2837	210	0	3047
Building	108	0	80	52394	998	53580
Highway	0	142	0	1541	7970	9653
Total	1030	4182	3702	79560	11240	99714

- Resultados imágenes DMC procesadas

Distancia error = 0

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	0	0	0	0	0	0
Tree	709	0	0	0	0	709
Shadows	0	4084	0	0	1370	5454
Wall	0	0	3631	198	0	3829
Building	321	0	71	75764	1156	77312
Highway	0	98	0	3598	8714	12410
Total	1030	4182	3702	79560	11240	99714

Distancia error = 100

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	771	3101	1985	53249	771	63682
Tree	85	0	0	0	85	85
Shadows	0	1071	0	0	0	1869
Wall	0	0	1696	57	0	1753
Building	174	0	21	25379	174	26415
Highway	0	10	0	875	0	5910
Total	1030	4182	3702	79560	11240	99714

Distancia error = 200

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	651	1582	741	35968	1581	40523
Tree	178	0	0	0	0	178
Shadows	0	2565	0	0	1051	3616
Wall	0	0	2902	75	0	2977
Building	201	0	59	42559	891	43710
Highway	0	35	0	958	7717	8710
Total	1030	4182	3702	79560	11240	99714

Distancia error = 300

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified	145	752	425	6585	962	8869
Tree	596	0	0	0	0	596
Shadows	0	3381	0	0	1302	4683
Wall	0	0	3212	178	0	3390
Building	289	0	65	70296	985	71635
Highway	0	49	0	2501	7991	10541
Total	1030	4182	3702	79560	11240	99714

Distancia error = 400

Class	Ground	Truth				Total
	Tree	Shadows	Wall	Building	Highway	
Unclassified		201	231	1985	295	2712
Tree	709					709
Shadows		3906			1328	5234
Wall			3406	171		3577
Building	321		65	74419	1110	75915
Highway		75		2985	8507	11567
Total	1030	4182	3702	79560	11240	99714

Anexo 2 Código desarrollos para tratamiento datos LiDAR

Anexo 2.1 Módulo lectura formato LAS

```

'*****
'Modulo para leer / escribir y tratar ficheros LAS
'*****
Imports System
Imports System.IO
Imports System.Runtime
Imports System.Runtime.InteropServices

Module UTIL_LAS
    'Estructura que define la cabecera del file_lasivo
    Public Structure header
        Dim File_Signature As String 'File Signature
        Dim Source_ID As UShort 'File Source ID
        Dim GE As UShort 'Global Encoding
        Dim P1 As UInteger 'Project ID - GUID data 1
        Dim P2 As UShort 'Project ID - GUID data 2
        Dim P3 As UShort 'Project ID - GUID data 3
        Dim P4 As String 'Project ID - GUID data 4
        Dim Ver_Major As Byte 'Version Major
        Dim Ver_Minor As Byte 'Version Minor
        Dim System_identify As String 'System Identifier
        Dim Software As String 'Generating Software
        Dim fecha_creacion As UShort 'Fecha de creación
        Dim año_creacion As UShort 'Año de creación
        Dim header_size As UShort 'Tamaño de cabecera
        Dim offset As UInteger 'Offset a datos de puntos
        Dim n_var As UInteger 'Numero de registros de
longitud variable
        Dim pFormat As Byte ' String 'ID del formato de los
puntos
        Dim pLenPointData As UShort 'Point data record
length
        Dim num_point As UInteger 'Numbers of points
records
        Dim num_point_return As ArrayList 'Numero de points
by return. Contiene cinco valores
        Dim x_scale As Double 'X scale factor
        Dim y_scale As Double 'Y scale factor
        Dim z_scale As Double 'Z scale factor
        Dim x_offset As Double
        Dim y_offset As Double
        Dim z_offset As Double
        Dim x_max As Double
        Dim y_max As Double

