

**METODOLOGÍA BASADA EN TELEDETECCIÓN,  
SIG Y GEOESTADÍSTICA PARA CARTOGRAFÍA Y  
ANÁLISIS DE CAMBIOS EN LAS CUBIERTAS DEL  
SUELO DE LA PROVINCIA DE GRANADA**



**TESIS DOCTORAL**

**VÍCTOR F. RODRÍGUEZ GALIANO**

DEPARTAMENTO DE GEODINÁMICA

UNIVERSIDAD DE GRANADA  
JULIO 2011

Editor: Editorial de la Universidad de Granada  
Autor: Víctor F. Rodríguez Galiano  
D.L.: GR 969-2012  
ISBN: 978-84-695-1161-9



D. Mario Chica Olmo, y D. Juan Pedro Rigol Sánchez, Catedrático y Profesor Titular, del Departamento de Geodinámica de la Universidad de Granada y del Departamento de Geología de la Universidad de Jaén, respectivamente,

**CERTIFICAN:**

Que el trabajo de investigación que se presenta en esta Memoria, titulado:

**METODOLOGÍA BASADA EN TELEDETECCIÓN, SIG Y GEOESTADÍSTICA PARA  
CARTOGRAFÍA Y ANÁLISIS DE CAMBIOS EN LAS CUBIERTAS DEL SUELO DE  
LA PROVINCIA DE GRANADA**

ha sido realizado en el Departamento de Geodinámica de la Universidad de Granada, bajo nuestra dirección, por el Licenciado D. Víctor F. Rodríguez Galiano, y constituye su Tesis Doctoral.

Con esta fecha autorizamos su presentación ante la Comisión de Doctorado de la Universidad de Granada.

Granada, 5 de Julio de 2011.

Fdo.: Mario Chica Olmo.

Fdo.: Juan Pedro Rigol Sánchez.

El doctorando.

Fdo.: Víctor F. Rodríguez Galiano.



# ÍNDICE GENERAL

<b>ABSTRACT.....</b>	<b>1</b>
1. CHAPTER 1. INTRODUCTION.....	1
1.1 Objectives.....	6
1.2 How the dissertation summary is organized.....	7
2. CHAPTER 2. STUDY AREA AND DATA .....	9
3. CHAPTER 3. MACHINE LEARNING METHODS FOR DIGITAL CLASSIFICATION .....	12
4. CHAPTER 4. IMAGE FUSION METHODS.....	14
5. CHAPTER 5. INCORPORATING THE DOWNSCALED LANDSAT TM THERMAL INFORMATION IN LAND COVER CLASSIFICATION .....	16
6. CHAPTER 6. INCORPORATING SPATIAL VARIABILITY MEASURES IN LAND COVER CLASSIFICATION .....	19
7. CHAPTER 7. LAND COVER CLASSIFICATION AND CHANGE ANALYSIS OF THE GRANADA PROVINCE .....	20
8. CONCLUSIONS .....	21
<b>CAPÍTULO 1: INTRODUCCIÓN GENERAL.....</b>	<b>24</b>
1 INTRODUCCIÓN GENERAL.....	24
1 ANTECEDENTES .....	29
2 OBJETIVOS.....	33
3 ORGANIZACIÓN DE LA MEMORIA.....	34
<b>CAPÍTULO 2: ÁREA DE ESTUDIO Y DATOS.....</b>	<b>37</b>
1 ÁREA DE ESTUDIO .....	37
1.1 Localización geográfica y fisiografía.....	37
1.2 Geología y litología.....	40
1.3 Edafología.....	45
1.4 Climatología.....	48
1.5 Usos del suelo.....	53
1.6 Marco socioeconómico .....	56
2 DATOS.....	59
2.1 Fundamentos del procesamiento de imágenes.....	61
2.1.1 Correcciones geométricas .....	61
2.1.2 Correcciones radiométricas.....	62
3.1.1.1 Métodos absolutos .....	65
3.1.1.2 Métodos relativos.....	66
2.2 Metodologías de corrección.....	69
2.2.1 Corrección atmosférica absoluta.....	69

**CAPÍTULO 3: MÉTODOS DE INTELIGENCIA ARTIFICIAL PARA CLASIFICACIÓN DIGITAL. .... 80**

1 INTRODUCCIÓN.....80

2 FUNDAMENTOS DE LOS MÉTODOS DE EVALUACIÓN DE LA EXACTITUD CARTOGRÁFICA .....82

3 FUNDAMENTOS DE LOS MÉTODOS DE CLASIFICACIÓN BASADOS EN APRENDIZAJE DE MÁQUINAS 84

    3.1 *Clasificadores en árbol* .....85

        3.1.1 Árboles de decisión.....85

        3.1.2 Random Forest.....87

    3.2 *Redes neuronales* .....91

    3.3 *Máquinas de vectores soporte* .....97

4 APLICACIÓN METODOLÓGICA DE LOS ALGORITMOS DE CLASIFICACIÓN ..... 102

    4.1 *Clasificadores en árbol* .....103

        4.1.1 Árboles de decision.....103

        4.1.2 Random Forest.....103

    4.2 *Redes neuronales* .....104

    4.3 *Máquinas de vectores soporte* .....105

5 RESULTADOS DE LAS CLASIFICACIONES .....106

    5.1 *Parametrización de los algoritmos*.....106

        5.1.1 Clasificadores en árbol.....107

            5.1.1.1 Árboles de decisión .....107

            5.1.1.2 Random Forest .....108

        Medida de la importancia relativa de las variables predictoras mediante RF.....111

        Medida de outliers .....113

        5.1.2 Redes neuronales.....114

        5.1.3 Máquinas de vectores soporte .....117

    5.2 *Evaluación de la exactitud cartográfica* .....122

        5.2.1 Comparación de Random Forest con Árboles de Decisión .....127

    5.3 *Análisis de la significatividad de las diferencias en exactitud entre algoritmos*.....130

