

D. AGUSTÍN J. SÁNCHEZ MEDINA, SECRETARIO DEL INSTITUTO UNIVERSITARIO DE CIENCIAS Y TECNOLOGÍAS CIBERNÉTICAS DE LA UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA

CERTIFICA,

Que la Comisión Ejecutiva del Instituto, en su sesión de fecha ocho de junio de dos mil diecisiete, tomó el acuerdo de dar el consentimiento para su tramitación a la tesis doctoral titulada "Procesado de imágenes de satélites de alta resolución para la clasificación de especies vegetales en espacios naturales protegidos", presentada por la doctoranda Dña. Anabella Medina Machín y dirigida por los doctores D. Francisco Javier Marcello Ruiz y D. Francisco Eugenio González.

Y para que así conste, y a efectos de lo previsto en el artículo 6 del Reglamento para la elaboración, tribunal, defensa y evaluación de tesis doctorales de esta Universidad, firmo la presente en Las Palmas de Gran Canaria a ocho de junio de dos mil diecisiete.

Universidad de Las Palmas de Gran Canaria Departamento de Señales y Comunicaciones

Programa de Doctorado

Cibernética y Telecomunicación



Procesado de imágenes de satélites de alta resolución para la clasificación de especies vegetales en espacios naturales protegidos.

AUTOR: Anabella Medina Machín

DIRECTORES: Dr. Francisco Javier Marcello Ruiz

Dr. Francisco Eugenio González

El Director

El Codirector

El Doctorando

Las Palmas de Gran Canaria, Junio de 2017

A mis padres por su sacrificio, a mis hermanos y mi hermana por motivarme

Y a mi pareja Javier, porque en los momentos difíciles siempre me ha apoyado. También a su familia, a los que están y a los que no por el tiempo que les he robado.

Especial atención merecen mis tutores Francisco Javier Marcello Ruiz y Francisco Eugenio González, siempre apoyándome con actitud positiva, dando buenas ideas y planteamientos resolutivos. Gracias Javier, por tu paciencia y perseverancia en sacar adelante esta Tesis Doctoral. Por tu implicación, las horas y el esfuerzo dedicado. Por los conocimientos compartidos a lo largo de estos años, y siempre con actitud humilde.

También expreso mi gratitud a los compañeros y compañeras del Grupo de Procesado de Imágenes (GPIT) de la ULPGC, con lo que he trabajado y que me han apoyado aportando su conocimiento.

A los miembros del Grupo de Investigación de Geografía Física y Medio Ambiente de la ULPGC, especialmente a Antonio I. Hernández Cordero, siempre dispuesto a ayudar y transmitir sus conocimientos. Con sus acertados consejos y su apoyo.

También quiero expresar agradecimiento a mis compañeros de trabajo de la División de Microelectrónica y Microsistemas del IUMA, por motivarme y alentarme. A Juan Antonio M. por su comprensión y sus ánimos.

Las Palmas de Gran Canaria, Junio de 2017

Este trabajo ha sido apoyado por los proyectos ARTeMISat (CGL2013-46674-R) y ARTEMISAT-2 (CTM2016-77733-R), financiados por la Agencia Estatal de Investigación (AEI) y el Fondo Europeo de Desarrollo Regional (FEDER).



ÍNDICE

1	Inti	roducción	1
	1.1	Antecedentes	1
	1 7	Objetivos	Δ
	1.2		
	1.3	Estructura de la memoria	8
2	Téc	nicas de Fusión de imágenes	11
	2.1	Introducción	12
	, ,	Estado del arte en técnicas de fusión	15
	2.2		15
	2.2.		. 15
	2.2.	2 Metodo InS	. 10
	2.2.	3 Metodo de fusion basado en el PCA	. 18
	2.2.	4 Algoritmo TWD de Mallat	. 19
	2.2.	5 Algoritmo A trous	. 22
	2.3	Evaluación de las técnicas de fusión de imágenes de alta resolución	25
	2.3.	1 Coeficiente de correlación	. 25
	2.3.	2 Índice Zhou	. 26
	2.3.	3 ERGAS	. 26
	2.3.	4 Structural Similarity Index (SSIM)	. 28
	2.3.	5 Universal image quality index	. 29
	2.4	Desultados de la susluación de las tómicos de fusión	20
	2.4		30
	2.4.	1 Fuence de información	. 30
	2.4.	2 Evaluación visual de los diferentes metodos de fusión	. 34
	2.4.	3 Evaluación cuantitativa de los algoritmos de fusión basada en metricas de calidad espacial	 20
	2.4	4 Fuelue sión executivativa de los eleccitanes de fusión becede en mótules de celidad especta	39
	2.4.	4 Evaluación cuantitativa de los algoritmos de fusión basada en métricas de calidad espectra	эг
	~ .		. 44
	2.4.	5 Evaluación de los algoritmos de fusión basada en una imagen sintetica	. 50
	2.5	Resumen	54
3	Cor	rrecciones de las imágenes de alta resolución espacial	57
5	001		57
	3.1	Fuente de información	58
	3.1.	1 Satélite WorldView-2	. 58
	3.2	Corrección radiométrica de imágenes	61
	3.2.	1 Desaparición de píxeles o líneas	. 61
	3.2	Corrección radiométrica relativa	. 61
	3.2.	3 Obtención de la radiancia ToA	63
	3.2.	4 Caracterización de la irradiancia solar y obtención del narámetro físico, reflectancia $To \Delta$	63
	2.2.	5 Determinación de la geometría del Sol	. 55
	ງ.∠. ຊາ	6 Distancia Tierra-Sol	
	ב. בי	7 Angulo conital solar	
	2.2. 2.2	 Aliguio cellital solal Pofloctancia a la altura de la atmósfera (TeA) 	. 00 66
	з.Z.	o nenectancia a la altura de la attitusiera (TUA)	. 00

:	3.3	Corrección atmosférica de las imágenes	67
	3.3.1	Modelado de la influencia de la atmósfera	68
	3.3.2	2 Estado del arte en técnicas de corrección atmosférica	69
	3.3.3	Metodología de evaluación de la corrección atmosférica	76
	3.3.4	Resultados de la evaluación de las técnicas de corrección atmosférica	79
	3.4	Corrección geométrica de las imágenes	84
	3.4.1	Co-registro de imágenes	85
	3.4.2	2 Metodología de Evaluación de los resultados del co-regitro	86
	3.4.3	Resultados del procedimiento de co-registro de imágenes	86
	3.5	Resumen	90
4	Clas	sificación de imágenes de satélites de alta resolución	91
4	4.1	Área de estudio: Reserva Natural Especial de las Dunas de Maspalomas	92
	4.1.1	Especies vegetales	92
	4.1.2	2 Datos disponibles	94
	4.2	Clasificación de imágenes multiespectrales de alta resolución	99
	4.2.1	Estado del arte de técnicas de clasificación basadas en desmezclado espectral	
	4.2.2	2 Estado del arte de técnicas de clasificación supervisada	
	4.2.3	Fase de entrenamiento	
	4.2.4	Estudio de la separabilidad de las clases	
	4.2.5	Evaluación de la precisión de imágenes clasificadas	
	4.2.6	Extracción de información espectral derivada	
	4.2.7	7 Extracción de información espacial derivada	112
	4.2.8	8 Postclasificación	113
4	4.3	Metodología para la generación de cartografía de especies vegetales	114
4	4.4	Resultados de la clasificación de especies vegetales en la Reserva Natural Espec	ial de
I	las Du	nas de Maspalomas	119
	4.4.1	Resultados de Clasificación SVM sobre las bandas WV-2	121
	4.4.2	2 Resultados de la Clasificación SVM incorporando información espectral	124
	4.4.3	Resultados de la Clasificación SVM incorporando información espacial	125
	4.4.4	Resultados de la Clasificación SVM integrando información espacial y espectral	126
	4.4.5	Resultados de la Clasificación SVM sobre mapas de abundancia	130
4	4.5	Clasificación SVM sobre Imagen Fusionada À trous	135
4	4.6	Resumen	141
5	Con	clusiones	143
ļ	5.1	Principales contribuciones	144
ļ	5.2	Líneas futuras de investigación	147
ļ	5.3	Listado de publicaciones	148
6	List	a de acrónimos	151
7	Bibl	liografía	155

ÍNDICE DE FIGURAS

Figura 1. Localización y vista general de la zona de estudio	. 2
Figura 2. Principales comunidades vegetales de Maspalomas: (a) Traganum moquini, (b) Suaeda mollis, (c, Launaea arborescens, (d) Zygophyllum fontanesii, (e) Tamarix canariensis y (f) Juncus acutus. Fuente [6]) . 3
Figura 3. Componentes analizados en el desarrollo de la metodología de clasificación sobre las bandas MS originales o fusionadas	. 5
Figura 4. Imagen mutiespectral original (derecha) e imagen fusionada (izquierda)	. 6
Figura 5. Satélites comerciales DigitalGlobe de muy alta resolución espacial [7]	12
Figura 6. Teledetección pasiva y activa	12
Figura 7. Espectro electromagnético. Fuente [9]	13
Figura 8. Diagrama de bloques genérico del proceso de fusión a nivel de píxel entre las bandas MS y PAN. Fuente [15]	14
Figura 9. Esquema de fusión basada en la transformada IHS. Fuente [15]	17
Figura 10. Esquema de fusión basado en la transformada PCA. Fuente [15]	19
Figura 11. Representación piramidal de algoritmos diezmados	20
Figura 12. Fase de análisis de la implementación práctica del algoritmo diezmado de Mallat	21
Figura 13. Fase de síntesis de la implementación práctica del algoritmo diezmado de Mallat	21
Figura 14. Representación del paralepípedo de descomposición del algoritmo À trous	22
Figura 15. Esquema de fusión basado en la transformada wavelet aditivo À trous. Fuente [15]	23
Figura 16. Esquema de fusión aditivo basado en la transformada wavelet À trous sobre I. Fuente [15]	24
Figura 17. Esquema de fusión aditivo basado en la transformada wavelet À trous sobre la CP1. Fuente [15]	l. 24
Figura 18. Respuesta espectral del sensor embarcado en la plataforma GeoEye-1	31
Figura 19. Base de datos de imágenes del satélite GeoEye-1 sobre diferentes coberturas de la superficie terrestre (MS arriba y PAN debajo)	34
Figura 20. Imágenes fusionadas para una zona de cobertura urbana	35
Figura 21. Imágenes fusionadas con detalle en el borde de una presa de agua	36
Figura 22. Imágenes fusionadas para una cobertura forestal	37
Figura 23. Imágenes fusionadas sobre una cobertura de vegetación	38
Figura 24. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura agrícola	41
Figura 25. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de forestal	41
Figura 26. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura costera.	42

Figura 27. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de agua embalsada42
Figura 28. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de Dunas42
Figura 29. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de Dunas43
Figura 30. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura urbana
Figura 31. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de vegetación43
Figura 32. Índices de calidad espectral para una cobertura agrícola
Figura 33. Índices de calidad espectral para una cobertura forestal
Figura 34. Índices de calidad espectral para una cobertura costera47
Figura 35. Índices de calidad espectral para una cobertura de agua embalsada48
Figura 36. Índices de calidad espectral para una cobertura de Dunas
Figura 37. Índices de calidad espectral para una cobertura de Dunas
Figura 38. Índices de calidad espectral para una cobertura urbana50
Figura 39. Índices de calidad espectral para una cobertura de vegetación50
Figura 40. Imagen sintética fusionada por diferentes métodos: MS original, PAN, FUS À trous, FUS À trous AWI, FUS À trous AWPC, FUS TWD, FUS Brovey, eIHS, IHS, PCA (de arriba a derecha)
Figura 41. Índices de calidad espacial sobre las imágenes fusionadas sintéticas53
Figura 42. Índices de calidad espectral sobre las imágenes fusionadas sintéticas
Figura 43. Diagrama de correcciones radiométrica, geométricas y atmosféricas
Figura 44. (a) Efecto del bandeado de la imagen de teledetección y (b) imagen corregida. Fuente: Digitalglobe
Figura 45. Curva de irradiancia espectral solar estándar WRC. Fuente: NASA
Figura 46. Transmisividad de la atmósfera a distintas longitudes de onda. Fuente [58]68
Figura 47. Modelo de influencia atmosférica69
Figura 48. Caminos A, B, y C mediante los cuales los fotones se desplazan hacia el sensor remoto71
Figura 49. Medias de diferentes librerías de endmembers seleccionados sobre diferentes sensores y diferente número de endmembers. Fuente [61]72
Figura 50. Mapa de puntos analizados sobre sustratos de suelo desnudo y de vegetación76
Figura 51. Radiómetro empleado en la campaña de campo77
Figura 52. Reflectividades de las coberturas medidas: (a) espectro-radiómetro (b) simuladas a las bandas del WV-2
Figura 53. Firmas espectrales comparando los datos in-situ y aplicando distintos algoritmos de corrección atmosférica sobre los puntos de vegetación

Figura 54. Firmas espectrales comparando los datos in-situ y aplicando distintos algoritmos de corrección atmosférica sobre los puntos de suelo desnudo
Figura 55. Puntos de control utilizados para el co-registro: (a) Imagen del 4 de junio 2015 (b) Imagen del 17 de enero 2013
Figura 56. Desplazamiento en un punto de referencia entre imagen base e imagen esclava
Figura 57. Punto de control 1 sobre la imagen base (izquierda) y sobre imagen esclava antes del co-registro (arriba e izquierda) y después del co-registro (abajo derecha)
Figura 58. Punto de control 2 sobre la imagen base (izquierda) y sobre imagen esclava antes del co-registro (arriba y derecha) y después del co-registro (abajo derecha)
Figura 59. Localización y vista general del área de estudio. Fuente [1]
Figura 60. Mapa de vegetación de Maspalomas. Fuente [6]
Figura 61. Comunidades vegetales de Maspalomas analizados: (a) Traganum moquini, (b) Suaeda mollis, (c) Launaea arborescens (d) Zygophyllum fontanesii, (e) Tamarix canariensis (f) Juncus acutus
Figura 62. Adquisición de firmas espectrales de plantas mediante espectro-radiometría de campo. Fuente [84]
Figura 63. Firma espectral (media ± desviación estándar) con espectro-radiometría de campo para cada comunidad vegetal de Maspalomas: (a) Traganum moquini, (b) Suaeda mollis, (c) Launaea arborescens (d) Zygophyllum fontanesii, (e) Tamarix canariensis y (f) Juncus acutus
Figura 64. Imagen WV-2 del 4 de junio de 2015 (composición RGB)97
Figura 65. Imagen WV-2 del 17 de enero de 2013 (composición RGB)97
Figura 66. Localización de los puntos de muestreo en la campaña de campo, sobre imagen WorldView-2, para cada comunidad vegetal de Maspalomas y foto en el momento de medida: (a) Traganum moquini, (b) Suaeda mollis, (c) Launaea arborecens (d) Zygophyllum fontanesii, (e) Tamarix canariensis y (f) Juncus acutus
Figura 67. Modelo de mezcla lineal. Fuente [90]
Figura 68. Modelo de mezcla no lineal [90]
Figura 69. Hiperplano b que separa dos clases maximizando el margen
Figura 70. Respuesta espectral de las especies vegetales a partir de: (a) datos del radiómetro de campo y (b) sobre la imagen WV-2
Figura 71. Estructura de una matriz de confusión108
Figura 72. Respuesta espectral de la vegetación sana
Figura 73. Filtrado postclasificación majority. Fuente [8]
Figura 74. Clasificación SVM sobre las bandas MS
Figura 75. Clasificación SVM sobre la composición de diferentes VIs
Figura 76. Clasificación SVM sobre la composición de bandas MS junto con cada índice de vegetación por separado
Figura 77. Clasificación SVM sobre la composición de bandas MS junto con cada mapa de textura por separado

Figura 78. Metodología de clasificación SVM incorporando información espacial y espectral118
Figura 79. Clasificación SVM sobre mapas de abundancia, a partir del desmezclado lineal con endmembers obtenidos del espectro-radiómetro de campo118
Figura 80. Clasificación SVM sobre mapas de abundancia, a partir del desmezclado lineal con endmembers extraídos de la imagen WV-2
Figura 81. Esquema de medida de la exactitud del clasificador
Figura 82. Regiones de entrenamiento sobre la imagen WV-2120
Figura 83. Regiones de test sobre la imagen WV-2121
Figura 84. Porcentaje de aciertos para cada especie, tras la clasificación SVM sobre todas las bandas WV-2.
Figura 85. Clasificación SVM sobre bandas multiespectrales de la imagen WV-2 de 4 de junio 2015123
Figura 86. Porcentaje de aciertos para cada especie, tras la clasificación SVM sobre todas las bandas WV-2 y sobre los índices de vegetación (VIs)
Figura 87. Exactitud global del clasificador añadiendo a las bandas WV-2 diferentes índices de vegetación por separado
Figura 88. Exactitud global del clasificador incluyendo información espacial a las bandas WV-2126
Figura 89. Exactitud global del clasificador combinando información espectral y espacial en el clasificador.
Figura 90. Porcentaje de aciertos, comparando metodología inicial con la metodología óptima para la imagen de 4 de junio de 2015 y 17 de enero de 2013127
Figura 91. Clasificación SVM óptima sobre la imagen del 4 de junio de 2015128
Figura 92. Clasificación SVM óptima sobre la imagen de enero de 2013128
Figura 93. Comparativa de los porcentajes de aciertos incluyendo postprocesado majority para la imagen del 4 de junio 2015
Figura 94. Comparativa de los porcentajes de aciertos incluyendo postprocesado majority para la imagen del 17 de enero 2013
Figura 95. Clasificación SVM óptima con filtrado majority sobre la imagen del 4 de junio de 2015130
Figura 96. Clasificación SVM óptima con filtrado majority sobre la imagen del 17 de enero de 2013130
Figura 97. Mapas de abundancia, en escala de color, sobre la composición RGB de la imagen WV-2132
Figura 98. Clasificación SVM sobre mapas de abundancia a partir de las reflectividades del radiómetro de campo: (a) Imagen del 4 de junio de 2015 y (b) Imagen del 17 de enero de 2013
Figura 99. Clasificación SVM sobre mapas de abundancia a partir de las reflectividades extraídas de la imagen WV-2: (a) Imagen del 4 de junio de 2015 y (b) Imagen del 17 de enero de 2013
Figura 100. Clasificación SVM con majority sobre mapas de abundancia a partir de las reflectividades del radiómetro: (a) Imagen del 4 de junio de 2015 y (b) Imagen del 17 de enero de 2013
Figura 101. Comparativa de la exactitud global del clasificador sobre mapas de abundancia
Figura 102. Comparativa entre la imagen multiespectral original (izquierda) y la imagen fusionada (derecha) sobre diferentes áreas de la Reserva Natural de las Dunas de Maspalomas

Figura 103. Clasificación SVM sobre la imagen fusionada del 17 de enero de 2013 136
Figura 104. Clasificación SVM sobre la imagen fusionada del 4 de junio de 2015
Figura 105. Clasificación SVM con la configuración óptima: (a) Imagen MS original (b) Imagen fusionada.137
Figura 106. Exactitud del clasificador SVM comparando con la imagen fusionada
Figura 107. Exactitud del clasificador SVM comparando con la imagen fusionada aplicando filtro majority.
Figura 108. Clasificación SVM sobre la imagen fusionada de junio 2015 con filtro majority
Figura 109. Clasificación SVM sobre la imagen fusionada de enero 2013 con filtro majority
Figura 110. Porcentajes de aciertos para la metodología óptima comparando con la imagen fusionada 139
Figura 111. Porcentajes de aciertos para la metodología comparando con la imagen fusionada, aplicando filtrado majority
Figura 112. Metodología óptima de clasificación de especies vegetales sobre la RNE de Maspalomas 140

ÍNDICE DE TABLAS

Tabla 1. Características del satélite GeoEye-1
Tabla 2. Análisis visual de la diferencia espacial entre la imagen PAN y fusionadas sobre una cobertura agrícola para las diferentes componentes: I (fila 1), R (fila 2), G (fila 3), B (fila 4)
Tabla 3. Análisis visual de la diferencia espacial entre la imagen PAN y fusionadas sobre una cobertura forestal para las diferentes componentes: I (fila 1), R (fila 2), G (fila 3), B (fila 4)
Tabla 4. Análisis visual de la calidad espectral de las componentes R-G-B (filas 1-2-3) de las imágenes fusionadas sobre una cobertura de agrícola
Tabla 5. Análisis visual de la calidad espectral de las componentes R-G-B (filas 1-2-3) de las imágenes fusionadas sobre una cobertura de forestal
Tabla 6. Análisis visual de la calidad espectral de las componentes R-G-B (fila 1-2-3) de las imágenes fusionadas sintéticas
Tabla 7. Análisis visual del detalle espacial de las diferentes componentes de las imágenes fusionadas sintéticas: I (fila1), R (fila 2), G (fila 3) y B (fila 4)
Tabla 8. Características del satélite WorldView-2
Tabla 9. Irradiancia solar espectral promedio para las bandas del WorldView-264
Tabla 10. Características de los puntos seleccionados. 77
Tabla 11. Parametrización de los modelos atmosféricos. 78
Tabla 12. RMSE entre los valores de reflectividad observados y los corregidos atmosféricamente para todos los puntos de vegetación y suelo desnudo
Tabla 13. BIAS entre los valores de reflectividad observados y los corregidos atmosféricamente para todos los puntos de vegetación y suelo desnudo
Tabla 14. Error del proceso de co-registro
Tabla 15. Matriz de separabilidad de las clases de entrenamiento
Tabla 16. Matriz de separabilidad de las clases de test
Tabla 17. Medidas de exactitud de la clasificación SVM sobre las bandas WV-2 para la imagen de junio 2015.
Tabla 18. Matriz de confusión sobre la clasificación SVM de las bandas de la imagen de 2015 (en valores porcentuales)
Tabla 19. Medidas de exactitud de la clasificación SVM sobre las bandas WV-2 y sobre los índices de vegetación (VIs) para la imagen del 4 de junio 2015124
Tabla 20. Precisión de la clasificación SVM incluyendo etapa de postclasificación
Tabla 21. Precisión de la clasificación SVM incluyendo etapa de postclasificación
Tabla 22. Medidas de precisión en la clasificación SVM sobre mapas de abundancia

Capítulo 1

Introducción

1.1 Antecedentes

Actualmente, la conservación del medioambiente es un elemento clave dada la relevancia que tienen los ecosistemas naturales para el desarrollo humano y el bienestar. Las instituciones encargadas de la gestión y conservación de áreas naturales protegidas consideran cada vez más prioritario el seguimiento ecológico de las formaciones vegetales.

En este contexto, a escala local, se requiere de datos con gran detalle del estado de los hábitats. Así, la necesidad de producir cartografías de vegetación se presenta como un elemento fundamental para la gestión de los ecosistemas y preservación de la diversidad biológica. Además, realizar el estudio y seguimiento de la distribución espacial a nivel de especie vegetal puede suponer un esfuerzo considerable. Para ello, la teledetección espacial de alta resolución es una tecnología en auge al servicio de la gestión y vigilancia de los recursos naturales.

En el marco de esta *Tesis Doctoral*, se pretende procesar imágenes de satélites de alta resolución para clasificar especies vegetales de interés en ecosistemas naturales singulares y vulnerables como la Reserva Natural Especial (RNE) de las Dunas de Maspalomas. Esta zona protegida está situada en el extremo sur de la isla de Gran Canaria (Figura 1), siendo uno de los escasos ecosistemas dunares que aún perviven en Canarias, pero que se está degradado debido a la elevada presión antrópica, que durante décadas, ha ocasionado el turismo.



Figura 1. Localización y vista general de la zona de estudio.

Este espacio está experimentando una intensa transformación y diversos estudios manifiestan que las geoformas dunares tienden a estabilizarse debido a factores externos que rodean la zona circundante [1]. Esto supone una oportunidad a la vegetación para extenderse, proceso que incide más en la estabilización de los sedimentos. Según el Plan Director de la Reserva Natural Especial de las Dunas de Maspalomas [2], este ecosistema alberga unas cincuenta especies de flores vasculares, algunas de ellas protegidas. El campo de Dunas posee una significativa diversidad de comunidades vegetales, las más abundantes se muestran en la Figura 2. Por ejemplo, muchas Dunas se han estabilizado tras ser colonizadas por ejemplares de Tamarix canariensis. Esto encadena otros factores, que favorecen la colonización de otras especies vegetales, como la Suaeda mollis, que están experimentando una notable expansión al presentar mejor adaptación al nuevo hábitat. En consecuencia, se está produciendo un incremento generalizado de la cobertura vegetal, aunque algunas comunidades vegetales están sufriendo una reducción o desaparición. Es el caso de la comunidad de Traganum moquini que ha ido desapareciendo actualmente de ciertas zonas, debido al incremento de las tasas de desplazamiento de las Dunas, que se ha producido como consecuencia de la alteración del flujo eólico inducido por la urbanización de la terraza alta del Inglés.

Las comunidades vegetales están sujetas a variabilidad, y su presencia y abundancia puede variar debido a gradientes ambientales, y la tasa de reproducción y crecimiento. Estas alteraciones referentes a las comunidades vegetales ponen de manifiesto cambios y perturbaciones en el sistema de Dunas de Maspalomas, de ahí el interés que implica tener un inventario detallado de su distribución, como base para la adecuada gestión de este espacio natural protegido.

La cartografía de la vegetación de Maspalomas existente en la actualidad se ha realizado por el Departamento de Geografía de la Universidad de Las Palmas de Gran Canaria (ULPGC) [3], utilizando métodos manuales, basados en la utilización de tecnologías de la información geográfica y el trabajo de campo, consistente en la fotointerpretación de ortofotos digitales, la digitalización de las comunidades vegetales utilizando sistemas de información geográfica y en la realización de inventarios de vegetación [4] [5]. Sin embargo, la actualización de la cartografía a partir de métodos tradicionales de seguimiento es costosa y requiere un tiempo considerable, además es destacable la dificultad de su automatización y sistematización. En este sentido, la teledetección se presenta como una herramienta clave y en auge gracias al desarrollo tecnológico y el avance en las técnicas de procesado. De hecho, actualmente, la teledetección es la mayor fuente de información espacial sobre el estado de las superficies naturales, alcanzando en los últimos años un papel relevante en el estudio de la estructura y el funcionamiento de las formaciones vegetales. Así, en esta *Tesis Doctoral* se pretende desarrollar una metodología que permita la clasificación de especies vegetales a partir de imágenes de satélites de muy alta resolución.

(c)



(a)

(d) (e) (f)

Figura 2. Principales comunidades vegetales de Maspalomas: (a) Traganum moquini, (b) Suaeda mollis, (c) Launaea arborescens, (d) Zygophyllum fontanesii, (e) Tamarix canariensis y (f) Juncus acutus. Fuente [6].

Desde la liberación de la teledetección espacial para usos civiles, reservada hasta entonces para uso militar, la comercialización de datos de satélite ha crecido de forma exponencial. En la actualidad existen cientos de satélites en el espacio observando la Tierra. Estas plataformas espaciales pueden considerarse una fuente abundante y precisa de datos, que proporcionan imágenes digitales que contienen cada vez mayor nivel de detalle e información. Dichas imágenes se captan en varias bandas del espectro electromagnético y con diferentes resoluciones espaciales, radiométricas y temporales.

La resolución espacial hace referencia a la capacidad de discriminación de objetos sobre una escena, mientras que la resolución espectral hace referencia a la capacidad del sensor de captar la energía reflejada a diferentes frecuencias o longitudes de onda y la resolución temporal se refiere a la frecuencia con la que se obtienen los datos.

Debido a las limitaciones hardware de los sensores, las imágenes obtenidas con altas resoluciones espaciales tienden a tener bajas resoluciones espectrales y viceversa. Para solventar este problema, muchos de los satélites actuales disponen a bordo de dos tipos de sensores, uno pancromático y otro multiespectral. El sensor multiespectral capta datos en varias bandas estrechas sobre un campo de visión amplio (baja resolución espacial), mientras que el sensor pancromático capta señales en una banda espectral ancha pero sobre un campo de visión pequeño, proporcionando imágenes de mayor resolución espacial pero peor espectral.

En el marco de esta Tesis Doctoral, una de las herramientas de procesado de mayor interés, son las técnicas de fusión de imágenes provenientes de diferentes sensores, que permiten obtener imágenes de varias bandas del espectro electromagnético con un gran nivel de detalle espacial. El principal objetivo de la fusión de imágenes es facilitar la interpretación y delimitación de diferentes objetos y estructuras sobre imágenes multiespectrales de teledetección.

Por otro lado, las imágenes distribuidas por los proveedores están formadas por unos datos numéricos enteros que representan a los valores de radiancia codificados digitalmente. Sin embargo, la radiancia registrada por el sensor no es una representación exacta de la radiancia emitida por las coberturas de la superficie terrestre. Esto significa que la imagen adquirida en formato numérico presenta una serie de anomalías con respecto a la escena real detectada. Estas anomalías están en la localización y en los niveles digitales de los píxeles que componen la matriz de datos. Por lo tanto, es necesario llevar a cabo una serie de operaciones de corrección que pretenden minimizar estas alteraciones. Finalmente, como resultado se obtiene una imagen corregida que es lo más próxima posible, geométrica y radiométricamente, a la verdadera energía radiante y características espaciales del área de estudio en el momento de captación de los datos. Además, entre el sensor y la superficie terrestre se interpone la atmósfera, que interactúa de formas diversas con el flujo radiante, produciendo modificaciones en la radiación originalmente propagada entre la cubierta terrestre y el sensor. Por lo tanto, es otro factor de considerable importancia que hay que tener en cuenta en la etapa de correcciones.

Una vez aplicadas estas técnicas de preprocesado, ya se dispone de las bandas espectrales mejoradas y corregidas para abordar el tratamiento de los datos para la generación de los productos terrestres que permitirá llevar a cabo el análisis exhaustivo de los recursos vegetales. Así, los principales procesados se orientan a la generación de índices multiespectrales o a la aplicación de algoritmos eficientes de clasificación que nos permitan obtener los mapas temáticos de interés.

A modo de síntesis, las imágenes de los satélites de teledetección necesitan ser previamente procesadas para poder generar productos útiles para la gestión de los recursos naturales. Este aspecto es de gran importancia, pero también de gran complejidad y la mayoría de las etapas suponen retos de investigación en continuo desarrollo.

Así, para cumplir el objetivo final de esta *Tesis Doctoral*, se llevará a cabo el desarrollo y análisis de diferentes técnicas de procesado sobre las imágenes de teledetección, con objeto de proponer una metodología fiable de clasificación de especies vegetales sobre la Reserva Natural Espacial de las Dunas de Maspalomas. En particular, aplicando la metodología propuesta se obtendrán productos temáticos que faciliten la gestión de este entorno, que constituye actualmente uno de los sistemas activos más importantes de Canarias y que está sufriendo alteraciones considerables, en gran parte debido a la intesta actividad turística de los alrededores.

En el marco de esta *Tesis Doctoral* van a ser objeto de estudio imágenes procedentes de sensores a bordo de dos plataformas distintas de muy alta resolución: *GeoEye-1* y *WorldView-2*. El primero fue lanzado en 2008, proporcionando información en una imagen multiespectral (MS) en cuatro bandas con una resolución de 2 m y una imagen pancromática (PAN) con una resolución de 0.5 m. Por otro lado, el lanzamiento del satélite *WorldView-2* (en lo sucesivo WV-2), a finales del 2009, aportó un nuevo hito en el estado del arte de los satélites de muy alta resolución, proporcionando una resolución espacial algo mejor pero además, en ocho canales multiespectrales, siendo ésta una cantidad de canales inusualmente alta para este tipo de satélites.

1.2 Objetivos

El objetivo de esta *Tesis Doctoral* consiste en el desarrollo de una metodología completa para la clasificación de especies vegetales en la Reserva Natural de las Dunas de Maspalomas a partir de imágenes de satélites de muy alta resolución. Para el desarrollo de esta metodología se analizan y evalúan todas las etapas de procesado necesarias para que la información obtenida represente la verdadera reflectividad de la superficie, eliminando perturbaciones asociadas a las condiciones de captación de la imagen y de la atmósfera. Además, se analizan diferentes técnicas de fusión de información procedentes de diferentes sensores, PAN y MS, con la intención de evaluar su influencia en los resultados de la clasificación. Finalmente, se aborda la etapa de clasificación donde se

evalúan diferentes estrategias a partir de algoritmos de aprendizaje supervisado y de técnicas de desmezclado lineal.

El desarrollo de la metodología propuesta está vinculada a la consecución de los siguientes objetivos:

- Implementación y evaluación de algoritmos de fusión de imágenes para mejorar la calidad espacial de los datos multiespectrales originales minimizando la distorsión espectral introducida.
- Evaluación y validación de algoritmos de corrección atmosférica para eliminar los efectos de la atmósfera, que provocan la absorción, la dispersión y la refracción de la energía en las diferentes bandas del espectro.
- Aplicación de algoritmos de co-registro de imágenes, para alinear geométricamente imágenes con diferentes geometrías de adquisición.
- Detección y clasificación de especies vegetales aplicando técnicas de clasificación supervisadas sobre imágenes de muy alta resolución espacial, integrando información espectral y espacial al clasificador con objeto de mejorar su capacidad de discriminación.
- Detección y clasificación de especies vegetales integrando información obtenida a partir de técnicas de análisis de mezcla lineal sobre imágenes de muy alta resolución espacial.
- Desarrollo de una metodología completa para la generación de cartografía de especies vegetales en la Reserva Natural de las Dunas de Maspalomas y su aplicación en imágenes multiespectrales.

La Figura 3 muestra de forma resumida todos los procesados analizados en los objetivos enumerados y que intervienen para el desarrollo de la metodología.



Figura 3. Componentes analizados en el desarrollo de la metodología de clasificación sobre las bandas MS originales o fusionadas.

Evaluación de técnicas de fusión de imágenes

La fusión se puede realizar a nivel de píxel, a nivel de objetos o a nivel de decisión. En esta *Tesis Doctoral* nos centraremos únicamente en la fusión a nivel de píxel. Estas técnicas de fusión a nivel de píxel (*pansharpening*) suelen aplicarse sobre los niveles digitales de la imagen, a las que se les ha aplicado previamente unas correcciones radiométricas y geométricas básicas antes de ser distribuidas. Como ya se ha adelantado anteriormente, el objetivo de la fusión es integrar la

información de los sensores PAN y MS que llevan a bordo los satélites de alta resolución, para generar una nueva imagen mejorada.

La mayoría de los sensores ópticos proporcionan una imagen multiespectral (varias bandas del espectro) y una imagen pancromática (una banda a mejor resolución espacial) de la misma escena registradas simultáneamente. Mediante técnicas de *pansharpening* la resolución espacial de la imagen multiespectral se puede mejorar incorporando la información de la imagen pancromática.

Existen una amplia variedad de técnicas de fusión a nivel de píxel. Las más populares están basadas en operaciones aritméticas y en sustitución de componentes a partir de transformadas como el Análisis de Componentes Principales (*PCA, Principal Component Analisys*) o la transformada Intensidad-Brillo-Saturación (*IHS, Intensity-Hue-Saturation*). Otras técnicas más evolucionadas, que intentan solventar las limitaciones de los métodos anteriores e introducen menor distorsión espectral, están basadas en técnicas de Análisis Multiresolución (*MRA, Multiresolution Analysis*).

En esta *Tesis Doctoral* se aborda el desarrollo y análisis de diferentes técnicas de fusión de imágenes. Se evalúan los efectos, a nivel espacial y espectral, que implica la fusión sobre los elementos de la superficie terrestre. Tras el estudio, se está en disposición de identificar el método más apropiado para integrarlo en la metodología de clasificación. Esta evaluación se basará en medidas cualitativas, donde se analizan de forma visual las imágenes resultantes, y en medidas cuantitativas, a partir del cómputo de diferentes índices que miden la calidad espacial y espectral de la imagen fusionada.

La Figura 4 muestra un ejemplo del resultado obtenido tras aplicar una técnica de fusión sobre una imagen *WorldView-2*, donde se aprecia la mejora espacial lograda.



Figura 4. Imagen mutiespectral original (derecha) e imagen fusionada (izquierda).

Pre-procesado de imágenes de satélites de alta resolución

Las imágenes de los satélites de teledetección espacial necesitan ser previamente procesadas para poder interpretar con fiabilidad la información que representan. Las imágenes son distribuidas con una serie de correcciones radiométrica y geométricas básicas. Estas correcciones se centran en eliminar los defectos debidos al propio sensor y que están relacionados con los niveles digitales de la imagen y la localización de los píxeles sobre la misma, asociados estos últimos al movimiento del sensor. Además, es necesario realizar otras correcciones adicionales, de tal manera que los píxeles de la imagen representen la verdadera energía reflejada de la superficie terrestre, sin verse afectada ésta por fenómenos externos, como pueden ser las condiciones de iluminación en el momento de captación de la imagen o la atmósfera. Estas correcciones son cruciales si se quieren comparar

imágenes obtenidas en distintos instantes de tiempo, pues se pretende que la metodología de clasificación sea de aplicación automática, sistemática y fiable sobre diferentes imágenes. Asimismo, si se desea hacer un estudio multitemporal o multisensor, las imágenes deben ser coregistradas, es decir, es necesario alinear geométricamente ambas imágenes.

Por lo tanto, el objetivo principal que se plantea en este apartado es establecer una serie de correcciones para extraer parámetros físicos de la superficie terrestre, de tal forma que la información obtenida sea independiente de las condiciones de adquisición de la imagen. A partir de estas imágenes ya es posible generar una clasificación fiable de información basada en la respuesta espectral de las coberturas terrestres.

Un aspecto clave de esta fase son las complejas correcciones atmosféricas que tienen como objetivo eliminar los efectos de absorción y dispersión que introduce la atmósfera en la radiación registrada por el sensor remoto. En las últimas décadas se han desarrollado diferentes métodos, unos basados en las características de la propia imagen como el *DOS* y *QUAC*, y otros basados en el modelado de transferencia radiativa como el *6S, ATCOR* y *FLAASH*. A lo largo de esta *Tesis Doctoral* se realizará un exhaustivo estudio de los diferentes algoritmos, comparando las respuestas espectrales de diferentes puntos sobre la imagen WV-2 y las medidas *in-situ* obtenidas, a partir de un espectro-radiómetro, durante una campaña de campo. El algoritmo de corrección atmosférica más adecuado será integrado dentro de la metodología de clasificación.

Clasificación de especies vegetales en la Reserva Natural Especial de las Dunas de Maspalomas

Una vez aplicadas las diferentes técnicas de procesado, ya se dispone de las bandas espectrales adecuadas para abordar la clasificación de las diferentes especies vegetales de interés sobre la Reserva Natural de las Dunas de Maspalomas.

Para esta etapa se dispone también de datos *in-situ* obtenidos durante una campaña de campo en dicha área natural protegida. Estos datos son cruciales para caracterizar las comunidades vegetales, así como para entrenar y validar los algoritmos de clasificación. Recordar que las alteraciones en las comunidades vegetales constituyen indicadores de cambios y perturbaciones que está experimentando el espacio geográfico. De ahí el interés que presenta disponer de una cartografía detallada de las especies vegetales sobre la zona.

El objetivo principal en esta fase de la *Tesis Doctoral* es hacer una evaluación exhaustiva de las técnicas más novedosas de clasificación para establecer una metodología que permita la generación de mapas temáticos de especies vegetales sobre la zona de estudio indicada. Esta metodología debe incluir todas las etapas de procesado previas para alcanzar de forma eficiente y robusta la identificación de las especies.

Se realiza un análisis del estado del arte de las diferentes técnicas de clasificación aplicadas sobre las imágenes de alta resolución. Los métodos de clasificación se pueden dividir en diferentes categorías. Atendiendo a la disponibilidad de muestras de entrenamiento, se puede hablar de técnicas supervisadas y no supervisadas. Las técnicas supervisadas hacen uso de un conjunto de muestras denominadas muestras de entrenamiento, que son seleccionadas por un usuario experto. En contraste, las no supervisadas, también conocidas como *clustering,* no hacen uso de muestras de entrenamiento, se basan en indicar un conjunto de clases seleccionados por el usuario o de forma arbitraria. Para asociar un píxel a cada clase se seleccionan unos criterios de similitud. Entre los métodos supervisados existe una amplia literatura, los métodos más conocidos son el *k-means, ISODATA* y *Fuzzy Cmeans.* Por otro lado, también existen otras técnicas semi-supervisadas que hacen uso tanto de muestras de entrenamiento como de datos no etiquetados. Existen otras categorizaciones para los clasificadores, atendiendo a la distribución de los datos de entrada, si se

asume conocida la función densidad de probabilidad se habla de clasificadores paramétricos, en caso contrario son clasificadores no paramétricos.

