

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE MÁSTER

Clasificación de imágenes multiespectrales e hiperespectrales de alta resolución para la obtención de cartografía temática en Maspalomas

Titulación: Máster Universitario en Ingeniería de
Telecomunicación

Autor: Juan Daniel Moreno Gázquez

Tutores: Francisco Javier Marcello Ruiz

Dionisio Rodríguez Esparragón

Fecha: Febrero de 2018

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE MÁSTER

**Clasificación de imágenes multispectrales e
hiperespectrales de alta resolución para la
obtención de cartografía temática en Maspalomas**

HOJA DE FIRMAS

Alumno

Fdo.: Juan Daniel Moreno Gázquez

Tutor

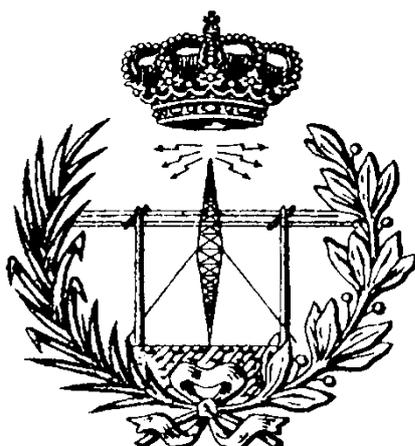
Tutor

Fdo.: Francisco Javier Marcello Ruiz

Fdo.: Dionisio Rodríguez Esparragón

Fecha: Febrero de 2018

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE MÁSTER

**Clasificación de imágenes multiespectrales e
hiperespectrales de alta resolución para la
obtención de cartografía temática en Maspalomas**

HOJA DE EVALUACIÓN

Calificación: _____

Presidente

Fdo.:

Vocal

Secretario/a

Fdo.:

Fdo.:

Fecha: Febrero de 2018

Índice

Parte I Memoria	1
Capítulo 1. Introducción	3
1.1. Antecedentes	3
1.2. Objetivos	4
1.3. Descripción de las tareas.....	5
1.4. Estructura de la memoria	7
Capítulo 2. Sensores de teledetección.....	9
2.1. Fundamentos de la teledetección	9
2.1.1. Firmas espectrales	11
2.1.2. Interferencia atmosférica	12
2.1.3. Sensores de alta resolución	13
2.1.3.1. Fotografías aéreas	15
2.1.3.2. Escáneres multiespectrales	16
2.1.3.3. Sensores hiperespectrales	17
2.2. WorldView-2	19
2.2.1. Características generales de WorldView-2.....	19
2.2.2. Características espectrales de WorldView-2	21
2.2.3. Productos de WorldView-2	22
2.3. CASI	23
2.3.1. Características generales del CASI.....	23
2.3.2. Modos de operación del CASI.....	24
2.3.2.1. Modo espacial	24
2.3.2.2. Modo hiperespectral	25
2.3.3. Productos del CASI	26
Capítulo 3. Técnicas de pre-procesado y correcciones de imágenes	29

3.1. Introducción	29
3.2. Corrección de las distorsiones geométricas	29
3.3. Corrección de las distorsiones radiométricas.....	31
3.4. Corrección atmosférica	32
3.5. Fusión de imágenes.....	33
3.6. Registro de imágenes	35
3.6.1. Introducción	35
3.6.2. Algoritmos de registro de imágenes	35
3.6.3. Alineación de características	36
3.6.4. Modelos de transformación	37
3.6.5. Reconstrucción de imagen	38
3.6.6. Evaluación del registro	39
Capítulo 4. Clasificación de imágenes.....	41
4.1. Clasificación	41
4.1.1. Introducción	41
4.1.2. Fase de entrenamiento	41
4.1.2.1. Método supervisado.....	42
4.1.2.2. Análisis de las estadísticas de entrenamiento	44
4.1.3. Fase de asignación	46
4.1.3.1. Máquina de vectores de soporte.....	46
4.1.4. Fase de verificación de resultados	48
4.1.4.1. Matriz de confusión	49
4.1.5. Obtención y presentación de resultados.....	50
4.1.5.1. Productos cartográficos.....	50
4.1.5.1.1. Formación de una tabla de color.....	50
4.1.5.1.2. Suavizado de los resultados	51
4.1.5.2. Productos estadísticos	52

4.2. Extracción de características.....	52
4.2.1. Reducción dimensional.....	52
4.2.2. Desmezclado espectral.....	54
4.2.3. Textura.....	54
Capítulo 5. Generación de mapas de cobertura terrestre en Maspalomas	57
5.1. Introducción	57
5.1.1. ENVI.....	58
5.2. Metodología	59
5.2.1. Pansharpening	59
5.2.2. Correcciones	60
5.2.3. Redimensionamiento espacial y selección de área	60
5.2.4. Registro de imágenes	61
5.2.5. Clasificación	64
5.2.5.1. ROIs de entrenamiento	64
5.2.5.2 Extracción de características.....	65
5.2.5.3. Clasificación supervisada	66
5.2.5.4. ROIs de evaluación.....	67
5.2.5.5. Post-clasificación.....	67
5.2.5.6. Detección de cambios	67
5.3. Resultados.....	69
5.3.1. Pansharpening.....	69
5.3.2. Redimensionamiento espacial y selección de área	70
5.3.3. Registro de imágenes	70
5.3.4. Clasificación	71
5.3.4.1. Clases y zonas	71
5.3.4.2. ROIs de entrenamiento	72
5.3.4.3. Extracción de características.....	75

5.3.4.4. ROIs de evaluación	80
5.3.4.5. Separabilidad entre clases y firmas espectrales	81
5.3.4.6. Análisis a nivel de clasificador	83
5.3.4.7. Análisis a nivel de clases	85
5.3.4.8. Detección de cambios	90
5.3.4.9. Cartografía temática de Maspalomas.....	91
Capítulo 6. Conclusiones	97
6.1. Revisión de los objetivos	97
6.2. Conclusiones del análisis de los resultados	98
6.3. Líneas futuras.....	100
Bibliografía	103
Parte II Pliego de condiciones.....	111
C1. Pliego de condiciones.....	113
C1.1. Requisitos hardware	113
C1.2. Requisitos software	113
C1.3. Imágenes utilizadas	114
Parte III Presupuesto.....	115
P1. Presupuesto Detallado	117
P1.1. Trabajo Tarifado por Tiempo Empleado	117
P1.2. Amortización del Inmovilizado Material	118
P1.2.1. Amortización del Material Hardware	118
P1.2.2. Amortización del Material Software	119
P1.2.3. Amortización de las Imágenes.....	119
P1.3. Costes de Redacción del TFM.....	120
P1.4. Material Fungible	121
P1.5. Derechos del Visado del COIT.....	121
P1.6. Gastos de Tramitación y Envío	121

P1.7. Aplicación de Impuestos	122
Parte IV Anexos	123
A1. Anexo 1	125
A2. Anexo 2	131
A3. Anexo 3	151
A4. Anexo 4	165

Índice de figuras

Figura 1.1. Diferencias entre sensores multispectrales y sensores hiperespectrales.	4
Figura 2.1. Espectro Electromagnético. El ojo humano sólo puede ver una gama limitada del espectro, mientras que los satélites pueden registrar longitudes de onda visibles, infrarrojas y otras.	10
Figura 2.2. Firmas espectrales del suelo seco y húmedo, vegetación, agua clara y turbia..	12
Figura 2.3. Absorción atmosférica para diferentes longitudes de onda.....	13
Figura 2.4. Relación IFOV- tamaño de píxel.	14
Figura 2.5. Satélite con escáner multispectral. La radiación del área escaneada de la superficie terrestre es registrada por detectores para cada uno de los distintos canales del sensor.....	17
Figura 2.6. Hipercubo capturado por el sensor AVIRIS de la NASA sobre Moffett Field, California, en 1992.	18
Figura 2.7. Subsistemas del satélite WorldView-2.	20
Figura 2.8. Bandas espectrales del satélite WorldView-2.	21
Figura 2.9. a) Aeronave C-212 del INTA y b) Sensor CASI.	23
Figura 2.10. Toma de imagen con sensor hiperespectral de tipo pushbroom.	26
Figura 3.1. Efecto del algoritmo de transferencia en la corrección geométrica de una imagen.	31
Figura 3.2. Triangulación de Delaunay.	38
Figura 3.3. Elección de valor de píxel mediante: a) Vecino más Próximo. b) Interpolación Bilineal. c) Convolución Cúbica.	39
Figura 4.1. Margen de un hiperplano de separación: a) Hiperplano de separación no-óptimo y su margen asociado, τ , (no máximo). b) Hiperplano de separación óptimo y su margen asociado máximo, $\tau_{\text{máx}}$	47
Figura 4.2. Ejemplos estadísticos para caracterización de texturas: a) De primer orden. b) De segundo orden.....	55
Figura 5.1. Imágenes color natural: a) CASI 1500i de junio de 2017. b) WorldView-2 de junio de 2015.	58
Figura 5.2. Esquema de la metodología seguida para el desarrollo de este TFM.	59
Figura 5.3. Redimensionamiento espacial de la imagen WV2 en ENVI.	60
Figura 5.4. Esquema de obtención de la imagen registrada.	61

Figura 5.5. Elección en ENVI de las imágenes de referencia y objetivo.	62
Figura 5.6. Elección en ENVI de los parámetros para la generación de puntos de control.	62
Figura 5.7. a) Puntos de control generados automáticamente en las imágenes CASI y WV2. b) Puntos de control automáticos y añadidos en el registro.	63
Figura 5.8. Selección del área de interés de la imagen WV2 registrada.	64
Figura 5.9. Menú de creación de ROIs en ENVI.....	65
Figura 5.10. Parámetros de coocurrencia en ENVI.	66
Figura 5.11. Parámetros usados en el clasificador SVM en ENVI.....	66
Figura 5.12. Parámetros del análisis de mayoría/minoría en ENVI.	67
Figura 5.13. a) ROI para generación de máscara. b) Máscara generada.	68
Figura 5.14. Refinado de los resultados de la detección de cambios.	69
Figura 5.15. a) Imagen multiespectral. b) Imagen pancromática. c) Imagen fusionada.	69
Figura 5.16. Imagen CASI recortada.....	70
Figura 5.17. Imagen WV2 registrada y recortada.	70
Figura 5.18. a) Imagen WV2 sin registrar frente a imagen CASI. b) Imagen WV2 registrada frente a imagen CASI.	71
Figura 5.19. Ejemplo de ROIs de entrenamiento de la clase arbustos.	73
Figura 5.20. Eigenvalues: a) PCA y b) MNF.	76
Figura 5.21. Muestras de diversas bandas PCA: a) Banda 1. b) Banda 3. c) Banda 5. d) Banda 10. e) Banda 20. f) Banda 30.	77
Figura 5.22. Muestras de diversas bandas MNF: a) Banda 1. b) Banda 3. c) Banda 5. d) Banda 10. e) Banda 20. f) Banda 30.....	77
Figura 5.23. Zoom en mapas de abundancia de la clase arena generados a partir de: a) Bandas espectrales, b) Componentes PCA, c) Componentes MNF, d) Bandas espectrales filtradas, e) Componentes PCA filtradas, f) Componentes MFN filtradas.....	78
Figura 5.24. Información de textura extraída de la imagen CASI usando los siguientes parámetros: a) Media. b) Varianza. c) Entropía.	79
Figura 5.25. Información de textura extraída de la imagen WV2 usando los siguientes parámetros: a) Media. b) Varianza. c) Entropía.	80
Figura 5.26. Firmas espectrales de las clases del primer conjunto de ROIs en: a) CASI. b) WV2.	82
Figura 5.27. Mejores mapas temáticos: a) CASI. b) WorldView-2.	85

Figura 5.28. CASI: Bandas + Textura (ROIs P + M 2): a) Matriz de confusión. b) Gráfica.	88
Figura 5.29. WorldView-2: Bandas espectrales (ROIs P + M 2): a) Matriz de confusión. b) Gráfica.	89
Figura 5.30. Detección de cambios de los mejores mapas clasificados de cada sensor.	91
Figura 5.31. Comparativa de imágenes de Maspalomas: a) Imágenes procedentes de CASI. b) Imágenes procedentes de WV2.	92
Figura 5.32. Caracterización del suelo (GRAFCAN): a) Mapa de ocupación de suelo. b) Mapa de vegetación.	94
Figura 5.33. Comunidades vegetales del campo de dunas de Maspalomas (2003).	95
Figura 5.34. Mapa temático obtenido a partir de la fusión de datos WV2, SAR y LiDAR.	95
Figura A1.1. Separabilidad entre clases por parejas de menor a mayor para las imágenes CASI (izquierda) y WV2 (derecha): a) P + M 1. b) P + M 2. c) Puros. d) Mezclados. e) Evaluación.	129
Figura A2.1. Mapas temáticos obtenidos a partir de las bandas espectrales de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	132
Figura A2.2. Mapas temáticos obtenidos a partir de las 10 primeras componentes PCA de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	134
Figura A2.3. Mapas temáticos obtenidos a partir de las 25 primeras componentes MNF de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	136
Figura A2.4. Mapas temáticos obtenidos a partir de las bandas espectrales de la imagen CASI más la información de textura usando los conjuntos de ROIs: a) P + M 1. b) Puros. c) Mezclados.	138
Figura A2.5. Mapas temáticos obtenidos a partir de los mapas de abundancia generados de las bandas de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	140
Figura A2.6. Mapas temáticos obtenidos a partir de los mapas de abundancia generados de las 10 primeras componentes PCA de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	142

Figura A2.7. Mapas temáticos obtenidos a partir de los mapas de abundancia generados de las 25 primeras componentes MNF de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	144
Figura A2.8. Mapas temáticos obtenidos usando el conjunto de ROIs P + M 1 a partir de los mapas de abundancia generados tras la aplicación de un filtro de mediana de las siguientes combinaciones de la imagen CASI: a) Bandas espectrales. b) 10 primeras componentes PCA. c) 25 primeras componentes MNF.	145
Figura A2.9. Mapas temáticos obtenidos a partir de las bandas espectrales de la imagen WV2 usando los conjuntos de ROIs: a) P + M 1. b) Puros. c) Mezclados.	147
Figura A2.10. Mapas temáticos obtenidos a partir de las bandas espectrales de la imagen WV2 más la información de textura usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	149
Figura A3.1. Matrices de confusión de los mapas temáticos obtenidos a partir de las bandas espectrales de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	153
Figura A3.2. Matrices de confusión de los mapas temáticos obtenidos a partir de las 10 primeras componentes PCA de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	154
Figura A3.3. Matrices de confusión de los mapas temáticos obtenidos a partir de las 25 primeras componentes MNF de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	155
Figura A3.4. Matrices de confusión de los mapas temáticos obtenidos a partir de las bandas espectrales de la imagen CASI más la información de textura usando los conjuntos de ROIs: a) P + M 1. b) Puros. c) Mezclados.	156
Figura A3.5. Matrices de confusión de los mapas temáticos obtenidos a partir de los mapas de abundancia de las bandas espectrales de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	158
Figura A3.6. Matrices de confusión de los mapas temáticos obtenidos a partir de los mapas de abundancia de las 10 primeras componentes PCA de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	159
Figura A3.7. Matrices de confusión de los mapas temáticos obtenidos a partir de los mapas de abundancia de las 25 primeras componentes MNF de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.	160

Figura A3.8. Matrices de confusión de los mapas temáticos obtenidos usando el conjunto de ROIs P + M 1 a partir de los mapas de abundancia generados tras la aplicación de un filtro de mediana de las siguientes combinaciones de la imagen CASI: a) Bandas espectrales. b) 10 primeras componentes PCA. c) 25 primeras componentes MNF. 161

Figura A3.9. Matrices de confusión de los mapas temáticos obtenidos a partir de las bandas espectrales de la imagen WV2 usando los conjuntos de ROIs: a) P + M 1. b) Puros. c) Mezclados..... 162

Figura A3.10. Matrices de confusión de los mapas temáticos obtenidos a partir de las bandas espectrales de la imagen WV2 más la información de textura usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados..... 164

Índice de tablas

Tabla 2.1. Parámetros de sistemas hiperspectrales.	19
Tabla 2.2. Características técnicas generales del sensor CASI.	24
Tabla 2.3. Relación entre bandas espectrales y factor de binning.	25
Tabla 5.1. Colores asignados a la clasificación de la imagen de Maspalomas.....	72
Tabla 5.2. Número de ROIs de entrenamiento de la imagen CASI.....	74
Tabla 5.3. Número de ROIs de entrenamiento de la imagen WV2.	75
Tabla 5.4. Número de ROIs de evaluación.....	81
Tabla 5.5. Fiabilidad global y coeficiente kappa de los datos CASI y WV2.	84
Tabla 5.6. Resumen de las categorías peor y mejor clasificadas, según el sensor utilizado.	86
Tabla 5.7. Estadísticas simplificadas de la detección de cambios.....	91
Tabla 5.8. Inventario de la ocupación del suelo en Maspalomas.	93
Tabla P1.1. Factor de corrección en función del número de horas invertidas.....	118
Tabla P1.2. Precios y costes de amortización de las herramientas hardware.....	119
Tabla P1.3. Precios y costes de amortización de las herramientas software.	119
Tabla P1.4. Precios y costes de amortización de las imágenes empleadas.	120
Tabla P1.5. Presupuesto incluyendo trabajo tarifado y amortización del inmovilizado material.	120
Tabla P1.6. Coste del material fungible.	121
Tabla P1.7. Coste total del trabajo.....	122
Tabla A4.1. Estadísticas completas de la detección de cambios.	165

Parte I
Memoria

Capítulo 1. Introducción

1.1. Antecedentes

En la actualidad cientos de plataformas de observación sobrevuelan la Tierra y generan a diario multitud de imágenes que se emplean en aplicaciones de uso civil y militar. Así, es posible obtener información de diversos objetos sin la necesidad de estar en contacto físico con los mismos. En este contexto aparece el término teledetección.

La teledetección es la técnica de adquisición de datos (imágenes) de la superficie terrestre desde sensores instalados en plataformas espaciales o aeroportadas [1]. Dichos sensores son instrumentos que transforman la radiación electromagnética en información perceptible y analizable [2]. Estos sensores se pueden clasificar según diversas propiedades como la procedencia de la fuente de radiación (activo o pasivo), la resolución espectral, la resolución espacial, etc. En función de su resolución espectral, pueden ser monoespectrales (pancromáticos), multiespectrales o hiperespectrales [3, 4].

Los sensores monoespectrales o pancromáticos toman imágenes que poseen una única banda espectral, habitualmente, situada en la región visible del espectro electromagnético. En cambio, los sensores multiespectrales e hiperespectrales capturan imágenes constituidas por un mayor número de bandas. Aunque existen múltiples diferencias entre una imagen multiespectral y una imagen hiperespectral, la más relevante es que el número de bandas espectrales es mayor en la imagen hiperespectral [5].

Como se observa en la Figura 1.1, un sensor multiespectral captura un menor número de bandas que las que capta un sensor hiperespectral. No obstante, aunque la mayoría de las imágenes hiperespectrales poseen cientos de bandas, lo que caracteriza este tipo de sensor no es el número de longitudes de onda observadas, sino la continuidad y fineza de sus mediciones. Es decir, la amplitud de la longitud de onda entre cada banda [6, 7].

Diferentes tipos de superficies, como el agua, la tierra desnuda o la vegetación, reflejan la radiación de manera distinta en varios canales. La radiación reflejada en función de la longitud de onda se denomina la firma espectral de la superficie [8]. Las imágenes hiperespectrales permiten identificar y distinguir materiales en función de su firma espectral, puesto que con éstas es posible obtener valores en las longitudes de onda continuos (firmas finas), mientras que las firmas de las imágenes multiespectrales sugieren funciones discretas.

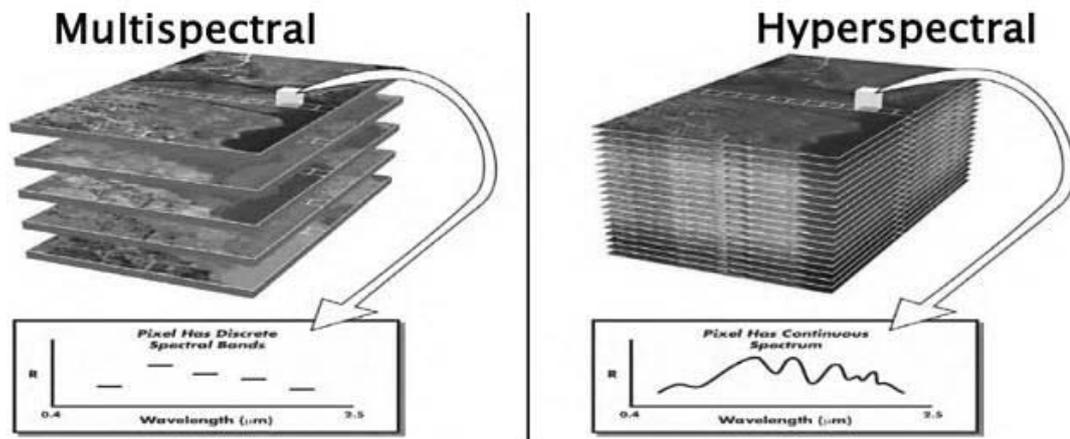


Figura 1.1. Diferencias entre sensores multiespectrales y sensores hiperspectrales. Fuente: http://oa.upm.es/34812/1/PFG_JULIAN_RODRIGUEZ_VILLAMIZAR.pdf

Por otra parte, para sensores satelitales, la resolución espacial de los sensores multiespectrales es, normalmente, mayor que la de los sensores hiperspectrales. Si se desea captar información en muchas bandas espectrales y además con elevada resolución espacial, es necesario recurrir a instrumentos hiperspectrales embarcados en aeronaves o drones. De esta forma, un mayor detalle espacial permite una mejor interpretación de los objetos que componen la escena.

Actualmente, el uso de estas imágenes en aplicaciones de clasificación de zonas urbanas, rurales o boscosas es de gran utilidad debido a su eficiencia para discriminar materiales complejos, gracias a su elevada resolución espectral (especialmente las imágenes hiperspectrales) [9]. En este contexto, el desarrollo de técnicas de clasificación es un continuo foco de investigación con el fin de generar mapas fiables y robustos. Así, la utilización de técnicas de clasificación avanzadas, como las máquinas de vectores de soporte (*Support Vector Machine*, SVM), permiten extraer información espectral de las imágenes citadas anteriormente, así como obtener cartografía temática de forma fiable [9, 10].

1.2. Objetivos

El objetivo principal de este Trabajo de Fin de Máster (TFM) es el procesado de los datos de alta resolución procedentes del satélite WorldView-2 (WV2) y del sensor hiperspectral CASI (*Compact Airborne Spectrographic Imager*) instalado a bordo de una plataforma aérea, capturados en junio de 2015 y 2017, respectivamente, en la zona de Maspalomas. De

esta manera, se pretende generar mapas temáticos de tipos de suelo (vegetación, agua, superficies artificiales, suelo desnudo, etc.) mediante la aplicación del algoritmo clasificador SVM.

Con estas clasificaciones se podrán realizar comparaciones multiplataforma entre ambas tecnologías con el fin de evaluar la idoneidad de cada una de ellas, así como determinar las ventajas y desventajas que aporta el uso de imágenes hiperespectrales con respecto a las multispectrales y en función del sensor utilizado. De esta manera, se comprobará qué tipo de datos permite, de forma más eficiente, la clasificación de materiales de distinta naturaleza y a qué coste computacional.

El lugar de estudio será Maspalomas debido a que es uno de los principales núcleos turísticos de Gran Canaria y consta de diferentes zonas de interés medioambiental. Por un lado, Maspalomas es el complejo vacacional más famoso de Gran Canaria con un gran número de visitantes cada año y muchos hoteles, apartamentos, centros comerciales, campos de golf, etc. Por otro lado, consta de la Reserva Natural de Maspalomas, declarado espacio protegido por primera vez en 1987. Este espacio tiene un área de 403,9 hectáreas de dunas de arena e incluye una charca de gran valor ecológico, así como una zona de nidificación de aves. Es un ecosistema de dunas costeras bien conservado que permaneció en gran parte intacto hasta la década de 1960, cuando el desarrollo turístico a gran escala cambió el área poniendo en peligro su pervivencia. De esta forma, con este trabajo se podrá facilitar la monitorización de los efectos de la presión antrópica, el estado de las dunas o la erosión costera, entre otros.

1.3. Descripción de las tareas

Para la consecución de este objetivo, a lo largo del TFM es necesario abordar las siguientes tareas específicas:

- **Estudio del sensor WV2, sus características espectrales y sus productos.** Se estudiarán las características generales del sensor (tipo de órbita, resolución, período orbital, etc.), así como las características básicas del satélite que lo transporta analizando sus ventajas frente a otros satélites de teledetección. Además, se estudiarán las principales propiedades de sus bandas espectrales y sus tres productos de imágenes disponibles para los usuarios según el nivel de procesamiento.

- **Estudio del sensor CASI, sus modos de operación y sus productos.** Se estudiarán las características generales del sensor tales como el rango espectral, el número de bandas espectrales o la resolución espacial, entre otras. Asimismo, se estudiarán los dos modos de operación en los que puede funcionar el CASI y los productos disponibles, en función del nivel de procesamiento.
- **Estudio y aplicación de técnicas de pre-procesado de imágenes.** Se estudiarán las fuentes que generan errores en las imágenes y se analizarán las técnicas de corrección de dichas distorsiones para posteriormente aplicarlas. Además, se estudiará el proceso de fusión (*pansharpening*) que permite fusionar la banda pancromática con las bandas multispectrales para conseguir una única imagen de mayor resolución espacial.
- **Estudio y aplicación de técnicas de co-registro de datos.** Se estudiará el proceso de transformación que permite alinear geoméricamente dos imágenes para que los píxeles correspondientes representen los mismos objetos. Se analizarán algoritmos de registro de imágenes, técnicas de alineación de características, modelos de transformación y técnicas de reconstrucción de imagen, para su posterior aplicación.
- **Estudio y aplicación de técnicas de clasificación.** Se estudiará todo el proceso de clasificación analizando sus distintas fases: fase de entrenamiento, fase de asignación y fase de evaluación. También se estudiarán las máquinas de vectores de soporte, ya que será el algoritmo de clasificación utilizado.
- **Generación de cartografía temática para Maspalomas.** Se crearán mapas de coberturas terrestres (vegetación, edificios, agua, arena, etc.) de la zona de Maspalomas. Éstos se conseguirán gracias a la aplicación de los procesos estudiados con anterioridad.
- **Detección de cambios entre clasificaciones.** Se aplicarán técnicas de detección de cambios a los mapas con mejores resultados que permitirán analizar las diferencias entre ambos.
- **Extracción de resultados y conclusiones.** Se revisarán los objetivos para comprobar su consecución y se analizarán los resultados, de los cuales se sacarán conclusiones. Por último, se expondrán algunas posibles líneas futuras.

1.4. Estructura de la memoria

El presente documento se compone de cuatro partes: Memoria, Pliego de Condiciones, Presupuesto y Anexos. A su vez, la memoria se divide en seis capítulos que se detallan a continuación:

- **Capítulo 1. Introducción.** En este capítulo se realiza una introducción de los antecedentes de este trabajo y se definen los objetivos marcados para el Trabajo de Fin de Máster.
- **Capítulo 2. Sensores de teledetección.** En este capítulo se estudian los conceptos básicos de los sensores de teledetección y sus principales fundamentos. Además, se explican las características de los sistemas WV2 y CASI, empleados en este TFM.
- **Capítulo 3. Técnicas de pre-procesado y correcciones de imágenes.** En este capítulo se describen las principales técnicas de correcciones y mejoras de los datos para el posterior procesado de las imágenes, incluyendo el proceso de registro de imágenes.
- **Capítulo 4. Clasificación multisensorial.** En este capítulo se presentan las fases necesarias para la clasificación digital de imágenes. Asimismo, se analiza el algoritmo clasificador utilizado en este TFM.
- **Capítulo 5. Generación de mapas de cobertura terrestre en Maspalomas.** En este capítulo se muestra la metodología seguida para la realización de los mapas temáticos de Maspalomas, así como los resultados obtenidos.
- **Capítulo 6. Conclusiones.** En este capítulo se revisan los objetivos, estudios y resultados conseguidos. Se extraen las conclusiones vinculadas al trabajo realizado y se presentan algunas de las líneas futuras de investigación.

Capítulo 2. Sensores de teledetección

A continuación, se detallan los principales fundamentos de la teledetección y se describen los sensores empleados en este Trabajo de Fin de Máster: WorldView-2 y CASI.

2.1. Fundamentos de la teledetección

La teledetección consiste en la adquisición de información procedente de objetos tomando y analizando datos empleando instrumentos que no estén en contacto directo con el objeto observado [11].

En teledetección hay tres elementos básicos: una fuente de energía, un objetivo o escena y un sensor. Brevemente, se explican cada uno de estos elementos [12]:

- La **fuente de energía** es la que “ilumina” el objetivo en función de la radiación de una onda electromagnética. También puede medirse el calor que se desprende de la superficie del objetivo (infrarrojo térmico). En este caso, el propio objetivo es la fuente de energía (se trata de energía solar almacenada y reemitida).
- El **objetivo o escena** es la porción de la superficie terrestre observada por el satélite. Dependiendo de la resolución del sensor, su dimensión varía de unos pocos m² a algunos miles de km².
- El **sensor** mide la radiación electromagnética que refleja o emite el objetivo. El sensor puede encontrarse en un satélite, en un avión o en un dron sobrevolando el objetivo a diferentes altitudes, desde unos pocos centenares de metros hasta distancias de 36.000 kilómetros en el caso de los satélites meteorológicos.

Como se ha mencionado, la teledetección es la obtención de información de un objeto a distancia, sin necesidad de estar en contacto físico con él. A modo de símil, la vista es un tipo de teledetección. Cuando el ojo ve un objeto, registra la radiación electromagnética (la luz reflejada) de la superficie del objeto. De esta manera, es posible observar su color y su forma gracias a la información que contiene dicha radiación. De igual forma, un escáner a bordo de un satélite registra la radiación electromagnética.

La radiación electromagnética de una superficie es una reflexión (luz solar reflejada), la cual sólo se puede medir durante el día, o una emisión (radiación emitida desde la superficie), que puede ser medida en cualquier momento.

El ojo humano sólo puede percibir radiaciones de una gama limitada del espectro electromagnético (Figura 2.1). Por eso, los instrumentos de teledetección que registran longitudes de onda diferentes al rango visible suponen una extensión del campo visual humano y proporcionan acceso a información adicional del mundo físico que nos rodea.

Un factor clave de la emisión es la temperatura de la superficie. Existe una correlación directa entre la temperatura superficial y el grado de emisiones de una longitud de onda determinada. Así, por ejemplo, el Sol tiene una temperatura superficial de 6.000 Kelvin (K) y su emisión máxima se centra en la gama de luz visible, mientras que la temperatura de la superficie de la Tierra es de unos 290 K y posee una emisión máxima a unos 14 micrómetros (banda térmica de infrarrojos). A partir de las emisiones térmicas de infrarrojos capturadas por sistemas de teledetección es posible calcular la temperatura superficial.

En cartografía, es esencial la capacidad de los satélites de diferenciar entre distintas firmas espectrales, puesto que es fundamental distinguir los diversos tipos de coberturas terrestres [13].

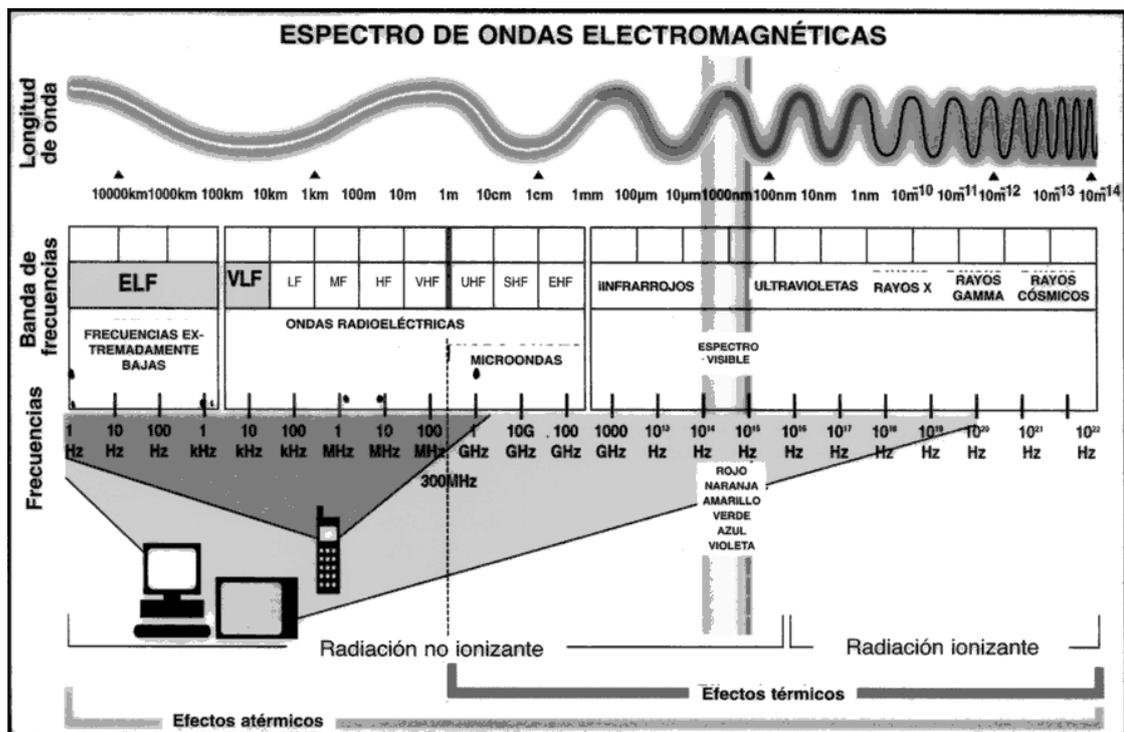


Figura 2.1. Espectro Electromagnético. El ojo humano sólo puede ver una gama limitada del espectro, mientras que los satélites pueden registrar longitudes de onda visibles, infrarrojas y otras. Fuente: <https://rincondelatecnologia.com/wp-content/uploads/2015/03/espectroelectro033.png>

2.1.1. Firmas espectrales

Dependiendo del tipo de superficie (agua, suelo desnudo, vegetación, ...) la radiación se refleja de manera distinta. Como ya se ha mencionado, la radiación reflejada en función de la longitud de onda se llama firma espectral de la superficie (Figura 2.2).

Como se observa en la Figura 2.2, la reflectancia del suelo desnudo aumenta ligeramente de la gama visible a la infrarroja del espectro. Asimismo, se aprecia que existen grandes diferencias entre los distintos tipos de suelo (tierra seca y húmeda). Las distintas composiciones minerales de la superficie también se reflejan en la firma espectral.

En términos generales, el agua sólo refleja la gama de luz visible. Así, puesto que el agua casi no se refleja en la gama del infrarrojo cercano, se distingue muy bien de otras superficies. De esta forma, en imágenes que se registren fuera del visible, las superficies acuáticas aparecerán claramente delimitadas como áreas oscuras (valores de píxel bajos). Además, en función de la turbidez del agua, su grado de reflectancia es mayor o menor.

Por otra parte, la firma espectral de las plantas verdes es muy característica. Para utilizarla en la fotosíntesis, la clorofila de una planta en crecimiento absorbe la luz visible y, especialmente, la luz roja (baja reflectancia en el canal visible rojo). No obstante, reflejan eficazmente la luz cercana al infrarrojo (reflectancia elevada en el canal infrarrojo cercano) ya que, de esta manera, evitan calentarse innecesariamente y perder jugos a través de la evaporación. Por tanto, como la reflexión de la vegetación en las gamas cercanas al infrarrojo y visible del espectro varía considerablemente, es posible determinar cuánta área está cubierta de hojas en crecimiento (índice de hojas verdes) a partir del grado de diferencia. En conclusión, las firmas espectrales de distintos materiales permiten distinguir de qué material están cubiertas las áreas observadas [8].

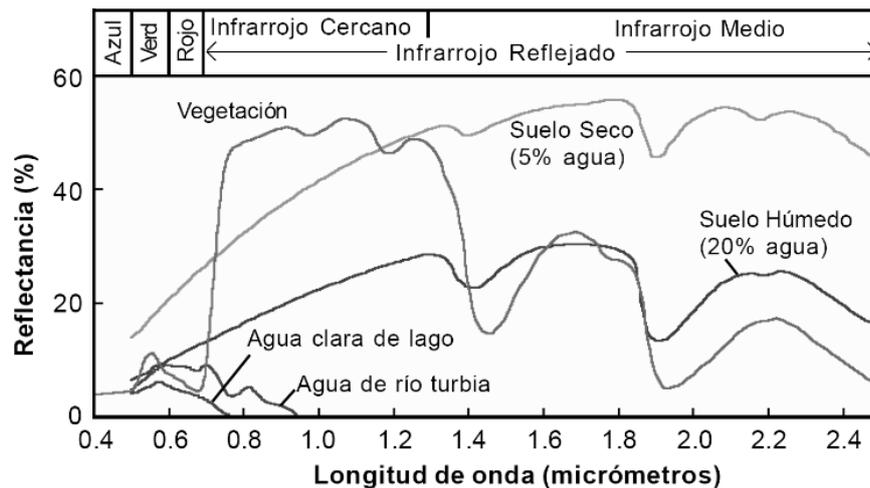


Figura 2.2. Firmas espectrales del suelo seco y húmedo, vegetación, agua clara y turbia. Fuente: <http://eprints.ucm.es/15828/1/T33468.pdf>

2.1.2. Interferencia atmosférica

Antes de alcanzar el sensor del satélite, la radiación del Sol y la reflexión de la superficie de la Tierra atraviesan la atmósfera, donde los gases atmosféricos absorben parte de la radiación. El ozono ejerce de barrera casi perfecta a la radiación ultravioleta, quedando absorbida casi toda la radiación de la gama de 9,5-10 micrómetros. Por su parte, el vapor de agua y el dióxido de carbono absorben la radiación en múltiples longitudes de onda diferentes.

Aquellas longitudes de onda donde la mayoría de la radiación puede atravesar la atmósfera sin ser absorbida se llaman ventanas atmosféricas. Como se observa en la Figura 2.3, la atmósfera permite el paso de una gran cantidad de luz visible, de lo contrario, la luz del día nunca llegaría a la superficie terrestre. Asimismo, la atmósfera es casi un 100 % transparente para ciertas gamas del infrarrojo cercano, lo que posibilita la observación por satélite con un mínimo de distorsión atmosférica. La gama térmica infrarroja de 10-12 micrómetros se usa para medir las temperaturas superficiales del suelo, el agua y las nubes. Además, existe otra ventana en la banda de las microondas.

Incluso si la teledetección se realiza en ventanas atmosféricas, ésta se ve interferida hasta cierto punto por la dispersión y la absorción de la atmósfera. Por eso, la teledetección a menudo queda ligeramente distorsionada y debe ajustarse mediante un posterior procesamiento digital de la imagen que efectúe la corrección atmosférica [14].

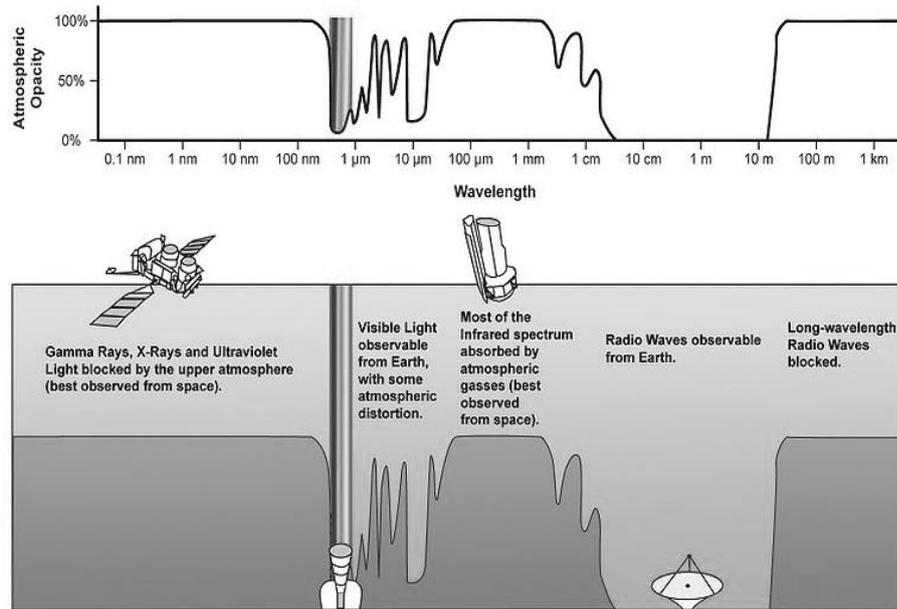


Figura 2.3. Absorción atmosférica para diferentes longitudes de onda. Fuente:

http://earthguide.ucsd.edu/eoc/special_topics/teach/sp_climate_change/p_atmospheric_window.html

2.1.3. Sensores de alta resolución

Los sistemas de percepción remota difieren en la resolución, es decir, el nivel de detalle con que pueden capturar las imágenes, su frecuencia temporal, etc. Desde este punto de vista, se pueden considerar los diferentes tipos de resolución que se explican a continuación [15].

La radiación (emitida o reflejada) de la superficie terrestre es un fenómeno continuo en cuatro dimensiones (espacio, tiempo, longitud de onda y radiancia). Un sensor debe muestrear en este continuo discretizándolo. El modo en que esta discretización se lleva a cabo define los cuatro tipos de resolución con los que se trabaja en teledetección [16]:

- **Resolución espacial.** Es el tamaño del píxel, es decir, designa al objeto más pequeño que puede ser distinguido sobre una imagen. En algunos casos se emplea el concepto de IFOV (campo instantáneo de visión) que se define como la sección angular (en radianes) observada en un momento determinado. La relación entre IFOV y el tamaño del píxel puede verse en la ecuación 2.1 y en la Figura 2.4.

$$d = 2H \tan\left(\frac{IFOV}{2}\right) \quad (2.1)$$

donde d es el tamaño de píxel y H la distancia del sensor a la superficie terrestre.

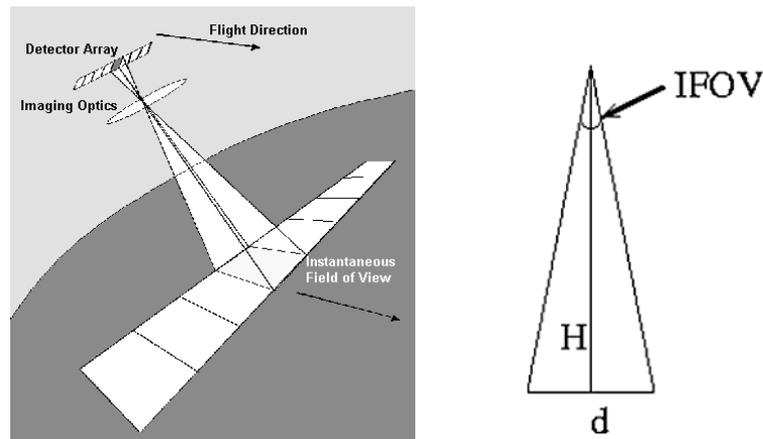


Figura 2.4. Relación IFOV- tamaño de píxel. Fuentes: <https://crisp.nus.edu.sg/~research/tutorial/image.htm> y <http://www.um.es/geograf/sigmur/teledet/tema03.pdf>

La resolución espacial de los sensores electro-ópticos depende de la altura orbital, la velocidad de exploración y el número de detectores.

Esta resolución es fundamental en la interpretación de la imagen ya que determina el detalle que se ofrece. Además, está relacionada con la escala de trabajo y con la fiabilidad de la interpretación.

- **Resolución espectral.** Indica el número y la anchura de las bandas espectrales que puede discriminar el sensor, es decir, en las que el sensor puede captar radiación electromagnética. En principio, cuantas más bandas incluya un sensor mejor, ya que cada banda constituye una variable para caracterizar la superficie captada. Por otro parte, es preferible que estas bandas sean estrechas para que su poder discriminante se incremente. Si las bandas son muy anchas van a recoger valores promediados que ocultarán elementos de diferenciación. Por ejemplo, resulta mucho más informativo contar con 3 bandas (rojo, verde y azul) en el visible que con una sola banda (imagen en escala de gris). El número de bandas y su localización en el espectro va a depender de los objetivos que se pretendan cubrir con la puesta en funcionamiento del sensor.
- **Resolución radiométrica.** Indica la sensibilidad del sensor, es decir, la capacidad de discriminar entre pequeñas variaciones en la radiación que capta. Suele expresarse mediante el número de bits necesarios que se precisan para almacenar cada píxel. Por ejemplo, si un sensor utiliza 8 bits da $2^8 = 256$ niveles de energía

(ND^{*}) que pueden ser captados. Cuanto mayor sea la precisión radiométrica mayor número de detalles podrán captarse en la imagen.

- **Resolución temporal.** Indica el intervalo de tiempo entre cada imagen obtenida por la plataforma espacial en la misma zona. Es de media hora o quince minutos en el caso de los satélites geoestacionarios, y variable en el caso de los satélites heliosíncronos de órbita baja. Además, existen satélites de muy alta resolución espacial con sensores orientables, de manera que la zona de la que captan imágenes es relativamente independiente de la posición que ocupe el satélite, con lo que la resolución temporal pasa a ser algo más flexible.

Estos tipos de resolución están relacionados entre sí. De forma general, cuanto mayor sea la resolución espacial menor será la temporal y la espectral. Asimismo, existe el problema de que cada vez que hay un aumento de resolución el volumen de datos que el sensor debe pre-procesar y enviar a las estaciones terrestres se multiplica. No obstante, gracias a la aparición de sensores de orientación modificable es posible compatibilizar alta resolución espacial y alta resolución temporal a costa de una toma de imágenes sistemática.

Los sensores de un satélite se diseñan considerando todo lo comentado anteriormente. Salvo excepciones, se trabaja en ventanas atmosféricas y se selecciona la combinación de regiones del espectro que más información proporcione sobre los fenómenos que se deseen estudiar.

2.1.3.1. Fotografías aéreas

Para observar el movimiento de las tropas enemigas, durante la Primera Guerra Mundial, se emplearon aviones de reconocimiento con cámaras convencionales instaladas. Las fotografías tomadas posibilitaban determinar la posición y las unidades que poseían los ejércitos enemigos. Estas técnicas de teledetección evolucionaron más durante la Segunda Guerra Mundial, donde se utilizaban fotografías aéreas para elaborar mapas que permitían estudiar las condiciones de la costa para identificar los lugares más adecuados para desembarcar. Además, se calculaban las profundidades del agua a partir de la longitud de

* ND: Abreviatura de nivel digital. Se trata del valor numérico discreto asignado por el sistema formador de imágenes a cada celda en respuesta a la irradiancia recibida sobre el plano focal del sensor. Se le conoce asimismo como nivel de gris, luminancia, número digital, valor de pixel, etc. Existe una relación lineal entre el ND grabado y la radiancia correspondiente a cada celda de terreno [57].

onda medida de las olas cercanas a la costa. Incluso, se usó película infrarroja para diferenciar la vegetación verde de las redes de camuflaje.

En los años 60 se desarrollaron películas sensibles a distintas longitudes de onda, las cuales se empleaban para representar en mapas diferentes tipos de vegetación. Asimismo, otras tecnologías de teledetección siguieron desarrollándose como, por ejemplo, el empleo de sistemas de radar aerotransportados con los que se realizaron varios proyectos de cartografía.