```

```
        Dim z_max As Double
        Dim x_min As Double
        Dim y_min As Double
        Dim z_min As Double
    End Structure
    'Estructura POINT DATA RECORD FORMAT 1
    Public Structure pFormat_1
        Dim x As Double
        Dim y As Double
        Dim z As Double
        Dim intensidad As UInt16
        Dim retorno As ArrayList '
        Dim num_retornos As ArrayList
        Dim scan_direction As Integer
        Dim edge_line As Integer 'Vale uno solo cuando el
punto es al final del escaneo
        Dim clasificacion As Byte
        Dim scan_angle As Byte 'Valor entre -90 y 90, 0 es
el nadir. El valor negativo es para la izquierda
        Dim File_Marker As Byte
        Dim id As UInt16 'Valor indicnado el ID del fichero
de procedencia
        Dim GPS_Time As Double
    End Structure
    'Estructura para los registros de longitud variable
    Public Structure Variable_record
        Dim reserva As UShort 'Reservado
        Dim id_usuario As String 'Id usuario
        Dim id_record As UShort
        Dim longitud As UShort 'Longitud registro despues
de la cabecera
        Dim descripcion As String
    End Structure
    '-----
    'Procedimiento para leer el formato de punto de tipo 1
    '-----
    Public Sub READ_FORMAT_1(ByVal arch As BinaryReader,
ByVal cabecera As header, ByVal punto As pFormat_1, ByVal
posicion As Long)
        Dim i As Integer
        Dim bit As System.Collections.BitArray
        Dim varbyte() As Byte
        ReDim varbyte(0)
        'Nos posicionamos en el archivo
        arch.BaseStream.Position = posicion
        punto.retorno = New ArrayList
        punto.num_retornos = New ArrayList
        With punto
            .x = arch.ReadInt32 * cabecera.x_scale +
cabecera.x_offset
            .y = arch.ReadInt32 * cabecera.y_scale +
cabecera.y_offset
```

```

        .z = arch.ReadInt32 * cabecera.z_scale +
cabecera.z_offset
        .intensidad = arch.ReadUInt16
Varbyte(0) = arch.ReadByte
bit = New System.Collections.BitArray(varbyte)
For i = 7 To 5 Step -1
    .retorno.Add(bit(i))
Next
For i = 4 To 2 Step -1
    .num_retornos.Add(bit(i))
Next
If bit(1) = True Then
    .scan_direction = 1
Else
    .scan_direction = 0
End If
If bit(0) = True Then
    .edge_line = 1
Else
    .edge_line = 0
End If
.clasificacion = arch.ReadByte
.scan_angle = arch.ReadSByte
.File_Marker = arch.ReadByte
.id = arch.ReadUInt16
.GPS_Time = arch.ReadDouble
End With
End Sub
'-----
'Procedimiento para leer archivo LAS
'-----

Public Sub Read_LAS(ByVal nombre_archivo As String,
ByRef Lista_Puntos As ArrayList, ByVal barraprogreso As
ToolStripProgressBar)
    Dim File_Las As BinaryReader = New
BinaryReader(File.Open(nombre_archivo, FileMode.Open))
    Dim posicion As Double = 0
    Dim cabecera As header
    Dim i As Double
    'Leemos primero la cabecera del archivo LAS. Para
'ello nos posicionamos al principio del file_lasivo
File_Las.BaseStream.Position = 0
cabecera.num_point_return = New ArrayList
With cabecera
    .File_Signature = File_Las.ReadChars(4)
    .Source_ID = File_Las.ReadUInt16
    .GE = File_Las.ReadUInt16
    .P1 = File_Las.ReadUInt32
    .P2 = File_Las.ReadUInt16
    .P3 = File_Las.ReadUInt16
    .P4 = File_Las.ReadChars(8)
    .Ver_Major = File_Las.ReadByte
    .Ver_Minor = File_Las.ReadByte