Puesto que tenemos conocimiento del terreno, obtenido a través de las medidas de campo y la ayuda de un técnico experto conocedor de la zona, en esta *Tesis Doctoral* se recurre a la implementación y evaluación de técnicas supervisadas. Los clasificadores supervisados más utilizados en teledetección están basados en redes neuronales, árboles de decisión y clasificadores de máxima probabilidad. En los últimos años han ganado especial importancia otras técnicas, como las basadas en máquinas de vectores soporte (*SVM*), menos sensibles a la dimensionalidad de los datos y a la calidad y cantidad de las regiones de entrenamiento. Por lo tanto, en esta *Tesis Doctoral* nos centraremos en estas técnicas.

Otras técnicas que también están adquiriendo importancia con el aumento de la resolución espectral de los sensores, son las basadas en el análisis de mezcla lineal, que buscan identificar las clases presentes en cada píxel de la imagen y su probabilidad o abundancia. Aunque son generalmente aplicadas con éxito en imágenes hiperespectrales, se analizará su viabilidad sobre las imágenes multiespectrales WV-2 para discriminar las especies vegetales a partir de los mapas de abundancia obtenidos tras este análisis de mezcla.

Además, se contempla la integración de información espectral adicional (índices de vegetación, VIs) y de información de contexto espacial, con objeto de favorecer la discriminación con mayor fiabilidad de las diferentes especies vegetales de interés.

Finalmente, una vez definida la mejor metodología de clasificación sobre las imágenes multiespectrales, se evaluará el impacto de utilizar la imagen fusionada, para analizar cómo afecta en los resultados de exactitud del clasificador.

1.3 Estructura de la memoria

La memoria de este trabajo se estructura de la siguiente manera. Tras el capítulo de introducción y objetivos, en el capítulo 2 se describen las diferentes técnicas de fusión de imágenes desarrolladas y analizadas en esta *Tesis Doctoral*. Se analiza el estado del arte y se detalla cada uno de los métodos más relevantes. A continuación se muestra la metodología de evaluación, que consiste principalmente en realizar un análisis visual y un análisis cuantitativo. Para el análisis cuantitativo se describen diferentes índices que evalúan la calidad espacial y espectral de la imagen fusionada, según se compare sobre la imagen MS o la PAN. Además, también se muestran los resultados de aplicar estas técnicas de *pansharpening* sobre una imagen sintética, con el fin de realizar el estudio sobre una imagen controlada.

En el capítulo 3 se detallan todas las correcciones radiométricas, atmosféricas y geométricas que son necesarias sobre las imágenes multiespectrales antes de ser utilizadas para su tratamiento en la etapa de clasificación. Se describen los diferentes problemas asociados a la captación de las imágenes y se realiza un análisis detallado de los diferentes algoritmos aplicados. En especial, se aborda un estudio exhaustivo de diferentes algoritmos de corrección atmosférica, así como su validación utilizando datos *in-situ* obtenidos tras una campaña de campo.

El capítulo 4 describe la metodología de clasificación de especies vegetales de interés sobre la Reserva Natural de las Dunas de Maspalomas. Se presenta la zona de estudio, datos disponibles y las especies vegetales de interés. A continuación, se muestra el estado del arte de las técnicas de clasificación. Asimismo, se describen las diferentes estrategias analizadas, que incluyen proporcionar información espectral y espacial adicional al clasificador o los mapas de abundancia. Todo ello con objeto de tratar de aumentar la discriminación de especies vegetales. Además, se incluye también el análisis de la metodología de clasificación sobre la imagen fusionada.

Finalmente, en el capítulo 5 se presentan las principales conclusiones y aportaciones de esta investigación, proporcionando las posibles líneas futuras de trabajo y la producción científica en el ámbito de esta *Tesis Doctoral*.

Capítulo 2

Técnicas de Fusión de imágenes

Las imágenes procedentes de sensores a bordo satélites de alta resolución se toman en varias bandas del espectro electromagnético y con varias resoluciones espaciales, temporales y radiométricas. La mayoría de sensores de alta resolución proporcionan una imagen pancromática (escala de grises) de alta resolución espacial y una imagen multiespectral con baja resolución espacial (típicamente 4 veces peor). Para solventar las limitaciones de estos sensores se recurre a operaciones de fusión de datos a nivel de píxel, entendida ésta como un proceso en el que, partiendo de imágenes de diferente resolución espacial, espectral y radiométrica, se obtienen productos complementarios que integran las mejores prestaciones de cada fuente de datos. Así, el objetivo fundamental de la fusión de imágenes es aumentar la resolución espacial de las bandas multiespectrales, mejorando la delimitación de diferentes objetos y estructuras sobre las imágenes.

2.1 Introducción

La teledetección se entiende como la percepción remota de datos de la superficie terrestre a través de satélites espaciales. En la actualidad existen cientos de satélites en el espacio observando la Tierra. Estos satélites pueden considerarse una fuente abundante y precisa de datos, que proporcionan imágenes digitales que contienen cada vez mayor nivel de detalle e información. Dichas imágenes se captan en varias bandas del espectro electromagnético y con diferentes resoluciones, espaciales, radiométricas y temporales. En la Figura 5 se muestra una breve comparativa de algunos satélites de alta resolución de la empresa *DigitalGlobe*.



Figura 5. Satélites comerciales DigitalGlobe de muy alta resolución espacial [7].

Las observaciones que se pueden obtener desde los satélites dependerán de los sensores que lleven a bordo. Un sensor remoto es un instrumento capaz de detectar, caracterizar y cuantificar la energía que proviene de objetos situados a distancia. Así, la teledetección o percepción remota de estos sensores puede ser de dos tipos: activa y pasiva (Figura 6).

La **teledetección pasiva** mide, de una parte, la radiación natural emitida por la Tierra debida a que toda materia por encima del cero absoluto (0 K) emite radiación electromagnética producida por el movimiento de las partículas cargadas de sus átomos y moléculas, y de la otra, también mide la energía reflejada por los objetos, debida a la radiación solar. En contraste, la **teledetección activa** envía pulsos de radiación electromagnética y mide la cantidad retrodispersada en dirección al sensor.



Superficie terrestre

Figura 6. Teledetección pasiva y activa.

A lo largo de esta *Tesis Doctoral* sólo se hará referencia a la teledetección pasiva. En este sentido, la energía reflejada de los cuerpos se denominada reflectancia o reflectividad y responde según las características físico químicas de éstos. Es lo que se denomina "firma espectral", que es propia para cada elemento y permite distinguirlos. Se denomina banda a la porción de radiación electromagnética que presenta un comportamiento similar, y a la organización de estas bandas de longitudes de onda o frecuencia se llama espectro electromagnético. Las siguientes bandas espectrales son las más frecuentes empleadas en teledetección [8]:

- Espectro visible (0.4 a 0.6 µm): se llama así por ser la única radiación que pueden percibir nuestros ojos. Dentro de este rango suelen distinguirse 3 bandas elementales (azul, verde y rojo) por los colores asociados a esas longitudes de onda.
- Infrarrojo cercano (0.7 a 1.3 μm): es de gran importancia por su capacidad de discriminar masas vegetales y concentraciones de humedad.
- Infrarrojo medio (1.3 a 8 µm): se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre.
- Infrarrojo lejano o térmico (8 a 14 µm): incluye la fracción emisiva del espectro.
- Microondas (a partir de 1 μm): de gran interés por ser un tipo de energía trasparente a la cubierta nubosa.

La Figura 7 muestra la distribución del espectro electromagnético.



Figura 7. Espectro electromagnético. Fuente [9].

Las imágenes procedentes de sensores remotos están caracterizadas por su resolución espectral, espacial, radiométrica y temporal. La resolución espectral se refiere al ancho de banda y tasa de muestro (número de canales) al que trabajan los sensores de captación de la información. Un ancho de banda estrecho representa alta resolución espectral. Por otro lado, la resolución espacial suele asociarse al tamaño del píxel y hace referencia a la capacidad de discriminación de objetos sobre una escena. De otra parte, la resolución radiométrica designa el número máximo de niveles digitales que puede detectar un sensor, esto es, la capacidad de detectar variaciones en la radiancia espectral que recibe. Finalmente, la resolución temporal determina la periodicidad con que éste adquiere datos de la misma porción de la superficie terrestre. Debido a las limitaciones hardware de los sensores, las imágenes obtenidas con altas resoluciones espaciales tienden a tener bajas resoluciones espectrales y viceversa.

Todos los sensores tienen una relación señal a ruido fija, que depende del diseño hardware. La energía reflejada por el blanco debe tener un nivel lo suficientemente alto para que éste sea detectado por el sensor. Este nivel de señal aumenta a mayor campo de visión del sensor o mayor ancho de banda

espectral. Al aumentar el campo de visión se reduce la resolución espacial, de ahí que sea necesario establecer un compromiso entre la resolución espacial y espectral del sensor.

Para solventar este problema, muchos de los sensores ópticos actuales disponen a su vez de dos tipos de instrumentos: uno pancromático y otro multiespectral. El sensor multiespectral capta señales en bandas estrechas sobre un campo de visión amplio, mientras que el sensor pancromático capta señales en una banda espectral ancha sobre un campo de visión pequeño. De tal manera que podemos concluir que el sensor multiespectral tiene gran resolución espectral pero baja espacial y el sensor pancromático lo contrario.

El principal objetivo de la fusión de imágenes es obtener mejores resultados en la clasificación y delimitación de diferentes objetos y estructuras sobre imágenes de teledetección [10]. La fusión de imágenes se puede realizar a cuatro niveles de procesado diferentes: a nivel de señal, a nivel de píxel, a nivel de objeto y a nivel de decisión [11] [12] [13] [14].

- A nivel de señal se combinan dos señales de diferentes sensores para obtener una imagen con mejor relación señal a ruido que las originales.
- A nivel de píxel se realiza la fusión sobre una base píxel a píxel. Se genera una imagen fusionada en la que la información asociada a cada píxel se determina a partir de los píxeles de las imágenes de origen.
- A nivel de objetos se requiere la extracción de objetos reconocidos en las fuentes de datos iniciales, por ejemplo, utilizando segmentación. Los objetos corresponden a las características extraídas de las imágenes iniciales que dependen de su entorno como pueden ser: extensión, forma y vecindad.
- A nivel de decisión consiste en fusionar la información a un nivel más alto de abstracción, combinando los resultados de múltiples algoritmos para obtener una fusión de decisión final. Las imágenes fuentes son procesadas independientemente para extraer la información, por ejemplo, tras un proceso de clasificación. Entonces, la información obtenida se combina aplicando reglas de decisión para reforzar la interpretación común.

Las técnicas de fusión que nos ocupan en este trabajo de *Tesis Doctoral* se realizan en el nivel de procesado de píxel. Estas técnicas también se denominan *pansharpening* porque tratan de integrar la información espacial de la pancromática (PAN) sobre la imagen multiespectral (MS) para obtener una imagen fusionada (FUS). La Figura 8 muestra un diagrama genérico del proceso de fusión.



Figura 8. Diagrama de bloques genérico del proceso de fusión a nivel de píxel entre las bandas MS y PAN. Fuente [15]

2.2 Estado del arte en técnicas de fusión

En la actualidad se dispone de un gran número de algoritmos de fusión [16] [17] principalmente aplicados para la fusión a nivel de píxel de imágenes ópticas e IR cercanas.

En sus inicios, las técnicas más populares fueron las basadas en operaciones aritméticas como la transformada *Brovey* [18] y las basadas en la sustitución de componentes a partir de transformadas como el Análisis de Componentes Principales (*PCA*, *Principal Component Analisys*), la transformada Intensidad-Brillo-Saturación (*IHS*, *Intensity-Hue-Saturation*) [19] [20] o el algoritmo *Gram-Schmidt* (GS) [21]. La utilización de estos algoritmos está muy extendida, dada la baja complejidad computacional que presentan. Sin embargo, proporcionan imágenes fusionadas cuyo color presenta distorsiones respecto al color de las imágenes multiespectrales originales.

Para solventar las limitaciones espectrales de los algoritmos mencionados, surgieron técnicas que inyectan la información de alta frecuencia, destacando los métodos *HPF* (*High-Pass-Filtering*), *HPM* (*High-Pass-Modulation*) [22] o el basado en la aplicación de filtros paso alto en el dominio de Fourier. Éstos no alcanzan las mejoras obtenidas con los métodos basado en técnicas de Análisis Multiresolución (*MRA, Multiresolution Analysis*) [23], que utilizan fundamentalmente la Transformada *Wavelet* Discreta (*TWD*) [24]. Para lograr resultados óptimos, diversos esquemas de fusión basados en *wavelet*s han sido propuestos por muchos investigadores, como el *Mallat* [25] y el À *trous* [26] [27]. Además, otras transformadas como *curvelets* [28], *ridgelets* [29], *contourlets* [30], se han propuesto como alternativas más eficientes desde el punto de vista de la representación de la información que la *TWD*. Estas nuevas transformadas son altamente anisotrópicas (no dependen de la dirección de los objetos de la imagen), permitiendo una extracción mucho más eficaz de los detalles espaciales en diferentes direcciones. El inconveniente que presentan estos enfoques es que son computacionalmente muy complejos.

Cada uno de los algoritmos expuestos tienen sus limitaciones y ventajas, por eso, otra estrategia seguida ha sido combinar diferentes esquemas de fusión que puedan lograr una mejor calidad de los resultados [31]. Así, por ejemplo, algunos investigadores han combinado con éxito la transformada *IHS* o la *PCA* con la transformada *wavelet* para intentar conseguir mejores resultados espaciales y espectrales [32]. Estos métodos son los llamados À *trous* AWI y À *trous* AWPC [33] [34].

Más recientemente, se ha propuesto una versión ponderada del algoritmo de fusión basado en la transformada *wavelet* À *trous*. La ponderación los coeficientes *Wavelet* de la imagen pancromática se lleva a cabo mediante mapas de dimensión fractal con objeto de adaptar la información de detalle que se inyecta en cada una de las bandas de la imagen multiespectral a los diferentes tipos de cubiertas presentes en la escena a fusionar [35].

A continuación, se procede a describir aquellos algoritmos implementados y que han sido objeto de estudio en esta *Tesis Doctoral*.

2.2.1 *Método Brovey*

El método *Brovey* [36] generalmente se aplica sobre una composición rojo, verde y azul (RGB, *Red-Green-Blue*) de las bandas espectrales. En una primera etapa, normaliza cada banda o, en su caso, la imagen compuesta, y luego se multiplica el resultado por los datos deseados, en este caso los de la imagen PAN. De esta forma se añade la componente intensidad o brillo de la imagen PAN.

A continuación, se muestra la ecuación extendida para N bandas. Con este método se consiguen buenos resultados espaciales, pero la imagen FUS presenta gran distorsión espectral.

$$ND_{i,FUS} = \frac{N \cdot ND_{bi}}{ND_{b1} + ND_{b2} + \dots + ND_{bN}} \cdot ND_{PAN}$$
(1)

donde, *N* es el número de bandas espectrales, $ND_{i,FUS}$ es el valor digital de cada banda fusionada *i*, ND_{bi} es el valor digital de cada banda MS *i* y ND_{PAN} es el valor digital de la banda PAN.

Al realizar la implementación del algoritmo ha de tenerse en cuenta que los valores a utilizar deben estar normalizados para evitar desbordamientos de rango.

2.2.2 Método IHS

Las imágenes digitales se muestran generalmente como una composición RGB. Sin embargo, los colores pueden ser descritos alternativamente por las componentes intensidad, brillo y saturación. La intensidad representa la luminancia de la imagen, el brillo representa la contribución de las longitudes de onda dominantes y la saturación describe la pureza del color relativo al gris. La transformación *IHS* permite separar la información espectral y espacial de la imagen RGB. La componente intensidad representa la información espectral y espacial de la imagen RGB. La componente intensidad representa la información espectral y operaciones sobre alguna de las componentes para mejorar la información espectral o espacial, en su caso, sin afectar a la otra. En este principio se basan los algoritmos de fusión basados en esta transformada.

El modelo de transformación varía de unos autores a otros. Éstos difieren no sólo en su tiempo de procesamiento, sino también en la metodología utilizada para calcular el valor de la componente *I*. Si el modelo de conversión utilizado entre el espacio RGB y el *IHS* es lineal, las transformaciones entre estos espacios se llevan a cabo con las siguientes ecuaciones (2) y (3).

$$\begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} \\ \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{6}} & \frac{-2}{\sqrt{6}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{6}} & \frac{-2}{\sqrt{6}} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} & 0 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

$$H = \tan^{-1}(\frac{V_2}{V_1})$$

$$S = \sqrt{V_1^2 + V_2^2}$$

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{3}} & \frac{-2}{\sqrt{6}} & 0 \\ \frac{V_1 = S \cdot \cos(H)}{V_2 = S \cdot \sin(H)} \end{bmatrix} \cdot \begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix}$$
(2)
(3)

Una vez descrita la transformación *IHS*, se pasa a describir los pasos del método de fusión basado en la misma y que se muestra en la Figura 9 [37]:

- I. La imagen MS RGB, de baja resolución es co-registrada a la misma área de la PAN y remuestreada a la misma resolución.
- II. Las tres bandas MS remuestreadas, que representan al espacio RGB, son transformadas en las componentes *IHS*.
- III. El histograma de la imagen PAN es igualado al histograma de la componente *I*. De tal manera que así se compensan las diferencias espectrales entre ambas imágenes.
IV. La componente intensidad de las imágenes MS es reemplazada por la banda PAN obtenida en el apartado anterior. Finalmente se obtiene la imagen MS RGB fusionada realizando la transformada de componentes *IHS* al espacio RGB.



Figura 9. Esquema de fusión basada en la transformada IHS. Fuente [15].

Al sustituir la componente *I* por la banda PAN se logra introducir el detalle espacial de la misma en la imagen MS.

La imagen fusionada presenta cierta distorsión espectral. Así, se puede considerar que es un buen método para un análisis visual, pero no es muy adecuado para aplicaciones de clasificación de objetos sobre la imagen. Además, la transformación *IHS* se aplica siempre a composiciones RGB lo que implica que la fusión sólo se podrá realizar para tres bandas de la imagen MS. Para superar este inconveniente se ha desarrollado un método alternativo que se detalla a continuación.

Método de fusión extended Fast IHS (eFIHS)

La implementación de la transformada *IHS* como se mostró en las ecuaciones (2) y (3), requiere de varias operaciones multiplicativas y aditivas, lo que supone un alto coste computacional. Además, el método de fusión *IHS* presenta la limitación del número de bandas (tres).

Para solventar estas limitaciones del método de fusión basado en la transformación *IHS* se ha propuesto el método de fusión *eFIHS* [38], que reduce notablemente el coste computacional y permite extender el número de bandas.

Si operamos sobre las ecuaciones de la transformada IHS:

$$\begin{bmatrix} R'\\G'\\B' \end{bmatrix} = \begin{bmatrix} 1 & -1/\sqrt{(2)} & 1/\sqrt{(2)}\\1 & -1/\sqrt{(2)} & -1/\sqrt{(2)}\\1 & \sqrt{(2)} & 0 \end{bmatrix} \cdot \begin{bmatrix} I+(I'-I)\\V_1\\V_2 \end{bmatrix} = \begin{bmatrix} 1 & -1/\sqrt{(2)} & 1/\sqrt{(2)}\\1 & -1/\sqrt{(2)} & -1/\sqrt{(2)}\\1 & \sqrt{(2)} & 0 \end{bmatrix} \cdot \begin{bmatrix} I+\delta\\V_1\\V_2 \end{bmatrix}$$

$$= \begin{bmatrix} R+\delta\\G+\delta\\B+\delta \end{bmatrix}$$

$$(4)$$

donde, $\delta = I' - I$ y siendo *I* la media de las bandas R, G y B.

Cuanto mayor sea el valor de δ mayor será el cambio en la componente *S*, y por lo tanto mayor será la diferencia entre la información espectral de la imagen MS fusionada de alta resolución y la imagen MS original de baja resolución.

Tradicionalmente, en el proceso de fusión la imagen PAN de alta resolución reemplaza a la componente *I*. De esta forma, $\delta = I' - I = PAN - I$, lo que produce distorsión espectral entre la imagen FUS y la MS, siendo mayor la diferencia en las zonas verdes (vegetación).

Para resolver este problema, y teniendo en cuenta que la banda espectral del sensor PAN cubre las bandas espectrales R, G, B e Infrarrojo cercano (NIR, Near Infrared) del sensor MS, es razonable suponer que también la banda NIR debe ser incluida en la definición de la componente I. Así, volviendo a la ecuación (4), la transformación *IHS* puede ser extendida de tres a cuatro bandas, como se muestra a continuación:

$$\begin{bmatrix} R'\\G'\\B'\\NIR'\end{bmatrix} = \begin{bmatrix} R+\delta\\G+\delta\\B+\delta\\NIR+\delta\end{bmatrix}$$
(5)

donde $\delta = I' - I = PAN - I$ y I = (R + G + B + NIR)/4. Con este método de fusión la diferencia radiométrica obtenida entre PAN e I es menor, siendo menor también el cambio en la componente S y, consecuentemente, la distorsión espectral de la FUS resultante [39].

2.2.3 Método de fusión basado en el PCA

La mayoría de los sensores MS recogen información en bandas adyacentes del espectro electromagnético, lo que habitualmente implica detectar información redundante, ya que muchas de las cubiertas existentes sobre la superficie terrestre tienden a presentar comportamientos similares en regiones próximas del espectro.

En este contexto, el Análisis en Componente Principales (*PCA*) [40] permite sintetizar las bandas originales creando nuevas bandas, las Componentes Principales (CP) [41], que recogen y reorganizan la información original. En general, la Primera Componente Principal (CP1) recoge información común a todas las bandas utilizadas como datos de entrada en el *PCA*, es decir, la información espacial, mientras que la información espectral propia de cada una de las bandas se recoge en el resto de CP. Esto hace que el *PCA* se presente como una técnica muy apropiada para la fusión de imágenes MS y PAN. En este caso, todas las bandas de la imagen MS original constituyen los datos de entrada para el *PCA* [42]. Como resultado de este análisis se obtienen nuevas bandas, no correlacionadas entre sí, las CP. La CP1 es reemplazada por la imagen PAN, cuyo histograma previamente se ha igualado al de la CP1. Seguidamente, se aplica la transformada inversa (*PCA*⁻¹) al conjunto de datos formado por la imagen PAN modificada y los CP2, CP3, CP4 y se obtienen las nuevas bandas fusionadas a las que se ha incorporado el detalle de la imagen PAN. Este esquema de fusión se muestra en la Figura 10.

La ventaja de este método es que no tiene limitación en el número de bandas a utilizar. Sin embargo, presenta, al igual que en el método *IHS*, cierta distorsión espectral en la imagen fusionada respecto a la original.



Figura 10. Esquema de fusión basado en la transformada PCA. Fuente [15].

2.2.4 Algoritmo TWD de Mallat

Dado que muchas de las aplicaciones de la fusión de imágenes se dedican a temas relacionados con clasificación, donde la información espectral juega un papel importante, cabe destacar la necesidad de buscar técnicas que minimicen la distorsión espectral. Se ha demostrado que los métodos basados en la teoría mutiresolución (*MRA*) [25] producen menor distorsión espectral que otros métodos, sobre la imagen fusionada, respecto de las bandas MS originales.

La teoría multiresolución se basa en el hecho de que resulta mucho más eficiente en el análisis de una imagen (reconocimiento de patrones) analizarla a diferentes resoluciones, a mantener la resolución de la misma y escalar los operadores de detección y clasificación.

Así, el *MRA* permite descomponer datos bidimensionales en componentes de distinta frecuencia y estudiar cada componente a una resolución acorde con su escala. A diferente resolución, el detalle de una imagen caracteriza diferentes estructuras físicas de la escena. A resoluciones groseras, este detalle corresponde a las estructuras de mayor tamaño mientras que a resoluciones más finas, esta información corresponde a las estructuras de menor tamaño.

El concepto de *MRA* se deriva de la idea de algoritmos piramidales empleada por primera vez por *Burt y Adelson* [23], quienes usaron estos algoritmos para analizar el detalle de señales a diferentes resoluciones. Con el fin de facilitar los cálculos, se trabaja con resoluciones decrecientes diádicas. *Mallat* utiliza este factor de degradación. La Figura 11 muestra de forma gráfica esta representación piramidal.



Figura 11. Representación piramidal de algoritmos diezmados.

La implementación práctica de la *TWD* asociada al *MRA* de *Mallat* se realiza aplicando convoluciones con filtros de cuadratura, filtros *h* y *g*, seguidos de operaciones de remuestreo.

El filtro *h*, asociado a una función de escala, es un filtro unidimensional paso bajo que permite analizar los datos de baja frecuencia, mientras que el filtro *g*, asociado a una función *wavelet*, es un filtro unidimensional paso alto que permite analizar las componentes de alta frecuencia, es decir, el detalle espacial de la imagen.

El número de coeficientes de estos filtros, así como el valor de los mismos depende de una función *Wavelet* Madre. La más utilizada habitualmente es la *wavelet* de Daubechies [43] "db4", que da lugar a filtros unidimensionales de cuatro coeficientes. Los coeficientes de los filtros asociados a la función *wavelet* seleccionada y a su correspondiente función de escala son:

$$h: \left\{ \frac{1 - \sqrt{3}}{4\sqrt{2}}, \frac{3 - \sqrt{3}}{4\sqrt{2}}, \frac{3 + \sqrt{3}}{4\sqrt{2}}, \frac{1 + \sqrt{3}}{4\sqrt{2}} \right\}$$
$$g: \left\{ -\frac{1 + \sqrt{3}}{4\sqrt{2}}, \frac{3 + \sqrt{3}}{4\sqrt{2}}, -\frac{3 - \sqrt{3}}{4\sqrt{2}}, \frac{1 - \sqrt{3}}{4\sqrt{2}} \right\}$$
(6)

Como se muestra en la Figura 12, los filtros g y h se aplican separadamente a las filas y columnas de la imagen. En primer lugar, los filtros h y g se aplican a todas las filas de la imagen original. Las dos imágenes resultantes son simplificadas, eliminando una de cada dos columnas.

Las cuatro imágenes resultantes se vuelven a simplificar, en este caso, eliminando una de cada dos filas. Como resultado de esta fase de análisis, se obtienen cuatro nuevas imágenes. La primera se denomina coeficiente o imagen de aproximación (A) y el resto se denominan coeficientes de detalle (D) y recogen detalle espacial (Horizontal, Vertical y Diagonal) que la imagen pierde al pasar de la resolución original a la mitad de resolución.

A partir de la imagen de aproximación y los tres coeficientes *wavelet* de detalle, puede reconstruirse exactamente la imagen original. Los filtros H y G, que se aplicarán en esta fase de síntesis (ver Figura 13), son filtros espejo de h y g.



Figura 12. Fase de análisis de la implementación práctica del algoritmo diezmado de Mallat.



Figura 13. Fase de síntesis de la implementación práctica del algoritmo diezmado de Mallat.

El proceso de fusión consiste en aplicar la fase de análisis de la transformación *wavelet* a las imágenes PAN y MS y obtener los coeficientes de aproximación y detalle para cada caso. A continuación, se aplica la fase de síntesis al coeficiente de aproximación de la MS y los coeficientes de detalle de la PAN.

Generalmente antes de aplicar la transformación *wavelet* a las imágenes PAN y MS, y con el fin de que los coeficientes de detalle tengan una información espectral lo más parecida posible a la de la MS, se equipara el histograma de la PAN al de cada una de las bandas de la MS.

Dentro de las estrategias de fusión de imágenes de satélite, el algoritmo piramidal de *Mallat* ha sido uno de los más ampliamente utilizados, debido a la alta calidad espectral que caracteriza a las imágenes fusionadas mediante este método. Sin embargo, la baja direccionalidad del proceso de filtrado (horizontal, vertical y diagonal) y su carácter diezmado, presenta como principal problema la aparición del efecto diente de sierra que deteriora notablemente la calidad espacial de las imágenes fusionadas.

2.2.5 Algoritmo À trous

El algoritmo À trous fue desarrollado por *Holschneider, Kronland-Martinet, Morlet y Tchamitchian* [44] en 1988. Consiste en una descomposición basada en la *TWD* en la que no se produce submuestreo de las imágenes, de tal forma que el esquema de descomposición de las imágenes no se representa con una pirámide sino con un paralelepípedo. La base de éste es también la imagen original. Cada nivel del paralelepípedo es una imagen aproximación de la imagen original, como en el algoritmo de *Mallat*. Conforme se asciende de nivel, las sucesivas aproximaciones presentan menor resolución con un factor de degradación diádico.



Figura 14. Representación del paralepípedo de descomposición del algoritmo À trous.

De forma práctica, se descompone la imagen convolucionándola mediante un filtro paso bajo bidimensional asociado a la función de escala, obteniendo de esta manera las imágenes aproximación.

La función de escalado más usada para el cómputo del algoritmo À *trous* es la *b3-spline*, que se puede representar como el filtro espacial de tamaño 5x5 que se muestra en la siguiente ecuación, si bien se pueden aplicar otros filtros cuyos coeficientes sean los correspondientes a los aplicados en la descomposición *wavelet* discreta.

$$h = \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & 36 & 24 & 6 \\ 4 & 16 & 24 & 16 & 4 \\ 4 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix}$$
(7)

Los coeficientes wavelet se obtienen de la diferencia entre dos niveles consecutivos de degradación.

Para realizar la síntesis de la imagen, desde un nivel de degradación se debe aplicar un criterio aditivo de la sumatoria de todos los coeficientes obtenidos, al último nivel de degradación de la imagen original, como se muestra en la ecuación (8).

$$A_{j}(x,y) = A_{j+n}(x,y) + \sum_{k=1}^{n} C_{j+k}(x,y)$$
(8)

Si $A_{j+n}(x, y)$ representa los sucesivos planos degradados que contienen la información de baja frecuencia de una imagen original, y $C_{j+k}(x, y)$ sus respectivos coeficientes *wavelet*, que contienen la información de alta frecuencia, entonces es posible plantear un esquema de fusión de imágenes en el que se integre la información de baja frecuencia contenida en una imagen MS, con la información de alta frecuencia contenida en los coeficientes *wavelet* de una imagen de alta resolución espacial (PAN), para obtener como resultado una imagen MS de alta resolución espacial.

Según el procedimiento utilizado para inyectar el detalle espacial de la imagen PAN en la imagen MS, es posible distinguir al menos tres métodos de fusión de imágenes distintos basado en la transformada *wavelet À trous* [45]:

 Wavelet Aditivo AW: Esta metodología consiste en degradar la imagen PAN en n planos wavelet e integrar la sumatoria de sus coeficientes wavelet a las diferentes bandas de la imagen MS original remuestreadas. Previamente se debe igualar el histograma de la PAN al de cada una de las bandas.



Figura 15. Esquema de fusión basado en la transformada wavelet aditivo À trous. Fuente [15].

- II. Wavelet Aditivo sobre la componente Intensidad (AWI): Probablemente, el método de fusión de imágenes MS y PAN más utilizado sea el basado en el método de sustitución de componentes basado en la transformada *IHS*. Posiblemente debido a la ventaja que presenta la transformación *IHS* de aislar la información espacial de la imagen en la componente *I*. El procedimiento seguido para esta fusión es el siguiente:
 - Se realiza la transformación IHS a la imagen MS RGB, para obtener la componente I.
 - Se iguala el histograma de la imagen PAN al de la componente I.

- Se realizan la transformada *wavelet* À *trous* de la imagen PAN igualada, y se obtienen los dos primeros planos *wavelet* de la misma.
- Se suman los coeficientes *wavelet* a la componente *I* y se realiza la transformada inversa.



Figura 16. Esquema de fusión aditivo basado en la transformada wavelet À trous sobre I. Fuente [15].

III. Wavelet Aditivo sobre la Primera Componente Principal (AWPC): Al igual que para la transformada IHS, PCA, permite aislar la información espacial, en este caso en la CP1. En el método de fusión basado en el análisis de componentes principales, se sustituye la CP1 por la banda PAN, introduciendo con ello, tanto la información espacial como espectral de la PAN. Sin embargo, en el método AWPC sólo se añade a la CP1 la información espacial de la PAN que le falta a la MS. El procedimiento llevado a cabo es similar al descrito en el apartado anterior, sólo que en este caso se utiliza la CP1 en vez de la componente *I*.



Figura 17. Esquema de fusión aditivo basado en la transformada wavelet À trous sobre la CP1. Fuente [15].

2.3 Evaluación de las técnicas de fusión de imágenes de alta resolución

La fusión de imágenes, especialmente la fusión de imágenes PAN y MS, está teniendo gran importancia dada la variedad de aplicaciones de las imágenes de sensores remotos, y a que la mayoría de éstos obtienen simultáneamente imágenes MS de baja resolución espacial e imágenes PAN de alta resolución. Numerosas técnicas de fusión se han desarrollado con sus diferentes ventajas y limitaciones, comentadas en aparatados anteriores. Sin embargo, la forma de evaluar la calidad de la imagen FUS de manera precisa para obtener resultados convincentes ha sido un tema muy discutido entre los investigadores y los usuarios de los productos fusionados [46].

Generalmente, en las publicaciones científicas, los criterios que se utilizan para medir la calidad de una imagen FUS se dividen en dos categorías diferentes:

- I. Medidas Cualitativas, que implican la comparación visual tanto del color entre la imagen MS y la FUS, como del detalle espacial entre la imagen PAN y la FUS.
- II. Medidas Cuantitativas, que implican un conjunto de indicadores de calidad definidos previamente para medir las similitudes espectral y espacial entre la imagen FUS y la original MS y/o PAN.

Dado que las Medidas Cualitativas presentan un factor subjetivo y pueden ser influenciadas por preferencias personales, se suelen requerir de medidas cuantitativas para demostrar la exactitud de la comparación visual.

Para obtener medidas cuantitativas se han definidos diversos métodos de evaluación de la calidad de la imagen FUS, desarrollados por diferentes autores. Sin embargo, aún no han llegado a un acuerdo para definir un indicador de evaluación común aceptable. Lo que supone que sea muy complicado proporcionar una medida convincente.

Básicamente, los métodos de evaluación cuantitativa pueden ser agrupados en base al aspecto que se pretende medir:

- I. Evaluación de la calidad espectral: determina la similitud espectral de la imagen FUS respecto a la imagen MS (por ejemplo, el coeficiente de correlación y *ERGAS* espectral).
- II. Evaluación de la calidad espacial: determina la cantidad de información espacial aportada por la imagen PAN (por ejemplo, índice *Zhou* y *ERGAS* espacial),
- III. Evaluación de la calidad global: determina simultáneamente la cantidad de información espectral y espacial proporcionada por la fusión (por ejemplo, índice *SSIM* y *Q*).

En la práctica estos procesos de evaluación se basan en el cálculo de una serie de índices de calidad, que miden distintos aspectos de la imagen. A continuación se describen los índices que serán empleados en la evaluación de las técnicas de fusión implementadas.

2.3.1 **Coeficiente de correlación**

El coeficiente de correlación lineal de *Pearson* mide la existencia de una relación lineal entre dos variables. Su cálculo se realiza dividiendo la covariancia por el producto de las desviaciones estándar de ambas variables:

$$CC = \frac{\sigma_{XY}}{\sigma_X \cdot \sigma_Y} \tag{9}$$

El coeficiente de correlación lineal de Pearson se utiliza con mucha frecuencia para comparar imágenes. De forma práctica, el coeficiente entre dos imágenes se obtiene como:

$$CC = \frac{\sum_{i} (x_{i} - x_{m}) \cdot (y_{i} - y_{m})}{\sqrt{\sum_{i} (x_{i} - x_{m})^{2}} \cdot \sqrt{\sum_{i} (y_{i} - y_{m})^{2}}}$$
(10)

donde x_i es el valor de intensidad del píxel *i* de una imagen monocromática *X*, y_i es el valor de intensidad del píxel i de una imagen monocromática *Y*, y donde $x_m e y_m$ son los valores de intensidad medios de las imágenes *X* e *Y* respectivamente.

El coeficiente de correlación tiene el valor r = 1 si las dos imágenes son absolutamente idénticas, r = 0 si están completamente incorreladas y r = -1 si existe una correlación negativa perfecta.

Este índice presenta baja sensibilidad a las variaciones de calidad lo que indica que su fiabilidad es cuestionable [47]. Aun así, es un índice que se utiliza en la mayoría de las publicaciones científicas para medir la calidad de las imágenes fusionadas.

En el caso de su aplicación para medir la calidad espectral de las imágenes fusionadas, la correlación se hace entre cada banda de la imagen FUS y MS.

2.3.2 Índice Zhou

Este índice, propuesto por *Zhou* [24], se utiliza para estimar de forma cuantitativa la calidad espacial de las imágenes fusionadas.

Teniendo en cuenta que la información espacial de la PAN se concentra principalmente en el dominio de las altas frecuencias, se puede utilizar como medida de la calidad espacial el factor de correlación entre la componente paso alto de la imagen FUS y la componente paso alto de la imagen PAN. Un factor de correlación elevado implicaría que la mayoría de la información espacial de la PAN se ha preservado.

Para extraer las componentes de alta frecuencia de la fusionada y la PAN se utiliza un filtro Laplaciano como el siguiente:

$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$
(11)

Así, el cálculo del factor de correlación quedaría como se muestra en la ecuación (12):

$$Zhou = \frac{\sum_{i} (FUS_{i}^{PA} - FUS_{m}^{PA}) \cdot (PAN_{i}^{PA} - PAN_{m}^{PA})}{\sqrt{\sum_{i} (FUS_{i}^{PA} - FUS_{m}^{PA})^{2}} \cdot \sqrt{\sum_{i} (PAN_{i}^{PA} - PAN_{m}^{PA})^{2}}}$$
(12)

donde FUS_i^{PA} es el valor de intensidad del píxel *i* de la imagen fusionada filtrada paso alto, PAN_i^{PA} es el valor de intensidad del píxel *i* de la imagen PAN filtrada y FUS_m^{PA} y PAN_m^{PA} son los valores de intensidad medios de las imágenes FUS y PAN filtradas respectivamente.

2.3.3 **ERGAS**

Este índice *ERGAS* (*Erreur Relative Globale Adimensionalle de Synthèse*) fue propuesto por *Wald* [48] y trata de obtener un valor cuantificable del error global del producto fusionado que sea exacto y fácil de interpretar. Para ello debe cumplir tres requerimientos:

- I. Debe ser independiente de las unidades y, en consecuencia, de los coeficientes de calibración y ganancia del instrumento.
- II. Esta cantidad debe ser independiente del número de bandas espectrales a considerar.
- III. Esta cantidad debe ser independiente de la relación de escala *h/l*, siendo *h* la resolución espacial del sensor PAN, y *l* la resolución espacial del sensor MS.

Wald propuso este índice como una evolución del índice *Error total* propuesto por *Munechika* [49], para cumplir los tres requerimientos anteriores.

El Error total se define como:

$$ErrorTotal = \sum_{i=1}^{N} RMSE(B_i)$$
(13)

donde N es el número de bandas y RMSE, representa el error cuadrático medio (*Root Mean Square Error*) y se define como:

$$RMSE_{i} = \frac{1}{n} \sqrt{\sum_{k=1}^{n} (MS_{i}(k) - FUS_{i}(k))^{2}}$$
(14)

donde MS_i es la banda *i* de la imagen original, FUS_i es la banda *i* de la imagen fusionada y *n* es el número de píxeles.

El *RMSE* es sensible al cambio de datos numéricos a radiancias. *Wald* propone generalizar esta fórmula a fin de poder comparar los errores obtenidos a partir de diferentes métodos, diferentes casos y diferentes sensores.

Si *M_i* representa el valor medio de la banda *B_i*, se define *M* como el valor de radiancia medio de N imágenes B_i.

$$M = \left(\frac{1}{N}\right) \sum_{i=1}^{N} M_i \tag{15}$$

El *Relative Average Spectral Error (RASE)* se expresa en porcentaje y caracteriza la eficacia media de un método sobre las bandas espectrales consideradas.

$$RASE = \frac{100}{M} \sqrt{\frac{1}{N} \sum_{i=1}^{N} RMSE(B_i)^2}$$
(16)

donde N representa el número de bandas.

El índice *RASE* cumple el primer y segundo requerimiento. Para cumplir el tercer requerimiento se propone la siguiente expresión final del índice *ERGAS*:

$$ERGAS = 100 \cdot \frac{h}{l} \sqrt{\frac{1}{N} \sum_{i=1}^{N} \frac{RMSE(B_i)^2}{(M_i)^2}}$$
(17)

El índice *ERGAS* es más robusto que el *RASE* a los cambios de unidades. Además, el cociente *h/l* permite tener en cuenta diferentes resoluciones. El umbral de satisfacción de medida de un producto

fusionado se establece en 3 para este índice. Por debajo de 3, el error es pequeño y el producto es de buena calidad. Por encima, el error es grande y el producto es de calidad inferior. Así, se concluye que la calidad disminuye a medida que el error aumenta.