En 1960 se puso en órbita el primer satélite meteorológico, el TIROS 1. Con este satélite, la US Weather Bureau conseguía diariamente imágenes de las formaciones de nubes, suponiendo un hito en la predicción meteorológica.

Con la puesta en órbita del primer satélite cartográfico (LANDSAT-1, 1972) la tecnología de teledetección no fotográfica progresó muy deprisa. LANDSAT-1 estaba equipado con un escáner multispectral (MSS), una nueva tecnología que supuso un gran avance en el procesado de las imágenes [17].

2.1.3.2. Escáneres multispectrales

En la actualidad, el escáner es un instrumento de gran importancia para la teledetección en aviones o a bordo de satélites. Cada escáner posee detectores diseñados para recibir radiaciones de canales específicos. Dependiendo de cada sensor, el número de canales, su longitud y situación en el espectro electromagnético cambia, lo que permite obtener diferentes características de resolución espectral y espacial. En función de estas combinaciones se establece la utilización para la cual las imágenes del sensor resultan más eficientes.

En la Figura 2.5 a) se observa el diagrama de un escáner de espejo giratorio (*whiskbroom*). La radiación del área escaneada de la Tierra incide en un espejo, desde el que pasa a un filtro óptico que separa las distintas longitudes de onda. La radiación filtrada incide en varios detectores, cada uno de los cuales mide la cantidad de radiación de su sensibilidad particular (canal). El resultado de esta medición es un número que cuantifica la cantidad de radiación de cada canal, lo que significa que el escáner registra datos digitales. En cada área escaneada se da un número (ND) a cada canal, con lo que se obtiene una matriz. Si todos los números de todos los canales se consideran en conjunto representan una firma espectral del área escaneada.

El espejo refleja la radiación de un área cuadrada de la superficie de la Tierra. Tanto el tamaño del área escaneada como la resolución espacial dependen de las características ópticas del satélite.

El espejo gira y avanza al mismo tiempo por su órbita. Cada vez que gira, escanea una nueva línea sobre la Tierra. Como el satélite se mueve sobre su rumbo, un mecanismo de apertura asegura que la luz se admita y se excluya siguiendo un patrón determinado, por lo que las líneas escaneadas se dividen en dos áreas de escaneado. De esta manera, se recopilan los datos para realizar una matriz. Los números de la matriz y los datos digitales se transmiten a estaciones terrestres mediante sistemas de radiocomunicación ordinarios.

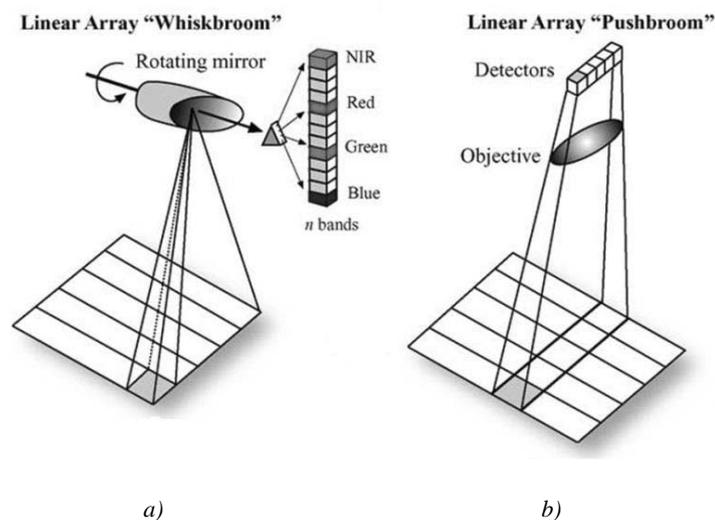


Figura 2.5. Satélite con escáner multiespectral. La radiación del área escaneada de la superficie terrestre es registrada por detectores para cada uno de los distintos canales del sensor. Fuente: <https://www.e-education.psu.edu/geog480/node/494>

El escaneado de empuje (*pushbroom*) consiste en un grupo de detectores dispuestos en línea que se orienta perpendicularmente a la dirección del movimiento (Figura 2.5 b). Los satélites que emplean el escaneado de empuje no giran y, por tanto, el grupo de detectores detecta la matriz al desplazarse el satélite por su trayectoria. Los satélites militares más avanzados pueden escanear áreas de 10×10 cm o menores. La resolución espacial verdadera se suele mantener en secreto, aunque es suficiente para detectar detalles muy pequeños, como personas, vehículos y pequeñas instalaciones [17].

2.1.3.3. Sensores hiperespectrales

Los sensores hiperespectrales, también llamados espectrómetros, son sistemas que permiten registrar imágenes de una escena en decenas o cientos de bandas continuas. Éstos

operan, normalmente, en las regiones visible e infrarrojo cercano del espectro electromagnético. Puesto que estos sistemas capturan información espectral y espacial, los datos que recopilamos se denominan cubos hiperespectrales o hipercubos. Estos cubos de datos están constituidos por las dos dimensiones espaciales, las cuales están unidas por la dimensión espectral (Figura 2.6) [18].

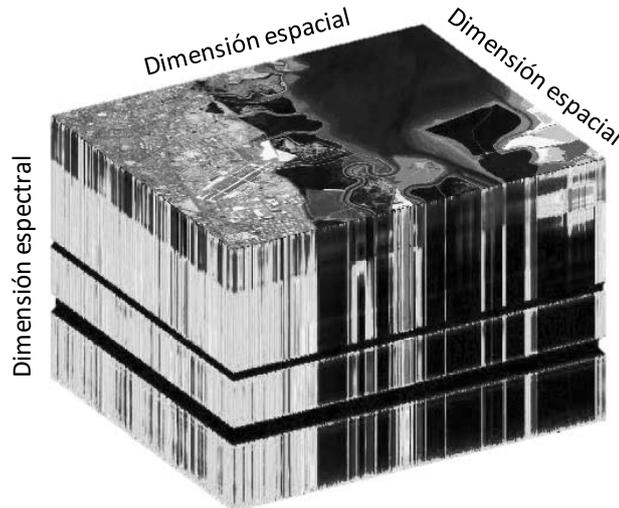


Figura 2.6. Hipercubo capturado por el sensor AVIRIS de la NASA sobre Moffett Field, California, en 1992. Fuente: https://aviris.jpl.nasa.gov/data/image_cube.html

Originalmente, la principal aplicación de los sensores hiperespectrales en teledetección era la identificación de minerales. Sin embargo, en la actualidad, sus aplicaciones son mucho más extensas: monitorización de la salud agrícola, seguridad alimenticia, control de la calidad del agua, etc. Especialmente, la clasificación de imágenes hiperespectrales ha sido un área de investigación muy activa en los últimos años [19, 20].

El desarrollo de los sensores hiperespectrales ha sido posible gracias principalmente a dos componentes fundamentales: la técnica de filtrado espectral, que permite capturar la escena observada en diferentes bandas estrechas; y la tecnología de matriz de detectores, que permite múltiples muestras espaciales o espectrales mediante matrices de una o dos dimensiones [18].

Estos sensores realizan la adquisición de las imágenes hiperespectrales a bordo de aeronaves o sistemas espaciales. Desde principios de la década de los 80, se han adquirido datos hiperespectrales desde sensores aerotransportados. A partir de ese momento, se ha trabajado para desarrollar sensores que proporcionen una alta resolución espectral (normalmente, 10-20 nm). Asimismo, se pueden conseguir imágenes con alta resolución

espacial, dependiendo de la altitud a la que opere la plataforma. Algunos de los sensores aerotransportados más populares en la actualidad son el HyMap, fabricado por Integrated Spectronics Pty Ltd, y el CASI, el cual se analizará en el apartado 2.3 ya que sus imágenes serán empleadas en este TFM. Por otra parte, desde el año 2000 se han utilizado sensores hiperespectrales en plataformas espaciales, siendo el Hyperion el primero en ser lanzado al espacio en el satélite Earth Observing-1 (EO-1) de la NASA [20]. En la Tabla 2.1 se muestran parámetros espaciales y espectrales de nueve sensores hiperespectrales: tres aerotransportados (HYDICE, AVIRIS y CASI 1500) y seis a bordo de sistemas espaciales (HYPERION, EnMAP, PRISMA, CHRIS, HypIRI, IASI).

Tabla 2.1. Parámetros de sistemas hiperespectrales. Fuente: <http://ieeexplore.ieee.org/abstract/document/6555921>

Parámetros	HYDICE	AVIRIS	CASI1500	HYPERION	EnMAP	PRISMA	CHRIS	HypIRI	IASI
Altitud (km)	1,6	20	3	705	653	614	556	626	817
Resolución espacial (m)	0,75	20	0,5-2	30	30	5-30	36	60	V: 1-2 km H: 25 km
Resolución espectral (nm)	7-14	10	<3,5	10	6,5-10	10	1,3-12	4-12	0,5 cm ⁻¹
Rango espectral (µm)	0,4-2,5	0,4-2,5	0,38-1,0	0,4-2,5	0,4-2,5	0,4-2,5	0,4-1,0	0,38-2,5 7,5-12	3,62-15,5 (645-2760 cm ⁻¹)
Número de bandas	210	224	288	220	228	238	63	217	8461

2.2. WorldView-2

2.2.1. Características generales de WorldView-2

WorldView-2 (WV2) fue el primer satélite comercial de alta resolución con 8 bandas multiespectrales. Fue lanzado el 8 de octubre de 2009 a bordo de un cohete Delta 7920 desde la base de la fuerza aérea estadounidense en Vardenberg. Pertenece a la constelación de satélites proporcionada por DigitalGlobe, operador civil y proveedor comercial de imágenes espaciales y de contenido geoespacial [21].

El WV2 se ubicó en una órbita polar heliosíncrona que se encuentra a una altitud de 770 km, proporcionando, en el nadir, un ancho de exploración de 16,4 km y una resolución

espacial de 46 cm para el canal pancromático y de 1,85 m para el multiespectral. Su período orbital es de, aproximadamente, 100 minutos y el tiempo promedio de revisita es de 1,1 días, aunque depende de la latitud. En consecuencia, es capaz de captar datos diariamente de una superficie de casi 975.000 km² [21].

En 2014 fue lanzado WorldView-3, siguiente satélite de la serie, el cual posee características similares a su predecesor y aporta algunas mejoras. En la Figura 2.7 se muestran los diferentes subsistemas que configuran la plataforma WV2.

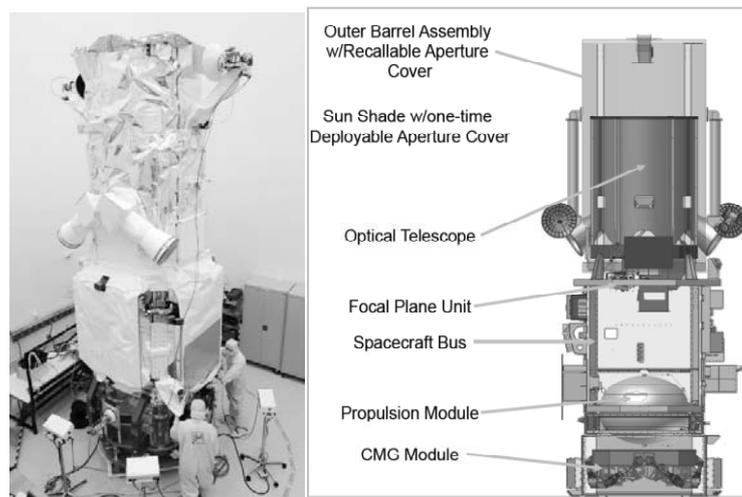


Figura 2.7. Subsistemas del satélite WorldView-2. Fuente: <https://directory.eoportal.org/web/eoportal/satellite-missions/v-w-x-y-z/worldview-2>

Las principales ventajas frente a otros satélites de teledetección de alta resolución son las siguientes [21]:

- **Mayor resolución espectral.** WorldView-2 fue el primer satélite comercial en proporcionar alta resolución espacial e imágenes multiespectrales de 8 bandas. Así, además de las cuatro bandas multiespectrales típicas (azul, verde, rojo e IR cercano), incluye 4 bandas adicionales para mejorar el análisis multiespectral y permitir nuevas aplicaciones.
- **Mayor agilidad.** La serie de satélites WorldView son las primeras plataformas comerciales con capacidad para controlar los momentos de fuerza generados por los giroscopios. Esta tecnología de alto rendimiento proporciona una aceleración hasta 10 veces mayor que la de otros actuadores de control de actitud y mejora la maniobrabilidad y la capacidad de orientación. El tiempo de giro se reduce de más de 60 segundos a sólo 9 segundos para cubrir 300 km, permitiendo obtener imágenes de diferentes zonas en un único pase orbital.

- **Mayor capacidad y revisita.** Gracias a su mayor agilidad, WV2 puede obtener imágenes multiespectrales de diferentes áreas en un solo pase. WV2 tiene una capacidad de exploración de hasta 975.000 km² por día. La combinación de una mayor agilidad en el WV2 y la altura orbital le permite tener una revisita casi diaria.
- **Mejor precisión.** La tecnología avanzada de posicionamiento de WorldView-2 es lo que permite mejoras significativas en su precisión de geolocalización. La especificación de precisión se ha mejorado hasta 6,5 m CE90 sin ningún tratamiento adicional, uso de modelo de elevación, ni puntos de control en tierra, pudiendo llegar hasta 2 m con datos adicionales.

2.2.2. Características espectrales de WorldView-2

WorldView-2 lleva un instrumento que genera una imagen pancromática de alta resolución espacial (0,46 m en el nadir) y ocho bandas espectrales de cuatro veces peor resolución espacial (1,85 m en el nadir), como se muestra en la Figura 2.8.

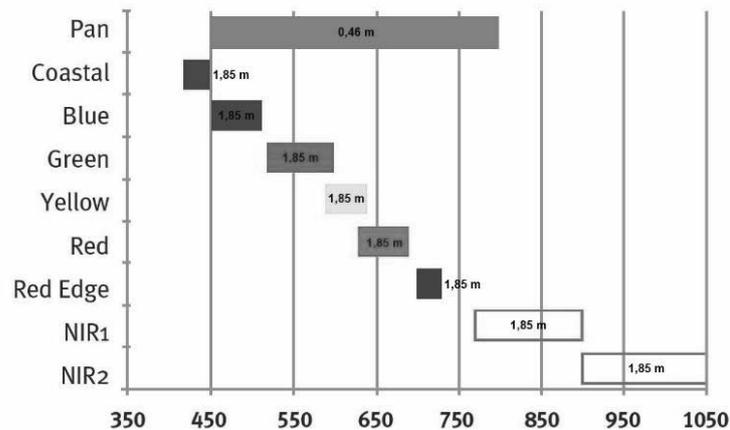


Figura 2.8. Bandas espectrales del satélite WorldView-2. Fuente: <https://www.satimagingcorp.com/satellite-sensors/worldview-2/>

Las bandas multiespectrales son capaces de proporcionar una precisión de color excelente, permitiendo el desarrollo de nuevas aplicaciones. Como se ha mencionado, además de las cuatro bandas multiespectrales tradicionales en el azul, verde, rojo e infrarrojo cercano, se incluyen cuatro bandas adicionales: una centrada en longitudes de onda más corta que el azul, aproximadamente en 427 nm; una banda amarilla, a 608 nm; una banda en el borde del rojo, centrada estratégicamente en, aproximadamente, 724 nm, al ser el inicio de la parte de alta reflectividad de la respuesta de la vegetación; y una adicional en el infrarrojo

cercano, pero a mayor longitud de onda, centrada aproximadamente en 949 nm, que es sensible al vapor de agua atmosférico [22].

Las principales características de las nuevas bandas incluidas son [22]:

- **Azul costero** (400-450 nm). Ayuda en la realización de análisis vegetal. Mayor penetración en el agua, por lo que ayuda en estudios marino-costeros y del agua. Muy útil en los estudios batimétricos. Tiene el potencial para mejorar las técnicas de corrección atmosférica.
- **Amarillo** (585-625 nm). Muy importante para la clasificación. Detecta la “amarillez” particular de la vegetación, tanto en tierra como en el agua.
- **Borde del rojo** (705-745 nm). Muy valiosa para medir la salud de plantas y ayudar en la clasificación de la vegetación. Está más enfocado a la detección de la luz roja por la clorofila en vegetaciones sanas y es muy útil en la clasificación de suelos desnudos, carreteras y caminos y coberturas geológicas.
- **Infrarrojo cercano – NIR2** (860-1040 nm). Se ve menos afectada por la influencia de la atmósfera. Permite el análisis de la vegetación y estudios de la biomasa. Ayuda para la separación de cuerpos de agua y vegetación, así como en la identificación de tipos de vegetación y en la separación entre tipos de suelos.

2.2.3. Productos de WorldView-2

Las imágenes WorldView-2 están disponibles para su adquisición según tres niveles de procesamiento [22, 23]:

- *Basic*, que incluyen únicamente la corrección radiométrica.
- *Standard/Ortho-ready*, que incluyen la corrección radiométrica y geométrica.
- *Stereo*, que incluyen dos escenas superpuestas con ángulos de visión adecuados.

Las bandas multiespectrales (MS) y la pancromática (Pan) se pueden adquirir de forma independiente o conjuntamente. En general, es necesario solicitar un polígono con una superficie en km² cuyo valor mínimo es variable, según se trate de una imagen de archivo o programada. Estos productos se entregan con una alta resolución radiométrica de 16 bits y, si el usuario lo requiere, la imagen puede entregarse con una resolución radiométrica de 8 bits ya sea en formato GeoTIFF o NITF 2.0 o 2.1.

2.3. CASI

2.3.1. Características generales del CASI

El sensor CASI (*Compact Airborne Spectrographic Imager*) es un sensor hiperespectral digital de empuje (*pushbroom*) fabricado por la compañía canadiense ITRES Research Limited. Desde 2009 el Instituto Nacional de Técnica Aeroespacial (INTA) ha estado operando en varias campañas con su versión más reciente: el CASI-1500 (Figura 2.9), el cual está basado en un dispositivo CCD bidimensional, es decir, con una dimensión espacial y otra espectral. Éste mide la radiación entrante a lo largo de 1500 píxeles espaciales “*across-track*” en hasta 288 bandas espectrales. Estas bandas pueden situarse en cualquier lugar dentro de un rango espectral de 670 nm, aproximadamente. Asimismo, el rango de longitudes de onda sobre el que opera es ajustable entre 380 nm hasta 1050 nm, a resoluciones espaciales comprendidas entre 0,5 y 2 metros. De esta forma, CASI es sensible a las longitudes de onda del infrarrojo cercano y de la parte visible del espectro electromagnético [24, 25, 26]. En la tabla 2.2 se resumen sus características técnicas generales.



a)



b)

Figura 2.9. a) Aeronave C-212 del INTA y b) Sensor CASI. Fuentes: http://artemisat2.ulpgc.es/?page_id=13 y <http://www.itres.com/casi-1500/>

Tabla 2.2. Características técnicas generales del sensor CASI. Fuente: <http://www.itres.com/wp-content/uploads/2014/10/CASI-1500.pdf>

Rango espectral	380-1050 nm
N.º canales espectrales	Hasta 288
N.º de píxeles	1500
FOV	40°
IFOV	0,49 mrad
Apertura de diafragma	f/3.5
Ancho espectral	2,4 nm
Resolución espectral (FWHM)	< 3,5 nm
Tamaño del píxel	20 × 20 µm
Resolución radiométrica	14 bits
Distorsión Smile/Keystone	± 0,35 píxeles

2.3.2. Modos de operación del CASI

El sensor CASI puede funcionar en dos modos diferentes:

2.3.2.1. Modo espacial

El modo espacial (en ocasiones llamado modo espectral) se suele emplear cuando se desea la máxima programabilidad espectral. Éste permite programar cada banda espectral de manera única, eligiendo el ancho y la colocación de cada una por separado. Puesto que se pueden programar menos bandas para la recopilación de datos, es posible conseguir tiempos de integración más cortos. Con esto se logran obtener resoluciones espaciales de píxeles menores para una velocidad de la aeronave determinada [27].

Se utilizan los 1500 píxeles y se puede registrar la dimensión espectral completa o subconjuntos de bandas personalizadas (con diferentes binnings* por conjunto) [24].

* Binning: es el proceso de combinar píxeles vecinos de un sensor en un único píxel mayor (“super píxel”). Así, todos los píxeles individuales contribuyen con sus cargas en dicho super píxel. Por ejemplo, con un factor binning 2×2 , la carga de un cuadrado de cuatro píxeles adyacentes se combina en un super píxel [56].

2.3.2.2. Modo hiperespectral

El modo hiperespectral se selecciona cuando se desea maximizar el número de bandas espectrales. En ocasiones, esto supone una disminución de la resolución espacial de los píxeles (los 1500 píxeles se reducen a 1440) o un menor ancho de barrido. En este modo, se pueden utilizar diferentes factores de suma de filas (binning) para dividir la dimensión espectral (filas) del CCD en bandas discretas de igual ancho de banda espectral. De esta forma, se consigue reducir la resolución espectral para incrementar la relación señal a ruido.

Si se emplea un factor de 1, se pueden adquirir hasta 288 bandas espectrales no superpuestas y adyacentes; mientras que empleando un factor de 12 se obtienen 24 bandas adyacentes de anchos iguales. En la Tabla 2.2 se muestra la relación entre el número de bandas espectrales y el factor de suma de filas [24, 27].

Tabla 2.3. Relación entre bandas espectrales y factor de binning. Fuente: <http://www.itres.com/glossary/>

Factor	Bandas espectrales
1	288
2	144
3	96
4	72
6	48
8	36
9	32
12	24

En cuanto a la anchura de barrido, mientras que el modo espacial adquiere automáticamente el número total de píxeles de imagen en la matriz (1500 para el CASI-1500), el modo hiperespectral permite al usuario, de forma opcional, reducir la cobertura del ancho de barrido. Esto supone unas líneas de vuelo más estrechas, siendo necesario que se requiera más tiempo de vuelo para cubrir una zona, lo que permite reducir el tiempo de integración [27].

Tanto en este modo como en el espacial, al modificar el factor de binning y el número de píxeles, es posible alcanzar resoluciones submétricas de hasta 15-20 cm.

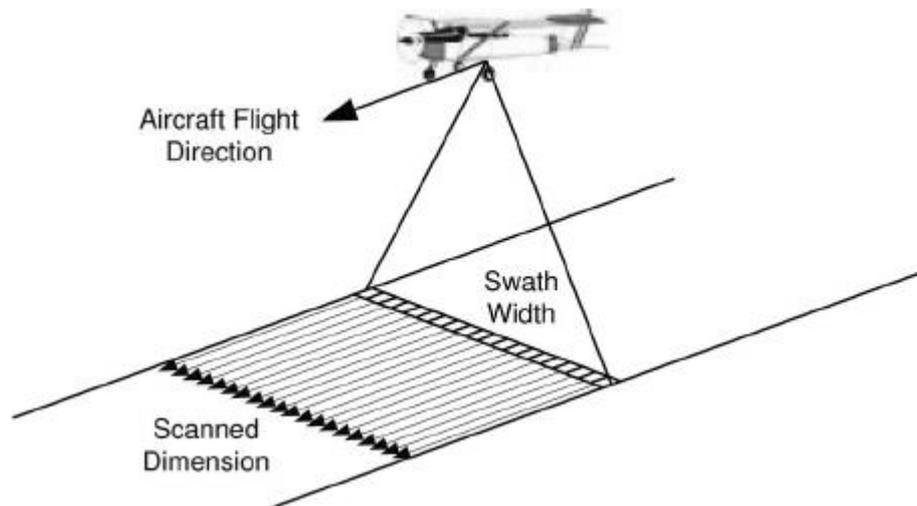


Figura 2.10. Toma de imagen con sensor hiperespectral de tipo pushbroom. Fuente:

https://www.researchgate.net/publication/224453518_Automated_Hyperspectral_Cueing_for_Civilian_Search_and_Rescue

2.3.3. Productos del CASI

El Área de Teledetección del INTA realiza el procesamiento de las imágenes adquiridas con el CASI. Se encuentran disponibles para los usuarios diferentes productos, en función del nivel de procesamiento aplicado sobre las imágenes. Estos niveles siguen las categorías clásicas en imágenes de teledetección: L1a, L1b, L1c, L2b y L2c [24].

Productos de imagen de Nivel 1:

- **L1a.** Datos brutos sin corrección radiométrica o corrección de señal, con archivos en formato Geomatica PIX en lugar de en el formato de captación nativo.
- **L1b.** Radiancias en el sensor georreferenciables en formato de archivo secuencial de banda (*Band Sequential, BSQ*) con cabecera ENVI. Corrección geométrica mediante archivos IGM (*Input Geometry Map*) y productos QA (*Quality Assurance*).
- **L1c.** Radiancias en el sensor georreferenciadas en formato BSQ con cabecera ENVI y productos QA.

Productos de imagen de Nivel 2:

- **L2b.** Factor de reflectancia hemisférica direccional georreferenciable en formato BSQ con cabecera ENVI. Usualmente con corrección geométrica mediante archivos IGM.

- **L2c.** Factor de reflectancia hemisférica direccional georreferenciado en formato BSQ con cabecera ENVI.

Capítulo 3. Técnicas de pre-procesado y correcciones de imágenes

3.1. Introducción

En imágenes de teledetección, la energía captada por cada una de las bandas espectrales sufre una serie de alteraciones (errores) antes de llegar al sensor. Por ello, es necesario conocer la naturaleza de dichos errores para realizar correcciones y mejoras que permitan compensarlos.

Las alteraciones sufridas por las imágenes se deben a diversos factores, de las cuales se pueden considerar las siguientes fuentes de error:

- Distorsiones originadas por instrumentos.
- Distorsiones originadas por la atmósfera.
- Distorsiones originadas por el terreno.

De forma genérica, los errores se pueden clasificar en errores geométricos y radiométricos. En sensores embarcados en satélites o plataformas aeroportados, los datos registrados pueden contener errores en geometría y en la medida de los ND de los píxeles. Por un lado, los errores geométricos pueden ser de dos tipos: errores sistemáticos, introducidos por el sistema de sensores (rotación y curvatura de la Tierra, ángulo de observación, ...); y no sistemáticos, introducidos por fenómenos que varían en tiempo y espacio (variaciones en actitud y posición de la plataforma, pérdida de propiedades del instrumento, ...). Por otro lado, los errores radiométricos pueden deberse a factores como la instrumentación utilizada para registrar los datos, de la dependencia de la longitud de onda en la radiación solar y del efecto atmosférico.

Hay una serie de condicionantes externos a los sensores que afectan en las medidas de las superficies que adquieren los distintos sistemas. El grado de influencia puede ser mayor o menor dependiendo de la plataforma de la que procedan los datos [28].

3.2. Corrección de las distorsiones geométricas

La corrección geométrica engloba las técnicas de corrección de las distorsiones que producen las principales fuentes de error en el momento de la adquisición de la imagen, como son el cabeceo (*pitch*), alabeo (*roll*), giro lateral (*yaw*) y las provocadas por la

trayectoria, altura y velocidad de la plataforma que sustenta al sensor. A éstas hay que añadir los efectos del relieve y de la esfericidad terrestre. Asimismo, se incluyen en estas técnicas las de georreferenciación, es decir, las de asignar una posición geográfica a los píxeles de la imagen.

Los principales factores o fuentes de error geométrico en la imagen son [28]:

- Rotación de la Tierra.
- Ancho campo de visión de algunos sensores.
- Curvatura de la Tierra.
- Variaciones de altitud, actitud y velocidad de la plataforma.
- Efecto panorámico.
- Relieve del terreno.

Estos factores producen una serie de errores geométricos que, en la mayoría de los casos, pueden ser resueltos de forma conjunta, es decir, aplicando una corrección se pueden minimizar los errores procedentes de distintas fuentes.

Dichos errores se deben corregir empleando métodos paramétricos y no paramétricos. En los métodos paramétricos se introducen, de forma directa y mediante sistemas e instrumentación de posicionamiento, los parámetros que intervienen. Por el contrario, en los métodos no paramétricos, los parámetros de transformación se deducen a partir de puntos de control.

Una vez que se tiene la imagen en su “situación” corregida, se transfiere el nivel digital utilizando el de la imagen original. Se hace habitualmente de tres formas [4, 28]:

- **Vecino más próximo** (*Nearest Neighbor*). En la celda de la imagen corregida el ND corresponde al del píxel más cercano de la imagen original.
- **Interpolación bilineal** (*Bilinear*). Promedia los ND de los cuatro píxeles más cercanos en la original. Difumina contrastes espaciales de la imagen original.
- **Convolución cúbica** (*Cubic Convolution*). Considera los ND de los dieciséis píxeles más próximos. Requiere un volumen de cálculo elevado.

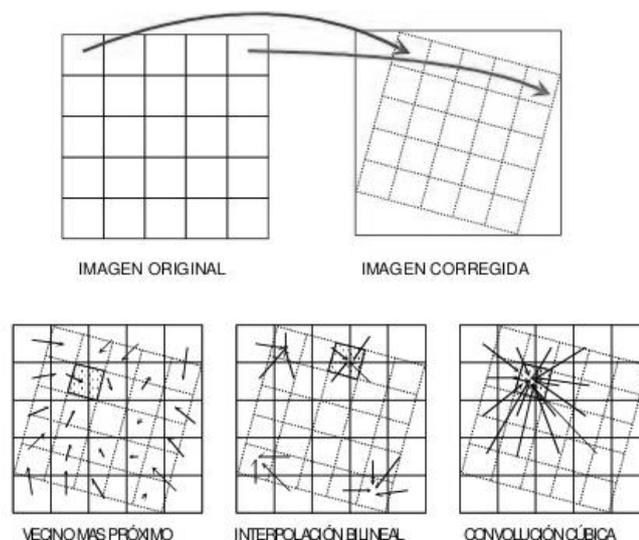


Figura 3.1. Efecto del algoritmo de transferencia en la corrección geométrica de una imagen. Fuente: http://api.eoi.es/api_v1_dev.php/fedora/asset/eoi:45518/componente45516.pdf

En el caso de WorldView-2, este tipo de correcciones ya vienen implementadas en el producto de imagen *ortho-ready*, empleado en este TFM.

Con respecto al sensor CASI, en el producto que se ha utilizado (L2c) ya vienen aplicadas correcciones geométricas. El INTA realiza la calibración geométrica para estimar los ángulos de orientación, es decir, los ángulos entre el eje de la unidad de medición inercial (IMU) y el eje del sensor. La IMU se fija al cuerpo del sensor, pero su sistema de referencia gira ligeramente con respecto al sistema de coordenadas del sensor (y de la imagen). Esto requiere que la relación de ambos sistemas de referencia se determine en términos de desalineaciones de alabeo, cabeceo y giro lateral. Los ángulos de orientación se calculan mediante un ajuste de paquete implementado en la herramienta software *pbsbund* de ITRES. [24].

3.3. Corrección de las distorsiones radiométricas

Los mecanismos que afectan e intervienen en la medida de los valores de brillo de los píxeles pueden ser fuentes de distorsión radiométrica. En primer lugar, la distribución del brillo en la imagen para cada una de las bandas dadas puede ser diferente en la escena y en el terreno. En segundo lugar, el ND relativo de un píxel singular de una banda a otra puede estar distorsionado comparado con la reflectividad espectral correspondiente a la región en el terreno. Ambos tipos de errores pueden ser el resultado conjunto de la presencia de la atmósfera y de la transmisión del medio en relación con la radiación que llega al sensor, y puede ser el resultado también de efectos en la instrumentación [28].

En los productos WorldView-2 las correcciones radiométricas ya vienen aplicadas y simplemente queda pendiente la calibración radiométrica para convertir los ND en valores de radiancia usando las ganancias y offsets del sensor de cada banda.

En el caso del sensor CASI, sus productos (salvo L1a) se ofrecen con las correcciones radiométricas. Además, el INTA realiza la determinación de los coeficientes de calibración radiométrica absoluta al iluminar el sistema con una esfera integradora de Sphere Optics, siguiendo los procedimientos definidos por el fabricante del instrumento [24].

3.4. Corrección atmosférica

Entre el sensor y la superficie terrestre se interpone la atmósfera, que interactúa de formas diversas con el flujo radiante. La atmósfera está compuesta de distintos gases que producen:

- La absorción de la energía en determinadas bandas del espectro.
- La dispersión (o *scattering*) de determinados flujos en función de su longitud de onda.
- La emisión, inherente a todo cuerpo caliente.

Todos estos procesos producen modificaciones en la radiación originalmente propagada entre la cubierta terrestre y el sensor [4, 29].

Generalmente, en los métodos facilitados para la conversión de las imágenes de niveles digitales a valores de reflectividad, no se suele considerar la influencia de la atmósfera, asumiendo, adicionalmente, que se trata de un terreno plano y una observación vertical. Estas consideraciones limitan considerablemente los resultados en el análisis de parámetros físicos sobre una imagen, ya que no se está midiendo realmente la reflectividad medida en la superficie. Por ello, se hace necesario plantear un modelado de la influencia atmosférica.

Habitualmente, los procedimientos de corrección atmosférica se engloban en modelos físicos de transferencia radiativa a partir de información obtenida de la propia imagen y métodos de ajuste empírico. Uno de los modelos más populares es MODTRAN (*MODerate resolution atmospheric TRANsmission*), que permite el cálculo de la transmisividad atmosférica, la radiancia atmosférica, la radiancia solar y lunar monodispersada, la irradiancia solar y lunar y las radiancias polidispersadas solar y térmica. Su principal cometido se basa en proporcionar un método preciso basado en principios físicos que da soporte a la obtención de propiedades atmosféricas y superficiales (como puede ser el albedo

superficial, la altitud, la columna de vapor de agua, la profundidad óptica de aerosol y nube y las temperaturas atmosféricas y superficiales).

Existen varios métodos de corrección atmosférica basados en este modelo. A los datos WV2 se ha aplicado el módulo FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*), el cual se basa en el algoritmo de transferencia de radiación MODTRAN4. El desarrollo de este método ha sido llevado a cabo por Spectral Sciences, Inc. para dar soporte a sensores hiperespectrales y multiespectrales en el rango de aplicación que va desde longitudes de onda del espectro visible, pasando por el infrarrojo, hasta llegar al ultravioleta. Se fundamenta inicialmente en la ecuación estándar de radiancia espectral para cada píxel del sensor, que se aplica al rango de longitud de onda solar (emisión termal es omitida) y superficies lambertianas, planas o sus equivalentes [30].

Para el sensor CASI, ya que los modelos atmosféricos para satélites no son directamente aplicables, el INTA suministra las imágenes corregidas empleando el modelo avanzado ATCOR 4. Este modelo, que utiliza para la corrección atmosférica de sensores con FOV pequeños y anchos, cuenta con una gran base de datos “monocromática” de funciones compilada con el código MODTRAN5. En función del sensor y del rango de altitudes de operación, los archivos de altitud correspondientes de la base de datos monocromática tienen que volver a muestrearse con las funciones de filtro espectral de todos los canales [31].

3.5. Fusión de imágenes

Las técnicas de fusión de datos en teledetección se desarrollan debido al condicionante de diseño de los sensores satelitales de adquisición de imágenes, ya que gracias a éste se produce una relación inversa entre la resolución espectral de los mismos y la resolución espacial a la que pueden registrar datos. Por este motivo, se han desarrollado metodologías cuyo objetivo último es transformar las imágenes multiespectrales, incorporando el detalle espacial a partir de canales pancromáticos de alta resolución, así como respetando el detalle espectral de las multiespectrales. Aunque existen diferentes términos para aludir a este concepto [28], en este TFM se hará referencia a estas técnicas como fusión de imágenes a nivel de píxel (*pansharpening*).

Existe una gran cantidad de algoritmos que se fundamentan en la extracción de la información espacial de la imagen pancromática para combinarla de una forma coherente con la información de la imagen multiespectral. Sin embargo, las metodologías más sencillas

proporcionan imágenes fusionadas con unas características espectrales muy diferentes a las de las imágenes multiespectrales originales, lo cual impide su empleo en diversas tareas de teledetección como la clasificación de imágenes. Por ello, es necesario utilizar técnicas de fusión que hagan distinción entre áreas de más a menos detalle. En este sentido, la dimensión fractal tiene la capacidad para diferenciar entre zonas de distinto detalle dentro de una imagen [32].

En análisis de imágenes, la mayor parte de las aplicaciones de las técnicas fractales se basan en el cálculo de la dimensión fractal, lo cual proporciona una medida de la irregularidad de los objetos complejos y de la homogeneidad de las superficies uniformes. Así, las superficies más rugosas se caracterizan por una dimensión fractal mayor que la de las superficies homogéneas. De esta forma, la dimensión fractal puede utilizarse como indicador para distinguir entre superficies con diversas características texturales. Además, como en las imágenes satelitales es frecuente la presencia de diversos tipos de cubiertas, se suelen emplear medidas locales de la dimensión fractal para diferenciar entre los distintos tipos de cubierta que componen una imagen. Luego, es posible usar esa información para mejorar la calidad de las imágenes fusionadas mediante algún método de fusión [32].

Aunque existe un elevado número de técnicas de fusión, una de las que mejor rendimiento proporciona con imágenes WV2 es el método de transformación *wavelet à trous* ponderado mediante mapas de dimensión fractal (WAT \otimes FRAC), el cual se basa en el algoritmo *wavelet à trous*. En este método se establece un mecanismo que controla el compromiso entre la calidad espacial y espectral introduciendo un factor de ponderación (α_i) a los coeficientes wavelet de la banda pancromática. Sin embargo, este factor sólo discrimina entre distintas bandas espectrales, no entre diferentes cubiertas de suelo, por lo que se define un nuevo factor de ponderación $\alpha_i(x, y)$ para cada punto de cada banda. El factor $\alpha_i(x, y)$ se define como un mapa de dimensión fractal con el mismo tamaño que la imagen original [33].

Esta técnica de fusión será la empleada en este TFM para mejorar la resolución espacial de las bandas multiespectrales de la imagen WV2.

3.6. Registro de imágenes

3.6.1. Introducción

El registro de imágenes puede definirse como el proceso de alineación de dos o más imágenes, o de una o más imágenes con algún otro conjunto de datos.

Teniendo en cuenta que una imagen se define como una matriz de píxeles, la alineación entre varias imágenes se realiza mediante transformaciones matemáticas. Para que queden registradas, las dos imágenes deberían representar mismos sectores para que puedan superponerse, es decir, que los píxeles correspondientes que representen los mismos objetos puedan integrarse. En el caso más simple, una imagen debería ser trasladada o, rotada y trasladada para ser alineada.

Este proceso incluye localizar y alinear regiones similares en dos imágenes [34].

3.6.2. Algoritmos de registro de imágenes

Los algoritmos de registro de imágenes generalmente son clasificados como [35]:

- Basados en puntos. Cuantifican la precisión del registro en base al error en el ajuste de un conjunto de puntos de control (*tie points*, PC), seleccionados en las dos imágenes. Se caracterizan por su reducido coste computacional y su robustez a las diferencias radiométricas o diferente modalidad de las imágenes. Sin embargo, su efectividad depende críticamente del número de PCs utilizados, así como de la precisión con la que han sido seleccionados y de lo representativos que sean de las diferencias geométricas de ambas imágenes (esto es, su distribución). Es muy común la utilización de estos algoritmos en el campo de la teledetección. Esto se debe fundamentalmente a que el tamaño de las imágenes, en ocasiones de varios cientos de megabytes, desaconsejan el uso de cualquier técnica basada en intensidad, mucho más costosas computacionalmente. Por este motivo en este Trabajo de Fin de Máster se ha optado por el empleo de estos algoritmos.
- Basados en intensidad. Cuantifican la precisión del registro mediante la comparación píxel a píxel del contenido de ambas imágenes, requiriendo, por tanto, un mayor esfuerzo computacional para su evaluación. Asimismo, tienen dificultad para discernir cuándo la diferencia de intensidad que presenta un píxel en ambas imágenes se debe a un mal ajuste o a un cambio radiométrico. Esta

circunstancia ocurre típicamente cuando se registran imágenes de diferente modalidad, o de igual modalidad pero que presentan cambios radiométricos importantes. Su principal ventaja es que no requieren seleccionar puntos de control.

Dependiendo de “quién” lleve a cabo el registro de imágenes, éste puede dividirse en dos grandes categorías [34]:

- Registro manual: una persona se encarga del proceso, utilizando un software interactivo. Los usuarios extraen de ambas imágenes puntos distintivos (puntos de control, PC). Luego los PCs correspondientes son utilizados para calcular los parámetros de las transformaciones geométricas.
- Registro automático: todo el proceso de registro se realiza sin intervención humana.

También puede ocurrir que, por su complejidad, sea difícil realizar el registro de forma completamente autónoma, y casi siempre existe algún tipo de umbral que debe ser fijado de antemano por un operador humano. En aquellos casos en los que la supervisión humana sea considerable, puede hablarse de registro semiautomático [36]. Este tipo de registro ha sido el que se ha utilizado en este TFM.

3.6.3. Alineación de características

En cuanto a la manera de medir la similitud entre los puntos o características comunes de dos imágenes, cuando el proceso de registro es automático, principalmente suelen emplearse dos métodos: correlación cruzada (*Cross Correlation*, CC) e información mutua (*Mutual Information*, MI).

El método de correlación cruzada es un tipo de registro que utiliza la mayoría de los píxeles y parte del supuesto de que existe alguna combinación matemática que suministre información de la similitud entre las imágenes. Cuando éstas estén alineadas, se alcanzará un valor óptimo [37].

La CC funciona correctamente para fines generales, especialmente para el registro de imágenes de modalidad similar (por ejemplo, el registro de dos imágenes ópticas) [38].

La información mutua es un método basado en la teoría de la información que busca registrar las imágenes en la misma forma que lo hace un experto, tratando de conseguir que

las dos imágenes en conjunto ofrezcan más información que cada una de ellas por separado [37].

La MI es una medida de la teoría de la información de la dependencia estadística entre dos variables aleatorias o la cantidad de información que una variable contiene acerca de la otra [39].

Este método se interpreta en imágenes con la medida de la información que contiene una imagen objetivo A con respecto a una imagen de referencia B. Matemáticamente, la información mutua se define como [37]:

$$MI(A, B) = H(A) + H(B) - H(A, B) \quad (3.1)$$

o bien la definición normalizada:

$$MI(A, B) = \frac{H(A) + H(B)}{H(A, B)} \quad (3.2)$$

donde $H(A)$ y $H(B)$ denotan la medida de la variación en los valores de intensidad de la imagen A y B. $H(A, B)$ es la medida de la variación de los valores de intensidad de la imagen B con respecto a la imagen A. Dicho de otra forma, la información mutua es la cantidad de información que ofrecen A y B en conjunto.

Cuando dos imágenes no están bien registradas su MI será menor que cuando sí lo están, pues aportan más información cuando las estructuras coinciden. Por lo tanto, se logrará el registro de las imágenes maximizando la información mutua.

Este método está optimizado para el registro de imágenes de diferentes modalidades (por ejemplo, para el registro de imágenes SAR con ópticas) [38].

3.6.4. Modelos de transformación

Para completar el registro de las imágenes es necesario transformar la imagen objetivo para superponer la imagen de referencia. Teniendo en cuenta las diferencias entre la imagen de referencia con la imagen objetivo se pueden definir algunas funciones de transformación como [34]:

- **Rotación, Escala y Traslación (RST).** Es un método simple que emplea la siguiente transformación afín:

$$x = a_1 + a_2X + a_3Y \quad (3.3)$$

$$y = b_1 + b_2X + b_3Y \quad (3.4)$$

- **Polinomial.** Una transformación polinomial de primer orden que incluye un término de interacción XY que permite la inclinación (*shearing*) de la imagen.

$$x = a_1 + a_2X + a_3Y + a_4XY \quad (3.5)$$

$$y = b_1 + b_2X + b_3Y + b_4XY \quad (3.6)$$

- **Triangulación de Delaunay.** Este método alinea las dos imágenes exactamente en las ubicaciones del punto de control. La triangulación es un método recomendado cuando existen distorsiones locales; es decir, cuando no afectan a toda la imagen por igual, en la imagen base y la imagen objetivo.

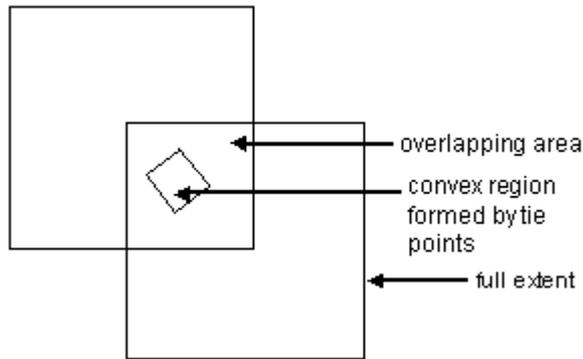


Figura 3.2. Triangulación de Delaunay. Fuente: <http://harrisgeospatial.com/docs/ImageRegistration.html>

3.6.5. Reconstrucción de imagen

Finalmente, un sistema de registro de imágenes debe utilizar múltiples técnicas para la construcción (remuestreo, *resampling*) de la imagen final. Es importante evitar el remuestreo de elementos que degraden el conjunto de datos o la precisión del registro.

El remuestreo se realiza comúnmente mediante muestreo inverso de valores de la imagen para volver a asignar la imagen objetivo a una nueva imagen. Si $f(u, v)$ es la transformación geométrica que alinea la imagen objetivo con la imagen de referencia, entonces la transformación inversa $f^{-1}(x, y)$ es aplicada para mapear un píxel en la nueva imagen objetivo.

Al igual que para la corrección geométrica en imágenes de satélite, se pueden clasificar los métodos de remuestreo de imagen para la registración como [34]:

- **Vecino más próximo.** Usa el valor del píxel más cercano para asignar el valor del píxel de salida.

- **Interpolación bilineal.** Usa los niveles de intensidad de cuatro píxeles en una ventana de 2×2 para calcular el valor del píxel de salida mediante una función lineal. En la interpolación bilineal, el valor del píxel se basa en las distancias entre la posición de la coordenada retransformada (u, v) y los cuatro píxeles más cercanos en la imagen de referencia.
- **Convolución cúbica.** Usa los niveles de intensidad de dieciséis píxeles en una ventana de 4×4 para calcular el valor de píxel de salida con una función cúbica. La convolución cúbica es similar a la interpolación bilineal, salvo que: un conjunto de 16 píxeles, en un arreglo de 4×4 , se promedia para determinar el valor del píxel de salida, y se aproxima mediante una función cúbica, en lugar de lineal, aplicando la misma a 16 valores de entrada.

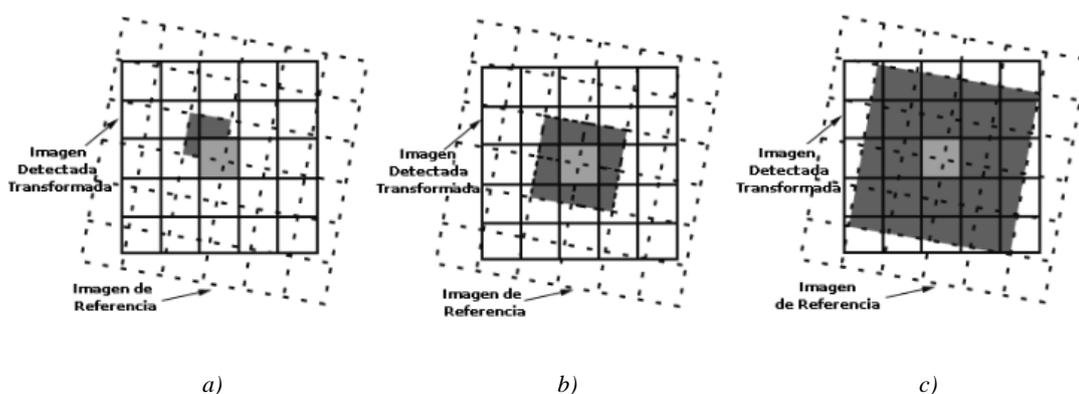


Figura 3.3. Elección de valor de píxel mediante: a) Vecino más Próximo. b) Interpolación Bilineal. c) Convolución Cúbica. Fuente: <http://www2.famaf.unc.edu.ar/institucional/biblioteca/trabajos/638/17035.pdf>

3.6.6. Evaluación del registro

La calidad del registro de imágenes puede valorarse comparando, para cada punto de control, las coordenadas estimadas por la regresión con las reales. El indicador más utilizado, con este objetivo, es el error cuadrático medio (*root mean square*, RMS). Un alto RMS indica que ese punto no se ajusta convenientemente a la transformación imagen/mapa. El promedio de los RMS para todos los puntos de control facilita una evaluación de la calidad general del ajuste. Si ese valor no es satisfactorio, puede optarse por eliminar aquellos puntos con un alto RMS, ya que se asume que no se localizaron correctamente. Al eliminarse algún punto de control, se calcula de nuevo la ecuación de ajuste y los RMS para cada punto [4].