```

```
.System_identify = File_Las.ReadChars(32)
.Software = File_Las.ReadChars(32)
.fecha_creacion = File_Las.ReadUInt16
.año_creacion = File_Las.ReadUInt16
.header_size = File_Las.ReadInt16
.offset = File_Las.ReadUInt32
.n_var = File_Las.ReadUInt32
.pFormat = File_Las.ReadByte
.pLenPointData = File_Las.ReadUInt16
.num_point = File_Las.ReadUInt32
For i = 1 To 5
    .num_point_return.Add(File_Las.ReadUInt32)
Next
.x_scale = File_Las.ReadDouble
.y_scale = File_Las.ReadDouble
.z_scale = File_Las.ReadDouble
.x_offset = File_Las.ReadDouble
.y_offset = File_Las.ReadDouble
.z_offset = File_Las.ReadDouble
.x_max = File_Las.ReadDouble
.x_min = File_Las.ReadDouble
.y_max = File_Las.ReadDouble
.y_min = File_Las.ReadDouble
.z_max = File_Las.ReadDouble
.z_min = File_Las.ReadDouble
End With
posicion = cabecera.header_size + 1
'Leemos ahora los registros de longitud variable
'Aparecen tantos como marque el campo Number of
variable length records de la cabecera
'una vez leida toda esta información
Dim Registro_Variable As New Variable_record
If cabecera.n_var > 0 Then
    For i = 0 To cabecera.n_var - 1
        posicion = posicion +
Marshal.SizeOf(Registro_Variable)
    Next
End If
'En función del tipo de formato de punto leemos una
u otra estructura
barraprogreso.Minimum = 0
barraprogreso.Maximum = cabecera.num_point
barraprogreso.Value = 0
Select Case cabecera.pFormat
Case 1
    Dim punto As New pFormat_1
    'Para el formato 1
    Application.DoEvents()
    posicion = cabecera.offset
    For i = 0 To cabecera.num_point - 1
        Application.DoEvents()
        READ_FORMAT_1(File_Las, cabecera,
punto, posicion)
```

```
                posicion = posicion +
cabecera.pLenPointData
                Lista_Puntos.Add(Puntonet et al.)
                barraprogreso.Value =
barraprogreso.Value + 1
                Next
                Case Else
                    MsgBox("Formato no programado")
                End Select
                File_Las.Close()
            End Sub
```

Anexo 2.2 Procedimiento para el filtrado de puntos

```
Private Sub filtrado(ByVal sender As System.Object,
ByVal e As System.EventArgs) Handles Button3.Click
'Procedimiento para generar un fichero con los
máximos de un fichero de puntos según una resolución
'El fichero de entrada será X,Y,Z,I
'Por ahora lo que hace es determinar el mínimo y el
máximo
Dim archivo As String 'fichero de puntos inicial
Dim archivo2 As String 'fichero de puntos de salida
Dim filetext As
Microsoft.VisualBasic.FileIO.TextFieldParser
Dim salidatext As StreamWriter
Dim arraycadena As String()
With Me.OpenFileDialog1
.ShowDialog()
archivo = .FileName
End With
With Me.SaveFileDialog1
.ShowDialog()
archivo2 = .FileName
End With
filetext = New
Microsoft.VisualBasic.FileIO.TextFieldParser(archivo)
filetext.TextFieldType = FileIO.FieldType.Delimited
filetext.SetDelimiters(" ")
If IO.File.Exists(archivo2) Then
IO.File.Delete(archivo2)
End If
salidatext = New StreamWriter(archivo2)
'Primero determinamos los valores máximos y mínimos
de cada componente
Dim xmin As Double = 999999999999999999
Dim ymin As Double = 999999999999999999
Dim zmin As Double = 999999999999999999
Dim xmax As Double = -999999999999999999
Dim ymax As Double = -999999999999999999
Dim zmax As Double = -999999999999999999
Dim num_puntos As Double = 0
While Not filetext.EndOfData
Application.DoEvents()
arraycadena = filetext.ReadFields()
If arraycadena(0) < xmin Then
xmin = arraycadena(0)
Else
If arraycadena(0) > xmax Then
xmax = arraycadena(0)
End If
End If
If arraycadena(1) < ymin Then
```

```

        ymin = arraycadena(1)
    Else
        If arraycadena(1) > ymax Then
            ymax = arraycadena(1)
        End If
    End If
    If arraycadena(2) < zmin Then
        zmin = arraycadena(2)
    Else
        If arraycadena(2) > zmax Then
            zmax = arraycadena(2)
        End If
    End If
    num_puntos = num_puntos + 1
End While
Dim num_columnas As Double
Dim num_filas As Double
Dim col As Double
Dim row As Double
Dim resolucion As Double
resolucion = Me.TextBox1.Text
num_columnas = Math.Floor((xmax - xmin) /
resolucion)
num_filas = Math.Floor((ymax - ymin) / resolucion)
Dim raster(0 To num_columnas, 0 To num_filas) As
ArrayList
Dim lista As New ArrayList
'Cerramos el archivo y lo volvemos a abrir para
leer desde el principio todos los puntos
filetext.Close()
filetext = New
Microsoft.VisualBasic.FileIO.TextFieldParser(archivo)
filetext.TextFieldType = FileIO.FieldType.Delimited
filetext.SetDelimiters(" ")
Dim pto As punto
Me.ProgressBar1.Minimum = 0
Me.ProgressBar1.Maximum = num_puntos
Me.ProgressBar1.Value = 0
While Not filetext.EndOfData
    Application.DoEvents()
    arraycadena = filetext.ReadFields()
    col = Math.Floor((arraycadena(0) - xmin) /
resolucion)
    row = Math.Floor((ymax - arraycadena(1)) /
resolucion)
    pto.x = arraycadena(0)
    pto.y = arraycadena(1)
    pto.z = arraycadena(2)
    pto.intensidad = arraycadena(3) (Jimenez-Muñoz
et al.)

    If raster(col, row) Is Nothing Then
        lista = New ArrayList
    Else