ERGAS espectral

Este índice se define con el objetivo de medir la calidad espectral de la imagen fusionada, donde las imágenes de referencia son la MS y la FUS. Así el *ERGAS*_{Espectral} se define como:

$$ERGAS_{Espectral} = 100 \cdot \frac{h}{l} \sqrt{\frac{1}{N} \sum_{i=1}^{N} \frac{RMSE(B_i)^2}{(M_{MSi})^2}}$$
(18)

donde, el RMSE se expresa como:

$$RMSE_{Espectral}(B_i) = \frac{1}{n} \sqrt{\sum_{k=1}^{n} (MS_i(k) - FUS_i(k))^2}$$
(19)

ERGAS espacial

Este índice se define con el objetivo de medir la calidad espacial de la imagen fusionada.

Así, el ERGAS_{Espacial} se define como:

$$ERGAS_{Espacial} = 100 \cdot \frac{h}{l} \sqrt{\frac{1}{N} \sum_{i=1}^{N} \frac{RMSE(B_i)^2}{(M_{PANi})^2}}$$
(20)

Se trata de un cambio de las imágenes de referencia para el cálculo del índice ERGAS.

$$RMSE_{Espacial}(B_i) = \frac{1}{n} \sqrt{\sum_{k=1}^{n} (PAN_i(k) - FUS_i(k))^2}$$
(21)

donde *PAN_i* corresponde a la imagen obtenida tras aplicar un ajuste de histograma entre la imagen *PAN* (original) y la iésima banda de la imagen *MS*.

2.3.4 Structural Similarity Index (SSIM)

El *Structural Similarity Index (SSIM)* [50] es un índice que permite medir la similitud entre dos imágenes. Fue diseñado para mejorar los resultados obtenidos con índices tradicionales como el error cuadrático medio y la potencia de señal a ruido, los cuales han demostrado ser inconsistentes. El resultado de este índice es un valor decimal entre -1 y 1. Un valor de 1 se obtiene en el caso de que las imágenes comparadas sean idénticas. Se define como:

$$SSIM^{i} = \frac{2 \cdot \overline{MS_{i}} \cdot \overline{FUS_{i}} + c_{1}}{\overline{MS_{i}^{2}} + \overline{FUS_{i}^{2}} + c_{1}} \cdot \frac{2 \cdot \sigma_{MS_{i}FUS_{i}} + c_{2}}{\sigma_{MS_{i}}^{2} + \sigma_{FUS_{i}}^{2} + c_{2}}$$
(22)

donde $c_1 = (k_1L)^2$ y $c_2 = (k_2L)^2$ son constantes de inestabilidad y donde *L* es el rango dinámico de los valores de píxel, k_1 y k_2 son también constantes con valores por defecto, habitualmente, de 0.01 y 0.03 respectivamente.

2.3.5 Universal image quality index

El *Universal Image Quality Index* [51], conocido como índice *Q*, fue diseñado por *Zhou Wang* modelando la distorsión espectral como una combinación de tres factores: pérdida de correlación, distorsión lumínica y distorsión del contraste. La palabra "universal" hace referencia a que la calidad de la medida no depende de las imágenes fuente ni de las condiciones de visualización u observadores. Es la particularización del índice *SSIM* cuando las constantes se anulan. Dado que es una métrica muy utilizada en teledetección, se va a describir con más detalle.

Sea x = { x_i | i = 1, 2, ..., N} e y = { y_i | i = 1, 2, ..., N}, donde *N* representa el número de píxeles de cada imagen, la ecuación para el cálculo del *índice Q* se define como:

$$Q = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\sigma_x^2 + \sigma_y^2) + [(\bar{x})^2 + (\bar{y})^2]}$$
(23)

donde,

$$\bar{x} = \frac{1}{N} \sum_{i=1}^{N} x_i, \qquad \bar{y} = \frac{1}{N} \sum_{i=1}^{N} y_i$$
 (24)

$$\sigma_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \qquad \qquad \sigma_y^2 = \frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2 \tag{25}$$

$$\sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^{N} (x_i - \bar{x})(y_i - \bar{y})$$
(26)

El rango dinámico del índice Q es [-1,1]. El mejor valor de Q = 1, significa que $y_i = x_i$ para todos los *i* =1,2,...,N

Para comprender el modelado de la distorsión espectral propuesto, la ecuación (23) se puede reescribir como:

$$Q = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \cdot \frac{2 \cdot \bar{x} \bar{y}}{(\bar{x})^2 + (\bar{y})^2} \cdot \frac{2 \cdot \sigma_x \sigma_y}{\sigma_x^2 + \sigma_y^2}$$
(27)

La primera componente corresponde al coeficiente de correlación entre x e y, mide el grado de correlación entre x e y, y su rango dinámico es [-1 1]. El mejor valor 1 se obtiene cuando $y_i = ax_i + b$ para i =1,2,...,*N*, donde *a* y *b* son constantes y *a*>0. Pero, aunque *x* e *y* estén relacionadas linealmente, aún puede haber distorsiones entre ellas, que son evaluadas en la segunda y tercera componentes de la Ecuación (27). La segunda componente, cuyo rango es [0 1], mide la cercanía entre las luminancias medias de *x* e *y*. El valor 1 se obtiene si $\bar{x} = \bar{y}$. Finalmente, σ_x y σ_y se pueden ver como la estimación del contraste de *x* e *y*, así la tercera componente mide la similitud del contraste entre las imágenes *x* e *y*. Su rango de valores es [0 1], y su mejor valor 1, se obtiene si $\sigma_x = \sigma_y$.

Al ser aplicados en la evaluación de la calidad de imágenes fusionadas se suele aplicar a las imágenes FUS y MS.

2.4 Resultados de la evaluación de las técnicas de fusión

En primer lugar, en este apartado se indican las características principales del sensor del que se han obtenido las imágenes utilizadas para el análisis de las técnicas de fusión de imágenes. A continuación, se expone una comparación entre los diferentes métodos de fusión tras ser aplicados a una base de datos de imágenes *GeoEye-1*, incluyendo diferentes tipos de cubierta terrestre. Para esta evaluación, se muestra, en primer lugar, una comparación visual de las distintas imágenes fusionadas obtenidas y, en segundo lugar, una comparación cuantitativa de los índices de calidad obtenidos para esas imágenes. Las imágenes fusionadas obtenidas pertenecen a distintos tipos de coberturas terrestres, ya que también se pretende evaluar cómo afectan las características de textura y color de las imágenes de partida a los resultados obtenidos en cada algoritmo de fusión.

2.4.1 *Fuente de información*

A continuación, se describen con más detalle las características principales del sensor de muy alta resolución del cual se han obtenido las imágenes con las que se ha realizado el análisis de las técnicas de fusión descritas en este capítulo de la *Tesis Doctoral*. En concreto, se han usado datos del satélite *GeoEye-1*, aunque los resultados son extrapolables a otros sensores de muy alta resolución. Este satélite adquiere imágenes de tipo multiespectral y pancromática, de forma simultánea, con resoluciones radiométricas de 11 bits. La empresa distribuidora es *DigitalGlobe* y ofrece sus imágenes con distintos niveles de procesado, de tal forma que se pueden adquirir desde productos básicos a corregidos radiométrica y geométricamente. Para el análisis de las técnicas de fusión se parte de imágenes comerciales con las correcciones radiométricas y geométricas y geométricas para llevar a cabo este proceso. Así, se utilizarán los datos de las imágenes en niveles digitales. En el capítulo 3 se tratarán en detalle las correcciones radiométricas, geométricas y atmosféricas, para obtener datos con significado físico, que serán necesarias para llevar a cabo la correcta clasificación y discriminación de especies vegetales sobre la Reserva Natural de las Dunas de Maspalomas, procedimiento que se describe en el capítulo 4.

Satélite GeoEye-1

El satélite *GeoEye-1*, lanzado en 2008, estaba equipado en su momento con las tecnologías más avanzadas que jamás se hayan utilizado en un sistema comercial de detección remota. Esta plataforma obtiene imágenes a una resolución pancromática de 0.41 m (en escala de grises) y a una resolución multiespectral de 1.65 m para sus cuatro bandas (Figura 18). Puede registrar hasta 350.000 km² de imágenes por día en modo pancromático y multiespectral, lo que le permite mapear proyectos de gran envergadura. *GeoEye-1* puede volver a obtener imágenes sobre cualquier punto de la Tierra una vez cada tres días y en algunas latitudes puede ser en menor tiempo.



Figura 18. Respuesta espectral del sensor embarcado en la plataforma GeoEye-1.

El satélite es de órbita polar y realiza 15 órbitas por día a una altitud de 681 kilómetros con una velocidad de alrededor de 7,5 km por segundo o 27.200 km/hora. Su órbita, sincrónica con el Sol, le permite pasar sobre una zona determinada alrededor de las 10:30 de la mañana (hora local), cada día. La totalidad del satélite es capaz de variar rápidamente su orientación en la órbita apuntando la cámara en las áreas terrestres que se encuentran directamente debajo del mismo, de lado a lado y de adelante hacia atrás. Esta característica le permite obtener mayor cantidad de imágenes durante la misma pasada.

La Tabla 1 muestra sus características principales de diseño y especificaciones.

Información sobre el lanzamiento	Fecha: 6 Vehículo Lugar de	de septiembre de 2008 de lanzamiento: Delta II lanzamiento: Base Vandenbe	erg de la Fuerza	Aérea, California
Órbita	Altitud: 681 km Tipo: sincrónica con el Sol, 10:30 a.m. nodo descendente Período: 98 min			
Duración de la misión	Expectativa >10 años			
Resolución del sensor	Pancromático: GSD de 0.41 m en el nadir; GSD de 0.50 m 60° fuera del nadir Multiespectral: GSD de 1.65 m en el nadir, GSD de 2.0 m 60° fuera del nadir			
Bandas de sensores	Pancrom 4 multies Azul: Verde:	aático: 450–800 nm spectrales: 450–510 nm 510–580 nm	Rojo: IR cercano:	655–690 nm 780–920 nm
Rango dinámico	11 bits por píxel			
Ancho de barrido	15.2 km			

Tabla 1. Características del satélite GeoEye-1.

Técnicas de Fusión de imágenes

Precisión de la geolocalización	Error circular del 90 % (circular error of 90%, CE90) de 5 m (especificación) CE90 de 3 m (medido)		
Frecuencia de revisita	Menos de 3 días		
Agilidad para la nueva determinación de objetivos	Tiempo de rotación a 200 km: 10 s		
Máxima superficie contigua recolectada en un solo paso (ángulo de 30° fuera del nadir)	TIRA LARGA HARDIAS		
Capacidad de recolección de imágenes	350,000 km ² /día (pancromática + instrumento multiespectral [multi-spectral instrument, MSI])		
Comunicaciones	Enlace descendente en banda X (a 740 mb/sec o 150 mb/sec)		
Almacenamiento a bordo	1 Terabit		

Las imágenes están disponibles con diferentes niveles de procesamiento: *Geo, Geo Professional* y *Geo Stereo,* así como productos derivados de estas imágenes, incluyendo *Modelos Digitales de Elevación (DEMs)* y *Modelos Digitales de Superficie (DSMs)*, mosaicos de grandes áreas y mapas caracterizados. A continuación se detallan los tres niveles de procesado.

- Geo: las imágenes son corregidas radiométrica y geométricamente. Este proceso de corrección elimina las distorsiones de las imágenes introducidas en el proceso de captura y remuestrea las imágenes a una proyección de mapas escogida por el usuario a diferentes tipos de proyecciones están disponibles (UTM, TM, Gauss Krüger, etc.). Las imágenes no son ortorectificadas, su precisión está limitada por el desplazamiento del terreno.
- GeoProfessional: estos productos están ortorectificados. Utilizan procesos patentados, perfeccionados y optimizados para los datos recogidos por sus satélites. Esto permite disponer de datos más precisos y exactos. Estos datos se facilitan en distintos niveles de exactitud GeoProfessional, Precision y PrecisionPlus.

GeoStereo: proporcionan una base sólida para el reconocimiento de características tridimensionales. GeoStereo proporciona dos imágenes con geometría estéreo para soportar una amplia variedad de aplicaciones, como la creación de DEMs y generación de mapas tridimensionales.

Para la evaluación de las técnicas de fusión analizadas en el capítulo de esta Tesis Doctoral se han utilizado productos Geo.

Base de datos de coberturas de estudio

Se ha creado una base de datos de imágenes con distintas coberturas de la superficie terrestre a fin de evaluar el comportamiento de cada método de fusión en función de las características de la imagen.

Previo a aplicar el proceso de fusión, se ha realizado una interpolación lineal para ajustar el tamaño de la MS al de la PAN, y un ajuste de histograma igualando medias y desviaciones típicas para reducir la distorsión espectral entre las bandas de la MS y la PAN.

Las imágenes corresponden al satélite GeoEye-1, son trozos de dimensiones 800x800 en el caso de la imagen pancromática y de 200x200 en el caso de la imagen multiespectral y pertenecen a una imagen del sur de la isla de Gran Canaria tomada el día 16 mayo de 2009. La resolución radiométrica es de 11 bits.

En la Figura 19 se muestra cada una de las imágenes pancromática junto a una composición RGB de la imagen multiespectral correspondiente. Para poder visualizarlas se han convertido a 8 bits y para mostrar las imágenes con mayor contraste se les ha hecho una expansión del histograma por corte de colas del 2%.

Las coberturas elegidas son: (1) una zona agrícola, (2) una zona costera, (3) y (4) dos imágenes pertenecientes a distintas zonas de las Dunas de Maspalomas, (5) una zona forestal, (6) una zona de agua embalsada, (7) una zona urbana y (8) una zona verde, en concreto de un campo de golf.



(1)

Continúa en Figura 19

(4)



Figura 19. Base de datos de imágenes del satélite GeoEye-1 sobre diferentes coberturas de la superficie terrestre (MS arriba y PAN debajo).

2.4.2 Evaluación visual de los diferentes métodos de fusión

En las Figura 20 a Figura 23 se muestran algunos resultados significativos de las imágenes fusionadas para cada método de fusión y para las distintas coberturas sobre la superficie terrestre. Se puede comprobar la considerable mejora obtenida en la resolución espacial de las imágenes obtenidas tras el *pansharpening*, con respecto a la multiespectral original. Para apreciar mejor las diferencias se muestran regiones pequeñas con un gran zoom.

Las imágenes fusionadas de la Figura 20 presentan, en general buenos resultados. Los bordes de los tejados están bien definidos en todas y no se aprecian grandes diferencias espaciales. Sin embargo, el color azul de la piscina presenta distintas gamas, más oscuras para *Brovey* e *IHS*, y más similares a la original para las basadas en *À trous*.

En las imágenes de la Figura 21 se aprecia con claridad la diferencia en la definición de los bordes de la presa para cada algoritmo, demostrándose la peor calidad espacial de los algoritmos basados en el análisis multiresolución y en especial del algoritmo de *Mallat (TWD)*. Esta diferencia espacial apenas se aprecia sobre la zona de vegetación. Si analizamos las imágenes de la Figura 22, se puede apreciar con más claridad las diferencias obtenidas con cada método de fusión en este tipo de coberturas vegetales, donde el color del suelo desnudo en la imagen *Brovey* e *IHS* presentan tonos más marrones, mientras que la *eIHS* y la *TWD* presentan un color más verdoso. Analizando espacialmente las copas de los árboles vemos que ésta última presenta una textura más borrosa que el resto y se aprecia la incapacidad de definir con precisión las zonas de sombra en las técnicas basadas en la transformada *wavelet*. Por último, las imágenes de la Figura 23 son muy similares. Al ser una cubierta más homogénea no se aprecian grandes diferencias, e incluso la variación del color es menos representativa que en el resto de imágenes.

En conclusión, comparando las diferentes imágenes fusionadas, se demuestra que en los métodos basados en operaciones aritméticas, como *Brovey*, la distorsión espectral es mayor, así como en los métodos basados en sustitución de componentes como *IHS* o *PCA*. Para estos métodos la calidad espacial mejora considerablemente y muestran excelentes resultados con bordes bien definidos. Los

métodos basados en análisis multiresolución usando la transformada *wavelet* presentan una calidad espectral mejor y muy comparable a la multiespectral original y con resultados espaciales aceptables, aunque la definición de los bordes es menos precisa. En algunos casos, la aparición del efecto de diente de sierra o la presencia de artefactos sobre la imagen fusionada, degrada la nitidez de la imagen fusionada, especialmente para la transformad *wavelet* usando el algoritmo de *Mallat* (*TWD*).

En general, el tipo de cubierta analizada puede influir en la selección del mejor algoritmo de fusión. Si se trata de una imagen homogénea, con extensiones uniformes, al no haber gran presencia de detalles espaciales, las imágenes fusionadas no presentan grandes diferencias, más allá de la variabilidad espectral que afecta en diferentes tonalidades del color, y, por tanto, las técnicas basadas en el algoritmo *À trous* son excelentes candidatas para generar una imagen fusionada de elevada calidad espectral.



MS original

FUS À trous AW

FUS À trous AWI







FUS TWD



FUS Brovey



FUS elHS

FUS IHS

FUS PCA





MS original

FUS À trous AW

FUS À trous AWI



À trous AWPC



FUS TWD



FUS Brovey



FUS eIHS







FUS PCA

Figura 21. Imágenes fusionadas con detalle en el borde de una presa de agua.



MS original

FUS À trous AW

FUS À trous AWI



À trous AWPC



FUS TWD



FUS Brovey



FUS eIHS

FUS IHS

FUS PCA

Figura 22. Imágenes fusionadas para una cobertura forestal.



MS original

FUS À trous AW



FUS À trous AWI



À trous AWPC



FUS TWD



FUS Brovey



FUS eIHS

FUS IHS

FUS PCA

Figura 23. Imágenes fusionadas sobre una cobertura de vegetación.

2.4.3 **Evaluación cuantitativa de los algoritmos de fusión basada en métricas de calidad espacial**

A continuación, se procede a realizar un análisis cuantitativo de la calidad espacial de las imágenes fusionadas mostradas en apartados anteriores. Para evaluar el detalle espacial, en primer lugar, se han obtenido las imágenes diferencia entre la imagen pancromática filtrada paso alto con un filtro detector de borde (*Sobel*) y la componente *I* de la imagen multiespectral fusionada obtenida con el mismo filtro. El objetivo de este proceso es evaluar las diferencias espaciales entre cada método de fusión. Además, para completar este análisis espacial también se han obtenido las imágenes diferencia entre las bandas R_{sobel}, G_{sobel} y B_{sobel} filtradas, de la multiespectral fusionada y la imagen pancromática filtrada *Sobel*. El objetivo es analizar la influencia de la fusión sobre las principales componentes de color.

Posteriormente, para cuantificar los resultados se han calculado los respectivos índices de calidad espacial, *ERGAS* espacial e índice *Zhou* sobre la imagen PAN y FUS.

En las Tabla 2 y Tabla 3, podemos ver las diferentes componentes diferencia para dos de las imágenes analizadas. Para una mejor interpretación se ha aplicado una paleta de colores. Para el resto de imágenes se muestran las gráficas que resumen los valores de los índices obtenidos para cada método de fusión (Figura 24 a Figura 31). Como ya se ha mencionado anteriormente, el procedimiento se ha realizado con una base de datos de imágenes de test abarcando diferentes coberturas, a fin de evaluar la influencia del tipo de cobertura en los resultados de la fusión.

Comparando visualmente los detalles espaciales con la componente *I* resulta que la que presenta menos diferencia con respecto a la PAN es la *IHS*, aunque no ocurre los mismo analizando las bandas por separado (ver Tabla 2 y Tabla 3). Tras el análisis visual del detalle espacial para todas las imágenes, separando las bandas R, G y B se puede concluir que se presentan algunas diferencias en los efectos de la fusión sobre cada componente de color. En general, para todas las coberturas analizadas, los métodos basados en *À trous* presentan errores menores en la banda G, donde los bordes presentan tonalidades más oscuras. En el caso del método *Brovey* esto se puede apreciar sobre la banda B, donde la diferencia es menor. Por otro lado, en los métodos basados en transformadas como *IHS* y *PCA*, los errores son menos significativos sobre la banda G. Para el caso de la *TWD* y en el método e*IHS* parece que se presenta un error más uniforme entre todas las bandas, lo cual es lógico en este último método porque la componente *I* se obtiene como un promedio de las tres bandas de la imagen multiespectral.

En general, se aprecia que los errores en las diferentes componentes coinciden para todas las coberturas analizadas. Afectando sobre las mismas componentes de color. Las zonas homogéneas presentan errores bajos, aunque cabía esperar niveles más bajos sobre los métodos de fusión basados en operaciones aritméticas como *Brovey*, que visualmente presenta detalles espaciales más definidos.

Tabla 2. Análisis visual de la diferencia espacial entre la imagen PAN y fusionadas sobre una cobertura agrícola para las diferentes componentes: I (fila 1), R (fila 2), G (fila 3), B (fila 4).



Tabla 3. Análisis visual de la diferencia espacial entre la imagen PAN y fusionadas sobre una cobertura forestal para las diferentes componentes: I (fila 1), R (fila 2), G (fila 3), B (fila 4).



Analizando los valores de los índices cuantitativos *ERGAS* espacial e índice *Zhou* (ver Figura 24 a Figura 31) se deducen que, para todas las coberturas, claramente *Brovey* y los métodos basados en la *IHS* y la *PCA* presentan los mejores resultados espaciales (valores más bajos de *ERGAS* espacial). En la mayoría de los casos, la calidad espacial de la imagen analizada de forma visual tiene una clara

correspondencia con los mejores valores de los índices. Por ejemplo, analizando nuevamente los valores de *ERGAS* espacial, en los métodos de fusión basados en análisis multiresolución, sus valores son generalmente más altos comparados con el resto, y visualmente presentan bordes menos definidos y borrosos. Algo que en algunas condiciones se contradice con el índice *Zhou*, que en general no presenta variaciones muy significativas. Este último índice sólo parece tener una clara respuesta respecto al método *TWD*, pues para todas las coberturas presenta el valor peor.

De los métodos basados en sustitución de componentes destaca el *PCA*, que presenta mejores resultados para todas las coberturas del *ERGAS* espacial. Finalmente, se observa que los valores de los índices obtienen valores en rango diferentes según el tipo de superficies presentes en la imagen. Por lo tanto, no es evidente establecer unos rangos o umbrales estándar que definan la calidad de la imagen fusionada.



Figura 24. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura agrícola.



Figura 25. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de forestal.



Figura 26. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura costera.



Figura 27. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de agua embalsada.



Figura 28. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de Dunas.



Figura 29. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de Dunas.



Figura 30. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura urbana.



Figura 31. Representación gráfica de los índices de calidad espacial para la imagen fusionada de una cobertura de vegetación.

2.4.4 Evaluación cuantitativa de los algoritmos de fusión basada en métricas de calidad espectral

De forma similar al análisis espacial, para evaluar la calidad espectral se han calculado las imágenes diferencia entre las bandas R, G y B de la multiespectral original y las bandas de la fusionada para cada método de fusión. Estas imágenes diferencia se han obtenido como el valor absoluto de la diferencia de los píxeles de ambas imágenes y se ha utilizado una paleta de colores para representar estos valores de error. Esto nos permitirá evaluar de forma visual cómo afecta cada método de fusión a las distintas componentes de color.

Además, se han calculado los respectivos índices de calidad espectral: *ERGAS* espectral, CC, índice Q e índice *SSIM*. En las Tabla 4 y Tabla 5 se presentan las diferentes bandas diferencia para dos de las imágenes analizadas. Para el resto de imágenes se muestran las gráficas que resumen los valores de los índices cuantitativos obtenidos para cada imagen fusionada.

Tras el análisis espectral de las diferentes componentes se constata la mejor calidad de los algoritmos multiresolución. Los métodos basados en *À trous* presentan mayor error en la banda G, al contrario de lo que pasaba en el caso espacial. El método *Brovey*, cuya distorsión espectral es considerablemente más alta que para el resto de métodos, presenta además mayor error en las bandas G y B. Nuevamente, al igual que pasaba en el análisis espacial, los métodos e*IHS* y *TWD* presentan errores más uniformes en todas las bandas. Por otro lado, el método *IHS* presenta menos error en la banda R y en el caso de la *PCA* en la banda B.

En resumen, para todas las coberturas se confirma que *Brovey* es la técnica que peores resultados espectrales ofrece, mientras que las basadas en *À trous* son la que mejor calidad espectral presentan. Este comportamiento concuerda en la mayoría de los casos con los valores de *ERGAS* espectrales y correlaciones espectrales (ver Figura 32 a Figura 39).

Tabla 4. Análisis visual de la calidad espectral de las componentes R-G-B (filas 1-2-3) de las imágenes fusionadas sobre una cobertura de agrícola.





Tabla 5. Análisis visual de la calidad espectral de las componentes R-G-B (filas 1-2-3) de las imágenes fusionadas sobre una cobertura de forestal.

De análisis cuantitativo de los índices (Figura 32 a Figura 39), se puede deducir que en general, se obtienen los mejores valores para los métodos basados en *À trous (ERGAS* espectrales más bajos y el resto de índices valores más altos). Aunque cabía esperar mejores resultados para el método *TWD* que suele presentar visualmente buenos resultados en la calidad espectral pero debido al elevado número de artefactos que introduce dicha calidad se degrada. *Brovey* se confirma como el índice que más distorsiona la información espectral. En general, parece que los índices no se contradicen, aunque no siempre todos ellos coinciden al identificar las mejores técnicas. Resulta más complicado sacar una conclusión con *SSIM* debido a su baja variabilidad y a que en algunos casos presenta valores más altos para métodos basado en la *IHS* o *PCA*, lo que no concuerda con el análisis visual ni con el resto de índices de calidad espectral. Además, queda patente que los resultados de estos índices están condicionado a las características de la escena analizada y no se puede definir un rango estándar que permita medir la calidad espectral de las imágenes.



Continúa en Figura 32



Figura 32. Índices de calidad espectral para una cobertura agrícola.







Figura 33. Índices de calidad espectral para una cobertura forestal.







Figura 34. Índices de calidad espectral para una cobertura costera.

Continúa en Figura 35



Figura 35. Índices de calidad espectral para una cobertura de agua embalsada.





Figura 36. Índices de calidad espectral para una cobertura de Dunas.





Figura 37. Índices de calidad espectral para una cobertura de Dunas.



Continúa en Figura 38



Figura 38. Índices de calidad espectral para una cobertura urbana.





Figura 39. Índices de calidad espectral para una cobertura de vegetación.

2.4.5 Evaluación de los algoritmos de fusión basada en una imagen sintética

A continuación, se ha procedido a validar los métodos de fusión a partir de una imagen generada de forma sintética. La imagen está formada por distintas formas, sombras y colores de manera que permita medir con más certeza los efectos que produce cada método de fusión sobre las diferentes estructuras y sobre cada componente de color. Se ha generado la imagen en color y su equivalente en escala de

grises para simular la pancromática. Por otro lado, la imagen RGB se ha filtrado paso bajo para simular el efecto degradado de una imagen multiespectral y se ha diezmado a una resolución cuatro veces inferior. A continuación, se muestran en la Figura 40 las imágenes originales y fusionadas resultantes.



Figura 40. Imagen sintética fusionada por diferentes métodos: MS original, PAN, FUS À trous, FUS À trous AWI, FUS À trous AWPC, FUS TWD, FUS Brovey, eIHS, IHS, PCA (de arriba a derecha).

En el análisis de la imagen sintética se puede apreciar como los métodos basados en la transformada *wavelet* mantienen el color de la imagen original, aunque presentan una calidad espacial peor con bordes y sombras menos definidos que para el resto de métodos de fusión. Además, se puede apreciar la aparición de sombras en los contornos de las figuras, muy apreciable en los bordes de los círculos. Específicamente en el método de fusión *TWD* se puede apreciar una distorsión espacial muy acentuada con un efecto de diente de sierra en todos los bordes que no sean horizontales o verticales. Para el método *Brovey* la calidad espacial es mucho mejor con los bordes de las figuras bien definidos. Sin embargo, destaca una mayor distorsión espectral, que como ya se adelantó en estudios anteriores afecta más a las componentes azules. Cabe destacar la elevada distorsión espectral de *PCA*, que afecta a la componente roja y verde principalmente, puesto que las zonas azules mantienen su color.

Con el objetivo de hacer un estudio más exhaustivo de esta imagen, al igual que se hizo para las imágenes de diferentes coberturas, se analizan las imágenes diferencia analizando el detalle espacial y espectral de las diferentes componentes I, R, G y B.

Analizando los resultados espectrales (Tabla 6) para esta imagen sintética es más difícil hacer una valoración sobre la mejor o peor respuesta de cada método sobre las distintas componentes de color, porque mayoritariamente las diferencias están sobre los bordes de las figuras donde los colores se entremezclan. Se puede decir en todo caso que para los métodos basados en la transformada *wavelet* discreta se mantiene la información espectral en las zonas continuas. Sin embargo, los métodos basados en operaciones algebraicas o en transformadas *IHS* o *PCA* muestran mayores cambios sobre las zonas de colores continuos.

Tabla 6. Análisis visual de la calidad espectral de las componentes R-G-B (fila 1-2-3) de las imágenes fusionadas sintéticas.



Si analizamos los resultados de las diferencias espaciales (Tabla 7), tanto para el caso de la componente I como en el análisis de las bandas por separado se aprecia como para el método de fusión *IHS* los bordes quedan más delimitados que para el resto de métodos, siendo las que peores resultados muestran las técnicas basadas en la transformada *wavelet*. Aunque éstas últimas presentan contornos bien definidos en las bandas donde los colores que intervienen entre las formas pertenezcan a las otras bandas de color. Como ocurre en la banda G con las estrellas azules sobre fondo rojo o en la banda B con los rombos verdes sobre fondo rojo.

Tabla 7. Análisis visual del detalle espacial de las diferentes componentes de las imágenes fusionadas sintéticas: I (fila1), R (fila 2), G (fila 3) y B (fila 4).


En cuanto a los índices cuantitativos, se observa que en las medidas de calidad espacial, el *ERGAS* es efectivamente más alto para los métodos basados en análisis multiresolución. El índice *Zhou* es más complicado de interpretar puesto que presenta valores negativos.



Figura 41. Índices de calidad espacial sobre las imágenes fusionadas sintéticas.

De los índices de calidad espectral, según el *ERGAS* espectral se llega a las mismas conclusiones que para las imágenes analizadas anteriormente, de los que se deduce que las imágenes fusionadas por métodos basados en análisis multiresolucion presentan una calidad espectral mejor. Sin embargo, el resto de índices presentan menor variabilidad y en algunos casos no coinciden con la inspección visual.





Figura 42. Índices de calidad espectral sobre las imágenes fusionadas sintéticas.

2.5 Resumen

A lo largo de este capítulo se ha realizado un análisis detallado de ocho algoritmos de fusión de imágenes (*Brovey, IHS, eIHS, PCA, TWD, À trous AW, À trous AWI* y *À trous AWPC*). Éstos se han evaluado sobre imágenes de ocho cubiertas diferentes de la superficie terrestre (agrícola, costera, árida, forestal, agua embalsada, urbana y vegetación vigorosa) pertenecientes al satélite GeoEye-1, para analizar el comportamiento de cada uno de los algoritmos sobre las diferentes coberturas terrestres. El estudio se ha realizado tanto de manera cualitativa como cuantitativa. Cualitativamente se ha evaluado visualmente la calidad espectral y espacial comparando con la imagen multiespectral y/o PAN respectivamente. Para el análisis cuantitativo se han utilizado seis índices de calidad, que tratan de cuantificar la calidad espacial (*ERGAS* espacial e índice *Zhou*) y espectral (*ERGAS* espectral, CC, *Zhou, Q* y *SSIM*) de la imagen.

Todos los métodos de fusión mejoran considerablemente la calidad espacial de la imagen. Aunque no hay un único método de fusión que demuestre una supremacía en cuanto a mejora de la resolución espacial preservando la calidad espectral. El algoritmo de Mallat produce muchos artefactos y efecto de diente de sierra en los contornos, por tanto, no es adecuado para la fusión. En general, ha quedado patente que los métodos de fusión basados en el algoritmo de À trous presentan mejor compromiso entre calidad espacial y espectral. Siendo estas imágenes las que presentan un color más similar a la imagen MS original, con una calidad espacial aceptable. Sin embargo, otros métodos como los basados en operaciones aritméticas o de sustituciones de componentes, presentan mejores resultados espaciales con bordes más definidos, pero la calidad espectral se degrada considerablemente. Brovey ha demostrado ser el algoritmo que más distorsiona la información espectral. Asimismo, se ha completado el análisis evaluando los efectos de cada técnica de fusión sobre diferentes componentes de la imagen. En concreto, para el análisis espectral se han calculado las imágenes diferencia entre las bandas R, G y B de la multiespectral original y la fusionada. para el análisis espacial se han calculado las imágenes diferencia entre las componentes I, R, G y B de la fusionada filtrada paso alto y la PAN también filtrada. Y se aprecian mayores errores en unas componentes de color que en otras según el método de fusión, tanto a nivel espacial como espectral. Aunque el comportamiento no es común para los ocho métodos de fusión, si se observa la misma pauta para las ocho coberturas.

En general se puede concluir que el método de fusión más adecuado depende de las características de la imagen y de la aplicación concreta. El tipo de cubierta analizada puede influir en la selección del mejor algoritmo de fusión. Si se trata de una imagen homogénea, con extensiones uniformes, al no haber gran presencia de detalles espaciales, las imágenes fusionadas no presentan grandes diferencias, más allá de la variabilidad espectral que afecta en diferentes tonalidades del color, y, por tanto, las técnicas basadas en el algoritmo À *trous* son excelentes candidatas para generar una imagen fusionada de elevada calidad espectral.

Las métricas de calidad tienen comportamientos diferentes según el área de estudio y su rango de valores varía considerablemente según la imagen analizada. Parece que los índices *ERGAS* de calidad espectral y Q son los más fiables para medir la calidad espectral, coincidiendo con la evaluación cualitativa obteniéndose los mejores resultados en las imágenes fusionadas basadas en *À trous*. Por otro lado, los índices CC y *SSIM* son menos sensibles y en ciertos casos los resultados cuantitativos de *SSIM* no correlan con la percepción visual. Respecto a los índices de calidad espacial, el *ERGAS* es más robusto y se obteniendo los mejores resultados para los métodos basados en operaciones aritmética o sustitución de componentes (e*IHS*, *IHS*, *PCA* y *Brovey*). Sin embargo, el índice *Zhou* es más variable y no siempre se corresponde con el análisis cualitativo.

Finalmente, también se ha creado una imagen sintética abarcando colores diferentes y estructuras espaciales diversas. El análisis llevado a cabo ha sido equivalente al de las imágenes *GeoEye-1*. Cualitativamente las conclusiones son similares. En el análisis para las diferentes componentes de las imágenes fusionadas sintéticas se puede deducir que se mantiene la información espectral sobre las

zonas homogéneas para las imágenes fusionadas basadas en la transformada *wavelet*, y que son más bajos los errores espaciales en los contornos de la *Brovey* y la eIHS.

En resumen, se ha demostrado el compromiso espacial-espectral de forma que no es posible incorporar simultáneamente el máximo detalle espacial de la PAN sin degradar la información espectral. Así, en aplicaciones como la generación de mapas temáticos es importante garantizar una buena fidelidad espectral y, por tanto, algoritmos basados en la transformada *wavelet* À trous pueden ser buenos candidatos para el *pansharpening*.

Capítulo 3

Correcciones de las imágenes de alta resolución espacial

Inicialmente, las imágenes distribuidas por los proveedores están formadas por unos datos numéricos enteros que representan a los valores de radiancia codificados digitalmente y que se definen como Niveles Digitales (ND). Sin embargo, la radiancia registrada por el sensor no es una representación exacta de la radiancia emitida por las coberturas de la superficie terrestre. Esto significa que la imagen adquirida en formato numérico presenta una serie de anomalías con respecto a la escena real detectada. Estas anomalías están en la localización de los píxeles y en los niveles digitales que componen la matriz de datos. Las operaciones de corrección pretenden minimizar estas alteraciones y se enmarcan dentro de las operaciones de pre-procesamiento porque, en general, se llevan a cabo antes de realizar los procedimientos de extracción de información cuantitativa. Tras estas trasformaciones se obtiene una imagen corregida que es lo más próxima posible, geométrica y radiométricamente, a la verdadera energía radiante y características espaciales del área de estudio en el momento de la recogida de los datos.

3.1 Fuente de información

En este apartado, se describe con más detalle las características principales del sensor de muy alta resolución *WorldView-2* del cual se han obtenido las imágenes analizadas en este capítulo. Sobre estas imágenes se realizarán las pertinentes correcciones radiométricas, geométricas y atmosféricas para su posterior clasificación. Para este satélite, al igual que el *GeoEye-1* (analizado en el capítulo anterior), se adquieren imágenes de tipo multiespectral y pancromática, de forma simultánea, con resoluciones radiométricas de 11 bits. La empresa distribuidora es *DigitalGlobe* y ofrece sus imágenes con distintos niveles de procesado, de tal forma que se pueden adquirir desde productos básicos a corregidos radiométrica y geométricamente.

3.1.1 Satélite WorldView-2

El satélite *WorldView-2* (WV-2), lanzado en octubre de 2009, fue el primer satélite comercial multiespectral de 8 bandas de alta resolución. *WorldView-2* opera a una altura de 770 kilómetros y proporciona una resolución pancromática de 46 cm y una resolución multiespectral de 1.85 m. Tiene un tiempo de revisita promedio de 3.7 días, y puede recolectar hasta 1 millón de km² de imágenes de 8 bandas por día, lo cual mejora en gran medida la capacidad de captación de imágenes multiespectrales de *DigitalGlobe* para una obtención más rápida y precisa. *WorldView-2* expande sustancialmente la oferta de productos de imágenes para aplicaciones de teledetección.

La siguiente Tabla 8 muestra las características principales del satélite.

Información sobre el Ianzamiento	Fecha: 8 de octubre de 2009 Vehículo de lanzamiento: Delta 7920 (9 montables) Lugar de lanzamiento: Base Vandenberg de la Fuerza Aérea, California				
Órbita	Altitud: 770 km Tipo: sincrónica con el sol, 10:30 a.m. nodo descendente Período: 100 min				
Duración de la misión	De 10 a 12 años, incluidos todos los consumibles y degradables (p. e. propelente)				
Resolución del sensor	Pancromático: GSD de 0.46 m en el nadir; GSD de 0.52 m 20° fuera del na Multiespectral: GSD de 1.85 m en el nadir, GSD de 2.07 m 20° fuera del na				
Bandas de sensores	Pancromático 8 multiespec Costero: Azul: Verde: Amarillo:	b: 450–800 nm trales: 400-450 nm 450–510 nm 510-580 nm 585-625 nm	Rojo: Rojo borde: IR cercano1: IR cercano2:	630-690 nm 705-745 nm 770-895 nm 860-1040 nm	

Tabla 8. Características del satélite WorldView-2.

Rango dinámico	11 bits por píxel
Ancho de barrido	16.4 km en el nadir
Precisión de la geolocalización	Error circular del 90 % (circular error of 90%, CE90) CE90 <3.5 m demostrado sin puntos de control terrestre
Frecuencia de revisita	1.1 días a GSD de 1 m o menos 3.7 días 20° fuera del nadir o menos (GSD de 0.52 m)
Agilidad para la nueva determinación de objetivos	Tiempo de rotación a 200 km: 10 s
Máxima superficie contigua recolectada en un solo paso (ángulo de 30° fuera del nadir)	TIRA LARGA 112 km - 112 km - 138 km - 360 km 0BJETIVOS DE MÚLTIPLES PUNTOS 16.4 km 16.4 km 16.4 km 112 km - 16.4 km
Capacidad de recolección de imágenes	1 millón de km² por día
Comunicaciones	Datos de imágenes y auxiliares: banda X de 800 Mbps Datos de gestión interna: 4, 16 o 32 kbps en tiempo real, 524 kbps almacenado, banda X Comando: banda S de 2 o 64 kbps
Almacenamiento a bordo	2199 Gb de estado sólido con detección y corrección de errores

Las principales características de las bandas multiespectrales del WV-2 son las siguientes:

 Azul costero (400-450 nm): ayuda en la realización de análisis vegetativo debido a su alta absorción. Mayor penetración en el agua, muy útil en los estudios batimétricos. Tiene el potencial para mejorar las técnicas de corrección atmosférica debido a la mayor absorción del ozono y por su alto nivel de difusión de Rayleigh.