Además de esta evaluación cuantitativa, es necesario realizar un análisis visual del resultado obtenido tras el registro que confirme que ambas imágenes han quedado alineadas.

Capítulo 4. Clasificación de imágenes

4.1. Clasificación

4.1.1. Introducción

En muchos casos es habitual que la clasificación sea la fase culminante del tratamiento digital de imágenes. Las operaciones estudiadas anteriormente se suelen orientar hacia ella, pues los resultados de la clasificación marcan la calidad final del proyecto desarrollado.

Este papel protagonista viene dado por la misma naturaleza de la teledetección espacial. Los ND adquiridos por el sensor no tienen sentido en sí mismos, sino en cuanto son interpretables; es decir, convertibles a categorías o clases que supongan un mejor conocimiento del territorio. Esta interpretación se puede hacer de manera visual, sobre reproducciones fotográficas de las imágenes, o digital, empleando la potencia y rapidez de cálculo que proporciona un ordenador. Como resultado de la clasificación digital se obtiene una cartografía e inventario de las clases objeto de estudio. En definitiva, la información espectral se reúne en un documento cartográfico y en unas tablas estadísticas, que definen la localización y ofrecen el inventario superficial de las categorías de interés.

El proceso de clasificación consta de las siguientes fases: definición digital de las categorías (fase de entrenamiento), distribución de los píxeles de la imagen en una de esas categorías (fase de asignación), y comprobación y evaluación de resultados (fase de verificación de resultados) [4].

4.1.2. Fase de entrenamiento

La clasificación digital comienza con la definición de cada una de las clases que pretenden discriminarse. Puesto que se trata de una clasificación numérica, esta definición también debe ser numérica; esto es, se trata de obtener el rango de ND, que identifica a cada categoría, para todas las bandas que intervienen en la clasificación.

Debido a los diversos factores que introducen cierta dispersión en torno al comportamiento espectral medio de cada cubierta, las distintas categorías no se definen por un solo ND, sino por una serie de ND, más o menos próximos entre sí. En términos de su clasificación digital, esto supone que existe una cierta dispersión en torno al ND que define cada categoría, más o menos significativa según las clases que se consideren y la propia complejidad del paisaje donde éstas se asienten. Por ello, la fase de entrenamiento es un

proceso complejo: se trata de definir con rigor cada una de las categorías que pretenden discriminarse, teniendo en cuenta su propia variabilidad en la zona de estudio.

Este objetivo se consigue al seleccionar una muestra de píxeles de la imagen que representen, adecuadamente, a las clases de interés. A partir de esos píxeles pueden calcularse los ND medios y la variabilidad numérica de cada categoría, en cada una de las bandas que se emplean en la clasificación. Al igual que en cualquier otro muestreo, el propósito de esta fase es obtener los resultados más precisos con el mínimo coste, es decir, identificar debidamente las distintas categorías, reduciendo a lo imprescindible los trabajos de campo. Asimismo, como en otras aplicaciones del muestreo, es fundamental la correcta selección de las muestras para conseguir buenos resultados en la clasificación posterior. Se ha comprobado que los resultados de la clasificación dependen mucho más de la definición previa de las clases que del criterio escogido para posteriormente discriminarlas. En conclusión, la fase de entrenamiento es la parte fundamental de la clasificación numérica.

Tradicionalmente, en función de la manera en que son obtenidas las estadísticas de entrenamiento, los métodos de clasificación se dividen en dos grupos: supervisado y no supervisado. El método supervisado parte de un conocimiento previo del terreno, a partir del cual se seleccionan las muestras para cada una de las categorías. Por su parte, el método no supervisado procede a una búsqueda automática de grupos de valores homogéneos dentro de la imagen. En este caso, corresponde al usuario la labor de encontrar correspondencias entre esos grupos y sus categorías de interés. La elección entre uno y otro método dependerá de los datos y medios disponibles y de las propias preferencias personales [4].

En este capítulo se tratará con mayor profundidad el método supervisado, ya que para la clasificación de las imágenes en este TFM se han aplicado técnicas de clasificación supervisada.

4.1.2.1. Método supervisado

Como se ha mencionado, el método supervisado parte de un cierto conocimiento de la zona de estudio, adquirido por la experiencia previa o por trabajos de campo. Esta familiaridad con la zona de test permite al intérprete delimitar sobre la imagen unas áreas piloto, que se consideran suficientemente representativas de las categorías que componen la leyenda. Estas áreas se denominan regiones o campos de entrenamiento (*training fields*), cuyo término indica que tales áreas sirven para “entrenar” al ordenador en el reconocimiento de las distintas clases. En otras palabras, el ordenador calcula los ND que caracterizan cada

una de las clases, para luego asignar el resto de los píxeles de la imagen a una de esas categorías en función de sus ND [4].

La mayoría de los equipos de tratamiento digital permiten localizar interactivamente las regiones de entrenamiento. Así, el usuario introduce sobre la pantalla los vértices que definen cada una de estas áreas, asignándolas a una de las clases definidas en la leyenda con anterioridad. Como ayuda para realizar una localización más precisa de estas áreas, la consulta de trabajos de campo y otros documentos auxiliares (fotografía aérea o cartografía convencional) puede ser utilidad, considerando que debe tratarse de ejemplos suficientemente representativos y homogéneos de la clase que pretende definirse. Al terminar la delimitación de una región de entrenamiento, pueden seleccionarse otras para la misma categoría, o bien culminar con ella la definición de esa clase. En general, resulta conveniente seleccionar varias regiones por categoría, a fin de reflejar adecuadamente su variabilidad en la zona de estudio.

Finalizada la selección de las áreas de entrenamiento, el ordenador calcula las estadísticas elementales de cada categoría: media, rango, desviación típica, matriz de varianza-covarianza, etc., a partir de los ND de todos los píxeles incluidos en las regiones de entrenamiento asignadas a esa clase. Lógicamente, este cálculo se aplica a todas las bandas que intervendrán en la clasificación. En definitiva, se asume que las áreas de entrenamiento son fieles representantes de las distintas categorías, y que, por tanto, las medidas extraídas a partir de sus ND definen convenientemente a esas clases. De aquí que sea crucial la correcta selección de estas regiones, pues de lo contrario la clasificación estaría viciada desde el inicio, al pretender discriminar categorías con escaso significado espectral.

Un último aspecto a considerar en la selección de las regiones de entrenamiento se refiere a los requisitos estadísticos que garantizan su grado de representatividad de las distintas categorías. Como se ha comentado anteriormente, este proceso es una forma peculiar de muestreo espacial. Por ello, conviene tener en cuenta algunos criterios habituales en este tipo de técnicas para elegir el tamaño y la distribución más idónea de la muestra, así como para realizar estimaciones a partir de ella.

En cuanto al tamaño, se requiere seleccionar un mínimo $m + 1$ píxeles por categoría, siendo m el número de bandas que integran el análisis. No obstante, se recomienda superar con creces este límite mínimo, el cual se relaciona estrechamente con el grado de asociación espacial entre píxeles. Aunque el muestreo convencional considera que las muestras

seleccionadas son aleatorias e independientes, para este caso esto no es válido puesto que una región de entrenamiento alberga a píxeles vecinos, afectados por el fenómeno de autocorrelación espacial. En pocas palabras, esta asociación supone que la información original extraída de un número de píxeles contiguos es menor que si fuese extraída de otros dispersos. En resumen, resulta más conveniente elegir varias regiones de pequeño tamaño, que uno solo de mayores dimensiones, ya que tenderá a infravalorarse la variabilidad de esta clase.

Respecto a la distribución, conviene tener en cuenta las propias características de la imagen, intentando abarcar las variaciones espaciales que se presentan en cada categoría: su orientación, pendiente, densidad, vigor, contenido de humedad, tipo de suelo, etc. En este sentido, varios autores han subrayado que la variabilidad de una cubierta es directamente proporcional a la resolución del sensor. Dicho de otro modo, cuanto mayor sea el detalle espacial registrado en la imagen, mayor será también su sensibilidad para detectar las variaciones internas de una categoría, antes ocultas bajo un píxel de mayor tamaño. Por tanto, a mayor heterogeneidad, mayor mezcla con clases similares, y por ello, mayor riesgo de confusiones en la asignación posterior [4].

4.1.2.2. Análisis de las estadísticas de entrenamiento

Independientemente del método empleado en definir la fase de entrenamiento, antes de abordar el proceso de clasificación propiamente dicho conviene analizar la separabilidad de las categorías seleccionadas, esto es, evaluar la viabilidad de que esas categorías puedan clasificarse sin grave riesgo de error. Por ejemplo, si se comprueba que dos o más son muy similares, habría una gran probabilidad de confusión entre ellas, por lo que resultaría aconsejable: confirmar que las estadísticas de entrenamiento han sido correctamente deducidas; adoptar una leyenda más general, con nuevas categorías que supongan una mezcla de las que ofrecen mayor riesgo de confusión; recabar información auxiliar o imágenes de otras fechas.

Existen varios métodos, tanto gráficos como numéricos, para evaluar las estadísticas de entrenamiento. En este apartado, se tratarán con más detalle los criterios cuantitativos que permiten evaluar numéricamente la posibilidad de discriminar las distintas categorías.

Uno de estos métodos es la divergencia estadística, el cual asume que los ND en una categoría se distribuyen normalmente, tomando la separabilidad como la medida del solape entre categorías vecinas. Puesto que se trata de calcular ese valor para un espacio

multivariado (tantas variables como bandas intervienen en el proceso), se considera el vector de medias y matriz de varianza-covarianza entre pares de categorías. La fórmula de cálculo se sintetiza de la siguiente forma [4, 40]:

$$D_{ij} = \frac{1}{2} \text{tr}[(C_i - C_j)(C_i^{-1} - C_j^{-1})] + \frac{1}{2} \text{tr}[(C_i^{-1} + C_j^{-1})(m_i - m_j)(m_i - m_j)^T] \quad (4.1)$$

donde D_{ij} indica la medida de la divergencia entre las categorías i y j ; tr se refiere a la traza o suma de los elementos de la diagonal de la matriz indicada []; C_i y C_j son las matrices de varianza-covarianza de las categorías i y j ; m_i y m_j son los vectores de medias correspondientes a las mismas categorías y bandas, y $()^T$ indica la matriz traspuesta de la indicada entre corchetes. Cuanto mayor sea el valor de la divergencia, mayor también la separabilidad entre clases, basada, lógicamente, sobre las bandas que se han considerado en su cálculo.

Algunos autores han propuesto transformar este valor, de tal forma que pueda escalarse de acuerdo a un rango conocido. Así, se formula la divergencia transformada [4, 41]:

$$DT_{ij} = 2(1 - e^{-D_{ij}/8}) \quad (4.2)$$

donde la constante de valor 2 es introducida para escalar el resultado entre unos rangos conocidos. Algunos autores recomiendan emplear un valor de 2.000 ó 100.

Además de la divergencia, se han propuesto otras medidas de separabilidad como la distancia de Jeffries-Matusita (JM), también llamada de Bhattacharyya. La distancia JM entre un par de distribuciones de probabilidad (clases espectrales) se define como:

$$J_{ij} = \int \left(\sqrt{p(r|\omega_i)} - \sqrt{p(r|\omega_j)} \right)^2 dr \quad (4.3)$$

Esta expresión cuantifica la suma de las distancias al cuadrado entre pares de valores de las distribuciones de probabilidad para el par de clases ω_i , ω_j . Para las clases de distribución normal se convierte en [4, 40, 41]:

$$J_{ij} = 2(1 - e^{-B_{ij}}) \quad (4.4)$$

donde

$$B_{ij} = \frac{1}{8} (m_i - m_j)^T \left[\frac{C_i + C_j}{2} \right]^{-1} (m_i - m_j) + \frac{1}{2} \ln \left[\frac{|(C_i + C_j)/2|}{|C_i C_j|^{1/2}} \right] \quad (4.5)$$

que se refiere a la distancia de Bhattacharyya. La distancia JM está acotada a 2, lo que significa que el par de clases que posea un valor igual a 2 tendrá una separabilidad perfecta.

Para calcular la separabilidad entre clases en este TFM se han empleado la divergencia transformada y la distancia JM.

4.1.3. Fase de asignación

Una vez culminada la selección y estudio de las categorías que intervendrán en la clasificación, se inicia la siguiente fase, denominada de asignación, puesto que se trata de atribuir cada uno de los píxeles de la imagen a una de las clases previamente seleccionadas. Esta asignación se realiza, naturalmente, en función de sus ND, para cada una de las bandas que intervienen en el proceso. Tras esta fase se obtendrá una nueva imagen, cuyos ND expresen la categoría en la cual se ha incluido cada uno de los píxeles de la imagen original [4].

En el siguiente subapartado se describirá el algoritmo clasificador basado en máquina de vectores de soporte (*Support Vector Machine*, SVM). Después de analizar la literatura y la evaluación de varios clasificadores, SVM ha demostrado un buen rendimiento en la clasificación de imágenes de alta resolución, siendo menos sensible a la dimensionalidad de los datos y a la cantidad y calidad de las regiones de entrenamiento [42, 43]. Por ello, para realizar la clasificación en este TFM se ha empleado este algoritmo.

4.1.3.1. Máquina de vectores de soporte

Las SVMs pertenecen a la categoría de clasificadores lineales, puesto que inducen separadores lineales o hiperplanos, ya sea en el espacio original de los ejemplos de entrada, si éstos son separables o cuasi-separables (ruido), o en un espacio transformado (espacio de características), si los ejemplos no son separables linealmente en el espacio original. La búsqueda del hiperplano de separación en estos espacios transformados, normalmente de muy alta dimensión, se hará de forma implícita utilizando las denominadas funciones kernel.

La idea es seleccionar un hiperplano de separación que equidista de las muestras más cercanas de cada clase para, de esta forma, conseguir lo que se denomina un margen máximo a cada lado del hiperplano. Además, a la hora de definir el hiperplano, sólo se consideran las muestras de entrenamiento de cada clase que caen justo en la frontera de dichos márgenes. Estas muestras reciben el nombre de vectores de soporte y son los elementos críticos del conjunto de entrenamiento.

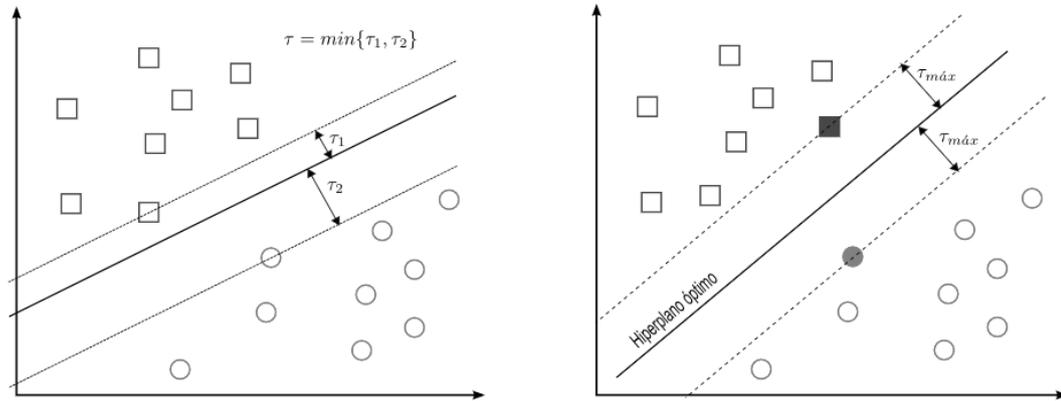


Figura 4.1. Margen de un hiperplano de separación: a) Hiperplano de separación no-óptimo y su margen asociado, τ , (no máximo). b) Hiperplano de separación óptimo y su margen asociado máximo, τ_{\max} . Fuente: [http://www.ia.uned.es/~ejcarmona/publicaciones/\[2016-%20Carmona\]%20SVM.pdf](http://www.ia.uned.es/~ejcarmona/publicaciones/[2016-%20Carmona]%20SVM.pdf)

Mientras SVM es un clasificador binario en su forma más simple, puede funcionar como un clasificador multiclase mediante la combinación de varios clasificadores SVM binarios (creando un clasificador binario para cada posible par de clases).

Asimismo, SVM incluye un parámetro de penalización que permite un cierto grado de error de clasificación, lo cual es particularmente importante para los conjuntos de entrenamiento no separables. Este parámetro controla la compensación entre errores de entrenamiento y márgenes rígidos (*hard margin*). Así, se crea un margen blando (*soft margin*) que permite algunos errores de clasificación a la vez que los penaliza. El incremento del valor del parámetro de penalización aumenta el coste de los puntos de clasificación errónea y obliga a la creación de un modelo más preciso que no puede generalizarse con claridad.

Como se comentó anteriormente, las funciones kernel son las que permiten convertir lo que sería un problema de clasificación no lineal en el espacio dimensional original, a un sencillo problema de clasificación lineal en un espacio dimensional mayor. Algunos ejemplos de funciones kernel son [44, 45]:

- Kernel lineal:

$$K(x_i, x_j) = x_i^T x_j \quad (4.6)$$

- Kernel polinómico de grado- d :

$$K(x_i, x_j) = (\gamma x_i^T x_j + \tau)^d, \gamma > 0 \quad (4.7)$$

- Función de base radial gaussiana (RBF):

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \gamma > 0 \quad (4.8)$$

- Kernel sigmoidal:

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + \tau) \quad (4.9)$$

donde a los parámetros γ , τ y d se les denomina parámetros del kernel.

4.1.4. Fase de verificación de resultados

El producto final de una clasificación, ya sea visual o digital, es un mapa temático, en donde el territorio de estudio se encuentra dividido en una serie de unidades espaciales (clases), de significado coherente con la leyenda de trabajo.

En general, se asume que el mapa obtenido es completamente fiable, es decir, se ajusta perfectamente a la realidad. Sin embargo, toda clasificación lleva consigo un cierto margen de error, que depende de la calidad de los datos y de la rigurosidad del método empleado. Por ello, es necesario aplicar algún procedimiento de verificación que permita cuantificar ese error y, en función de él, valorar la calidad final del trabajo y su aplicabilidad operativa.

La estimación de la exactitud alcanzada por el mapa puede realizarse por diversos criterios: comparando el inventario de la clasificación con el obtenido por otras fuentes convencionales, estudiando la fiabilidad obtenida al clasificar las áreas de entrenamiento, y seleccionando unas áreas de verificación para las que se cuenta con la cubierta realmente en el suelo.

En este TFM se describirá con detalle esta última vía de trabajo. Ésta consiste en seleccionar una serie de áreas de evaluación, que permitan obtener una medida independiente del acuerdo entre mapa y verdad-terreno. Este procedimiento pasa por realizar un muestreo del área de estudio, a fin de obtener las medidas de campo necesarias para verificar los resultados de la clasificación. Tal muestreo no repercute en una mejora de la fiabilidad de la clasificación, sino sólo en la medida de ésta. La validación rigurosa de los resultados facilita, no sólo una medida de la calidad del mapa que se aporta, sino también un criterio para demostrar la idoneidad de uno u otro método para una aplicación específica.

A partir de la realización del muestreo, puede construirse una tabla o matriz de confusión, en donde se resuman los acuerdos y desacuerdos entre clases del mapa y del terreno. Esta

matriz puede analizarse estadísticamente, con objeto de obtener una serie de medidas sobre la fiabilidad del trabajo global y para cada una de las categorías [4].

4.1.4.1. Matriz de confusión

Como resultado de la fase de muestreo se tiene un listado de puntos de test para los que se posee tanto su cobertura real como la deducida por la clasificación. Con estos datos puede formarse una matriz, denominada de confusión puesto que recoge los conflictos que se presentan entre categorías. Se trata de una matriz bidimensional, en donde las columnas se ocupan por las clases de referencia, y las filas por las categorías deducidas de la clasificación. Lógicamente ambas tendrán el mismo número y significado, por lo que se trata de una matriz cuadrada: $n \times n$, donde n indica el número de clases [4].

La fiabilidad global del mapa (*overall accuracy*) se calcula sumando el número de píxeles clasificados correctamente y dividiendo por el número total de píxeles. Por una parte, el número total de píxeles es la suma de todos los píxeles de todas las clases reales en el terreno (áreas de evaluación). Por otra parte, los píxeles clasificados correctamente indican el número de píxeles que fueron clasificados en la clase real a la que pertenecen. Éstos se encuentran a lo largo de la diagonal principal de la matriz de confusión. En cambio, los situados fuera de la diagonal principal suponen errores de asignación (marginales). Por un lado, los residuales en filas representan los errores de comisión, por otro, los residuales en columnas expresan los errores de omisión [4, 46, 47].

Los errores de comisión representan los píxeles clasificados en una categoría a la que no pertenecen. Se plantea como riesgo del usuario. Los errores de omisión constituyen los píxeles que conforman una determinada categoría, pero no han sido clasificados en dicha categoría. Se plantea como riesgo del productor [47].

Otra forma de medir la precisión total de la clasificación es el cálculo del coeficiente kappa (κ). Este coeficiente mide la concordancia entre los píxeles clasificados y los pertenecientes a la clase real. Un coeficiente kappa de valor igual a 1 representa una concordancia perfecta, mientras que un valor igual a 0 representa concordancia nula. Se calcula aplicando la siguiente expresión [46]:

$$\kappa = \frac{N \sum_{i=1}^n m_{i,i} - \sum_{i=1}^n (G_i C_i)}{N^2 - \sum_{i=1}^n (G_i C_i)} \quad (4.10)$$

donde i es el número de clases; N es el número total de píxeles clasificados que son comparados con la clase real; $m_{i,i}$ es el número de píxeles perteneciente a la clase real i , que también ha sido clasificada con una clase i (es decir, los valores que se encuentran en la diagonal de la matriz de confusión); C_i es el número total de píxeles clasificados que pertenecen a la clase i ; y G_i es el número total de píxeles de la clase real (verdad-terreno, áreas de evaluación) que pertenecen a la clase i .

A diferencia de la fiabilidad global, este coeficiente tiene en cuenta los errores de comisión y omisión.

4.1.5. Obtención y presentación de resultados

Independientemente del método empleado en la clasificación digital, los resultados se almacenan en una nueva imagen, similar a las originales, en cuanto estructura y tamaño, pero con la importante diferencia de que el ND de cada píxel no corresponde a un valor de reflectividad, sino a la categoría a la que se asignó. Por tanto, se obtiene una nueva matriz numérica similar a la original aunque de dos dimensiones, pues se ha condensado la información espectral (varias bandas) en una sola clase temática.

Esa nueva imagen puede dar lugar a dos tipos de productos: cartográficos y estadísticos. En el primer caso, se trata de convertir la imagen clasificada en un mapa; en el segundo, de realizar un inventario a partir de los ND que componen esa imagen [4].

4.1.5.1. Productos cartográficos

4.1.5.1.1. Formación de una tabla de color

Para visualizar la imagen clasificada es necesario una tabla de referencia del color (*Color Look-Up Table*, CLUT) que refleje adecuadamente el significado temático de cada una de las clases. En este sentido, conviene respetar las convenciones establecidas en la asignación temática de colores, por ejemplo: rojo para las zonas urbanas, verde para la vegetación, azul para las zonas acuáticas, etc.

La manipulación numérica del color ofrece al intérprete una amplia paleta de colores: de 0 a 255 niveles, por cada uno de los tres colores primarios. De esta forma, para diseñar un color apropiado a cada categoría, basta indicar tres valores numéricos, entre 0 y 255, que expresen el nivel de rojo, verde y azul, asignado a dicha clase [4].

4.1.5.1.2. Suavizado de los resultados

Resulta bastante frecuente que los resultados de una clasificación digital sufran una excesiva fragmentación. En otras palabras, las diversas categorías se superponen entre sí, en una compleja sucesión espacial. Manchas de color, más o menos homogéneas, se encuentran salpicadas por píxeles asignados a otras categorías, perdiéndose su unidad geográfica y dificultando la interpretación de los resultados. Este suceso se denomina coloquialmente efecto de sal y pimienta (*salt and pepper*), y se debe a una doble causa: por un lado, a que la mayor parte de los criterios de asignación no tienen en cuenta la pertenencia de píxeles vecinos; por otro, a la propia complejidad del paisaje, directamente relacionada con la aparición de píxeles de borde –fronterizos a dos o más categorías– que son los principales responsables de la discontinuidad visible en el mapa.

Para solventar este problema, se suele aplicar una técnica de suavizado de resultados, similar en la concepción, aunque no en la ejecución, a los filtros paso bajo. Sobre la imagen clasificada no puede aplicarse un filtro convencional, puesto que cualquier promedio de píxeles vecinos introduciría cambios imprevisibles en la clasificación. En otras palabras, se trata de una imagen categorizada, no de una imagen de tono continuo, en donde no tiene sentido establecer análisis de gradientes. Por esta razón, se aplican sobre la imagen esquemas de filtrado originales, basados sobre medidas categóricas en lugar de promedios.

El objetivo último es reasignar aquellos píxeles aislados o poco significativos, facilitando una distribución espacial más nítida de las distintas categorías. Para ello, se procede a comparar la clase asignada a cada píxel con la que ofrecen los píxeles vecinos. Si esa clase es similar a los píxeles del entorno, se mantiene la asignación original; en caso contrario, se modifica. Normalmente, esta comparación se realiza a partir de una ventana móvil de 3×3 píxeles, si bien la técnica es independiente de su tamaño. En la terminología habitual se distinguen, a este respecto, dos tipos de filtro [4]:

- Filtro modal. El píxel situado en el centro de la matriz se asigna a la categoría más frecuente entre los píxeles vecinos, siempre que, lógicamente, no pertenezca a ella.
- Filtro de mayoría. El píxel central se asigna a la categoría que cuente con la mitad más uno de los píxeles vecinos. En caso de que ninguna categoría rebese ese valor, el píxel central mantiene su asignación primitiva.

4.1.5.2. Productos estadísticos

Como ya se ha comentado, la imagen clasificada es una matriz numérica en la cual el ND de cada píxel indica la categoría a la que pertenece. De esta forma, una simple tabulación de frecuencias permite obtener el inventario del área clasificada; es decir, el número de píxeles incluidos en cada una de las categorías. Puesto que es conocida la dimensión superficial de cada píxel, resulta inmediato obtener la extensión ocupada por cada categoría.

Este cómputo de frecuencias puede realizarse sobre toda la imagen o sobre polígonos determinados. Si esos polígonos coinciden con unidades administrativas (municipios, comarcas), puede obtenerse un inventario de gran interés para las estadísticas oficiales [4].

4.2. Extracción de características

Una imagen es representada por una colección de características visuales que describe el contenido de la imagen. Por ello, en el proceso de clasificación, es habitual la aplicación de diversos métodos que se encarguen de extraer dichas características con alguna información cuantitativa de interés o que sean fundamentales para diferenciar una clase de objeto de otra. En concreto, la extracción de características en imágenes hiperespectrales es una cuestión clave, ya sea para reducir la dimensión de sus datos o para realizar un análisis espectral (desmezclado espectral). Además, la inclusión de información adicional, como por ejemplo la textura, a las bandas espectrales de las imágenes multiespectrales o hiperespectrales puede mejorar la clasificación.

Obviamente, tales operaciones no proporcionan una nueva información que no estuviera ya incluida en los datos originales. No obstante, permiten mejorar la disposición de los datos, de forma que sean más evidentes determinados fenómenos de interés [4].

A continuación, en los siguientes subapartados se describen los procesos de reducción dimensional y desmezclado espectral habituales en las imágenes hiperespectrales, así como la extracción de información de textura.

4.2.1. Reducción dimensional

Uno de los motivos principales para la aplicación de técnicas que reduzcan la dimensionalidad de los datos de las imágenes hiperespectrales es el fenómeno de Hughes. Este fenómeno establece que el tamaño del conjunto de regiones de entrenamiento necesario para un clasificador determinado aumenta exponencialmente con el número de bandas. Por

tanto, debido a la gran cantidad de datos de las imágenes hiperespectrales, se necesitaría un elevado número de muestras para que el rendimiento del clasificador sea óptimo [48].

Algunas de las técnicas que mitigan el fenómeno de Hughes mediante la reducción dimensional son el análisis de componentes principales (*Principal Components Analysis*, PCA) y la fracción de mínimo ruido (*Minimum Noise Fraction*, MNF). Estas técnicas posibilitan la disminución del número de bandas de la imagen original al concentrar en un número inferior de componentes la información básica de los datos mediante la eliminación de información redundante. De esta forma, además, se consigue reducir la carga computacional. La manera más común para seleccionar estas componentes es a través de valores propios (*eigenvalues*), que son la medida de la varianza de las componentes obtenidas a partir de las técnicas de reducción dimensional. Asimismo, se puede facilitar la selección de las componentes mediante un análisis visual de los resultados [48, 49].

PCA es una transformación ortogonal que convierte un conjunto de bandas con un alto grado de correlación entre ellas en un conjunto de bandas incorreladas llamadas componentes principales, las cuales son combinaciones lineales de las originales [40, 48].

Se pueden calcular tantas componentes principales como bandas espectrales de entrada tenga la imagen utilizada. La primera componente principal contiene el mayor porcentaje de varianza de datos, la segunda contiene la segunda mayor varianza de datos, y así hasta llegar a las últimas componentes principales, las cuales parecen ruidosas ya que contienen muy poca variación [40].

MNF es una variante de la transformación PCA que ecualiza y estima la cantidad de ruido en cada banda de imagen para garantizar que las componentes de salida estén ordenadas en base a su cantidad de información. Al igual que PCA, es un procedimiento basado en la estructura de covarianza del ruido en el conjunto de datos de imágenes. El objetivo de la transformación MNF es seleccionar componentes de tal forma que maximicen la relación de señal a ruido, que compara el nivel de la señal con el nivel del ruido de fondo en lugar del contenido de la información. El hecho de ordenar las componentes de acuerdo con la cantidad de información permite identificar y eliminar de manera más fiable las componentes ruidosas, así como preserva las componentes que contienen información útil [48].

4.2.2. Desmezclado espectral

Una estrategia importante para extraer información relevante, principalmente en imágenes hiperespectrales, es la aplicación de técnicas de desmezclado espectral. Ésta consiste en estimar el porcentaje de contribución de cada clase pura (*endmember*) a la reflectividad total de cada píxel [50]. Una técnica estándar para la extracción de los *endmembers* es el desmezclado espectral lineal, la cual supone que la reflectancia en cada píxel de la imagen es una combinación lineal de la reflectancia de cada material puro (o *endmember*) presente dentro del píxel. De esta forma, permite determinar la abundancia relativa de los materiales representados en las imágenes multispectrales o hiperespectrales basándose en sus características espectrales. El resultado obtenido tras la aplicación de esta técnica son mapas de abundancia de cada clase considerada derivados de las bandas espectrales del sensor [51].

4.2.3. Textura

Aunque no hay una definición estándar de textura, esta puede definirse como la repetición de un patrón espacial básico, cuya estructura puede ser periódica, o parcialmente periódica. Adicionalmente, para caracterizar la textura de una superficie de una imagen, se tiene en cuenta la distribución de valores de intensidad a nivel espacial, permitiendo evaluar propiedades como: fineza, rugosidad, suavidad, granulación, aleatoriedad, etc.

Uno de los procedimientos para el análisis de textura son los métodos estadísticos. En ellos, se distinguen los de primer y segundo orden. Los estadísticos de primer orden involucran píxeles simples, por ejemplo, en un histograma normalizado de los niveles de gris de una imagen, se pueden considerar datos como la media, varianza, suavidad, sesgo, curtosis, correlación, energía o entropía para caracterizar la textura. Los de segundo orden consideran propiedades de pares de píxeles, por ejemplo, métodos de matrices de coocurrencia*, los cuales consideran características como energía, entropía, contraste, homogeneidad, y correlación [52].

* Matrices de coocurrencia: También llamadas matrices de dependencia espacial o GLCM (*Gray-Level Co-occurrence Matrix*). Son histogramas bidimensionales que estiman la probabilidad de que dos píxeles a una distancia d tengan el mismo valor [58, 59].

Momento de orden k:	$m_k = E[i^k] = \sum_{i=0}^{255} i^k p(i)$
• nivel medio de intensidad:	$m_1 = E[i]$
Momento central de orden k:	$\mu_k = E[(i - m_1)^k] = \sum_{i=0}^{255} (i - m_1)^k p(i)$
• varianza de la intensidad:	$\mu_2 = \text{Var}[i] = \sigma^2$
– ancho del histograma	
• coeficientes de asimetría:	$\mu_3, \gamma_1 = \frac{\mu_3}{\mu_2^{3/2}} = \frac{\mu_3}{\sigma^3}$
– asimetría respecto de la media (<i>skewness</i>)	
▪ = 0 – distribución simétrica, > 0 – desplazado a la izquierda, < 0 – desplazado a la derecha	
• coeficientes de kurtosis:	$\mu_4, \gamma_2 = \frac{\mu_4}{\mu_2^2} = \frac{\mu_4}{\sigma^4}$
– aplanamiento respecto a una distribución normal (<i>sharpness</i>)	
▪ 3 – distribución normal, >3 – más alta/esbelta que la normal, <3 – más aplanada que la normal	

a)

Segundo Momento Angular (<i>Angular Second Moment</i>) – Energía	Contraste
$ASM = \sum_{i=0}^{255} \sum_{j=0}^{255} p(i, j)^2$	$CON = \sum_{i=0}^{255} \sum_{j=0}^{255} (i - j)^2 p(i, j)$
cuanto más suave es la textura, mayor valor toma ASM (p.e. intensidad constante \Rightarrow ASM = 1, distribución unif. de parejas \Rightarrow ASM = p < 1)	cuanto mayor es el contraste de la imagen, mayor es el valor de CON al ponderar las diferencias $ i-j $ con $(i-j)^2$
Entropía	Momento Diferencial Inverso (<i>Inverse Difference Moment</i>) – Homogeneidad
$H_{xy} = - \sum_{i=0}^{255} \sum_{j=0}^{255} p(i, j) \log_2 p(i, j)$	$IDF = \sum_{i=0}^{255} \sum_{j=0}^{255} \frac{p(i, j)}{1 + (i - j)^2}$
H toma valores bajos cuanto más suave es la textura (menos aleatoria)	cuanto menor es el contraste, más alto es IDF debido a la ponderación inversa a través de $(i-j)^2$

b)

Figura 4.2. Ejemplos estadísticos para caracterización de texturas: a) De primer orden. b) De segundo orden.

Fuente: <http://dmi.uib.es/aortiz/4730-tema9.pdf>

Capítulo 5. Generación de mapas de cobertura terrestre en Maspalomas

5.1. Introducción

Para la realización de este Trabajo de Fin de Máster se han procesado dos imágenes capturadas por dos sensores diferentes.

En primer lugar, se ha utilizado una imagen hiperespectral (producto L2c) procedente del sensor INTA CASI instalado a bordo del avión CASA C-212-200, tomada el 2 de junio de 2017 (Figura 5.1 a). La resolución espectral de esta imagen se redujo a 68 bandas para aumentar la relación señal/ruido, ya que la resolución espacial requerida fue de 50 cm. Con estas bandas se cubre el rango de longitudes de onda entre 396,9-1039,0 nm. En segundo lugar, se ha empleado una imagen multispectral (producto *ortho-ready*) procedente del satélite WorldView-2, tomada el 4 de junio de 2015 (Figura 5.1 b), con una resolución espacial de 46 cm para el canal pancromático y de 1,85 m para el multispectral (8 bandas). Estas 8 bandas cubren el rango de longitudes de onda entre 427,3-908,0 nm.

Finalmente, para tener la misma resolución espacial en ambas imágenes, se ha procesado la imagen WV2 aplicándole un algoritmo *pansharpening* y se ha realizado un redimensionamiento para trabajar a una resolución de 50 cm.

A continuación, se realiza una breve introducción del software utilizado en este TFM para, posteriormente, detallar la metodología seguida.



a)



b)

Figura 5.1. Imágenes color natural: a) CASI 1500i de junio de 2017. b) WorldView-2 de junio de 2015.

5.1.1. ENVI

La creciente dependencia de las imágenes geospaciales hace cada vez más importante la capacidad de obtener la información elaborada a partir de estos datos. Por ello, es esencial disponer de herramientas y aplicaciones que ayuden a extraer información de forma sencilla y precisa.

ENVI (*ENvironment for Visualizing Images*) es uno de los entornos software de procesamiento y análisis avanzado de imágenes geospaciales más empleados, y es utilizado por analistas de imágenes, investigadores, científicos y profesionales del SIG (Sistemas de Información Geográfica) en una amplia variedad de disciplinas.

Esta herramienta proporciona instrumentos avanzados fáciles de usar para leer, explorar, preparar, analizar y compartir la información extraída de todo tipo de imágenes (diferentes sensores): imágenes pancromáticas, multiespectrales, hiperespectrales, radar, etc. ENVI permite la realización de múltiples tareas como [53]:

- Ortorectificación de imágenes.
- Registro de dos o más imágenes.
- Calibrado de imágenes.
- Corrección de distorsiones atmosféricas.
- Identificación de regiones de interés (ROIs).
- Creación de modelos digitales de elevación (DEMs).
- Fusión de imágenes, máscaras, generación de mosaicos, etc.
- Conversión, redimensionamiento y rotación de datos.

- Clasificación de imágenes con métodos supervisados (o no).
- Cálculo de índices de vegetación.

Para el procesamiento de las imágenes en este TFM se han empleado las versiones ENVI 5.1 y 5.4.

5.2. Metodología

La metodología seguida puede verse resumida en la Figura 5.2.

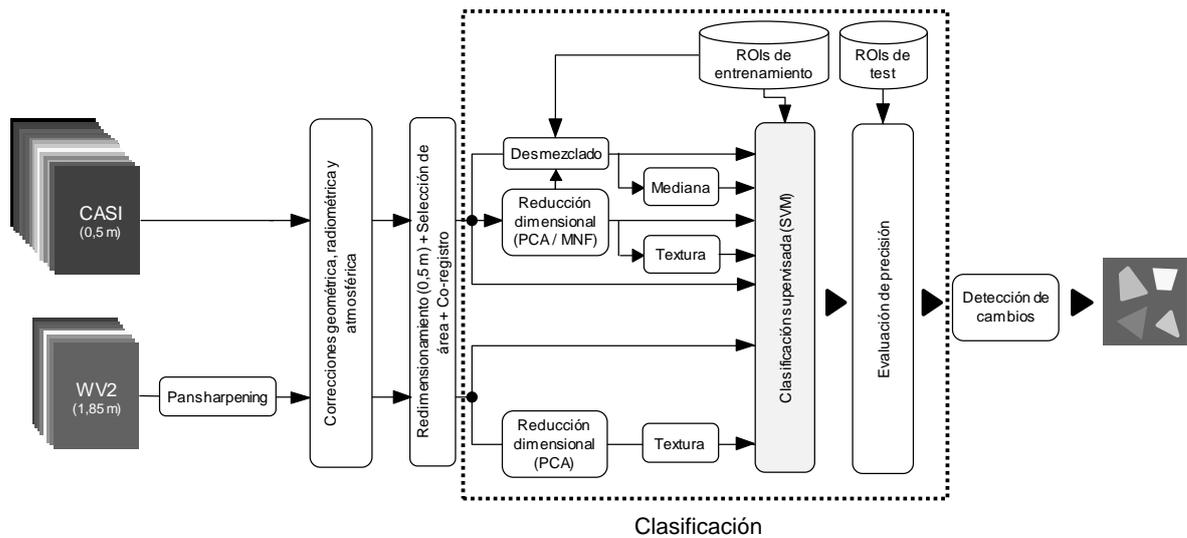


Figura 5.2. Esquema de la metodología seguida para el desarrollo de este TFM.

5.2.1. Pansharpening

Con el objetivo de mejorar la calidad espacial de las bandas multiespectrales de la imagen WV2 utilizando la banda pancromática, en este trabajo se han aplicado técnicas de *pansharpening*. Asimismo, como se ha comentado anteriormente, es importante mantener el detalle espectral de las bandas multiespectrales, por lo que se ha escogido un método que garantice la mínima distorsión espectral.

Puesto que en una imagen de satélite es habitual la presencia de distintos tipos de cubiertas, en este TFM se han empleado medidas locales de la dimensión fractal para distinguir entre los diversos tipos de cubierta que se encuentran en una imagen. Para ello, se han generado mapas de dimensión fractal local, mediante un proceso de ventaneo de la imagen utilizando el algoritmo box-counting. Esta información se ha usado para mejorar la calidad de las imágenes fusionadas mediante el método de fusión basado en la transformada *wavelet à trous*.

5.2.2. Correcciones

El producto de imagen del satélite WorldView-2 utilizado en este TFM incluye las correcciones geométricas y radiométricas. Sin embargo, para la corrección atmosférica de la imagen WV2 se ha utilizado el modelo FLAASH, que es un módulo avanzado de corrección atmosférica disponible en el software ENVI, el cual se basa en el algoritmo de transferencia de radiación MODTRAN4.

Respecto a la corrección del sensor aeroportado CASI, debido a que los modelos atmosféricos para satélites no son directamente aplicables, el INTA proporciona las imágenes corregidas utilizando el modelo ATCOR 4.

5.2.3. Redimensionamiento espacial y selección de área

Puesto que tras aplicar el algoritmo *pansharpening* a la imagen WV2 la resolución espacial de esta imagen pasó de 1,85 a 0,46 metros, ha sido necesario redimensionar espacialmente la imagen para que su resolución fuese la misma que la de la imagen CASI (0,5 metros). Para ello, se ha aplicado la herramienta *Resize Data* de ENVI, empleando el método de remuestreo de vecino más próximo.

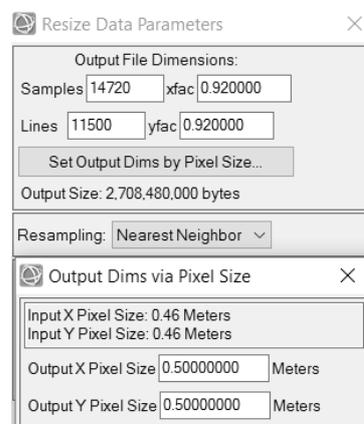


Figura 5.3. Redimensionamiento espacial de la imagen WV2 en ENVI.

Por otra parte, se ha recortado la imagen CASI para que coincidiera con la zona estudiada en un trabajo anterior [54]. De esta manera, se descartaron áreas de la imagen original que no son de interés en este TFM consiguiendo un beneficio en términos de una reducción de la carga computacional en los posteriores procesos. De igual forma, se ha recortado la imagen WV2, pero dejando un tamaño ligeramente superior a la CASI para que en el proceso de registro de imágenes, tras realizar la transformación de la imagen, no queden zonas sin datos.

5.2.4. Registro de imágenes

Para realizar el registro de imágenes, se ha seguido el esquema mostrado en la Figura 5.4.

En primer lugar, se debe seleccionar la imagen de referencia, la cual no se modifica, y la imagen objetivo, la cual es transformada para poder ser alineada con la imagen de referencia.

El siguiente paso será la generación de puntos de control. Para ello, se debe elegir una serie de parámetros que determinan la manera de encontrar y generar de forma automática dichos puntos, como pueden ser el método de similitud y alineación (correlación cruzada o información mutua), el modelo geométrico, el número de puntos requeridos, entre otros. Una vez escogidos los parámetros, se generan automáticamente distintos puntos de control en las imágenes. Además, es posible añadir y eliminar manualmente puntos con el fin de obtener mayor precisión en el registro.

Cuando se hayan seleccionado los puntos de control, se procede a realizar la transformación de la imagen objetivo. Con este propósito, se debe elegir el método de deformación y el remuestreo a emplear.

Por último, a modo de comprobación del resultado obtenido, se evalúa la precisión del registro. En este Trabajo de Fin de Máster, esta evaluación se ha realizado de manera visual comparando zonas perfectamente distinguibles en las dos imágenes y confirmando que se han alineado.

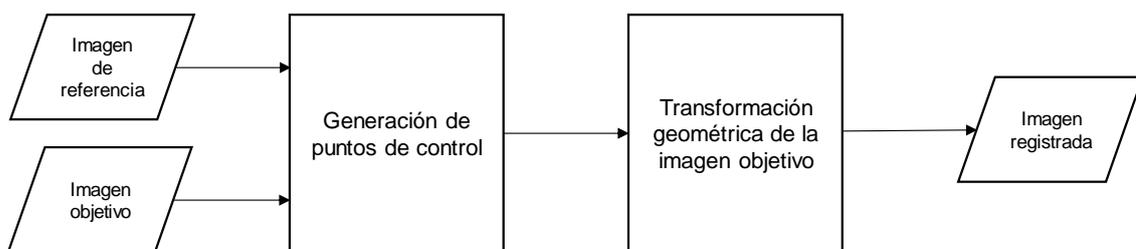


Figura 5.4. Esquema de obtención de la imagen registrada.

Para llevar a cabo este proceso, en este TFM se ha empleado la herramienta *Image Registration Workflow* del software ENVI. A continuación, se muestran los pasos seguidos en este programa en concordancia con lo explicado anteriormente:

En la Figura 5.5 puede verse el menú de elección de las imágenes de referencia y objetivo. En este registro se ha escogido de imagen de referencia la obtenida del sensor CASI (banda 28) y de imagen objetivo la obtenida del WorldView-2 (banda 5).

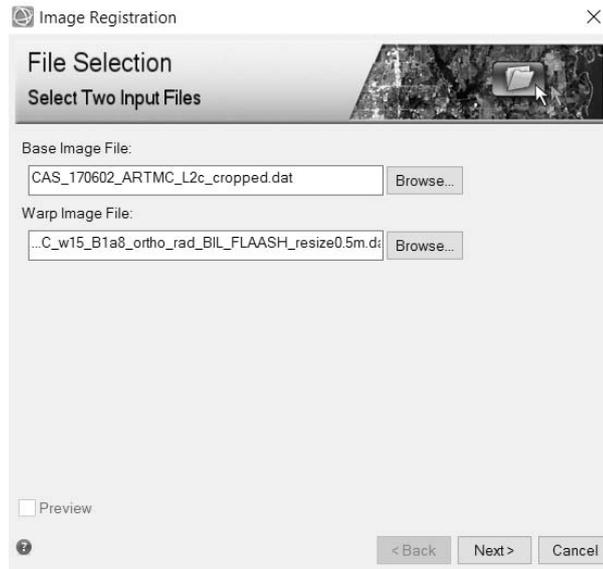


Figura 5.5. Elección en ENVI de las imágenes de referencia y objetivo.

A continuación, tras el siguiente paso se muestran los parámetros seleccionables para la generación automática de los puntos de control (Figura 5.6). En este TFM se ha seleccionado el método de alineación de información mutua, ya que ofrece mejores resultados que el de correlación cruzada. Además, se ha utilizado una transformación polinómica de primer orden, pues es un método más complejo que el RST (Rotación, Escala y Traslación). Se ha seleccionado un error máximo permitido por punto de control de 5 píxeles.