    5.4 *Sensibilidad al ruido de los clasificadores* .....131

    5.5 *Efecto de la reducción de áreas de entrenamiento en los clasificadores* 134

6 CONCLUSIONES.....136

**CAPÍTULO 4: MÉTODOS DE FUSIÓN DE IMÁGENES DE SATÉLITE. .... 138**

1 INTRODUCCIÓN.....138

2 FUNDAMENTOS DE LOS MÉTODOS DE FUSIÓN DE IMÁGENES.....141

    2.1 *Método WAT* .....141

    2.2 *Método MDMR*.....143

    2.3 *Método DCK* .....144

    2.4 *Método LICOR* .....146

3 PARÁMETROS E ÍNDICES PARA EVALUAR LA CALIDAD DE LAS IMÁGENES FUSIONADAS .....148

4 RESULTADOS DE LAS FUSIONES.....151

    4.1 *Parametrización de los algoritmos de fusión* .....152

        4.1.1 WAT .....152

4.1.2	MDMR .....	152
4.1.3	DCK .....	153
4.1.4	L1COR .....	156
4.2	<i>Evaluación de la calidad de las imágenes fusionadas</i> .....	157
4.2.1	Evaluación cualitativa .....	157
4.2.2	Evaluación cuantitativa directa .....	160
4.2.3	Evaluación cuantitativa indirecta .....	164
5	CONCLUSIONES .....	167
<b>CAPÍTULO 5: MEJORA DE LA RESOLUCIÓN ESPACIAL DE LA INFORMACIÓN TÉRMICA PARA LA OBTENCIÓN DE MAPAS DE TEMPERATURA. ....</b>		<b>169</b>
1	INTRODUCCIÓN.....	169
2	FUNDAMENTOS .....	172
2.1	<i>Fundamentos del aumento de resolución de la banda térmica TIR</i> .....	172
2.2	<i>Fundamentos del cálculo de la Temperatura de Superficie (LST)</i> .....	177
3	ÁREA DE ESTUDIO Y DATOS.....	180
4	METODOLOGÍA.....	180
5	RESULTADOS Y DISCUSIÓN .....	182
5.1	<i>Downscaling de la información TIR</i> .....	182
5.2	<i>Obtención de la imagen LST de alta resolución</i> .....	187
6	CONCLUSIONES .....	191
<b>CAPÍTULO 6: APLICACIÓN DE MEDIDAS TEXTURALES A LA CLASIFICACIÓN DE IMÁGENES DE SATÉLITE.....</b>		<b>193</b>
1	INTRODUCCIÓN .....	193
2	FUNDAMENTOS .....	196
2.1	<i>Fundamentos de la textura geoestadística</i> .....	196
2.2	<i>Fundamentos de las matrices de co-ocurrencia</i> .....	198
2.3	<i>Fundamentos de la selección de características</i> .....	199
2	METODOLOGÍA.....	200
2.1	<i>Análisis textural</i> .....	200
2.1.1	Cálculo de las medidas derivadas del variograma .....	201
2.1.2	Cálculo de las medidas GLCM.....	203
3	RESULTADOS Y DISCUSIÓN .....	206
3.1	<i>Clasificación de las medidas texturales con RF</i> .....	206
3.2	<i>Comparación entre las medidas derivadas del variograma y las GLCM</i> .....	207
3.3	<i>Importancia de las medidas texturales</i> .....	212
2.1.3	Análisis de las 10 medidas texturales más importantes .....	214
3.4	<i>Selección de las características texturales geoestadísticas más importantes</i> .....	217
4	CONCLUSIONES .....	220
<b>CAPÍTULO 7: ANÁLISIS DE CAMBIOS EN LA PROVINCIA DE GRANADA ENTRE 1998 Y 2004. ....</b>		<b>222</b>
1	INTRODUCCIÓN .....	222



2	FUNDAMENTOS DE LOS MÉTODOS DE DETECCIÓN Y ANÁLISIS DE CAMBIOS.....	224
2.1	<i>Técnicas de realce de cambios pre-clasificación</i> .....	226
2.1.1	Diferencia entre imágenes .....	226
2.1.2	Cocientes multi-temporales.....	226
2.1.3	Regresión de imágenes .....	227
2.1.4	Vectores multitemporales .....	228
2.1.5	Componentes principales .....	229
2.1.6	Transformación Kauth Thomas multi-temporal.....	230
2.2	<i>Análisis Compuesto</i> .....	230
2.3	<i>Técnicas post-clasificación.</i> .....	231
3	METODOLOGÍA.....	232
4	RESULTADOS .....	234
4.1	<i>Generación de los mapas clasificados de 1998 y 2004</i> .....	234
4.1.1	Importancia de las variables en los modelos de clasificación .....	239
4.2	<i>Análisis de cambios entre 1998 y 2004</i> .....	242
5	CONCLUSIONES.....	245
	<b>CAPÍTULO 8: CONCLUSIONES GENERALES. ....</b>	<b>247</b>
	<b>REFERENCIAS.....</b>	<b>253</b>