- Azul (450-510 nm): es equivalente a la banda azul de otros satélites de alta resolución. Al igual que el azul costero, es afectado fuertemente por la absorción de la clorofila y tiene una alta penetración en el agua. El canal azul tiene la ventaja de soportar menores efectos atmosféricos que el azul costero.
- Verde (510-580 nm): esta banda permite la detección de la vegetación gracias al pico de reflectividad dentro del rango visible. Combinado con la banda amarilla permite discriminar ente tipos de vegetaciones terrestres. Esta banda permite una amplia penetración en el agua, incluso de mayor profundidad en aguas costeras con altos niveles de materia disuelta y/o suspendida.
- Amarillo (585-625 nm): muy importante para la clasificación, dado que detecta la "amarillez" particular de la vegetación, tanto en tierra como en el agua. Permitiendo una penetración moderada en el agua.
- Rojo (630-690 nm): permite discriminar la vegetación terrestre junto al rojo borde gracias a su baja reflectividad. La penetración de esta banda en el agua se reduce a unos pocos metros.
- Rojo borde (705-745 nm): muy valiosa para medir la salud de plantas y ayudar en la clasificación de la vegetación. La penetración de esta banda en el agua es aún más reducida que el rojo.
- Infrarrojo cercano NIR1 (770-895 nm): proporciona una alta separación con la banda rojo borde, tiene un alto valor de reflectividad en la vegetación terrestre siendo muy útil en la clasificación de cubiertas terrestres. La penetración en el agua es casi nula siendo muy importante en los algoritmos de eliminación de brillo solar.
- Infrarrojo cercano NIR2 (860-1040 nm): tiene un alto valor de reflectividad en la vegetación terrestre siendo muy útil en la clasificación de cubiertas terrestres. Se ve menos afectada por la influencia de la atmósfera. Permite el análisis de la vegetación y estudios de la biomasa. La penetración en el agua es casi nula siendo muy importante en los algoritmos de eliminación de brillo solar.

Las imágenes Worldview-2 están disponibles para su adquisición según 3 niveles de procesamiento:

- Basic, que incluye únicamente la corrección radiométrica.
- Standard/Ortho-ready, que incluye la corrección radiométrica y geométrica.
- Stereo, que incluye 2 escenas superpuestas con ángulo de visión estéreo.

Las bandas multiespectrales y la pancromática 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.

A continuación, se procede a describir en cada apartado las diferentes técnicas de corrección radiométrica, geométrica y atmosférica, que son necesarias aplicar sobre las imágenes, para poder interpretar de forma correcta los datos. Sin embargo, las imágenes suelen ser distribuidas por lo proveedores con correcciones radiométricas y geométricas básicas aplicadas. En la Figura 43 se muestran las diferentes fases del proceso de corrección y, en el marco punteado, se indica los procesos que han sido implementados y analizados en esta *Tesis Doctoral* relativos a cada una de las correcciones.



Figura 43. Diagrama de correcciones radiométrica, geométricas y atmosféricas.

3.2 Corrección radiométrica de imágenes

Las correcciones radiométricas son aquellas técnicas que tienen por objeto modificar los niveles digitales de las imágenes con el fin de corregir problemas de distinta naturaleza, no sólo debido a la eficiencia cuántica del detector, sino también a las pérdidas de transmisión debidas a la óptica del telescopio y a los filtros ópticos multiespectrales. Estas correcciones abordan los siguientes procedimientos:

- Desaparición de píxeles o líneas: tratan los problemas radiométricos debidos al mal funcionamiento del sensor, una caída de las lentes o de la comunicación para la transferencia de imagen, llevando a la desaparición de líneas o píxeles.
- Corrección radiométrica relativa: tratan las causas principales de la falta de uniformidad sobre la imagen, debido a variabilidades en la respuesta del detector, variabilidad en la ganancia y offset de la electrónica, desplazamiento de las lentes o contaminación por partículas en el plano focal. El resultado es la aparición periódica de una banda más clara u oscura que las demás.
- Obtención de la radiancia *ToA (Top of Atmosphere)*: definida como la radiancia reflejada por la superficie de la Tierra y la columna vertical de la atmósfera, que entra por la apertura del telescopio a la altura del satélite.
- Caracterización de la irradiancia solar y obtención del parámetro físico, reflectancia ToA.

A continuación, se describen con más detalle los principales procesos de corrección radiométrica.

3.2.1 **Desaparición de píxeles o líneas**

Si se ha perdido el valor de algún píxel, la solución es estimarlo como la media de los valores del mismo píxel en las líneas anterior y posterior. Para detectar líneas perdidas se compara la media de los Niveles Digitales de una línea con las medias de las líneas anterior y posterior. Para detectar píxeles perdidos se compara el valor de un píxel con los de los 8 píxeles vecinos mediante algún procedimiento de filtrado.

3.2.2 Corrección radiométrica relativa

La corrección radiométrica relativa es realizada sobre los datos crudos provenientes de todos los detectores en todas las bandas, durante los momentos iniciales de generación de los productos del satélite. Esta corrección incluye la eliminación del offset y una corrección no uniforme [52].

Asumiendo que los detectores tienen una respuesta lineal en función de la radiancia de entrada, los niveles digitales de la imagen cruda vendrán dados por,

$$DN_{Banda} = L_{Banda} \cdot Gain_{Banda} + Offset_{Banda}$$
(28)

donde L_{Banda} es la radiancia espectral [W-m⁻²sr⁻¹-µm⁻¹], $Gain_{Banda}$ es la ganancia absoluta, y $Offset_{Banda}$ es el offset del instrumento. De esta manera se determina una única ganancia para cada banda y, luego, cada detector es escalado respecto a los otros detectores en la misma banda. Separando estas ganancias absoluta y relativa se llega a la siguiente expresión:

$$DN_{Banda} = L_{Banda} \cdot Gain_{Banda} \cdot B_{Banda} + Offset_{Banda}$$
(29)

donde $Gain_{Banda}$ es la ganancia absoluta y B_{Banda} es la ganancia relativa del detector. Por definición, la media relativa de las ganancias tiene que ser igual a uno. Para normalizar la nomenclatura, redefinimos DN_{Banda} como p_{Banda} , $L_{Band} \cdot Gain_{Banda}$ como q_{Banda} y $Offset_{Banda}$ como A_{Banda} . Así, podemos expresar la ecuación (29) como,

$$p_{Banda} = q_{Banda} \cdot B_{Banda} + A_{Banda} \tag{30}$$

donde p_{Banda} son los datos crudos, q_{Banda} son los datos del detector radiométricamente corregidos, los cuales han sido linealmente escalados respecto a los valores de radiancia, B_{Banda} es la ganacia relativa del detector, y A_{Banda} es el offset.

Los valores de configuración de la ganancia para la imagen pancromática (PAN) y las bandas multiespectrales (MS) dependen de varios parámetros como la banda, el tiempo-retardo de integración (*TDI, time-delayed-integration*), la resolución radiométrica del producto, etc. Los valores de ganancia apropiados, teniendo en cuenta la combinación de estos parámetros, son proporcionados en el archivo de metadatos que acompaña a cada producto.

A partir de la ecuación (30), los datos del detector radiométricamente corregidos, son:

$$q_{Banda} = p_{Banda} = \frac{q_{Banda} - A_{Banda}}{B_{Banda}}$$
(31)

Para ilustrar las no uniformidades que presenta el bandeado en una imagen sólo hay que referirse a la Figura 44, donde se observa el resultado de aplicar la corrección radiométrica.





(b)

Figura 44. (a) Efecto del bandeado de la imagen de teledetección y (b) imagen corregida. Fuente: Digitalglobe.

Habitualmente, estas correcciones de bandeado ya vienen aplicadas sobre las imágenes.

3.2.3 Obtención de la radiancia ToA

La conversión desde los datos del satélite, radiométricamente corregidos, a valores de radiancia se realiza mediante la siguiente expresión:

$$L_{\lambda Banda} = \frac{K_{Banda} \cdot q_{Pixel,Banda}}{\Delta \lambda_{Banda}}$$
(32)

donde $L_{\lambda Banda}$ representa la imagen de radiancia, K_{Banda} es el factor de calibración radiométrica para una banda, $q_{Pixel,Banda}$ es la imagen radiométricamente corregida y $\Delta \lambda_{Banda}$ es el ancho de banda efectivo para cada banda específica. La eliminación del offset no es necesaria en este punto, dado que ya ha sido realizado en el paso de corrección radiométrica relativa durante la generación del producto.

La conversión a radiancia es un proceso simple que implica la realización de dos pasos:

- I. Multiplicar los valores de píxel de la imagen corregida radiométricamente por el factor de calibración K.
- II. Dividir el resultado por el ancho de banda efectivo apropiado para cada banda.

Los valores del factor de calibración y el ancho de banda efectivo para cada banda son proporcionados con cada producto y son especificados en el archivo de metadatos.

3.2.4 Caracterización de la irradiancia solar y obtención del parámetro físico, reflectancia ToA

La mayoría de los sensores ópticos son sensibles a las longitudes de onda de la luz en el visible hasta porciones del infrarrojo cercano del espectro electromagnético. En esta región, la medida por el sensor está dominada por la radiación solar reflejada, donde la irradiación de la superficie y atmósfera como cuerpo negro es despreciable. La irradiancia espectral está definida como la energía por unidad de área que incide sobre la superficie en función de la longitud de onda. Como el Sol actúa como un radiador de cuerpo negro, la irradiancia solar espectral puede ser aproximada con las curvas de cuerpo negro de Planck a 5900 K, corregido por el área del disco solar y la distancia entre la Tierra y el Sol. Sin embargo, un modelo de la irradiancia solar [53] fue creado por *World Radiation Center* (WRC) a partir de una serie de medidas solares y es el utilizado para la conversión a reflectancia, como se muestra en la Figura 45.



Figura 45. Curva de irradiancia espectral solar estándar WRC. Fuente: NASA.

Como se muestra en la Figura 45, la curva de irradiancia espectral solar WRC, alcanza su máximo en 450 nm (azul-costero y azul) y disminuye ligeramente para las demás longitudes de onda. En general, la irradiancia solar espectral promedio está definida como la media ponderada de los valores de máxima irradiancia efectiva normalizada sobre la banda de paso del detector, definida por:

$$Esun_{\lambda \ banda} = \frac{\int_{0}^{\infty} Esun(\lambda) \cdot R'(\lambda)_{Banda} \cdot d\lambda}{\int_{0}^{\infty} R'(\lambda)_{Banda} \cdot d\lambda}$$
(33)

donde $Esun_{\lambda \ banda}$ es la irradiancia solar espectral promedio en [W-m⁻²-µm⁻¹] para una banda dada, $Esun(\lambda)$ es la curva de irradiancia espectral solar WRC [W-m⁻²-µm⁻¹] mostrada en la Figura 45 y $R'(\lambda)_{Banda}$ es la respuesta de radiancia espectral relativa para una banda dada.

A modo de referencia, para el caso concreto del sensor del *WorldView-2* los valores de irradiancia solar espectral promedio para una distancia Tierra-Sol de 1 Unidad Astronómica, normal a la superficie que está siendo iluminada, se proporcionan en la Tabla 9.

Banda espectral	Irradiancia solar [W-m ⁻² -µm ⁻¹]
Pancromática	1580.8140
Costera	1758.2229
Azul	1974.2416
Verde	1856.4104
Amarillo	1738.4791
Rojo	1559.4555
Rojo extremo	1342.0695
Infrarrojo cercano 1	1069.7302
Infrarrojo cercano 2	861.2866

3.2.5 Determinación de la geometría del Sol

Las variaciones en la irradiancia solar están dominadas por la geometría solar durante la adquisición de una imagen específica. El Sol puede ser aproximado como un punto dado en que la distancia entre la Tierra y el Sol es mucho mayor que el diámetro del Sol. La irradiancia de un punto es proporcional a la inversa del cuadrado de la distancia. Así, la irradiancia de un punto a la distancia deseada, puede ser calculada dando la irradiancia de la fuente a una distancia específica, mediante:

$$E_2 = \frac{E_1 \cdot r_1^2}{r_2^2} \tag{34}$$

donde E_2 es la irradiancia buscada a la distancia deseada r_2 y E_1 es la irradiancia conocida de la fuente a la distancia específica r_1 . La distancia media entre la Tierra y el Sol es una unidad astronómica (*UA*). Así la ecuación queda como:

$$E_2 = \frac{E_1}{r_2^2}$$
(35)

Dado que el dato de irradiancia solar a la distancia de 1 UA ha sido anteriormente definido como $Esun_{\lambda Banda}$, se puede reescribir la ecuación anterior como,

$$Ees_{\lambda Banda} = \frac{Esun_{\lambda Banda}}{d_{ES}^2}$$
(36)

donde $Ees_{\lambda Banda}$ es la irradiancia solar media a una distancia dada entre la Tierra y el Sol, $Esun_{\lambda Banda}$ es la irradiancia solar dada en la Tabla 9 y d_{ES}^2 es la distancia entre el Sol y la Tierra, dada en unidades astronómicas, en el momento de adquisición de la imagen.

La irradiancia solar definida se refiere a la normal a la superficie que está siendo iluminada. A medida que el ángulo cenital solar se mueve fuera de la normal, aparece el efecto de área proyectada y, consecuentemente, el mismo haz de luz ilumina un área más grande. Este efecto es una función del coseno del ángulo de iluminación y viene dado por,

$$E\theta_{\lambda Banda} = Esun_{\lambda Banda} \cdot cos(\theta_s) \tag{37}$$

donde $E\theta_{\lambda Banda}$ es la irradiancia solar media para un ángulo cenital del Sol, $Esun_{\lambda Banda}$ es la irradiancia solar media normal a la superficie que está siendo iluminada, que coinciden con los datos de la Tabla 9 y θ_s es el ángulo cenital del Sol.

Las ecuaciones (36) y (37) pueden ser combinadas para obtener la irradiancia solar media, teniendo en cuenta la geometría del Sol, en el momento de adquisición de la imagen:

$$E_{\lambda Banda} = \frac{Esun_{\lambda Banda}}{d_{ES}^2} \cdot \cos(\theta_s)$$
(38)

3.2.6 Distancia Tierra-Sol

Para calcular la distancia entre la Tierra y el Sol, para un producto concreto, es necesario calcular el Día Juliano a partir de los datos de la hora de adquisición de la imagen [54]. La hora de adquisición se encuentra en el archivo de metadatos y representa la hora *UTC*. Del formato *UTC*, se extrae el año, el mes, el día y se calcula la hora universal (UT, *Universal Time*) a partir de la hora, minutos y segundos:

$$UT = horas + \frac{minutos}{60.0} + \frac{segundos}{3600.0}$$
(39)

El Día Juliano (JD), se puede calcular a partir de la siguiente ecuación:

$$JD = int[365.25 \cdot (ano + 4716)] + int[30.6001 \cdot (mes + 1)] + dia + \frac{UT}{24.0} + B - 1524.5$$
(40)

donde $B = 2 - A + int \left(\frac{A}{4}\right) \operatorname{con} A = int \left(\frac{ano}{100}\right)$, *int* hace referencia a truncar los decimales y quedarse sólo con la parte entera del número en cuestión. Si la imagen fue adquirida en enero o febrero, antes de aplicar la ecuación del día juliano, el año y el mes debe ser modificado como: (año = año - 1) y (mes = mes +12).

Una vez se ha calculado el *JD*, se puede obtener la distancia entre la Tierra y el Sol a partir de la siguiente ecuación (41) [55]:

$$d_{ES} = 1.00014 - 0.01671 \cdot \cos(g) - 0.00014 \cdot \cos(2g) \quad [en \ U.A.]$$
(41)

donde, g = 357.529 + 0.98560028 * D [grados], y D = JD - 2451545.0.

3.2.7 Angulo cenital solar

El valor medio del ángulo cenital del Sol de una imagen de muy alta resolución es una aproximación válida para toda la imagen debido a que la variación del ángulo es despreciable dentro de la escena. La media del ángulo de elevación (θ_e), expresado en grados, para un producto dado, es calculada para el centro de la escena y puede ser obtenido a partir del archivo de metadatos. El ángulo cenital del Sol se puede obtener, a partir de este dato, aplicando la siguiente ecuación:

$$\theta_s = 90 - \theta_e \tag{42}$$

3.2.8 Reflectancia a la altura de la atmósfera (ToA)

La forma de las curvas de radiancia espectral a la altura de la atmósfera están dominadas por la forma de la curva solar. Esta radiancia puede ser modelada con la contribución de tres radiaciones principales:

$$L_{\lambda}^{s} = L_{\lambda}^{su} + L_{\lambda}^{sd} + L_{\lambda}^{sp}$$
(43)

donde L_{λ}^{s} es la radiancia total a lo alto de la atmósfera, L_{λ}^{su} es la radiancia reflejada por la superficie, L_{λ}^{sd} es la radiación dispersada por la atmósfera y reflejada en la superficie y L_{λ}^{sp} es la radiancia dispersada por las moléculas de la atmósfera que depende de la longitud de onda. Expandiendo la radiación reflejada por la superficie terrestre y asumiendo una superficie Lambertiana, se puede expresar como:

$$L_{\lambda}^{su} = \rho_{\lambda} \frac{\tau_{\nu\lambda} \cdot \tau_{s\lambda} \cdot Esun_{\lambda,Banda} \cdot \cos(\theta_s)}{d_{ES}^2 \cdot \pi}$$
(44)

donde ρ_{λ} es la reflectancia espectral difusa, $\tau_{\nu\lambda}$ es la transmisividad de la atmósfera en la dirección del sensor, $\tau_{s\lambda}$ es la transmisividad de la atmósfera que atraviesa la radiación solar dirección descendente, $Esun_{\lambda,Banda}$ es la irradiancia solar, θ_s es el ángulo cenital del Sol, y d_{ES} es la distancia entre la Tierra y el Sol. Sustituyendo en la ecuación (43), obtenemos lo siguiente:

$$L_{\lambda}^{s} = \rho_{\lambda} \frac{\tau_{\nu\lambda} \cdot \tau_{s\lambda} \cdot Esun_{\lambda,Banda} \cdot cos(\theta_{s})}{d_{ES}^{2} \cdot \pi} + L_{\lambda}^{sd} + L_{\lambda}^{sp}$$
(45)

Despreciando los efectos de la atmósfera, que se compensan durante el proceso de corrección atmosférica, obtenemos la siguiente ecuación:

$$L_{\lambda}^{s} = \rho_{\lambda} \frac{Esun_{\lambda,Banda} \cdot cos(\theta_{s})}{d_{ES}^{2} \cdot \pi}$$
(46)

Finalmente, reorganizando los términos, para despejar el valor de reflectancia, obtenemos lo siguiente:

$$\rho_{\lambda} = \frac{L_{\lambda}^{s} \cdot d_{ES}^{2} \cdot \pi}{Esun_{\lambda,Banda} \cdot \cos(\theta_{s})}$$
(47)

3.3 Corrección atmosférica de las imágenes

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: (a) la absorción de la energía en determinadas bandas del espectro, (b) la dispersión (*o scattering*) de determinados flujos en función de su longitud de onda y (c) la emisión, inherente a todo cuerpo caliente. Todos estos procesos producen modificaciones en la radiación originalmente propagada entre la cubierta terrestre y el sensor [56] [57].

- Absorción de la atmósfera. La atmósfera se comporta como un filtro selectivo que limita la observación remota a longitudes de onda concretas. Los principales gases causantes de este fenómeno son: oxígeno atómico (O₂), ozono (O₃), vapor de agua y el dióxido de carbono (CO₂). Estos gases reducen la observación espacial en determinadas bandas, conocidas como ventanas atmosféricas, en donde la transmisividad de la atmósfera es suficientemente alta, como se puede observar en la Figura 46.
- Dispersión atmosférica. El efecto de la dispersión atmosférica resulta un proceso más complejo de resolver, respecto a la absorción, ya que está presente en cualquier imagen adquirida por los sensores remotos. Ésta dispersión de la radiación electromagnética es causada por la interacción entre ésta y los gases y partículas atmosféricas en suspensión. La reflexión consecuente a ese choque implica un aporte adicional a la radiancia proveniente de la superficie. Cuando se pretende convertir los valores digitales de una imagen a parámetros físicos, es importante considerar este factor, especialmente fundamental en superficies de baja reflectividad y en análisis multitemporal.
- Emisión atmosférica. Al igual que cualquier cuerpo por encima del cero absoluto, la atmósfera emite radiación electromagnética en el rango térmico, por lo que este parámetro debe considerarse, fundamentalmente cuando se hace uso de las bandas del infrarrojo térmico.



Figura 46. Transmisividad de la atmósfera a distintas longitudes de onda. Fuente [58].

3.3.1 Modelado de la influencia de la atmósfera

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 de la superficie. Por ello, se hace necesario plantear un modelado de la influencia atmosférica.

La influencia atmosférica no afecta por igual a las dos componentes del cálculo de reflectividad, flujo descendente y ascendente, ya que el espesor y condiciones de la atmósfera son distintos. Así, la radiancia que recibe el sensor se puede expresar como:

$$L_{\lambda}^{sen} = L_{su,\lambda} * \tau_{\nu\lambda} + L_{a,\lambda}$$
(48)

siendo $L_{su,\lambda}$ la radiancia que sale de la superficie, $\tau_{v\lambda}$ la transmisividad de la atmósfera para el flujo ascendente, $L_{a,\lambda}$ la radiancia aportada por la dispersión atmosférica para la banda de longitud de onda λ .

La transmisividad en la dirección ascendente depende del espesor óptico del ozono ($\tau_{oz,\lambda}$), de aerosoles ($\tau_{a,\lambda}$) y moléculas ($\tau_{r,\lambda}$), para esa misma banda λ , y del ángulo de visión (θ_v), expresado mediante:

$$\tau_{v\lambda} = e^{\left(\frac{-\tau_{oz,\lambda} - \tau_{a,\lambda} - \tau_{r,\lambda}}{\cos \theta_v}\right)}$$
(49)

El ángulo de observación debe considerarse, dado que la adquisición de los satélites no tiene porqué ser vertical. La Figura 47 muestra, de forma gráfica, cada uno de los parámetros que intervienen en las ecuaciones de modelado de influencia de la atmósfera.



Figura 47. Modelo de influencia atmosférica.

Respecto al flujo incidente, hay que tener en cuenta que la irradiancia que llega a la superficie ($E_{su,\lambda}$) no es la que llega a lo alto de la atmósfera ($E_{0,\lambda}$), sino que también está afectada por la atenuación de la atmósfera y por la componente de luz difusa, como:

$$E_{su,\lambda} = E_{0\lambda} \cos \theta_s \tau_{s\lambda} + E_{d,\lambda}$$
(50)

donde $E_{0,\lambda}$ es la irradiancia solar en lo alto de la atmósfera, θ_s es el ángulo cenital del flujo incidente formado por la vertical y los rayos solares y que se obtiene como el complementario del ángulo de elevación solar que se incluye en la cabecera de la imagen, $\tau_{s\lambda}$ es la transmisividad que afecta al rayo incidente y $E_{d,\lambda}$ es la irradiancia difusa, como consecuencia de la dispersión y que depende de las condiciones de la atmósfera. La transmisividad del rayo incidente, en este caso, depende del ángulo de incidencia:

$$\tau_{s\lambda} = e^{\left(\frac{-\tau_{oz,\lambda} - \tau_{a,\lambda} - \tau_{r,\lambda}}{\cos\theta_s}\right)}$$
(51)

Si utilizamos la ecuación (47) de la reflectividad, y sustituimos en ella las expresiones anteriormente descritas, obtenemos que la reflectividad de la superficie terrestre se puede expresar como:

$$\rho_{\lambda} = \frac{(L_{\lambda}^{sen} - L_{a,\lambda}) \cdot d_{ES}^2 \cdot \pi}{\tau_{\nu\lambda} (E_{o\lambda} \cdot \cos \theta_S \cdot \tau_{s\lambda} + E_{d,\lambda})}$$
(52)

Para proceder a realizar las correcciones atmosféricas se requiere de datos sobre las condiciones de la atmósfera, en el momento de tomar la imagen, que no suelen estar disponibles. Por ello, se suele recurrir a ciertas simplificaciones o aproximaciones que modelen estos datos. En los siguientes apartados se procede a describir las distintas técnicas utilizadas para abordar la corrección atmosférica de las imágenes procedentes de satélites.

3.3.2 Estado del arte en técnicas de corrección atmosférica

Para compensar los efectos atmosféricos, parámetros como la distribución de aerosoles, la cantidad de vapor de agua y la visibilidad de la escena deben ser conocidos. Dado que las medidas de estas propiedades atmosféricas raramente están disponibles en el momento de captación de la imagen, se han desarrollado diferentes estrategias. Los métodos más comúnmente utilizados basados en la

imagen son el DOS (Dark Object Subtraction) [59], que corrige el efecto de la dispersión aditiva, COST (Cosine of the sun zenith angle) [60] que además tiene en cuenta el efecto multiplicativo de la transmitancia, y el QUAC (QUick Atmospheric Correction) [61] que está basado en la demostración empírica de que la reflectancia media de diversos materiales no depende de la escena. Por otro lado, el método SMAC (Simplified Method for the Atmospheric Correction) [62] es un método semi-empírico diseñado para la corrección atmosférica de series largas de datos adquiridos para alcanzar grandes campos de visión. El ELC (Empirical Line Calibration) [63] usa medidas de campo de la reflectancia de la superficie, a partir de una serie de objetos calibrados e invariantes en el tiempo, para estimar la reflectancia en cada banda. Para realizar la corrección atmosférica se desarrolla una ecuación de ajuste por regresión para cada banda de la imagen. Por último, para modelar el efecto atmosférico se han propuesto desarrollos más complejos, basados en un modelo de transferencia radiativa (Radiative Transfer Code, RTC) de la atmósfera como el MODTRAN (MODerate resolution atmospheric TRANsmission) [64], FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes) [65], ATCOR (ATmospheric CORrection) [66] y el 6S (Second Simulation of a Satellite Signal in the Solar Spectrum) [67]. A continuación, se procede a describir en detalle los algoritmos objeto de estudio y análisis en esta Tesis Doctoral.

Dark Object Subtraction (DOS)

El método *Dark Object Subtraction (DOS)* [59], se trata de un algoritmo de corrección basado sólo en los datos de la propia imagen. Este método, a pesar de ser muy utilizado por la comunidad científica, es de aplicación limitada, puesto que sólo tiene en cuenta el efecto aditivo de la dispersión atmosférica y no el efecto atenuador de la transmisividad. El núcleo de esta técnica se basa en asumir que algunos píxeles en la imagen están en completa sombra y, por lo tanto, sus radiancias a la entrada del sensor deberían ser atribuidas sólo a la dispersión atmosférica, no teniéndose en cuenta la irradiancia difusa ($E_{d,\lambda}$). De forma práctica, los valores de estos píxeles se obtienen a partir del histograma de cada banda. Así, se atribuye el efecto de dispersión atmosférica al valor mínimo superior a cero. La corrección atmosférica se consigue restando a todos los píxeles de la imagen el mínimo de esa banda. La ecuación de cálculo de reflectividad, teniendo en cuenta esta suposición, queda de la siguiente forma:

$$\rho_{\lambda} = \frac{(L_{\lambda}^{sen} - L_{\lambda}^{haze}) \cdot d_{ES}^{2} \cdot \pi}{E_{o,\lambda} \cdot \cos \theta_{s}}$$
(53)

donde L_{λ}^{haze} representa los valores de radiancia mínima, obtenidos a partir del histograma de cada banda.

Algoritmo de corrección atmosférica QUick Atmospheric Correction (QUAC)

La característica más importante de este algoritmo reside en que se basa en información de la escena, requiriendo solamente especificaciones sobre la localización de las bandas del sensor y su calibración radiométrica. *QUAC* [61] asume una relación lineal entre la reflectancia espectral y la radiancia medida, como una buena aproximación para la mayoría de las escenas.

Una explicación física del algoritmo es representada en la Figura 48. La radiancia espectral observada, ρ_{obs} para un píxel con reflectancia superficial ρ_{sur} es la suma de los tres caminos mostrados en la Figura 48.



Figura 48. Caminos A, B, y C mediante los cuales los fotones se desplazan hacia el sensor remoto.

La ecuación que caracteriza al sistema responde a la ecuación (54):

$$\rho_{obs} = (A + C\rho_{ave}) + B\rho_{sur} \tag{54}$$

Las componentes ($A + C\rho_{ave}$) son agrupadas, porque son aproximadamente constantes sobre la imagen, de tal forma que se puede considerar como un Offset común para todos los píxeles de la imagen. Así, se puede expresar la reflectividad superficial en términos de la señal observada y los parámetros atmosféricos derivados:

$$\rho_{sur} = Gain \left(\rho_{obs} - Offset\right) \tag{55}$$

donde *Gain* = 1/*B* y el *Offset* = ($A + C\rho_{ave}$). Los parámetros *A*, *B* y *C* se determinan directamente desde la información espectral de la escena y algunas suposiciones subyacentes claves [68]. A continuación, se muestran las expresiones para obtener la ganancia y el Offset:

$$Gain = \frac{\langle \rho_{end} \rangle_{lib}}{\langle \rho_{obs} - C \rho_{ave} \rangle_{end}}$$
(56)

Offset = valor del pixel más oscuro para cada banda

donde $\langle \rho_{end} \rangle_{lib}$ es el valor medio de los *endmembers* espectrales que representan la reflectancia espectral de diferentes materiales incluidos en una librería de referencia y $\langle \rho_{obs} - C \rho_{ave} \rangle_{end}$ es el valor medio de una colección de *endmembers* recuperados a partir de los espectros de los píxeles presentes en la escena [69].

Un *endmember* representa un único espectro. En la mayoría de los casos, la combinación lineal de una pequeña cantidad de *endmembers* espectrales puede representar con exactitud un gran número de espectros asociados con una librería espectral o imagen. En *QUAC* se utiliza el código SMACC (*Sequential Maximum Angle Convex Cone*) para encontrar los *endmembers*.

La suposición clave que empíricamente sostiene *QUAC* para la mayoría de las escenas, es que la media de los espectros de reflectancia de los *endmembers* que no están altamente estructurada (es decir, excluyendo la vegetación, barro, etc.), es siempre la misma. De forma más específica, se asume que cada imagen presenta al menos más de diez materiales espectralmente diferentes, cuyo espectro medio puede ser considerado como una referencia universal (ver Figura 49).



Figura 49. Medias de diferentes librerías de endmembers seleccionados sobre diferentes sensores y diferente número de endmembers. Fuente [61].

El espectro de referencia universal se deriva del promedio de una colección de diversos espectros procedentes de materiales naturales y artificiales. Típicamente se extraen unos 50 *endmembers* por escena para el proceso de corrección, y el espectro de referencia se basa en ese mismo número de *endmembers*. Es importante eliminar espectros que puedan introducir características no deseadas o desviaciones en la curva de ganancia. El ejemplo más común es la vegetación, que alcanza un fuerte incremento en el rojo borde. *QUAC* descarta los píxeles de vegetación utilizando el índice *NDVI (Normalized Difference Vegetation Index)* antes de extraer los *endmembers* de la imagen.

Para el cálculo correcto del offset se requiere realizar previamente los siguientes pasos: (1) eliminar los valores de píxeles extremos (2) promediar los píxeles adyacentes en una línea (3) descartar los valores menores o igual a 0 y (4) aplicar un filtrado de mediana para eliminar artefactos brillantes.

Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes (FLAASH)

Este algoritmo utiliza *MODTRAN4* [64], que se corresponde con una evolución del código de transferencia radiativa *MODTRAN*. La ecuación para recuperar la radiancia espectral se representa de la siguiente manera:

$$L^* = \frac{A \cdot \rho}{1 - \rho_e S} + \frac{B \cdot \rho_e}{1 - \rho_e S} + L_s^*$$
(57)

donde, ρ es la reflectividad superficial del píxel, ρ_e es la reflectividad superficial media para el píxel y su región vecina, *S* es el albedo esférico de la atmósfera, L_s^* es la radiancia retrodispersada por la atmósfera y *A* y *B* son coeficientes que dependen de las condiciones atmosféricas y geométricas [70].

El primer término de la ecuación corresponde a la radiancia procedente de la superficie que llega directamente a la entrada del sensor, mientras que el segundo término corresponde a la radiancia de la superficie que es dispersada por la atmósfera antes de llegar al sensor. La distinción entre ρ y ρ_e , radica en tener en cuenta el efecto de adyacencia (mezcla espacial de radiancia entre los píxeles vecinos) causada por la dispersión atmosférica.

Para un modelo de atmósfera específico los valores de *A*, *B*, *S* y L^* pueden ser determinados empíricamente a través de simulaciones *MODTRAN*, que permiten obtener las radiancias espectrales totales y directas desde el suelo, calculadas en tres valores diferentes de reflectividad superficial: 0, 0.5 y 1. El modelado de la atmósfera se ejecuta en correspondencia con la elección

de uno de los 6 modelos que presenta el estándar de *MODTRAN*. Cada uno de ellos definidos por la temperatura, presión, densidad y la combinación de diferentes proporciones de H₂O, O₃, CH₄, CO y N₂O. Los modelos de atmósfera definidos son: *Sub-Artic Winter (SAW), Mid-Latitude Winter (MLW), Tropical (T), Mid-Latitude Summer (MLS), Sub-Artic Summer (SAS) y U.S. Standard (US)* [71].

En cuanto al modelo de aerosol, *FLAASH* proporciona 4 modelos que se basan en el estándar *MODTRAN*. Dichos modelos se basan en compuestos como agua disuelta, polvo, humo, sal de mar, etc. que se mezclan homogéneamente. Además se caracteriza el crecimiento de tamaño de las partículas de aerosol y sus cambios en el índice de refractividad como función de la humedad relativa. Los cuatro modelos de aerosol definidos son: rural, urbano, marítimo y troposférico [72].

El ángulo de visión y el ángulo solar en el momento de la adquisición, junto con los valores nominales de la elevación superficial, el tipo de aerosol y el rango visible de la escena deben ser especificados. Para tener en cuenta posibles variaciones en la columna de vapor de agua a través de la escena, se establecen una serie de perfiles de agua variables. Para ello *MODTRAN4* permite introducir un factor de escala que es aplicado sobre el perfil nominal del agua dentro del modelo de atmósfera especificado.

Al igual que hacen otros métodos, antes de obtener los valores de reflectividad corregidos se recupera la columna de vapor de agua píxel a píxel. Para ello se utilizan promedios de radiancias en dos conjuntos de canales: unos de absorción y otros de referencia. El primer conjunto centrado en la banda de agua (típicamente a 1.13µm) y el otro se toma en los bordes de dicha banda. En caso de sensores donde las imágenes no contienen las bandas en la longitud de onda apropiada para soportar la recuperación de agua, la cantidad de columna de vapor de agua es determinada por la selección del usuario en la elección del modelo atmosférico. La recuperación del agua es realizada construyendo una *look-up-table (LUT)* bidimensional desde las salidas de *MODTRAN4* y a través de un proceso de triangulación de *Delaunay* [73].

El algoritmo *FLAASH* incluye un método para la recuperación de la cantidad de aerosol que presenta la escena a través de la selección de píxeles oscuros de terreno que se presenta en ella para diferentes rangos de visibilidad. Dicho método se basa en las observaciones de *Kauffman* [74] que encuentran una relación fija entre las reflectancias para píxeles en longitudes de onda de 660 nm y 2100 nm. En el caso de no disponer de estas bandas, *FLAASH* realiza una aproximación basada en el concepto de profundidad óptica para obtener la visibilidad de la escena. Así, se define la visibilidad V, como un rango meteorológico centrado en 550nm y que se relaciona con el coeficiente de extinción β por la ecuación siguiente (58):

$$V = \frac{3,912}{\beta} \tag{58}$$

donde β se define como el espesor óptico horizontal por kilómetro. Un valor relacionado a éste y más fácilmente adquirible a través de mediciones meteorológicas y satelitales es el espesor óptico de aerosoles, que comúnmente se denota por el acrónimo AOT. Éste, a diferencia de β , se mide verticalmente, desde la superficie al espacio. Para convertir el AOT a β , se debe dividir el AOT por el espesor de la capa de aerosol eficaz, que típicamente tiene un valor alrededor de 2 km, pero que varía con la visibilidad, elevación y otros factores.

AT-mos-pheric COR-rection (ATCOR)

El algoritmo ATCOR [66], fundamentado en la teoría de transferencia radiativa desarrollada en *MODTRAN4*, tiene un procedimiento de corrección que se divide principalmente en dos pasos. El primero se basa en la obtención del efecto atmosférico mediante la ley de reflectividad isotrópica

(Lambert) descuidando el efecto de los píxeles adyacentes. El siguiente paso, ejecuta un modelado de los píxeles vecinos teniendo en cuenta el efecto de adyacencia.

Por tanto, inicialmente, *ATCOR* tiene como cometido la obtención de un albedo planetario modelado. Esta cantidad se genera a partir del cálculo de la radiación retrodispersada, dato que se origina al suponer una superficie oscura de reflectividad 0, y de la transmitancia difusa de subida, el albedo esférico y la irradiancia en la superficie. Estos últimos parámetros son producto de emplear reflectividades de referencia superficiales iguales a 0 y 0,15 [75].

Así pues, finalmente se aplica la ecuación siguiente:

$$\rho_{MOD} = a_0(\text{Atm}, \theta_i, \theta_o, \varphi) + a_1(\text{Atm}, \theta_i, \theta_o) \times \rho_{\text{SUP}}$$
(59)

donde a_0 y a_1 son coeficientes dependientes de Atm, indica la relación con parámetros atmosféricos, θ_0 , ángulo de visión del sensor, y φ , acimut relativo. Con lo que, sustituyendo la modelización de reflectividad usada por *ATCOR*, se genera la expresión siguiente:

$$\rho_{SUP} = \frac{1}{a_1} \left(\frac{d^2 \pi (c_o + c_i DN)}{E_{TOA} \cos \theta_i} - a_0 \right)$$
(60)

Para la caracterización de los coeficientes a_0 y a_1 se debe estimar el parámetro visibilidad, así como los modelos de atmósfera y aerosol. *ATCOR* proporciona la posibilidad de estimar la visibilidad de forma automatizada. Con este propósito se utilizan superficies que se caracterizan por ser oscuras. En el supuesto caso de que se presenten píxeles negativos en ellas, la visibilidad es incrementada iterativamente hasta alcanzar reflectividades de al menos un 1% en la banda roja y un 0% en la banda NIR. Los modelos atmosféricos se caracterizan por parámetros como presión, temperatura del aire y humedad, todos ellos relativos a una altitud predeterminada. Además, a los modelos *MODTRAN* preestablecidos se añaden dos tipologías de atmósfera, otoñal-primaveral (*fall-spring*) (según hemisferio) y seco (*dry*). Para el modelado de aerosol se utilizan cuatro tipologías definidas en *MODTRAN*: rural, urbano, marítimo *Navy* (a diferencia del tipo de aerosol marítimo, el modelo marítimo *Navy* incluye una dependencia explícita con la velocidad del viento) y desértico.

El segundo paso, que realiza una corrección aproximada del efecto de adyacencia, calcula el promedio de cantidad de reflectividad de la imagen cercana al punto de estudio, $\bar{\rho}_{SUP_i}$. La elección del rango de píxeles que contribuyen a la adyacencia no es crítica puesto que la influencia de este efecto es de segundo orden. Así pues, el procedimiento de obtención total de reflectividad superficial libre de adyacencia se reduce a la siguiente expresión:

$$\rho_{SUP}' = \rho_{SUP} + \left(\int_{\lambda_1}^{\lambda_2} \frac{\tau_{odif}}{\tau_{odir}} R \, d\lambda\right) \left(\rho_{SUP} - \sum_{i=1}^{n_R} \bar{\rho}_{SUP_i} \, w_i\right) \tag{61}$$

donde $\tau_{o_{dif}}$ y $\tau_{o_{dir}}$ son transmitancias de subida difusa y directa, respectivamente, *R* es la función de respuesta espectral normalizada del sensor y w_i representa coeficientes de peso en función de la distancia hasta el punto de interés.

Second Simulation of a Satellite Signal in the Solar Spectrum (6S)

El Second Simulation of a Satellite Signal in the Solar Spectrum (6S) [67] es un modelo avanzado de transferencia radiativa diseñado para simular la reflexión de la radiación solar en condiciones de

una atmósfera libre de nubes, según condiciones específicas geométricas y espectrales. Este modelo tiene en cuenta los principales parámetros atmosféricos para modelar la dispersión y la absorción que produce la atmósfera en la longitud de onda del canal del satélite. El algoritmo 6S es utilizado para generar las *LUTs* (*Look-Up Tables*) en los algoritmos de corrección atmosférica del sensor *MODIS* de la *NASA* [76] [77].

El código de transferencia radiativa 6S estima la reflectividad aparente *ToA* teniendo en cuenta los efectos de absorción de los gases, la difusión de las moléculas y aerosoles presentes en la atmósfera, y la falta de homogeneidad de la reflectividad de la superficie terrestre.