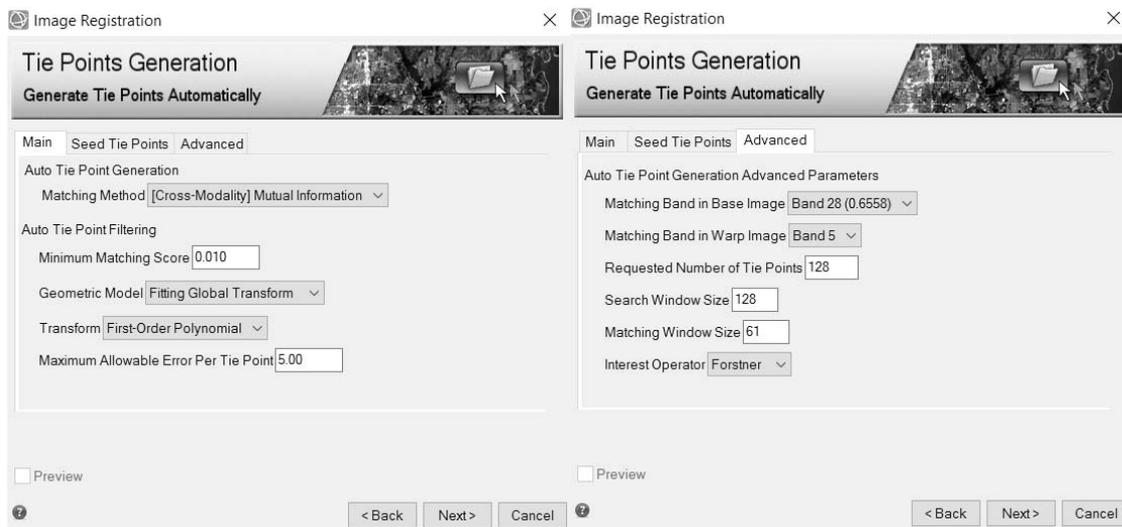


Figura 5.6. Elección en ENVI de los parámetros para la generación de puntos de control.

Con estos parámetros se han generado 67 puntos de control (Figura 5.7 a). Con el objetivo de obtener mayor precisión en el registro de las imágenes, se han añadido y eliminado diversos puntos de control. Para conseguir que los resultados fuesen óptimos, se han

seleccionado puntos sobre los lugares distintivos de la imagen (esquinas de edificios, intersecciones viales, puntos salientes, etc.), teniendo en cuenta que éstos puedan detectarse de forma fiable en las dos imágenes.

Al utilizar la opción de vista previa se ha comprobado el resultado de la deformación antes del procesamiento y ha permitido identificar las zonas donde el registro conseguía peores resultados, pudiendo mejorarlo con la adición de nuevos puntos. Además, se ha procurado que los puntos de control se encuentren homogéneamente distribuidos por toda la imagen, para que las funciones de deformación que se calculen a partir de ellos no se comporten de forma extraña en aquellas zonas donde no se hayan definido puntos de control.

El número final de puntos de control ha sido de 182 (Figura 5.7 b), siendo su error RMS de 3,56 píxeles. Asimismo, antes de pasar al proceso de deformación, se ha inspeccionado visualmente cada punto de control para confirmar que identifican de forma adecuada las ubicaciones correspondientes en ambas imágenes.

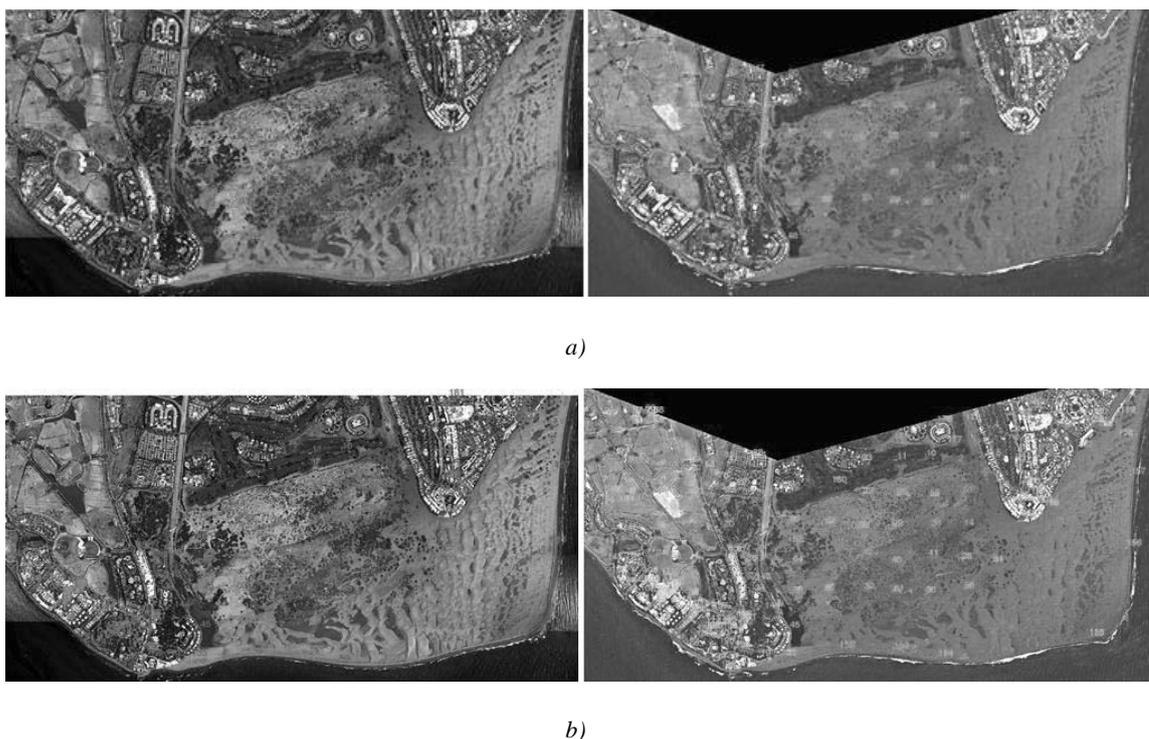


Figura 5.7. a) Puntos de control generados automáticamente en las imágenes CASI y WV2. b) Puntos de control automáticos y añadidos en el registro.

El registro de imagen se ha completado seleccionando el método de deformación de triangulación y remuestreo bilineal.

Por último, se ha recortado la imagen WV2 registrada para que abarque la misma zona que la imagen CASI.

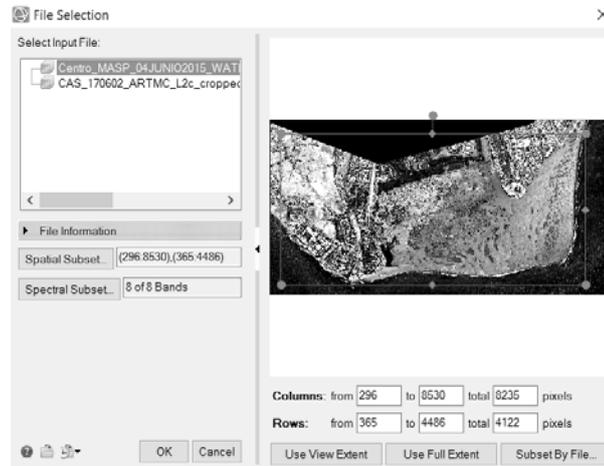


Figura 5.8. Selección del área de interés de la imagen WV2 registrada.

5.2.5. Clasificación

Una tarea clave en este TFM ha sido la clasificación de la zona de interés. En los siguientes apartados se explica con detalle cada paso seguido para el proceso de clasificación empleando el software ENVI.

5.2.5.1. ROIs de entrenamiento

Para seleccionar las áreas de entrenamiento que permiten al software el reconocimiento de las distintas categorías, se han utilizado las regiones de interés (ROIs). Éstas se han elegido sobre la imagen CASI y, tras ligeras modificaciones, necesarias al no ser perfecto el registro de imágenes, se han reutilizado en la imagen WV2.

En primer lugar, se crean tantas ROIs como clases se desean clasificar, asignándole un nombre y un color representativo a cada una. Luego se añaden los registros que van a diferenciar a cada ROI. Éstos pueden crearse de distintas maneras (mediante figuras geométricas, número de píxeles, etc.). En este TFM, se ha optado por definir cada registro usando figuras geométricas (polígonos, rectángulos y elipses).

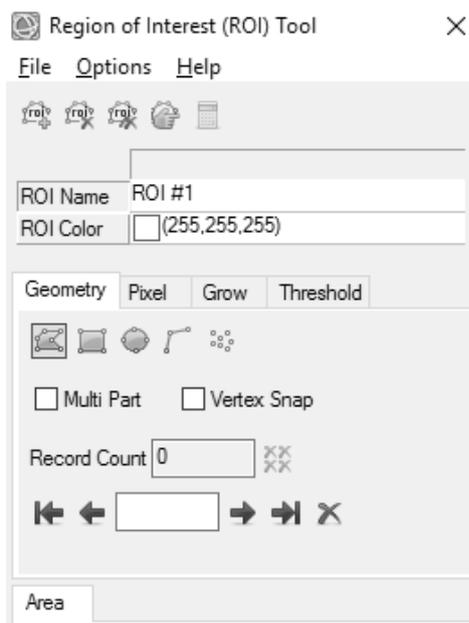


Figura 5.9. Menú de creación de ROIs en ENVI.

Una vez seleccionados todos los campos de entrenamiento, se ha calculado el grado de separabilidad entre las diferentes categorías, mediante la herramienta *Compute ROI Separability*, así como se han analizado sus firmas espectrales mediante *Compute Statistics from ROIs*.

5.2.5.2 Extracción de características

Con el objetivo de optimizar la clasificación, en términos de tiempo de cómputo y de precisión, que se consigue empleando las imágenes CASI y WV2 originales, se ha decidido extraer informaciones concretas de éstas que puedan enriquecer este proceso.

Por un lado, se ha aplicado una reducción dimensional a la imagen CASI empleando transformaciones PCA (a partir de la matriz de covarianza) y MNF. Esto se ha logrado utilizando las herramientas *Forward PCA Rotation New Statistics and Rotate* y *Forward MNF Estimate Noise Statistics* en ENVI.

Además, se han generado mapas de abundancia aplicando una técnica de desmezclado espectral lineal a partir de las ROIs de cada clase. Con este propósito, se ha utilizado la herramienta *Linear Spectral Unmixing* del software ENVI. Esta técnica ha sido utilizada tanto para la imagen CASI original como para las imágenes obtenidas tras la reducción dimensional.

Asimismo, puesto que los mapas de abundancia obtenidos estaban afectados por ruido sal y pimienta y ya que no conseguían una precisión adecuada tras la evaluación de la

clasificación, fue necesaria la aplicación de un filtro sobre aquellos mapas con mejores resultados. Para reducir este ruido se ha aplicado un filtro de mediana con una máscara (kernel) de 5×5 usando la función *Convolutions and Morphology* en ENVI.

Por otro lado, en las imágenes CASI y WV2 se ha extraído información de textura, obtenida usando los parámetros (media, varianza y entropía) del filtro de coocurrencia aplicado sobre la primera componente principal.

Para ello, se ha usado en ENVI la función *Co-occurrence Measures*, aplicando una ventana de procesamiento de 3×3 y 64 niveles de cuantificación de escala de gris (Figura 5.10).

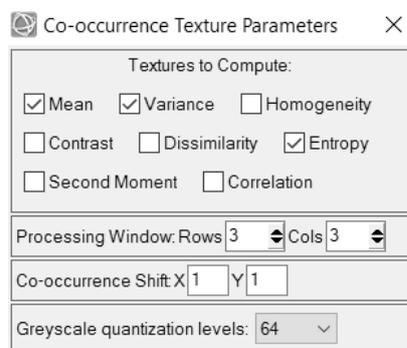


Figura 5.10. Parámetros de coocurrencia en ENVI.

5.2.5.3. Clasificación supervisada

Para realizar la clasificación de las imágenes se ha utilizado ENVI para aplicar un algoritmo basado en máquina de vectores de soporte. En este caso, se ha empleado una función kernel de base radial, al ser la más eficiente según indican diversas referencias [42] [43]. Los parámetros que definen a esta función se han mantenido con los valores por defecto que ENVI estima en función de los parámetros de entrada (Figura 5.11) para todas las clasificaciones.

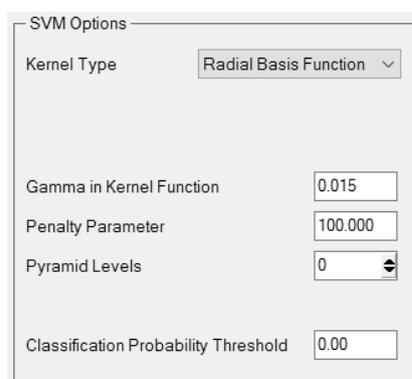


Figura 5.11. Parámetros usados en el clasificador SVM en ENVI.

5.2.5.4. ROIs de evaluación

Para la elección de las áreas de test se ha seguido el mismo procedimiento que el descrito en la elección de las áreas de entrenamiento (apartado 5.2.5.1). Sin embargo, en este caso se han seleccionado un mayor número de registros situados en zonas distintas a las de entrenamiento para conseguir una correcta evaluación de la clasificación.

5.2.5.5. Post-clasificación

Se han llevado a cabo tres tareas de post-clasificación:

En la primera, con objeto de analizar la fiabilidad de la clasificación global, así como la de cada clase, se han calculado las matrices de confusión de cada imagen clasificada empleando, para ello, las ROIs de evaluación.

De esta forma, utilizando *Confusion Matrix Using Ground Truth ROIs* en ENVI, este software genera un informe que muestra la fiabilidad global, el coeficiente kappa, la matriz de confusión, los errores de comisión y omisión y las precisiones del productor y del usuario para cada clase.

La segunda tarea de post-clasificación realizada ha sido la aplicación de un filtro de mayoría a las imágenes con el mayor porcentaje de fiabilidad global en ambos sensores. Para ello, se ha aplicado la herramienta *Majority/Minority Analysis*, con una ventana móvil de 3×3 píxeles y un píxel central de importancia 1. Esto último se emplea para determinar cuántas veces la clase del píxel central se cuenta al determinar qué clase está en la mayoría.

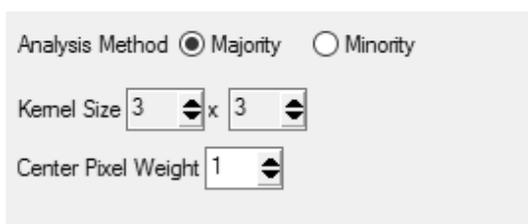


Figura 5.12. Parámetros del análisis de mayoría/minoría en ENVI.

Por último, se han calculado las estadísticas de las clases de las imágenes filtradas con objeto de conocer la cantidad de superficie que ocupa cada categoría. La manera de computar estos datos en ENVI es mediante la herramienta *Class Statistics*.

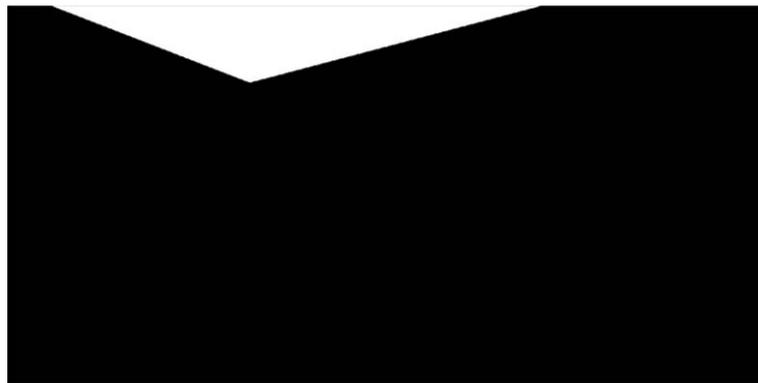
5.2.5.6. Detección de cambios

Sobre los mapas temáticos con mejores resultados de los sensores CASI y WV2 se han aplicado técnicas de detección de cambios. Para ello, se ha utilizado la herramienta *Thematic Change Workflow* de ENVI, la cual permite identificar las diferencias entre ambos mapas.

Sin embargo, antes de realizar este proceso, se ha construido una máscara del área que no contiene datos de la imagen WV2 para que no se tenga en cuenta en la detección de cambios. Esta máscara se ha creado generando, en primer lugar, una ROI de la zona deseada (Figura 5.13 a) guardándola como archivo ROI, y luego, utilizando dicha ROI para construir la máscara mediante la opción *Build Mask* de ENVI (Figura 5.13 b).



a)



b)

Figura 5.13. a) ROI para generación de máscara. b) Máscara generada.

Tras generar la máscara se inicia el proceso de trabajo para la detección de cambios seleccionando los dos mapas objeto de análisis y la máscara (invertida). Posteriormente, para refinar el resultado del proceso se habilitan dos opciones: suavizado (*Smoothing*) para eliminar ruido sal y pimienta y agregación (*Aggregation*) para eliminar regiones pequeñas. Para el suavizado se ha empleado un filtro de mayoría con una máscara de 5×5 píxeles, y para la agregación se ha establecido un tamaño mínimo de 9 píxeles, donde las regiones con un tamaño de este valor o menor se agregan a una región adyacente más grande.

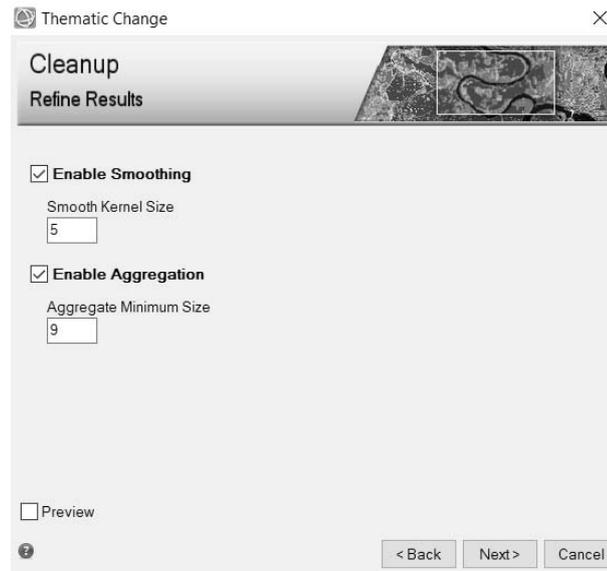


Figura 5.14. Refinado de los resultados de la detección de cambios.

Por último, se seleccionan los directorios donde se van a guardar los archivos, incluyendo las estadísticas de los cambios.

5.3. Resultados

En este apartado se exponen los resultados obtenidos en cada uno de los procesos realizados. El procedimiento seguido para llevarlos a cabo se ha explicado en el apartado anterior.

5.3.1. Pansharpening

En la Figura 5.15 se observa un ejemplo de la imagen WV2 antes y después de aplicar el algoritmo *pansharpening*, en la cual se puede apreciar como la imagen fusionada tiene una resolución espacial superior a la imagen multiespectral.

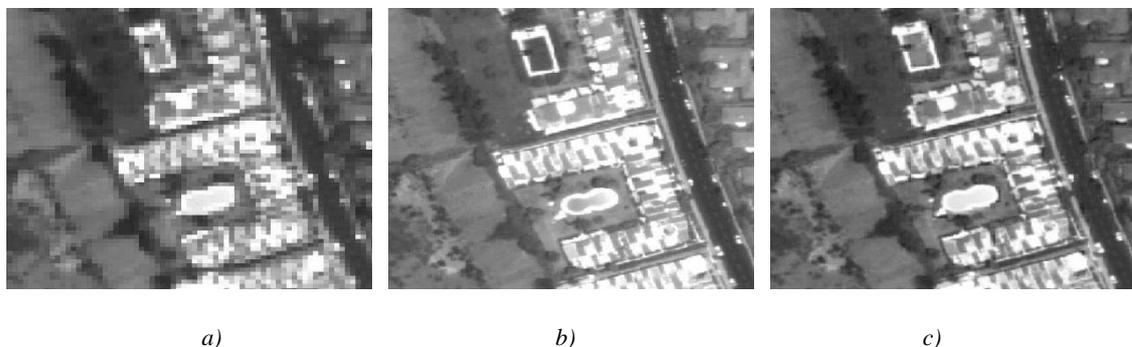


Figura 5.15. a) Imagen multiespectral. b) Imagen pancromática. c) Imagen fusionada.

5.3.2. Redimensionamiento espacial y selección de área

En la Figura 5.16 se puede observar la imagen CASI recortada.



Figura 5.16. Imagen CASI recortada.

5.3.3. Registro de imágenes

En la Figura 5.17 se muestra la imagen WV2 registrada y recortada.

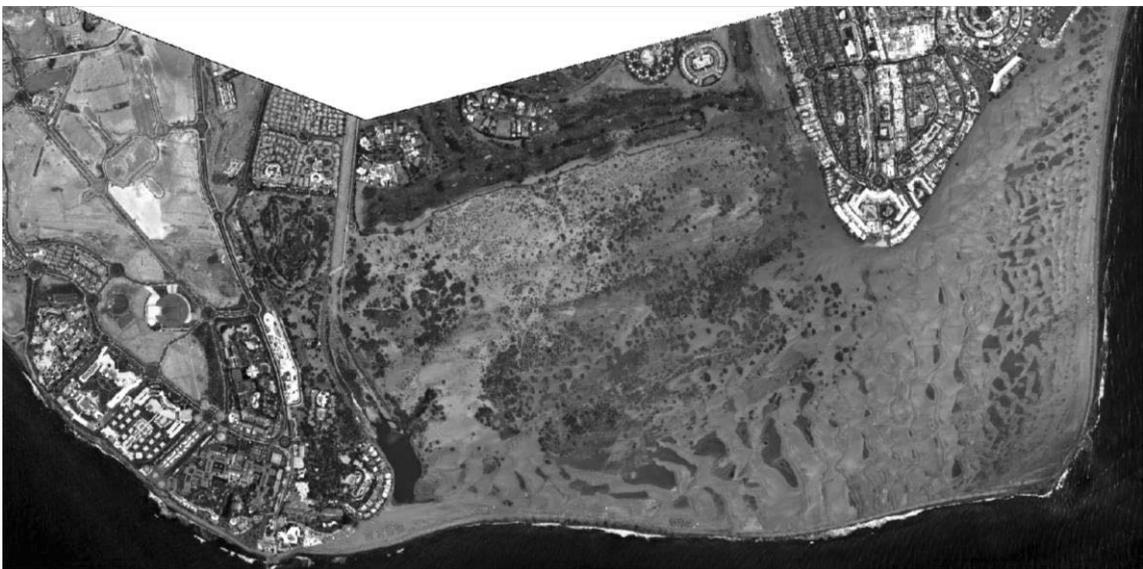


Figura 5.17. Imagen WV2 registrada y recortada.

Además, a modo de comprobación visual, se ha comparado la imagen de referencia (CASI) con la WV2 sin registrar y con la WV2 registrada. Para que pueda apreciarse la mejoría, se ha hecho un zoom de una zona y se ha superpuesto sobre la imagen CASI un cuadro con la imagen WV2 antes y después del proceso. En la Figura 5.18 se muestran estas

imágenes donde en la figura a) se observa la imagen WV2 antes del registro, mientras que en la figura b) se ve la imagen WV2 registrada, ambas superpuestas en la imagen CASI. Como se aprecia en esta figura (por ejemplo, en la rotonda), la imagen registrada ha quedado mejor alineada que la sin registrar con respecto a la imagen de referencia.



a)



b)

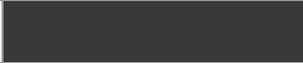
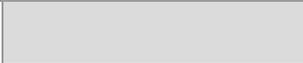
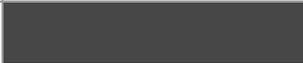
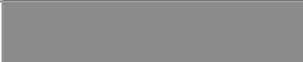
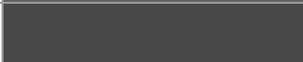
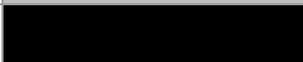
Figura 5.18. a) Imagen WV2 sin registrar frente a imagen CASI. b) Imagen WV2 registrada frente a imagen CASI.

5.3.4. Clasificación

5.3.4.1. Clases y zonas

En este TFM se ha considerado un total de 12 clases: árboles, arbustos, hierba, mar, lago, piscinas, olas, suelo construido, asfalto, arena, suelo desnudo y otros. En la Tabla 5.1 se representan las clases a discriminar y la tabla de referencia de color (CLUT) utilizada en la clasificación de las imágenes.

Tabla 5.1. Colores asignados a la clasificación de la imagen de Maspalomas.

Grupos de clases	Clases/Categorías	ENVI colors (ROI tool)	Color
Vegetación	Árboles	0, 64, 0	
	Arbustos	0, 128, 0	
	Hierba/Césped	0, 255, 0	
Masas de agua	Mar	0, 0, 255	
	Lago	128, 128, 255	
	Piscinas	0, 255, 255	
	Olas	255, 255, 255	
Superficies construidas	Suelo construido	196, 0, 0	
	Asfalto (carreteras)	72, 72, 72	
Suelos desnudos	Arena	255, 255, 0	
	Resto de suelos desnudos	196, 196, 0	
Otros	Sombras, borde/marco, ...	0, 0, 0	

5.3.4.2. ROIs de entrenamiento

En cuanto a la elección de las ROIs de entrenamiento, se han usado diferentes conjuntos de regiones de entrenamiento para cada sensor, basadas en el conocimiento de la información del terreno y utilizando una estrategia de selección aleatoria. En concreto, se han considerado 4 conjuntos de ROIs de entrenamiento distintos que incluyen sólo píxeles puros, píxeles mezclados (cerca del borde de cada objeto) y dos de ellos que contienen una combinación de ambos tipos de píxeles.

Se ha tenido especial cuidado al seleccionar estas regiones de entrenamiento para garantizar que fueran correctas y aplicables en ambos conjuntos de datos utilizados en el análisis, así como que incluyesen la posible variabilidad de cada clase en la imagen. Para ello, se han seleccionado teniendo en cuenta no sólo las zonas más homogéneas de cada clase, donde la presencia de ésta es más evidente, sino que también se ha considerado la variación real que presenta cada categoría. Por ejemplo, para clasificar los arbustos, se han escogido tanto áreas donde el arbusto aparece más denso, como zonas donde es menos frondoso y posee una menor vigorosidad (Figura 5.19).

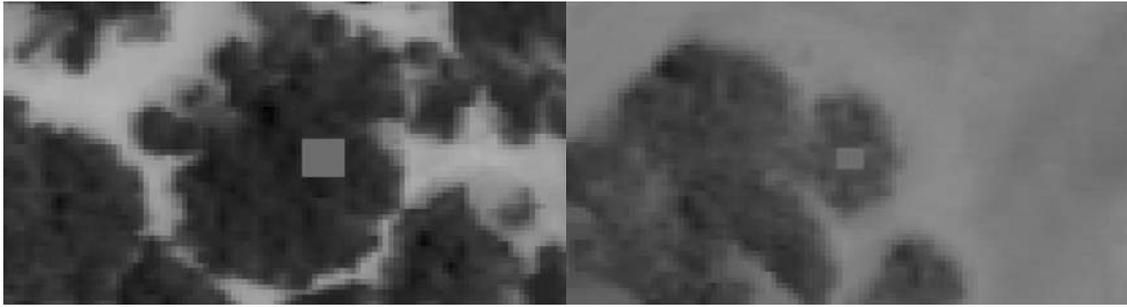


Figura 5.19. Ejemplo de ROIs de entrenamiento de la clase arbustos.

Además, se ha procurado que el número de ROIs de entrenamiento de cada clase tuviese la misma cantidad de píxeles (entre 400 y 600 en el conjunto de píxeles puros, entre 200 y 500 en los mezclados, y entre 1000 y 2000 píxeles en los conjuntos que contienen la combinación de ambos), salvo en la clase olas ya que ocupaba una superficie bastante menor que el resto. Por otra parte, ha sido necesario realizar ciertas modificaciones a las ROIs utilizadas en la imagen WV2 para que coincidieran con la clase objetivo debido a los pequeños desplazamientos no corregidos con el registro. La mayor parte de estas variaciones se ha aplicado sobre la clase otros pues, debido al diferente horario de adquisición de las imágenes, los objetos de la imagen CASI proyectaban sombras donde los de la imagen WV2 no lo hacían. En las Tablas 5.2 y 5.3 puede verse con detalle la cantidad ROIs de entrenamiento elegidas para cada una de las clases en los distintos conjuntos seleccionados, para la imagen CASI y WV2, respectivamente.

Tabla 5.2. Número de ROIs de entrenamiento de la imagen CASI.

Grupos de clases	Clases/Categorías	ROIs de entrenamiento (n° de píxeles)			
		Puras	Mezcladas	P + M 1	P + M 2
Vegetación	Árboles	35 (452)	26 (392)	27 (1.296)	19 (1.189)
	Arbustos	20 (495)	25 (260)	16 (1.361)	15 (1.424)
	Hierba/Césped	16 (554)	24 (291)	10 (1.737)	13 (1.202)
Masas de agua	Mar	14 (492)	20 (318)	15 (1.860)	19 (1.919)
	Lago	5 (535)	17 (245)	5 (1.327)	6 (1.436)
	Piscinas	19 (452)	25 (249)	15 (1.468)	17 (1.291)
	Olas	7 (109)	21 (202)	12 (575)	20 (568)
Superficies construidas	Suelo construido	61 (560)	40 (472)	60 (1.986)	65 (1.956)
	Asfalto (carreteras)	26 (483)	35 (397)	10 (1.594)	9 (1.668)
Suelos desnudos	Arena	15 (597)	19 (306)	13 (1.916)	11 (1.853)
	Resto de suelos desnudos	25 (562)	30 (365)	23 (1.851)	25 (1.922)
Otros	Sombras, borde/marco, ...	41 (437)	38 (349)	38 (1.123)	30 (1.376)

Tabla 5.3. Número de ROIs de entrenamiento de la imagen WV2.

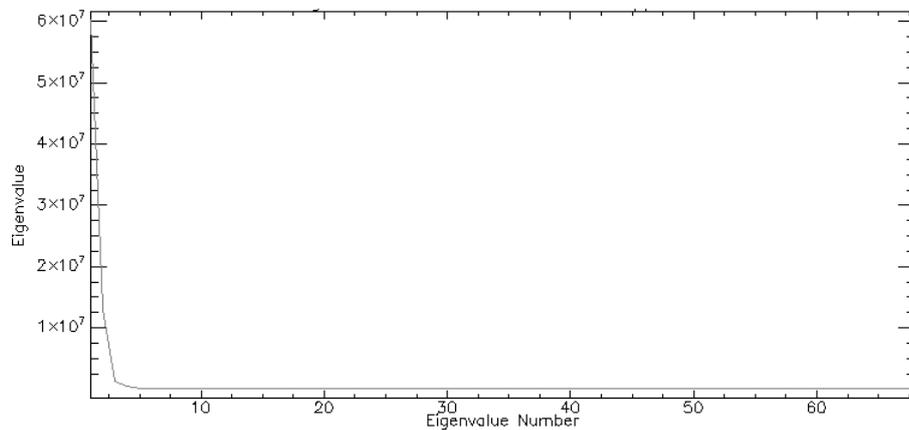
Grupos de clases	Clases/Categorías	ROIs de entrenamiento (nº de píxeles)			
		Puras	Mezcladas	P + M 1	P + M 2
Vegetación	Árboles	35 (446)	24 (303)	27 (1.194)	19 (1.089)
	Arbustos	20 (490)	25 (324)	16 (1.333)	15 (1.472)
	Hierba/Césped	16 (557)	24 (328)	10 (1.704)	13 (1.177)
Masas de agua	Mar	14 (505)	18 (353)	15 (1.852)	19 (1.956)
	Lago	5 (528)	15 (208)	5 (1.292)	6 (1.479)
	Piscinas	19 (429)	25 (258)	15 (1.311)	17 (1.116)
	Olas	7 (102)	20 (324)	12 (491)	20 (546)
Superficies construidas	Suelo construido	57 (517)	40 (444)	59 (1.940)	65 (1.966)
	Asfalto (carreteras)	25 (464)	30 (413)	10 (1.488)	9 (1.676)
Suelos desnudos	Arena	15 (586)	19 (256)	13 (1.943)	11 (1.837)
	Resto de suelos desnudos	25 (549)	30 (380)	23 (1.908)	25 (1.910)
Otros	Sombras, borde/marco, ...	13 (136)	12 (138)	16 (1.004)	12 (1.535)

5.3.4.3. Extracción de características

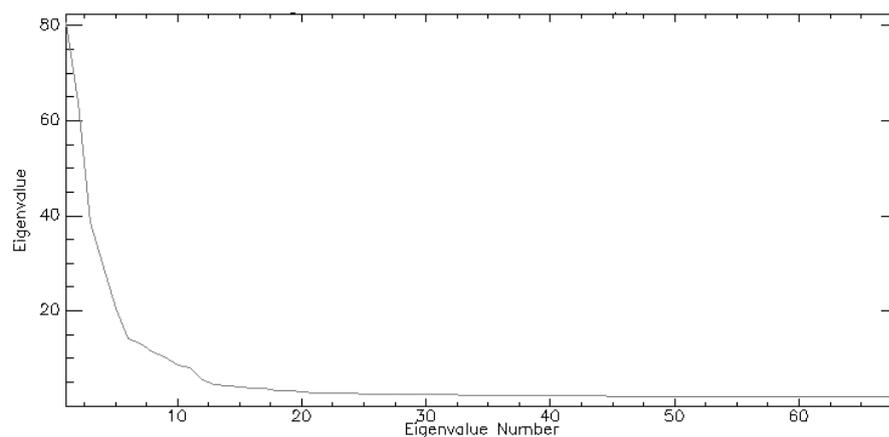
A continuación, se muestran los resultados obtenidos a partir de la extracción de características de las imágenes CASI (reducción dimensional, desmezclado espectral y textura) y WorldView-2 (textura). Puesto que en las imágenes multiespectrales la reducción dimensional no es necesaria, al disponer de muchas menos bandas, y que las técnicas de desmezclado no suelen ser efectivas al tener menos riqueza espectral y, por tanto, ser más impreciso el modelado de las firmas espectrales, en la imagen WV2 no se han aplicado estos procesos.

En primer lugar, en cuanto a las técnicas de reducción dimensional aplicadas a la imagen CASI, se han analizado las bandas de PCA y MNF, así como sus valores propios (*eigenvalues*). Como se ha mencionado con anterioridad, la información de las bandas PCA y MNF decrece a medida que se incrementa el número de bandas. Este hecho puede

observarse en la Figura 5.20, la cual muestra los niveles de los *eigenvalues* frente al número de bandas para las transformaciones PCA y MNF, respectivamente. En la Figura 5.20 a) se aprecia como a partir de la banda 5 el nivel de los *eigenvalues* se mantiene constante en su mínimo, mientras que en la Figura 5.20 b) esta situación ocurre, aproximadamente, a partir de la banda 15. No obstante, analizando de manera visual estas bandas se observa que más allá de éstas también existe información útil. En las Figuras 5.21 y 5.22 se muestran las bandas PCA y MNF de la 1 a la 30, respectivamente. Como se ve, la mayor parte de la información se concentra en las primeras bandas y las restantes se van convirtiendo en ruido. Por un lado, en el caso de la transformación PCA la mayoría de la información útil está contenida en las 10 primeras bandas; por otro, en la transformación MNF gran parte de la información se encuentra en las 25 primeras bandas. Por tanto, se han empleado estas bandas para sustituir al conjunto de datos original sin apenas pérdida de información.



a)



b)

Figura 5.20. Eigenvalues: a) PCA y b) MNF.

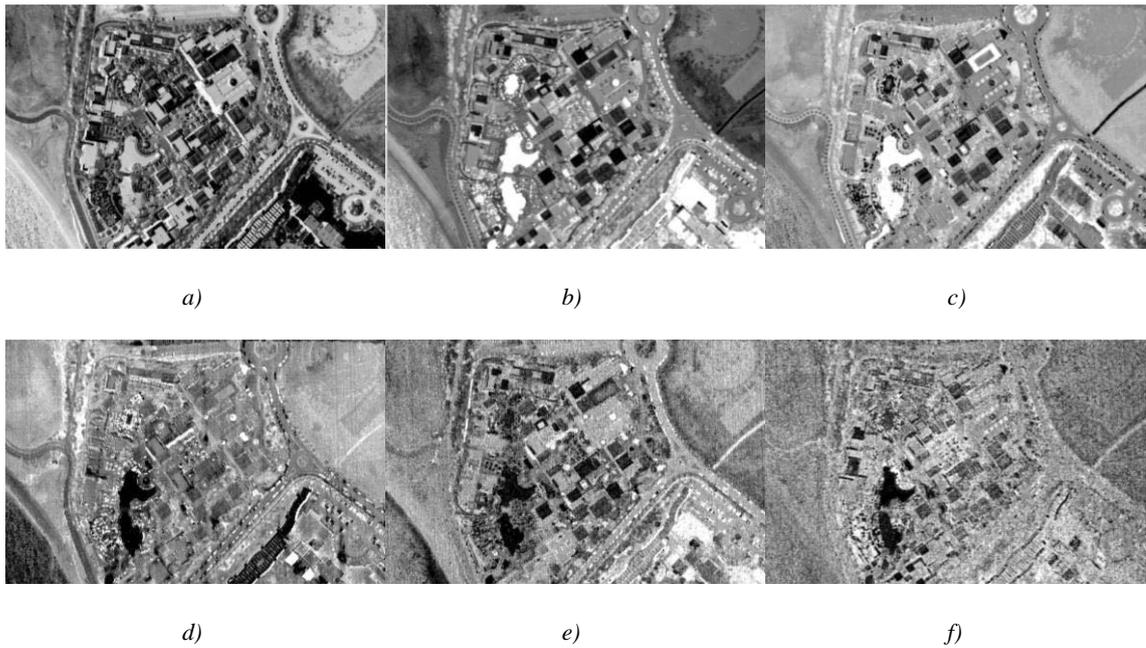


Figura 5.21. Muestras de diversas bandas PCA: a) Banda 1. b) Banda 3. c) Banda 5. d) Banda 10. e) Banda 20. f) Banda 30.

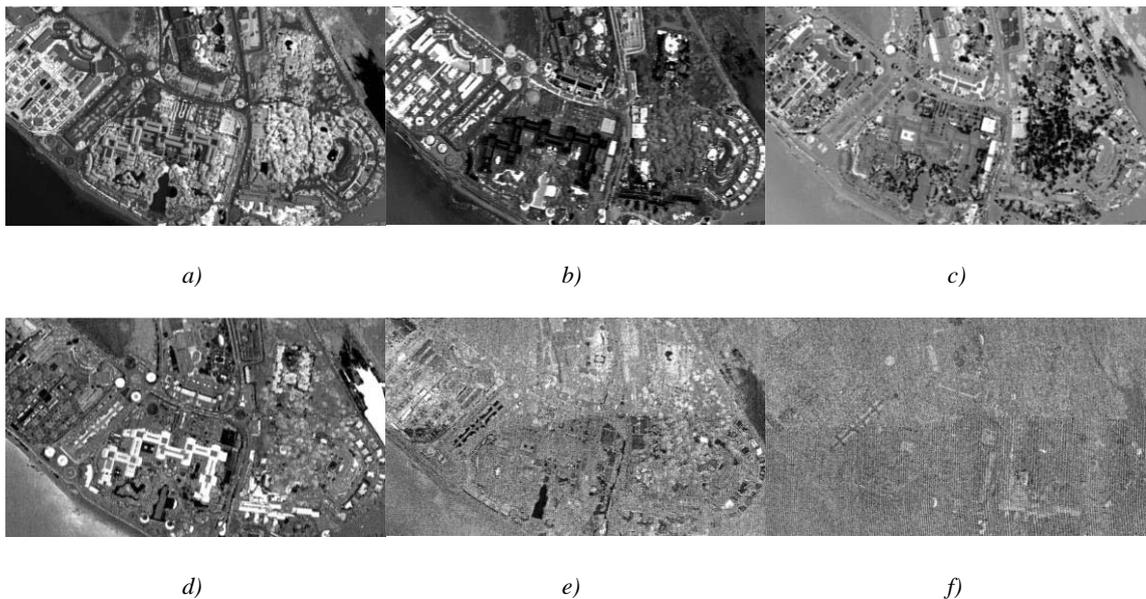


Figura 5.22. Muestras de diversas bandas MNF: a) Banda 1. b) Banda 3. c) Banda 5. d) Banda 10. e) Banda 20. f) Banda 30.

En segundo lugar, se obtuvieron los mapas de abundancia de cada clase tras la aplicación de técnicas de desmezclado espectral lineal a las bandas de la imagen CASI y a las componentes reducidas dimensionalmente. En la Figura 5.23 (a, b y c) se presentan zonas aumentadas de los mapas de abundancia pertenecientes a la clase arena obtenidos del primer conjunto de ROIs a partir de las bandas originales y de las componentes PCA y MNF de la imagen CASI. En esta figura se observan en color amarillo los píxeles que contienen más

arena, pasando por tonos azules hasta llegar al violeta aquellos píxeles que contengan menos cantidad de esta clase. Como se aprecia, con las componentes MNF los píxeles que contienen más arena se corresponden de manera más adecuada con los observados en la imagen RGB que con las bandas originales y las componentes PCA. Estos resultados se mantienen en el resto de clases, independientemente del conjunto de ROIs utilizado.

Sin embargo, se puede ver que estos mapas están afectados en gran medida por ruido sal y pimienta, por lo que se aplicó un filtro de mediana en los mapas con mejores resultados (los obtenidos con el primer conjunto de ROIs). En la Figura 5.23 (d, e y f) puede observarse la mejoría tras la aplicación de este filtro.

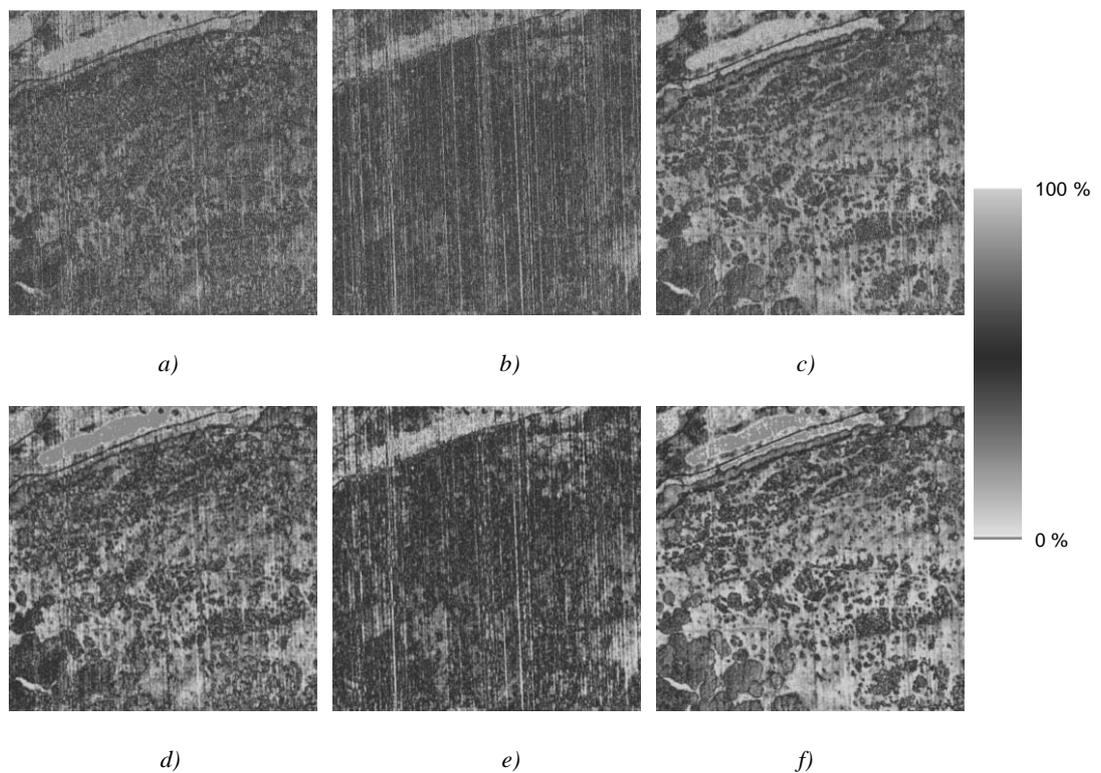


Figura 5.23. Zoom en mapas de abundancia de la clase arena generados a partir de: a) Bandas espectrales, b) Componentes PCA, c) Componentes MNF, d) Bandas espectrales filtradas, e) Componentes PCA filtradas, f) Componentes MNF filtradas.

Por último, en las Figuras 5.24 y 5.25 se presenta la información de textura extraída de las imágenes CASI y WV2, respectivamente.



a)

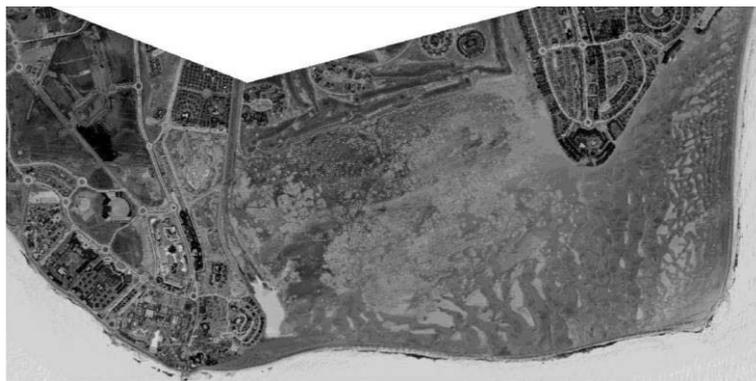


b)

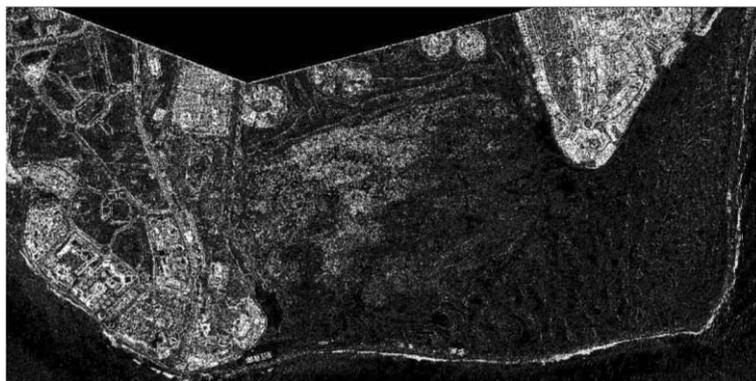


c)

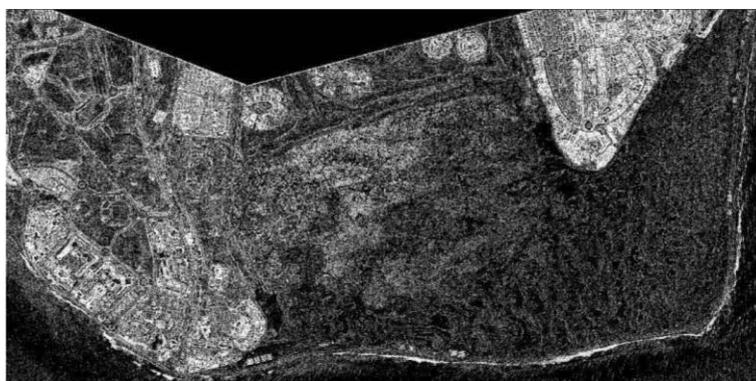
Figura 5.24. Información de textura extraída de la imagen CASI usando los siguientes parámetros: a) Media. b) Varianza. c) Entropía.



a)



b)



c)

Figura 5.25. Información de textura extraída de la imagen WV2 usando los siguientes parámetros: a) Media. b) Varianza. c) Entropía.