# ÍNDICE DE FIGURAS

FIGURA 2.1. COMARCAS AGRARIAS DE GRANADA Y PRINCIPALES NÚCLEOS DE POBLACIÓN.....	38
FIGURA 2.2. DISTRIBUCIÓN DE ALTURAS DE LA PROVINCIA DE GRANADA. FUENTE: MAPA DIGITAL DE ANDALUCÍA (1999), CONSEJERÍA DE OBRAS PÚBLICAS Y TRANSPORTES. JUNTA DE ANDALUCÍA, SEVILLA.....	39
FIGURA 2.3. MAPA DE PENDIENTES DE LA PROVINCIA DE GRANADA.....	40
FIGURA 2.4. PRINCIPALES UNIDADES GEOLÓGICAS DE LA PROVINCIA DE GRANADA.....	44
FIGURA 2.5. LITOLOGÍA DE LA PROVINCIA DE GRANADA. MODIFICADO: MAPA GEOLÓGICO DE ANDALUCÍA. ....	44
FIGURA 2.6. MAPA DE SUELOS DE GRANADA. MODIFICADO DE: MAPA DE SUELOS DE ANDALUCÍA (1989), IARA-CSIC .....	45
FIGURA 2.7. MAPA DE LA TEMPERATURA MEDIA ANUAL. FUENTE: ATLAS CLIMÁTICO DE ESPAÑA (1983), INSTITUTO DE METEOROLOGÍA, MADRID.....	48
FIGURA 2.8. MAPAS DE LA TEMPERATURA MEDIA DE ENERO Y JULIO. FUENTE: ATLAS CLIMÁTICO DE ESPAÑA (1983), INSTITUTO DE METEOROLOGÍA, MADRID. ....	49
FIGURA 2.9. MAPA DE PRECIPITACIÓN DE LA PROVINCIA DE GRANADA. FUENTE: ATLAS CLIMÁTICO DE ESPAÑA (1983), INSTITUTO DE METEOROLOGÍA, MADRID .....	49
FIGURA 2.10. MAPAS DE PRECIPITACIÓN DE JULIO Y ENERO DE LA PROVINCIA DE GRANADA. FUENTE: ATLAS CLIMÁTICO DE ESPAÑA (1983). INSTITUTO DE METEOROLOGÍA. MADRID. ....	50
FIGURA 2.11. PRINCIPALES DOMINIOS CLIMÁTICOS DE LA PROVINCIA DE GRANADA. FUENTE: GRAN ATLAS DE ESPAÑA (1989), PLANETA, BARCELONA. ....	51
FIGURA 2.12. MAPA DE USOS DEL SUELO DE LA PROVINCIA DE GRANADA. FUENTE: MODIFICADO DE “MAPA DE USOS Y COBERTURAS VEGETALES DEL SUELO DE ANDALUCÍA. ESCALA 1:10.000” ..	54
FIGURA 2.13. MAPA DE LA DENSIDAD DE POBLACIÓN DE GRANADA EN EL AÑO 2011 POR MUNICIPIOS. ....	56
FIGURA 2.14. MAPA DEL INCREMENTO DE LA POBLACIÓN DE GRANADA EN LOS AÑOS 2004 A 1998 POR MUNICIPIOS (Nº DE HABITANTES). ....	57
FIGURA 2.15. MAPA DEL INCREMENTO DE LA SUPERFICIE DE LAS PARCELAS EDIFICADAS (HA).....	58
FIGURA 2.16. MAPA DEL PORCENTAJE DE SUPERFICIE AGRÍCOLA DE LA PROVINCIA DE GRANADA. ....	59
FIGURA 2.17. MODELO HYSPLIT. RETROTRAYECTORIAS PARA LAS CONDICIONES DE ADQUISICIÓN DE LAS IMÁGENES DEL 12-04-1998, 17-07-1998, 12-04-2004 Y 18-08-2004 .....	76
FIGURA 2.18. ÍNDICE DE AEROSOL DIARIO MEDIDO POR EL <i>EARTH PROBE</i> TOMS PARA LAS FECHAS 12-04-1998, 17-07-1998, 12-04-2004 Y 18-08-2004 .....	79
FIGURA 3.1. ESQUEMA CONCEPTUAL DE UN ÁRBOL DE DECISIÓN.....	86
FIGURA 3.2. ESQUEMA DE LA METODOLOGÍA DE CLASIFICACIÓN BASADA EN RF. ....	90
FIGURA 3.3. ESQUEMA DE LA METODOLOGÍA DE CLASIFICACIÓN BASADA EN RNA .....	94
FIGURA 3.4. ESQUEMA DE LA METODOLOGÍA DE CLASIFICACIÓN BASADA EN MVS.....	102
FIGURA 3.5. A. EFECTO DE LA PROFUNDIDAD DE LOS ÁRBOLES Y NÚMERO DE OBSERVACIONES MÍNIMAS EN LOS NODOS (N) EN EL ERROR DEL TEST INDEPENDIENTE. B. EFECTO DEL NÚMERO DE OBSERVACIONES MÍNIMAS EN LOS NODOS. ....	108

FIGURA 3.6. EFECTO DEL NÚMERO DE ÁRBOLES ( $\kappa$ ) Y VARIABLES ALEATORIAS ( $M$ ) EN EL ERROR OOB Y DEL TEST INDEPENDIENTE. ....	109
FIGURA 3.7. RESULTADOS DEL ÍNDICE KAPPA EN RELACIÓN CON EL NÚMERO DE ÁRBOLES ( $\kappa$ ) Y EL NÚMERO DE VARIABLES ALEATORIAS ( $M$ ). ....	110
FIGURA 3.8. IMPORTANCIA RELATIVA DE LAS VARIABLES EN LA CLASIFICACIÓN DEL ÁREA DE ESTUDIO EN FUNCIÓN DEL ÍNDICE DE GINI (A) Y DEL DECREMENTO EN EXACTITUD DEL SUBCONJUNTO OOB (B). ....	112
FIGURA 3.9. ANÁLISIS OUTLIER DEL TOTAL DE LAS ÁREAS DE ENTRENAMIENTO UTILIZADAS EN LA CLASIFICACIÓN CON RANDOM FOREST. ....	114
FIGURA 3.10. EXACTITUD CARTOGRÁFICA (KAPPA) DE LAS RNAs EN FUNCIÓN DEL NÚMERO DE UNIDADES DE LA CAPA OCULTA. ....	115
FIGURA 3.11. EXACTITUD CARTOGRÁFICA (KAPPA) DE LAS RNAs EN FUNCIÓN DEL RANGO (A) Y DEL DECAIMIENTO DE PESOS (B). ....	116
FIGURA 3.12. EXACTITUD CARTOGRÁFICA (KAPPA) DE LOS MVS POLINOMIALES EN FUNCIÓN DEL GRADO DEL POLINOMIO. ....	118
FIGURA 3.13. EXACTITUD CARTOGRÁFICA (KAPPA) DE LOS MVS POLINOMIALES EN FUNCIÓN DEL COSTE. ....	119
FIGURA 3.14. EXACTITUD CARTOGRÁFICA EN FUNCIÓN DEL TIPO DE KERNEL Y EL COSTE (A) Y DEL TIPO DE KERNEL Y $\gamma$ (B). ....	122
FIGURA 3.15. MAPAS DE CAMBIO ENTRE LAS CLASIFICACIONES PRODUCIDAS A PARTIR DE LOS CLASIFICADORES RF Y AD. ....	129
FIGURA 3.16. COMPARACIÓN DE LAS CLASIFICACIONES EFECTUADAS POR AD Y RF, EN TÉRMINOS DE PORCENTAJE DE PÍXELES QUE CAMBIARON AL USAR RF. ....	129
FIGURA 3.17. EFECTO EN LA EXACTITUD CARTOGRÁFICA DE LA ADICIÓN DE RUIDO EN LOS DATOS DE ENTRENAMIENTO. ....	133
FIGURA 3.18. EFECTO EN LA EXACTITUD CARTOGRÁFICA DE LA REDUCCIÓN DE LOS DATOS DE ENTRENAMIENTO. ....	135
FIGURA 4.1. COMPOSICIÓN EN FALSO COLOR 432 (RGB) DE LA IMAGEN LANDSAT 7 ETM+ DEL ÁREA DE ESTUDIO (944 km <sup>2</sup> ). ....	141
FIGURA 4.2. ESQUEMA DE LA METODOLOGÍA SEGUIDA PARA LA EVALUACIÓN COMPARATIVA DE LOS ALGORITMOS DE FUSIÓN. ....	149
FIGURA 4.3. PLANOS ESPECTRAL Y ESPACIAL PARA EL NIVEL DE DEGRADACIÓN $k=2$ DEL MÉTODO MULTIDIRECCIÓN-MULTIRRESOLUCIÓN. ....	153
FIGURA 4.4. VARIOGRAMAS EXPERIMENTALES Y MODELOS INDUCIDOS DE LAS BANDAS DE LA IMAGEN MULTIESPECTRAL (AZUL, VERDE, ROJO E INFRARROJO PRÓXIMO) Y DE LA IMAGEN PANCRÓMATICA (DE IZQUIERDA A DERECHA Y DE ARRIBA ABAJO). ....	155
FIGURA 4.5. VARIOGRAMAS CRUZADOS EXPERIMENTALES Y MODELOS INDUCIDOS ENTRE LAS BANDAS DE LA IMAGEN MULTIESPECTRAL (AZUL, VERDE, ROJO E INFRARROJO PRÓXIMO) Y LA IMAGEN PANCRÓMATICA (DE IZQUIERDA A DERECHA Y DE ARRIBA ABAJO). ....	156
FIGURA 4.6. DETALLES EN COLOR REAL DE LA IMAGEN MULTIESPECTRAL ORIGINAL Y LAS IMÁGENES FUSIONADAS DE LOS SECTORES A Y B. SE MUESTRAN LAS SIGUIENTES IMÁGENES DE ARRIBA ABAJO Y DE IZQUIERDA A DERECHA: LA IMAGEN MULTIESPECTRAL DE REFERENCIA, LAS IMÁGENES FUSIONADAS POR L1COR, DCK, WAT Y MDMR, RESPECTIVAMENTE; ASÍ COMO LA IMAGEN MULTIESPECTRAL ORIGINAL REMUESTREADA. ....	159