6S define ρ_c como la reflectividad superficial del objetivo, rodeado de un entorno homogéneo de reflectividad ρ_e , mientras que la reflectividad *ToA* se define como ρ , la cual es definida de la siguiente manera.

$$\rho(\theta_s, \theta_v, \Delta \phi) = tg(\theta_s, \theta_v) \left\{ \rho_a(\theta_s, \theta_v, \Delta \phi) + \left[e^{-\tau/\mu_s} + td(\theta_s) \right] \frac{\rho_c e^{-\tau/\mu_v} + \rho_e td(\theta_v)}{1 - \rho_e S} \right\}$$
(62)

La referencia a la longitud de onda ha sido omitida para una mayor claridad de la ecuación. El significado de los términos de la ecuación se explica a continuación:

- $\mu_s = \cos(\theta_s)$, $\mu_v = \cos(\theta_v)$.
- $\Delta \phi$ representa la diferencia entre el acimut solar y del satélite.
- *tg* representa la transmisibilidad total de los gases (en la trayectoria de bajada y subida), teniendo en cuenta la absorción de los diferentes gases de la atmósfera.
- *ρ_a* representa la reflectividad atmosférica, la cual depende de las propiedades moleculares
 y de los aerosoles presentes en la atmósfera.
- τ representa al espesor atmosférico (Atmospheric Optical Depth, AOD)
- $td(\theta_s), td(\theta_v)$ representa a la transmitancia difusa de la atmósfera.
- *S* representa el albedo esférico de la atmósfera.

El término $(1 - \rho_e S)$ tiene en cuenta las difusiones múltiples entre la superficie y la atmósfera. Como se puede observar, en la ecuación 6S se abordan separadamente los procesos de absorción y difusión. Las difusiones producidas por las moléculas y por los aerosoles son, análogamente, diferenciados. La reflectividad total de la atmósfera se obtiene mediante la introducción de coeficientes procedentes del scattering de Rayleigh y de los aerosoles. Estos coeficientes son obtenidos mediante aproximaciones de primer orden.

6S es un modelo de una única capa, en donde no se tiene en cuenta las variaciones de los parámetros en la columna vertical de la atmósfera. La ecuación (62) es una expresión monocromática. Para obtener el resultado de una banda multiespectral, 6S calcula la ecuación para todo el rango de longitudes de onda con un paso de 5 nm, integrando todos estos resultados en el resultado final de la banda, según la respuesta espectral del sensor para dicha longitud de onda.

Una vez configurados los archivos necesarios, para la corrección de cada uno de los canales del satélite, se ejecuta el modelo, obteniéndose los valores de los principales parámetros atmosféricos que intervienen en los fenómenos de absorción y *scattering* producidos por la atmósfera. Resaltar que la expresión genérica para la corrección atmosférica de las imágenes de radiancia del modelo 6S viene dada por:

$$\rho_{c,\lambda} = \frac{y}{1 + (x_c * y)}, \quad y = (x_a * L_{\lambda}^{sen}) - x_b$$
(63)

donde,

- $\rho_{c,\lambda}$ es la reflectancia superficial corregida atmosféricamente (*ToC*)
- L_{λ}^{sen} es la radiancia medida por el satélite en [W/m²/sr]
- *x_a* es la inversa de la transmitancia atmosférica
- x_b es el scattering de la atmósfera
- *x_c* es el albedo atmosférico para la luz isotrópica

De esta forma se realiza una conversión de la radiancia medida por el satélite a reflectividad de la superficie terrestre, ya corregida atmosféricamente, mediante el uso de tres variables generadas por el modelo *6S*, para las condiciones geométricas, espectrales y atmosféricas indicadas en los archivos de configuración [78].

3.3.3 Metodología de evaluación de la corrección atmosférica

Para llevar a cabo el análisis comparativo de diferentes algoritmos de corrección atmosférica, con el objetivo de identificar el más adecuado, se dispone de una imagen *WorldView-2* adquirida el 4 de junio de 2015 junto con medidas de campo realizados el mismo día sobre la Reserva Natural Especial de las Dunas de Maspalomas. Un total de 12 puntos fueron monitorizados cubriendo diferentes tipos de suelo desnudo y vegetación. Para este análisis se seleccionaron 6 puntos en cada tipo de suelo y vegetación. En la Figura 50 se muestra la localización de los puntos sobre una imagen [79] obtenida a partir de vuelos fotogramétricos con GSD de 22 cm/píxel, ortorectificada a partir de orientaciones obtenidas por procesos de aerotriangulación y corregidas cromáticamente mediante procesos semiautomáticos. Finalmente, la resolución de la ortofoto es de 25 cm/píxel.



Figura 50. Mapa de puntos analizados sobre sustratos de suelo desnudo y de vegetación.

La Tabla 10 muestra información más detallada de la localización y características del tipo de suelo o vegetación en los diferentes puntos indicados. La información obtenida para cada punto fue la reflectividad a diferentes longitudes de onda, cubriendo las bandas del óptico al infrarrojo cercano. El instrumento utilizado fue un espectro-radiómetro *ADS Fieldspec 3* (Figura 51). Para la precisión

en la localización geométrica se utilizó un receptor *GPS* y finalmente el ángulo solar azimutal y cenital, la columna de ozono, el vapor de agua y el espesor óptico fueron medidos utilizando un fotómetro solar *MICROTOPS II*.

X (m)	Y (m)	Especie
441988,2375	3068437,957	Tamarix canariensis
442085	3068440	Juncus acutus
442107,8575	3068406,307	Tetraena fontanesii
442334,3175	3068490,936	Suaeda mollis
442632,012	3068543,051	Launaea arborescens
442889,4083	3068696,179	Traganum moquini
442100	3068336	Arena húmeda
442108	3068284	Arena seca
442435	3068219	Paleobarra
442311	3068601	Costra salina
442639	3068540	Aluvial
442697	3068844	Calcarenita

Tabla 10. Características de los puntos seleccionados.



Figura 51. Radiómetro empleado en la campaña de campo.

La característica multiespectral de las bandas WV-2 proporcionan reflectividades promediadas para todo su ancho de banda, mientras que la reflectividad del radiómetro sólo corresponde a anchos de banda cercanos a 1 nanómetro (sensor hiperespectral). Por este motivo, los resultados de reflectividad corregida de las bandas WV-2 y los resultados obtenidos por el radiómetro no resultan ser cuantitativamente comparables.

Para obtener un resultado cuantitativo de los valores de reflectividad corregida del WV-2 y los datos del radiómetro se hace uso de la simulación de bandas multiespectrales a partir de datos hiperespectrales (*SMS*, *Simulated Multi-Spectral*). Dicha simulación consiste en obtener la banda de reflectividad superficial simulada, pseudo WV2, ($\rho_{c,pwv2}^{band}$) a partir de multiplicar la función normalizada de respuesta del filtro paso banda (*NMRF*, *Normalized Multispectral Response*)

Function) de la banda por el valor de reflectividad monocromáticas del radiómetro. De esta manera se obtiene una integración de la reflectividad del radiómetro para la banda Multiespectral, desde λ_{min} hasta λ_{max} [80].

$$\rho_{c,pwv2}^{band} = \sum_{\lambda=\lambda_{min}}^{\lambda_{max}} \rho_{\lambda}^{radiometer} * NMRF_{\lambda}^{band}$$
(64)

Una vez los datos se hayan adecuado correctamente, en segundo lugar, se realiza la configuración de los parámetros para cada algoritmo de corrección atmosférica basado en el modelado físico de la atmósfera. La justificación de la parametrización se basa en las condiciones de la zona de estudio. Así, el modelo atmosférico *Mid-Latitude Summer* es el que más se adecúa al clima en Canarias, teniendo en cuenta que las islas tienden a ser zonas con mayor aridez. Para la elección de un modelo atmosférico se tienen en cuenta diversos factores como temperatura, vapor de agua y presión [66].

El modelo de aerosol responde a las tipologías de las escenas, que se deduce por la inspección de las mismas. Diferentes tipos de aerosol van a generar distintas componentes de dispersión y absorción dependiendo de la composición de éstos. El espesor óptico de aerosol se obtiene de [81] [82] para las fechas específicas de cada imagen y para la zona de estudio. La altura supone una media determinada mediante [83]. La Tabla 11 muestra un resumen de la configuración de los parámetros.

Modelo atmosférico	Mid-latitude summer	
Modelo aerosol	Marítimo	
Modelo de reflectancia terrestre	Vegetación	
Espesor óptico de aerosol	0.45	
Altitud media de la escena	10 m	

Tabla 11. Parametrización de los modelos atmosféricos.

A la hora de evaluar los resultados, tras la corrección atmosférica, se ha realizado un análisis diferenciando entre puntos situados en vegetación y puntos situados en suelo desnudo. Se ha realizado una comparativa gráfica de los valores de reflectividad obtenida para cada punto antes y después de realizar la corrección atmosférica.

En la metodología llevada a cabo para comparar los distintos métodos de corrección atmosférica se diferencia entre los resultados obtenidos para los algoritmos basados en la imagen y los algoritmos basados en parámetros físicos. Por lo tanto, en los resultados se mostrará una gráfica comparando los algoritmos basados en *DOS* y *QUAC* y otra gráfica con los algoritmos basados en parámetros físicos.

Para cuantificar la diferencia entre los valores de reflectividad reales observados y los corregidos por los distintos algoritmos o modelos de corrección atmosférica se utiliza el parámetro *RMSE* (*Root Mean Square Error*). Donde *n* es el número de muestras y el *RMSE* se define como:

$$RMSE_i = \frac{1}{n} \sqrt{\sum_{k=1}^{n} (\hat{\theta}_i(k) - \theta_i(k))^2}$$
(65)

donde $\hat{\theta}_i$, es el valor estimado y θ_i es el valor real observado. El parámetro de error varía entre 0 y 1, siendo más similares la medida *in-situ* y la corregida cuanto más cerca del cero sea el resultado.

Otro valor estadístico que resulta de interés es el sesgo o *BIAS*, que estima la desviación de los valores obtenidos respecto a las medidas de campo. La expresión es la siguiente:

$$BIAS_i = \sum_{k=1}^n \frac{(\hat{\theta}_i(k) - \theta_i(k))}{n}$$
(66)

En este caso, si el *BIAS* es negativo el algoritmo tiende a subestimar la medida mientras que en el caso contrario la predisposición es a sobreestimar los datos *in-situ*.

3.3.4 Resultados de la evaluación de las técnicas de corrección atmosférica

La Figura 52 muestra la representación gráfica de las reflectividades del radiómetro para los puntos de vegetación y sustrato y los resultados tras la simulación de las reflectividades a las bandas del WV-2.



Figura 52. Reflectividades de las coberturas medidas: (a) espectro-radiómetro (b) simuladas a las bandas del WV-2.

Una vez se han adaptado las medidas de campo a la respuesta de los filtros del sensor WV-2, se lleva a cabo la metodología para comparar los distintos métodos de corrección atmosférica. Se diferencia entre los resultados obtenidos para los algoritmos basados en la imagen y los algoritmos basados en parámetros físicos. Se realiza el análisis sobre los puntos medidos en vegetación y en suelo desnudo.

Análisis sobre los puntos de vegetación y suelo desnudo

En la Figura 53 se muestra cada una de las firmas espectrales de los 6 puntos para los diferentes tipos de vegetación, para los algoritmos *DOS* y *QUAC* en la gráfica de la izquierda y para los algoritmos basados en modelado físico en la gráfica de la derecha, en concreto los modelos *FLAASH*, *ATCOR* y *6S*. Al mismo tiempo se incluye la firma espectral de los datos *in-situ* en color rojo y la reflectividad TOA en color negro. En el eje de abscisas se representa la longitud de onda dada en nanómetros y en el de ordenadas la reflectividad superficial escalada en un rango de 0 a 1.



Continúa en Figura 53



Figura 53. Firmas espectrales comparando los datos in-situ y aplicando distintos algoritmos de corrección atmosférica sobre los puntos de vegetación.

Al igual que se ha hecho para los puntos de vegetación, en la Figura 54 se muestra cada una de las firmas espectrales para los 6 puntos de diferentes tipos de suelo, para los algoritmos *DOS* y *QUAC* en la gráfica de la izquierda y para los algoritmos basados en modelado físico en la gráfica de la derecha, en concreto los modelos *FLAASH*, *ATCOR* y *6S*. Al mismo tiempo se incluye la firma espectral de los datos *in-situ* en color rojo y la reflectividad TOA en color negro. En el eje de abscisas nuevamente se representa la longitud de onda dada en nanómetros y en el de ordenadas la reflectividad superficial escalada en un rango de 0 a 1.



Continúa en Figura 54



Figura 54. Firmas espectrales comparando los datos in-situ y aplicando distintos algoritmos de corrección atmosférica sobre los puntos de suelo desnudo.

A continuación, se muestran los valores de error cuadrático medio (*RMSE*) calculados para los doce puntos considerados en el análisis (Tabla 12). Igualmente, se muestran en la Tabla 12 los valores de las desviaciones *BIAS*.

	DOS	QUAC	FLAASH	6S	ATCOR
Tamarix canariensis	0,0154	0,0142	0,0049	0,0047	0,0071
Juncus acutus	0,0106	0,0077	0,0105	0,0055	0,0112
Tetraena fontanesii	0,0128	0,0137	0,0089	0,0043	0,0088
Suaeda mollis	0,0090	0,0082	0,0108	0,0066	0,0088
Launaea arborescens	0,0108	0,0039	0,0176	0,0124	0,0135
Traganum moquini	0,0078	0,0043	0,0202	0,0143	0,0180
Arena Húmeda	0,0143	0,0198	0,0093	0,0053	0,0059
Arena Seca	0,0268	0,0342	0,0175	0,0089	0,0061
Paleobarra	0,0154	0,0242	0,0142	0,0074	0,0139
Costra Salina	0,0223	0,0298	0,0070	0,0074	0,0074
Calcarenita	0,0249	0,0329	0,0130	0,0271	0,0243
Sustrato Aluvial	0,0300	0,0361	0,0068	0,0204	0,0182
Promedio	0,0167	0,0191	0,0117	0,0104	0,0119

Tabla 12.	RMSE entre	los valores	de reflectividad	observados	y los corregidos	atmosféricamente
	μ	oara todos lo	s puntos de veg	getación y su	elo desnudo.	

83

	DOS	QUAC	FLAASH	6S	ATCOR
Tamarix canariensis	-0,0317	-0,0386	0,0063	-0,0081	-0,0034
Juncus acutus	-0,0145	-0,0192	0,0212	0,0089	0,0143
Tetraena fontanesii	-0,0145	-0,0192	0,0212	0,0089	0,0143
Suaeda mollis	-0,0121	-0,0230	0,0292	0,0118	0,0167
Launaea arborescens	0,0049	-0,0075	0,0468	0,0266	0,0303
Traganum moquini	0,0101	-0,0015	0,0548	0,0371	0,0434
Arena Húmeda	-0,0392	-0,0534	0,0246	-0,0101	-0,0023
Arena Seca	-0,0739	-0,0937	-0,0458	-0,0217	-0,0014
Paleobarra	-0,0414	-0,0626	0,0359	0,0096	0,0299
Costra Salina	-0,0613	-0,0807	0,0128	-0,0132	0,0061
Calcarenita	-0,0690	-0,0897	-0,0353	-0,0751	-0,0678
Sustrato Aluvial	-0,0845	-0,1002	-0,0171	-0,0569	-0,0496
Promedio	-0,0356	-0,0491	0,0129	-0,0068	0,0025

 Tabla 13. BIAS entre los valores de reflectividad observados y los corregidos atmosféricamente

 para todos los puntos de vegetación y suelo desnudo.

Analizando los resultados sobre los puntos de vegetación y suelo desnudo podemos apreciar que en general los algoritmos basados en modelado radiativo presentan mejores resultados, asemejándose más la firma espectral estimada a partir de las imágenes WV-2 a la obtenida con las medidas *in-situ*. En concreto, *6S* parece ser más preciso que *FLAASH* y *ATCOR*. Estos dos últimos parecen tener comportamientos más similares, presentando derivas mayores en las bandas de los bordes. En algunos casos puntuales, los algoritmos basados en información de la imagen, como el *QUAC* superan al resto, que tienden a sobreestimar en exceso los valores de la reflectividad para algunas especies vegetales. En este sentido, *FLAASH* tiene mayor tendencia a sobreestimar de manera general las medidas, lo cual queda patente con una desviación *BIAS* más alta que para el resto de métodos. Por otro lado, analizando las gráficas se puede apreciar que el algoritmo *DOS* tiene a degradar la firma espectral típica de la vegetación al tener un valor alto de reflectividad en el rojo y un descenso considerable en el canal IR cercano. Sobre los puntos de suelo desnudo, el comportamiento de los algoritmos *DOS* y *QUAC* tiende a subestimar bastante las reflectividades, respecto a las medidas *in-situ*.

3.4 Corrección geométrica de las imágenes

Con el nombre de Corrección Geométrica se engloban 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. Así mismo, se incluyen en estas técnicas las de georreferenciación, es decir, las de asignar una posición geográfica a los píxeles de nuestra imagen.

Además, en el caso de tratar con imágenes adquiridas por distintos sensores, pueden ser obtenidas en instantes de tiempo diferentes, por lo tanto éstas deben ser registradas u ortorectificadas a un marco común de referencia. Además de georreferenciadas, la ortorectificación hace referencia al mismo concepto que georeferenciación, sólo que se tiene en cuenta el relieve del entorno. Los principales factores o fuentes de error geométrico en la imagen son:

- 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

Estas fuentes de error van a producir unas distorsiones desde el punto de vista geométrico que pueden ser tratadas en la mayoría de los casos conjuntamente, 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.

Los métodos de corrección geométrica tradicionales se basan en la colocación visual de puntos homólogos para: (1) co-registrar o ajustar geométricamente una imagen respecto a otra del mismo u otro sensor que se toma como referencia y que puede estar proyectada o no y, (2) georreferenciar o proyectar la imagen a un sistema de referencia cartográfico de manera que las posiciones de la imagen coincidan con posiciones sobre el terreno. La "registración" se refiere a encontrar el correcto mapeado de una imagen a otra.

Respecto a la corrección geométrica, dado que las imágenes proporcionadas por *DigitalGlobe* ya tienen aplicadas las correcciones geométricas, en el marco de esta *Tesis Doctoral* sólo se llevará a cabo el proceso de co-registro de imágenes de alta resolución obtenidas en diferentes fechas, a partir de la selección de puntos de control. A continuación, se describe el procedimiento de co-registro más en detalle.

3.4.1 **Co-registro de imágenes**

El proceso de registración de imágenes suele constar de tres pasos. El primer paso consiste en la selección de características. Seguidamente, cada una de estas características se compara con las características potenciales correspondientes de la otra imagen. Un par de características que concuerden se aceptan como un punto de control de Tierra (GCP, *Ground Control Point*). Finalmente, utilizando estos *GCPs*, se realiza una transformación para modelar la deformación entre ambas imágenes. Para llevar a cabo este proceso de forma automática, se han propuesto varios algoritmos, clasificados como:

- Algoritmos que directamente utilizan valores de píxel.
- Algoritmos que operan en el dominio de la frecuencia.
- Algoritmos basados en características de bajo nivel, tales como contornos y esquinas.
- Algoritmos basados en características de alto nivel como, por ejemplo, objetos identificables.

Debido a que en la etapa de clasificación dispondremos de imágenes adquiridas en dos fechas, es necesario incluir en la cadena de procesado el co-registro de imágenes para garantizar una superposición precisa de las mismas.

Como se adelantó en el apartado anterior, el co-registro es el proceso que permite alinear geométricamente dos imágenes para que los píxeles integrantes correspondan a los mismos objetos en ambas imágenes. Típicamente se obtiene una relación geométrica entre una imagen que se

utiliza como base y una imagen esclava a transformar, a partir de una serie de puntos de control que permiten modelar la transformación. Estos puntos de control se pueden obtener de forma automática a través de algún operador (p.e. *Moravec o Förnster*) o de forma manual.

La búsqueda de puntos correspondientes u homólogos entre ambas imágenes se suele basar en la información radiométrica de las imágenes, a partir de alguna métrica de similitud (p.e. Correlación Cruzada o Información Mutua) medida en el rango de una ventana deslizante que se desplaza sobre una ventana de área mayor denominada ventana de búsqueda. Se trata de encontrar la localización conjugada basada en el patrón de mayor similitud.

3.4.2 Metodología de Evaluación de los resultados del co-regitro

El procedimiento para obtener una medida de calidad en el proceso de co-registro ha consistido en seleccionar de forma manual parejas de puntos homólogos sobre la imagen base y la imagen esclava y obtener la distancia en píxeles entre dichos puntos antes y después de la transformación. Se han seleccionado puntos diferentes a los utilizados como puntos de control para llevar a cabo la transformación. Se dispone de dos imágenes WV-2 con un gran desplazamiento, una perteneciente a 17 de enero de 2013 y la otra perteneciente a 4 de junio de 2015.

Para realizar un análisis cuantitativo del error se utiliza la expresión de error que se define de la siguiente forma, donde *n* es el número de puntos:

$$ERROR = \sqrt{\frac{\sum_{k=1}^{n} (x_{base}(k) - x_{esclava}(k))^{2} + (y_{base}(k) - y_{esclava}(k))^{2}}{n}}$$
(67)

donde ($x_{base} y_{base}$), representan las coordenadas sobre la imagen de referencia y ($x_{esclava} y_{esclava}$) representan las coordenadas sobre la imagen esclava, y se computarán antes y después de la transformación llevada a cabo tras el proceso de co-registro.

3.4.3 Resultados del procedimiento de co-registro de imágenes

En la Figura 55 se muestran los puntos de control seleccionados para las imágenes *WorldView-2* de la zona de Maspalomas. Para obtener buenos resultados en el proceso de co-registro se han seleccionado más de 100 puntos de control distribuidos por toda la imagen. Estos puntos han sido seleccionados combinando puntos obtenidos de forma automática, con el operador *Förnster* dado que ambas imágenes provienen del mismo sensor, y como métrica de similitud se ha utilizado la Correlación Cruzada, junto a puntos obtenidos de forma manual. Para apreciar mejor los puntos se muestra sólo un trozo de la imagen original. Dado que la Reserva Natural de Maspalomas está cubierta por Dunas móviles no es posible identificar puntos de control de ciertas zonas. En cualquier caso, dado que el estudio se centra en las comunidades vegetales la precisión del co-registro se considera aceptable.



Figura 55. Puntos de control utilizados para el co-registro: (a) Imagen del 4 de junio 2015 (b) Imagen del 17 de enero 2013.

Para apreciar con mayor detalle el desplazamiento entre ambas imágenes, podemos ver en la siguiente Figura 56 el ejemplo para un punto concreto. La esquina marcada en color rojo sobre la imagen base se toma como referencia. A la derecha podemos ver donde se sitúa esa esquina sobre la imagen esclava si superponemos ambas imágenes. En color verde se puede ver la posición de esa misma esquina sobre la imagen esclava.



Imagen base: Punto de referencia



Imagen esclava: Punto homólogo (verde) Posición superpuesta (rojo)

Figura 56. Desplazamiento en un punto de referencia entre imagen base e imagen esclava.

Para estimar las posiciones de los píxeles de la imagen esclava a partir de los puntos de control definidos sobre ambas imágenes se hace uso de una transformación polinómica de tercer orden, ya que está última demostró ser la transformación que mejor se adaptaba.

De forma visual, y a modo de ejemplo, se observan en las siguientes figuras parejas de puntos homólogos sobre la imagen base (a la izquierda) y sobre la imagen esclava (a la derecha) antes del co-registro (arriba) y después del co-registro (abajo). Se muestran ejemplos para diferentes puntos de control.



Figura 57. Punto de control 1 sobre la imagen base (izquierda) y sobre imagen esclava antes del co-registro (arriba e izquierda) y después del co-registro (abajo derecha).



Figura 58. Punto de control 2 sobre la imagen base (izquierda) y sobre imagen esclava antes del co-registro (arriba y derecha) y después del co-registro (abajo derecha).

La Tabla 14 muestra las coordenadas (x, y) de los puntos utilizados para validar los resultados del co-registro sobre la imagen base, la imagen esclava y la imagen co-registrada. Además, se muestran los resultados en el cómputo del error para cada punto y de forma global.
Base	Base (x,y) Esclava (x,y)		va (x,y)	Co-reç	jistrada (x,y)	ERROR antes (píxeles)	ERROR después (píxeles)
888,673	829,653	880,676	830,668	889,434	829,653	8,061	0,762
1009,755	977,381	997,469	977,462	1005,875	975,523	12,285	4,302
1204,383	1367,734	1198,921	1369,141	1204,052	1367,238	5,641	0,597
712,579	673,558	701,468	673,673	713,510	673,765	11,111	0,954
2629,488	1361,503	2621,506	1363,526	2628,319	1361,503	8,235	1,170
3375,388	1652,560	3366,419	1653,665	3375,518	1652,560	9,037	0,130
3611,474	1704,667	3606,421	1706,604	3615,520	1705,512	5,412	4,133
4100,589	1465,541	4090,426	1466,470	4101,500	1465,506	10,205	0,911
4498,383	1894,542	4489,512	1896,635	4497,486	1894,741	9,115	0,919
4440,583	1464,528	4427,613	1464,528	4439,576	1464,654	12,971	1,015
5146,435	2120,426	5140,367	2121,665	5145,468	2120,491	6,194	0,969
5708,494	2082,441	5703,368	2083,558	5708,428	2082,441	5,247	0,066
5308,404	1647,481	5301,359	1648,375	5309,403	1647,481	7,102	0,999
5942,614	1658,779	5934,728	1660,258	5941,464	1658,615	8,024	1,162
6245,531	1434,428	6239,534	1436,564	6246,435	1434,592	6,366	0,919
6130,537	1336,613	6121,603	1336,613	6129,510	1335,689	8,934	1,382
6493,492	1019,408	6483,428	1019,716	6491,438	1019,408	10,068	2,054
6804,399	814,618	6799,470	815,538	6805,385	814,618	5,014	0,986
7214,491	483,624	7198,389	482,703	7207,393	482,572	16,128	7,175
7731,347	368,537	7725,350	370,509	7733,318	369,523	6,313	2,204
8110,531	326,725	8102,522	327,443	8109,710	326,622	8,042	0,828
					FRROR TOTAL	8 99	2 29

Tabla 14. Error del proceso de co-registro.

Analizando los resultados obtenidos, podemos apreciar que tras el co-registro se ha reducido el desplazamiento en todos los puntos utilizados para el análisis. En la mayoría de los casos, la diferencia es considerable, pasando en algunos casos de una diferencia de 12 píxeles a uno. La última fila muestra el error total de forma global, donde se puede apreciar una variación de, aproximadamente, 9 píxeles a un error en la localización cercana a 2 píxeles. Esto demuestra la importancia de llevar a cabo un procesado de este tipo de procesado a la hora de comparar imágenes adquiridas en distintos instantes de tiempo.

3.5 Resumen

A lo largo de este capítulo se han detallado las diferentes técnicas de corrección realizadas sobre las imágenes WorldView-2. Se ha incluido una descripción de los procedimientos llevados a cabo para eliminar los efectos de distorsión radiométrica, atmosférica y geométrica de las imágenes. Estas correcciones son necesarias para poder interpretar de manera fiable la información de la imagen en los procesos de clasificación posteriores. Dentro de estos preprocesados, las correcciones atmosféricas son las que presentan la mayor dificultad, principalmente los métodos basados en el modelado de transferencia radiativa como son el FLAASH, ATCOR y 6S, que requieren de una configuración adecuada de diferentes parámetros relacionados con el momento de captación de la imagen y las condiciones ambientales. Tras una revisión del estado del arte y tras llevar a cabo un análisis exhaustivo de diferentes puntos sobre vegetación y suelo desnudo localizados en la Reserva Natural de las Dunas de Maspalomas, se han validado dichas correcciones comparando las medidas simultáneas de un espectro radiómetro de campo con las reflectividades de las imágenes corregidas. Ha quedado patente la mayor precisión de los algoritmos basados en el modelado radiativo de la atmosfera (FLAASH, 6S y ATCOR) y, en especial, del algoritmo 6S que es el que ofrece un menor error cuadrático medio para los puntos de vegetación y suelo analizados. Los algoritmos basados en la imagen (DOS y QUAC) tienden a degradar la firma espectral y a subestimar, en general, la reflectividad real. Tras este análisis, se ha considerado adecuado incorporar en la cadena de procesado el algoritmo de corrección atmosférica 6S.

Finalmente, a la hora de utilizar las imágenes multiespectrales es necesario garantizar la perfecta correspondencia geométrica entre ellas. En este sentido, tras las correcciones geométricas ya aplicadas a las imágenes WV-2, se ha realizado el co-registro de las dos escenas, que se utilizarán en la generación de cartografía de especies vegetales. Tras revisar las técnicas de co-registro, se aplicó la más adecuada usando puntos de control obtenidos tanto de forma automática como manual. La evaluación de la precisión demostró una mejora significativa en la localización final de los puntos

Capítulo 4

Clasificación de imágenes de satélites de alta resolución

La generación de mapas temáticos a partir de datos de teledetección sigue siendo el propósito fundamental dentro de las aplicaciones de procesado digital de la imagen. El principal objetivo de la clasificación es extraer información de la superficie terrestre, asignando a cada píxel de la imagen una categoría que identifica una cubierta de interés. Esta información ayuda en la toma de decisiones, ya sea para optimizar la gestión del territorio, elaborar estudios medioambientales, predecir riesgos, etc. Esto resulta de especial interés en zonas naturales vulnerables como la Reserva Natural de las Dunas de Maspalomas que, debido a la presión del entorno circundante, está sufriendo cambios que afectan al ecosistema. En este sentido, disponer de un inventario preciso de la vegetación puede resultar interesante, ya que afecta directamente a la distribución de los sedimentos arenosos. En este capítulo se plantea una metodología de clasificación de las diferentes especies vegetales de interés sobre la zona de estudio. Para ello se han implementado y evaluado diferentes metodologías con el fin de establecer el mejor procedimiento capaz de discriminar con exactitud las poblaciones vegetales más significativas.

4.1 Área de estudio: Reserva Natural Especial de las Dunas de Maspalomas

El campo de Dunas de Maspalomas, con una extensión de 360,9 ha, está situado en el extremo sur de la isla de Gran Canaria, en el municipio de San Bartolomé de Tirajana. Limita al norte con el campo de golf de Maspalomas y la urbanización Playa del Inglés, al oeste con el barranco de Maspalomas, que forma en su desembocadura una laguna litoral (la Charca de Maspalomas), y al este y al sur con el mar, a través de una playa continua que recibe distintas denominaciones: playa del Inglés (al este), playa de Maspalomas (al sur) y punta de la Bajeta (en su vértice suroriental) (Figura 59) [1].



Figura 59. Localización y vista general del área de estudio. Fuente [1].

4.1.1 Especies vegetales

El campo de Dunas de Maspalomas posee una significativa diversidad de comunidades vegetales, sobre todo si consideramos la escasa superficie del mismo (menos de 4 km²). Esto se debe a la variedad de situaciones ecológicas existentes: Dunas móviles, Dunas estabilizadas, afloramiento de materiales del basamento, depresiones interdunares con un nivel freático a escasa profundidad, zonas antropizadas, etc.

La disposición de la vegetación está relacionada con: (I) el gradiente en la movilidad y el volumen de la arena existente entre la playa del Inglés y el interior del sistema de Dunas y (II) la existencia de depresiones interdunares y superficies de deflación que diversifican las condiciones ambientales existentes debido al afloramiento del basamento o a la disminución de la profundidad del nivel freático, de tal forma que se generan nuevos hábitats [6].

Esto permite la existencia de diferentes comunidades en función de las características del sustrato que aflora: freatófilas y edafohigrófilas (juncales de *Juncus acutus*, césped de *Cyperus laevigatus*, poblaciones y bosquetes de *Tamarix canariensis* y matorral de *Zygophyllum fontanesii*), halófilas (matorral de *Suaeda mollis*) y xerófilas (aulagar de *Launaea arborescens*, matorral de *Schizogyne glaberrima* y matorral de *Plocama pendula*).

En la Figura 61 se presenta un mapa de vegetación de Maspalomas del año 2003, a escala 1:5.000, desarrollado por investigadores del Departamento de Geografía de la ULPGC [1]. Además, este mapa se utilizará como imagen de apoyo para la interpretación y la validación de la clasificación de las especies vegetales a partir de imágenes de satélite, al ser el más preciso existente hasta la fecha.



Figura 60. Mapa de vegetación de Maspalomas. Fuente [6]

A continuación, se hace referencia a las comunidades vegetales que han sido identificadas y clasificadas en el desarrollo de esta Tesis Doctoral:

- Poblaciones y bosquetes de Tamarix canariensis: comunidad de porte arbóreo presente en la mayor parte del campo de Dunas de Maspalomas, excepto en la zona de entrada de sedimentos (zona este de la Reserva).
- **Matorral de Traganum moquini:** constituye una comunidad vegetal especializada en vivir en las Dunas embrionarias, contribuyendo a su formación.
- Matorral de Zygophyllum fontanesii: en Maspalomas esta comunidad vegetal se comporta como freatófila, ya que ocupa las superficies de deflación donde la capa freática se sitúa cerca de la superficie.

- Juncal de Juncus acutus: esta comunidad vegetal está vinculada a depresiones interdunares y a superficies de deflación de zonas totalmente estabilizadas, donde la capa freática se localiza a una escasa profundidad.
- Matorral de Suaeda mollis: matorral halófilo de porte bajo, ocupa normalmente superficies de deflación donde el sustrato está formado por depósitos aluviales, así como zonas que presentan un elevado grado de antropización.
- Aulagar de Launaea arborecens: matorral espinoso muy extendido por la mayor parte del campo de Dunas. Los aulagares pueden vivir en una gran variedad de biotopos (en zonas móviles y estabilizadas).

El resto de especies son herbáceas o estacionales y no es fiable su clasificación a partir de datos de satélite. La Figura 61 muestra el aspecto que presentan dichas especies.





Figura 61. Comunidades vegetales de Maspalomas analizados: (a) Traganum moquini, (b) Suaeda mollis, (c) Launaea arborescens (d) Zygophyllum fontanesii, (e) Tamarix canariensis (f) Juncus acutus.

Debido al desarrollo turístico, Maspalomas es un ecosistema vulnerable que experimenta en la actualidad un déficit sedimentario y el avance de la vegetación en el interior del sistema contribuye, aún más, a estabilizar los sedimentos. De ahí el interés que presenta conocer cómo se distribuye la vegetación en la zona.

4.1.2 Datos disponibles

Para la caracterización de la verdad terreno de las diferentes especies vegetales se realizó una campaña de campo en la reserva Natural de Maspalomas el 4 de junio de 2015. Para realizar las medidas se utilizó un espectro-radiómetro de campo. El instrumento de campo registra la radiancia espectral del objeto que está observando. Para la adquisición de la reflectancia espectral con espectro-radiómetros de campo modelo *ASD Field Spec 3*, se realiza una medida de la radiancia del objeto en estudio y se divide por la radiancia medida de una superficie o panel de referencia que hace las veces de irradiancia solar (Figura 62). La superficie de referencia se denomina "blanco de referencia" y está fabricado de un material altamente reflectante y lambertiano a lo largo de todo el espectro-radiómetro, que es medida continuamente por el propio instrumento. La adquisición se ha realizado en unas condiciones óptimas de iluminación y buena elevación solar. La distancia sobre

el panel de referencia será de unos 20 cm y de, aproximadamente, 1 m sobre el dosel de la planta, asegurando abarcar la mayor área de ambas superficies sin verse contaminadas por otras. En el caso del dosel de la planta, al ser heterogéneo en cantidad y orientación de las hojas se recomienda desplazar hacia los extremos del dosel, para integrar la mayor área posible [84].



Figura 62. Adquisición de firmas espectrales de plantas mediante espectro-radiometría de campo. Fuente [84] .

Estos datos de espectro-radiometría se han utilizado para: (I) calibración y validación de la corrección atmosférica en las imágenes de satélite del *WorldView-2* (detallado en el capítulo 3) y (II) estudiar la respuesta espectral de cada especie y generar una librería espectral. Al disponer de las firmas espectrales de cada especie podemos analizar las diferencias existentes entre las mismas. Si se realizaran medidas en diferentes estaciones, se podría estimar el momento fenológico de mayor discriminación entre las especies.

Esta información de espectro-radiometría supondrá un apoyo para el análisis y la interpretación de la imagen de satélite. En la selección de los individuos se ha tenido en cuenta el estado de crecimiento de la planta, eligiendo los más representativos y la selección de coberturas homogéneas. Además, para cada individuo se hicieron al menos 3 medidas a diferentes ángulos.

A continuación, se muestran las firmas espectrales medidas por el espectro-radiómetro de campo para cada especie [85]:



continúa en Figura 63



Figura 63. Firma espectral (media ± desviación estándar) con espectro-radiometría de campo para cada comunidad vegetal de Maspalomas: (a) Traganum moquini, (b) Suaeda mollis, (c) Launaea arborescens (d) Zygophyllum fontanesii, (e) Tamarix canariensis y (f) Juncus acutus.

De forma simultánea a la campaña de datos *in-situ*, se realizó la adquisición de una imagen *WorldView-2* de la misma zona. En concreto, los datos pertenecen al 4 de junio de 2015. La imagen se muestra en la Figura 64, donde se ha remarcado el área de estudio. Sobre esta imagen se va a realizar el análisis para desarrollar una metodología óptima de clasificación de especies vegetales sobre la Reserva de las Dunas de Maspalomas. Además, para validar esta metodología se va a utilizar otra imagen WV-2 del 17 de enero de 2013 que se muestra en la Figura 65.

La Figura 66 muestra la localización de los puntos de muestreo *in-situ* realizados para cada especie sobre una composición RGB de la imagen *WorldView-2* de ese mismo día.



Figura 64. Imagen WV-2 del 4 de junio de 2015 (composición RGB).



Figura 65. Imagen WV-2 del 17 de enero de 2013 (composición RGB).





(a)





(b)





(c)



(d) Continúa en Figura 66



(f)

Figura 66. Localización de los puntos de muestreo en la campaña de campo, sobre imagen WorldView-2, para cada comunidad vegetal de Maspalomas y foto en el momento de medida: (a) Traganum moquini, (b) Suaeda mollis, (c) Launaea arborecens (d) Zygophyllum fontanesii, (e) Tamarix canariensis y (f) Juncus acutus.

4.2 Clasificación de imágenes multiespectrales de alta resolución

Las técnicas de clasificación digital de imágenes proporcionan una herramienta robusta y consistente para generar mapas temáticos sobre la superficie terrestre. Esta clasificación puede ser aplicada sobre datos crudos, pero la mayoría de los autores recomienda llevar a cabo previamente las correcciones radiométricas y geométricas para evitar el efecto de factores externos de ruido. Además, para realizar un análisis riguroso y comparar imágenes de diferentes épocas hay que eliminar los efectos asociado al momento de adquisición de la imagen y las correcciones atmosféricas. Las principales etapas de la clasificación de imágenes incluyen el preprocesado de la imagen, la selección de muestras de entrenamiento, la selección de una adecuada técnica de clasificación, el postprocesado y la evaluación de la exactitud.

Atendiendo a la disponibilidad de datos de entrenamiento, las técnicas de clasificación se pueden dividir en supervisadas y no supervisadas. En las técnicas supervisadas, se clasifican los datos de entrada, utilizando para cada clase un conjunto de muestras representativas conocidas como muestras de entrenamiento. Generalmente, estas muestras son identificadas por el usuario de forma manual, etiquetando un conjunto de píxeles sobre la imagen o a partir de datos de campo. De otra parte, las técnicas no supervisadas no consideran muestras de entrenamiento. En este tipo de clasificadores los datos se agrupan entorno a unos centroides, basados en unos criterios de similitud. Estos centroides pueden ser indicados por el usuario o seleccionados de forma arbitraria. Existe una gran cantidad de literatura sobre técnicas no supervisadas, entre los más populares se encuentra el *Kmeans, ISODATA y Fuzzy Cmeans Rank* [86] [87] [88]. En cualquier caso, estos métodos son menos

precisos que las técnicas supervisadas y dado que no serán objeto de estudio en esta *Tesis Doctoral* tampoco se entrará en mayor detalle.

Desde otra perspectiva, los clasificadores pueden ser divididos en paramétricos y no paramétricos. Los paramétricos suponen conocida la distribución de los datos de entrada, mientras que los no paramétricos no siguen ninguna restricción. Por ejemplo, el clasificador de máxima probabilidad (*Maximum Likelihood Classifier, MLC*) que es unos de los métodos supervisados más ampliamente utilizado en un contexto paramétrico. De tal manera, que se basa en el supuesto de que la función de densidad de probabilidad para cada clase se rige por una distribución gaussiana. Sin embargo, otros métodos no paramétricos como son *SVM*s, redes neuronales o árboles de decisión pueden ser aplicados sin disponer de información acerca de las densidades de cada clase o en el caso de que éstas no se puedan estimar de forma fiable.