5.3.4.4. ROIs de evaluación

Para la elección de las ROIs de evaluación se han seguido criterios similares a los explicados en el apartado anterior. Sin embargo, con el fin de obtener una mayor exactitud en la evaluación de la clasificación, se ha generado un único conjunto compuesto por número de áreas de test mayor a las de entrenamiento. En la Tabla 5.4 se observan las ROIs de evaluación seleccionadas para cada clase en los dos sensores usados.

Tabla 5.4. Número de ROIs de evaluación.

Grupos de clases	Clases/Categorías	ROIs de evaluación (nº de píxeles)	
		CASI	WV2
Vegetación	Árboles	66 (4.773)	64 (4.154)
	Arbustos	65 (4.131)	65 (4.262)
	Hierba/Césped	41 (4.991)	40 (4.803)
Masas de agua	Mar	26 (5.689)	26 (5.745)
	Lago	11 (4.359)	11 (4.327)
	Piscinas	32 (4.727)	31 (4.617)
	Olas	28 (1.556)	25 (1.839)
Superficies construidas	Suelo construido	70 (5.313)	68 (4.933)
	Asfalto (carreteras)	94 (4.402)	90 (4.181)
Suelos desnudos	Arena	43 (4.621)	43 (4.739)
	Resto de suelos desnudos	49 (5.536)	47 (5.551)
Otros	Sombras, borde/marco, ...	79 (4.106)	20 (946)

5.3.4.5. Separabilidad entre clases y firmas espectrales

En el Anexo 1 se pueden ver los resultados de separabilidad espectral entre las parejas de clases, usando la distancia de Jeffries-Matusita, de los cuatro conjuntos de regiones de interés de entrenamiento y el de evaluación para los dos sensores.

Analizando los valores se aprecia que todas las parejas en la imagen CASI obtienen una buena separabilidad (valores mayores a 1,9). No obstante, en la imagen WV2 las parejas de aquellas clases cuyos terrenos tienen una gran variabilidad y complejidad o son similares entre sí, como el suelo construido (*Built soil*) y el asfalto (*Asphalt*) o la arena (*Sand*) y el resto de suelos desnudos (*Rest bare soils*), tienen una separabilidad algo menor a 1,9 en los conjuntos de ROIs de píxeles puros y en las combinaciones entre puros y mezclados. Además, en el conjunto de píxeles mezclados, un mayor número de parejas tienen peor separabilidad (hasta un valor mínimo de 1,5) debido a que la resolución espectral inferior del sensor WV2 con respecto al CASI dificulta la distinción entre clases cuando las regiones se seleccionan en los bordes de los objetos.

Por último, en cuanto a los resultados de separabilidad de las regiones de interés de evaluación, al igual que las muestras usadas para el entrenamiento, en la imagen CASI todas las parejas de clases obtienen un valor superior a 1,9, mientras que en la imagen WV2 algunas están por debajo de este valor.

En cuanto a las firmas espectrales, en la Figura 5.26 se muestran las firmas de las clases del primer conjunto de ROIs en ambos sensores. Por un lado, en la Figura 5.26 a) se presentan los valores de reflectancia adquiridos por el sensor CASI en las 68 bandas (rango de longitudes de onda entre 396,9-1039,0 nm). Por otro lado, en la Figura 5.26 b) se presentan los valores adquiridos por el sensor WV2 en las 8 bandas (rango de longitudes de onda entre 427,3-908,0 nm). En ambos casos el valor de reflectancia real puede adquirirse aplicando un factor de escala de 10^{-4} . Se aprecia que el gran número de bandas de la imagen CASI permite obtener firmas espectrales más detalladas que la imagen WV2. En el resto de conjuntos de ROIs de entrenamiento y en el de evaluación las firmas obtenidas son similares a las de este conjunto.

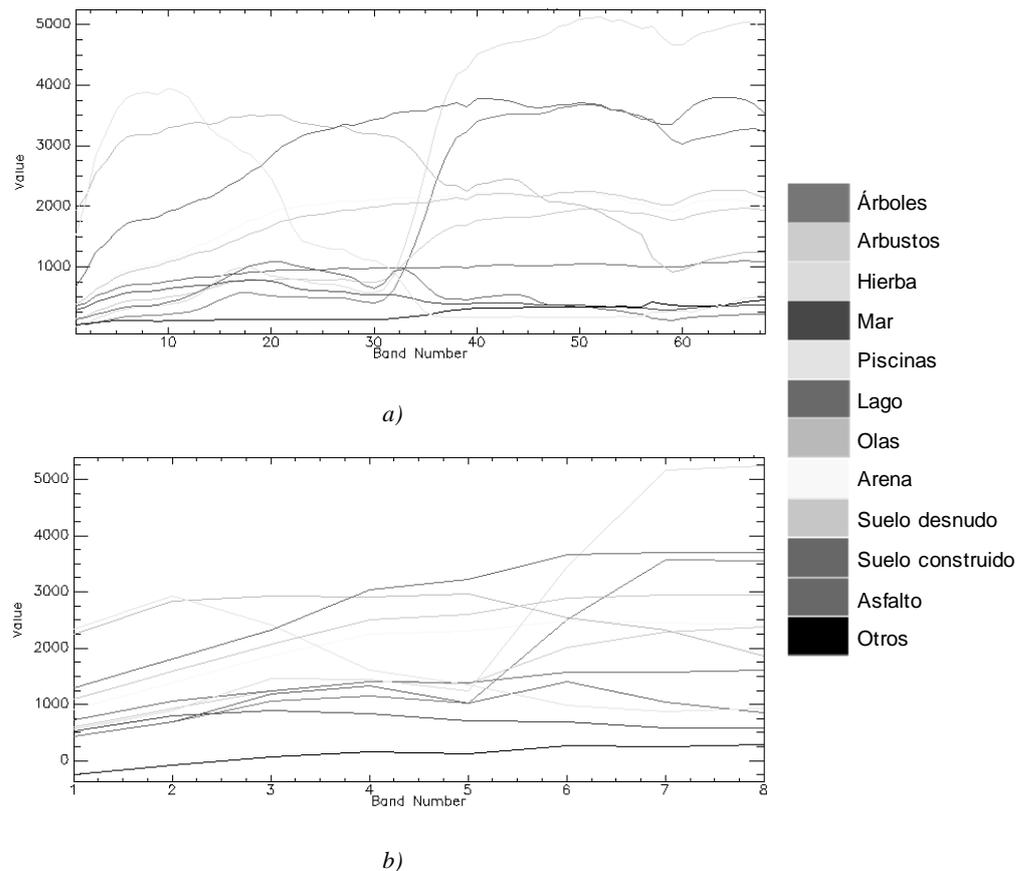


Figura 5.26. Firmas espectrales de las clases del primer conjunto de ROIs en: a) CASI. b) WV2.

5.3.4.6. Análisis a nivel de clasificador

En este apartado se analiza la precisión de la clasificación realizada tras el clasificador SVM a los datos multiespectrales e hiperespectrales a las siguientes combinaciones de entrada:

- Bandas espectrales.
- 10 primeras componentes PCA de la imagen CASI.
- 25 primeras componentes MNF de la imagen CASI.
- Bandas espectrales más la información de textura.
- Mapas de abundancia (Ab) de cada clase tras la aplicación de técnicas lineales de descomposición espectral tanto a las bandas como a las componentes reducidas dimensionalmente de la imagen CASI.

Como se ha indicado, se consideraron 4 conjuntos diferentes de regiones de entrenamiento para evaluar la robustez de las distintas metodologías. En la Tabla 5.5 puede verse la fiabilidad global de los mapas, así como el coeficiente kappa entre paréntesis de cada una de las estrategias evaluadas. En sombreado amarillo se destacan los mejores resultados obtenidos en el sensor CASI y en azul los del sensor WV2.

Con respecto a los sensores, se observa que CASI proporciona unas precisiones ligeramente superiores que WV2. En cuanto a las ROIs de entrenamiento, los mejores resultados se consiguen usando las regiones que combinan píxeles puros y mezclados, mientras que los más desfavorables se obtienen con los píxeles mezclados. En el caso de las técnicas de reducción dimensional, la transformación MNF logra precisiones mayores que la PCA. Por otra parte, la información de textura no siempre mejora el rendimiento de la metodología, sin embargo, su inclusión en los datos CASI aporta buenos resultados. Por último, la aplicación de técnicas de desmezclado espectral no mejora la clasificación, ni siquiera tratándose de una imagen hiperespectral. No obstante, con la aplicación de un filtro de mediana a los mapas de abundancia se logra incrementar la precisión, aproximadamente, un 20 %.

Tabla 5.5. Fiabilidad global y coeficiente kappa de los datos CASI y WV2.

Sensor	Datos de entrada (nº de bandas)	Puros	Mezclados	P + M 1	P + M 2
CASI	Bandas espectrales (68)	85,48 % (0,841)	76,36 % (0,741)	91,40 % (0,906)	91,91 % (0,911)
	PCA 1-10 (10)	85,40 % (0,840)	76,19 % (0,739)	91,23 % (0,904)	92,16 % (0,914)
	MNF 1-25 (25)	87,84 % (0,867)	80,37 % (0,785)	91,35 % (0,905)	91,35 % (0,905)
	Bandas + textura (71)	86,29 % (0,850)	73,84 % (0,713)	91,53 % (0,907)	92,38 % (0,916)
	Ab bandas (12)	56,43 % (0,524)	53,67 % (0,494)	63,17 % (0,597)*	61,28 % (0,577)
	Ab PCA 1-10 (12)	45,34 % (0,402)	45,03 % (0,400)	60,76 % (0,570)*	50,26 % (0,456)
	Ab MNF 1-25 (12)	62,21 % (0,587)	56,61 % (0,526)	64,44 % (0,611)*	62,16 % (0,586)
WorldView-2	Bandas espectrales (8)	87,54 % (0,863)	71,71 % (0,689)	88,57 % (0,874)	90,14 % (0,891)
	Bandas + textura (11)	87,20 % (0,859)	70,49 % (0,675)	87,52 % (0,862)	88,60 % (0,874)

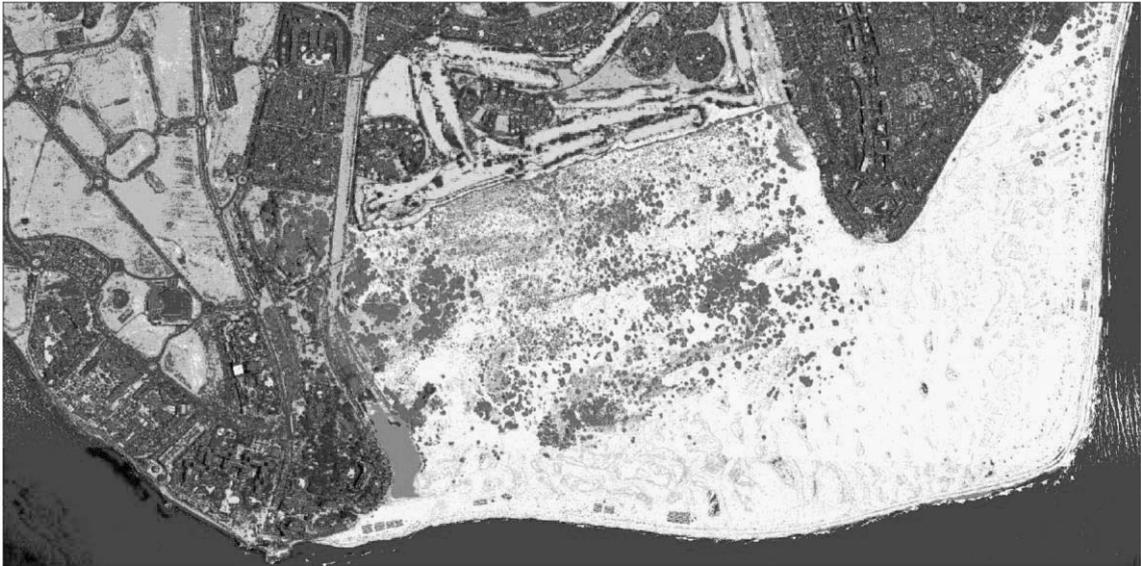
* Resultados tras la aplicación del filtro de mediana:

Ab bandas (12): 78,95 % (0,769)

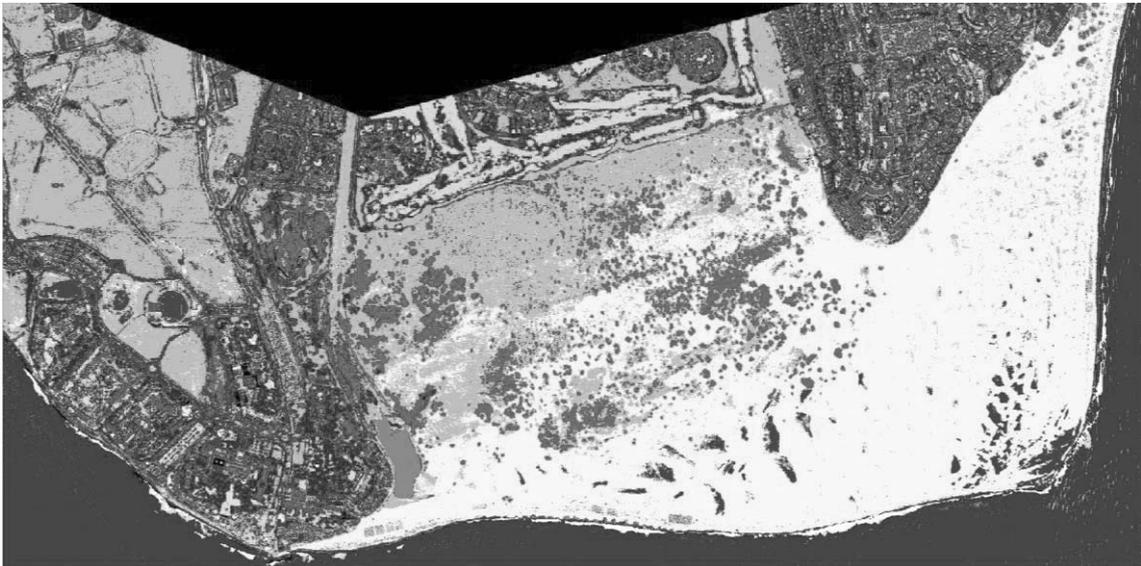
Ab PCA 1-10 (12): 79,51 % (0,775)

Ab MNF 1-25 (12): 84,28 % (0,828)

En la Figura 5.27 se muestran los mejores mapas temáticos para cada sensor. Para el sensor CASI se obtuvo a partir de las bandas espectrales más la información de textura y para el sensor WV2 sólo a partir de las bandas. Ambos mapas se generaron usando las ROIs que combinan píxeles puros y mezclados. Los resultados tienen precisiones similares, 92,38 % y 90,14 % para CASI y WV2, respectivamente. El resto de mapas generados pueden verse en el Anexo 2.



a)



b)

Figura 5.27. Mejores mapas temáticos: a) CASI. b) WorldView-2.

5.3.4.7. Análisis a nivel de clases

Para realizar este análisis de las clases es necesario examinar las matrices de confusión de las distintas imágenes. En este apartado se estudiarán las matrices de los dos mapas con mejores resultados para cada clasificador (el resto de matrices de confusión pueden verse en el Anexo 3). A modo de resumen, las categorías peor y mejor clasificadas para cada sensor se muestran en la Tabla 5.6.

Tabla 5.6. Resumen de las categorías peor y mejor clasificadas, según el sensor utilizado.

Sensor	Clases peor clasificadas (% píxeles asignados correctamente)	Clases mejor clasificadas (% píxeles asignados correctamente)
CASI	Suelo construido (86,50 %)	Piscinas (97,06 %)
	Mar (87,64 %)	Lago (99,98 %)
WorldView-2	Arena (71,09 %)	Mar (98,76 %)
	Árboles (79,15 %)	Piscinas (99,20 %)

Para facilitar la comprensión de las matrices de confusión se han usado gráficos de barras, en los cuales las columnas representan las clases a discriminar y las barras de colores indican el porcentaje de píxeles pertenecientes a la clase real (áreas de evaluación) que se han asignado a cada categoría a clasificar. A continuación, se detallan estos resultados:

- **CASI: Bandas + Textura** (Figura 5.28). La clase suelo construido ofrece el peor resultado con un porcentaje de exactitud de 86,5 % (error de omisión del 13,5 %). Esta categoría presenta confusión con la clase resto de suelos desnudos, a la cual se le asignan el 9,49 % de los píxeles que le corresponden al suelo construido. Esto se debe, principalmente, al material de construcción arenoso de ciertos tejados. En menor medida, las clases arbusto y arena asignan de manera errónea píxeles pertenecientes al suelo construido.

Las siguientes clases con más errores de omisión son el mar y el resto de suelos desnudos con precisiones del 87,64 % y 87,73 %, respectivamente. Por un lado, un 8,53 % de los píxeles pertenecientes al mar se asignan a la clase otros. Esto puede verse en la esquina inferior izquierda de la Figura 5.27 a), donde la mayoría de estos píxeles errores se concentran en las zonas más oscuras del mar. En menor medida, se asignan píxeles de la clase mar al resto de categorías de agua y al asfalto. Por otro lado, cerca de un 5 % de los píxeles de la clase resto de suelos desnudos se clasifican como arena y, con porcentajes algo menores, también se tienen equivocaciones en el asfalto, los arbustos y el suelo construido. Esto es debido a la gran variabilidad de esta clase, la cual está compuesta por materiales que poseen similitud espectral con algunos materiales de las clases confundidas. El resto de clases tienen errores de omisión inferiores al 10 %, siendo los más bajos los de las clases lago y piscinas, 0,02 % y 2,94 %, respectivamente.

- **WorldView-2: Bandas espectrales** (Figura 5.29). El principal problema surge en la clase arena, con un 28,91 % de error de omisión. Esta categoría presenta una gran confusión con la clase resto de suelos desnudos, a la cual se le asignan un 24,98 % de los píxeles que pertenecen a arena. Esto se observa con claridad en la Figura 5.27 b), donde en la zona central de las dunas los píxeles que bordean a los arbustos se clasifican de forma errónea.

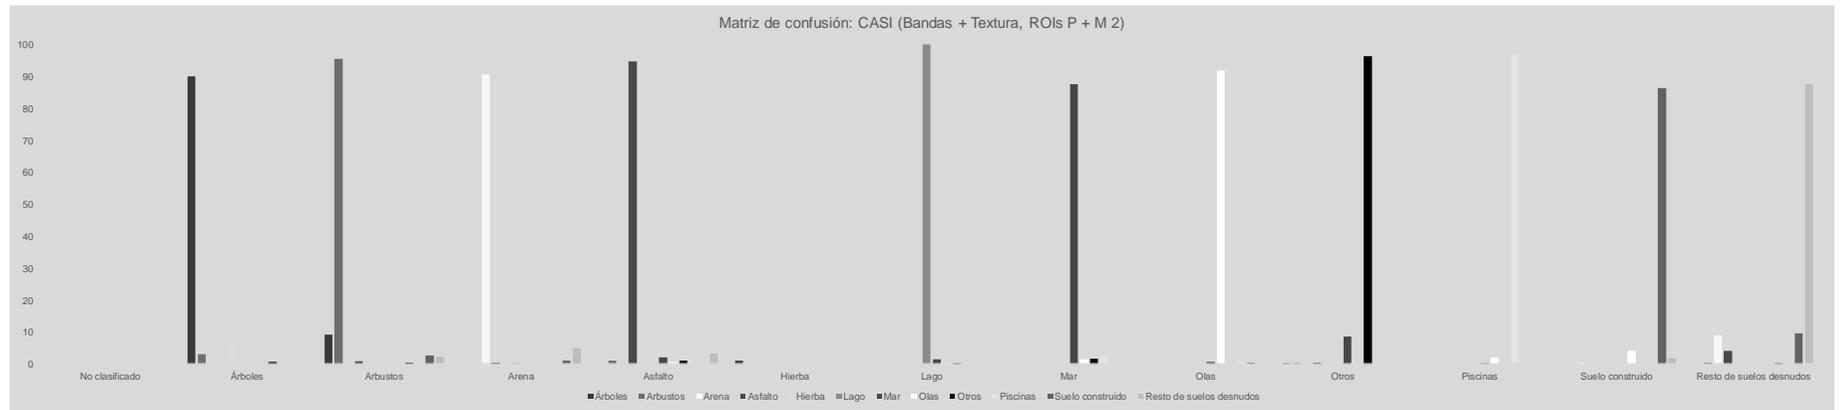
Con un error de omisión de aproximadamente el 20 % aparece la clase árboles, la cual, de manera similar a como ocurre en el sensor CASI, poco más del 15 % de los píxeles pertenecientes a su categoría se clasifican como arbustos. Un porcentaje inferior de píxeles de la clase árboles son asignados también a la hierba. Las siguientes clases con errores de omisión significativos son el resto de suelos desnudos y el suelo construido. Por una parte, el resto de suelos desnudos presenta sus equivocaciones, al igual que en CASI, con la arena, el asfalto, los arbustos y el suelo construido. Por otra parte, cerca del 10 % de píxeles correspondientes al suelo construido se categorizan como suelo desnudo.

Las demás categorías obtienen mejores resultados de precisión con errores de omisión por debajo del 10 %.

Capítulo 5. Generación de mapas de cobertura terrestre en Maspalomas

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	89,99	3,1	0	0	5,91	0	0	0	0,49	0	0	0	8,74
Arbustos	9,09	95,57	0	0,77	0,04	0	0	0	0,41	0	2,54	2,2	8,66
Arena	0	0	90,76	0,27	0	0,02	0	0	0	0	1,07	4,95	8,37
Asfalto	0	1,04	0	94,68	0	0	1,92	0,64	0,88	0	0	3,27	8,39
Hierba	0,9	0	0	0	94,05	0	0	0	0	0	0	0	8,74
Lago	0	0	0	0	0	99,98	1,35	0,06	0,05	0	0	0	8,19
Mar	0	0	0	0	0	0	87,64	1,41	1,63	2,31	0	0	9,56
Olas	0	0	0	0	0	0	0,51	91,84	0	0,63	0,4	0	2,78
Otros	0,02	0,02	0	0,3	0	0	8,53	0	96,42	0	0	0	8,23
Piscinas	0	0	0	0	0	0	0,05	1,99	0	97,06	0	0	8,53
Suelo construido	0	0	0,28	0	0	0	0	4,05	0	0	86,5	1,84	8,81
Resto de suelos desnudos	0	0,27	8,96	3,98	0	0	0	0,12	0	0	9,49	87,73	11,01
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

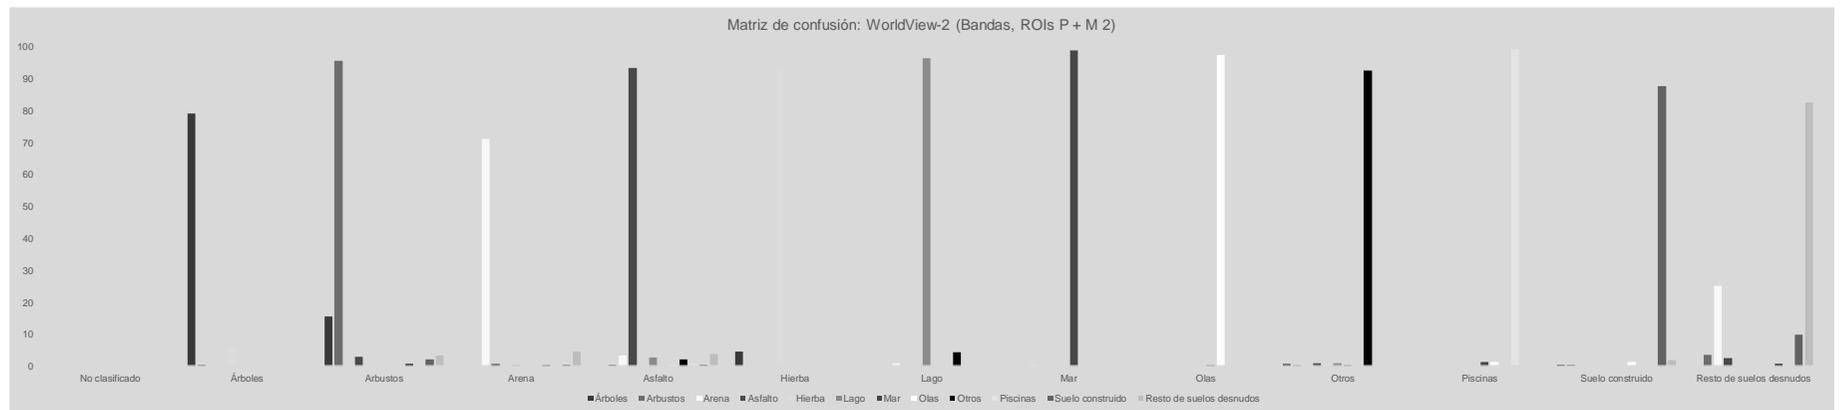


b)

Figura 5.28. CASI: Bandas + Textura (ROIs P + M 2): a) Matriz de confusión. b) Gráfica.

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	79,15	0,31	0	0	5,79	0	0	0	0	0	0	0	7,14
Arbustos	15,38	95,57	0	2,8	0	0	0	0	0,63	0,02	2,05	3,12	10,2
Arena	0	0	71,09	0,57	0	0,09	0	0	0,11	0	0,28	4,38	7,3
Asfalto	0	0,31	3,14	93,37	0	2,63	0	0,11	1,9	0,5	0,43	3,64	8,87
Hierba	4,43	0	0	0	94,21	0	0	0	0	0	0	0	9,4
Lago	0	0	0,76	0	0	96,42	0	0	4,23	0	0	0	8,48
Mar	0	0	0,02	0	0	0	98,76	0	0	0,19	0	0	11,35
Olas	0	0	0	0	0	0	0,05	97,5	0	0,09	0	0	3,59
Otros	0,63	0,07	0	0,77	0	0,86	0,02	0	92,49	0	0	0	1,94
Piscinas	0	0	0	0	0	0	1,17	1,25	0	99,2	0	0	9,32
Suelo construido	0,41	0,35	0	0	0	0	0	1,14	0	0	87,57	1,84	9,42
Resto de suelos desnudos	0	3,4	24,98	2,49	0	0	0	0,63	0	0	9,67	82,62	12,98
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)



b)

Figura 5.29. WorldView-2: Bandas espectrales (ROIs P + M 2): a) Matriz de confusión. b) Gráfica.

5.3.4.8. Detección de cambios

En la Figura 5.30 se presenta el mapa generado a partir del proceso de detección de cambios en el cual se muestran las diferencias entre los dos mapas con mejores resultados de los sensores CASI y WV2. Además, en la Tabla 5.7 se pueden ver las clases, ordenadas de mayor a menor, que han producido cambios superiores al 0,85 % de un mapa al otro (las estadísticas completas se encuentran en el Anexo 4).

Analizando estos resultados, se observa que el 75 % del área del mapa ha permanecido sin cambios (color blanco en la Figura 5.30). En cuanto a las diferencias, los cambios más significativos fueron las clases que cambiaron de resto de suelos desnudos a otra clase o viceversa. En concreto, el mayor cambio se ha producido al cambiar de suelo desnudo a arena (color verde) y de arena a suelo desnudo (color rojo), lo cual muestra el error a la hora de discriminar estas clases en ambos sensores. Los siguientes cambios más relevantes se encuentran en las transiciones de suelo construido a suelo desnudo y viceversa (colores beige y azul grisáceo), causados principalmente por la dificultad para distinguir dichas categorías en terrenos pedregosos, y de suelo desnudo a arbustos (color morado), producidos sobre todo por la dificultad para diferenciar los arbustos menos frondosos del suelo desnudo usando la imagen WV2, problema que la imagen CASI solventa de manera más eficiente. Por un motivo similar se produce el cambio de suelo construido a arbustos (color celeste), ya que existen regiones con alta variabilidad que complican su correcta clasificación. Aproximadamente el 1 % del mapa se cambia de asfalto a arena (color gris claro), debido a que las zonas de arena húmeda son clasificadas en la imagen WV2 como asfalto. Finalmente, el 0,85 % del mapa cambia de suelo desnudo a asfalto y el motivo principal en este caso no es un error de clasificación, sino un cambio debido a que en la fecha de captura de la imagen WV2 había carreteras que aún no estaban asfaltadas y sí lo estaban en la fecha de la imagen CASI.



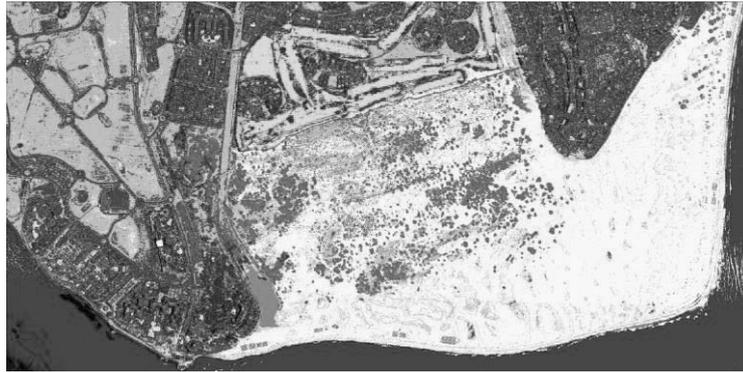
Figura 5.30. Detección de cambios de los mejores mapas clasificados de cada sensor.

Tabla 5.7. Estadísticas simplificadas de la detección de cambios.

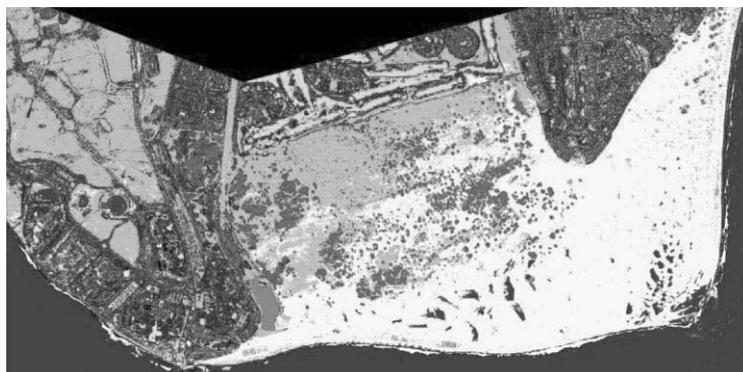
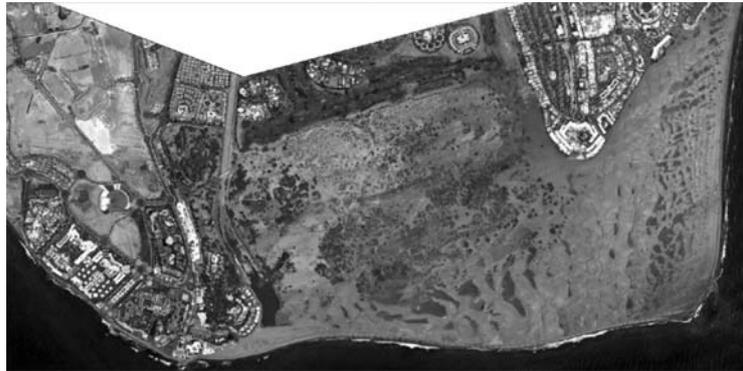
Clasificación_T1 (WV2)	Clasificación_T2 (CASI)	Área (m ²)	Porcentaje	Color
Sin cambios	Sin cambios	5.980.512,25	75,448906	
Resto de suelos desnudos	Arena	363.415,5	4,584775	
Arena	Resto de suelos desnudos	190.468,25	2,402908	
Suelo construido	Resto de suelos desnudos	135.935,25	1,714931	
Resto de suelos desnudos	Arbustos	125.067	1,577819	
Resto de suelos desnudos	Suelo construido	107.033	1,350306	
Suelo construido	Arbustos	89.146,25	1,124651	
Asfalto	Arena	84.590,75	1,067179	
Resto de suelos desnudos	Asfalto	67.467,5	0,851156	

5.3.4.9. Cartografía temática de Maspalomas

Para terminar, a los mapas temáticos con mejores resultados en la clasificación de ambos sensores empleados se ha aplicado un filtro de mayoría de manera que se han obtenido los mapas de coberturas terrestres definitivos de la zona de Maspalomas. En la Figura 5.31 se pueden comparar estos mapas junto con las imágenes procedentes de ambos sensores.



a)



b)

Figura 5.31. Comparativa de imágenes de Maspalomas: a) Imágenes procedentes de CASI. b) Imágenes procedentes de WV2.

Asimismo, se ha calculado el número de píxeles incluidos en cada clase (Tabla 5.8). Al ser conocida la dimensión superficial de cada píxel (0,25 m²), se ha podido hallar la extensión ocupada por cada categoría.

Tabla 5.8. Inventario de la ocupación del suelo en Maspalomas.

Clases/Categorías	Nº de píxeles (% total)		Superficie (km ²)	
	CASI	WV2	CASI	WV2
Árboles	1.934.190 (5,70 %)	1.537.565 (4,53 %)	0,483	0,384
Arbustos	3.723.184 (10,98 %)	2.953.479 (8,70 %)	0,930	0,738
Hierba/Césped	1.411.435 (4,16 %)	1.054.560 (3,11 %)	0,353	0,263
Total Vegetación	7.068.809 (20,84 %)	5.545.604 (16,34 %)	1,767	1,386
Mar	4.244.429 (12,51 %)	4.512.253 (13,29 %)	1,061	1,128
Lago	190.483 (0,56 %)	151.070 (0,45 %)	0,047	0,037
Piscinas	145.786 (0,43 %)	189.878 (0,56 %)	0,036	0,047
Olas	191.970 (0,57 %)	210.857 (0,62 %)	0,047	0,052
Total masas de agua	4.772.668 (14,07 %)	5.064.058 (14,92 %)	1,193	1,266
Suelo construido	2.735.199 (8,06 %)	3.033.193 (8,94 %)	0,683	0,758
Asfalto (carreteras)	1.847.002 (5,44 %)	1.461.029 (4,30 %)	0,461	0,365
Total superficies construidas	4.582.201 (13,51 %)	4.494.222 (13,24 %)	1,145	1,123
Arena	9.738.968 (28,71 %)	8.884.819 (26,17 %)	2,434	2,221
Resto de suelos desnudos	7.260.890 (21,41 %)	7.685.747 (22,64 %)	1,815	1,921
Total suelos desnudos	16.999.858 (50,12 %)	16.570.566 (48,82 %)	4,249	4,142
Sombras, borde/marco, ...	496.424 (1,46 %)	2.270.220 (6,69 %)	0,124	0,567
Dimensión total de la imagen	33.919.960	33.944.670	8,479	8,486

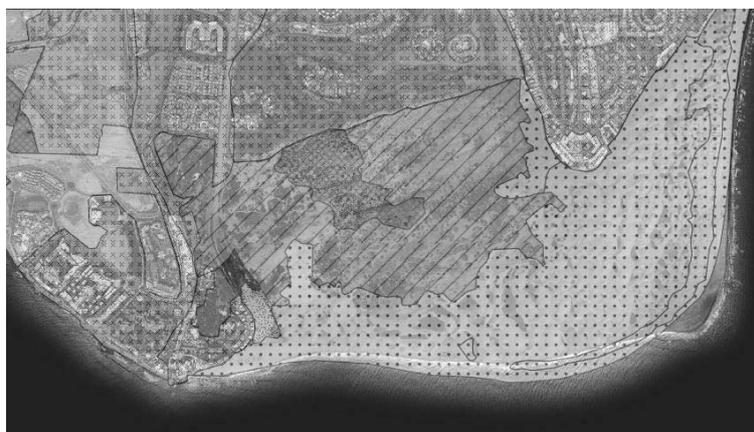
Con esta tabla se pueden obtener informaciones útiles acerca del área que ocupan las distintas categorías presentes en Maspalomas. Por ejemplo, de ella puede extraerse la clase que ocupa mayor superficie en esta zona (la arena, con cerca de 2,5 km²), la extensión aproximada que ocupa la vegetación (poco más de 1,7 km²), el área de las zonas construidas (alrededor de 1 km²), etc.

Antes de este trabajo sólo se disponía, para Maspalomas, de los mapas de caracterización del suelo proporcionados por GRAFCAN-Gobierno de Canarias (Figura 5.32). Éstos son mapas generados de forma no automática que ofrecen una información poco precisa de la superficie ocupada, ya que hacen una discriminación a gran escala sin tener en cuenta las distintas

coberturas terrestres que se encuentran en esas extensiones. GRAFCAN también ofrece un mapa de los tipos de vegetación, pero, al igual que en el caso anterior, la distinción la realiza sin mucho detalle.



a)



b)

Figura 5.32. Caracterización del suelo (GRAFCAN): a) Mapa de ocupación de suelo. b) Mapa de vegetación. Fuente: <http://visor.grafcan.es/visorweb/>

Aparte de la cartografía mencionada, se tiene constancia de un trabajo de investigación enfocado en la cubierta vegetal de Maspalomas en el año 2003 [55]. Este estudio se centra en la caracterización de los diferentes tipos de especies de vegetación que conviven en Maspalomas (Figura 5.33). Fue realizado a partir de técnicas de fotointerpretación y trabajos de campo, procesos mucho más lentos y costosos que los realizados en este TFM.

Asimismo, se tienen mapas de coberturas de suelo de esta zona obtenidos a partir de la fusión de datos de diferente naturaleza (WV2, SAR y LiDAR) tras la aplicación de diversos algoritmos clasificadores, generados como resultado de mi Trabajo de Fin de Grado (TFG) [54]. En la Figura 5.34 se puede ver el mapa con la precisión más alta de dicho TFG. Comparando este

mapa con los obtenidos en este TFM, se aprecia que los resultados alcanzados son similares en ambos trabajos. No obstante, en este TFM se ha logrado mejorar los problemas a la hora de discriminar el suelo construido del suelo desnudo presentes en el mapa del TFG.

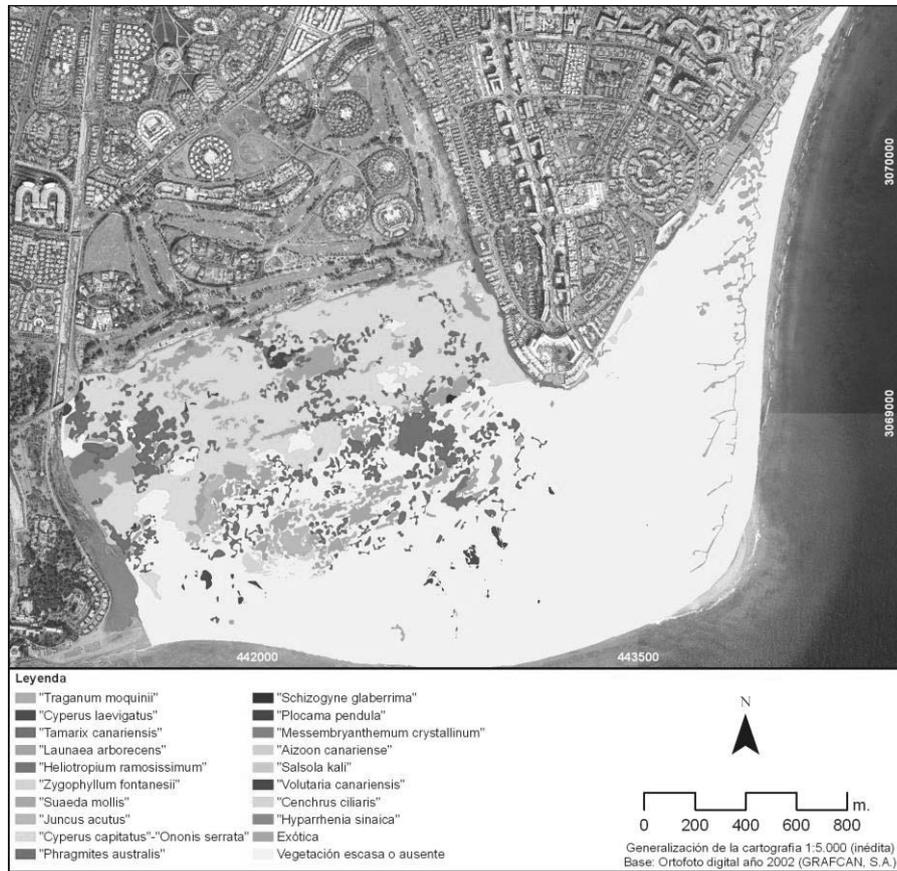


Figura 5.33. Comunidades vegetales del campo de dunas de Maspalomas (2003). Fuente: https://www.researchgate.net/publication/259581388_APLICACION_DE_TECNOLOGIAS_DE_LA_INFORMACION_GEOGRAFICA_AL_ESTUDIO_DE_LA_VEGETACION_EN_SISTEMAS_DE_DUNAS_LITORALES_RESULTADOS_PRELIMINARES_EN_EL_CAMPO_DE_DUNAS_DE_MASPALO-MAS_GRAN_CANARIA_ISLAS_CANARI

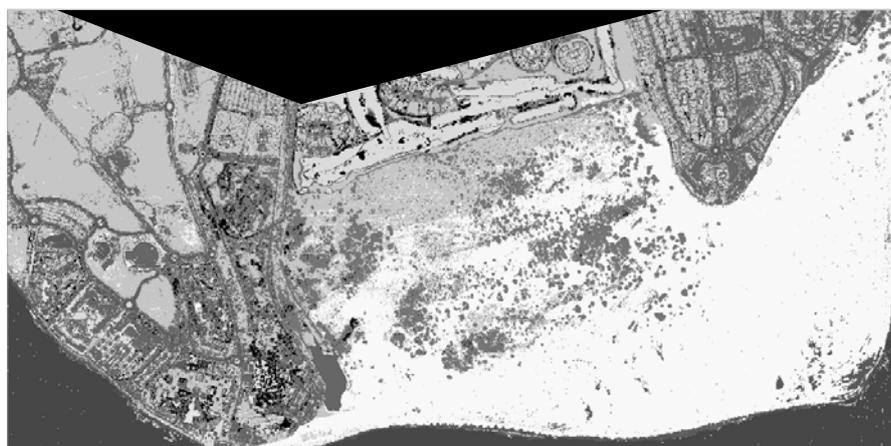


Figura 5.34. Mapa temático obtenido a partir de la fusión de datos WV2, SAR y LiDAR.

Capítulo 6. Conclusiones

6.1. Revisión de los objetivos

Una vez generada la cartografía temática de Maspalomas, se pretende analizar los objetivos fijados al inicio de este TFM y las tareas realizadas para su consecución. Éstos se revisan a continuación:

- Se han estudiado los fundamentos básicos de la teledetección y, en concreto, los sensores empleados en este TFM: el sensor multiespectral WV2 y el sensor hiperespectral CASI, analizando sus características generales y sus productos disponibles. Además, se han estudiado las diferencias principales entre ambos tipos de sistemas.
- Se han estudiado los diversos tipos de distorsión que afectan a las imágenes durante su adquisición, así como las técnicas de pre-procesado que permiten su corrección y mejora. En especial, se ha analizado la fusión de las imágenes pancromática y multiespectral para la obtención de una sola imagen de mayor resolución espacial (*pansharpening*) mediante el método basado en la transformada *wavelet à trous* y en la dimensión fractal para su posterior aplicación sobre la imagen WV2.
- Se han estudiado distintos métodos que permiten el proceso de alineación geométrica de las imágenes (registro de imágenes), posibilitando la elección del procedimiento que se ha aplicado sobre las imágenes de los sistemas WV2 y CASI. De esta forma, se ha logrado que los píxeles correspondientes de ambas imágenes representen los mismos objetos para, tras la aplicación de diversos procesos, poder compararlas.
- Se han generado 4 conjuntos diferentes de regiones de entrenamiento considerando un total de 12 categorías a discriminar para poder realizar la clasificación supervisada, así como para generar mapas de abundancias empleando técnicas de desmezclado espectral lineal. También se ha generado un conjunto de regiones de test, formado por un número mayor de muestras, para evaluar la precisión de los mapas temáticos obtenidos.
- Se ha realizado un estudio de la separabilidad espectral de las distintas clases mediante la distancia de Jeffries-Matusita. Asimismo, se han analizado las firmas espectrales de las clases examinando las ventajas que presentan las procedentes del sensor hiperespectral frente al multiespectral.

- Se han estudiado las transformaciones PCA y MNF para aplicarlas sobre los datos hiperespectrales con el objetivo de conseguir una reducción dimensional.
- Se han estudiado técnicas de desmezclado espectral lineal para su aplicación sobre la imagen CASI. De esta manera, se han obtenido mapas de abundancia de cada clase. Además, sobre los mapas con mejores resultados se ha aplicado un filtro de mediana para eliminar el ruido sal y pimienta.
- Se ha extraído información de textura de las imágenes WV2 y CASI, la cual se ha añadido a las bandas espectrales de sus respectivas imágenes con el fin de incrementar la precisión de la clasificación.
- Se han estudiado los fundamentos básicos del algoritmo clasificador basado en máquinas de vectores de soporte.
- Se han cartografiado mapas temáticos de Maspalomas a partir de diferentes combinaciones de entrada utilizando los datos multiespectrales e hiperespectrales.
- Se ha evaluado la fiabilidad global de cada mapa temático generado y la de cada clase por separado mediante matrices de confusión.
- Se han aplicado técnicas de detección de cambios a los mapas con mejores resultados de cada sensor analizando las diferencias entre cada uno de ellos.
- Se han realizado operaciones de post-clasificación, como la aplicación de un filtro de mayoría, para suavizar los resultados con mejor precisión y, así, obtener los mapas definitivos de Maspalomas. Asimismo, se ha generado un inventario de la ocupación del suelo de la zona de estudio.
- Se ha identificado la metodología óptima para cada sensor y su robustez dependiendo de la calidad de las muestras de entrenamiento utilizadas, así como las ventajas e inconvenientes del uso de datos multiespectrales e hiperespectrales en este tipo de aplicación.

6.2. Conclusiones del análisis de los resultados

En este TFM se han analizado distintas metodologías para la generación de mapas de coberturas terrestres en Maspalomas. Para ello, se han empleado dos imágenes de alta resolución procedentes del sensor hiperespectral CASI y del satélite multiespectral WorldView-2. A raíz de los resultados obtenidos, se han extraído las siguientes conclusiones:

En primer lugar, tras examinar la separabilidad espectral entre parejas de clases, se ha evidenciado que con los datos hiperespectrales se consiguen valores óptimos independientemente tanto del conjunto de regiones de entrenamiento utilizado como de las clases a comparar. En el caso de los datos multiespectrales, los valores de separabilidad son menores en aquellas clases con terrenos de gran variabilidad en los conjuntos de ROIs de píxeles puros y en las combinaciones entre puros y mezclados. Con el conjunto de píxeles mezclados, cuyas muestras se han seleccionado en los bordes de los objetos, se obtiene peor separabilidad en un mayor número de clases con unos valores inferiores. Lo mismo ocurre para las ROIs de evaluación: separabilidad óptima en todas las categorías con la imagen CASI y separabilidad inferior en aquellas clases más complejas en la imagen WV2. Estos resultados se ratifican analizando las firmas espectrales de las clases, ya que con la imagen CASI se tienen firmas mucho más detalladas que con la imagen WV2, gracias a su resolución espectral superior.