```

```
        lista = raster(col, row)
    End If
    lista.Add(pto)
    raster(col, row) = lista
    lista = Nothing
    pto = Nothing
    Me.ProgressBar1.Value = Me.ProgressBar1.Value +
1
    End While
    Dim i As Double
    Dim j As Double
    Dim k As Long
    Dim pto_alto As punto
    'Recorremos la matriz generada y nos quedamos con
el valor de mas cota
    Me.ProgressBar1.Minimum = 0
    Me.ProgressBar1.Maximum = num_columnas * num_filas
    Me.ProgressBar1.Value = 0
    For i = 0 To num_columnas - 1
        Application.DoEvents()
        For j = 0 To num_filas - 1
            Application.DoEvents()
            If Not raster(i, j) Is Nothing Then
                lista = raster(i, j)
                zmax = -99999999
                For k = 0 To lista.Count - 1
                    Application.DoEvents()
                    pto = lista.Item(k)
                    If pto.z > zmax Then
                        pto_alto = pto
                    End If
                Next
                salidatext.WriteLine(pto_alto.x & vbTab
& pto_alto.y & vbTab & pto_alto.z & vbTab &
pto_alto.intensidad)
                pto_alto = Nothing
            End If
            Me.ProgressBar1.Value =
Me.ProgressBar1.Value + 1
        Next
    Next
    salidatext.Close()
end sub
```


Anexo 2.3 Procedimiento para la normalización de la intensidad LiDAR

```

Private Sub
WriteIntensidadNormDepuraToolStripMenuItem1_Click(ByVal sender
As System.Object, ByVal e As System.EventArgs) Handles
WriteIntensidadNormDepuraToolStripMenuItem1.Click
'-----
-----
'Procedimiento para normalizar los valores de intensidad
según distancia
'-----
-----
    Dim distanciaref As Double = 900
    Dim Strlidarin As String 'Cotiene la cadena con el
nombre y ruta del archivo entrada
    Dim Strlidarout As String 'Contiene la cadena con
el nombre y ruta del archivo salida
    Dim Flidarin As BinaryReader 'Lee el fichero LiDAR
en formato binario
    Dim Flidarout_dist As BinaryWriter 'Escribe el
fichero LiDAR en formato binario
    Dim Flidarout_ang As BinaryWriter 'Escribe el
fichero LiDAR en formato binario
    Dim pathTrj As String 'Almacena la ruta de
almacenamiento de los trayectorias de vuelo
    Dim FileTrj As
Microsoft.VisualBasic.FileIO.TextFieldParser
    Dim Toma1 As String()
    Dim Toma2 As String()
    'El usuario seleccionada el fihcero LiDAR a
normalizar
    With Me.OpenFileDialog1
        .Title = "Selección fichero LAS"
        .Filter = "*.las |*.las"
        .ShowDialog()
        Strlidarin = .FileName
    End With
    'El usuario seleccionada el directorio donde se
encuentran las trayectorias del avion.
    With Me.FolderBrowserDialog1
        .ShowDialog()
        pathTrj = .SelectedPath
    End With
    Strlidarout = Strings.Replace(Strlidarin, ".las",
"-distancia.las") 'Renombramos archivo
    IO.File.Copy(Strlidarin, Strlidarout, True)
    Flidarin = New BinaryReader(File.Open(Strlidarin,
FileMode.Open)) 'Abrimos el fichero de entrada de datos LiDAR