Por otro lado, en teledetección existen otras técnicas avanzadas basadas en análisis de mezcla espectral. Estas técnicas son aplicadas con éxito en la discriminación, detección y clasificación de materiales. Se basan en que un píxel sobre la imagen está generalmente formado por una combinación o mezcla de diferentes materiales presentes en la escena. A lo largo de los años se han propuestos dos tipos de modelados. Uno a nivel de mezcla macroscópica [89], que modela un píxel como una combinación lineal de materiales con concentraciones relativas. El segundo modelo se denomina de mezcla espectral íntima que, es una mezcla no lineal de materiales. Dado que estos últimos son muy complejos y requieren de mayor cantidad de información, generalmente no disponible, en esta *Tesis Doctoral* sólo se tratará el modelado lineal de mezcla. Cabe mencionar, que este tipo de técnicas generalmente se utilizan sobre datos hiperespectrales, al disponer de mayor cantidad de información distribuida en cientos de bandas. En cualquier caso, en este trabajo se analizará el potencial de estas técnicas aplicado a los datos multiespectrales del WV-2 de ocho bandas.

4.2.1 Estado del arte de técnicas de clasificación basadas en desmezclado espectral

Debido a las limitaciones en la resolución espacial de los sensores, el píxel de una imagen se asume que representa una mezcla de espectros de diferentes materiales en la escena. Estos espectros son denominados *endmembers*. Se denomina desmezclado al proceso que involucra la estimación de estos *endmembers* y su firma espectral, así como las abundancias a nivel de cada píxel.

Se asume que los *endmembers*, generalmente, representan el espectro de materiales puros presentes en la imagen y las abundancias indican el porcentaje de cada *endmember* presente en cada píxel de la imagen [90]. Dependiendo del modelo de mezcla esperado, el análisis puede ser lineal o no lineal. La mezcla lineal tiene lugar a nivel macroscópico, ocurre cuando el tamaño del píxel no es lo suficientemente grande para separar diferentes materiales, con lo que el espectro resultante obtenido por el sensor será en realidad un espectro correspondiente a una mezcla de componentes. La Figura 68 representa el modelo de mezcla lineal, donde se representa que la luz dispersada por los tres materiales en una escena incide sobre el sensor que mide la radiancia en diferentes bandas. El espectro medido es una media ponderada de los espectros de los materiales. La cantidad relativa de cada material viene determinado por los pesos α_i .

Por otro lado, los modelos de mezcla no lineal se deben a la interacción física entre la luz dispersada por los múltiples materiales de la escena. En este caso, los espectros mezcla recogidos por el instrumento se describen mejor bajo el supuesto de que parte de la radiación de origen se dispersa múltiplemente antes de ser capturadas en el sensor (Figura 68).



Figura 67. Modelo de mezcla lineal. Fuente [90].

En esta *Tesis Doctoral* se aborda el modelo de mezcla lineal dado que es el más ampliamente utilizado y proporciona resultados adecuados en gran cantidad de aplicaciones. Además, aunque el modelo no lineal puede resultar más preciso en determinadas circunstancias, su aplicación requiere de información previa acerca de la geometría y las propiedades físicas de los objetos observados, lo cual lo hace difícilmente abordable en situaciones en las que no existe dicha información.



Figura 68. Modelo de mezcla no lineal [90].

Modelo de mezcla lineal

En el modelo de mezcla lineal, el espectro de un píxel se aproxima con la mezcla lineal de los espectros de los *endmembers* ponderados por las correspondientes fracciones de sus abundancias. La medida espectral en el canal *i* \in {1,...,B}, siendo *B* el número de bandas, para un píxel concreto y denotado por *y_i* es dado por el modelo lineal de mezcla como:

$$y_i = \sum_{j=1}^p p_{ij} \alpha_j + w_i \tag{68}$$

donde $p_{ij} > 0$, denota la medida espectral del *endmember j* $\in \{1, ..., p\}$ en la banda espectral *i*, $\alpha_j \ge 0$ denota la fracción de abundancia del *endmember j*, w_i incluye una fuente de error aditiva y p indica el número de *endmembers*. Sobre un píxel, la fracción de abundancia α_j , representa la fracción de área ocupada por el *endmember j*.

Si representamos *y* como un vector columna bidimensional y m_j representa la firma espectral del endmember j $m_j \equiv [p_{1j}, p_{2j}, ..., p_{Bj}]^T$. La anterior ecuación se puede representar como:

$$y = M\alpha + w \tag{69}$$

siendo el vector de abundancia $\alpha \equiv [\alpha_1, \alpha_2, ..., \alpha_p]^T$ y $M \equiv [m_1, m_2, ..., m_p]^T$ representa la matriz de mezcla que contiene las firmas de los *endmembers* presentes en el área cubierta.

Además, para poder dar significado físico a los valores, estas fracciones de abundancia cumplen las siguientes restricciones, denominando así al proceso de desmezclado lineal como *FCLU* (*Fully Constrained Linear Unmixing*) [89]:

$$\alpha_j \ge 0, \qquad j = 1, \dots, p$$

$$\sum_{j=1}^p \alpha_j = 1$$
(70)

Es decir, las abundancias siempre han de tomar valores nulos positivos y la suma de todas ellas ha de ser igual a 1.

En la literatura se pueden encontrar diferentes aproximaciones para solucionar el problema de mezcla lineal [91]. Cuando no se tiene ningún conocimiento previo sobre los *endmembers* y las abundancias, el proceso de desmezclado espectral se denomina problema de desmezclado completo. En el caso que nos incumbe en esta *Tesis Doctoral* se hará uso de información a priori de los *endmembers*, asumiendo que vienen representados por las respuestas espectrales de las especies de vegetación que queremos discriminar y que se tratará en secciones posteriores. Por lo tanto, el problema queda resumido en la estimación de las abundancias.

El problema de la estimación de las abundancias puede ser visto como un problema de minimización de distancia, dado por:

$$\hat{\alpha} = \arg\min_{x} D(M\alpha, y) \tag{71}$$

donde $D(M\alpha, y)$ es la función distancia, *M* es la matriz de *endmembers*, *y* es el píxel en observación, α es el vector de abundancia, y *arg min_x f* devuelve la *x* que hace mínima la función *f*. La medida de distancia más común utilizada es la de mínimos cuadrados. Imponiendo, además, la restricción de valores no negativos resulta en el siguiente problema de optimización:

$$\min_{\alpha \in \Delta} \{ (y - M\alpha)^T (y - M\alpha) \}, \text{ sujeto } \alpha \Delta = \{ \alpha, \sum_{i=1}^p \alpha_i = 1 \} y \alpha \ge 0$$
(72)

Para encontrar la solución óptima se recurre a algoritmos de optimización. Uno de los métodos más utilizados es el del *Levenberg-Marquardt* (*LMA*) [92].

LMA es un método iterativo que calcula el mínimo local de la suma de los cuadrados de la función de coste. Simplificadamente, es una combinación entre el método de descenso por gradiente (*steepest descent*), que realiza una minimización a través de la dirección del gradiente, y el método de *Gauss-Newton*, mediante la utilización del modelo cuadrático para acelerar el proceso iterativo de búsqueda de la solución. El algoritmo se comporta como un método de máxima pendiente, lento pero que garantiza la correcta convergencia cuando la solución obtenida en el paso iterativo está

lejos de la óptima, y se convierte en método de *Gauss-Newton* cuando la solución actual está cerca de la óptima, obteniendo una mayor velocidad de convergencia.

El algoritmo *LMA* sólo asegura la obtención de un mínimo de la función, el cual puede ser local o global. Para restringir el ámbito de búsqueda, *LMA* proporciona herramientas que permiten restringir y orientar el resultado mediante cuatro tipos fundamentales de parámetros: valor inicial de las variables, condiciones de contorno, escala y salto máximo entre las variables.

Aunque estas técnicas son generalmente aplicadas a datos hiperespectrales, que presentan gran resolución espectral ofreciendo datos en el rango se cientos de bandas. En nuestro caso disponemos de datos en tan sólo ocho bandas espectrales. En línea con el objetivo de esta *Tesis Doctoral*, se trata de analizar si estas técnicas pueden aportar a la discriminación de las especies vegetales en la Reserva Natural de las Dunas de Maspalomas, considerando como *endmembers* las respuestas espectrales de las especies obtenidas a partir de medidas de campo.

4.2.2 Estado del arte de técnicas de clasificación supervisada

Dentro de los algoritmos más utilizados para la clasificación de la superficie terrestre se encuentran los basados en enfoques estadísticos, redes neuronales y árboles de decisión. Dentro de los clasificadores basados en teoría estadística [93] [94] [95] se utilizan diferentes criterios para establecer las fronteras entre categorías. Los criterios más comunes son: 1) mínima distancia, por el cual el píxel se asigna a la clase más cercana espectralmente, 2) paralelepípedo, donde el usuario establece unos umbrales de dispersión espectral asociados a cada clase, 3) máxima probabilidad, dentro de estos el más conocido es el *Máximum Likelihood Classifiers (MLCs)*. El *MLC* es un clasificador paramétrico basado en la teoría estadística que asigna un píxel a la clase a la que tenga mayor probabilidad de pertenecer. Otros métodos, como la regresión logística multinomial (*Multinomial Logistic Regression, ML*R) [96] [97] se basan en una referencia bayesina para modelar la distribución de las clases suministrando un grado admisible a cada clase. *Sparse MLR (SMLR)* [98], *Logistic Regression via splittin*g and augmented Lagrangian (LORSAL) son ejemplos de otros algoritmos pero más aplicados al procesado de imágenes hiperespectrales.

Las redes neuronales (*RN*) son técnicas no paramétricas con un gran potencial de discriminación que aún son muy recurridas por la comunidad científica, ya que evitan algunas limitaciones de los *MLCs*. Existen una gran cantidad de variantes de las *RNs* [99], una de las más populares utilizadas para clasificación de datos de teledetección es el perceptrón multicapa [100]. Por otro lado, también muy ampliamente utilizados están los árboles de decisión, que se trata de clasificadores paramétricos simples. Se presentan como un proceso recursivo que divide un proceso complejo en múltiples estados donde se toman decisiones más simples [101]. Para abordar casos más complejos, como la clasificación compuesta de datos multitemporales, se han desarrollado algoritmos neuronales basados en múltiples clasificadores (*ensemble*) como el *Random Forest (RF)* [102].

En los últimos años, han ganado especial importancia otras técnicas basadas en máquinas de vectores soporte (*SVM*) [103], puesto que presentan buenos resultados en la clasificación y son menos sensibles a la dimensionalidad de los datos y a la cantidad y calidad de las regiones de entrenamiento [104]. Dado que esta técnica es la utilizada a lo largo de esta *Tesis Doctoral*, a continuación se describen con mayor detalle los fundamentos de *SVM* (*Support Vector Machine*).

Support Vector Machine

Las máquinas de vectores soporte son algoritmos de aprendizaje automático supervisado que han sido desarrolladas principalmente para problemas de clasificación y de regresión. Las *SVM* pertenecían inicialmente a la familia de los clasificadores lineales y su fundamento matemático puede ser encontrado en [105] [106] [107].

En la formulación original de las *SVM* se presenta un conjunto de muestras y, durante el entrenamiento, el algoritmo trata de determinar hiperplanos que discriminen el conjunto de datos en un número predefinido discreto de clases. Se define como hiperplano óptimo aquel que entre todos los hiperplanos separadores maximice la distancia de separación entre las clases (Figura 69). Una característica única de las *SVM* es que no se utilizan necesariamente todas las muestras de entrenamiento para definir el hiperplano, si no que se utiliza un subconjunto de los datos, que son seleccionados como vectores soporte (*Support Vectors, SP*) y localizados en las zonas más cercanas a las fronteras entre clases. Como se puede en la Figura 69, sólo los puntos en negro son utilizados para construir el hiperplano *b* que maximice la distancia entre las clases 1 y 2.



Figura 69. Hiperplano b que separa dos clases maximizando el margen.

Durante el proceso de aprendizaje se trata de encontrar una condición de contorno óptima que separe las muestras de entrenamiento y se aplique sobre las muestras de test bajo la misma configuración.

Dado que no siempre es posible encontrar un hiperplano que separe las clases, para mapear los datos en un espacio de características de mayor dimensión se recurre a diferentes funciones *kernel*. La definición adecuada de la función *kernel* base que refleje la similitud entre las muestras es un parte crucial en la configuración del clasificador.

El teorema de *Mercer* [108] establece las condiciones para que una función sea un *kernel*: continúa, simétrica, y positiva semidefinida. Bajo estas condiciones, las funciones *kernel* más comúnmente utilizadas para desarrollar *SVM*s son las siguientes:

• Kernel Lineal:

$$k(x_i, x_j) = x_i \cdot x_j \tag{73}$$

• Kernel polinomial:

$$k(x_i, x_j) = (\gamma x_i \cdot x_j + r)^d, \gamma > 0$$
(74)

Siendo d>0 una constante que define el grado del polinomio y γ un factor de ponderación o peso.

• Función kernel de base radial (RBF):

$$k(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right)$$
(75)

Siendo γ un factor de ponderación o peso.

• Función kernel sigmoidal:

$$k(x_i, x_j) = \tanh(-\gamma x_i \cdot x_j + r) \tag{76}$$

Siendo γ un factor de ponderación o peso.

Cada función *kernel* incluye el producto $x_i \cdot x_j$ para medir la similitud entre los dos vectores.

La principal limitación de *SVM* es la necesidad de seleccionar la configuración de los parámetros más adecuada para mejorar la capacidad del clasificador. Existen diferentes metodologías de ajuste de los parámetros, conocidas como *grid search* y *gradient descent technique* [109] [110]. Con objeto de identificar los parámetros óptimos que maximicen el rendimiento del clasificador *SVM*, se ha optado por un procedimiento de búsqueda sistemática *grid search*. Consiste en entrenar y evaluar diferentes configuraciones, variando los valores de los parámetros. Finalmente se utiliza la combinación con los mejores resultados. El primer parámetro a configurar es el *kernel*, apoyándonos en la literatura científica [111] se ha elegido la función *kernel* de base radial, pues en la mayoría de los casos es el que ofrece los mejores resultados. Seguidamente se ajustan los valores de los parámetros (C, γ), partiendo de los valores iniciales (100, 0.125) propuestos en [112].

4.2.3 Fase de entrenamiento

Como ya se ha adelantado anteriormente, el método supervisado parte de un cierto conocimiento de la zona de estudio. Por tanto, es necesario delimitar sobre la imagen las áreas representativas de cada una de las categorías de interés. Estas áreas son denominadas áreas de entrenamiento. Su apropiada caracterización es una fase muy importante en el proceso de clasificación.

En el marco de esta *Tesis Doctoral*, estas clases son la representación de cada una de las diferentes especies vegetales. El propósito de la fase de entrenamiento es localizar los niveles digitales o reflectancias que identifican a cada categoría para todas las bandas de la imagen. A partir de ellas se caracterizará el resto de píxeles de la imagen en función de los criterios de similitud del clasificador.

Para la localización más precisa de estas áreas de entrenamiento han sido de gran ayuda las medidas de campo durante la campaña, así como el asesoramiento de un experto bien conocedor de la zona de estudio. Al disponer de la imagen en la misma fecha, se garantiza la consistencia entre lo medido en el terreno y por el sensor. Se ha tratado de seleccionar zonas lo más homogéneas

posibles y ejemplares de vegetación suficientemente representativos de cada categoría y seleccionando varias zonas, a fin de reflejar su variabilidad. Esta tarea resulta muy complicada sobre la Reserva Natural de las Dunas de Maspalomas, al tratarse de especies arbustivas no muy extensas y poco densas. Además, de la heterogeneidad de las especies y la similitud entre ellas. Esta situación va a condicionar en gran medida los resultados del clasificador.

La metodología de seleccionar las muestras y el tamaño del muestreo es importante en términos de la exactitud con la que se estimarán los parámetros estadísticos que describan las clases obtenidas. En cuanto al tamaño, como criterio habitual se requiere seleccionar un mínimo de m+1 píxeles por categoría, siendo m el número de bandas de la imagen [8]. La distribución espacial, viene condicionada por la resolución del sensor. Las variaciones internas de una categoría, pueden quedar enmascaradas por el tamaño del píxel. Así, como individuos de menor tamaño.

4.2.4 Estudio de la separabilidad de las clases

Una vez definida la fase de entrenamiento, antes de abordar el proceso de clasificación, conviene evaluar la separabilidad de las categorías seleccionadas. Se trata de analizar si estas clases son discriminables sin riesgo de error, pues en el caso de que dos a más clases sea muy similares, es probable que haya confusión entre ambas. En esta situación conviene introducir otro tipo de información de entrada que intente paliar este inconveniente o refundir dichas clases en una única.

Existen varios métodos para evaluar la sensibilidad espectral de las regiones de entrenamiento. Una puede ser una representación gráfica de las firmas espectrales de las categorías, que puede resultar muy útil para proporcionar una primera valoración de las tendencias espectrales de cada categoría. La Figura 70 muestra una representación gráfica de la reflectividad de las especies vegetales a discriminar en esta *Tesis Doctoral*. Vemos que representan espectros típicos de vegetación y, a primera vista, las respuestas espectrales de las especies son muy similares, agrupándose principalmente en dos grupos de tres en la segunda franja del espectro, con respuestas más similares. La Figura 70 (a) presenta las reflectividades obtenidas a partir de los datos de campo, mientras que la Figura 70 (b) representa la firma espectral a partir de la reflectividad obtenida sobre la imagen WV-2 en las posiciones equivalentes. Podemos apreciar que las respuestas son similares, aunque no son exactamente coincidentes. Esto se debe a factores como la resolución espacial del sensor, donde el píxel seleccionado puede abarcar una mezcla de otras cubiertas y también hay que tener en cuenta errores en la precisión de la localización de los píxeles.



Figura 70. Respuesta espectral de las especies vegetales a partir de: (a) datos del radiómetro de campo y (b) sobre la imagen WV-2.

Junto a los procedimientos gráficos, existen otros criterios cuantitativos que permiten evaluar numéricamente la posibilidad de discriminar las distintas categorías. Entre estos criterios cabe mencionar la divergencia estadística y la distancia de *Jeffries-Matusita* [113]. Estas dos medidas tienen en cuenta el vector de medias y la matriz de varianza-covarianza entre pares de categorías, asumiendo una distribución normal de las clases. A continuación, se describen con mayor detalle estas medidas.

Divergencia transformada (DT): se plantea con una fórmula que depende de la divergencia estadística, tratando de acotar los valores de esta última, cuyo problema fundamental es que no se satura. Es decir, la exactitud del clasificador aumentaría al incrementar el número de bandas utilizadas para clasificador. La expresión de la divergencia estadística se muestra en la ecuación (77). Cuanto mayor sea el valor de la divergencia, mayor será la separabilidad entre clases.

$$D_{ij} = \frac{1}{2} tr\left((C_i - C_j) (C_i^{-1} - C_j^{-1}) \right) + \frac{1}{2} tr\left((C_i^{-1} - C_j^{-1}) (\mu_i - \mu_j) (\mu_i - \mu_j)^T \right)$$
(77)

donde C_i y C_j son las matrices de varianza-covarianza de las categorías *i,j; tr* refiere a la traza o suma de los elementos de la diagonal de la matriz indicada; μ_i , μ_j son los vectores de medias correspondientes a las mismas categorías y bandas y T indica la matriz traspuesta.

Finalmente, la fórmula de la divergencia transformada acotada entre [0 2] es la siguiente. Para valores superior a 1.7 se considera una buena separabilidad entre las clases *i,j*.

$$\mathrm{DT}_{\mathrm{ij}} = 2\left(1 - \mathrm{e}^{\frac{-\mathrm{D}_{\mathrm{ij}}}{8}}\right) \tag{78}$$

Jeffries-Matusita (JM): al igual que la *DT*, tiene un comportamiento de saturación acotado en el valor 2, a medida que aumenta la separación entre las clases. Para poder definirla matemáticamente se debe conocer primero la distancia de *Bhattacharyya (B)*, que básicamente, mide la similitud de dos variables de dos distribuciones de probabilidad:

$$B = \frac{1}{8} (\mu_{i} - \mu_{j})^{T} \left(\frac{C_{i} + C_{j}}{2}\right)^{-1} (\mu_{i} - \mu_{j}) + \frac{1}{2} \ln \left(\frac{\frac{|C_{i} + C_{j}|}{2}}{\sqrt{|C_{j}||C_{i}|}}\right)$$
(79)

donde C_i y C_j son las matrices de varianza-covarianza de las categorías i,j; μ_i , μ_j son los vectores de medias correspondientes a las mismas categorías y bandas y $|C_i|$ es el determinante de la matriz.

Ahora, partiendo de la distancia anterior definimos el índice de Jeffries-Matusita como:

$$JM_{ij} = \sqrt{2(1 - e^{-B})}$$
(80)

Tanto la divergencia como la distancia de *Jeffries-Matusita* poseen límites inferiores y superiores. Si el valor calculado toma el límite superior se puede decir que esas dos clases son totalmente separables. Si el valor es nulo significa que no se pueden separar.

4.2.5 **Evaluación de la precisión de imágenes clasificadas**

Para evaluar la exactitud del clasificador se seleccionan unos datos de test suficientemente independientes de las muestras de entrenamiento.

La validación consiste en evaluar el rendimiento del clasificador mediante el cálculo de dos de los parámetros más utilizados: la precisión global y el estadístico kappa. Estas métricas se derivan de la matriz de confusión. Los resultados de la validación se utilizan para la selección de la configuración de parámetros óptimos, para comparar modelos de clasificación obtenidos mediante conjuntos de entrenamiento o combinaciones de parámetros de entrada para comparar las *SVM*.

A continuación, se describe con más detalle el cálculo de los parámetros utilizados.

Matriz de confusión

Con objeto de evaluar los errores en la imagen clasificada se crea la matriz de confusión. Para ello se comparan una serie de regiones o áreas de test obtenidas del mismo modo que las regiones de entrenamiento, es decir seleccionado sobre la imagen de forma manual píxeles representativos de cada especie o clase.

La matriz de confusión representa una tabla cruzada de las asignaciones hechas sobre la imagen frente a las asignaciones reales de las mismas clases (Figura 71). Así, se reflejan los acuerdos y desacuerdos entre la clasificación y la fuente de referencia. Las columnas indican las clases de referencia y las filas las categorías de la clasificación. En la diagonal se representan los píxeles de las muestras en los cuales hay coincidencia entre ambas fuentes. Mientras que las marginales representan los errores de la clasificación.

La relación entre el número de píxeles correctamente clasificados y el número total de muestras expresa la exactitud global del mapa. Las columnas residuales indican las asignaciones verdaderas que no fueron identificadas en el mapa, mientras que las filas residuales indican los píxeles clasificados que no corresponden a la realidad. Es decir, las filas indican los valores que asignados a la clase *i* fueron identificados como otras clases, y en las columnas se indican los píxeles asignados a otras clases que han sido identificados como la clase *i*. La matriz de confusión no sólo muestra la exactitud general del proceso, sino también la exactitud de cada categoría y los conflictos entre ellas.

	Referencia						
		Clase 1	Clase 2	Clase 3	Clase n	Total	
sión	Clase 1	X ₁₁				X ₁₊	
icac	Clase 2		X ₂₂			X ₂₊	
lasif	Clase 3			X ₃₃		X ₃₊	
0	Clase n				Xnn	X _{n+}	
	Total	X+1	X+2	X+3	X+n	ΣX _{ij}	

Figura 71. Estructura de una matriz de confusión.

Precisión global y estadístico kappa

A partir de la matriz de confusión se pueden derivar una serie de métricas de exactitud. Uno de los más simples es la relación entre las celdas de la diagonal, que representan las muestras que han

sido bien clasificadas del total de muestras de la validación. Este índice se denomina exactitud global (*OA, Overall Accuracy*) y se define mediante la siguiente expresión:

$$OA = \frac{\sum_{i=1,n} x_{ii}}{\sum_{i=1,n} \sum_{j=1,n} x_{ij}}$$
(81)

donde, x_{ii} es la diagonal de cada columna y x_{ij} es cualquier celda de la matriz de confusión.

Por otro lado, el estadístico kappa (\hat{k}) mide la coincidencia entre las categorías del mapa clasificado y las de referencia prescindiendo del efecto del azar. La estimación de este índice se puede realizar a partir de la siguiente ecuación:

$$\hat{k} = \frac{n \sum_{i=1,n} x_{ii} - \sum_{i=1,n} x_{i+} x_{+i}}{n^2 - \sum_{i=1,n} x_{i+} x_{+i}}$$
(82)

donde, *n* representa el número de muestras y x_{ii} indican las muestras bien clasificadas. El producto total de las filas y columnas ($x_{i+}x_{+i}$) estima los aciertos esperados para cada categoría.

El valor del estadístico kappa siempre va a ser inferior al de la precisión global, y cuanto más se aproximen ambos valores, menor es el efecto del azar en el resultado y mejor la capacidad de generalización del clasificador.

Otros parámetros que también pueden ser útiles en función de la aplicación son la precisión individual o porcentaje de aciertos y/o el porcentaje de errores o falsas alarmas dentro de cada clase.

4.2.6 Extracción de información espectral derivada

Además de la información contenida en las bandas originales de la imagen, se consideró de interés generar información derivada en forma de índices espectrales que pudieran incorporarse a la clasificación para facilitar la separabilidad de las cubiertas. En concreto, a partir de índices de vegetación.

Generalmente, los índices de vegetación son relaciones o combinaciones algebraicas de la reflectividad superficial de dos o más longitudes de onda diseñadas para destacar una propiedad espectral de la vegetación.

La reflectancia espectral de la cobertura vegetal varía con la longitud de onda, reflejando más en ciertas longitudes de onda que en otras. Una hoja está constituida por diferentes capas de materia orgánica de estructura fibrosa, las cuales contienen diferentes tipos de pigmentos como la clorofila a y b, xántofilas, carotenos y otros. Poseen una estructura fisiológica compleja y contenidos de agua variable, dependiendo de la especie y de las condiciones del sitio donde se desarrollan, como también de las características fenológicas de la propia hoja. Comúnmente, los índices de vegetación están basados en las bandas de infrarrojo cercano y el rojo, puesto que la reflectancia en el rojo depende del contenido de clorofila y la reflectancia en el infrarrojo cercano está asociado a la estructura interna de las células de las hojas. En la Figura 72 se presenta la curva de reflectividad típica de la vegetación sana [114].



Figura 72. Respuesta espectral de la vegetación sana.

Como indica la Figura 72, se puede resumir para las diferentes regiones espectrales lo siguiente:

- Región del visible (0,4 a 0,7 µm.): alta absorción, baja reflectancia y transmitancia, debido a los pigmentos.
- Región del infrarrojo cercano (0,7 a 1,3 µm.): absorción baja, reflectancia media-alta y transmitancia media. En este rango, la reflectividad crece notablemente debido a la escasa absorción de las plantas por su estructura fisiológica.
- Región del infrarrojo medio (1,3 a 3,0 µm.): absorción media-alta, reflectancia media, transmitancia baja. En esta región, el agua contenida en la hoja es la responsable de la baja reflectividad, dado que en esta región el agua presenta un máximo de absorción.

Más de 150 índices de vegetación han sido descritos en publicaciones científicas, pero sólo un pequeño subgrupo tiene bases biofísicas sustanciales o han sido sistemáticamente probados para detectar la presencia y abundancia relativa de pigmentos, agua y carbono reflejados en el espectro visible e infrarrojo (de 400 nm a 2500 nm). De estos índices, se ha hecho una selección de los más adecuados para sensores multiespectrales, como el *WorldView-2* [115]. Además, teniendo en cuenta las condiciones de la zona de estudio se ha tenido especial atención en incluir aquellos índices más adecuados para zonas semi-áridas.

Así, a continuación se muestran las expresiones de los índices de vegetación objeto de análisis en esta *Tesis Doctoral* usando las bandas del satélite WV-2:

Simple Ratio Index(SRI)	:	
	NIR1	(83)
	RED	
Normalized Difference V	/egetation Index (NDVI) [116]:	
	NIR1 – RED	(84)
	NIR1 + RED	(07)
Transformed Vegetation	Index (TVI):	
	$\sqrt{NDVI + 0.5}$	(85)

Non-Linear Index (NLI):

$$\frac{\text{NIR}^2 - \text{RED}}{\text{NIR}^2 + \text{RED}}$$
(86)

Atmospherically Resistant Vegetation Index (ARVI) [117]:

$$\frac{NIR2 - [(2 \cdot RED) - BLUE]}{NIR2 + [(2 \cdot RED) - BLUE]}$$
(87)

Structure-Insensitive Pigment Index (SIPI):

$$\frac{NIR1 - BLUE}{NIR1 - RED EDGE}$$
(88)

Renormalized Difference Index (RDI):

$$\frac{NIR1 - RED}{\sqrt{NIR1 + RED}}$$
(89)

Green Normalized Difference Vegetation Index (GNDVI):

$$\frac{NIR1 - GREEN}{NIR1 + GREEN}$$
(90)

Modified Simple Ratio MSR (MSR):

$$\frac{\frac{NIR1}{RED} - 1}{\sqrt{\frac{NIR1}{RED} + 1}}$$
(91)

Pigment Specific Simple Ratio (Chlorophyll a) (PSSRa):

$$\frac{NIR1}{RED \ EDGE} \tag{92}$$

Plant Senescence Reflectance Index (PSRI):

$$\frac{RED \ EDGE - BLUE}{NIR1} \tag{93}$$

Enhanced Vegetation Index (EVI) [118]:

$$2.5 \cdot \frac{(NIR1 - RED)}{NIR1 + 6 \cdot RED - 7.5 \cdot BLUE + 1}$$
(94)

Modified Chlorophyll Absorption in Reflectance Index (MCARI):

$$[(RED EDGE - RED) - 0.2 \cdot (RED EDGE - GREEN)] \cdot \frac{RED EDGE}{RED}$$
(95)

Modified Simple Ratio (MSR):

$$\frac{NIR1 - BLUE}{RED - BLUE}$$
(96)

Difference Vegetation Index (DVI):

$$NIR1 - RED \tag{97}$$

Transformed Chlorophyll Absorption in Reflectance Index (TCARI):

$$3 \cdot \left[(RED \ EDGE - RED) - 0.2 \cdot (RED \ EDGE - GREEN) \left(\frac{RED \ EDGE}{RED} \right) \right]$$
(98)

Visible Atmospherically Resistant Index (VARI):

$$\frac{GREEN - RED}{GREEN + RED - BLUE}$$
(99)

Visible Green Index (VGI):

$$\frac{GREEN - RED}{GREEN + RED}$$
(100)

Modified Normalized Difference (MND):

$$\frac{NIR1 - BLUE}{NIR1 + RED EDGE - 2 \cdot BLUE}$$
(101)

Carotenoid Reflectance Index (CRI):

$$\frac{1}{BLUE} - \frac{1}{RED \ EDGE} \tag{102}$$

Green Index (GI):

$$\frac{NIR1}{GREEN} - 1 \tag{103}$$

Red Index (RI):

$$\frac{NIR1}{RED} - 1 \tag{104}$$

Modified Soil Adjusted Vegetation Index 2 (MSAVI2) [119]:

$$\frac{(2*NIR+1-\sqrt{(2*NIR+1)^2-8*(NIR-RED)})}{2}$$
(105)

4.2.7 Extracción de información espacial derivada

Existe una gran variedad de medidas de texturas propuestas en la literatura científica. En esta *Tesis Doctoral* nos centraremos en las basadas en la *Gray-Level-Co-occurrence Matrix (GLCM)* [120]. Estas medidas de textura han sido empleadas por números investigadores con resultados generalmente beneficiosos. En el marco de esta *Tesis Doctoral*, se pretende incluir esta información textural a la clasificación con objeto de mejorar la separabilidad entre las especies [121].

La idea principal de las medidas de *GLCM* es que la información de textura contenida en una imagen está definida por la relación de adyacencia que tienen unos tonos de gris con otros presentes en la imagen. La relación de las frecuencias de ocurrencia entre celdas de distintos tonos de gris puede ser calculada de forma fiable para cualquier dirección y distancia *d* entre ambas. Aunque generalmente se consideran cuatro direcciones (0°, 45°, 90° y 135°). Es decir, si una imagen contiene una región homogénea extensa, y la medida de distancia *d* es relativamente pequeña en comparación con la estructura de la textura, la relación entre niveles de gris vecinos debería ser parecida, concentrando valores más altos en la diagonal de la matriz de co-ocurrencia. Por el contrario, para un patrón de textura muy heterogéneo, si la medida de distancia es comparable a la

escala de la estructura, los niveles de gris separados esa distancia serán muy diferentes, dispersando los valores altos lejos de la diagonal de la matriz de co-ocurrencia [113].

A continuación se muestran las expresiones de las medidas de textura que han sido objeto de análisis en esta *Tesis Doctoral* y que se engloban dentro de las más frecuentemente utilizadas por la comunidad científica [122]. En las siguientes ecuaciones p(i, j) denota la n-ésima entrada (i, j) de la matriz *GLCM* normalizada, y N_G indica el total de niveles de gris en la imagen cuantificada.

Varianza: mide la dispersión de los valores respecto a la media.

$$\sum_{i} \sum_{j} (i - u)^2 p(i, j)$$
(106)

Homogeneidad: es una medida relacionada con las características de textura específicas de la imagen. Aumenta su valor cuando cuanto el contraste entre las parejas de píxeles desciende.

$$\sum_{i} \sum_{j} \frac{1}{1 + (i - j)^2} p(i, j)$$
(107)

Disimilaridad: se computa con la diferencia en valor absoluto de los niveles de gris.

$$\sum_{n=1}^{N_{g-1}} |i-j| \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j)^2 \right\}$$
(108)

Entropía: es una medida de la complejidad y cantidad de información de la imagen. A mayor entropía mayor complejidad.

$$-\sum_{i}\sum_{j}p(i,j)\log(p(i,j))$$
(109)

4.2.8 Postclasificación

En el contexto espacial puede ser considerado como un postprocesado después de la etapa de clasificación para refinar los resultados. Tradicionalmente, los métodos de clasificación basado en píxeles muestran una excesiva fragmentación y píxeles etiquetados con una cierta categoría pueden estar rodeados de otras categorías no relacionadas. Las técnicas de postclasificación pueden ser utilizadas para reducir estos efectos. Generalmente se basan en filtros estadísticos, como la moda o el *majority* [123]. Éstos son aplicados a través de ventanas móviles de un cierto tamaño (3x3 o 7x7). La asignación del píxel central de la ventana es comparado con las asignaciones de los píxeles vecinos. El filtro de *majority* sólo cambia su asignación cuando hay una categoría con al menos más de la mitad más uno de todos los píxeles de la ventana. En otro caso, el píxel central mantiene su asignación original. La Figura 8 muestra un ejemplo de este filtrado.



Figura 73. Filtrado postclasificación majority. Fuente [8].

4.3 Metodología para la generación de cartografía de especies vegetales

A continuación, se describen las metodologías abordadas con objeto de discriminar las diferentes especies vegetales de interés sobre la Reserva Natural de Maspalomas. Se ha aplicado el algoritmo de clasificación supervisada *SVM* con los parámetros óptimos. La búsqueda de estos parámetros se ha realizado en dos fases. Una primera fase, donde se varían de forma exponencial creciente los valores de los parámetros (C=2⁻⁵,2⁻³,...,2²¹; γ =2⁻⁴,...,2³) y a continuación, una segunda búsqueda de afinamiento, variando ligeramente los valores en el entorno de la mejor configuración obtenida en la primera fase. Los indicadores utilizados para medir la exactitud del clasificador son la precisión global y el estadístico kappa. Tras el análisis descrito, se han obtenido los mejores resultados en la exactitud del clasificador con la pareja de valores (2^{19,5}, 0.125). Siendo, por tanto, estos valores lo que definen la configuración paramétrica óptima utilizada.

La estrategia para evaluar las diferentes metodologías de clasificación ha sido seleccionar regiones de interés representativas para cada especie o clase y entrenar el clasificador con dicha información. Inicialmente se realiza únicamente sobre las bandas multiespectrales de la imagen y posteriormente se va añadiendo información complementaria, espectral y/o espacial con objeto de mejorar la discriminación de las especies.

Finalmente, también se lleva a cabo el análisis del modelado lineal de mezcla de los píxeles, utilizando como *endmembers* las respuestas espectrales de las diferentes especies. Se extraen los mapas de abundancia y se introducen en el clasificador con objeto de evaluar la precisión de estas técnicas.

En los próximos apartados se irán detallando los diagramas de cada una de las metodologías propuestas.

Clasificación SVM sobre las bandas WV-2

En el siguiente diagrama se muestra cada una de las fases del procesado llevadas a cabo sobre las bandas multiespectrales de la imagen WV-2 para obtener la cartografía de especies vegetales objeto de análisis. En esta metodología sólo intervienen las bandas multiespectrales de la imagen WV-2.



Figura 74. Clasificación SVM sobre las bandas MS.

Clasificación SVM considerando índices de vegetación

Con objeto de aumentar la separabilidad entre las especies vegetales, se ha considerado introducir al clasificador información espectral derivada de las bandas multiespectrales de la imagen. La información espectral se ha extraído en forma de diferentes índices de vegetación (VIs), descritos en apartados anteriores. Para este caso se han abordado diferentes esquemas.

En primer lugar, se ha aplicado la clasificación *SVM* sobre una composición de los diferentes índices de vegetación, con la intención de analizar si las especies vegetales presentan características diferenciables con estos índices. El diagrama se muestra en la Figura 75.



Figura 75. Clasificación SVM sobre la composición de diferentes VIs.

En segundo lugar, también se ha analizado la incorporación de estos índices de vegetación junto a la información de las bandas multiespectrales en el clasificador *SVM*. En este sentido, cabe mencionar el conocido fenómeno de *Hughes* [124], que caracteriza la relación entre el número de muestras disponibles y el número de bandas. Aunque *SVM* presenta muy buenos resultados, puede dar fallos modelando la clasificación en caso de que esta relación sea muy baja. Así, en vez de añadir todos los índices de vegetación que implican mucha información para el clasificador, tras un estudio previo, se plantea analizar por separado cada índice de vegetación con el fin encontrar la mejor combinación que junto a las bandas multiespectrales, pueda proporcionar mayor separabilidad entre las clases. El diagrama se muestra en la Figura 76.



Figura 76. Clasificación SVM sobre la composición de bandas MS junto con cada índice de vegetación por separado.

Finalmente, se plantea la combinación de las bandas multiespectrales con diferentes emparejamientos de los índices de vegetación. Se analiza la matriz de separabilidad de las clases para cada par de índices de vegetación a fin de seleccionar la configuración que pueda producir mayor porcentaje de acierto en la clasificación.

Clasificación SVM incorporando información espacial

Igualmente, con objeto de aumentar la separabilidad entre las especies vegetales, se ha considerado introducir al clasificador información espacial derivada de las bandas multiespectrales

de la imagen. La información espacial extraída se ha obtenido a partir de medidas de textura basadas en la *Gray-Level-Co-occurrence Matrix*, que han sido descritas en apartados anteriores. Previo a la extracción de mapas de textura, se realiza una transformación en componentes principales de las bandas multiespectrales, con el fin de reducir la dimensionalidad de los datos y concentrar la información espacial en una sola banda. Así, se obtienen los mapas de textura sobre la primera componente principal. A continuación, con objeto de evaluar la mejor combinación, se aplica la clasificación *SVM* sobre una composición de las bandas multiespectrales y cada uno de los mapas de texturas, tal como se muestra en la Figura 77.



Figura 77. Clasificación SVM sobre la composición de bandas MS junto con cada mapa de textura por separado.

Clasificación SVM incorporando información espectral y espacial

Derivado de las metodologías descritas anteriormente, parece lógico pensar en incorporar de forma combinada información espectral y espacial. Así, se plantea el esquema de la Figura 78, donde se incluirán sólo los índices espaciales y espectrales que ofrezcan los mejores resultados.



Figura 78. Metodología de clasificación SVM incorporando información espacial y espectral.

Clasificación SVM basada en mapas de abundancia

A continuación, haciendo uso de la respuesta o firma espectral de cada especie vegetal y aplicando técnicas de modelado lineal de mezcla para cada píxel, se han obtenido los mapas de abundancia. Este procedimiento ya se ha descrito en apartados anteriores. Las firmas espectrales se han obtenido aplicando dos metodologías diferentes: (1) a partir de las medidas de campo obtenidas con un espectro-radiómetro sobre individuos representativos de cada especie y (2) a partir de las bandas multiespectrales de imagen WV-2, extrayendo la reflectividad de los píxeles localizados en los puntos donde se realizaron las medidas *in-situ*. La Figura 79 muestra la metodología para el caso (1) y la Figura 80 muestra la metodología para el caso (2).