Por otra parte, al analizar la precisión de la clasificación realizada usando el clasificador SVM, se ha comprobado que, con respecto a los sensores, CASI logra precisiones ligeramente superiores que WV2. No obstante, la mejoría proporcionada por los datos hiperespectrales no es muy significativa, al menos, para este tipo de aplicación donde la mayoría de clases no son demasiado similares espectralmente.

Con respecto a las ROIs de entrenamiento, las mejores precisiones se obtienen con las regiones que combinan píxeles puros y mezclados. Los peores resultados se consiguen empleando las regiones de píxeles mezclados, decrementando, en términos generales, un 15 % la precisión de cada mapa.

En cuanto a las combinaciones de datos de entrada, de las técnicas de reducción dimensional usadas para disminuir el efecto Hughes, la transformación MNF consigue un rendimiento mejor que la PCA. En el caso de la información de textura, su inclusión en los datos CASI logra buenas precisiones, mientras que con los datos WV2 no se obtienen mejorías. Con respecto a las técnicas de desmezclado espectral, el uso de los mapas de abundancia de clases no logra incrementar la precisión de la clasificación. Sin embargo, con la aplicación de un filtro de mediana a estos mapas de abundancia se alcanzan mejorías del 20 %.

Finalmente, tras evaluar cada mapa obtenido se observa que los resultados más eficientes se obtienen utilizando las bandas espectrales de la imagen CASI más la información de textura y

sólo las bandas de la imagen WV2, en ambos casos con el empleo de las ROIs que combinan píxeles puros y mezclados.

Además, analizando las matrices de confusión de las imágenes clasificadas, se ha puesto de manifiesto que las clases piscinas y lago, en el sensor hiperespectral, y mar y piscinas, en el multispectral, alcanzan unos resultados de clasificación superiores al resto de categorías. Esto se debe principalmente a la poca variabilidad que caracteriza a las superficies de estas clases. Por el contrario, las clases suelo construido y mar, y arena y árboles cuentan con mayores problemas a la hora de clasificarse en los sensores CASI y WV2, respectivamente. En el caso del suelo construido, el motivo principal que genera confusión es la gran complejidad de este tipo de terreno compuesto por una amplia variedad de materiales distintos. Por su parte, el mar tiene dificultades en aquellas zonas más oscuras que se confunden con sombras y se asignan de forma errónea a la clase otros. Los errores de la arena y los árboles se deben a su similitud con otras clases, la arena con el resto de suelos desnudo y los árboles con los arbustos.

En lo que concierne a la detección de cambios en los mapas mejor clasificados, la mayor parte de la superficie de estos mapas no ha sufrido cambios. No obstante, las variaciones más significativas entre éstos se producen con las categorías que cambian de resto de suelos desnudos a otras clases y viceversa. La mayoría de estos cambios se deben a fallos en la clasificación de la imagen WV2 con respecto a la imagen CASI y no a modificaciones del terreno de una fecha a otra.

Por último, una vez obtenidos los mapas definitivos de Maspalomas tras aplicar un filtro de mayoría a los mapas con mejores resultados de cada sensor, la realización del inventario del área clasificada ha permitido deducir la superficie de suelo que ocupa cada clase en la zona de estudio. De esta forma, se concluye que las categorías que ocupan mayor superficie son las pertenecientes al suelo desnudo (aproximadamente el 50 % del mapa). Las categorías con menor superficie ocupada en Maspalomas son las piscinas y el lago, abarcando un 1 % del territorio.

6.3. Líneas futuras

Dada la enorme cantidad de utilidades que aporta la teledetección, pueden surgir múltiples líneas futuras a raíz de este Trabajo de Fin de Máster. Después de examinar el trabajo realizado y los resultados conseguidos, algunos de los estudios que pueden elaborarse en un futuro son:

- Aplicar técnicas de análisis de imágenes basada en objetos (OBIA) para obtener nuevos mapas temáticos y comprobar su rendimiento con respecto a la clasificación a nivel de píxel realizada.
- Modificar los parámetros de la función kernel del algoritmo SVM para optimizar la clasificación.
- Aprovechar el detalle espectral de los datos hiperespectrales del sensor CASI para llevar a cabo una clasificación más exhaustiva de la vegetación consistente en distinguir entre las distintas especies de la flora de Maspalomas.
- Volver a clasificar imágenes de la misma zona de Maspalomas, pero de fechas anteriores y posteriores, con objeto de calcular el efecto de la presión antrópica sobre la vegetación, el estado de las dunas, las nuevas edificaciones construidas, la erosión producida por el mar, entre otras.

Bibliografía

- [1] Instituto Geográfico Nacional, «Teledetección,» [En línea]. Available: <http://www.ign.es/web/resources/docs/IGNCnig/OBS-Teledeteccion.pdf>. [Último acceso: 15 septiembre 2017].
- [2] Concurso.cnice.mec.es, «Sensores de Teledetección: los ojos de los satélites,» [En línea]. Available: <http://concurso.cnice.mec.es/cnice2006/material121/unidad3/sensores.htm>. [Último acceso: 15 septiembre 2017].
- [3] S. Zlatanova y J. Li, Geospatial information technology for emergency response, vol. 6, CRC Press, 2008.
- [4] E. Chuvieco, Fundamentos de teledetección espacial, Segunda ed., Madrid: Rialp S.A., 1995.
- [5] Alava Ingenieros, «¿Qué diferencia una imagen multispectral de una hiperespectral?,» [En línea]. Available: <http://www.grupoalava.com/repositorio/5347/pdf/7468/2/articulo-tecnicomulti-e-hiper.pdf>. [Último acceso: 15 septiembre 2017].
- [6] S. Quiñones, «Imágenes hiperespectrales: Análisis y aplicaciones,» [En línea]. Available: http://esri.cl/emailing/encuentro-usuarios-2013/pdf/Sebastian_Quinones.pdf. [Último acceso: 15 septiembre 2017].
- [7] J. Rodríguez Villamizar, «Sistemas multispectrales e hiperespectrales para la observación del territorio. Análisis y aplicación a la prospección de hidrocarburos.,» Madrid, 2015.
- [8] ESA – Eduspace, «Teledetección, a fondo. Firmas espectrales,» [En línea]. Available: http://www.esa.int/SPECIALS/Eduspace_ES/SEM6DYD3GXF_0.html. [Último acceso: 15 septiembre 2017].

- [9] P. Ghamisi, G. Cavallaro, D. Wu, J. A. Benediktsson y A. Plaza, «Integration of LiDAR and Hyperspectral Data for Land-cover Classification: A Case Study,» 2016.
- [10] B. Tso y P. Mather, Classification methods for remotely sensed data, CRC Press, 2016.
- [11] ESA – Eduspace, «¿Qué es la teledetección?,» [En línea]. Available: http://www.esa.int/SPECIALS/Eduspace_ES/SEMO1U3FEXF_0.html. [Último acceso: 20 Octubre 2017].
- [12] J. Vivancos, A. Llastarri, M. Grau y D. Vivancos, «Fundamentos de la Teledetección: Proceso de la Teledetección. La Tierra a vista de satélite,» 2006. [En línea]. Available: <http://concurso.cnice.mec.es/cnice2006/material121/>. [Último acceso: 20 Octubre 2017].
- [13] ESA – Eduspace, «Teledetección, a fondo. Introducción,» [En línea]. Available: http://www.esa.int/SPECIALS/Eduspace_ES/SEMZ3YD3GXF_0.html. [Último acceso: 20 Octubre 2017].
- [14] ESA – Eduspace, «Teledetección, a fondo. Interferencia atmosférica,» [En línea]. Available: http://www.esa.int/SPECIALS/Eduspace_ES/SEMPPYD3GXF_0.html. [Último acceso: 20 Octubre 2017].
- [15] Teledet, «Resolución,» [En línea]. Available: <http://www.teledet.com.uy/tutorial-imagenes-satelitales/satelites-resolucion-espacial.htm>. [Último acceso: 20 Octubre 2017].
- [16] F. Alonso, «Resolución de imágenes de satélite,» Universidad de Murcia, [En línea]. Available: <http://ocw.um.es/ciencias/herramientas-de-teledeteccion-aplicadas-a-la/material-de-clase-1/tema-5-plataformas-sensores-y-canales.pdf>. [Último acceso: 20 Octubre 2017].
- [17] ESA – Eduspace, «Historia de la observación terrestre,» [En línea]. Available: http://www.esa.int/SPECIALS/Eduspace_ES/SEMZQYD3GXF_0.html. [Último acceso: 20 Octubre 2017].

- [18] J. Kerekes, «Hyperspectral Sensors,» Chester F. Carlson Center for Imaging Science, [En línea]. Available: <http://www.grss-ieee.org/hyperspectral-sensors/>. [Último acceso: 21 octubre 2017].
- [19] J. M. Bioucas-Dias, A. Plaza, G. Camps-Valls, P. Scheunders, N. M. Nasrabadi y J. Chanussot, «Hyperspectral remote sensing data analysis and future challenges,» *IEEE Geoscience and remote sensing magazine*, vol. 1, nº 2, pp. 6-36, 2013.
- [20] I. Dowman, «Hyperspectral imaging: Beyond the niche,» Geospatial World, 2011. [En línea]. Available: <https://www.geospatialworld.net/article/hyperspectral-imaging-beyond-the-niche/>. [Último acceso: 21 octubre 2017].
- [21] Satellite Imaging Corporation, «WorldView-2 Satellite Sensor,» [En línea]. Available: <https://www.satimagingcorp.com/satellite-sensors/worldview-2/>. [Último acceso: 20 Octubre 2017].
- [22] DigitalGlobe, «The benefits of the eight spectral bands of WorldView-2,» 2010. [En línea]. Available: https://dg-cms-uploads-production.s3.amazonaws.com/uploads/document/file/35/DG-8SPECTRAL-WP_0.pdf. [Último acceso: 20 Octubre 2017].
- [23] Aeroterra, «DigitalGlobe,» [En línea]. Available: <http://aeroterra.com/p-DigitalGlobe.html>. [Último acceso: 20 Octubre 2017].
- [24] E. de Miguel, A. Fernández-Renau, E. Prado, M. Jiménez, Ó. Gutiérrez de la Cámara, C. Linés, J. A. Gómez, A. I. Martín y M. Félix, «The processing of CASI-1500I data at INTA PAF,» *EARSel eProceedings*, vol. 13, nº 1, pp. 30-37, 2014.
- [25] Itres, «CASI-1500 Visible Near Infrared Imager,» [En línea]. Available: <http://www.itres.com/casi-1500/>. [Último acceso: 9 Octubre 2017].
- [26] INTA, «Teledetección Aeroportada,» [En línea]. Available: http://www.inta.es/opencms/export/sites/default/INTA/es/servicios/Tecnologia_SG_COPLA-11/. [Último acceso: 16 Octubre 2017].
- [27] Itres, «Glossary,» [En línea]. Available: <http://www.itres.com/glossary/>. [Último acceso: 13 Octubre 2017].

- [28] J. G. Rejas, «Tratamiento digital previo de las imágenes,» 2008. [En línea]. Available:
http://api.eoi.es/api_v1_dev.php/fedora/asset/eoi:45518/componente45516.pdf.
[Último acceso: 22 Diciembre 2017].
- [29] R. A. Schowengerdt, *Remote Sensing Models and Methods for Image Processing*, Tercera ed., Elsevier, 2006.
- [30] ITT Visual Information Solutions, «Atmospheric Correction Module: QUAC and FLAASH User's Guide,» Agosto 2009. [En línea]. Available:
http://www.harrisgeospatial.com/portals/0/pdfs/envi/Flaash_Module.pdf. [Último acceso: 9 Noviembre 2017].
- [31] ReSe Applications, «ATCOR 4: Atmospheric and Topographic Correction for Airborne Scanner Data,» 2016. [En línea]. Available:
<http://www.rese.ch/products/atcor/atcor4/>. [Último acceso: 15 Noviembre 2017].
- [32] C. Gonzalo-Martin, M. Lillo, F. J. Merino y F. Zambrano Bigiarini, «Fusión iHS Ponderada Mediante Dimensión Fractal,» Enero 2008. [En línea]. Available:
https://www.researchgate.net/publication/44742069_Fusion_iHS_Ponderada_Mediante_Dimension_Fractal. [Último acceso: 22 Septiembre 2017].
- [33] E. Ibarrola Ulzurrun, C. Gonzalo Martin, J. G. P. A. Marcello Ruiz y D. Rodriguez Esparragon, «Fusion of High Resolution Multispectral Imagery in Vulnerable Coastal and Land Ecosystems,» *Sensors*, vol. 17, n° 2, p. 228, 2017.
- [34] M. J. Gómez, «Registro de imágenes de teledetección espacial,» Córdoba, 2014.
- [35] V. M. Arévalo Espejo, «Registro de imágenes mediante transformaciones lineales por trozos,» Málaga, 2008.
- [36] E. Coiras López, «Registro automático de imágenes de bandas espectrales alejadas,» Madrid, 1999.
- [37] O. A. Vélez Martínez, «Metodología para el registro multimodal de imágenes 3D utilizando información mutua,» Pereira, 2014.

- [38] Harris Geospatial Solutions, «Image Registration,» [En línea]. Available: <http://harrisgeospatial.com/docs/ImageRegistration.html>. [Último acceso: 12 Octubre 2017].
- [39] V. Roshni y K. Revathy, «Using mutual information and cross correlation as metrics for registration of images,» *Journal of Theoretical & Applied Information Technology*, vol. 4, n° 6, 2008.
- [40] J. A. Richards, Remote sensing digital image analysis, Springer-Verlag, 1999.
- [41] J. L. Chávez, Tratamiento digital de imágenes multiespectrales, Segunda ed., Lulu, 2010.
- [42] U. Maulik y D. Chakraborty, «Remote Sensing Image Classification: A survey of support-vector-machine-based advanced techniques,» *IEEE Geoscience and Remote Sensing Magazine*, vol. 5, n° 1, pp. 33-52, 2017.
- [43] P. Ghamisi, J. Plaza, Y. Chen, J. Li y A. Plaza, «Advanced Spectral Classifiers for Hyperspectral Images: A review,» *IEEE Geoscience and Remote Sensing Magazine*, vol. 5, n° 1, pp. 8-32, 2017.
- [44] E. J. Carmona Suárez, «Tutorial sobre Máquinas de Vectores Soporte (SVM),» 2014. [En línea]. Available: [http://www.ia.uned.es/~ejcarmona/publicaciones/\[2016-%20Carmona\]%20SVM.pdf](http://www.ia.uned.es/~ejcarmona/publicaciones/[2016-%20Carmona]%20SVM.pdf). [Último acceso: 27 Noviembre 2017].
- [45] Harris Geospatial Solutions, «Support Vector Machine Background,» [En línea]. Available: <http://www.harrisgeospatial.com/docs/backgroundsvm.html>. [Último acceso: 27 Noviembre 2017].
- [46] Harris Geospatial Solutions, «Calculate Confusion Matrices,» [En línea]. Available: <http://www.harrisgeospatial.com/docs/calculatingconfusionmatrices.html>. [Último acceso: 13 Noviembre 2017].
- [47] A. Argerich, M. A. Barrera, C. Chayle y M. Montivero, «Fundamentos de normalización y calidad de información geográfica, Módulo 3.,» Instituto Geográfico Nacional de la República Argentina, 2010. [En línea]. Available:

- <http://www.ign.gov.ar/descargas/CursoIso/MODULO3-EJEMPLO-APLIC.pdf>.
[Último acceso: 13 Noviembre 2017].
- [48] E. Ibarrola Ulzurrun, J. Marcello y C. Gonzalo Martin, «Assessment of Component Selection Strategies in Hyperspectral Imagery,» *Entropy*, vol. 19, n° 12, p. 666, 2017.
- [49] C. Rodarmel y J. Shan, «Principal Component Analysis for Hyperspectral Image Classification,» *Surveying and Land Information Science*, vol. 62, n° 2, pp. 115-123, 2002.
- [50] J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader y J. Chanussot, «Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-Based Approaches,» *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, n° 2, pp. 354-379, 2012.
- [51] Harris Geospatial Solutions, «Linear Spectral Unmixing,» [En línea]. Available: <http://www.harrisgeospatial.com/docs/LinearSpectralUnmixing.html>. [Último acceso: 7 Diciembre 2017].
- [52] N. La Serna Palomino, W. Contreras Flores y M. E. Ruiz Rivera, «Procesamiento Digital de textura: Técnicas utilizadas en aplicaciones actuales de CBIR,» *Revista de investigación de Sistemas e Informática*, vol. 7, n° 1, pp. 57-64, 2010.
- [53] Esri España, «ENVI,» [En línea]. Available: http://www.esri.es/es/productos/aplicaciones-especializadas/envi_66/. [Último acceso: 18 Septiembre 2017].
- [54] J. D. Moreno Gázquez, J. Marcello Ruiz y D. Rodríguez Esparragón, «Fusión de datos de alta resolución para la obtención de mapas de coberturas terrestres en Maspalomas,» Las Palmas de Gran Canaria, 2016.
- [55] A. I. Hernández Cordero, E. Pérez Chacón y L. Hernández Calvento, «Aplicación de tecnologías de la información geográfica al estudio de la vegetación en sistemas de dunas litorales. Resultados preliminares en el campo de dunas de Maspalomas (Gran Canaria, Islas Canarias),» Las Palmas de Gran Canaria, 2003.

- [56] Grupo de Astrometría y Fotometría, «Taller de Fotometría Diferencial,» 2015. [En línea]. Available: <http://gafoac.com/sites/default/files/cursos/Taller%20de%20Fotometria%20diferencial%20Unidad%203%2020150412.pdf>. [Último acceso: 12 Octubre 2017].
- [57] J. Jorge, «Glosario,» Universidad Politécnica de Cataluña, 2008. [En línea]. Available: <http://lacova.upc.es/~jorge/Bolivia/RS-Glosario.pdf>. [Último acceso: 20 Octubre 2017].
- [58] A. Ortiz Rodríguez, «Texturas y descriptores de regiones,» 2008.
- [59] F. Banterla, M. García y M. A. Vezanzones, «Texturas. Descripción y aplicaciones,» [En línea]. Available: <http://www.ehu.es/ccwintco/uploads/d/d7/Texturas.pdf>. [Último acceso: 8 Diciembre 2017].

Parte II

Pliego de condiciones

C1. Pliego de condiciones

A continuación, se va a proceder a indicar los requisitos hardware de los equipos y las herramientas software necesarias para la realización de las tareas implicadas en este Trabajo de Fin de Máster.

C1.1. Requisitos hardware

Para el presente trabajo, se ha utilizado una serie de herramientas hardware que se indican a continuación:

- Ordenador portátil MSI GL62M 7RD: Ordenador en el que se ha instalado el software ENVI (ENvironment for Visualizing Images), se ha realizado todo el procesamiento de las imágenes WV2 y CASI, y se ha redactado la memoria de este Trabajo de Fin de Máster.

Las principales características de este PC son:

- Procesador Intel Core i7-7700HQ a 2,80 GHz.
 - 8 GB de memoria RAM.
 - Capacidad de disco 1 TB.
- Impresora HP LaserJet 2430 DTN: Utilizada para la impresión del material necesario para el desarrollo del trabajo y de la presente memoria.

C1.2. Requisitos software

Las herramientas software que fueron necesarias son:

- Sistema operativo Windows 10 Pro: Sistema operativo bajo el cual se ha realizado todo el trabajo.
- Microsoft Office 2016: Conjunto de aplicaciones utilizadas para la elaboración de las tablas, gráficas y diagramas de bloques de la memoria de este TFM.
- Programa ENVI 5.1 y 5.4: Aplicación informática, utilizada para procesar y analizar imágenes, instalada en el ordenador MSI GL62M 7RD para realizar el procesamiento de las imágenes WV2 y CASI.

C1.3. Imágenes utilizadas

Las imágenes utilizadas para el desarrollo de este Trabajo Fin de Máster proceden de los siguientes sistemas:

- WorldView-2.
- Compact Airborne Spectrographic Imager.

Parte III

Presupuesto

P1. Presupuesto Detallado

En esta parte del Trabajo de Fin de Máster se expone el presupuesto del trabajo. Para tal labor, se han desglosado varias secciones donde se dividen los distintos costes asociados al desarrollo de esta tarea. De esta forma cada uno de los conceptos que se tienen en cuenta son:

1. Trabajo Tarifado por Tiempo Empleado.
2. Amortización del Inmovilizado Material.
3. Costes de Redacción del Trabajo de Fin de Máster.
4. Material Fungible.
5. Derechos de Visado del COIT.
6. Gastos de Tramitación y Envío.
7. Aplicación de Impuestos.

Para el cálculo de este presupuesto se ha utilizado la base de los “Baremos orientativos para el cálculo de honorarios” del Colegio Oficial de Ingenieros de Telecomunicación (COIT), actualizado a 1 de enero de 2008 (no existen baremos más actualizados ya que se ha prohibido su publicación para mantener la libre competencia).

P1.1. Trabajo Tarifado por Tiempo Empleado

En este Trabajo Fin de Máster se ha invertido un total de 300 horas en las tareas de formación, especificación, desarrollo y documentación necesarias para la elaboración del mismo. El importe de las horas de trabajo empleadas para la realización del TFM se calcula siguiendo las recomendaciones del COIT:

$$H = C_t * 74,88 * H_n + C_t * 96,72 * H_e \quad (P.1)$$

donde:

- H son los honorarios totales por el tiempo dedicado.
- C_t es un factor de corrección función del número de horas trabajadas.
- H_n son las horas normales trabajadas (dentro de la jornada laboral).
- H_e son las horas especiales.

Se estima que el tiempo empleado para la realización de este TFM son 300 horas, y que todas ellas se han realizado dentro del horario normal, por lo que el número de horas especiales es cero.

Según el COIT, el coeficiente C_t tiene un valor variable en función del número de horas empleadas de acuerdo con la siguiente tabla:

Tabla P1.1. Factor de corrección en función del número de horas invertidas.

Horas empleadas	Factor de corrección C_t
Hasta 36 horas	1,00
Desde 36 horas a 72 horas	0,90
Desde 72 horas a 108 horas	0,80
Desde 108 horas a 144 horas	0,70
Desde 144 horas a 180 horas	0,65
Desde 180 horas a 360 horas	0,60
Desde 360 horas a 540 horas	0,55

En nuestro caso el número de horas está comprendido entre 180 y 360 horas, por tanto, según la Tabla P1.1, el factor de corrección es de $C_t = 0,60$. Con ello, la ecuación del importe de horas de trabajo resulta de la siguiente forma:

$$H = 0,60 * 74,88 * 300 + 0,60 * 96,72 * 0 = 13.478,40\text{€}$$

Los honorarios totales por tiempo dedicado libres de impuestos ascienden a **trece mil cuatrocientos setenta y ocho euros con cuarenta céntimos (13.478,40 €)**.

P1.2. Amortización del Inmovilizado Material

En el inmovilizado material se consideran los recursos hardware, software y las imágenes empleadas para la realización de este TFM. Se estipula el coste de amortización para un período de 3 años utilizando un sistema de amortización lineal, en el que se supone que el inmovilizado material se deprecia de forma constante a lo largo de su vida útil. La cuota de amortización anual se calcula haciendo uso de (P.2):

$$Cuota\ anual = \frac{Valor\ de\ adquisición - Valor\ residual}{Años\ de\ vida\ útil} \quad (P.2)$$

donde el valor residual es el valor teórico que se supone que tendrá el elemento en cuestión después de su vida útil.

P1.2.1. Amortización del Material Hardware

Las herramientas hardware en la que se apoya el presente trabajo son:

- Ordenador portátil MSI GL62M 7RD CPU @ 2.80 GHz, a 8 GB de RAM y capacidad de disco 1 TB.
- Impresora HP LaserJet 2430 DTN.

Dado que la duración del TFM es de 4 meses y es inferior al período de 3 años estipulado para el coste de amortización, los costes serán los derivados de los primeros 4 meses.

Tabla P1.2. Precios y costes de amortización de las herramientas hardware.

Recursos hardware	Valor de adquisición	Valor residual	Coste de la amortización
Ordenador portátil MSI GL62M 7RD	839,20 €	155,00 €	76,02 €
Impresora HP LaserJet 2430 DTN	508,00 €	150,00 €	39,78 €

P1.2.2. Amortización del Material Software

Las herramientas software utilizadas en el presente trabajo son:

- Programa ENVI 5.1 y 5.4.
- Microsoft Office 2016.

En el cálculo de los costes de amortización del material software se considerarán, al igual que con el material hardware, los costes derivados de los primeros 4 meses.

Tabla P1.3. Precios y costes de amortización de las herramientas software.

Recursos software	Valor de adquisición	Valor residual	Coste de la amortización
ENVI 5.1 y 5.4	4.200,00 €	0,00 €	1.400,00 €
Microsoft Office 2016	0,00 €	0,00 €	0,00 €

P1.2.3. Amortización de las Imágenes

Para la elaboración de este TFM, se ha utilizado una imagen procedente del satélite WorldView-2 y otra del sensor aeroportado CASI.

Al igual que en los casos anteriores, para el cálculo de los costes de amortización de las imágenes utilizadas se considerarán los costes derivados de los primeros 4 meses.

Tabla P1.4. Precios y costes de amortización de las imágenes empleadas.

Imágenes	Valor de adquisición	Valor residual	Coste de la amortización
WorldView-2	2.200,00 €	0,00 €	733,33 €
CASI	2895,00 €	0,00 €	965,00 €

Por tanto, el coste total de los recursos materiales asciende a **tres mil doscientos catorce euros con trece céntimos (3.214,13 €)**.

P1.3. Costes de Redacción del TFM

El importe de la redacción del trabajo se calcula de acuerdo a la siguiente expresión:

$$R = 0,07 * P * C_n \quad (P. 3)$$

donde:

- P es el presupuesto del trabajo.
- C_n es el coeficiente en función del presupuesto.

En la siguiente tabla se muestra el presupuesto calculado hasta el momento:

Tabla P1.5. Presupuesto incluyendo trabajo tarifado y amortización del inmovilizado material.

Recursos	Coste
Recursos Hardware	115,8 €
Recursos Software	1.400,00 €
Imágenes empleadas	1698,33 €
Trabajo Tarifado por Tiempo Empleado	13.478,40 €
Total	16.692,53 €

El presupuesto calculado hasta el momento asciende a **16.692,53 €**. Como el coeficiente de ponderación para presupuestos menores de 30.050,00 € viene definido por el COIT con un valor de 1,00, el coste derivado de la redacción de este Trabajo Fin de Máster es de:

$$R = 0,07 * 16.692,53 * 1,00 = 1.168.48 €$$

Por tanto, el coste libre de impuestos derivado de la redacción del trabajo es de **mil ciento sesenta y ocho euros con cuarenta y ocho céntimos (1.168,48 €)**.

P1.4. Material Fungible

Además de los recursos hardware y software, en este trabajo se han empleado otros materiales, como son los folios y el tóner de la impresora entre otros, que se especifican como material fungible.

Tabla P1.6. Coste del material fungible.

Material fungible	Coste
Folios	10,00 €
Tóner de la impresora	30,00 €
Encuadernación	4,00 €
Tres CDs	6,00 €
Total	50,00 €

Los costes del material fungible ascienden a **cincuenta euros (50 €)**.

P1.5. Derechos del Visado del COIT

Los gastos de visado del COIT se tarifican mediante la siguiente expresión:

$$V = 0,006 * P * C_v \quad (P.3)$$

donde:

- P es el presupuesto del trabajo.
- C_v es el coeficiente reductor en función del presupuesto del trabajo.

El presupuesto calculado hasta el momento asciende a la cantidad de 17.911,01 €.

Como el coeficiente reductor para presupuestos menores de 30.050,00€, viene definido por el COIT con un valor de 1,00, el coste de los derechos de visado del trabajo asciende a la cantidad de:

$$V = 0,006 * 17.911,01 * 1,00 = 107,47 \text{ €}$$

Por tanto, el coste de los derechos de visado del trabajo asciende a **ciento siete euros con cuarenta y siete céntimos (107,47 €)**.

P1.6. Gastos de Tramitación y Envío

Los gastos de tramitación y envío están fijados en **6,01 €**.

P1.7. Aplicación de Impuestos

Para la actividad económica del presente trabajo, el valor del Impuesto General Indirecto Canario (I.G.I.C.) grava el presupuesto con un 7 %. El coste total del trabajo con el I.G.I.C. incluido se desglosa en la Tabla P1.7.

Tabla P1.7. Coste total del trabajo.

Recursos	Coste
Trabajo Tarifado por Tiempo Empleado	13.478,40 €
Amortización del inmovilizado material	3.214,13 €
Redacción del TFM	1.168,48 €
Material Fungible	50,00 €
Derechos de Visado del COIT	107,47 €
Gastos de Tramitación y Envío	6,01 €
Subtotal	18.024,49 €
Aplicación de Impuestos (7 % IGIC)	1.261,71 €
Total	19.286,20 €

El presupuesto total de este Trabajo Fin de Máster asciende a la cantidad de **diecinueve mil doscientos ochenta y seis euros con veinte céntimos (19.286,20 €)**.

Las Palmas de Gran Canaria a 1 de febrero de 2018.

Firma:

Juan Daniel Moreno Gázquez

Parte IV

Anexos

A1. Anexo 1

En este anexo se adjuntan los resultados de separabilidad espectral entre las parejas de clases de los cuatro conjuntos de regiones de entrenamiento y el de evaluación para los dos sensores.

Asphalt (roads) and Rest bare soils - 1.98865103	Asphalt (roads) and Rest bare soils - 1.89622234
Sand and Asphalt (roads) - 1.99950333	Built soil and Rest bare soils - 1.92299236
Sand and Rest bare soils - 1.99969941	Sand and Rest bare soils - 1.92924456
Built soil and Rest bare soils - 1.99975888	Sand and Asphalt (roads) - 1.93055568
Shrubs and Rest bare soils - 1.99982919	Shrubs and Rest bare soils - 1.96761986
Shrubs and Asphalt (roads) - 1.99986851	Trees and Shrubs - 1.97291953
Trees and Shrubs - 1.99993995	Trees and Grass - 1.97450894
Asphalt (roads) and Others - 1.99997456	Waves and Others - 1.98268906
Sand and Sea - 1.99998919	Sea and Waves - 1.99201807
Asphalt (roads) and Sea - 1.99998966	Shrubs and Sand - 1.99265178
Sea and Rest bare soils - 1.99998980	Others and Swimming pools - 1.99407353
Sea and Others - 1.99999330	Shrubs and Asphalt (roads) - 1.99441742
Sand and Built soil - 1.99999347	Sand and Sea - 1.99462328
Shrubs and Sand - 1.99999862	Waves and Swimming pools - 1.99508344
Asphalt (roads) and Built soil - 1.99999898	Waves and Built soil - 1.99525631
Sand and Others - 1.99999902	Shrubs and Built soil - 1.99672786
Waves and Built soil - 1.99999937	Asphalt (roads) and Built soil - 1.99706842
Sea and Built soil - 1.99999955	Sand and Built soil - 1.99727486
Shrubs and Built soil - 1.99999958	Others and Built soil - 1.99746551
Others and Rest bare soils - 1.99999980	Trees and Rest bare soils - 1.99748473
Others and Built soil - 1.99999988	Sea and Swimming pools - 1.99785425
Waves and Rest bare soils - 1.99999992	Others and Rest bare soils - 1.99801301
Sea and Waves - 1.99999996	Trees and Built soil - 1.99868585
Sea and Swimming pools - 1.99999997	Asphalt (roads) and Waves - 1.99870857
Sand and Waves - 1.99999999	Waves and Rest bare soils - 1.99902508
Trees and Grass - 2.00000000	Sand and Waves - 1.99924553
Shrubs and Others - 2.00000000	Sea and Rest bare soils - 1.99935989
Shrubs and Sea - 2.00000000	Trees and Others - 1.99953180
Asphalt (roads) and Waves - 2.00000000	Asphalt (roads) and Others - 1.99962554
Trees and Built soil - 2.00000000	Swimming pools and Built soil - 1.99977042
Shrubs and Waves - 2.00000000	Sea and Built soil - 1.99987358
Trees and Asphalt (roads) - 2.00000000	Trees and Waves - 1.99989446
Trees and Others - 2.00000000	Sea and Others - 1.99992123
Others and Swimming pools - 2.00000000	Sand and Swimming pools - 1.99993205
Trees and Rest bare soils - 2.00000000	Swimming pools and Rest bare soils - 1.99993592
Swimming pools and Built soil - 2.00000000	Shrubs and Others - 1.99997103
Trees and Sea - 2.00000000	Sand and Others - 1.99997449
Trees and Sand - 2.00000000	Trees and Asphalt (roads) - 1.99998231
Sand and Swimming pools - 2.00000000	Asphalt (roads) and Swimming pools - 1.99998390
Waves and Others - 2.00000000	Shrubs and Waves - 1.99998958
Swimming pools and Rest bare soils - 2.00000000	Trees and Swimming pools - 1.99999177
Shrubs and Grass - 2.00000000	Shrubs and Grass - 1.99999672
Asphalt (roads) and Swimming pools - 2.00000000	Trees and Sand - 1.99999787
Trees and Waves - 2.00000000	Lake and Waves - 1.99999836
Waves and Swimming pools - 2.00000000	Lake and Built soil - 1.99999842
Grass and Lake - 2.00000000	Asphalt (roads) and Sea - 1.99999987
Lake and Others - 2.00000000	Shrubs and Swimming pools - 1.99999995
Asphalt (roads) and Lake - 2.00000000	Trees and Sea - 2.00000000
Sand and Lake - 2.00000000	Grass and Built soil - 2.00000000
Shrubs and Lake - 2.00000000	Trees and Lake - 2.00000000
Trees and Lake - 2.00000000	Grass and Rest bare soils - 2.00000000
Trees and Swimming pools - 2.00000000	Lake and Swimming pools - 2.00000000
Shrubs and Swimming pools - 2.00000000	Grass and Others - 2.00000000
Grass and Others - 2.00000000	Sand and Grass - 2.00000000
Lake and Sea - 2.00000000	Grass and Waves - 2.00000000
Grass and Swimming pools - 2.00000000	Shrubs and Sea - 2.00000000
Lake and Swimming pools - 2.00000000	Asphalt (roads) and Grass - 2.00000000
Grass and Rest bare soils - 2.00000000	Lake and Sea - 2.00000000
Lake and Waves - 2.00000000	Sand and Lake - 2.00000000
Grass and Built soil - 2.00000000	Asphalt (roads) and Lake - 2.00000000
Grass and Waves - 2.00000000	Grass and Sea - 2.00000000
Grass and Sea - 2.00000000	Grass and Lake - 2.00000000
Lake and Built soil - 2.00000000	Grass and Swimming pools - 2.00000000
Asphalt (roads) and Grass - 2.00000000	Shrubs and Lake - 2.00000000
Sand and Grass - 2.00000000	Lake and Others - 2.00000000
Lake and Rest bare soils - 2.00000000	Lake and Rest bare soils - 2.00000000

a)

Asphalt (roads) and Rest bare soils - 1.97542135
 Sand and Asphalt (roads) - 1.99760329
 Sand and Rest bare soils - 1.99768691
 Trees and Shrubs - 1.99971460
 Built soil and Rest bare soils - 1.99973802
 Shrubs and Asphalt (roads) - 1.99975585
 Shrubs and Rest bare soils - 1.99987666
 Asphalt (roads) and Waves - 1.99995193
 Waves and Rest bare soils - 1.99995261
 Asphalt (roads) and Built soil - 1.99998325
 Asphalt (roads) and Sea - 1.99998888
 Sand and Waves - 1.99999086
 Waves and Built soil - 1.99999096
 Sand and Built soil - 1.99999243
 Sea and Waves - 1.99999285
 Sea and Rest bare soils - 1.99999426
 Sand and Sea - 1.99999783
 Shrubs and Sand - 1.99999878
 Asphalt (roads) and Others - 1.99999919
 Shrubs and Built soil - 1.99999944
 Sea and Built soil - 1.99999961
 Trees and Grass - 1.99999967
 Trees and Rest bare soils - 1.99999977
 Trees and Asphalt (roads) - 1.99999989
 Sand and Others - 1.99999993
 Waves and Swimming pools - 1.99999994
 Others and Rest bare soils - 1.99999996
 Sea and Others - 1.99999997
 Trees and Sea - 1.99999998
 Trees and Sand - 1.99999998
 Shrubs and Waves - 1.99999999
 Trees and Built soil - 1.99999999
 Swimming pools and Built soil - 2.00000000
 Others and Built soil - 2.00000000
 Sea and Swimming pools - 2.00000000
 Shrubs and Sea - 2.00000000
 Trees and Waves - 2.00000000
 Waves and Others - 2.00000000
 Shrubs and Grass - 2.00000000
 Trees and Others - 2.00000000
 Shrubs and Others - 2.00000000
 Others and Swimming pools - 2.00000000
 Swimming pools and Rest bare soils - 2.00000000
 Asphalt (roads) and Swimming pools - 2.00000000
 Grass and Built soil - 2.00000000
 Trees and Swimming pools - 2.00000000
 Sand and Swimming pools - 2.00000000
 Shrubs and Swimming pools - 2.00000000
 Sand and Grass - 2.00000000
 Trees and Lake - 2.00000000
 Grass and Others - 2.00000000
 Asphalt (roads) and Grass - 2.00000000
 Grass and Swimming pools - 2.00000000
 Lake and Swimming pools - 2.00000000
 Shrubs and Lake - 2.00000000
 Sand and Lake - 2.00000000
 Grass and Waves - 2.00000000
 Asphalt (roads) and Lake - 2.00000000
 Grass and Lake - 2.00000000
 Lake and Waves - 2.00000000
 Lake and Sea - 2.00000000
 Lake and Others - 2.00000000
 Lake and Built soil - 2.00000000
 Grass and Sea - 2.00000000
 Grass and Rest bare soils - 2.00000000
 Lake and Rest bare soils - 2.00000000

Built soil and Rest bare soils - 1.87117940
 Asphalt (roads) and Rest bare soils - 1.90667484
 Sand and Rest bare soils - 1.93530871
 Shrubs and Rest bare soils - 1.96583697
 Trees and Grass - 1.96903503
 Waves and Swimming pools - 1.97984980
 Sea and Rest bare soils - 1.98183322
 Waves and Built soil - 1.98265530
 Trees and Shrubs - 1.98967879
 Asphalt (roads) and Built soil - 1.99013104
 Sand and Asphalt (roads) - 1.99237176
 Swimming pools and Built soil - 1.99290817
 Sea and Swimming pools - 1.99294536
 Swimming pools and Rest bare soils - 1.99330542
 Asphalt (roads) and Waves - 1.99384336
 Others and Swimming pools - 1.99450746
 Waves and Rest bare soils - 1.99534014
 Shrubs and Built soil - 1.99537954
 Asphalt (roads) and Swimming pools - 1.99666010
 Sand and Built soil - 1.99713371
 Shrubs and Asphalt (roads) - 1.99725545
 Sea and Waves - 1.99807066
 Others and Rest bare soils - 1.99838048
 Shrubs and Sand - 1.99943841
 Others and Built soil - 1.99945101
 Asphalt (roads) and Others - 1.99954099
 Waves and Others - 1.99970401
 Trees and Built soil - 1.99979667
 Sea and Built soil - 1.99980259
 Sand and Swimming pools - 1.99992795
 Lake and Waves - 1.99994244
 Shrubs and Swimming pools - 1.99994682
 Sand and Waves - 1.99995394
 Grass and Built soil - 1.99996367
 Trees and Rest bare soils - 1.99997086
 Lake and Swimming pools - 1.99998101
 Shrubs and Waves - 1.99998146
 Shrubs and Grass - 1.99998229
 Lake and Built soil - 1.99998857
 Sea and Others - 1.99999434
 Trees and Asphalt (roads) - 1.99999791
 Shrubs and Others - 1.99999830
 Grass and Rest bare soils - 1.99999879
 Trees and Swimming pools - 1.99999924
 Trees and Sand - 1.99999951
 Sand and Others - 1.99999953
 Trees and Waves - 1.99999977
 Asphalt (roads) and Lake - 1.99999980
 Lake and Rest bare soils - 1.99999986
 Sand and Sea - 1.99999988
 Grass and Swimming pools - 1.99999999
 Sand and Grass - 1.99999999
 Trees and Others - 2.00000000
 Lake and Others - 2.00000000
 Asphalt (roads) and Sea - 2.00000000
 Trees and Sea - 2.00000000
 Grass and Waves - 2.00000000
 Trees and Lake - 2.00000000
 Sand and Lake - 2.00000000
 Asphalt (roads) and Grass - 2.00000000
 Grass and Others - 2.00000000
 Shrubs and Sea - 2.00000000
 Grass and Lake - 2.00000000
 Shrubs and Lake - 2.00000000
 Grass and Sea - 2.00000000
 Lake and Sea - 2.00000000

b)

Asphalt (roads) and Rest bare soils - 1.99938939
 Trees and Shrubs - 1.99988355
 Sand and Rest bare soils - 1.99991227
 Built soil and Rest bare soils - 1.99997891
 Shrubs and Rest bare soils - 1.9999358
 Shrubs and Asphalt (roads) - 1.9999650
 Sand and Asphalt (roads) - 1.9999678
 Trees and Grass - 1.9999744
 Sea and Others - 1.9999809
 Asphalt (roads) and Others - 1.9999827
 Sand and Built soil - 1.9999945
 Sand and Others - 1.9999989
 Sand and Sea - 1.9999990
 Asphalt (roads) and Built soil - 1.9999993
 Shrubs and Built soil - 1.9999998
 Asphalt (roads) and Sea - 1.9999998
 Shrubs and Others - 1.9999999
 Others and Built soil - 2.0000000
 Trees and Others - 2.0000000
 Shrubs and Grass - 2.0000000
 Trees and Built soil - 2.0000000
 Others and Rest bare soils - 2.0000000
 Trees and Asphalt (roads) - 2.0000000
 Sea and Rest bare soils - 2.0000000
 Sea and Built soil - 2.0000000
 Shrubs and Sand - 2.0000000
 Sand and Waves - 2.0000000
 Sea and Swimming pools - 2.0000000
 Trees and Sand - 2.0000000
 Trees and Sea - 2.0000000
 Waves and Rest bare soils - 2.0000000
 Asphalt (roads) and Waves - 2.0000000
 Grass and Built soil - 2.0000000
 Trees and Rest bare soils - 2.0000000
 Waves and Built soil - 2.0000000
 Sea and Waves - 2.0000000
 Others and Swimming pools - 2.0000000
 Swimming pools and Built soil - 2.0000000
 Shrubs and Sea - 2.0000000
 Sand and Swimming pools - 2.0000000
 Swimming pools and Rest bare soils - 2.0000000
 Asphalt (roads) and Swimming pools - 2.0000000
 Shrubs and Waves - 2.0000000
 Grass and Rest bare soils - 2.0000000
 Sand and Lake - 2.0000000
 Grass and Others - 2.0000000
 Lake and Others - 2.0000000
 Grass and Swimming pools - 2.0000000
 Waves and Others - 2.0000000
 Lake and Waves - 2.0000000
 Grass and Waves - 2.0000000
 Trees and Lake - 2.0000000
 Shrubs and Swimming pools - 2.0000000
 Asphalt (roads) and Lake - 2.0000000
 Shrubs and Lake - 2.0000000
 Lake and Swimming pools - 2.0000000
 Grass and Lake - 2.0000000
 Waves and Swimming pools - 2.0000000
 Asphalt (roads) and Grass - 2.0000000
 Trees and Waves - 2.0000000
 Sand and Grass - 2.0000000
 Trees and Swimming pools - 2.0000000
 Lake and Sea - 2.0000000
 Lake and Built soil - 2.0000000
 Grass and Sea - 2.0000000
 Lake and Rest bare soils - 2.0000000

Built soil and Rest bare soils - 1.88488534
 Sand and Rest bare soils - 1.89458551
 Trees and Shrubs - 1.90506614
 Trees and Grass - 1.93692294
 Sand and Asphalt (roads) - 1.96321146
 Asphalt (roads) and Rest bare soils - 1.96434952
 Shrubs and Rest bare soils - 1.98157545
 Sand and Built soil - 1.99531358
 Trees and Built soil - 1.99677803
 Shrubs and Built soil - 1.99706226
 Shrubs and Asphalt (roads) - 1.99723626
 Sea and Swimming pools - 1.99822462
 Asphalt (roads) and Built soil - 1.99839567
 Sand and Sea - 1.99881961
 Others and Rest bare soils - 1.99885323
 Trees and Rest bare soils - 1.99903161
 Others and Swimming pools - 1.99922939
 Shrubs and Sand - 1.99933473
 Waves and Built soil - 1.99935654
 Trees and Others - 1.99939611
 Trees and Asphalt (roads) - 1.99947634
 Trees and Sand - 1.99970995
 Waves and Swimming pools - 1.99975718
 Others and Built soil - 1.99983695
 Asphalt (roads) and Others - 1.99983733
 Asphalt (roads) and Sea - 1.99985997
 Swimming pools and Rest bare soils - 1.99989148
 Asphalt (roads) and Swimming pools - 1.99995842
 Swimming pools and Built soil - 1.99996532
 Sand and Swimming pools - 1.99997465
 Sand and Others - 1.99998101
 Sea and Rest bare soils - 1.99998558
 Shrubs and Others - 1.99998611
 Shrubs and Grass - 1.99999145
 Asphalt (roads) and Waves - 1.99999235
 Sea and Others - 1.99999609
 Grass and Built soil - 1.99999743
 Waves and Rest bare soils - 1.99999785
 Trees and Swimming pools - 1.99999811
 Sand and Waves - 1.99999855
 Sea and Built soil - 1.99999923
 Trees and Waves - 1.99999961
 Trees and Sea - 1.99999985
 Lake and Built soil - 1.99999985
 Lake and Waves - 1.99999994
 Trees and Lake - 1.99999996
 Waves and Others - 1.99999999
 Shrubs and Waves - 1.99999999
 Grass and Rest bare soils - 1.99999999
 Shrubs and Swimming pools - 1.99999999
 Sea and Waves - 2.00000000
 Lake and Swimming pools - 2.00000000
 Grass and Others - 2.00000000
 Sand and Grass - 2.00000000
 Asphalt (roads) and Grass - 2.00000000
 Lake and Rest bare soils - 2.00000000
 Grass and Waves - 2.00000000
 Grass and Swimming pools - 2.00000000
 Lake and Sea - 2.00000000
 Grass and Lake - 2.00000000
 Shrubs and Lake - 2.00000000
 Lake and Others - 2.00000000
 Asphalt (roads) and Lake - 2.00000000
 Sand and Lake - 2.00000000
 Shrubs and Sea - 2.00000000
 Grass and Sea - 2.00000000

c)