FIGURA 4.7. VALORES PROMEDIO DEL ÍNDICE Q PARA LOS DIFERENTES TAMAÑOS DE VENTANAS MÓVILES USADAS. ....	162
FIGURA 4.8. MAPAS DERIVADOS DE LAS CLASIFICACIONES DE LA IMAGEN ORIGINAL Y DE LAS IMÁGENES FUSIONADAS POR L1COR, DCK, WAT Y MDMR (DE ARRIBA ABAJO Y DE IZQUIERDA A DERECHA).....	166
FIGURA 5.1. FUNCIÓN DE RESPUESTA ESPECTRAL DE LA BANDA TIR DE LANDSAT 5 Y 7. ....	179
FIGURA 5.2. ESQUEMA DE LA METODOLOGÍA SEGUIDA PARA LA OBTENCIÓN DE LAS IMÁGENES DE LST DE ALTA RESOLUCIÓN (AR). ....	182
FIGURA 5.3. VARIOGRAMAS DE LAS VARIABLES IMPLICADAS EN EL COKRIGEAJE DE LA BANDA TIR (ETM6). A: SEMIVARIOGRAMA DE LA IMAGEN TIR DE RESOLUCIÓN 60 M. B: SEMIVARIOGRAMA DE LA BANDA ETM7 DE RESOLUCIÓN 30M. C: SEMIVARIOGRAMA CRUZADO ENTRE LAS BANDAS TIR Y ETM7. D: SEMIVARIOGRAMAS OMNIDIRECCIONALES DE LA BANDA TIR DE RESOLUCIÓN 60 M Y LA BANDA TIR DE RESOLUCIÓN ESPACIAL MEJORADA (30 M).....	184
FIGURA 5.4. IMAGEN LST DE RESOLUCIÓN ESPACIAL IGUAL A 30 M. LOS COLORES CÁLIDOS Y FRÍOS REPRESENTAN LAS ÁREAS DE MAYOR Y MENOR TEMPERATURA, RESPECTIVAMENTE. ....	189
FIGURA 6.1. IMPORTANCIA DE LAS CARACTERÍSTICAS TEXTURALES CON RESPECTO A LA FUNCIÓN UTILIZADA Y EL TAMAÑO DE VENTANA. A. CONTRIBUCIÓN DE LOS PARÁMETROS TEXTURALES DEL MODELO MULTI-ESCALA. B. CONTRIBUCIÓN DE LOS PARÁMETROS TEXTURALES DE LOS MODELOS DE ESCALA SIMPLE. V, M, R, C, Y PC SE REFIEREN AL VARIOGRAMA, MADOGRAMA, RODOGRAMA VARIOGRAMA CRUZADO Y VARIOGRAMA PSEUDO-CRUZADO, RESPECTIVAMENTE. ....	213
FIGURA 6.2. MEDIDAS DE IMPORTANCIA RELATIVA BASADAS EN OOB (A) Y EL ÍNDICE DE GINI (B). LOS ACRÓNIMOS VER., PRI,, MS., VERD., Y HUM., SE REFIEREN A VERANO, PRIMAVERA, MULTI-ESCAIONAL, VERDOR Y HUMEDAD, RESPECTIVAMENTE. LOS NÚMEROS DETRÁS DE LOS ACRÓNIMOS SE REFIEREN A LAS BANDAS LANDSAT TM5 USADAS EN EL CÁLCULO DE LAS MEDIDAS TEXTURALES. ....	215
FIGURA6.3. MEDIDAS OOB DE IMPORTANCIA RELATIVA PARA LA CLASIFICACIÓN DE LAS CATEGORÍAS DEL ÁREA DE ESTUDIO. ....	216
FIGURA 6.4. EXACTITUD CARTOGRÁFICA DERIVADA DE LA SELECCIÓN DE CARACTERÍSTICAS LLEVADA A CABO EN BASE A LA REDUCCIÓN DE LAS VARIABLES MENOS IMPORTANTES ESTIMADAS POR LAS MEDIDAS OOB Y GINI. ....	219
FIGURA 7.1. MAPA CLASIFICADO CORRESPONDIENTE A 1998.....	235
FIGURA 7.2. MAPA CLASIFICADO CORRESPONDIENTE A 2004.....	235
FIGURA 7.3. MEDIDAS DE IMPORTANCIA DE LAS 10 VARIABLES MÁS SIGNIFICATIVAS PARA LA CLASIFICACIÓN DE 1998 (A Y B) Y DE 2004 (C Y D). VER: VERANO, PRI: PRIMAVERA, ME: MULTI-ESTACIONAL, M: MADOGRAMA Y PC: VARIOGRAMA PSEUDO-CRUZADO. ....	240
FIGURA 7.4. CAMBIOS NETOS EN LAS CUBIERTAS DEL SUELO ENTRE 1998 Y 2004.....	242
FIGURA 7.5. MAPA DE CAMBIOS ENTRE 1998 Y 2004.....	246