```

```
        Flidarout_dist = New
BinaryWriter(IO.File.Open(Strlidarout, FileMode.Open))
'Abrimos el fichero de salida según normalización intensidad
de datos LiDAR
        IO.File.Copy(Strlidarin, Strlidarout, True)
        Strlidarout = Strings.Replace(Strlidarin, ".las",
"-angulo.las") 'Renombramos archivo
        Flidarout_ang = New
BinaryWriter(IO.File.Open(Strlidarout, FileMode.Open))
'Abrimos el fichero de salida según normalización ángulo de
datos LiDAR
        Dim posicion As Double = 0
        Dim cabecera As UTIL_LAS.header 'Almacena en la
estructura tipo header la info de la cabecera
        Dim i As Double
        'Primero se procede a leer la cabecera del archivo
LAS
        'Para ello nos posicionamos al principio del
archivo
        Flidarout_dist.BaseStream.Position = 0
        Flidarout_ang.BaseStream.Position = 0
        cabecera.num_point_return = New ArrayList
        With cabecera
            .File_Signature = Flidarin.ReadChars(Holmgren
et al.)
                .Source_ID = Flidarin.ReadUInt16
                .GE = Flidarin.ReadUInt16
                .P1 = Flidarin.ReadUInt32
                .P2 = Flidarin.ReadUInt16
                .P3 = Flidarin.ReadUInt16
                .P4 = Flidarin.ReadChars(8)
                .Ver_Major = Flidarin.ReadByte
                .Ver_Minor = Flidarin.ReadByte
                .System_identify = Flidarin.ReadChars(32)
                .Software = Flidarin.ReadChars(32)
                .fecha_creacion = Flidarin.ReadUInt16
                .año_creacion = Flidarin.ReadUInt16
                .header_size = Flidarin.ReadInt16
                .offset = Flidarin.ReadUInt32
                .n_var = Flidarin.ReadUInt32
                .pFormat = Flidarin.ReadByte
                .pLenPointData = Flidarin.ReadUInt16
                .num_point = Flidarin.ReadUInt32
                For i = 1 To 5
                    .num_point_return.Add(Flidarin.ReadUInt32)
                Next
                .x_scale = Flidarin.ReadDouble
                .y_scale = Flidarin.ReadDouble
                .z_scale = Flidarin.ReadDouble
                .x_offset = Flidarin.ReadDouble
                .y_offset = Flidarin.ReadDouble
                .z_offset = Flidarin.ReadDouble
                .x_max = Flidarin.ReadDouble
```

```

        .x_min = Flidarin.ReadDouble
        .y_max = Flidarin.ReadDouble
        .y_min = Flidarin.ReadDouble
        .z_max = Flidarin.ReadDouble
        .z_min = Flidarin.ReadDouble
    End With
    posicion = cabecera.header_size + 1
    'Leemos ahora los registros de longitud variable
    'Aparecen tantos como marque el campo Number of
variable length records de la cabecera
    'Lo que se hace es determinar la posición en el
archivo
    Dim Registro_Variable As New
UTIL_LAS.Variable_record
    If cabecera.n_var > 0 Then
        For i = 0 To cabecera.n_var - 1
            posicion = posicion +
Marshal.SizeOf(Registro_Variable)
        Next
    End If
    'En función del tipo de formato de punto leemos una
u otra estructura
    Me.ToolStripProgressBar1.Minimum = 0
    Me.ToolStripProgressBar1.Maximum =
cabecera.num_point
    Me.ToolStripProgressBar1.Value = 0
    Select Case cabecera.pFormat
        Case 1
            Dim punto As New pFormat_1
            'Para el formato 1
            Application.DoEvents()
            posicion = cabecera.offset
            Dim llave As Boolean = False
            Dim contador_aciertos As Double = 0
            Dim contador_negativos As Double = 0
            Dim StrTemp As String()
            Dim incrX As Double
            Dim incrY As Double
            Dim incrZ As Double
            Dim intensidad As UInt16
            Dim distancia As Double
            For i = 0 To cabecera.num_point - 1
                Application.DoEvents()
                READ_FORMAT_1(Flidarin, cabecera,
punto, posicion)
                'Abrimos el archivo que nos interesa
                FileTrj = New
Microsoft.VisualBasic.FileIO.TextFieldParser(pathTrj & "\" &
punto.id & "\" & Math.Floor(CDbl(punto.GPS_Time)) & ".txt")
                FileTrj.TextFieldType =
FileIO.FieldType.Delimited
                FileTrj.SetDelimiters(" ")