Sand and Rest bare soils - 1.99854999
 Asphalt (roads) and Rest bare soils - 1.99939698
 Shrubs and Rest bare soils - 1.99944557
 Trees and Grass - 1.99955200
 Shrubs and Sand - 1.99957000
 Trees and Shrubs - 1.99974548
 Sand and Asphalt (roads) - 1.99975647
 Asphalt (roads) and Others - 1.99979389
 Shrubs and Asphalt (roads) - 1.99989235
 Trees and Rest bare soils - 1.99991624
 Trees and Others - 1.99993364
 Built soil and Rest bare soils - 1.99994757
 Asphalt (roads) and Sea - 1.99994939
 Sea and Waves - 1.99996091
 Trees and Sand - 1.99997097
 Grass and Rest bare soils - 1.99997156
 Shrubs and Others - 1.99997194
 Trees and Asphalt (roads) - 1.99998478
 Trees and Built soil - 1.99998632
 Sea and Others - 1.99998690
 Others and Built soil - 1.99998836
 Others and Rest bare soils - 1.99998839
 Shrubs and Grass - 1.99998985
 Sand and Built soil - 1.99999014
 Sand and Sea - 1.99999064
 Asphalt (roads) and Built soil - 1.99999353
 Sand and Others - 1.99999711
 Trees and Sea - 1.99999775
 Shrubs and Built soil - 1.99999789
 Grass and Built soil - 1.99999847
 Lake and Sea - 1.99999874
 Swimming pools and Built soil - 1.99999885
 Sand and Grass - 1.99999891
 Sea and Built soil - 1.99999920
 Sea and Rest bare soils - 1.99999933
 Waves and Built soil - 1.99999948
 Shrubs and Sea - 1.99999956
 Asphalt (roads) and Waves - 1.99999965
 Grass and Others - 1.99999978
 Waves and Swimming pools - 1.99999990
 Waves and Rest bare soils - 1.99999993
 Sea and Swimming pools - 1.99999994
 Waves and Others - 1.99999996
 Others and Swimming pools - 1.99999997
 Sand and Waves - 1.99999997
 Asphalt (roads) and Grass - 1.99999998
 Sand and Lake - 1.99999998
 Asphalt (roads) and Swimming pools - 1.99999999
 Trees and Waves - 1.99999999
 Trees and Lake - 1.99999999
 Trees and Swimming pools - 1.99999999
 Swimming pools and Rest bare soils - 1.99999999
 Sand and Swimming pools - 2.00000000
 Lake and Waves - 2.00000000
 Asphalt (roads) and Lake - 2.00000000
 Shrubs and Lake - 2.00000000
 Shrubs and Waves - 2.00000000
 Lake and Others - 2.00000000
 Shrubs and Swimming pools - 2.00000000
 Lake and Built soil - 2.00000000
 Lake and Rest bare soils - 2.00000000
 Lake and Swimming pools - 2.00000000
 Grass and Sea - 2.00000000
 Grass and Waves - 2.00000000
 Grass and Swimming pools - 2.00000000
 Grass and Lake - 2.00000000

Trees and Grass - 1.51319261
 Sand and Rest bare soils - 1.52015859
 Trees and Shrubs - 1.62567573
 Shrubs and Sand - 1.66989185
 Shrubs and Rest bare soils - 1.78672518
 Shrubs and Asphalt (roads) - 1.79579297
 Built soil and Rest bare soils - 1.79918012
 Trees and Rest bare soils - 1.81569266
 Sand and Asphalt (roads) - 1.82446959
 Waves and Swimming pools - 1.85322981
 Asphalt (roads) and Rest bare soils - 1.86663426
 Trees and Asphalt (roads) - 1.87918301
 Swimming pools and Built soil - 1.89386206
 Trees and Built soil - 1.91953932
 Trees and Sand - 1.92255806
 Asphalt (roads) and Others - 1.93214337
 Sea and Waves - 1.94207909
 Sand and Others - 1.96225430
 Shrubs and Built soil - 1.96506751
 Shrubs and Others - 1.96992703
 Lake and Others - 1.97215039
 Sand and Built soil - 1.97360620
 Shrubs and Grass - 1.97390537
 Trees and Others - 1.97495350
 Asphalt (roads) and Sea - 1.97689266
 Trees and Swimming pools - 1.97783287
 Lake and Waves - 1.97840508
 Asphalt (roads) and Swimming pools - 1.97913539
 Others and Built soil - 1.98103729
 Swimming pools and Rest bare soils - 1.98136785
 Waves and Others - 1.98210260
 Others and Swimming pools - 1.98282962
 Others and Rest bare soils - 1.98325393
 Asphalt (roads) and Built soil - 1.98682449
 Asphalt (roads) and Waves - 1.98700216
 Trees and Lake - 1.98787206
 Trees and Waves - 1.98880067
 Sand and Lake - 1.99008641
 Shrubs and Swimming pools - 1.99125385
 Waves and Built soil - 1.99177469
 Asphalt (roads) and Lake - 1.99225102
 Lake and Sea - 1.99289197
 Sand and Swimming pools - 1.99292192
 Sand and Waves - 1.99324619
 Grass and Built soil - 1.99384019
 Lake and Swimming pools - 1.99532676
 Grass and Rest bare soils - 1.99567149
 Shrubs and Lake - 1.99662716
 Sea and Others - 1.99718914
 Sea and Swimming pools - 1.99724418
 Waves and Rest bare soils - 1.99729526
 Sand and Grass - 1.99881422
 Sand and Sea - 1.99883168
 Trees and Sea - 1.99888809
 Asphalt (roads) and Grass - 1.99892550
 Lake and Built soil - 1.99900547
 Shrubs and Waves - 1.99951145
 Lake and Rest bare soils - 1.99978984
 Grass and Swimming pools - 1.99987493
 Sea and Built soil - 1.99987734
 Sea and Rest bare soils - 1.99994384
 Grass and Others - 1.99996567
 Grass and Lake - 1.99998760
 Grass and Waves - 1.99999330
 Shrubs and Sea - 1.99999996
 Grass and Sea - 1.99999997

d)

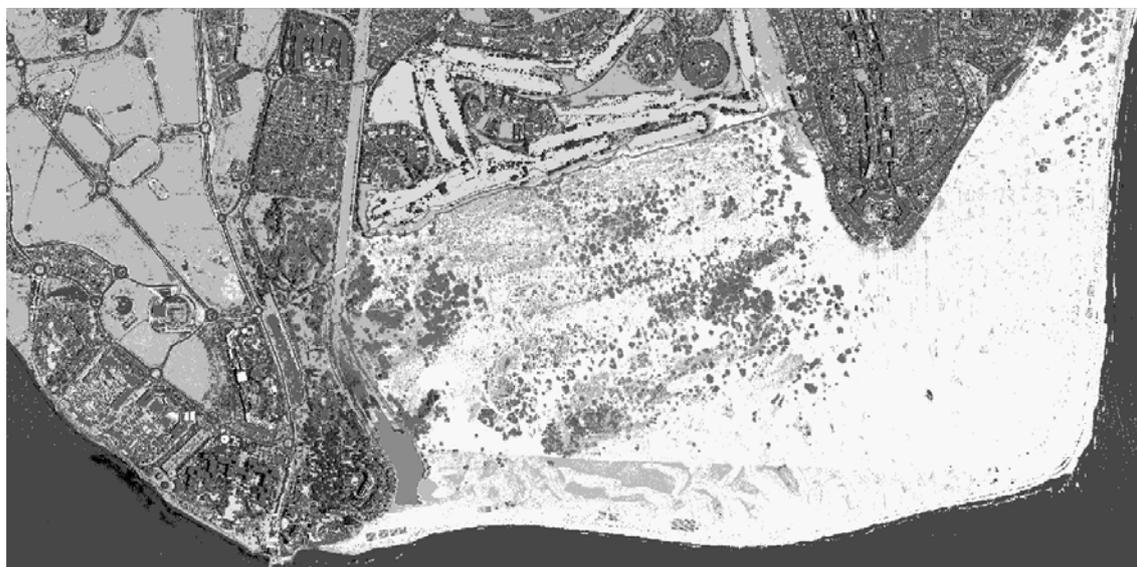
Asphalt (roads) and Rest bare soils - 1.95014273	Asphalt (roads) and Rest bare soils - 1.70069641
Shrubs and Asphalt (roads) - 1.99293608	Sand and Rest bare soils - 1.80796783
Sand and Rest bare soils - 1.99466630	Trees and Shrubs - 1.82982255
Shrubs and Rest bare soils - 1.99626977	Shrubs and Rest bare soils - 1.83968437
Trees and Shrubs - 1.99663041	Built soil and Rest bare soils - 1.84544977
Sand and Asphalt (roads) - 1.99782401	Sand and Asphalt (roads) - 1.91788048
Sea and Others - 1.99952467	Shrubs and Asphalt (roads) - 1.94334802
Asphalt (roads) and Sea - 1.99973023	Trees and Grass - 1.94836145
Asphalt (roads) and Others - 1.99976231	Others and Swimming pools - 1.98143005
Built soil and Rest bare soils - 1.99985901	Waves and Built soil - 1.98292576
Sea and Waves - 1.99988791	Trees and Rest bare soils - 1.98425632
Trees and Grass - 1.99990164	Asphalt (roads) and Waves - 1.98765712
Others and Rest bare soils - 1.99993962	Shrubs and Sand - 1.98825737
Sea and Rest bare soils - 1.99994564	Shrubs and Built soil - 1.99032517
Sand and Sea - 1.99994969	Asphalt (roads) and Others - 1.99103557
Waves and Built soil - 1.99995007	Trees and Asphalt (roads) - 1.99248358
Sand and Others - 1.99995306	Waves and Swimming pools - 1.99250803
Waves and Rest bare soils - 1.99996081	Trees and Built soil - 1.99294673
Sand and Waves - 1.99996662	Others and Rest bare soils - 1.99398859
Shrubs and Sand - 1.99997944	Asphalt (roads) and Built soil - 1.99412161
Sand and Built soil - 1.99998274	Sand and Built soil - 1.99431426
Trees and Others - 1.99998801	Sand and Sea - 1.99447798
Shrubs and Others - 1.99998966	Waves and Others - 1.99453779
Asphalt (roads) and Waves - 1.99999222	Waves and Rest bare soils - 1.99537976
Waves and Others - 1.99999433	Sea and Rest bare soils - 1.99589742
Trees and Sea - 1.99999578	Swimming pools and Built soil - 1.99641649
Asphalt (roads) and Built soil - 1.99999819	Asphalt (roads) and Swimming pools - 1.99698571
Shrubs and Built soil - 1.99999849	Shrubs and Others - 1.99724288
Others and Built soil - 1.99999850	Sea and Swimming pools - 1.99766043
Shrubs and Grass - 1.99999862	Trees and Others - 1.99768763
Shrubs and Sea - 1.99999887	Swimming pools and Rest bare soils - 1.99798781
Trees and Rest bare soils - 1.99999913	Sea and Others - 1.99844321
Shrubs and Waves - 1.99999920	Sea and Waves - 1.99852911
Trees and Asphalt (roads) - 1.99999925	Asphalt (roads) and Sea - 1.99858413
Sea and Built soil - 1.99999956	Trees and Waves - 1.99892602
Trees and Sand - 1.99999973	Shrubs and Waves - 1.99895024
Sea and Swimming pools - 1.99999986	Trees and Sand - 1.99905629
Trees and Built soil - 1.99999992	Sand and Waves - 1.99909208
Others and Swimming pools - 1.99999994	Others and Built soil - 1.99910345
Swimming pools and Built soil - 1.99999994	Trees and Swimming pools - 1.99937634
Trees and Waves - 1.99999998	Sand and Others - 1.99958817
Waves and Swimming pools - 1.99999998	Lake and Waves - 1.99968248
Swimming pools and Rest bare soils - 2.00000000	Sand and Swimming pools - 1.99981684
Lake and Sea - 2.00000000	Shrubs and Swimming pools - 1.99988417
Sand and Swimming pools - 2.00000000	Trees and Sea - 1.99995816
Asphalt (roads) and Swimming pools - 2.00000000	Sea and Built soil - 1.99996899
Trees and Swimming pools - 2.00000000	Lake and Swimming pools - 1.99997039
Shrubs and Swimming pools - 2.00000000	Lake and Built soil - 1.99999771
Grass and Built soil - 2.00000000	Grass and Built soil - 1.99999798
Lake and Waves - 2.00000000	Trees and Lake - 1.99999872
Grass and Rest bare soils - 2.00000000	Shrubs and Grass - 1.99999885
Grass and Others - 2.00000000	Lake and Others - 1.99999986
Trees and Lake - 2.00000000	Lake and Rest bare soils - 1.99999992
Lake and Built soil - 2.00000000	Grass and Others - 1.99999997
Grass and Waves - 2.00000000	Grass and Rest bare soils - 1.99999999
Lake and Others - 2.00000000	Grass and Waves - 2.00000000
Lake and Swimming pools - 2.00000000	Asphalt (roads) and Lake - 2.00000000
Sand and Grass - 2.00000000	Sand and Lake - 2.00000000
Asphalt (roads) and Grass - 2.00000000	Grass and Swimming pools - 2.00000000
Grass and Lake - 2.00000000	Shrubs and Sea - 2.00000000
Grass and Sea - 2.00000000	Asphalt (roads) and Grass - 2.00000000
Asphalt (roads) and Lake - 2.00000000	Lake and Sea - 2.00000000
Grass and Swimming pools - 2.00000000	Sand and Grass - 2.00000000
Shrubs and Lake - 2.00000000	Shrubs and Lake - 2.00000000
Sand and Lake - 2.00000000	Grass and Lake - 2.00000000
Lake and Rest bare soils - 2.00000000	Grass and Sea - 2.00000000

e)

Figura A1.1. Separabilidad entre clases por parejas de menor a mayor para las imágenes CASI (izquierda) y WV2 (derecha): a) P + M 1, b) P + M 2, c) Puros, d) Mezclados, e) Evaluación.

A2. Anexo 2

En este anexo se adjuntan los mapas temáticos de las clasificaciones realizadas no incluidas en la memoria.



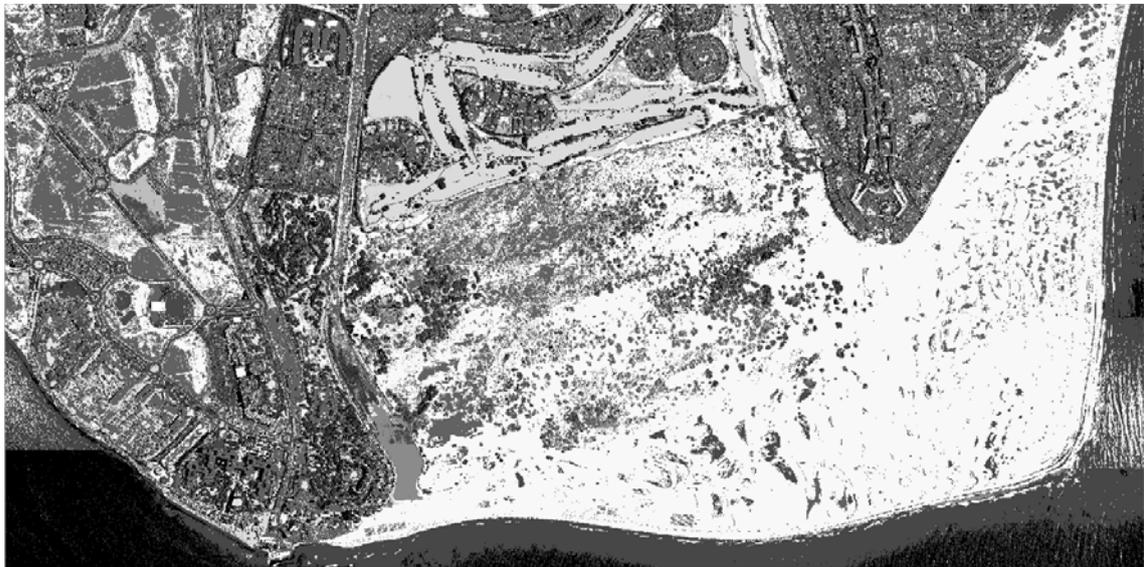
a)



b)



c)



d)

Figura A2.1. Mapas temáticos obtenidos a partir de las bandas espectrales de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.



a)



b)



c)



d)

Figura A2.2. Mapas temáticos obtenidos a partir de las 10 primeras componentes PCA de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.



a)



b)



c)

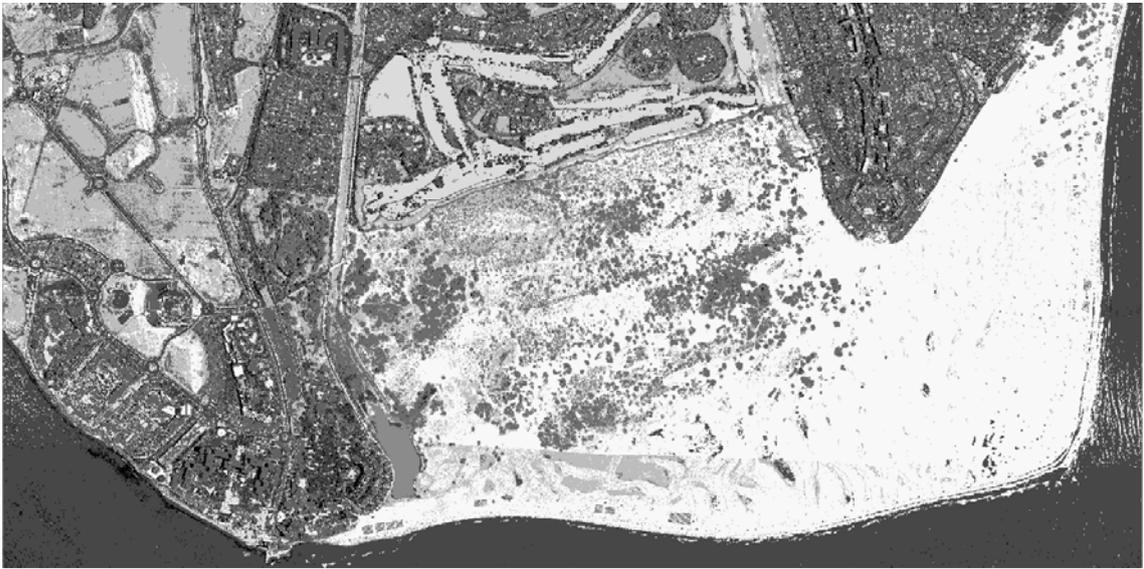


d)

Figura A2.3. Mapas temáticos obtenidos a partir de las 25 primeras componentes MNF de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.



a)



b)



c)

Figura A2.4. Mapas temáticos obtenidos a partir de las bandas espectrales de la imagen CASI más la información de textura usando los conjuntos de ROIs: a) P + M I. b) Puros. c) Mezclados.



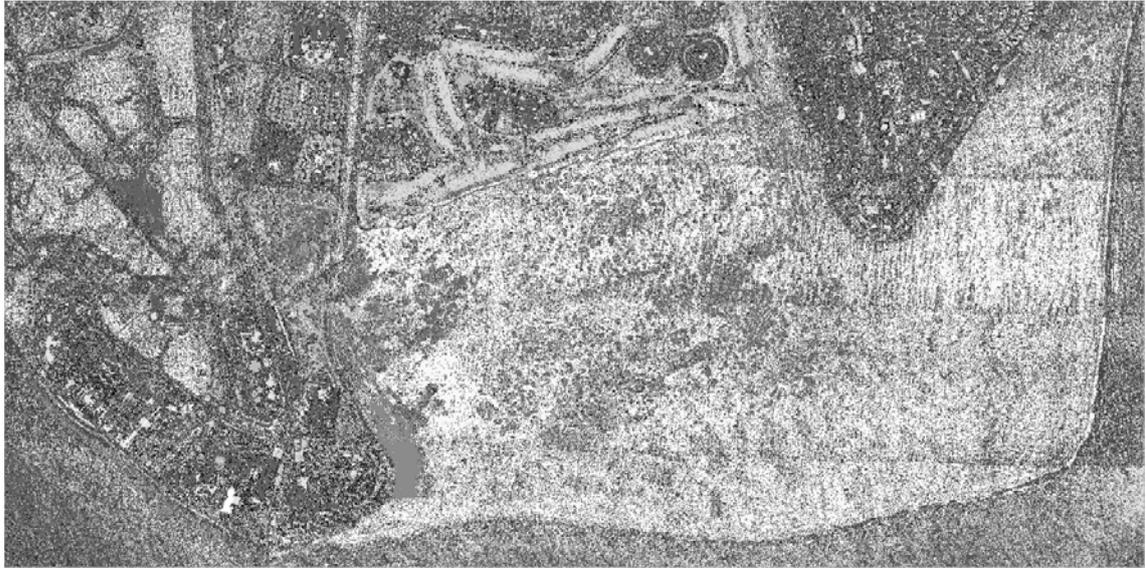
a)



b)



c)



d)

Figura A2.5. Mapas temáticos obtenidos a partir de los mapas de abundancia generados de las bandas de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.



a)



b)



c)



d)

Figura A2.6. Mapas temáticos obtenidos a partir de los mapas de abundancia generados de las 10 primeras componentes PCA de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.



a)



b)



c)



d)

Figura A2.7. Mapas temáticos obtenidos a partir de los mapas de abundancia generados de las 25 primeras componentes MNF de la imagen CASI usando los conjuntos de ROIs: a) $P + M 1$. b) $P + M 2$. c) Puros. d) Mezclados.



a)

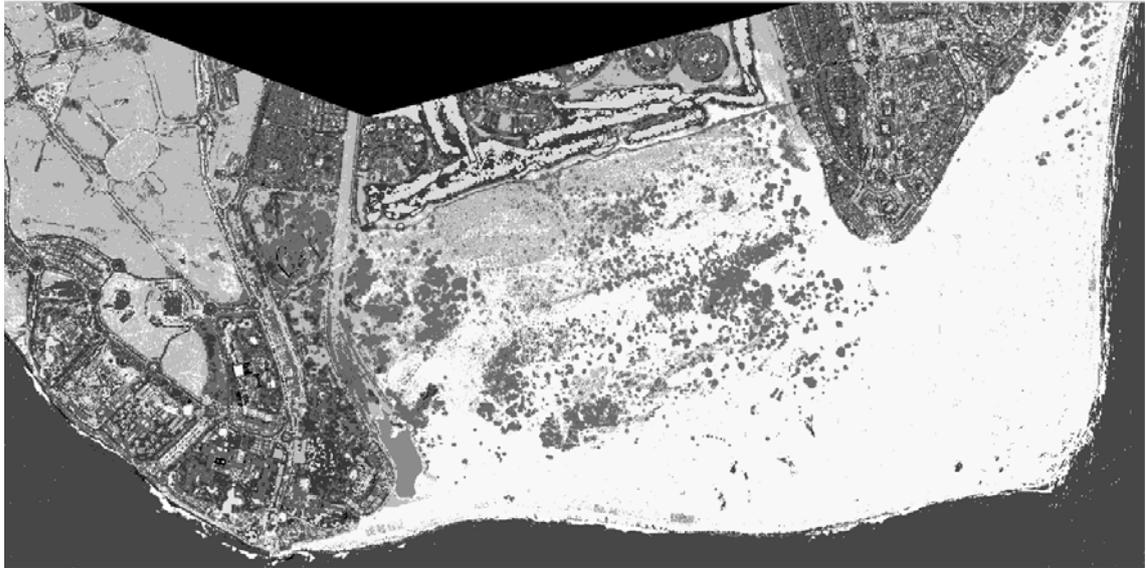


b)

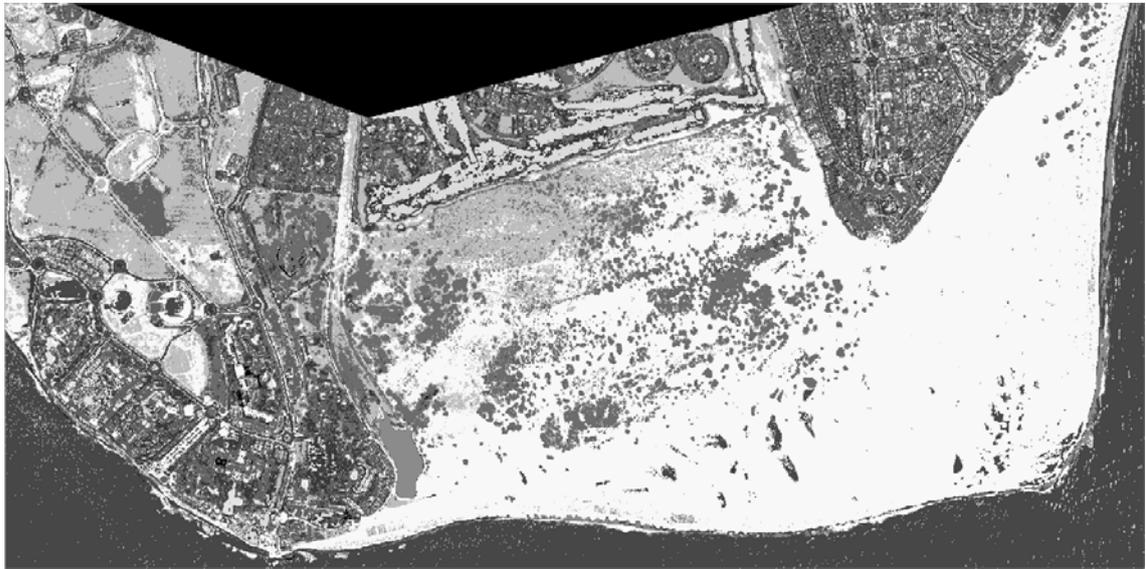


c)

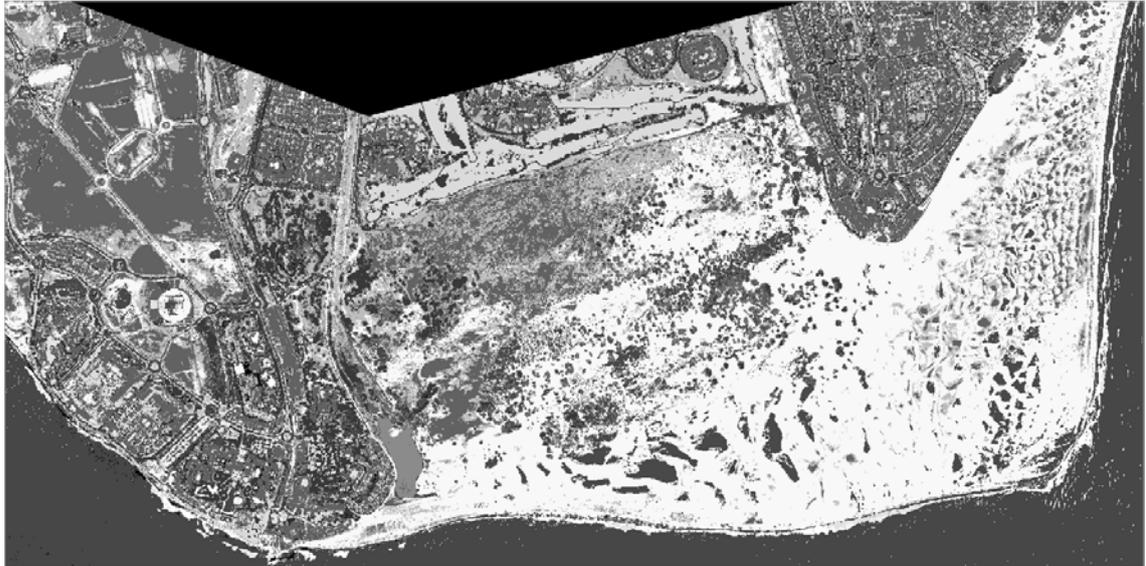
Figura A2.8. Mapas temáticos obtenidos usando el conjunto de ROIs P + M 1 a partir de los mapas de abundancia generados tras la aplicación de un filtro de mediana de las siguientes combinaciones de la imagen CASI: a) Bandas espectrales. b) 10 primeras componentes PCA. c) 25 primeras componentes MNF.



a)

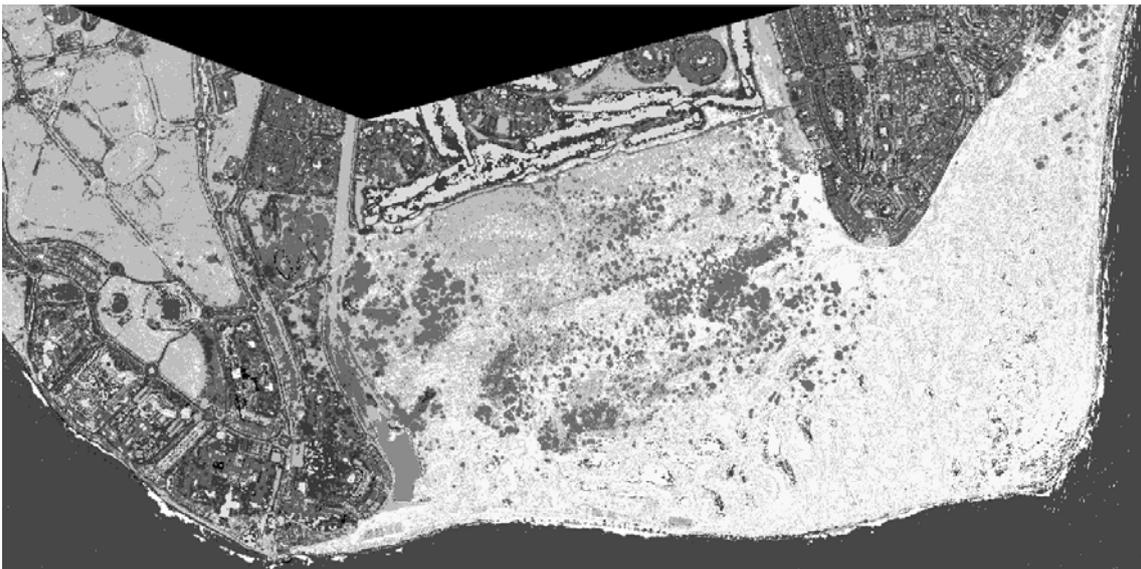


b)

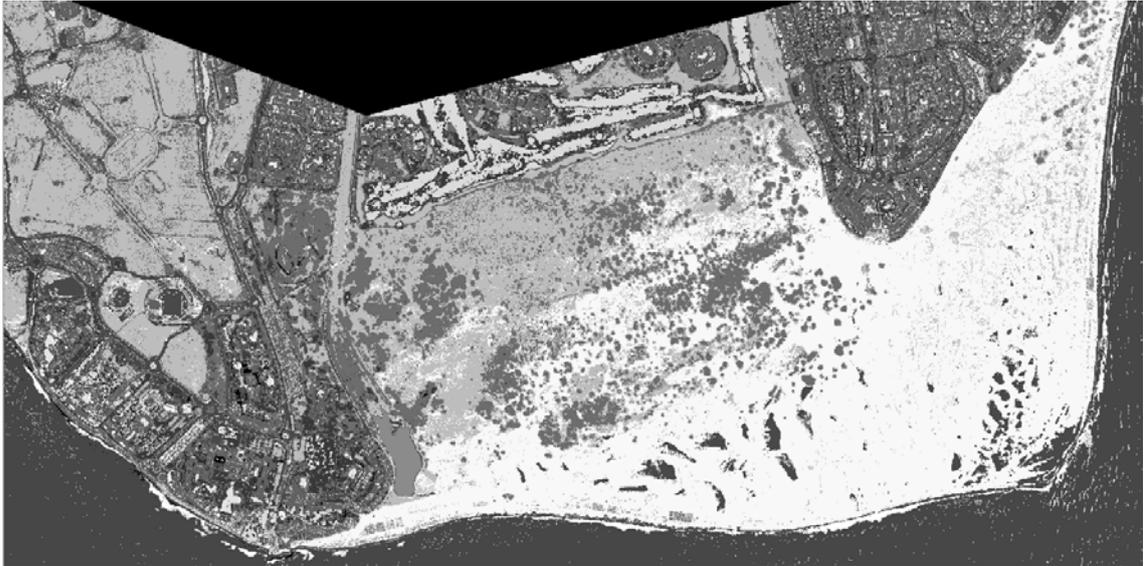


c)

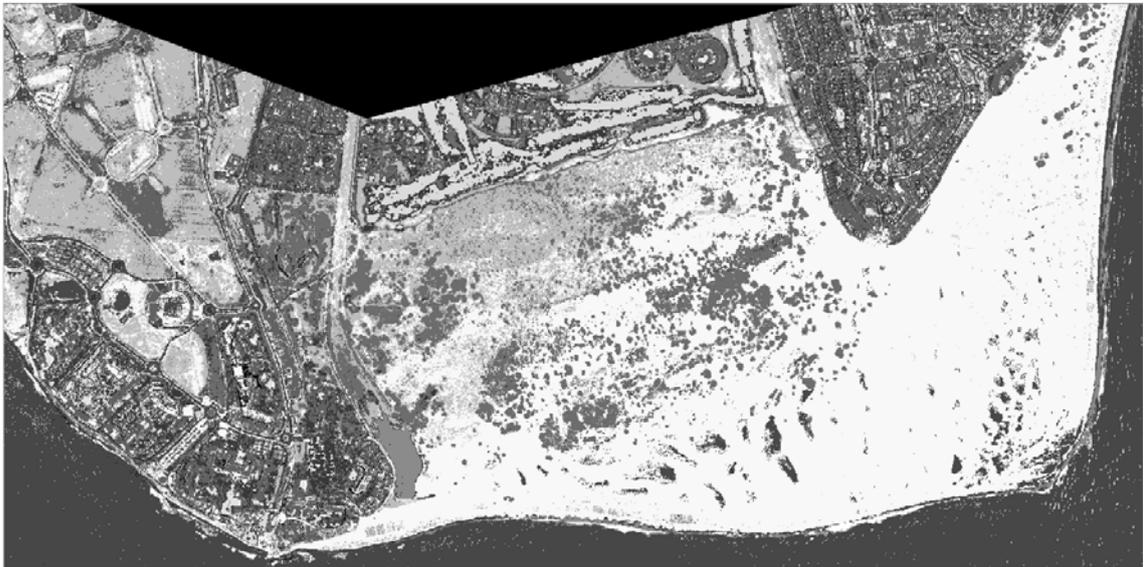
Figura A2.9. Mapas temáticos obtenidos a partir de las bandas espectrales de la imagen WV2 usando los conjuntos de ROIs: a) P + M I. b) Puros. c) Mezclados.



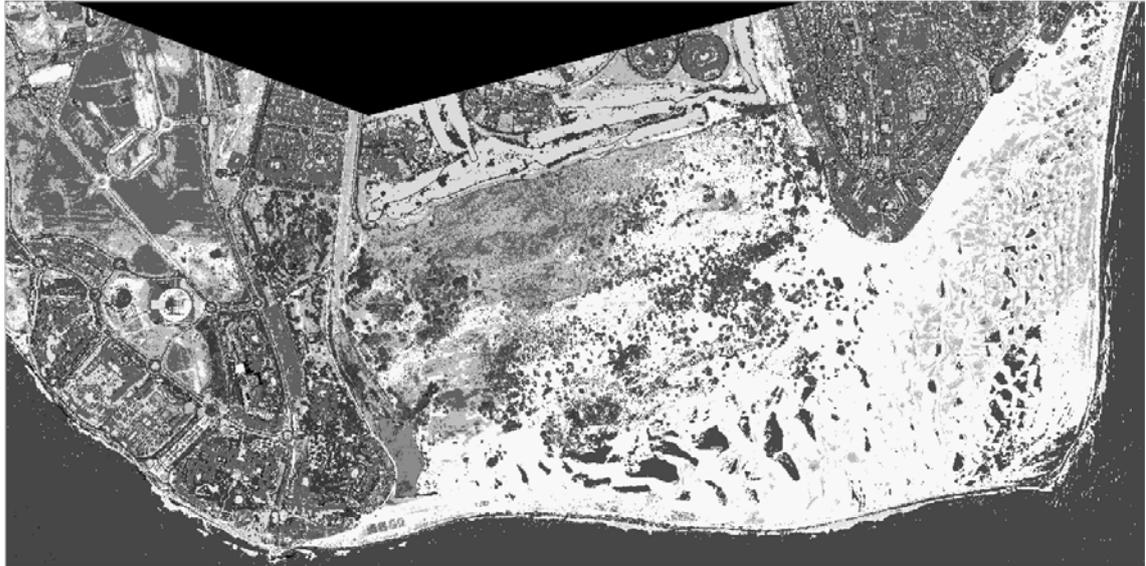
a)



b)



c)



d)

Figura A2.10. Mapas temáticos obtenidos a partir de las bandas espectrales de la imagen WV2 más la información de textura usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.

A3. Anexo 3

En este anexo se adjuntan las matrices de confusión no incluidas en la memoria de las clasificaciones realizadas.

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	80,47	4,16	0	0	0,38	0	0	0	0,27	0	0	0	7,46
Arbustos	13,83	90,24	0	0	0,54	0	0	0	0,07	0	1,9	1,14	8,45
Arena	0	0	90,24	0,41	0	0,09	0	2,06	0	0	2,58	1,3	8,18
Asfalto	0	1,77	0	90,12	0	0	0,42	0,06	1,19	0,08	0	2,31	7,83
Hierba	5,55	0	0	0	99,08	0	0	0	0	0	0	0	9,61
Lago	0	0	0	0	0	98,16	0	0	0	0	0	0	7,89
Mar	0	0	0	0	0	1,74	91,74	11,7	2,63	1,67	0,38	0	10,49
Olas	0	0	0	0	0	0	0	74,68	0	4,97	0	0	2,58
Otros	0,15	0,07	0	0,25	0	0	7,8	0	95,66	0	0	0	8,1
Piscinas	0	0	0	0	0	0,04	0	0,13	0,17	93,27	0	0	8,15
Suelo construido	0	0,27	0	0,02	0	0	0	11,12	0	0	88,1	1,08	9,09
Resto de suelos desnudos	0	3,49	9,76	9,2	0	0	0	0,26	0	0	7,04	94,17	12,16
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	89,31	3,49	0	0	12,74	0	0	0	0,41	0	0	0	9,34
Arbustos	8,76	95,35	0	0,52	0	0	0	0	0,66	0	1,84	1,93	8,51
Arena	0	0	97,32	0	0	0,14	0	0	0	0	0,83	7,46	9,15
Asfalto	0	0,92	0	95,41	0	0	2,3	0,32	1,36	0	2,58	3,32	8,77
Hierba	1,93	0	0	0	87,26	0	0	0	0	0	0	0	8,2
Lago	0	0	0	0	0	99,86	1,35	0,06	0,05	0	0	0	8,18
Mar	0	0	0	0	0	0	87,19	0,77	1,66	0,23	0	0	9,32
Olas	0	0	0	0	0	0	0,67	88,37	0	0,57	1,09	0	2,76
Otros	0	0	0	0,18	0	0	8,4	0	95,66	0	0	0	8,14
Piscinas	0	0	0	0	0	0,09	2,83	0	99,2	0	0	0	8,74
Suelo construido	0	0	0,11	0	0	0	7,46	0	0	85,41	2,02	8,8	
Resto de suelos desnudos	0	0,24	2,58	3,88	0	0	0	0,19	0,19	0	8,24	85,26	10,09
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	74,92	0,15	0	0	1,08	0	0	0	0	0	0	0	6,71
Arbustos	19,8	94,34	0	0,5	0	0	0	0	0,49	0	1,69	2,49	9,43
Arena	0	0	84,68	3,11	0	0,02	0,14	1,74	0	0	1,79	21,1	9,87
Asfalto	0	0,94	1,26	94,57	0	0,21	27	1,41	1,63	0,36	0	4,5	11,36
Hierba	5,17	0	0	0	98,92	0	0	0	0	0	0,75	0	9,64
Lago	0	0	0	0	0	94,52	0,19	0,06	0	0	0	0	7,62
Mar	0	0	0	0	0	5,25	64,84	0,13	1,88	0	0	0	7,37
Olas	0	0	0	0	0	0,05	0	85,48	0	1,99	0,28	0	2,66
Otros	0,1	0,29	0	0,14	0	0	7,33	0	95,98	0	0	0	8,08
Piscinas	0	0	0	0	0	0,44	2,76	0,02	97,65	0	0	0	8,64
Suelo construido	0	0,1	0	0,02	0	0	8,35	0	0	81,84	3,22	8,6	
Resto de suelos desnudos	0	4,19	14,07	1,66	0	0	0	0,06	0	13,65	68,7	10,01	
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	88,41	32,97	0	0	0,98	0	0	0	0,02	0	0	0	10,39
Arbustos	0,34	37,79	0	0	0	0	0	0	0	0	0,09	1,79	3,1
Arena	0	0	77,93	1,27	0	0	0	0,19	0	0	3,07	37,93	10,93
Asfalto	0	21,57	3,03	85,6	0	0	1,16	0,13	0	0	0,28	8,82	9,91
Hierba	8,69	0	0	0	99,02	0	0	0	0	0	0,13	0,02	9,9
Lago	0	0	0	0	0	84,03	1,35	0	0,12	0	0	0	6,91
Mar	0	0	0	9,31	0	15,97	77,59	0,77	0,34	0,53	0	0	10,28
Olas	0	0	0	0	0	0	0,88	90,1	0	0	6,74	0	3,34
Otros	2,56	6,8	0	3,73	0	0	17,74	0	99,51	12,54	0,02	0,04	11,55
Piscinas	0	0	0	0	0	0	1,28	5,21	0	86,93	0	0	7,86
Suelo construido	0	0	19,04	0,02	0	0	0	3,6	0	0	84	30,44	13,07
Resto de suelos desnudos	0	0,87	0	0,07	0	0	0	0	0	0	5,67	20,97	2,77
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

d)

Figura A3.1. Matrices de confusión de los mapas temáticos obtenidos a partir de las bandas espectrales de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	82,67	3,49	0	0	0,04	0	0	0	0,27	0	0	0	7,57
Arbustos	10,77	91,26	0	0,09	0,04	0	0	0	0,17	0	2,11	1,17	8,25
Arena	0	0	89,96	0,25	0	0,02	0	0,58	0	0	5,46	3,92	8,64
Asfalto	0	1,6	0	91,66	0	0	0,79	0,06	1,58	0	0	2,55	8,03
Hierba	6,41	0	0	0	99,92	0	0	0	0	0	0	0	9,76
Lago	0	0	0	0	0	96,95	0	0	0	0	0	0	7,8
Mar	0	0	0	0	0	3,03	91,23	10,73	3,19	0,97	0,19	0	10,47
Olas	0	0	0	0	0	0	0	76,09	0	2,54	0	0	2,41
Otros	0,15	0,1	0	0,25	0	0	7,96	0	94,45	0	0	0	8,03
Piscinas	0	0	0	0	0	0	0,26	0,34	96,49	0	0	0	8,45
Suelo construido	0	0,15	0	0,07	0	0	11,95	0	0	84,17	1,23	8,74	
Resto de suelos desnudos	0	3,41	10,04	7,68	0	0	0,32	0	0	8,07	91,13	11,85	
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	90,4	2,66	0	0	6,41	0	0	0	0,17	0	0	0	8,77
Arbustos	8,51	95,18	0	0,48	0,02	0	0	0	1,39	0	3,22	1,61	8,63
Arena	0	0	92,34	0	0	0	0	0	0	0	1,17	2,64	8,26
Asfalto	0	1,09	0	95,09	0	0	3,69	0,39	1,36	0	1,36	3,92	8,84
Hierba	1,09	0	0	0	93,57	0	0	0	0	0	0	0	8,71
Lago	0	0	0	0	0	100	1,42	0,06	0,07	0	0	0	8,2
Mar	0	0	0	0	0	0	85,6	0,58	1,8	0,23	0	0	9,16
Olas	0	0	0	0	0	0	0,83	89,46	0	0,44	0,94	0	2,79
Otros	0	0	0	0,34	0	0	8,35	0	95,06	0	0	0	8,1
Piscinas	0	0	0	0	0	0	0,11	3,34	0,02	99,32	0	0	8,77
Suelo construido	0	0	0,3	0	0	0	0	5,98	0	0	84,64	3,92	8,89
Resto de suelos desnudos	0	1,07	7,36	4,09	0	0	0	0,19	0,12	0	8,68	87,92	10,88
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	78,73	0,12	0	0	2,04	0	0	0	0	0	0	0	7,13
Arbustos	18,46	95,3	0	0,43	0	0	0	0	0,32	0	1,69	2,57	9,38
Arena	0	0	85,13	2,61	0	0,02	1,09	0	0	0	1,3	19,76	9,65
Asfalto	0	1,14	0,09	95,14	0	0	34,08	1,99	2,36	0,08	0	4,41	12,09
Hierba	2,47	0	0	0	97,96	0	0	0	0	0	2,09	0	9,44
Lago	0	0	0	0	0	96,83	0	0	0	0	0	0	7,79
Mar	0	0	0	0	0	3,17	59,15	0,06	2,53	0	0	0	6,66
Olas	0	0	0	0	0	0	0,04	84,77	0	0,93	0,08	0	2,53
Otros	0,34	0,29	0	0,25	0	0	5,8	0	94,76	0	0	0	7,86
Piscinas	0	0	0	0	0	0	0,91	3,15	0,02	98,94	0	0	8,82
Suelo construido	0	0	0,04	0,05	0	0	0	8,93	0	0,04	80,78	4,28	8,62
Resto de suelos desnudos	0	3,15	14,74	1,52	0	0	0	0	0	0	14,06	68,98	10,04
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	90,11	31,23	0	0	0,4	0	0	0	0,02	0	0,02	0	10,36
Arbustos	0,75	41,71	0	0	0	0	0	0	0	0	0,21	1,63	3,43
Arena	0	0	70,14	1,41	0	0	0	0	0	0	4,23	33,47	9,93
Asfalto	0	20,46	1,97	82,89	0	1,42	0,13	0	0	0	0,26	8,22	9,48
Hierba	6,89	0	0	0	99,6	0	0	0	0	0	0,32	0	9,81
Lago	0	0	0	0	0	83,48	1,83	0	0,22	0	0	0	6,92
Mar	0	0	0	11,99	0	16,52	79,94	0,84	0,39	0,4	0	0	10,78
Olas	0	0	0	0	0	0	0,62	90,94	0	0,02	6,78	0	3,34
Otros	2,24	5,57	0	3,5	0	0	14,45	0	99,37	12,67	0	0,04	11,06
Piscinas	0	0	0	0	0	1,74	0	4,37	0	86,91	0,02	0	7,89
Suelo construido	0	0	27,89	0,07	0	0	0	3,73	0	0	82,99	34,66	14,17
Resto de suelos desnudos	0	1,04	0	0,14	0	0	0	0	0	0	5,18	21,98	2,84
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

d)

Figura A3.2. Matrices de confusión de los mapas temáticos obtenidos a partir de las 10 primeras componentes PCA de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	77,27	1,23	0	0	0,5	0	0	0	0,02	0	0	0	6,95
Arbustos	12,91	92,25	0	0,39	0,18	0	0	0,06	1,61	0	2,41	0,78	8,65
Arena	0	0	95,26	1,75	0	0	0	1,35	0	0	6,53	7,6	9,72
Asfalto	0	1,31	0	89,07	0	0	1,16	0,26	2,97	0	0	3,47	8,04
Hierba	9,76	0	0	0	99,32	0	0	0	0	0	2,01	0	10,2
Lago	0	0	0	0	0	98,33	0	0	0,02	0	0	0	7,91
Mar	0	0	0	0	0	1,67	95,71	6,68	2,09	1,57	0,04	0	10,67
Olas	0	0	0	0	0	0	0	88,56	0	0,06	0	0	2,55
Otros	0	0	0	0,8	0	0	3,06	0	93,18	0	0	0	7,44
Piscinas	0	0	0	0	0	0,05	0,06	0,05	98,37	0	0	0	8,59
Suelo construido	0,06	0,05	0	0,02	0	0	0,02	2,96	0	0	82,72	2,2	8,43
Resto de suelos desnudos	0	5,16	4,74	7,97	0	0	0	0,06	0,05	0	6,29	85,95	10,84
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	85,98	0,99	0	0	4,73	0	0	0	0,02	0	0	0	8,08
Arbustos	12,13	97,34	0	2,34	0	0	0	0,06	1,58	0	1,79	3,38	9,32
Arena	0	0	97,64	0,43	0	0	0	0,06	0	0	3,78	8,91	9,64
Asfalto	0	0,97	0	91,41	0	0	4,87	0,64	2,53	0	0	3,85	8,61
Hierba	1,76	0	0	0	95,27	0	0	0	0	0	3,2	0	9,24
Lago	0	0	0	0	0	99,89	0,09	0	0,07	0	0	0	8,05
Mar	0	0	0	0	0	0,11	85,52	0,51	1,02	0,55	0	0	9,12
Olas	0,04	0	0	0	0	0	0,6	96,34	0	0,04	0,51	0	2,89
Otros	0,08	0	0	0,84	0	0	8,6	0	94,69	0,3	0	0	8,18
Piscinas	0	0	0	0	0	0	0,33	1,09	0	99,11	0	0	8,71
Suelo construido	0	0	0,02	0	0	0	0	1,29	0	0	83,08	4,46	8,64
Resto de suelos desnudos	0	0,7	2,34	4,98	0	0	0	0	0,07	0	7,64	79,41	9,52
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	77,77	0,07	0	0	2,76	0	0	0	0	0	0	0	7,11
Arbustos	19	98,43	0	2,2	0	0	0	0,06	1,66	0,02	0,08	2,78	9,77
Arena	0	0	99,65	2,14	0	0	0	0,45	0	0	2,94	22,99	11,32
Asfalto	0	1,04	0,19	90,57	0	0	20,21	1,22	0,15	0,02	0	4,5	10,08
Hierba	3,12	0	0	0	97,24	0	0	0	0	0	3,88	0	9,61
Lago	0	0	0	0	0	98,76	0	0	0	0	0	0	7,94
Mar	0	0	0	0	0	1,24	72,93	0,13	1,85	0	0	0	7,9
Olas	0	0	0	0	0	0	0	90,36	0	0,04	0	0	2,6
Otros	0,04	0,1	0	3,77	0	0	4,39	0	96,35	0,28	0,02	0,05	8,11
Piscinas	0	0	0	0	0	0	2,46	2,31	0	99,64	0	0	9,01
Suelo construido	0,06	0	0,04	0,02	0	0	0	5,4	0	0	77,53	2,02	7,97
Resto de suelos desnudos	0	0,36	0,11	1,29	0	0	0	0,06	0	0	15,57	67,65	8,58
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	81,81	17,24	0	0	0	0	0	0	0,02	0	0	0	8,52
Arbustos	3,71	68,09	0	0	0	0	0	0	0,15	0	0	3,72	5,91
Arena	0	0,1	96,34	1,48	0	0	0	0,06	0	0	4,72	55,33	14,46
Asfalto	0	10,6	0,95	69,35	0	0	0,6	0,13	0,02	0	0,08	7,01	7,31
Hierba	13,66	0	0	0	100	0	0	0	0	0	3,05	0	10,71
Lago	0	0	0	0	0	100	3,97	0,06	1,66	0	0	0	8,59
Mar	0	0	0	4	0	0	87,78	1,09	3,9	0	0	0	9,86
Olas	0	0	0	0	0	0	0,09	95,95	0	0	7,36	0	3,48
Otros	0,82	3,44	0	25,17	0	0	5,27	0	94,25	5,94	0,15	1,64	10,77
Piscinas	0	0	0	0	0	0	2,29	2,12	0	94,06	0,43	0	8,55
Suelo construido	0	0	2,71	0	0	0	0	0,51	0	0	80,27	15,64	9,71
Resto de suelos desnudos	0	0,53	0	0	0	0	0	0,06	0	0	3,93	16,65	2,13
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

d)

Figura A3.3. Matrices de confusión de los mapas temáticos obtenidos a partir de las 25 primeras componentes MNF de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	82,88	3,46	0	0	0,54	0	0	0	0,29	0	0	0	7,63
Arbustos	14	91,12	0	0	0,18	0	0	0	0,07	0	2,2	1,17	8,53
Arena	0	0	89,22	0,95	0	0,05	0	0,13	0	0	1,88	1,81	8,06
Asfalto	0	1,28	0	89,89	0	0,02	0,16	0	0,51	0,08	0,09	2,76	7,75
Hierba	2,98	0	0	0	99,24	0	0	0	0	0	0	0	9,4
Lago	0	0	0	0	0	97,89	0	0	0	0	0	0	7,87
Mar	0	0	0	0,18	0	2,04	0	91,9	11,44	2,56	1,82	0,02	10,51
Olas	0	0	0	0	0	0	0	76,74	0	6,03	0,02	0	2,73
Otros	0,15	0,36	0	0,39	0	0	7,95	0	96,4	0	0	0	8,21
Piscinas	0	0	0	0	0	0	0	0	0,17	92,07	0	0	8,04
Suelo construido	0	0,34	0	0,02	0,04	0	0	11,57	0	0	88,31	0,89	9,11
Resto de suelos desnudos	0	3,44	10,78	8,56	0	0	0	0,13	0	0	7,47	93,37	12,15
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	77,39	0,1	0	0	1,98	0	0	0	0	0	0	0	7,01
Arbustos	19,92	93,34	0	0,91	0	0	0	0,06	0,37	0	2,43	7,24	9,95
Arena	0	0	86,47	2,7	0	0	0	0,13	0	0	1,58	17,36	9,52
Asfalto	0	1,02	0,84	94,16	0	0,16	25,01	0,71	0,54	0,36	0	4,48	10,98
Hierba	2,37	0	0	0	98,02	0	0	0	0	0	0	0	9,23
Lago	0	0	0	0	0	95,16	0,07	0	0	0	0	0	7,66
Mar	0	0	0	0	0	4,29	68,87	0,58	1,83	0,93	0	0	7,81
Olas	0	0	0	0,02	0	0	0,33	96,59	0	2,79	1,22	0	3,17
Otros	0,31	0,53	0	0,41	0	0,39	5,7	0	97,27	0	0	0	8,1
Piscinas	0	0	0	0	0	0	0,02	0,77	0	95,92	0	0	8,39
Suelo construido	0	0,15	0	0,02	0	0	0	1,16	0	0	82,27	3,67	8,48
Resto de suelos desnudos	0	4,87	12,68	1,77	0	0	0	0	0	0	12,5	67,25	9,69
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	84,14	23,51	0	0	1,22	0	0	0	0	0	0	0	9,31
Arbustos	4,97	48,68	0	0	0	0	0	0	0	0	0,09	1,17	4,28
Arena	0	0	96,1	1,09	0	0	0	0	0	0	9,77	57,26	15,09
Asfalto	0	22,95	3,9	93,48	0	0	1,07	0,13	0,22	0	0,26	9,05	10,76
Hierba	8,72	0	0	0	98,78	0	0	0	0	0	1,56	0,04	10,02
Lago	0	0	0	0	0	33,75	0,7	0,06	0,1	0	0	0	2,8
Mar	0	0	0	4,75	0	66,23	80,98	0,71	1,97	0,38	0	0	14,41
Olas	0	0	0	0	0	0,02	1,04	79,37	0	0	1,13	0	2,5
Otros	2,18	3,78	0	0,39	0	0	14,41	0	97,71	12,69	0,02	0	10,53
Piscinas	0	0	0	0	0	0	1,79	14,65	0	86,93	4,27	0	8,61
Suelo construido	0	0,02	0	0,11	0	0	0	5,08	0	0	66,18	4,3	7,08
Resto de suelos desnudos	0	1,07	0	0,18	0	0	0	0	0	0	16,71	28,18	4,61
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Figura A3.4. Matrices de confusión de los mapas temáticos obtenidos a partir de las bandas espectrales de la imagen CASI más la información de textura usando los conjuntos de ROIs:

a) P + M I. b) Puros. c) Mezclados.