# ÍNDICE DE TABLAS

TABLA 2.1. ÁNGULOS DE ELEVACIÓN SOLAR Y HORAS DE ADQUISICIÓN DE LAS IMÁGENES LANDSAT ..	72
TABLA 2.2. CANTIDAD DE VAPOR DE AGUA Y TEMPERATURAS DE SUPERFICIE PARA LOS MODELOS DE ATMÓSFERA DE MODTRAN .....	72
TABLA 2.3. SELECCIÓN DE MODELOS DE ATMÓSFERA DE MODTRAN EN FUNCIÓN DE LA DEPENDENCIA LATITUDINAL Y ESTACIONAL DE LA TEMPERATURA DE SUPERFICIE .....	72
TABLA 2.4. VALORES DE ESPESOR ÓPTICO ATMOSFÉRICO (AOD), VAPOR DE AGUA Y VISIBILIDAD INTRODUCIDOS EN EL MODELO .....	73
TABLA 2.5. VALORES DE ESPESOR ÓPTICO ATMOSFÉRICO (AOD) PARA EL 17-07-1998 .....	78
TABLA 3.1. IMPORTANCIA RELATIVA DE LAS VARIABLES EN LA CLASIFICACIÓN DE CADA TIPO DE COBERTURA. ....	113
TABLA 3.2. EXACTITUD CARTOGRÁFICA Y PARÁMETROS DE AJUSTE DE LOS MEJORES MODELOS DE RNA PARA DIFERENTES NÚMEROS DE UNIDADES DE LA CAPA OCULTA. ....	115
TABLA 3.3. EXACTITUD CARTOGRÁFICA Y PARÁMETROS DE AJUSTE DE LOS MEJORES MODELOS DE MVS PARA LOS DIFERENTES GRADOS POSIBLES DE LOS KERNELS POLINOMIALES. ....	117
TABLA 3.4. EXACTITUD CARTOGRÁFICA (KAPPA) DE LOS MEJORES MODELOS DE MVS PARA LOS DIFERENTES VALORES POSIBLES DE SESGO. ....	120
TABLA 3.5. MEJORES MODELOS MVS EN FUNCIÓN DEL TIPO DE KERNEL. ....	121
TABLA 3.6. MATRIZ DE CONFUSIÓN DE LA MEJOR CLASIFICACIÓN OBTENIDA POR AD. ....	125
TABLA 3.7. MATRIZ DE CONFUSIÓN DE LA MEJOR CLASIFICACIÓN OBTENIDA POR RF. ....	125
TABLA 3.8. MATRIZ DE CONFUSIÓN DE LA MEJOR CLASIFICACIÓN OBTENIDA POR RNA. ....	126
TABLA 3.9. MATRIZ DE CONFUSIÓN DE LA MEJOR CLASIFICACIÓN OBTENIDA POR MVS. ....	126
TABLA 3.10. RESUMEN DE LA EXACTITUD CARTOGRÁFICA POR CATEGORÍAS OBTENIDA POR LAS DIFERENTES METODOLOGÍAS DE CLASIFICACIÓN. E. P.: EXACTITUD PRODUCTOR, E. U.: EXACTITUD USUARIO Y K.: KAPPA .....	127
TABLA 3.11. VALORES E INCREMENTOS DEL ÍNDICE KAPPA POR CATEGORÍAS PARA LOS CLASIFICADORES AD Y RF .....	128
TABLA 3.12. RESULTADOS DE LA EVALUACIÓN DE LA SIGNIFICATIVIDAD ESTADÍSTICA (Z) DE LAS DIFERENCIAS EN LOS COEFICIENTES KAPPA DE LOS MAPAS TEMÁTICOS CLASIFICADOS POR LOS DIFERENTES ALGORITMOS DE AUTO-APRENDIZAJE. ....	131
TABLA 3.13. VALORES DE Z OBTENIDOS PARA LOS DATOS CLASIFICADOS A PARTIR DE DATOS DE ENTRENAMIENTO CON DIFERENTES PROPORCIONES DE RUIDO RESPECTO A LOS RESULTADOS ORIGINALES. ....	133
TABLA 3.14. VALORES DE Z OBTENIDOS PARA LOS DATOS CLASIFICADOS A PARTIR DE CONJUNTOS DE ENTRENAMIENTO DE TAMAÑO REDUCIDO RESPECTO A LOS RESULTADOS ORIGINALES. ....	135
TABLA 4.1. VALORES DE LOS COEFICIENTES DE CORRELACIÓN (C), ERROR CUADRÁTICO MEDIO (RMSE) Y COEFICIENTES DE CORRELACIÓN DE LAS ALTAS FRECUENCIAS (HFC) PARA LAS BANDAS MULTIESPECTRALES AZUL (A), VERDE (V), ROJA (R) E INFRARROJA (IR). ....	161