```

```
-----  
-----  
'Buscamos el tramos de tiempo GPS donde  
el punto ha sido adquirido  
-----  
-----  
Toma1 = FileTrj.ReadFields()  
While Not FileTrj.EndOfData  
Application.DoEvents()  
Toma2 = FileTrj.ReadFields()  
While Toma2(0) < punto.GPS_Time  
Toma1 = Toma2  
Toma2 = FileTrj.ReadFields()  
End While  
If Not Toma2 Is Nothing Then  
llave = True  
contador_aciertos =  
contador_aciertos + 1  
FileTrj.Close()  
Exit While  
End If  
End While  
If llave = False Then  
contador_negativos =  
contador_negativos + 1  
Else  
'Interpolamos la posición del punto  
de disparo  
'Primero de todo determinamos si la  
pasada va de derecha a izquierda o al contrario  
If Toma1(1) > Toma2(0) Then  
StrTemp = Toma1  
Toma1 = Toma2  
Toma2 = StrTemp  
End If  
'Interpolamos por una simple regla  
de tres la coordenada X,Y,Z de la trayectoria  
incrX = Toma1(1) + (punto.GPS_Time  
- Toma1(0)) * (Toma2(1) - Toma1(1)) / (Toma2(0) - Toma1(0))  
incrY = Toma1(2) + (punto.GPS_Time  
- Toma1(0)) * (Toma2(2) - Toma1(2)) / (Toma2(0) - Toma1(0))  
incrZ = Toma1(3) + (punto.GPS_Time  
- Toma1(0)) * (Toma2(3) - Toma1(3)) / (Toma2(0) - Toma1(0))  
'La distancia al cuadrado entre el  
punto y la posición interpolada  
distancia = Math.Sqrt((punto.x -  
incrX) ^ 2 + (punto.y - incrY) ^ 2 + (punto.z - incrZ) ^ 2)  
Flidarout_dist.BaseStream.Position  
= posicion + 12  
Flidarout_ang.BaseStream.Position =  
posicion + 12  
intensidad =  
Math.Ceiling(punto.intensidad * distancia / distanciaref ^ 2)
```

```

                                'Escribe el valor de la intensidad
normalizada por la distancia
                                Flidarout_dist.Write(intensidad)
                                intensidad =
Math.Ceiling(punto.intensidad * distancia / distanciaref ^ 2 /
Math.Abs(Math.Cos((90 - punto.scan_angle) * Math.PI / 180)))
                                'Escribe el valor de la intensidad
normalizada por la distancia y el angulo
                                Flidarout_ang.Write(intensidad)
                                posicion = posicion +
cabecera.pLenPointData
                                End If
                                Me.ToolStripProgressBar1.Value =
Me.ToolStripProgressBar1.Value + 1
                                Me.ToolStripStatusLabel1.Text =
Me.ToolStripProgressBar1.Value
                                Next
                                Case Else
                                    MsgBox("Formato no programado")
                                End Select
                                Flidarin.Close()
                                Flidarout.Close()
End Sub
```