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	48,06	2,95	3,44	1,86	8,15	2,18	5,99	2,38	6,09	0	1,13	2,17	7,32
Arbustos	17,68	68,99	1,47	2,07	13,36	0,11	2,07	0,45	2,44	0,02	4,65	2,2	9,45
Arena	1,63	0,41	67,78	3,45	0,5	1,47	5,22	2,44	2,05	0,25	8,43	17,4	9,8
Asfalto	0,46	9,61	3,27	51,27	1,3	0	16,21	3,21	13,05	0,55	1,84	13,87	9,76
Hierba	9,34	2,35	0,19	0,77	74,01	0	1,76	0	1,49	0	1,05	0,2	8,32
Lago	0	0	0	0	0	95,64	0,05	0	0,02	0	0,32	0	7,73
Mar	0,71	0,12	6,28	4,5	0,08	0	38,95	1,16	7,4	0,21	0,38	1,46	5,87
Olas	0,04	0	0	0	0	0	0	78,73	0	0,13	0,23	0	2,3
Otros	14,29	3,87	7,36	26,85	1,1	0,6	21,34	9,13	60,23	0,91	3,84	10,04	13,06
Piscinas	3,79	0,24	0	0,05	0,34	0	0,07	0,13	0,29	76,96	0,53	0,27	7,21
Suelo construido	1,91	0,31	0,28	0,95	0,12	0	1,51	2,38	1,17	20,96	65,89	1,91	9,1
Resto de suelos desnudos	2,07	11,14	9,93	8,22	1,02	0	6,82	0	5,77	0	11,71	50,47	10,1
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	73,16	2,28	0,15	0,07	29,41	1,12	1,62	0,64	2,53	0	1,05	0,49	9,97
Arbustos	5,66	51,59	1,95	9,2	3,29	0	6,13	0,06	8,48	0,04	5,21	13,46	8,82
Arena	2,87	7,41	75,11	2,29	0,4	0,67	9,4	0,32	1,29	1,16	10,52	22,8	12,05
Asfalto	0,19	6,97	8,7	51,39	0,4	0	20,2	0,45	14,37	1,8	6	14,54	10,95
Hierba	10,08	9,05	1,6	0,75	64,14	0	1,78	0	2,29	0	0,36	0,58	8,13
Lago	0	0	0	0	0	98,03	0,19	0,06	0,34	0	0,15	0	7,95
Mar	0,29	1,69	5,89	4,93	0,62	0,05	32,29	0	8,3	0,53	0,11	5,04	5,71
Olas	2,18	0,17	0	0	0	0,14	0,19	92,16	0,1	1,02	2,24	0	3,2
Otros	4,38	12,47	2,79	24,72	0,48	0	19,46	4,18	53,46	2,39	3,69	9	11,33
Piscinas	0,25	0,19	0	0,18	0,16	0	0,97	1,86	0,75	92,72	1,58	0,02	8,52
Suelo construido	0,75	0,94	0,67	1,32	0,22	0	3,23	0,26	2,14	0,34	56,62	6,5	7,08
Resto de suelos desnudos	0,19	7,24	3,14	5,16	0,88	0	4,54	0	5,94	0	12,46	27,58	6,3
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	77,71	0,51	1,1	0,27	35,02	1,97	0,42	1,03	2,44	0	7,23	0,98	11,45
Arbustos	11,77	45,99	7,25	5,32	5,65	4,91	7,24	0,06	6,02	0,11	0,75	4,12	8,23
Arena	0,44	1,07	56,98	4,84	1,16	0	6,5	0	2,14	0	5,63	13,85	8,29
Asfalto	0,1	6,39	5,91	34,73	0,36	0	23,68	3,34	8,13	0,02	0,41	10,51	8,17
Hierba	0,78	2,69	0,41	0,59	54,44	0,05	3,27	0,06	0,85	0	7,3	0,9	6,59
Lago	0	0	0	0	0	89,52	0,09	0	0,22	0,04	0,06	0	7,23
Mar	0,4	2,52	9,35	4,79	0,26	1,24	25,12	2,06	6,16	0,3	0,45	5,09	5,29
Olas	1,32	0	0	0	0	0	0	81,75	0	1,84	0,04	0	2,63
Otros	5,55	20,19	15	44,89	2,3	2,02	27,07	6,43	69,05	0,23	4,52	20,05	18,09
Piscinas	0,02	0,56	0,24	0,66	0,02	0	2,72	1,48	0,97	84,75	16,09	0,38	9,53
Suelo construido	0,5	0,87	0,26	1,04	0,12	0,3	3,2	3,79	1,75	12,71	49,14	7,14	7,48
Resto de suelos desnudos	1,4	19,22	3,51	2,86	0,66	0	0,69	0	2,26	0	8,38	36,98	7,02
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	58,87	1,33	4,07	0,89	27,19	0,02	1,86	0,32	5,16	0	0,41	4,44	9,3
Arbustos	12,03	62,43	7,88	16,86	6,75	0,46	9,88	1,8	16,12	0	1	7,17	11,66
Arena	6,33	1,53	66,44	5,91	3,35	0,02	10,35	0,39	9,38	0	7,47	30,47	12,78
Asfalto	0,54	5,4	5,73	48,55	0,46	0,02	20,64	2,83	16,85	0	0,96	15,72	10,16
Hierba	3,29	10,19	0,63	9,97	48,61	3,81	11,88	0,19	8,67	0	0,58	1,28	8,81
Lago	3,56	7,31	0,58	0,75	1,54	91,72	6,82	0,32	5,82	0	0,15	0,96	9,78
Mar	0,48	1,36	13,78	10,34	0,42	3,95	28,63	12,15	12,08	0	0,15	5,36	7,35
Olas	5,64	0,17	0	0	0	0	0,42	78,34	0,27	23,78	1,75	0,07	5,08
Otros	3,79	2,49	0	4,11	0,92	0	0,47	1,86	22,45	0	0,11	1,41	2,9
Piscinas	0	0	0	0	0,02	0	7,65	1,22	0,24	76,22	7,62	0	8,25
Suelo construido	0,8	0,05	0,78	0,45	0,08	0	0,51	0,81	0,41	0	69,53	14,99	8,66
Resto de suelos desnudos	4,67	7,75	0,11	2,18	10,66	0	0,58	0,06	2,53	0	10,26	18,12	5,28
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

d)

Figura A3.5. Matrices de confusión de los mapas temáticos obtenidos a partir de los mapas de abundancia de las bandas espectrales de la imagen CASI usando los conjuntos de ROIs:

a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	58,79	3,82	3,14	0,52	3,97	3,99	4,31	11,18	3,12	0	1,17	1,39	7,73
Arbustos	15,78	49,87	12,38	6,88	4,39	2,18	13,43	0,64	8,45	0,11	1,41	6,9	10,3
Arena	0,34	0,63	51,5	1,48	0,02	1,06	1,63	1,16	0,34	0	6,19	21,89	7,75
Asfalto	0,82	18,71	4,57	51,23	0,24	0,18	15,5	1,29	12,96	6,43	4,03	18,33	11,56
Hierba	12,38	2,49	0,06	0	90,92	0,07	0,26	0	0,12	0	2,22	0,07	9,93
Lago	0,67	0,34	0	0	0,16	91,37	0,7	0	0,1	0	1,79	0	7,7
Mar	0,54	5,74	13,01	9,7	0,16	1,12	47,83	2,12	13,03	0,34	0,34	7,42	9,38
Olas	0,15	0	0	0	0	0	0	70,82	0	0,34	0,09	0	2,08
Otros	8,36	5,95	4,98	19,95	0	0,02	12,2	4,69	58,48	0	2,99	6,59	10,05
Piscinas	1,09	0,05	0	0	0,04	0	0,44	2,51	0,1	79,1	8,55	0,04	7,97
Suelo construido	0,04	0,7	0,28	1,09	0,04	0	0,44	5,46	0,24	13,69	56,65	2,35	7,38
Resto de suelos desnudos	1,05	11,69	10,08	9,15	0,06	0	3,25	0,13	3,07	0	14,57	35,01	8,17
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	71,21	6,54	6,84	1,27	22,86	10,28	6,98	1,03	6,6	0,06	0,55	3,03	12,02
Arbustos	5,05	38,15	11,69	2,26	12,84	1,28	8,35	0	14,44	0,04	0,7	14,69	9,24
Arena	1,45	4,7	45,57	2,2	0,54	0,71	5,03	0,06	3,58	0,59	3,39	22,33	8,12
Asfalto	1,13	6,83	8,96	50,73	1,32	0,87	16	0,32	8,94	0,08	4,99	22,49	10,85
Hierba	9,66	11,93	3,94	5,18	61,57	8,79	5,89	0,13	5,19	0	2,79	3,29	10,52
Lago	0,8	1,67	2,4	1,32	0,26	63,09	5,98	0	3,07	0	0,58	0,94	6,62
Mar	0,59	11,98	12,12	9,68	7,85	10,42	32,61	0	12,06	0,74	3,93	12,95	10,45
Olas	0,19	0	0	0	0	0	0,26	82,71	0,02	12,93	1,92	0	3,74
Otros	6,45	6,78	3,25	6,32	0,34	2,68	7,79	0	40,06	0,11	2,33	2,89	6,51
Piscinas	0,25	0	0,02	0,2	0	0	2,41	10,67	0,54	83,82	11,76	0,07	9,11
Suelo construido	2,01	1,96	0,8	1,7	0,22	1,54	4,8	4,95	1,12	1,63	50,08	4,71	6,94
Resto de suelos desnudos	1,22	9,47	4,41	8,56	2,76	0,34	3,92	0,13	4,38	0	16,98	12,61	5,88
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	44,56	6,29	8,18	7,09	22,24	4,04	9,72	0,45	11,96	0	3,29	5,56	10,88
Arbustos	21,52	34,2	3,92	2,59	11,64	18,44	4,25	0,45	2,9	0,15	3,2	1,23	8,73
Arena	3,37	1,89	57,54	2,77	1,08	0,41	0,63	1,29	0,29	0	10,33	40,84	11,01
Asfalto	1,26	16,65	5,63	29,74	5,55	2,34	25	1,22	12,13	9,2	2,32	11,92	10,8
Hierba	0,42	0,48	0	0	46,26	0,32	0,11	0	0	0	3,46	0,13	4,72
Lago	0,52	0,82	0,61	0,3	3,39	48,96	1,95	0	0,34	0	1,32	0,27	4,82
Mar	5,82	22,03	11,51	17,58	4,15	17	35,49	0,13	22,19	0,15	0,6	13,46	13,21
Olas	0,19	0	0	0	0	0,02	0,33	88,3	0	7,89	2,82	0	3,55
Otros	9,99	13,94	4,65	38,35	0,7	8,05	18,44	1,35	48,76	0,38	2,3	6,85	12,79
Piscinas	0,08	0,02	0,04	0,39	0,22	0	3,22	6,36	0,46	82,23	13,87	0,04	9,15
Suelo construido	0,1	0,24	1,06	0,18	0,68	0,32	0,4	0,45	0,24	0	48,58	5,94	5,66
Resto de suelos desnudos	12,15	3,41	6,86	1,02	4,09	0,09	0,46	0	0,73	0	7,91	13,76	4,67
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	65,77	2,47	0,35	0,75	28,71	0,07	0,53	0,19	5,02	0,02	0,09	0,16	9,19
Arbustos	8,57	50,38	4,13	25,4	1,6	3,05	31,57	1,22	29,25	2,18	0,83	7,19	13,97
Arena	2,83	1,16	44,54	1,23	3,99	6,72	3,23	0,84	1,14	0	4,54	21,77	8,26
Asfalto	0,17	11,06	7,75	35,71	0,76	4,77	17,38	0,58	5,85	4,78	2,52	13,44	9,19
Hierba	2,1	6,73	2,08	1,73	62,87	64,07	12,36	3,02	0,71	0,61	5,74	1,61	14,17
Lago	1,74	6,17	12,29	5,45	0,16	15,88	4,34	0,19	4,21	0	0,47	5,62	4,81
Mar	0,54	5,5	6,02	9	0,38	0,67	20,39	0,32	7,94	0	0,08	3,74	4,94
Olas	2,87	0,77	0,8	2,18	0,12	0,23	0,72	84	0,58	24,52	6,15	2,38	6,1
Otros	14,71	9,25	0,65	9,43	0,98	0,21	3,5	0	42,33	0,28	0,43	2,2	6,79
Piscinas	0,02	0,1	0	0,02	0,08	0	0,74	1,48	0,07	66,7	11,8	0	7,12
Suelo construido	0,44	2,23	15,15	5,79	0,3	4,27	4,69	8,03	2,56	0,91	65,97	26,25	12,48
Resto de suelos desnudos	0,25	4,19	6,25	3,32	0,04	0,07	0,54	0,13	0,34	0	1,37	15,64	2,97
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

d)

Figura A3.6. Matrices de confusión de los mapas temáticos obtenidos a partir de los mapas de abundancia de las 10 primeras componentes PCA de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	52,88	0,63	0,22	0,05	2,32	0,34	1,42	2,51	0,46	0	5,74	1,08	5,9
Arbustos	22,48	76,86	2,12	0,95	9,84	0,02	1,6	0,13	1,51	0,08	2,58	3,56	9,91
Arena	0,21	0,02	70,5	0,48	0	0,05	2,02	0,77	1,29	0	6,1	4,52	7,46
Asfalto	0,67	12,32	11,62	66,92	0	0	29,76	0,9	31,86	0,76	1,24	28,65	16,1
Hierba	5,55	2,08	0,82	0,2	86,4	0,25	0,32	0,27	0	0	4,59	1,26	9,32
Lago	0	0	0	0	0	94,47	0	0	0	0,02	0	0	7,6
Mar	1,36	0,15	2,45	6,04	0,1	0,05	39,23	3,6	6,19	0,06	0,64	6,12	6,23
Olas	0,06	0	0	0	0	0	0	88,5	0	0,13	0,94	0	2,65
Otros	10,77	3,41	10,93	24,47	1,1	5,07	25,21	1,29	57,87	0,04	2,71	14,74	13,48
Piscinas	4,94	0	0	0,24	0	0	0,13	0,05	73,79	0,04	2,84	0,02	7,18
Suelo construido	0,02	0	0	0	0	0	0,23	1,86	0,12	25,11	55,66	0,92	7,83
Resto de suelos desnudos	1,05	4,53	1,34	0,89	0	0	0,28	0	0,39	0	16,96	39,13	6,34
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	67.4	1.89	0	0	27.07	0.96	0.35	0.39	2.14	0.93	0.53	0.04	9
Arbustos	7.42	56.02	5.67	16.38	0.92	0.5	3.57	0.06	4.36	0.17	2.11	10.69	8.88
Arena	2.12	5.11	58.69	6.04	0.02	0.5	8.21	0.13	0.32	0	4.54	26.82	10.19
Asfalto	0.02	4.31	2.36	38.41	0.26	0	8.61	0.64	1.83	4.25	8.26	6.43	6.57
Hierba	13.51	1.04	1.56	0.34	68.64	0	1.39	0	0.56	0.04	2.39	0.02	8.18
Lago	0	0	0	0	0	95.39	0	0	0.05	0	0.06	0	7.68
Mar	0.94	15.2	19.22	24.51	0.42	1.24	59.89	0.13	22.92	0.04	0.09	22.8	15.38
Olas	0.78	0	0	0	0	0.53	0.28	96.27	0.12	0.13	0.49	0	2.97
Otros	7.54	13.73	10.5	13.86	0.06	0.87	16.14	0.32	66.29	1.04	1.71	9.47	11.76
Piscinas	0.02	0	0	0.02	0	0	0.21	1.35	0.24	93.27	9.47	0	9.15
Suelo construido	0.17	0	0.26	0.05	0.02	0	0.83	0.71	0.61	0.11	57.09	3.76	6.18
Resto de suelos desnudos	0.08	2.71	1.75	0.39	2.58	0	0.53	0	0.56	0.02	13.27	19.98	4.07
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	70.98	0.24	0	0.07	27.13	0.11	0.33	1.22	1.9	0.32	4.91	0.07	9.51
Arbustos	19.09	49.75	1.84	0.27	4.51	6.88	2.27	0.13	3.53	0.17	4.42	1.73	7.75
Arena	0.08	0	25.41	0	0	0	0.09	0	0.07	0	0.98	0.13	2.3
Asfalto	0	1.65	3.55	32.35	0.02	0	14.36	1.16	2.95	0.02	1.47	6.11	5.59
Hierba	0.94	0.36	0.41	0	65.26	0	0.25	0.32	0.07	0	3.99	0.16	6.6
Lago	0	0	0	0	0	92.45	0.02	0	0	0	0	0	7.44
Mar	0.23	0.63	17.16	0.52	0.72	0.48	36.09	0.32	3.6	2.28	0.08	1.35	6.09
Olas	1.93	0.05	0	0	0	0	0	90.62	0.07	0.7	0.56	0	2.9
Otros	5.76	22.73	41.81	59.95	1.88	0.07	41.47	1.22	82.66	0	2.62	23.39	24.15
Piscinas	0.15	0	0	0.09	0	2.58	4.11	0.73	96.51	5.25	0	9.4	9.4
Suelo construido	0	0	0	0	0	0.02	0.77	0	0	0	65.91	4.3	6.92
Resto de suelos desnudos	0.84	24.59	9.82	6.75	0.48	0	2.53	0.13	4.41	0	9.81	62.75	11.35
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	51.29	0.05	0.63	0.95	7.55	0	1.35	0	2.02	0	0.28	2.67	5.94
Arbustos	15.92	67.61	5.65	14.47	1.6	0	32.22	0.06	29.88	0	0.88	5.55	14.66
Arena	4.99	3.2	51.2	2.75	2	0	1.6	0.06	5.36	0	0.55	16.06	7.72
Asfalto	0.29	5.93	9.67	49.77	0	0	7.72	0.06	7.99	0.08	1.13	26.07	9.54
Hierba	3.77	7.87	10.86	11.43	76.96	0	4.54	0	2	0	0.75	4.3	11.01
Lago	5.72	2.74	3.18	0.11	1.36	99.82	8.05	0	1.78	0	1.24	1.54	10.4
Mar	0.78	1.74	17.85	19.72	0.22	0.18	31.25	0.39	30.35	0.02	0.11	12.68	10.26
Olas	7.96	2.98	0.19	0	4.99	0	0.4	96.92	0.71	15.17	8.55	0.04	6.45
Otros	5.22	1.69	0.13	0.36	3.11	0	0.21	0	17.32	0	0.75	0.6	2.38
Piscinas	0	0	0	0	0	11.48	1.67	0.93	84.73	8.21	0	9.52	9.52
Suelo construido	2.01	0	0.63	0.05	1.04	0	0.12	0.84	0.49	0	69.45	12.36	8.47
Resto de suelos desnudos	2.05	6.2	0	0.39	1.16	0	1.05	0	1.19	0	8.09	18.15	3.64
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

d)

Figura A3.7. Matrices de confusión de los mapas temáticos obtenidos a partir de los mapas de abundancia de las 25 primeras componentes MNF de la imagen CASI usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	78,5	8,33	0	0,2	2,79	2,39	2,55	0,77	2,26	0	0	0	8,47
Arbustos	9,6	77,1	0	0,84	7,51	0	0,11	0,13	0,51	1,33	5,5	3,07	8,5
Arena	0	0	90,8	0,39	0	0,48	2,79	0,58	0,46	6,46	13,24	10,18	0
Asfalto	0,17	2,66	0,69	72,06	0	0	15,03	2,83	8,72	0,91	1,17	13,73	10,04
Hierba	6,66	0,15	0	0	89,66	0	0	0	0	0	0	0	8,85
Lago	0	0	0	0	0	95,92	0	0	0	0	0	0	7,71
Mar	0,52	0	0,54	2,27	0	1,17	58,01	1,35	10,67	1,86	0,36	0,25	7,53
Olas	0	0	0	0	0	0	0	90,42	0	0	0,87	0	2,68
Otros	4,21	0,17	3,51	13,61	0	0,05	14,43	2,06	70,24	0,89	0,87	1,21	8,97
Piscinas	0	0	0	0	0	0	0,65	1,29	0,61	94,52	0,21	0	8,41
Suelo construido	0,23	0,05	0	0	0,04	0	0,04	0,58	0	0	76,28	1,19	7,65
Resto de suelos desnudos	0,1	11,55	4,46	10,63	0	0	6,4	0	6,53	0,02	8,3	67,3	10,99
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	81,19	5,74	0	0,05	0,46	0,07	0,05	1,48	0	0,36	0,14	7,81	0
Arbustos	8,99	65,6	3,18	0,73	1,72	0,32	2,53	0,13	2,05	4,32	1,43	3,92	7,65
Arena	0,17	0,02	81,74	0,45	0	3,99	4,52	10,41	0,32	3,41	17,52	10,29	0
Asfalto	0,13	14,16	1,1	77,76	0	0	9,46	0,06	9,99	0,15	1,45	15,73	11,01
Hierba	8,19	0,53	0	0	97,82	0	0	0	0	0	0,21	0	9,79
Lago	0,06	0	0	0	0	95,62	0,76	0	0,24	0	3,52	0	8,14
Mar	0,84	1,26	3,64	6,52	0	0	74	3,53	12,27	0,08	0,17	1,63	10
Olas	0,08	0	0	0	0	0	0	78,92	0	0	0	0	2,27
Otros	0,27	0,34	1,28	3,38	0	0	5,84	0,06	71,29	0,32	0,58	0,72	6,61
Piscinas	0	0	0	0	0	0	0	2,76	0,05	92,85	0,7	0	8,25
Suelo construido	0	0,44	0,28	0,61	0	0	0,3	2,63	0,07	1,9	81,44	2,89	8,66
Resto de suelos desnudos	0,08	11,91	8,79	10,5	0	0	2,55	0	2,73	0,06	6,74	57,44	9,52
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	83,22	3,82	0	0	0,42	2,04	0,09	0,06	0,24	0	0,04	0	7,86
Arbustos	10,81	84,99	0,04	0,23	2,83	0	3,43	0,19	2,58	0	4,89	1,93	8,95
Arena	0	0	90,39	0,77	0	0	1	0,13	0,05	0	3,67	4,86	8,74
Asfalto	0	0,22	0,13	82,12	0	0	9,14	0	1,66	1,9	1,04	9,97	9,07
Hierba	4,46	0,12	0	0	96,75	0	0	0	0	0	2,11	0	9,52
Lago	0	0	0	0	0	96,51	0	0	0	0	0	0	7,76
Mar	0,78	0	0	0,82	0	1,45	63,44	0,84	2,29	0	0,19	0,31	7,16
Olas	0	0	0	0	0	0	0	93,38	0	0	2,03	0	2,88
Otros	0,63	0	3,09	6,34	0	0	16,45	0,51	88,43	0	2,03	1,68	9,65
Piscinas	0	0	0	0	0	0	2,34	4,43	1,1	97,93	2,64	0	9,25
Suelo construido	0	0	0	0	0	0	0,02	0,45	0	0,17	71,94	4,9	7,58
Resto de suelos desnudos	0,1	10,84	6,34	9,72	0	0	4,1	0	3,65	0	9,43	76,35	11,6
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Figura A3.8. Matrices de confusión de los mapas temáticos obtenidos usando el conjunto de ROIs P + M 1 a partir de los mapas de abundancia generados tras la aplicación de un filtro de mediana de las siguientes combinaciones de la imagen CASI: a) Bandas espectrales. b) 10 primeras componentes PCA. c) 25 primeras componentes MNF.

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	80,26	1,64	0	0	5,48	0	0	0	1,06	0	0	0	7,34
Arbustos	12,18	94,67	0	2,77	0	0	0	0	0,21	0	0,45	5,69	9,97
Arena	0	0,07	94,62	4,04	0	17,22	0	0	0,21	0	0,67	9,1	11,86
Asfalto	0	2,35	0,32	91,39	0	0	0	4,02	2,64	0,76	0	2,88	8,44
Hierba	6,79	0	0	0	94,52	0	0	0	0	0	0	0	9,63
Lago	0	0	0,17	0	0	81,67	0	0	2,43	0	0	0	7,12
Mar	0	0	0	0	0	0	99,83	0	0	3,81	0	0	11,8
Olas	0	0	0	0	0	0	0,17	80,86	0	1,13	0	0	3,09
Otros	0,75	0,31	0	0,86	0	1,11	0	0	93,45	0	0	0	2,02
Piscinas	0	0	0	0	0	0	0	0	0	94,3	0	0	8,69
Suelo construido	0,02	0,05	0	0	0	0	0	6,58	0	0	78,23	4,79	8,48
Resto de suelos desnudos	0	0,92	4,9	0,93	0	0	0	8,54	0	0	20,66	77,54	11,56
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	73,23	0	0	0	4,16	0	0	0	0	0	0	0	6,47
Arbustos	22,22	95,87	0	2,03	0	0	0	0	2,11	0	0,2	6,18	10,91
Arena	0	0,05	90,4	3,3	0	0	0	1,96	0	0	2,98	23,08	11,75
Asfalto	0	3,31	1,92	94,28	0	0	0	5,55	4,44	0,69	0	3,13	9,03
Hierba	3,76	0	0	0	95,84	0	0	0	0	0	0	0	9,5
Lago	0	0	1,18	0	0	98,89	0,1	8,92	2,33	0	0	0	9,04
Mar	0	0	0	0	0	0	97,96	0,11	0	0,15	0	0	11,25
Olas	0	0	0	0	0	0	0	76,24	0	0,61	0	0	2,85
Otros	0,58	0,49	0	0,33	0	1,11	0	0	91,12	0	0	0	1,93
Piscinas	0	0	0	0	0	0	1,93	0,22	0	98,55	0	0	9,31
Suelo construido	0,22	0,09	0	0	0	0	0	7,01	0	0	81,59	10,84	9,52
Resto de suelos desnudos	0	0,19	6,5	0,05	0	0	0	0	0	0	15,22	56,76	8,42
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	78,79	42,14	0	0,07	0,65	0	0	0	2,33	0	0	0	10,23
Arbustos	0,51	34,84	0	0,05	0	0	0	0	0	0	0,41	3,71	3,46
Arena	0	0,33	54,67	4,59	0	0	0	0	0	0	3,1	25,15	8,68
Asfalto	0,41	22,6	11,56	94,04	0	0	0	0	0,53	0,06	0	5,57	11,53
Hierba	20,08	0	0	0	99,35	0	0	0	0	0	0,2	0	11,21
Lago	0	0,02	0,63	0,19	0	74,05	0	0	4,97	0	0	0	6,57
Mar	0	0	0,38	0	0	6,61	98,76	0	0	13,99	0	0	13,22
Olas	0	0	0,06	0,02	0	18,19	0,8	66,18	0	24	0	0,02	6,31
Otros	0,07	0	0	1,03	0	1,16	0,44	0	92,18	0	0	0	1,98
Piscinas	0	0	0	0	0	0	0	32,95	0	61,94	1,01	0,14	7,03
Suelo construido	0	0	23,23	0	0	0	0	0,87	0	0	89,42	35,96	15,02
Resto de suelos desnudos	0,14	0,07	9,45	0	0	0	0	0	0	0	5,86	29,45	4,75
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Figura A3.9. Matrices de confusión de los mapas temáticos obtenidos a partir de las bandas espectrales de la imagen WV2 usando los conjuntos de ROIs: a) P + M 1. b) Puros. c) Mezclados.

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	80,48	2,04	0	0	4,73	0	0	0	0,95	0	0	0	7,32
Arbustos	11,72	94,49	0	3,13	0	0	0	0	0,11	0	0,16	5,48	9,9
Arena	0	0	78,03	1,51	0	16,48	0	0	0,42	0,08	0	7,46	9,77
Asfalto	0	1,57	2,79	93,57	0	0	0	2,61	2,75	0,76	0	3,82	8,85
Hierba	6,81	0	0	0	95,27	0	0	0	0	0	0	0	9,7
Lago	0	0	0,32	0	0	83,04	0	0	3,91	0	0	0	7,28
Mar	0	0	0	0	0	0	99,83	0	0	4,05	0	0	11,82
Olas	0	0	0	0	0	0	0,16	82,06	0	0,95	0	0	3,12
Otros	0,99	0,02	0	0,62	0	0,49	0,02	0	91,86	0	0	0	1,91
Piscinas	0	0	0	0	0	0	0	0	0	94,24	0	0	8,69
Suelo construido	0	0,02	0	0	0	0	0	6,47	0	0	79,26	5,35	8,64
Resto de suelos desnudos	0	1,85	18,86	1,17	0	0	0	8,86	0	0	20,49	77,9	13,01
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

a)

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	79,25	0,23	0	0	5,18	0	0	0	0	0	0	0	7,09
Arbustos	15,6	95,66	0	3,01	0	0	0	0	1,06	0,02	1,62	4,4	10,35
Arena	0	0	67,06	0,65	0	0,14	0	0	0	0,26	0,26	3,77	6,85
Asfalto	0	0,16	3,86	92,87	0	9,06	0	0,27	1,59	0,5	0,08	3,58	9,4
Hierba	4,26	0	0	0	94,82	0	0	0	0	0	0	0	9,44
Lago	0	0	0,78	0	0	90,18	0	0	4,76	0	0	0	7,95
Mar	0	0	0	0	0	0	98,87	0	0	0,26	0	0	11,36
Olas	0	0	0	0	0	0,09	0,14	98,31	0	0,26	0	0	3,66
Otros	0,58	0,02	0	0,74	0	0,53	0,02	0	92,6	0	0	0	1,91
Piscinas	0	0	0	0	0	0	0,97	1,25	0	98,96	0	0	9,28
Suelo construido	0,31	0,16	0	0	0	0	0	0,16	0	0	83,28	7,93	9,12
Resto de suelos desnudos	0	3,75	28,3	2,73	0	0	0	0	0	0	14,76	80,33	13,58
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

b)

Ground Truth (Percent)													
Clases	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	Total
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	72,22	0	0	0	4,14	0	0	0	0	0	0	0	6,39
Arbustos	23,81	97,04	0	2,03	0	0	0	0	1,69	0,02	0,26	5,93	11,12
Arena	0	0,12	85,82	3,97	0	0	0	1,41	0	0	3,65	21,28	11,23
Asfalto	0	2,53	3	93,49	0	0,55	0,19	3,53	5,39	1,08	0,19	3,33	9,07
Hierba	3,61	0	0	0	95,86	0	0	0	0	0	0	0	9,49
Lago	0	0	1,18	0	0	98,43	0,09	7,61	1,37	0	0	0	8,93
Mar	0	0	0	0	0	0	98,96	0,05	2,64	1,41	0	0	11,53
Olas	0	0	0	0	0	0	0	83,58	0	0,65	0,26	0	3,15
Otros	0,26	0,02	0	0,29	0	1,02	0	0	88,9	0	0	0	1,81
Piscinas	0	0	0	0	0	0	0,77	0,05	0	96,84	0	0	9,01
Suelo construido	0,1	0	0	0	0	0	0	3,75	0	0	79,89	11,15	9,25
Resto de suelos desnudos	0	0,28	10	0,22	0	0	0	0	0	0	15,93	58,31	9,02
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

c)

Clases	Ground Truth (Percent)												Total
	Árboles	Arbustos	Arena	Asfalto	Hierba	Lago	Mar	Olas	Otros	Piscinas	Suelo construido	Resto de suelos desnudos	
No clasificado	0	0	0	0	0	0	0	0	0	0	0	0	0
Árboles	73,09	27,38	0	0,07	0,46	0	0	0	1,59	0	0	0	8,47
Arbustos	2,77	30,5	0	0,33	0	0	0	0	0,11	0	0,26	2,79	3,19
Arena	0	0,21	52,71	3,68	0	0	0	0	0	0	3,89	26,37	8,62
Asfalto	1,88	41,83	15,09	93,66	0	13,22	0	0	0,85	0,06	0,02	6,41	14,84
Hierba	22	0	0	0	99,54	0	0	0	0	0	0,75	0	11,44
Lago	0,05	0,02	0,95	1,72	0	63,39	0	0	5,71	0	0	0	5,82
Mar	0	0	0,04	0	0	20,5	99,48	0	1,48	18,65	0	0	14,93
Olas	0	0	0	0,07	0	2,22	0,52	43,94	0	4,79	0	0,05	2,32
Otros	0,02	0	0	0,45	0	0,67	0	0	90,27	0	0	0	1,8
Piscinas	0	0	0	0	0	0	0	54,32	0	76,5	1,72	0,07	9,22
Suelo construido	0	0	6,35	0	0	0	0	1,74	0	0	81,35	26,1	11,57
Resto de suelos desnudos	0,19	0,05	24,86	0	0	0	0	0	0	0	12	38,19	7,78
Total	100	100	100	100	100	100	100	100	100	100	100	100	100

d)

Figura A3.10. Matrices de confusión de los mapas temáticos obtenidos a partir de las bandas espectrales de la imagen WV2 más la información de textura usando los conjuntos de ROIs: a) P + M 1. b) P + M 2. c) Puros. d) Mezclados.

A4. Anexo 4

En este anexo se adjunta la tabla que incluye las estadísticas completas de la detección de cambios de los dos mapas con mejores resultados de los sensores WV2 y CASI.

Tabla A4.1. Estadísticas completas de la detección de cambios.

Clasificación_T1 (WV2)	Clasificación_T2 (CASI)	Área (m ²)	Porcentaje
Sin cambios	Sin cambios	5.980.512,25	75,448906
Resto de suelos desnudos	Arena	363.415,5	4,584775
Arena	Resto de suelos desnudos	190.468,25	2,402908
Suelo construido	Resto de suelos desnudos	135.935,25	1,714931
Resto de suelos desnudos	Arbustos	125.067	1,577819
Resto de suelos desnudos	Suelo construido	107.033	1,350306
Suelo construido	Arbustos	89.146,25	1,124651
Asfalto	Arena	84.590,75	1,067179
Resto de suelos desnudos	Asfalto	67.467,5	0,851156
Arbustos	Árboles	67.312,25	0,849197
Árboles	Arbustos	54.662,75	0,689614
Arbustos	Resto de suelos desnudos	51.570	0,650596
Hierba	Árboles	45.019,75	0,56796
Árboles	Hierba	43.141,5	0,544264
Arbustos	Asfalto	33.304,75	0,420166
Asfalto	Resto de suelos desnudos	33.228,25	0,419201
Suelo construido	Árboles	30.660,5	0,386807
Suelo construido	Asfalto	29.270,25	0,369267
Arbustos	Otros	27.281,75	0,344181
Mar	Olas	26.752	0,337498
Arena	Asfalto	24.688,5	0,311465
Mar	Otros	24.582,75	0,310131
Mar	Arena	18.948,5	0,23905
Mar	Asfalto	18.517,5	0,233613
Olas	Arena	13.658,75	0,172316
Suelo construido	Otros	13.473,75	0,169982
Olas	Mar	12.445	0,157004
Piscinas	Mar	12.345,5	0,155748
Arena	Suelo construido	10.270	0,129564
Suelo construido	Hierba	9.953,25	0,125568
Arbustos	Suelo construido	9.722,25	0,122654
Asfalto	Suelo construido	9.532,5	0,12026
Asfalto	Otros	9.328,75	0,11769
Árboles	Otros	8.715,25	0,10995
Árboles	Suelo construido	8.539,5	0,107733
Resto de suelos desnudos	Otros	7.151,75	0,090225
Asfalto	Mar	6.829,5	0,08616

Mar	Lago	6.579,75	0,083009
Hierba	Arbustos	6.291,25	0,079369
Lago	Arena	5.877	0,074143
Mar	Resto de suelos desnudos	5.727	0,072251
Arbustos	Arena	5.156,75	0,065056
Olas	Lago	5.034	0,063508
Hierba	Suelo construido	4.983,5	0,062871
Olas	Asfalto	4.881,25	0,061581
Árboles	Resto de suelos desnudos	4.710,25	0,059424
Asfalto	Arbustos	4.594,5	0,057963
Resto de suelos desnudos	Árboles	4.032,5	0,050873
Resto de suelos desnudos	Lago	3.805,5	0,048009
Arena	Arbustos	3.763,5	0,04748
Olas	Resto de suelos desnudos	3.503,25	0,044196
Otros	Asfalto	3.366,5	0,042471
Arena	Otros	2.967,5	0,037437
Suelo construido	Arena	2.796	0,035274
Suelo construido	Olas	2.559,5	0,03229
Arena	Mar	2.538,75	0,032028
Asfalto	Lago	2.481,5	0,031306
Olas	Suelo construido	2.386	0,030101
Arena	Lago	2.110,5	0,026626
Olas	Otros	2.046	0,025812
Otros	Arbustos	1.904,25	0,024024
Olas	Piscinas	1.847	0,023301
Árboles	Asfalto	1.640,25	0,020693
Lago	Mar	1.607	0,020274
Arbustos	Hierba	1.491,5	0,018816
Asfalto	Olas	1.421,25	0,01793
Piscinas	Olas	1.353,25	0,017072
Hierba	Resto de suelos desnudos	1.109,5	0,013997
Lago	Asfalto	1.056,25	0,013325
Piscinas	Asfalto	965,75	0,012184
Suelo construido	Piscinas	879,75	0,011099
Arbustos	Mar	799,75	0,010089
Asfalto	Piscinas	795,25	0,010033
Asfalto	Árboles	678,25	0,008557
Resto de suelos desnudos	Mar	667,25	0,008418
Otros	Árboles	646,75	0,008159
Piscinas	Otros	638,5	0,008055
Lago	Resto de suelos desnudos	626	0,007897
Suelo construido	Mar	582	0,007342
Piscinas	Suelo construido	580,5	0,007323
Resto de suelos desnudos	Hierba	504,25	0,006362
Árboles	Arena	492,25	0,00621
Mar	Arbustos	443	0,005589

Hierba	Otros	419,25	0,005289
Arena	Olas	415	0,005236
Otros	Mar	403,25	0,005087
Piscinas	Arena	401	0,005059
Arena	Árboles	392,5	0,004952
Resto de suelos desnudos	Olas	387,25	0,004885
Mar	Piscinas	350	0,004416
Hierba	Piscinas	337,5	0,004258
Piscinas	Lago	321,75	0,004059
Arbustos	Piscinas	288	0,003633
Lago	Otros	262,75	0,003315
Otros	Lago	254,25	0,003208
Mar	Suelo construido	244	0,003078
Lago	Suelo construido	231,75	0,002924
Piscinas	Resto de suelos desnudos	216,5	0,002731
Hierba	Asfalto	213	0,002687
Lago	Arbustos	191,75	0,002419
Suelo construido	Lago	185,25	0,002337
Olas	Arbustos	182,5	0,002302
Otros	Suelo construido	178,5	0,002252
Piscinas	Arbustos	173,75	0,002192
Arbustos	Lago	168,75	0,002129
Otros	Resto de suelos desnudos	162,5	0,00205
Árboles	Piscinas	114	0,001438
Lago	Olas	107,5	0,001356
Arbustos	Olas	105	0,001325
Resto de suelos desnudos	Piscinas	83,5	0,001053
Otros	Arena	74,5	0,00094
Piscinas	Árboles	53	0,000669
Árboles	Olas	32,25	0,000407
Arena	Piscinas	29,75	0,000375
Arena	Hierba	26,25	0,000331
Asfalto	Hierba	26	0,000328
Árboles	Lago	16,5	0,000208
Otros	Olas	13	0,000164
Olas	Árboles	13	0,000164
Árboles	Mar	11,5	0,000145
Olas	Hierba	10,5	0,000132
Lago	Piscinas	5	0,000063
Hierba	Mar	3,75	0,000047
Otros	Piscinas	2,5	0,000032
No clasificado	Árboles	0	0
No clasificado	Arbustos	0	0
No clasificado	Arena	0	0
No clasificado	Asfalto	0	0
No clasificado	Hierba	0	0

No clasificado	Lago	0	0
No clasificado	Mar	0	0
No clasificado	Olas	0	0
No clasificado	Otros	0	0
No clasificado	Piscinas	0	0
No clasificado	Suelo construido	0	0
No clasificado	Resto de suelos desnudos	0	0
Resto de suelos desnudos	No clasificado	0	0
Suelo construido	No clasificado	0	0
Piscinas	No clasificado	0	0
Piscinas	Hierba	0	0
Otros	No clasificado	0	0
Otros	Hierba	0	0
Olas	No clasificado	0	0
Mar	No clasificado	0	0
Mar	Árboles	0	0
Mar	Hierba	0	0
Lago	No clasificado	0	0
Lago	Árboles	0	0
Lago	Hierba	0	0
Hierba	No clasificado	0	0
Hierba	Arena	0	0
Hierba	Lago	0	0
Hierba	Olas	0	0
Asfalto	No clasificado	0	0
Arena	No clasificado	0	0
Arbustos	No clasificado	0	0
Árboles	No clasificado	0	0