TABLA 4.2. VALORES DEL ÍNDICE ERGAS, DE CALIDAD UNIVERSAL (Q) Y DE SIMILITUD ESTRUCTURAL (SSIM), PARA LAS BANDAS MULTIESPECTRALES AZUL (A), VERDE (V), ROJA (R), INFRARROJA (IR) Y EL PROMEDIO DE LAS BANDAS (MED).....	163
TABLA 4.3. VALORES DE LOS COEFICIENTES DE CORRELACIÓN (C) Y ERROR CUADRÁTICO MEDIO (RMSE), ENTRE LA IMAGEN MULTIESPECTRAL ORIGINAL Y LAS IMÁGENES FUSIONADAS DEGRADADAS, PARA LAS BANDAS MULTIESPECTRALES AZUL (A), VERDE (V), ROJA (R) E INFRARROJA (IR).....	163
TABLA 4.4. VALORES DEL ESTADÍSTICO KAPPA POR CATEGORÍAS DERIVADOS DE LAS CLASIFICACIONES ISODATA DE LAS IMÁGENES FUSIONADAS.....	167
TABLA 5.1. CARACTERÍSTICAS TÉCNICAS DE SENSORES CON DIFERENTE RESOLUCIÓN ESPACIAL EN EL VISIBLE E INFRARROJO CERCANO (VNIR) Y EL INFRARROJO TÉRMICO (TIR).....	171
TABLA 5.2. COEFICIENTES DE CORRELACIÓN ENTRE LOS CANALES ESPECTRALES DE LA IMAGEN LANDSAT 7 ETM+.....	183
TABLA 5.3. COEFICIENTES DE CORREGIONALIZACIÓN LINEAL.....	185
TABLA 5.4. ESTADÍSTICOS DE LA IMAGEN TIR ORIGINAL Y DE LA IMAGEN TIR DE RESOLUCIÓN ESPACIAL MEJORADA MEDIANTE <i>Downscaling Cokriging</i> . ND: NÚMERO DIGITAL.....	186
TABLA 5.5. ESTADÍSTICOS DE LA IMAGEN LST DE RESOLUCIÓN MÁS GROSERA Y DE LA IMAGEN LST DE RESOLUCIÓN MEJORADA MEDIANTE <i>Downscaling Cokriging</i> . ND: NÚMERO DIGITAL.....	191
TABLA 6.1. PARÁMETROS DEL CLASIFICADOR RANDOM FOREST PARA LOS MODELOS MÁS EXACTOS (EXACTITUD GLOBAL Y KAPPA) A PARTIR DE LOS DATOS DE TEXTURA GEOESTADÍSTICA PARA LOS DIFERENTES PASOS. MKT SE REFIERE AL CONJUNTO DE DATOS ÚNICAMENTE ESPECTRALES. G, G5, G15 Y G31 SE REFIERE A LOS MODELOS TEXTURALES MULTI-ESCALA Y A LOS MODELOS PARA TAMAÑOS DE VENTANA DE 5x5, 15x15 Y 31x31, RESPECTIVAMENTE.....	208
TABLA 6.2. PARÁMETROS DEL CLASIFICADOR RANDOM FOREST, EXACTITUD CARTOGRÁFICA E INCREMENTOS EN LA EXACTITUD (EXACTITUD GLOBAL Y KAPPA) Y VALORES DE Z, PARA EVALUAR LA SIGNIFICATIVIDAD DE LAS DIFERENCIAS ENTRE LOS COEFICIENTES KAPPA DE LAS CLASIFICACIONES OBTENIDAS A PARTIR DE LOS SUBCONJUNTOS DE DATOS MKT Y DE LOS MODELOS TEXTURALES (Z) Y ENTRE LOS COEFICIENTES KAPPA DE LOS SUBCONJUNTOS CON CARACTERÍSTICAS GEOESTADÍSTICAS Y LOS QUE CONTIENEN CARACTERÍSTICAS GLCM (Z*).....	208
TABLA 6.3. MATRIZ DE CONFUSIÓN DEL MODELO MKT.....	211
TABLA 6.4. RESULTADOS DEL ESTADÍSTICO KAPPA POR CATEGORÍAS DEL MODELO MKT Y DE LOS MODELOS TEXTURALES GEOESTADÍSTICOS E INCREMENTOS EN KAPPA DE LOS MODELOS TEXTURALES RESPECTO AL MODELO MKT.....	211
TABLA 6.5. RESULTADOS DEL ESTADÍSTICO KAPPA POR CATEGORÍAS DEL MODELO MKT Y DE LOS MODELOS TEXTURALES DE CO-OCURRENCIA E INCREMENTOS EN KAPPA DE LOS MODELOS TEXTURALES RESPECTO AL MODELO MKT.....	212
TABLA 7.1. VARIABLES UTILIZADAS EN LAS CLASIFICACIONES CORRESPONDIENTES A LOS AÑOS 1998 Y 2004.....	234
TABLA 7.2. ESTADÍSTICOS DE LA EXACTITUD CARTOGRÁFICA POR CATEGORÍAS DE LAS CLASIFICACIONES DE 1998 Y 2004.....	236
TABLA 7.3. MATRIZ DE CONFUSIÓN DE LA MEJOR CLASIFICACIÓN OBTENIDA PARA LA IMAGEN DE 1998.....	237
TABLA 7.4. MATRIZ DE CONFUSIÓN DE LA MEJOR CLASIFICACIÓN OBTENIDA PARA LA IMAGEN DE 2004.....	237
TABLA 7.5. ESTADÍSTICAS DE LAS CATEGORÍAS DE LOS MAPAS DE 1998 Y 2004.....	238

TABLA 7.6. MEDIDAS DE IMPORTANCIA DE LAS 10 VARIABLES MÁS SIGNIFICATIVAS PARA LA CLASIFICACIÓN DE LAS CATEGORÍAS DE LOS MAPAS DE 1998 Y DE 2004. VER: VERANO, PRI: PRIMAVERA, ME: MULTI-ESTACIONAL, V: VARIOGRAMA, R: RODOGRAMA, M: MADOGRAMA Y PC: VARIOGRAMA PSEUDO-CRUZADO .....	241
TABLA 7.7. MATRIZ DE CAMBIOS ENTRE LAS CLASIFICACIONES DE 1998 Y 2004 (km <sup>2</sup> ) .....	243





# Applying Remote Sensing, Machine Learning and Geostatistics to Land Cover Mapping: A case study in Granada, Spain

## Abstract

### **1. Chapter 1. Introduction**

Environmental management requires updated and synoptic information on the environment's condition and on the extension and magnitude environmental policies have over their areas of application. Earth observation represents an invaluable source of information regarding this, as a large number of relevant variables for environmental policies can be studied through remote sensing. Moreover remote sensing enables the monitoring of environmental processes at different scales, and the quality of the mapping generated for this monitoring process can be both qualitatively and quantitatively assessed. Hence, it turns out to be a tool of excellent characteristics to support environmental policies and decisions related to management and planning (de Leeuw et al., 2010; Prenzel, 2004; Rogan y Chen, 2004; Treitz y Rogan, 2004).