Figura 79. Clasificación SVM sobre mapas de abundancia, a partir del desmezclado lineal con endmembers obtenidos del espectro-radiómetro de campo.



Figura 80. Clasificación SVM sobre mapas de abundancia, a partir del desmezclado lineal con endmembers extraídos de la imagen WV-2.

Una vez descritas todas las metodologías propuestas se procede a exponer y comparar los resultados obtenidos con cada uno de los procedimientos de clasificación. Además, la metodología que ofrezca los mejores resultados en la medida de exactitud del clasificador será aplicada sobre una imagen fusionada con el algoritmo *À trous*. Se ha seleccionado este método tras el análisis realizado en el capítulo 2 ya que ofrece una buena calidad espacial con mínima distorsión espectral.

Toda la evaluación se hará con la imagen WV-2 del 4 de junio de 2015 ya que se dispone de datos simultáneos de campo y, además, la metodología más adecuada también se validará con la imagen WV-2 del 17 de enero de 2013.

4.4 Resultados de la clasificación de especies vegetales en la Reserva Natural Especial de las Dunas de Maspalomas

Para llevar a cabo la medida cuantitativa de la exactitud de las imágenes clasificadas en cada una de las metodologías propuestas, se plantea el esquema que se muestra en la Figura 81. Como se aprecia se ha seleccionado otro conjunto de muestras de test o validación, diferentes a las utilizadas en el entrenamiento del clasificador.

Una vez obtenida la imagen clasificada se seleccionan las diferentes regiones de interés de test representativas para cada clase y se hace un análisis de la matriz de confusión para cada clase vegetal y de la medida de la exactitud global y del coeficiente kappa. Todas las metodologías son evaluadas con las mismas regiones de test.



Cartografía especies vegetales

Figura 81. Esquema de medida de la exactitud del clasificador.

En los casos más representativos, además se mostrarán datos de la matriz de confusión con objeto de analizar en detalle los errores del clasificador comparando las clases de las regiones de test con las clases asignadas por el clasificador.

Antes de proceder a mostrar los resultados de cada metodología, la Figura 82 muestra las regiones representativas de las diferentes especies vegetales utilizadas para entrenar al clasificador.



Figura 82. Regiones de entrenamiento sobre la imagen WV-2.

La Tabla 15 muestra la separabilidad de las clases de entrenamiento. Se aprecia que algunas clases presentan valores muy bajos de separabilidad (en negrita en la Tabla 15), lo cual evidencia que será difícil separar a partir de la información de las bandas multiespectrales. Es el caso de la *Tetraena fontanesii*, que con respecto al resto de especies, es la que más se confunde, sobre todo con la *Suaeda mollis* y la Launaea arborescens. A su vez, estas dos últimas se confunden entre ellas, presentando el valor de separabilidad más bajo de la tabla. Por otro lado, en base a los resultados se puede decir que, a priori, el *Tamarix canariensis* es la especie más separable, aunque con el *Juncus acutus* la separabilidad parece más limitada.

	Tamarix canariensis	Tetraena fontanesii	Traganum moquini	Suaeda mollis	Juncus acutus
Tamarix canariensis					
Tetraena fontanesii	1,959				
Traganum moquini	1,955	1,544			
Suaeda mollis	1,978	1,428	1,776		
Juncus acutus	1,733	1,948	1,994	1,974	
Launaea arborescens	1,937	1,428	1,633	1,369	1,901

Tabla 15. Matriz de separabilidad de las clases de entrenamiento.

Finalmente, en la Figura 83 se muestran las regiones de test utilizadas en el proceso de evaluación del clasificador.



Figura 83. Regiones de test sobre la imagen WV-2.

La Tabla 16 muestra la matriz de separabilidad sobre las clases de test, se puede observar nuevamente que la *Tetraena fontanesii* es la especie más conflictiva. Sin embargo, hay algunas diferencias entre la separabilidad de las especies respecto a las clases de entrenamiento. Esto demuestra lo sensible que es la caracterización de las regiones para cada especie, que aun siendo seleccionadas de forma rigurosa, los errores de precisión o el propio estado fenológico de distintos individuos de la misma especie complica el proceso de selección pudiendo inducir a errores.

	Tamarix canariensis	Tetraena fontanesii	Traganum moquini	Suaeda mollis	Juncus acutus
Tamarix canariensis					
Tetraena fontanesii	1.910				
Traganum moquini	1.965	1.338			
Suaeda mollis	1.998	1.445	1.874		
Juncus acutus	1.908	1.856	1.950	1.975	
Launaea arborescens	1.982	1.677	1.727	1.745	1.805

Tabla 16. Matriz de separabilidad de las clases de test.

4.4.1 Resultados de Clasificación SVM sobre las bandas WV-2

A continuación, se muestran los resultados tras aplicar la clasificación *SVM* sobre la imagen *WorldView-2* del 4 de junio de 2015 con las regiones de entrenamiento que se muestran en la Figura 82. En la Tabla 17 se muestran los valores de exactitud global y el coeficiente kappa evaluando la imagen clasificada con las regiones de test que se muestran en la Figura 83.

Tabla 17. Medidas de exactitud de la clasificación SVM sobre las bandas WV-2 para la imagen de junio 2015.

Imagen 2015				
Exactitud global Coeficiente kappa				
86,40%	0,82			

En la gráfica de la Figura 84 se analiza el porcentaje de aciertos para cada especie. En general, casi todas presentan buenos porcentajes de acierto, excepto la *Tetraena fontanesii*, que como ya se había adelantado en la matriz de separabilidad, se trata de la especie menos separable del resto. Además, su discriminación es más crítica debido a que es escasa, de menor tamaño y dispersa. Asimismo, hay que tener en cuenta el inconveniente de la clasificación de especies vegetales en píxeles donde se mezclan diferentes especies.



Figura 84. Porcentaje de aciertos para cada especie, tras la clasificación SVM sobre todas las bandas WV-2.

Analizando la matriz de confusión podemos evaluar los conflictos entre las especies. Las columnas representan las clases verdaderas, mientras que las filas representan los resultados del clasificador. En la diagonal de la matriz de confusión podemos ver los píxeles correctamente clasificados para cada especie. En cambio, los elementos fuera de la diagonal indican los errores de asignación. En las columnas se indican los errores por omisión y en las filas los errores por comisión.

La Tabla 18 muestra la matriz de confusión en porcentajes. Vemos que sobre las muestras de test seleccionadas, se han clasificado correctamente y por tanto con porcentajes muy altos la mayoría de las especies, excepto la *Tetraena fontanesii* con un 34,15% de acierto y aproximadamente un 65% porcentaje de error por omisión. De los cuales casi un 22% de los píxeles se han clasificado como *Tamarix canariensis* y un 24,39% como *Suaeda mollis*. Por otro lado, también píxeles pertenecientes a *Juncus acutus* han sido asignados a *Launaea arborescens*, en concreto un 16,39%. Con respecto a las demás especies, el *Tamarix canariensis* es la especie con el mayor porcentaje de acierto y errores de asignación a otras especies muy bajos (<1%). En el caso de Traganum moquini la mayoría de los píxeles omitidos han sido asignados a *Launaea arborescens*. Para esta última, de los píxeles omitidos, casi un 10% has sido asignados a Traganum moquini.

Imagen 2015	Tamarix canariensis	Traganum moquini	Juncus acutus	Suaeda mollis	Tetraena fontanesii	Launaea arborescens	Total
Tamarix canariensis	97,64	0,00	4,92	0,00	21,95	0,00	43,80
Traganum moquini	0,47	84,38	1,64	0,00	7,32	9,72	13,20
Juncus acutus	0,94	0,00	70,49	0,00	0,00	0,00	9,00
Suaeda mollis	0,47	0,00	1,64	100,00	24,39	1,39	12,60
Tetraena fontanesii	0,00	3,13	4,92	0,00	34,15	0,00	3,80
Launaea arborescens	0,47	12,50	16,39	0,00	12,20	88,89	17,60
TOTAL	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Tabla 18. Matriz de confusión sobre la clasificación SVM de las bandas de la imagen de 2015 (en valores porcentuales).

A continuación se muestra la imagen resultante de la clasificación. Visualmente se puede apreciar que la clasificación es buena y la distribución de la vegetación es muy similar al mapa cartográfico de la Figura 60 realizado sobre el terreno. Hay que tener en cuenta, que la clasificación *SVM* se realiza píxel a píxel, mientras que en el mapa cartográfico se realiza manualmente sobre poblaciones predominantes en el área. De ahí que la similitud nunca pueda llegar a ser exacta.



Figura 85. Clasificación SVM sobre bandas multiespectrales de la imagen WV-2 de 4 de junio 2015.

4.4.2 Resultados de la Clasificación SVM incorporando información espectral

A partir de los datos de referencia del análisis del apartado anterior, se ha considerado analizar la precisión de la clasificación incluyendo información sólo procedente de índices de vegetación. Se han seleccionado los índices más significativos y apropiados con objeto de discriminar las especies vegetales respecto a sus respuestas. En la Tabla 19 se muestran los resultados de exactitud y en la Figura 86 el porcentaje de aciertos tras aplicar la clasificación sobre la combinación de todos los índices de vegetación, ya descritos en apartados anteriores. Además, a modo de referencia se han incluido los valores obtenidos con las bandas multiespectrales.

Los resultados obtenidos en cuanto a la exactitud global y el coeficiente kappa no presentan gran variación para la imagen de 2015. Cabe recordar que este análisis está supeditado a unas regiones de interés concretas, que se ha intentado que sean representativas.

Tabla 19. Medidas de exactitud de la clasificación SVM sobre las bandas WV-2 y sobre los índices de vegetación (VIs) para la imagen del 4 de junio 2015.

	Imagen 2015				
	Exactitud global	Coeficiente kappa			
WV-2	86,40%	0,82			
VIs	86,34%	0,82			

Comparando los porcentajes de aciertos, se observa que se ha conseguido mejorar el porcentaje de acierto para la *Tetraena fontanesii*, que parece ser la especie más crítica. También el *Traganum moquini* presenta un porcentaje de acierto más alto. Para el resto de las especies no ha habido apenas variación. En definitiva, se puede concluir, que sólo las bandas de índices de vegetación no ayudan a mejorar la separabilidad de las especies ya conseguida a partir de las bandas multiespectrales originales.



Figura 86. Porcentaje de aciertos para cada especie, tras la clasificación SVM sobre todas las bandas WV-2 y sobre los índices de vegetación (VIs).

Por lo tanto, a continuación se plantea la estrategia de añadir a las bandas multiespectrales la información de los índices de vegetación. Con objeto de no introducir demasiadas bandas al clasificador, ya que puede degradar la exactitud del mismo, se ha optado, por realizar un análisis de la exactitud añadiendo por separado cada uno de los índices de vegetación.
La Figura 87 muestra los resultados de exactitud global obtenidos por el clasificador, para las bandas WV-2 añadiendo por separado los diferentes índices de vegetación analizados. Los resultados obtenidos manifiestan que no todos los índices de vegetación son adecuados para mejorar la discriminación de las especies vegetales en estudio. Pero se obtienen mejoras en la discriminación de especies vegetales con ciertos índices. En concreto, el índice que ofrece los mejores resultados es el *MSAVI2*. Este índice de vegetación modificado ajustado al suelo, es adecuado para zona áridas, como es el caso de la Reserva de Maspalomas.



Figura 87. Exactitud global del clasificador añadiendo a las bandas WV-2 diferentes índices de vegetación por separado.

Asimismo, también se realizó un análisis emparejando los índices de vegetación de la Figura 87 con los valores de exactitud más precisos, y se analizaron las matrices de separabilidad de las especies. Las parejas más óptimas se añadieron al clasificador con objeto de mejorar la discriminación de las especies vegetales. Sin embargo, en ningún caso se superó el valor de exactitud de 87.12% obtenido con el índice de vegetación *MSAVI2*. Por tanto, este índice será incluido dentro de la metodología de clasificación óptima.

4.4.3 **Resultados de la Clasificación SVM incorporando información espacial**

Con objeto de mejorar la exactitud se ha incluido información espacial de textura. En concreto, se ha ido añadiendo la información basada en la *Gray-Level-Co-occurrence Matrix (GLCM)* obtenida sobre la primera componente principal, tal y como se ha descrito en la metodología. La premisa es que el resultado de la clasificación de un píxel pueda variar cuando éste se analiza aisladamente a cuando se consideran también sus vecinos. El procedimiento seguido ha sido el mismo que al incorporar la información procedente de los índices de vegetación. Se ha ido incluyendo cada uno de los mapas de texturas a las bandas WV-2, posteriormente se ha analizado la exactitud del clasificador, utilizando las mismas regiones de test que para las metodologías propuestas anteriormente.

La Figura 88 muestra los porcentajes de acierto obtenidos incluyendo la información de entropía, disimilaridad, homogeneidad y varianza. Comparando los resultados sobre ambas imágenes, parece que la disimilaridad y la varianza ofrecen los mejores resultados. En concreto, la varianza ofrece mejores resultados que considerar sólo información de las bandas multiespectrales.



Figura 88. Exactitud global del clasificador incluyendo información espacial a las bandas WV-2.

Por lo tanto, en la metodología de clasificación óptima se incluirá la información de varianza.

4.4.4 Resultados de la Clasificación SVM integrando información espacial y espectral

Diferentes estudios han corroborado que incluyendo datos de textura conjuntamente con datos espectrales se mejora la precisión de la clasificación. Por tanto, una vez analizados los índices espaciales y espectrales más adecuados en la discriminación de las especies vegetales objeto de estudio, el siguiente paso es analizar la combinación de dichos índices y evaluar la respuesta del clasificador con esta información incluida.

Los resultados obtenidos se evalúan en la Figura 89, en la cual se han añadido los porcentajes obtenidos con las metodologías descritas anteriormente y los resultados combinando el índice de vegetación *MSAVI2* y la varianza de la *GLCM*. Como se aprecia, se ha conseguido mejorar el porcentaje de acierto con dicha combinación.



EXACTITUD GLOBAL DEL CLASIFICADOR

Figura 89. Exactitud global del clasificador combinando información espectral y espacial en el clasificador.

Una vez establecida como metodología óptima incluir a las bandas MS el índice de vegetación *MSAVI2* y la varianza de la matriz de co-ocurrencia, tras aplicar el procedimiento sobre la imagen del 4 de junio de 2015, además se aplicará la metodología sobre la otra imagen WV-2 perteneciente a la fecha del 17 de enero de 2013. Es interesante que pertenezca a otra estación del año puesto que permite analizar la fiabilidad cuando la vegetación presenta mayor vigorosidad. La *Tabla 20*

muestra los valores de exactitud del clasificador comparando los valores obtenidos con las bandas WV-2 y la configuración óptima. La Figura 91 muestra los porcentajes de aciertos para cada especie, comparando con la metodología inicial. Vemos que para ambas imágenes los resultados son buenos. Por tanto, la metodología demuestra ser robusta y con la configuración óptima se consigue mejorar los valores para la mayoría de las especies.

	Imagen 2015		Imagen 2013	
	Exactitud global	Coeficiente kappa	Exactitud global	Coeficiente kappa
Bandas WV-2	86,40%	0,82	77%	0,6982
Configuración óptima	88,03%	0,84	80,38%	0,73

Tabla 20. Precisión de la clasificación SVM incluyendo etapa de postclasificación.



Figura 90. Porcentaje de aciertos, comparando metodología inicial con la metodología óptima para la imagen de 4 de junio de 2015 y 17 de enero de 2013.

A continuación se muestran las imágenes resultantes óptimas tras la clasificación (Figura 91 y Figura 92). Los resultados en la discriminación y clasificación de las especies vegetales son buenos y la comparativa con la imagen cartográfica de referencia revela que las asignaciones realizadas se asemejan en gran medida a la verdad terreno.



Figura 91. Clasificación SVM óptima sobre la imagen del 4 de junio de 2015.



Figura 92. Clasificación SVM óptima sobre la imagen de enero de 2013.

Finalmente se incluye una etapa de postprocesado a la imagen clasificada, con el objetivo de suavizarla e introducir información contextual a las clases. En concreto, se ha aplicado el filtro de *majority*, descrito en apartados anteriores, con una ventana de 3x3. La exactitud del clasificador mejora (Tabla 21). En cuanto a los porcentajes de aciertos para cada especie vegetal, como se puede ver en la Figura 93 y Figura 94, mejora para la mayoría de ellas, especialmente para las

especies *Traganum moquini* y *Launaea arborescens*, aunque no es el caso de la *Tetraena fontanesii*, que al ser más dispersa y de menor tamaño queda enmascarada por las especies circundantes. Visualmente, la imagen queda menos ruidosa al reagruparse los píxeles aislados a la clase dominante (Figura 96 y Figura 95).

	Imagen 2015		Imagen 2013	
	Exactitud global	Coeficiente kappa	Exactitud global	Coeficiente kappa
Configuración óptima	88,03%	0,84	80,38%	0,73
Con filtrado majority	92%	0,89	86%	0,82

Tabla 21. Precisión de la clasificación SVM incluyendo etapa de postclasificación.



Figura 93. Comparativa de los porcentajes de aciertos incluyendo postprocesado majority para la imagen del 4 de junio 2015.



Figura 94. Comparativa de los porcentajes de aciertos incluyendo postprocesado majority para la imagen del 17 de enero 2013.



Figura 95. Clasificación SVM óptima con filtrado majority sobre la imagen del 4 de junio de 2015.



Figura 96. Clasificación SVM óptima con filtrado majority sobre la imagen del 17 de enero de 2013.

4.4.5 **Resultados de la Clasificación SVM sobre mapas de abundancia**

En este apartado se muestran los resultados obtenidos aplicando las técnicas de análisis de mezcla lineal descritas en apartados anteriores. Se evalúan los resultados del clasificador *SVM* sobre los mapas de abundancia obtenidos en dos casos. En el primer caso se extraen las reflectividades de

la imagen WV-2 sobre los puntos geolocalizados. En segundo lugar, se utilizan como *endmembers* las reflectividades de las especies vegetales, obtenidas con el radiómetro durante las medidas de campo. La Tabla 22 muestra los resultados de exactitud del clasificador sobre ambos casos. Como se puede apreciar, al utilizar directamente los datos del radiómetro la precisión lograda es mayor que al utilizar las reflectividades extraídas sobre la imagen WV-2. Se asume que puede ser debido también a errores de precisión en la localización de los puntos, que afectan a la hora de extraer estos *endmembers* y, además, a que la reflectividad de un píxel no representa un *endmember* puro debido al tamaño del píxel comparado con el de las especies vegetales y la baja densidad de algunas especies. Así, el individuo muestreado *in-situ* no es lo suficientemente grande comparado con la resolución del sensor puede que el punto considerado sobre la imagen sea un píxel que representa una mezcla de espectros. Hay que tener en cuenta que los datos del radiómetro se obtuvieron simultáneamente a la imagen del 2015 y, en consecuencia, es lógico que para la imagen del 2013 la exactitud sea peor al estar la vegetación en otro estado fenológico diferente.

	Imagen 2015		Imagen 2013	
	Exactitud global	Coeficiente kappa	Exactitud global	Coeficiente kappa
Abundancia imagen WV-2	67.88%	0.54	61.22%	0.47
Abundancia radiómetro	81.46%	0.72	65.06%	0.50

Tabla 22. Medidas de precisión en la clasificación SVM sobre mapas de abundancia.

En la Figura 97 se muestran los mapas de abundancia extraídos utilizando técnicas de desmezclado, considerando como *endmembers* las reflectividades del radiómetro, y superpuestas sobre la composición RGB de la imagen WV-2. Se observa que para algunas de las especies las abundancias no son representativas. Es decir, considera para muchos de los píxeles que están formados por una combinación de mezcla más representativa de duna húmeda y seca que de alguna especie de vegetación, excepto en especies más vigorosas, como el *Tamarix canariensis* y el *Juncus acutus*, que al ser más densas y tener un espectro de vegetación más definido, sí son más significativas en el modelado lineal.



Endmember-1 Tamarix canariensis

Endmember-2 Juncus acutus

Continúa en Figura 97



Endmember-3 Tetraena fontanesii

Endmember-4 Suaeda mollis



Endmember-5 Traganum moquini



Endmember-6 Launaea arborescens



Endmember-7 Duna seca

ο

Endmember-8 Duna húmeda



La Figura 98 muestra las imágenes clasificadas resultantes usando el algoritmo *SVM* y los mapas de abundancia obtenidos considerando los *endmembers* extraídos a partir de las medidas de campo. De otra parte, la Figura 99 muestra los resultados para el segundo caso, donde los *endmembers* se extraen de la información de la imagen WV-2.



Figura 98. Clasificación SVM sobre mapas de abundancia a partir de las reflectividades del radiómetro de campo: (a) Imagen del 4 de junio *de 2015 y (b) Imagen del 17 de enero de 2013.*



Figura 99. Clasificación SVM sobre mapas de abundancia a partir de las reflectividades extraídas de la imagen WV-2: (a) Imagen del 4 de junio de 2015 y (b) Imagen del 17 de enero de 2013.

En la Figura 100 se muestra la cartografía de especies vegetales tras aplicar un filtro de postprocesado *majority*, sobre las imágenes clasificadas de la Figura 98.



Figura 100. Clasificación SVM con majority sobre mapas de abundancia a partir de las reflectividades del radiómetro: (a) Imagen del 4 de junio de 2015 y (b) Imagen del 17 de enero de 2013.

Visualmente se observa mayor presencia de vegetación sobre la imagen del 17 de enero de 2013, esto puede ser debido a que al pertenecer a una época más lluviosa la vegetación está más vigorosa y la firma espectral de la vegetación es más pura y por tanto el porcentaje de abundancia es más significativo. Es decir, la mezcla del píxel no queda tan enmascarada por la presencia de la duna.

A continuación, se realiza una comparación de la precisión del clasificador *SVM* sobre las metodologías más adecuadas analizadas hasta el momento. Tal y como se muestra en la Figura 101, se puede concluir que la mejor metodología sigue siendo añadir la información de índice de vegetación y textura a las bandas multiespectrales de la imagen. El análisis con modelado lineal de mezcla, ofrece buenos resultados, pero no son tan precisos. Aunque algunas especies vegetales pueden estar mezcladas en un mismo píxel, es muy complejo modelar de forma lineal esta mezcla debido a la moderada resolución espectral del sensor embarcado en la plataforma WV-2 y las limitaciones espaciales antes reseñadas.



Figura 101. Comparativa de la exactitud global del clasificador sobre mapas de abundancia.

4.5 Clasificación SVM sobre Imagen Fusionada À trous

Una vez se han analizado diferentes metodologías para abordar la clasificación de las especies vegetales sobre la Reserva Natural de las Dunas de Maspalomas, se ha concluido que la mejor estrategia para la obtención del mapa de especies vegetales es incluir información de índices de vegetación (MSAVI-2) y texturas (varianza) a las bandas de la imagen multiespectral original. A continuación, se procede a evaluar el efecto de las técnicas de fusión sobre los resultados de la clasificación.

En primer lugar, mostramos el aspecto que tiene la imagen fusionada À *trous* sobre diferentes áreas de la zona de estudio. Podemos apreciar como quedan bien definidos los detalles espaciales sin alterar en gran medida la calidad espectral respecto a la multiespectral original.



Figura 102. Comparativa entre la imagen multiespectral original (izquierda) y la imagen fusionada (derecha) sobre diferentes áreas de la Reserva Natural de las Dunas de Maspalomas.

La Figura 103 y Figura 104 muestran los resultados de la clasificación *SVM* sobre las imágenes fusionadas aplicando la metodología óptima indicada anteriormente. Visualmente muestran buenos resultados, aunque comparativamente con la imagen multiespectral original las diferencias no son tan relevantes.



Figura 103. Clasificación SVM sobre la imagen fusionada del 17 de enero de 2013.



Figura 104. Clasificación SVM sobre la imagen fusionada del 4 de junio de 2015.

En la Figura 105 se muestra un zoom comparando la imagen MS original y la imagen fusionada, clasificadas ambas con la configuración óptima descrita para la metodología. Se aprecia una mejor definición en los contornos y la delimitación de las coberturas vegetales es más precisa. En algunas zonas la imagen fusionada discrimina más especies vegetales, que al ser más pequeñas quedan enmascaradas en la imagen MS original. Aunque, en la clasificación de las especies vegetales, a grandes rasgos, no se aprecian grandes diferencias.



Figura 105. Clasificación SVM con la configuración óptima: (a) Imagen MS original (b) Imagen fusionada.

Analizando de forma numérica la exactitud del clasificador obtenemos porcentajes menores para la imagen fusionada. En síntesis, la fusión no aporta valor a la hora de ayudar a discriminar las especies vegetales, más allá de una mejor identificación visual de su morfología.



Figura 106. Exactitud del clasificador SVM comparando con la imagen fusionada.

Añadiendo una etapa de postclasificación, mediante la aplicación nuevamente del filtro *majority*, se observa en la Figura 107 que la exactitud mejora ligeramente, aunque no se superan los porcentajes obtenidos al aplicar también el filtro *majority* sobre la imagen clasificada multiespectral original.



Figura 107. Exactitud del clasificador SVM comparando con la imagen fusionada aplicando filtro majority.

En las Figura 108 y Figura 109 se presentan los mapas tras el postprocesado para las imágenes fusionadas.



Figura 108. Clasificación SVM sobre la imagen fusionada de junio 2015 con filtro majority.



Figura 109. Clasificación SVM sobre la imagen fusionada de enero 2013 con filtro majority.

Analizando los porcentajes de aciertos por especies a partir de las matrices de confusión (Figura 110 y Figura 111) se concluye que, en general, son más altos para la imagen multiespectral original. Aunque cabe destacar que con la imagen fusionada se mejora considerablemente el porcentaje de acierto de la *Tetraena fontanesii*, lo cual resulta de interés, debido a que esta especie es de las más críticas a la hora de lograr su identificación. Sin embargo, como se puede observar, para el resto de especies se pierde mayoritariamente precisión.



Figura 110. Porcentajes de aciertos para la metodología óptima comparando con la imagen fusionada.



Figura 111. Porcentajes de aciertos para la metodología comparando con la imagen fusionada, aplicando filtrado majority.

A modo de conclusión, tras el completo análisis realizado se ha demostrado que la mejor metodología para la clasificación de especies vegetales sobre la Reserva de Maspalomas pasa por añadir a las bandas MS originales corregidas, información extraída de índices de vegetación (*MSAVI2*) e información del contexto espacial (varianza) de la textura (Figura 112). La clasificación a partir del modelado lineal de mezcla ofrece resultados aceptables en la clasificación, pero con una precisión menor. Esto es debido que la información de la imagen multiespectral no es suficientemente precisa y haría falta recurrir a otro tipo de imágenes como las hiperespectrales que ofrecen información en cientos de bandas. Finalmente, hay que indicar que la fusión de imágenes no ofrece mejoras destacables en la clasificación de especies a partir de la información del píxel, aunque visualmente ayuda en la delimitación precisa de las estructuras sobre la superficie terrestre.



Figura 112. Metodología óptima de clasificación de especies vegetales sobre la RNE de Maspalomas.

4.6 Resumen

En este capítulo se ha llevado a cabo el desarrollo y análisis de una metodología de clasificación de especies vegetales sobre la Reserva Natural Espacial de las Dunas de Maspalomas. Se han evaluado diferentes estrategias añadiendo información complementaria al clasificador con objeto de facilitar la separabilidad de las especies vegetales de interés. El clasificador elegido ha sido el *SVM*, adecuadamente parametrizado, y la configuración óptima se consigue al añadir información de índices de vegetación y de textura. En concreto, añadir el índice MSAVI2 y el mapa de varianza de la textura ha aportado los valores de precisión más exactos en la clasificación.

Esta metodología se ha aplicado sobre una imagen WV-2 de junio de 2015 y se ha validado sobre otra imagen WV-2 de enero de 2013. Los resultados obtenidos en la clasificación son comparables a la cartografía generada manualmente a partir de tecnología SIG por el Departamento de Geografía de la Universidad de Las Palmas de Gran Canaria. En el proceso de validación, además se ha contado con información de un experto conocedor de la zona.

Se ha intentado extrapolar las técnicas de desmezclado lineal, normalmente aplicadas sobre imágenes hiperespectrales, a las imágenes multiespectrales disponibles. Para analizar su viabilidad para la consecución del objetivo de esta *Tesis Doctoral*. A pesar de sólo disponer de información en ocho canales, los resultados obtenidos con estas técnicas permiten discriminar las especies vegetales de forma adecuada, especialmente si se aplican utilizando los *endmembers* medidos con el radiómetro de campo. Se ha constatado que en algunos casos y para ciertas especies los porcentajes de acierto son comparables o incluso mejores.

Cabe destacar que a lo largo de esta etapa de la *Tesis Doctoral*, se ha tenido que hacer frente a diferentes circunstancias que dificultan la clasificación de las especies vegetales. Por un lado, la baja resolución espacial del sensor comparado con el tamaño de ciertas especies vegetales que ocasiona que queden mezcladas varias coberturas en un píxel. Además, la resolución espectral (8 bandas) ha resultado ser escasa para distinguir especies con comportamientos espectrales similares, como es el caso de las especies vegetales objeto de estudio. Asimismo, sólo se dispone de datos del radiómetro de una época del año (época seca) y por tanto no se ha podido incluir la variabilidad suficiente para caracterizar de forma rigurosa a cada especie vegetal. Hay que tener en cuenta que ciertas especies en época de estrés hídrico pierden su vigorosidad y pueden casi secarse por completo (como la *Suaeda mollis* o la *Launaea arborescens*). Esto provoca que sea muy complicado obtener buenos resultados en la clasificación y, en especial, en la basada en modelado de mezcla lineal.

Finalmente, la fusión de imágenes se presenta como una técnica especialmente interesante para ayudar en la interpretación visual de la imagen. Sin embargo, no ofrece mejoras apreciables en la precisión del clasificador, puesto que no está aportado mayor información espectral a la imagen fusionada, y según el algoritmo de fusión elegido dicha información espectral puede alterarse.

En síntesis, tras un riguroso análisis, se ha logrado una metodología de clasificación adecuada para la generación de cartografía de especies vegetales en un ecosistema vulnerable y de gran complejidad a partir de datos de satélites de muy alta resolución espacial.

Capítulo 5

Conclusiones

El conocimiento de la distribución de la vegetación sobre ecosistemas naturales vulnerables como la Reserva Natural de las Dunas de Maspalomas es un indicador fundamental de las alteraciones de estos espacios singulares protegidos. Disponer de una cartografía detallada supone un esfuerzo considerable y actualizar los mapas, usando métodos tradicionales, es costoso y requiere excesiva dedicación y tiempo. Además, la automatización y sistematización es una tarea compleja.

En esta *Tesis Doctoral* se ha desarrollado una metodología de clasificación de especies vegetales sobre la Reserva Natural de las Dunas de Maspalomas, a partir de imágenes de satélites de última generación. En concreto, se ha realizado el análisis con imágenes de la plataforma *WorldView-2*, que ofrece una elevada resolución espacial y 8 bandas multiespectrales.

Sin embargo, la complejidad técnica de los actuales sistemas de teledetección y los diferentes niveles de procesado involucrados en la obtención de parámetros geofísicos requiere el establecimiento de una jerarquía de procesos que permitan la generación de productos operacionales de elevada resolución espacial y precisión. En este sentido, es clave el análisis de diferentes técnicas de procesado para obtener resultados precisos y fiables. Partiendo de estas premisas, a lo largo de esta *Tesis Doctoral* se han desarrollado y evaluado las diferentes técnicas de procesado involucradas. Hay que tener en cuenta que se pretende que esta metodología sea extrapolable a otras imágenes y zonas con independencia de las condiciones de adquisición.

Específicamente, se ha realizado el análisis y validación sobre dos imágenes WV-2 de enero de 2013 y junio de 2015. Además, simultáneamente a esta segunda imagen, se realizó una campaña de campo y se tomaron medidas *in-situ* de las reflectividades de las diferentes especies vegetales de interés, mediante un espectro-radiómetro de campo.

A continuación, se analizan con mayor detalle tanto las principales contribuciones de esta *Tesis Doctoral* como las futuras líneas de trabajo. Finalmente, se detallarán las principales publicaciones en revistas de impacto y contribuciones a congresos nacionales e internacionales vinculadas con esta *Tesis Doctoral*.

5.1 Principales contribuciones

El trabajo realizado en esta *Tesis Doctoral* puede ser dividido en tres bloques principales: técnicas de fusión de imágenes, técnicas de corrección de imágenes y clasificación de especies vegetales en la Reserva Natural de las Dunas de Maspalomas, los cuales se corresponden con los capítulos 2, 3, y 4 respectivamente. A continuación se van a presentar las principales contribuciones realizadas en cada uno de estos tres bloques.

Técnicas de fusión de imágenes de satélite

En este contexto, se ha llevado a cabo la implementación de diferentes técnicas de fusión (*pansharpening*) de imágenes, integrando la información multiespectral y pancromática. Se ha realizado un análisis exhaustivo de diferentes algoritmos, aplicado a imágenes de satélite abarcando diferentes coberturas de la superficie terrestre, con objeto de analizar los efectos que produce la fusión sobre la imagen resultante, en cuanto a calidad espacial y espectral, y su influencia según las características propias de la escena. El análisis se ha realizado cualitativamente y cuantitativamente. Específicamente, se han evaluado ocho algoritmos de fusión (*Brovey, IHS, eIHS, PCA, TWD, À trous AW, À trous AWI* y *À trous AWPC*) sobre ocho coberturas (agrícola, costera, árida, forestal, agua embalsada, urbana y vegetación vigorosa), usando para la medida de calidad un total de seis índices (*ERGAS espacial e índice Zhou, ERGAS espectral, CC, Zhou, Q y SSIM*).

En el análisis cualitativo se ha comprobado que todos los métodos de fusión mejoran considerablemente la calidad espacial de la imagen. Las técnicas basadas en operaciones aritméticas y de sustitución de componentes, como *IHS* o *PCA* presentan mejor eficiencia espacial, con bordes mejor definidos, sin embargo, alteran en mayor medida la información espectral de las bandas originales. Los métodos basados en la transformada *wavelet* producen bordes más difusos, con una distorsión más significativa en el algoritmo de *Mallat*. Además, presentan la aparición de sombras sobre la imagen, pero la calidad espectral de la imagen fusionada es mayor. Este análisis cualitativo se completó evaluando los efectos espectrales de la fusión en cada componente de color, comparando las bandas R, G y B de la imagen fusionada y multiespectral original respectivamente. Asimismo, para evaluar los efectos del detalle espacial sobre estas componentes, se añadió el filtrado paso alto Sobel sobre las bandas R, G y B, además se incluyó la componente *I*.

En cuanto a las medidas cuantitativas, se han analizado diferentes índices para medir la calidad espacial y espectral, según se compare con la imagen MS o la imagen PAN, respectivamente. Las medidas de calidad espectral están más extendidas que las medidas de calidad espacial, siendo éstas últimas más escasas y menos fiables. Tras el análisis se ha demostrado que para todas las coberturas los índices *ERGAS* espectral y *Q* son los más fiables para medir la calidad espectral, y el *ERGAS* espacial es más robusto para medir la calidad espacial. El resto de índices, en general son menos sensibles y en algunos casos presentan inconsistencias con la inspección visual.

Como conclusión fundamental, en relación con las técnicas de fusión tanto su análisis cualitativo como cuantitativo demuestran que las técnicas basadas en transformada *wavelet À trous* presentan las mejores respuestas espectrales. Por tanto, con una aceptable mejora espacial se presentan como las más adecuadas para llevar a cabo técnicas la clasificación basadas en la respuesta espectral de elementos de la superficie terrestre, y, en especial, de la vegetación.

Finalmente, con objeto de analizar de forma precisa y controlada cada algoritmo de fusión, se ha creado una imagen sintética, con alta riqueza espacial y espectral, y se ha realizado la evaluación cuantitativa y cualitativa tras la aplicación de las distintas técnicas de *pansharpening*. Las conclusiones extraídas son consistentes con las descritas para las imágenes reales.

Técnicas de corrección de imágenes de satélite

Para una correcta interpretación de los datos de las imágenes de satélite es necesario llevar a cabo las pertinentes correcciones geométricas, radiométricas y atmosféricas. Las imágenes son distribuidas con ciertas correcciones radiométricas y geométricas asociadas a perturbaciones propias de los sensores y movimientos de las plataformas, que afectan en los valores de los niveles digitales de la imagen y a la posición de los píxeles. Sin embargo, los píxeles de las imágenes suministradas siguen sin representar la verdadera energía reflejada de la superficie terrestre. Por este motivo es necesario llevar a cabo las correcciones que eliminen los efectos condicionados al momento de adquisición de la imagen y las perturbaciones atmosféricas.

En este contexto, las correcciones atmosféricas son las que presentan la mayor dificultad, puesto que se requiere modelar el efecto de absorción y dispersión que produce la atmósfera y, para ello, es necesario información de parámetros físicos en el momento de captación de la imagen que no siempre están disponibles. Tras analizar y evaluar el estado del arte en técnicas de corrección atmosférica, existen métodos más sencillos basados en información de la propia imagen (*DOS* y *QUAC*), pero no siempre resultan adecuados y son menos precisos que los basados en modelado de transferencia radiativa de la atmósfera (*ATCOR, FLAASH y 6S*). Estos modelos requieren de la configuración de diferentes parámetros, como son: el modelo de atmósfera y de aerosol, el valor del espesor óptico, la altitud de la escena y la presencia del efecto de adyacencia.

Al disponer de medidas *in-situ* tomadas durante una campaña de campo simultánea al paso del satélite, se han podido utilizar estos datos para hacer una evaluación rigurosa de las correcciones atmosféricas. Este procedimiento se ha realizado sobre diferentes puntos de sustrato y vegetación situados en la Reserva Natural de las Dunas de Maspalomas y se ha realizado un análisis cuantitativo, comparando las reflectividades de las medidas *in-situ* con las obtenidas sobre la imagen corregida por los diferentes algoritmos de corrección atmosférica.

En general, tras el análisis de los resultados obtenidos, se puede concluir que los algoritmos basados en parámetros físicos como *ATCOR*, *FLAASH* y 6S presentan resultados más correlados con las medidas *in-situ y*, en especial, el algoritmo 6S es el que ofrece un menor error cuadrático medio para los puntos de vegetación y suelo analizados. Los algoritmos basados en la imagen (*DOS* y *QUAC*) tienden a degradar la firma espectral y a subestimar, en general, la reflectividad real. Por tanto, en la cadena final de procesado se ha considerado incorporar esta corrección atmosférica.

Finalmente, a la hora de utilizar las imágenes multiespectrales es necesario garantizar la perfecta correspondencia geométrica entre ellas. En este sentido, tras las correcciones geométricas ya aplicadas a las imágenes WV-2, se ha realizado el co-registro de las dos escenas, que se utilizarán en la generación de cartografía de especies vegetales. Tras revisar las técnicas de co-registro, se aplicó la más adecuada usando puntos de control obtenidos tanto de forma automática como manual. La evaluación de la precisión demostró una mejora significativa en la localización final de los puntos.

Clasificación de especies de vegetales en la Reserva Natural de Maspalomas

Finalmente, uno de los principales objetivos de esta *Tesis Doctoral* es la clasificación de especies vegetales sobre la Reserva Natural de las Dunas de Maspalomas. En concreto, la clasificación de seis especies vegetales denominadas: *Tamarix canariensis, Traganum moquini, Zygophyllum fontanesii, Juncus acutus, Suaeda mollis y Launaea arborescens*.

En primer lugar, se ha realizado un análisis del estado del arte de las diferentes técnicas de clasificación de imágenes de alta resolución. En esta *Tesis Doctoral* nos centramos en las técnicas de clasificación supervisada, y en especial, en las basadas en *Máquinas Vectores Soporte (SVM)*, por su fiabilidad a la hora de obtener resultados consistentes en la clasificación.

Una de las limitaciones de los clasificadores supervisados es la adecuada definición de las regiones de entrenamiento. De otra parte, el clasificador *SVM* requiere la correcta configuración de sus parámetros. En este sentido, se ha tenido que realizar una evaluación para la obtención de los parámetros óptimos de entrenamiento basada en los resultados de exactitud obtenidos para las mismas regiones de entrenamiento a partir del método de *grid search en dos etapas*. Una vez adecuadamente parametrizado el clasificador, se procede a analizar las fuentes de información disponibles para discriminar las especies vegetales de interés. Para este fin, se plantean diferentes metodologías, que incluyen la adición de información espectral y espacial a las bandas multiespectrales de la imagen. Para introducir información espectral adicional se realiza un análisis sobre diferentes índices de vegetación. La información espacial se obtiene a partir de la textura de la imagen calculada mediante la matriz de co-ocurrencia. Las metodologías analizadas incluyen diferentes combinaciones a la hora de introducir la información al clasificador. En todo momento se evalúa la exactitud del clasificador utilizando otras regiones de test diferentes a las utilizadas durante el entrenamiento. Tanto en la generación de regiones de entrenamiento como de test se ha contado con la ayuda de un experto conocedor de la zona.