The term 'land cover' refers to both physic and biological covers which surround the Earth's surface, and comprises water, vegetation, bare soils, and/or artificial structures, while the term 'land use' presents more social and economic

overtones referring to the use a certain land cover has (Di Gregorio y Jansen, 2000). Land cover and land use monitoring and mapping is one of the main applications of the data provided by Earth Observing Satellites (Anderson et al., 1976). It is essential for the estimation of land cover changes, which have a crucial role in the study of global change (Foley et al., 2005). The mapping of land covers of extensive areas is important, as those modifications undergo, either anthropic or natural, have an effect on the biophysical and biochemical properties of the Earth's surface (Bala et al., 2007; Betts et al., 2007; Bonan, 2008; Brovkin et al., 2004). The mapping of these areas has many applications, such as the study of cover changes and deforestation, forest inventory assessment, and determination of priority areas for biodiversity conservation, among other uses (Lambin et al., 2001; Mas et al., 2004; Turner et al., 2007). On the other hand, land cover changes, through changes in the composition of carbon dioxide and other atmospheric gases linked to greenhouse effect, have an effect over climate, too (Bala et al., 2007; Betts et al., 2007; Bonan, 2008; Brovkin et al., 2004; Fearnside, 2000). In short, many applications depend on the existence of an accurate mapping of extensive and heterogeneous landscapes.

The increasing availability of satellite data has made it possible to develop land cover monitoring programmes, which are based on the mapping of large areas at repeated time intervals (Friedl et al., 2002a). Despite the foundations of an operative and accurate mapping of these areas are well established (Franklin y Wulder, 2002), there are still different questions related to the mapping process which need be solved.

The mapping of complex and heterogeneous areas is challenging. The reason for this is that they are made up of land covers difficult to differentiate due to a low inter-class separability and a high intra-class variability as a consequence of abrupt changes on environmental gradients such as humidity, altitude or temperature and the presence of alterations originated by environmental or anthropic processes (Ghimire et al., 2010; Rogan y Miller, 2006). Particularly, the thematic mapping of Mediterranean areas, obtained from satellite imagery, is especially complex given the land cover characteristics of these regions (Lloyd et al., 2004). Mediterranean covers present a similar spectral behaviour (low inter-class separability), together with a

complex landscape spatial structure, which shows a great variability in spatial patterns, being highly fragmented. The low inter-class separability of Mediterranean areas is a direct consequence of both the climate and land cover characteristics of these regions. Water scarcity brings about abundant bare soils, usually calcareous and very light-toned, with a high reflectance that may hide the component reflected by vegetation and make it imperceptible and indistinguishable from other high-reflectance covers such as urban areas. Hence, the mapping accuracy with which urban areas, soils and non-dense vegetation covers (e.g. olive grove) can be spectrally separated is low (Berberoglu et al., 2007; Berberoglu et al., 2000).

Different approaches can be adopted in order to increase inter-class separability in the case of classes which are spectrally similar. On the one hand, it is feasible to add information on the phenological state of vegetal covers through the incorporation of multi-seasonal imagery. Auxiliary variables may be included which describe environmental gradients that improve land cover characterization: temperature, digital terrain models, humidity.... The characterization of spatial variability in these images, by means of textural measures, provides important information on the arrangement of objects and their spatial relationships within the image. In short, a great number of auxiliary variables may be used for land cover and land use classification. However, it is not possible to construct models in an operative way from a very high data volume due to computational restrictions. Moreover, using a high number of variables may bring about a decrease in the accuracy of classifiers as a result of the Hughes effect (Bellman, 2003; Pacifici et al., 2009). Hence, the selection of more suitable variables for the classification of certain covers deserves special research.

Most land cover and land use mapping applications only use satellite images as input variables for the classification (Dixon y Candade, 2008; Oetter et al., 2001; Yuan et al., 2005a). In recent years it is more and more frequent to use auxiliary variables to enhance the classification process (Franklin, 1998; Rogan et al., 2008; Rogan et al., 2003; Watanachaturaporn et al., 2008). The results of studies on land cover and land use mapping suggest that including non-spectral variables into the classification process helps to improve the discrimination of thematic classes and,

consequently, gives as a result more accurate maps (e.g. 5-10%) (Franklin, 1995; Rogan et al., 2003; Watanachaturaporn et al., 2008; Wright y Gallant, 2007). Several studies show that the combination of multi-seasonal images enables a better distinction of certain covers (Lunetta y Balogh, 1999b; Oetter et al., 2001; Wolter et al., 1995; Yuan et al., 2005a). Additionally, other studies on land cover and land use mapping have proved that including textural variables provides additional information to the classification process in order to enhance mapping accuracy (Agüera et al., 2008; Asner et al., 2002; Chan et al., 2003; Chica-Olmo y Abarca-Hernández, 2000; Franklin et al., 2000; Johansen et al., 2007).

Another basic aspect for the mapping of complex areas is the choice of a suitable classification method. The classification of this type of areas requires robust methods, being also operative, interpretable, transparent and with a high degree of automation at the same time. However the choice of a classification algorithm depends on software availability, easiness of use and easiness of results interpretation most of the times. The choice of a classification method must also take into account possible errors in remote sensing data and auxiliary variables (Lunetta et al., 1991; Xiaolong y Khorram, 1998). The major source of error is 'noise', which is incorporated into classification models by data as a consequence of positional errors of the independent variables (e.g. spectral variables and digital terrain models). Errors related to the georeferenciation of these variables provoke displacements and, hence, bring about the fact that input layers will not be overlaid. Another source of noise linked to positional errors is due to a deficient location of those reference data used to train classification algorithms and validate the accuracy of the maps produced (Foody, 2002). On the other hand, (a) measure error(s) may take place due to an erroneous interpretation of field data or orthophotos (Franklin et al., 2001; Lippitt et al., 2008; Rogan et al., 2008). Lastly, a common source of errors is the presence of noise resulting from deficiencies in the measure of input variables, such as saturation of the satellite signal, lost or wrongly scanned lines, error in data processing, etc. For all that has been said, the choice of a suitable classification method for the mapping of

complex areas depends on the method's capacity to handle data with noise and complex measure spaces (DeFries y Chan, 2000; Rogan et al., 2008).

There is a wide range of algorithms which have been used for land cover and land use classification, as well as for change mapping, which use remote sensing data. These range from unsupervised to supervised parametric algorithms, such as the maximum likelihood algorithm (Jensen, 2005), or non-parametric machine learning algorithms. Several studies have proved that machine learning algorithms are more accurate than traditional classification techniques, such as maximum likelihood (Murthy et al., 2003; Pal, 2005; Pal y Mather, 2003; Seto y Liu, 2003). The superiority of machine learning algorithms is due to their non-parametric nature, as covers with high intra-class variability do not usually follow a normal distribution.