Tras el análisis efectuado, se ha concluido que la metodología que ofrece los mejores resultados está representada por un compromiso entre la cantidad de información introducida y la precisión del clasificador. Es decir, no por introducir mayor cantidad de información, los resultados han sido mejores. En conclusión, incluir las bandas multiespectrales, más un índice de vegetación (MSAVI-2) y una banda de información contextual (varianza) es la combinación que ofrece los mejores resultados. Además, aplicando un filtrado de postprocesado como el *majority* se consigue suavizar el mapa cartográfico y también la precisión.

Paralelamente, se ha realizado un análisis de técnicas de mezcla lineal, que tratan de modelar la respuesta espectral de cada píxel como una combinación lineal de firmas espectrales puras (denominadas *endmembers*). Para este análisis se evaluaron dos casos. En el primero se asumen como *endmembers* las respuestas espectrales de las especies vegetales obtenidas a través del radiómetro de campo. En el segundo análisis se extraen los *endmembers* sobre la imagen, en aquellos puntos donde se han realizado las medidas *in-situ*. Tras este proceso de desmezclado lineal se obtienen unos mapas de abundancia que representan la proporción de cada *endmember*. A continuación, estos mapas de abundancia son introducidos en el clasificador *SVM*. Este modelado ofrece resultados aceptables, pero de menor precisión que los anteriores. Probablemente, debido al limitado número de bandas multiespectrales de la imagen que implica no disponer de información suficiente para poder discriminar las diferentes especies con comportamientos espectrales tan similares. Sería necesario disponer de datos hiperespectrales de alta resolución para alcanzar resultados adecuados.

El exhaustivo análisis realizado para identificar la metodología adecuada se ha realizado sobre la imagen WV-2 del 4 de junio de 2015 y el protocolo óptimo adecuado ha sido validado sobre otra imagen WV-2 del 17 enero de 2013. La metodología ha demostrado ser robusta ante los cambios relativos al estado fenológico de la vegetación. Hay que tener en cuenta que ambas imágenes pertenecen a épocas distintas. Una fue captada en verano, donde la vegetación está normalmente más seca al sufrir mayor estrés hídrico y la otra en invierno, cuando las precipitaciones son más frecuentes. Además de la evaluación cuantitativa, para llevar a cabo el análisis visual de los mapas de vegetación, también se ha contado con el conocimiento del experto, que ha validado los resultados obtenidos tras la clasificación.

Por otro lado, cabe mencionar las limitaciones de la clasificación de especies vegetales, que en algunos casos presenta una complejidad insalvable debido a la distribución de la propia vegetación, donde algunos individuos quedan enmascarados bajo otras especies vegetales, y donde el píxel queda representado como una mezcla de especies difícil de caracterizar. También hay que tener en cuenta el pequeño tamaño de las especies y la dinámica de la zona de estudio donde el

desplazamiento de las Dunas puede provocar enterramientos parciales de ciertas especies vegetales.

Finalmente, aplicando la metodología óptima sobre las imágenes previamente fusionadas mediante el algoritmo À trous, se concluye que los resultados de la clasificación no ofrecen considerables mejoras. Es decir, una clasificación basada principalmente en la información radiométrica del píxel no se ve mejorada por el proceso de fusión, ya que éste puede alterar en alguna medida la calidad espectral de la imagen al introducir información de la PAN. En cualquier caso, para una inspección visual del mapa de vegetación obtenido si se considera interesante incluir la imagen fusionada en la cadena de procesado al delimitarse con mayor precisión los contornos de la vegetación.

5.2 Líneas futuras de investigación

Las limitaciones de la cartografía de comunidades vegetales en zonas semiáridas a partir de imágenes de satélites multiespectrales están asociadas a la falta de suficiente información espectral y espacial que represente la variabilidad total de los individuos de cada comunidad vegetal, más aún cuando las especies vegetales presentan respuestas muy similares en este tipo de ecosistemas. En consecuencia, se plantean las siguientes líneas futuras con objeto de mejorar los resultados de la clasificación.

• Cartografía de especies vegetales mediante teledetección hiperespectral

La teledetección hiperespectral tiene una gran capacidad para el estudio y seguimiento de las formaciones vegetales [84]. El inconveniente que presenta actualmente para obtener información precisa y de alta resolución espacial es la necesidad de recurrir a datos de vuelo aerotransportado, lo cual implica un elevado coste y menor operatividad. Aunque hay que destacar que la obtención de datos hiperespectrales a partir de vuelos con drones está empezando a potenciarse.

Por otro lado, las imágenes hiperespectrales presentan una complejidad de procesado mayor al de las imágenes multiespectrales. Sin embargo, ofrecen información en cientos de bandas espectrales, suficientes para caracterizar con detalle la firma espectral de diferentes elementos de la cubierta terrestre. Son, por tanto, una fuente de información atractiva para generar cartografía fiable de vegetación gracias a su capacidad para discriminar especies vegetales muy parecidas.

Clasificación basada en objetos

Otras técnicas de clasificación que están resultando novedosas y con gran potencial en el procesado de imágenes de muy alta resolución son las basadas en el análisis de la imagen basada en objetos (*OBIA, Object Based Image Analysis*). Para ello se requiere de un proceso riguroso de segmentación previo de la imagen, puesto que estas técnicas interpretan las imágenes no en base a píxeles, sino a los objetos que aparecen en ellas, de forma análoga a como lo hace el Sistema Visual Humano. La identificación de los objetos se basa en características espectrales, texturales, de forma y en información de contexto, estructural y en las relaciones espaciales entre diferentes escalas. Realizar un análisis de estas técnicas, con intención de tratar algún patrón espacial o de contexto que caracterice a las diferentes especies vegetales podría ser una interesante línea de trabajo futura.

Modelado radiativo de la vegetación

El comportamiento espectral de la vegetación es un problema volumétrico tridimensional de índole no lineal el cual puede ser resuelto mediante los modelos de transferencia radiativa. Se trata de modelar, de forma analítica, los procesos bioquímicos y geométricos que inciden en la reflectividad de la vegetación.

El modelo más ampliamente utilizado por la comunidad científica es el *PROSAIL*, el cual es el resultado de la integración de dos modelos; el *PROSPECT*, que se encarga del modelado de las propiedades de reflexión-transmisión de la luz en las hojas según sus componentes bioquímicos, y el modelo SAIL que se encarga del modelado de la difusión de la luz en el volumen tridimensional de la planta, utilizando para ello información geométrica de iluminación-visión, densidad foliar y función de distribución de la forma-inclinación de las hojas. PROSAIL permite un modelado del espectro visible, infrarrojo cercano e infrarrojo medio (400-2500 nm). Si bien *PROSAIL* está orientado al modelado radiativo de sensores hiperespectrales, varios trabajos han demostrado que es posible la utilización del modelo en imágenes multiespectrales [125].

Por tanto, se plantea como una línea futura llevar a cabo un análisis de la sensibilidad a estos parámetros, de las diferentes especies vegetales con objeto de discriminarlas a partir de este tipo de información.

5.3 Listado de publicaciones

A continuación, se detalla la producción científica derivada, de forma directa o indirecta, de las investigaciones realizadas durante la *Tesis Doctoral*.

Publicaciones en revistas de impacto

Javier Marcello, Francisco Eugenio, Ulises Perdomo, Anabella Medina. Assessment of atmospheric algorithms to retrieve vegetation in natural protected areas using multispectral high resolution imagery. Sensors 2016, 16(10), 1624; DOI:10.3390/s16101624. [Índice de impacto: 2.033]

Javier Martin Abasolo, Francisco Eugenio, Javier Marcello, Anabella Medina. Automatic Sun Glint Removal of Multispectral High-Resolution Worldview-2 Imagery for Retrieving Coastal Shallow Water Parameters. Remote Sensing 01/2016; 8(1). DOI:10.3390/rs8010037. [Índice de impacto: 3.180]

Javier Marcello, A. Medina, F. Eugenio. Evaluation of Spatial and Spectral Effectiveness of Píxel-Level Fusion Techniques. IEEE Geoscience and Remote Sensing Letters 05/2013; 10(3). DOI:10.1109/LGRS.2012.2207944. [Índice de impacto: 1.809]

Publicaciones en congresos

J. Marcello, A. Medina, A. Hernández y F. Eugenio. Cartografía de especies vegetales mediante la aplicación de técnicas de desmezclado y clasificación en imágenes de alta resolución. XVII Congreso de la Asociación Española de Teledetección. Murcia, 10/2017.

J. Marcello, F. Marqués, F. Eugenio, A. Medina, E. Ibarrola. Selección de información espacial para mejorar la clasificación temática en imágenes de alta resolución. XVI Congreso Internacional de la Asociación Española de Teledetección. Sevilla, 10/2015.

D. Rodríguez, J. Marcello, Anabella Medina Machín, F. Eugenio, C. Gonzalo, Á. García. Evaluation of the performance of spatial assessments of pansharpened images. IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Quebec, 07/2014.

D. Rodríguez, J. Marcello, A. Medina, F. Eugenio, Consuelo Gonzalo Martín. Evaluación de las Métricas de Calidad Espectral de Imágenes Fusionadas frente a variaciones de intensidad. XV Congreso Internacional de la Asociación Española de Teledetección. Madrid, 10/2013. D. Rodríguez, M. Galve, J. Marcello, A. Medina, F. Eugenio, C. Gonzalo. QIT Fusion, Herramienta para el Análisis de la Calidad de las Imágenes Fusionadas a partir de Datos de Teledetección. XV Congreso Internacional de la Asociación Española de Teledetección. Madrid, 10/2013.

A. Medina, J. Marcello, F. Eugenio, D. Rodríguez, J. Martín. Color and spatial distortions of pansharpening methods in real and synthetic images. Proceedings of SPIE - The International Society for Optical Engineering. Edinburgh, 11/2012.

J. Martin, F. Eugenio, J. Marcello, A. Medina, J. A. Bermejo, M. Arbelo. Atmospheric correction models for high resolution WorldView-2 multispectral imagery: A case study in Canary Islands. Proceedings of SPIE - The International Society for Optical Engineering. Spain. Edinburgh, 11/2012.

J. Marcello, F. Eugenio, A. Medina. Analysis of regional vegetation changes with medium and high resolution imagery. Proceedings of SPIE - The International Society for Optical Engineering. Edinburgh, 09/2012.

A. Medina, J. Marcello, D. Rodríguez, F. Eugenio, J. Martin. Quality evaluation of pansharpening techniques on different land cover types. IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Munich, 07/2012

S. Lopez, G. Marrero, A. Medina, J. F. Lopez, R. Sarmiento. High-level FPGA-based implementation of a hyperspectral endmember extraction algorithm. 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Shanghai, 06/2012

A. Medina. Implementación de algoritmos matemáticos para la mejora de la calidad espacial en imágenes multiespectrales de satélites de muy alta resolución. VI Congreso Spanish Space Students del Laboratorio para Experimentación en Espacio y Microgravedad. Las Palmas de Gran Canaria, 11/2011.

J. Marcello, A. Medina, Dionisio Rodríguez y F. Eugenio. Identificación y análisis de técnicas de fusión en imágenes de satélites de muy alta resolución. XIV Congreso Internacional de la Asociación Española de Teledetección. Mieres, 09/2011.

D. Rodríguez, J. Marcello, A. Medina. Introducción a la Fusión de Imágenes y sus Métricas de Calidad. Conferencia Iberoamericana en Sistemas, Cibernética e Informática (CISCI). Orlando, 07/2011

Capítulo 6

Lista de acrónimos

Acrónimo	Descripción	
SIG	Sistemas de Información Geográfica	
WV-2	WoldView-2	
PAN	Pancromático	
MS	Multiespectral	
PCA	Principal Component Analysis	
IHS	Intensity Hue Saturation	
MRA	MultiResolution Analysis	
SVM	Support Vector Machine	
FUS	Fusionada	
GS	Gram-Schmidt	
HPF	High Pass Filtering	
HPM	High Pass Modulation	

TWD	Trasformada Wavelet Discreta
AWI	À trous Wavelet IHS
AWPC	À trous Wavelet PCA
RGB	Red-Green-Blue
eFIHS	extended Fast IHS
NIR	Near-Infra-Red
CP1	Primera componente principal
ERGAS	Erreur Relative Globale Adimensionalle de Synthèse
SSIM	Structural SIMilarity
Q	Image Quality index
СС	Coeficiente de correlación
RMSE	Root Mean Square Error
RASE	Relative Average Spectral Error
CE90	Circular Error 90%
DEM	Digital Elevation Model
DSM	Digital Surface Model
UTM	Universal Transverse Mercator
ND	Niveles Digitales
ToA	Top of Atmosphere
TDI	Time Delayed Integration
WRC	World Radiation Center
UA	Unidad astronómica
DOS	Dark Object Subtraction
COST	Cosine of the sun zenith angle
QUAC	QUick Atmospheric Correction
SMAC	Simplified Method for the Atmospheric Correction
ELC	Empirical Line Calibration
RTC	Radiative Transfer Code

MODTRAN	MODerate resolution atmospheric TRANsmission	
FLAASH	Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes	
ATCOR	ATmospheric CORrection	
6S	Second Simulation of a Satellite Signal in the Solar Spectrum	
SMACC	Sequential Maximum Angle Convex Cone	
NDVI	Normalized Difference Vegetation Index	
SAW	Sub-Artic Winter	
MLW	Mid-Latitude Winter	
MLS	Mid-Latitude Summer	
SAS	Sub-Artic Summer	
LUT	Look-Up-Table	
ΑΟΤ	Aerosol Optical Thickness	
AOD	Atmospheric Optical Depth	
SMS	Simulated Multi-Spectral	
NMRF	Normalized Multispectral Response Function	
GCPs	Ground Control Points	
ULPGC	Universidad de Las Palmas de Gran Canaria	
MLC	Maximum likelihood classifier	
LMA	Levenberg-Marquardt-Algorithm	
MLR	Multinomial Logistic Regression	
SLR	Sparse MLR	
LORSAL	Logistic Regression via splitting and augmented Lagrangian	
RN	Redes Neuronales	
RF	Random Forest	
SP	Support Vectors	
RBF	Radial Base Function	
JM	Jeffries-Matusita	
OA	Overall Accuracy	

SRI	Simple Ratio Index
TVI	Transformed Vegetation Index
NLI	Non-Linear Index
ARVI	Atmospherically Resistant Vegetation Index
SIPI	Structure-Insensitive Pigment Index
RDI	Renormalized Difference Index
GNDVI	Green Normalized Difference Vegetation Index
MSR	Modified Simple Ratio MSR
PSSRa	Pigment Specific Simple Ratio (Chlorophyll a)
PSRI	Plant Senescence Reflectance Index
EVI	Enhanced Vegetation Index
MCARI	Modified Chlorophyll Absorption in Reflectance Index
MSR	Modified Simple Ratio
DVI	Difference Vegetation Index
TCARI	Transformed Chlorophyll Absorption in Reflectance Index
VARI	Visible Atmospherically Resistant Index
VGI	Visible Green Index
MND	Modified Normalized Difference
CRI	Carotenoid Reflectance Index
GI	Green Index
RI	Red Index
MSAVI2	Modified Soil Adjusted Vegetation Index 2
GLCM	Gray-Level-Co-occurrence Matrix
OBIA	Object Based Image Analysis

Capítulo 7

Bibliografía

- [1] HERNÁNDEZ CORDERO, A. I.; PÉREZ-CHACÓN ESPINO, E.; HERNÁNDEZ CALVENTO, L. 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). *Tecnologías de la Información Geográfica para el Desarrollo Territorial. Servicio de Publicaciones y Difusión Científica de la ULPGC*, 2008, p. 603-617.
- [2] Red Canaria de Espacios Naturales Protegidos de Gran Canaria, «Gobierno de Canarias» [En línea]. Available: http://www.gobiernodecanarias.org. [Último acceso: Junio 2017].
- [3] HERNÁNDEZ-CORDERO, A. Análisis de la vegetación como indicadora de las alteraciones ambientales inducidas por la actividad turística en la Reserva Natural Especial de las Dunas de Maspalomas. 2012.
- [4] HERNÁNDEZ-CORDERO, Antonio I.; HERNÁNDEZ-CALVENTO, Luis; ESPINO, Emma Pérez-Chacón. Vegetation changes as an indicator of impact from tourist development in an arid transgressive coastal dune field. Land Use Policy, 2017, vol. 64, p. 479-491.
- [5] HERNÁNDEZ-CORDERO, Antonio I.; PÉREZ-CHACÓN ESPINO, Emma; HERNÁNDEZ-CALVENTO, Luis. Vegetation, distance to the coast, and aeolian geomorphic processes and landforms in a transgressive arid coastal dune system. Physical Geography, 2015, vol. 36, no 1, p. 60-83.

- [6] PÉREZ-CHACÓN, E., et al. Maspalomas: claves científicas para el análisis de su problemática ambiental. Universidad de Las Palmas de Gran Canaria, 2007.
- [7] Aeroterra, «aeroterra» [En línea]. Available: http://aeroterra.com/p-DigitalGlobe.html. [Último acceso: Junio 2017]
- [8] CHUVIECO, Emilio. Fundamentals of Satellite Remote Sensing: An Environmental Approach. CRC press, 2016.
- [9] Imagen adaptada, «My NASA Data,» [En línea]. Available: https://mynasadata.larc.nasa.gov/images/EM_Spectrum3-new.jpg. [Último acceso: Mayo 2017].
- [10] LI, Xu; LI, Lixin; HE, Mingyi. A novel pansharpening algorithm for WorldView-2 satellite images. En International Conference on Industrial and Intelligent Information (ICIII 2012). 2012. p. 18-23.
- [11] STATHAKI, Tania. Image fusion: algorithms and applications. Academic Press, 2011.
- [12] KPALMA, Kidiyo; EL-MEZOUAR, Miloud Chikr; TALEB, Nasreddine. Recent Trends in Satellite Image Pan-sharpening techniques. En 1st International Conference on Electrical, Electronic and Computing Engineering. 2014..
- [13] AMRO, Israa, et al. A survey of classical methods and new trends in pansharpening of multispectral images. *EURASIP Journal on Advances in Signal Processing*, 2011, vol. 2011, no 1, p. 79.
- [14] ZHANG, Jixian. Multi-source remote sensing data fusion: status and trends. *International Journal of Image and Data Fusion*, 2010, vol. 1, no 1, p. 5-24.
- [15] RODRÍGUEZ-ESPARRAGÓN, Dionisio. Evaluación y desarrollo de métricas de calidad espacial y espectral para aplicaciones de fusión de imágenes multiespectrales de teledetección de alta resolución. 2016.
- [16] VIVONE, Gemine, et al. A critical comparison among pansharpening algorithms. IEEE Transactions on Geoscience and Remote Sensing, 2015, vol. 53, no 5, p. 2565-2586.
- [17] EHLERS, Manfred, et al. Multi-sensor image fusion for pansharpening in remote sensing. International Journal of Image and Data Fusion, 2010, vol. 1, no 1, p. 25-45.
- [18] HALLADA, Wayne A.; COX, Scott. Image sharpening for mixed spatial and spectral resolution satellite systems. 1983.
- [19] CHAVEZ, Pats, et al. Comparison of three different methods to merge multiresolution and multispectral data- Landsat TM and SPOT panchromatic. *Photogrammetric Engineering and remote sensing*, 1991, vol. 57, no 3, p. 295-303.

- [20] POHL, Christine; TOURON, Hervé. Issues and challenges of operational applications using multisensor image fusion. En *Fusion of earth data. International conference*. 2000. p. 25-31.
- [21] LABEN, Craig A.; BROWER, Bernard V. Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening. U.S. Patent No 6,011,875, 4 Ene. 2000.
- [22] PALUBINSKAS, Gintautas. Fast, simple, and good pan-sharpening method. *Journal of Applied Remote Sensing*, 2013, vol. 7, no 1, p. 073526-073526.
- [23] BURT, Peter; ADELSON, Edward. The Laplacian pyramid as a compact image code. *IEEE Transactions on communications*, 1983, vol. 31, no 4, p. 532-540.
- [24] ZHOU, J.; CIVCO, D. L.; SILANDER, J. A. A wavelet transform method to merge Landsat TM and SPOT panchromatic data. *International Journal of Remote Sensing*, 1998, vol. 19, no 4, p. 743-757.
- [25] MALLAT, Stephane G. A theory for multiresolution signal decomposition: the wavelet representation. IEEE transactions on pattern analysis and machine intelligence, 1989, vol. 11, no 7, p. 674-693.
- [26] SHENSA, Mark J. The discrete wavelet transform: wedding the a trous and Mallat algorithms. *IEEE Transactions on signal processing*, 1992, vol. 40, no 10, p. 2464-2482.
- [27] DUTILLEUX, Pierre. An implementation of the "algorithme à trous" to compute the wavelet transform. En *Wavelets*. Springer Berlin Heidelberg, 1989. p. 298-304.
- [28] CANDES, Emmanuel J.; DONOHO, David L. *Curvelets: A surprisingly effective nonadaptive representation for objects with edges.* Stanford Univ Ca Dept of Statistics, 2000.
- [29] CANDÈS, Emmanuel J.; DONOHO, David L. Ridgelets: A key to higher-dimensional intermittency?. Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences, 1999, vol. 357, no 1760, p. 2495-2509.
- [30] DO, Minh N.; VETTERLI, Martin. The contourlet transform: an efficient directional multiresolution image representation. IEEE Transactions on image processing, 2005, vol. 14, no 12, p. 2091-2106.
- [31] GONZÁLEZ-AUDÍCANA, M., et al. Comparison between Mallat's and the 'à trous' discrete wavelet transform based algorithms for the fusion of multispectral and panchromatic images. International Journal of Remote Sensing, 2005, vol. 26, no 3, p. 595-614.
- [32] GONZALO-MARTÍN, C.; LILLO-SAAVEDRA, M. Fusión de Imágenes QuickBird Mediante una Representación Conjunta Multirresolución-Multidireccional.
- [33] GONZÁLEZ-AUDÍCANA, M., et al. Bondad de los algoritmos de descomposición wavelet de Mallat y 'À trous' para la fusión de imágenes Quickbird. Revista de Teledetección, 2004, vol. 21, p. 79-84.

- [34] NUNEZ, Jorge, et al. Multiresolution-based image fusion with additive wavelet decomposition. IEEE Transactions on Geoscience and Remote sensing, 1999, vol. 37, no 3, p. 1204-1211.
- [35] LILLO-SAAVEDRA, Mario; GONZALO, Consuelo; LAGOS, Octavio. Toward reduction of artifacts in fused images. International Journal of Applied Earth Observation and Geoinformation, 2011, vol. 13, no 3, p. 368-375.
- [36] GILLESPIE, Alan R.; KAHLE, Anne B.; WALKER, Richard E. Color enhancement of highly correlated images. II. Channel ratio and "chromaticity" transformation techniques. Remote Sensing of Environment, 1987, vol. 22, no 3, p. 343-365.
- [37] CARPER, W. Joseph. The use of intensity-hue-saturation transformations for merging SPOT panchromatic and multispectral image data. *Photogramm. Eng. Remote Sens.*, 1990, vol. 56, no 4, p. 457-467.
- [38] TU, Te-Ming, et al. A fast intensity-hue-saturation fusion technique with spectral adjustment for IKONOS imagery. IEEE Geoscience and Remote sensing letters, 2004, vol. 1, no 4, p. 309-312.
- [39] GONZÁLEZ-AUDÍCANA, María, et al. A low computational-cost method to fuse IKONOS images using the spectral response function of its sensors. *IEEE Transactions on Geoscience* and Remote Sensing, 2006, vol. 44, no 6, p. 1683-1691.
- [40] JOLLIFFE, Ian. Principal component analysis. John Wiley & Sons, Ltd, 2002.
- [41] KWARTENG, P. S.; CHAVEZ, A. Y. Extracting spectral contrast in Landsat Thematic Mapper image data using selective principal component analysis. Photogramm. Eng. Remote Sens, 1989, vol. 55, p. 339-348.
- [42] SHETTIGARA, V. K. A generalized component substitution technique for spatial enhancement of multispectral images using a higher resolution data set. Photogrammetric Engineering and remote sensing, 1992, vol. 58, no 5, p. 561-567.
- [43] COHEN, Albert; DAUBECHIES, Ingrid; FEAUVEAU, J.-C. Biorthogonal bases of compactly supported wavelets. Communications on pure and applied mathematics, 1992, vol. 45, no 5, p. 485-560.
- [44] HOLSCHNEIDER, Matthias, et al. The algorithm àtrous, CPT-88/P2115, 1988.
- [45] GONZÁLEZ-AUDÍCANA, M.; GARCÍA, R.; SECO, A. Fusión de imágenes multiespectrales y pancromáti-cas: nuevas alternativas metodológicas basadas en las transformaciones wavelet discretas empleando el algoritmo de Mallat. Revista de Teledetección, 2002, vol. 18, p. 63-73.
- [46] ZHANG, Yun. Methods for image fusion quality assessment-a review, comparison and analysis. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2008, vol. 37, no PART B7, p. 1101-1109.

- [47] YEN, K.; YEN, Eugene K.; JOHNSTON, Roger G. The ineffectiveness of the correlation coefficient for image comparisons. 1996.
- [48] WALD, Lucien. Quality of high resolution synthesised images: Is there a simple criterion?. En Third conference" Fusion of Earth data: merging point measurements, raster maps and remotely sensed images". SEE/URISCA, 2000. p. 99-103.
- [49] MUNECHIKA, Curtis K., et al. Resolution enhancement of multispectral image data to improve classification accuracy. Photogrammetric Engineering and Remote Sensing, 1993, vol. 59, no 1, p. 67-72.
- [50] WANG, Zhou, et al. Image quality assessment: from error visibility to structural similarity. IEEE transactions on image processing, 2004, vol. 13, no 4, p. 600-612.
- [51] WANG, Zhou, et al. A universal image quality index. IEEE Signal Processing Letters, 2002, vol. 9, no 3, p. 81-84.
- [52] DigitalGlobe. Radiometric use of Worldview2 Imagery. Revision 1.0, 2010.
- [53] MUHAMMAD, Iqbal. An introduction to solar radiation. Academic, Vancouver, 1983.
- [54] REDA, Ibrahim; ANDREAS, Afshin. Solar position algorithm for solar radiation applications. Solar energy, 2004, vol. 76, no 5, p. 577-589.
- [55] QI CHEN. Assessment of Vegetation Response to Ungulate Removal Utilizing High Resolution Remotely Sensed Data. University of Hawaii at Manoa.
- [56] CHUVIECO, Emilio. Teledetección Ambiental: la observación de la tierra desde el espacio. España: Barcelona. Ariel, 2002.
- [57] SCHOWENGERDT, Robert A. *Remote sensing: models and methods for image processing.* Academic press, 2006.
- [58] U. Navy, «Departamento de física y astronomía de la Universidad de Mississippi» [En línea]. Available: http://www.navy.mil/. [Último acceso: Mayo 2017].
- [59] CHAVEZ, Pat S. Image-based atmospheric corrections-revisited and improved. Photogrammetric engineering and remote sensing, 1996, vol. 62, no 9, p. 1025-1035.
- [60] MAHINY, Abdolrassoul S.; TURNER, Brian J. A comparison of four common atmospheric correction methods. Photogrammetric Engineering & Remote Sensing, 2007, vol. 73, no 4, p. 361-368.
- [61] BERNSTEIN, Lawrence S., et al. A new method for atmospheric correction and aerosol optical property retrieval for VIS-SWIR multi-and hyperspectral imaging sensors: QUAC (QUick Atmospheric Correction). SPECTRAL SCIENCES INC BURLINGTON MA, 2005.

- [62] GRUNINGER, John H.; RATKOWSKI, Anthony J.; HOKE, Michael L. The sequential maximum angle convex cone (SMACC) endmember model. En Defense and Security. International Society for Optics and Photonics, 2004. p. 1-14.
- [63] KARPOUZLI, E.; MALTHUS, T. The empirical line method for the atmospheric correction of IKONOS imagery. International Journal of Remote Sensing, 2003, vol. 24, no 5, p. 1143-1150.
- [64] ADLER-GOLDEN, Steven M., et al. Atmospheric correction for shortwave spectral imagery based on MODTRAN4. En SPIE's International Symposium on Optical Science, Engineering, and Instrumentation. International Society for Optics and Photonics, 1999. p. 61-69.
- [65] COOLEY, T., et al. FLAASH, a MODTRAN4-based atmospheric correction algorithm, its application and validation. En Geoscience and Remote Sensing Symposium, 2002. IGARSS'02. 2002 IEEE International. IEEE, 2002. p. 1414-1418.
- [66] RICHTER, Rudolf; SCHLÄPFER, D. Atmospheric/topographic correction for satellite imagery. DLR report DLR-IB, 2005, p. 565-01.
- [67] VERMOTE, E., et al. Second simulation of a satellite signal in the solar spectrum-vector (6SV).6S User Guide Version, 2006, vol. 3, p. 1-55.
- [68] BERNSTEIN, Lawrence S., et al. Quick atmospheric correction code: algorithm description and recent upgrades. Optical engineering, 2012, vol. 51, no 11, p. 111719-1-111719-11.
- [69] DE REDES NEURONALES, Grupo; GRNPS, Procesamiento de Señal. Algoritmos de extracción de endmembers en imágenes hiperespectrales. Revista de teledetección, 2004, vol. 21, p. 101-105.
- [70] VERMOTE, E. F.; VERMEULEN, A. Atmospheric correction algorithm: spectral reflectances (MOD09). ATBD version, 1999, vol. 4.
- [71] CARR, Stephen B. The aerosol models in MODTRAN: incorporating selected measurements from northern Australia. DEFENCE SCIENCE AND TECHNOLOGY ORGANISATION EDINBURGH (AUSTRALIA) INTELLIGENCE SURVEILLANCE AND RECONNAISSANCE DIV, 2005.
- [72] SHETTLE, Eric P.; FENN, Robert W. Models for the aerosols of the lower atmosphere and the effects of humidity variations on their optical properties. AIR FORCE GEOPHYSICS LAB HANSCOM AFB MA, 1979.
- [73] PERKINS, Timothy, et al. Speed and accuracy improvements in FLAASH atmospheric correction of hyperspectral imagery. Optical Engineering, 2012, vol. 51, no 11, p. 111707-1-111707-7.
- [74] KAUFMAN, Y. J., et al. The MODIS 2.1 μm channel-correlation with visible reflectance for use in remote sensing of aerosol, IEEE T. Geosci. Remote., 35, 1286–1298. 1997.
- [75] RICHTER, R. ATCOR for ERDAS IMAGINE-Atmospheric and Topographic Correction ATCOR2 and ATCOR3 (Ver. 2.0) User Manual. Geosystems, Germering, 2002.
- [76] Science Compunting Facility, «6s.ltdri» [En línea]. Available: http://6s.ltdri.org/.
- [77] KOTCHENOVA, Svetlana Y., et al. Validation of a vector version of the 6S radiative transfer code for atmospheric correction of satellite data. Part I: Path radiance. Applied optics, 2006, vol. 45, no 26, p. 6762-6774.
- [78] MARTIN, J., et al. Atmospheric correction models for high resolution WorldView-2 multispectral imagery: a case study in Canary Islands, Spain. En SPIE Remote Sensing. International Society for Optics and Photonics, 2012. p. 853400-853400-10.
- [79] Gobierno de Canarias, «Infraestructura de Datos Espaciales de Canarias» [En línea]. Available: https://www.idecanarias.es. [Último acceso: Mayo 2017].
- [80] KHANDELWAL, Ankush; RAJAN, K. S. Sensor Simulation based Hyperspectral Image Enhancement with Minimal Spectral Distortion. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2014, vol. 2, no 8, p. 179.
- [81] AERONET, «Aerosol Optical Depth» [En línea]. Available: http://aeronet.gsfc.nasa.gov/new_web/aerosols.html. [Último acceso: Mayo 2017].
- [82] «Giovanni» [En línea]. Available: http://disc.sci.gsfc.nasa.gov/giovanni. [Último acceso: Mayo 2017].
- [83] «Google Earth» [En línea]. Available: https://www.google.es/intl/es/earth/index.html. [Último acceso: Mayo 2017].
- [84] JIMÉNEZ, M.; POU, A.; DÍAZ-DELGADO, R. Cartografía de especies de matorral de la Reserva Biológica de Doñana mediante el sistema hiperespacial aeroportado INTA-AHS. Implicaciones en el estudio y segimiento del matorral de Doñana. *Revista de Teledetección*, 2011, vol. 36, p. 98-102.
- [85] INTA Área de Teledetección, «Campaña de radiometría de campo ARTEMISAT» 2015.
- [86] MACQUEEN, James, et al. Some methods for classification and analysis of multivariate observations. En Proceedings of the fifth Berkeley symposium on mathematical statistics and probability. 1967. p. 281-297.
- [87] BALL, Geoffrey H.; HALL, David J. ISODATA, a novel method of data analysis and pattern classification. Stanford research inst Menlo Park CA, 1965.
- [88] BEZDEK, James C.; EHRLICH, Robert; FULL, William. FCM: The fuzzy c-means clustering algorithm. Computers & Geosciences, 1984, vol. 10, no 2-3, p. 191-203.

- [89] HEINZ, Daniel C., et al. Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery. IEEE transactions on geoscience and remote sensing, 2001, vol. 39, no 3, p. 529-545.
- [90] BIOUCAS-DIAS, José M., et al. Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, vol. 5, no 2, p. 354-379.
- [91] GONZÁLEZ CALVO, Carlos. Procesamiento a bordo de imágenes hiperespectrales de la superficie terrestre mediante hardware reconfigurable. 2012. Tesis Doctoral. Universidad Complutense de Madrid.
- [92] MORÉ, Jorge J. The Levenberg-Marquardt algorithm: implementation and theory. En Numerical analysis. Springer Berlin Heidelberg, 1978. p. 105-116.
- [93] WASKE, Björn; BENEDIKTSSON, Jón Atli. Pattern recognition and classification. En Encyclopedia of Remote Sensing. Springer New York, 2014. p. 503-509.
- [94] FUKUNAGA, Keinosuke. Introduction to statistical pattern recognition. Academic press, 2013.
- [95] ZHONG, Yanfei; ZHU, Qiqi; ZHANG, Liangpei. Scene classification based on the multifeature fusion probabilistic topic model for high spatial resolution remote sensing imagery. IEEE Transactions on Geoscience and Remote Sensing, 2015, vol. 53, no 11, p. 6207-6222.
- [96] BÖHNING, Dankmar. Multinomial logistic regression algorithm. Annals of the Institute of Statistical Mathematics, 1992, vol. 44, no 1, p. 197-200.
- [97] LI, Jun; BIOUCAS-DIAS, José M.; PLAZA, Antonio. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning. IEEE Transactions on Geoscience and Remote Sensing, 2010, vol. 48, no 11, p. 4085-4098.
- [98] ZHONG, Ping; ZHANG, Peng; WANG, Runsheng. Dynamic learning of SMLR for feature selection and classification of hyperspectral data. IEEE Geoscience and Remote Sensing Letters, 2008, vol. 5, no 2, p. 280-284.
- [99] LI, Jun; BIOUCAS-DIAS, José M.; PLAZA, Antonio. Spectral-spatial hyperspectral image segmentation using subspace multinomial logistic regression and Markov random fields. IEEE Transactions on Geoscience and Remote Sensing, 2012, vol. 50, no 3, p. 809-823.
- [100] ZHONG, Ping; WANG, Runsheng. Learning conditional random fields for classification of hyperspectral images. IEEE Transactions on Image Processing, 2010, vol. 19, no 7, p. 1890-1907.
- [101] ZHONG, Ping; WANG, Runsheng. Jointly learning the hybrid CRF and MLR model for simultaneous denoising and classification of hyperspectral imagery. IEEE Transactions on Neural Networks and Learning Systems, 2014, vol. 25, no 7, p. 1319-1334.

- [102] KHODADADZADEH, Mahdi, et al. Spectral-spatial classification of hyperspectral data using local and global probabilities for mixed pixel characterization. IEEE Transactions on Geoscience and Remote Sensing, 2014, vol. 52, no 10, p. 6298-6314.
- [103] LANDGREBE, David A. Signal theory methods in multispectral remote sensing. John Wiley & Sons, 2005.
- [104] ZHAO, Ji, et al. High-resolution image classification integrating spectral-spatial-location cues by conditional random fields. IEEE Transactions on Image Processing, 2016, vol. 25, no 9, p. 4033-4045.
- [105] VAPNIK, Vladimir Naumovich; VAPNIK, Vlamimir. Statistical learning theory. New York: Wiley, 1998.
- [106] VAPNIK, Vladimir. The nature of statistical learning theory. Springer science & business media, 2013.
- [107] BURGES, Christopher JC. A tutorial on support vector machines for pattern recognition. Data mining and knowledge discovery, 1998, vol. 2, no 2, p. 121-167.
- [108] SMOLA, Alex J.; SCHÖLKOPF, Bernhard. Learning with kernels. GMD-Forschungszentrum Informationstechnik, 1998.
- [109] CHANG, Chih-Chung; LIN, Chih-Jen. LIBSVM: a library for support vector machines. ACM Transactions on Intelligent Systems and Technology (TIST), 2011, vol. 2, no 3, p. 27.
- [110] YANG, Xiaojun. Parameterizing support vector machines for land cover classification. Photogrammetric Engineering & Remote Sensing, 2011, vol. 77, no 1, p. 27-37.
- [111] KAVZOGLU, Taskin; COLKESEN, I. A kernel functions analysis for support vector machines for land cover classification. International Journal of Applied Earth Observation and Geoinformation, 2009, vol. 11, no 5, p. 352-359.
- [112] DIXIT, Ankur; AGARWAL, Shefali. Comparison of various models and optimum range of its parameters used in SVM classification of digital satellite image. En Image Information Processing (ICIIP), 2013 IEEE Second International Conference on. IEEE, 2013. p. 363-368.
- [113] MATHER, Paul; TSO, Brandt. Classification methods for remotely sensed data. Boca Raton: CRC press, 2009.
- [114] CASTRO, Roberto, et al. Estudio de caso para la aplicación del "Sistema de seguimiento y análisis de tierras mediante teledetección"(TeleSat). Análisis de cambios de coberturas vegetacionales y determinación del índice de protección del suelo en Laguna Blanca-San Gregorio, Región de Magallanes, Chile, 1999.
- [115] OMER, Galal, et al. Empirical prediction of Leaf Area Index (LAI) of endangered tree species in intact and fragmented indigenous forests ecosystems using WorldView-2 data and two robust machine learning algorithms. Remote Sensing, 2016, vol. 8, no 4, p. 324.

- [116] ROUSE JR, J_W, et al. Monitoring vegetation systems in the Great Plains with ERTS. 1974.
- [117] KAUFMAN, Yoram J.; TANRE, Didier. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. IEEE transactions on Geoscience and Remote Sensing, 1992, vol. 30, no 2, p. 261-270.
- [118] HUETE, Alfredo, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. Remote sensing of environment, 2002, vol. 83, no 1, p. 195-213.
- [119] QI, Jiaguo, et al. A modified soil adjusted vegetation index. Remote sensing of environment, 1994, vol. 48, no 2, p. 119-126.
- [120] HARALICK, Robert M., et al. Textural features for image classification. IEEE Transactions on systems, man, and cybernetics, 1973, vol. 3, no 6, p. 610-621.
- [121] ANYS, H., et al. Texture analysis for the mapping of urban areas using airborne MEIS-II images. En Proceedings of the first international airborne remote sensing conference and exhibition. Environmental Research Institute of Michigan, 1994. p. 231-245.
- [122] PUISSANT, Anne; HIRSCH, Jacky; WEBER, Christiane. The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery. International Journal of Remote Sensing, 2005, vol. 26, no 4, p. 733-745.
- [123] CANTY, Morton J. Image analysis, classification and change detection in remote sensing: with algorithms for ENVI/IDL and Python. Crc Press, 2014.
- [124] HUGHES, Gordon. On the mean accuracy of statistical pattern recognizers. IEEE transactions on information theory, 1968, vol. 14, no 1, p. 55-63.
- [125] JACQUEMOUD, Stéphane, et al. PROSPECT+ SAIL models: A review of use for vegetation characterization. Remote sensing of environment, 2009, vol. 113, p. S56-S66.