Machine Learning is a branch of Artificial Intelligence whose aim is to develop techniques that enable learning. More specifically, it is about creating algorithms able to generalise behaviours from non-structured information provided as examples. Hence, it is a knowledge-induction process. Many times the scope of Machine Learning overlaps with that of Statistics, since both disciplines are based on data analysis. However, Machine Learning is more focused on the study of the Computational Complexity of problems (Sierra-Araujo, 2006).

Machine learning is a relatively new field of science and it is under continuous improvement. In recent decades a great number of classification methods for the generation of thematic mapping have emerged (Tso y Mather, 2009; Wilkinson, 2005). Among the most used are classification trees (Breiman, 1984), artificial neural networks (Mas y Flores, 2008), support vector machines (Mountrakis et al., 2011) and ensembles of classifiers (Breiman, 1996; Chan y Paelinckx, 2008). These methods start from very diverse conceptual bases and their application is complex sometimes. The accuracy of induced models by means of self-learning methods strongly depends on the combination of parameters used. Hence, there is a need to study the impact of the internal parametrization of these algorithms for land cover and land use classification in depth, especially in the case of those methods whose

application on remote sensing data classification is not consolidated due to their newness. Only once a detailed study of the internal parametrization of these machine learning techniques has been performed, it is possible to determine which methods are more suitable to classify remote sensing data in terms of their mapping accuracy, noise and training data size sensitivity and their ability to learn from a high volume of variables, and generalization.

## 1.1 Objectives

The final objective of this dissertation is to advance towards the development of an accurate and operative method for land cover mapping in the Province of Granada, by means of the application of remote sensing, machine learning and geostatistics techniques. A series of partial objectives have been defined in turn, among which stand out the assessment of different machine learning classification algorithms, the incorporation of new auxiliary environmental variables in the classification process and the integration of the analysis of the spatial variability of satellite images. These partial objectives can be summarized as follows:

1. Assessment of different machine learning methods for land cover classification. Among the assessed classification algorithms there were classifiers based on simple decision trees or ensembles of classification trees such as Random Forest, Artificial Neural Networks and Support Vector Machines. On the other hand, an important objective of this dissertation was determining the optimum parametrization of said methods and to analyse their sensitivity against variations in training data (presence of noise and variation in data size).

2. Assessment of different methods to increase the spatial resolution of satellite imagery based on wavelet transforms, Bayesian methods and Cokriging, as well as their application on a special case in which the correlation between bands is low: the thermal band of Landsat TM-5 satellite.

3. Extraction and incorporation of variables linked to environmental gradients such as humidity, temperature, altitude, vegetation indexes, etc. into the classification

system, as well as the assessment of their relative importance within the classification model and the classification of each type of cover in the study area.

4. Comparison of extraction methods of textural measures from digital imagery based on geostatistics and co-occurrence matrices. Incorporation and assessment of bi-seasonal textural measures by means of geostatistical techniques.

5. The application of transformations to the satellite images' original bands dramatically increases data dimensionality, which may affect the classifiers' accuracy. In this sense, an objective of this dissertation has been to apply a state-of-the-art classifier (Random Forest) capable of classifying from high data volumes and of selecting the most important textural features for the classification of the study area.

6. Our final objective has been, once classified maps have been obtained, the location, post-classification analysis, and quantification of those changes which took place on the covers of the study area between 1998 and 2004.

## 1.2 How the dissertation summary is organized

This dissertation consists of eight chapters. Chapter 1 is the introduction, and provides an orientation to the general theoretical background and the context in which this dissertation is framed: land cover and land use classification from Remote Sensing data. Following the introduction in Chapter 1, Chapter 2 presents the study area and describes the environmental and socioeconomic framework of the Province of Granada. Likewise a brief description of data used is provided. Also, this chapter describes major sources of error in satellite imagery and those different stages necessary for Remote Sensing data processing, particularly a reference is made to satellite imagery geometric and radiometric correction methods. Among the latter, relative and absolute atmospheric correction methods are included, based on regression techniques and radiative transfer codes which take into account simulated atmospheres based on *in situ* meteorological data, respectively.



A final chapter provides the most outstanding general conclusions of this study. The rest are chapters of a more methodological nature, and we have decided to use a dissertation structure in which an introduction, theoretical fundamentals, methodology, results and specific conclusions can be provided independently for each chapter, since these do not present common methods. Next follows a summary of the remaining chapters.

Chapter 3 entirely covers the thematic classification of satellite imagery through machine learning techniques. This chapter provides the study of some of the most state-of-the-art machine learning techniques/algorithms which can be applied to land cover classification in the Province of Granada. To this end a comparative analysis from different perspectives has been carried out: the mapping accuracy of classifications, each technique's parametrization needs and, last but not least, noise sensitivity and training data reduction.

Chapter 4 describes several techniques to increase the spatial resolution of satellite imagery (downscaling).

Chapter 5 starts from results in chapter 4 in order to apply a downscaling method to the thermal band of Landsat TM5 sensor in order to make its spatial resolution equal to that of the rest of multi-spectral bands and make it possible to include it into the classification methods. Finally, this chapter assesses the contribution of thermal information to land cover classification in the Province of Granada.

Chapter 6 covers the spatial analysis of satellite imagery, from which new information variables result that comprise different textural measures applied to the bands of satellite images. Additionally, an innovative method to select the most relevant textural variables for the classification (feature selection) is described.

Finally, Chapter 7 describes both land cover change detection and change analysis approaches from remote sensing data. Lastly, this chapter deals with the location, post-classification analysis and quantification of those changes occurred on covers in the study area among the classifications made for the years ranging from 1998 and 2004.

## 2. Chapter 2. Study area and data

The province of Granada is the study area chosen for this project. It is located in the south of Spain on the Mediterranean coast, encircled by the Penibetica mountain range (**Error! No se encuentra el origen de la referencia.**). This area occupies 12,635 km<sup>2</sup> and elevation ranges from sea level to the Mulhacen Peak (3,482 m) in Sierra Nevada National Park. The climate of Granada is Mediterranean with a continental influence, characterised by hot and dry summers and wet and cold winters. Average annual temperatures range from 18 degrees celcius at the coast to 10 degrees celcius in the mountains. Climate ranges from arid to semi-arid (between 300 and 500 mm). The study area is composed of a variety of land cover types, mainly including agriculture (46 %), with tobacco and corn fields, olive trees, tropical crops and substantial greehouse production. The remainder of the study area is characterized by the presence of upland conifer forest (18 %), shrub-grasslands (22 %) and oak grove (8 %).The natural vegetation zone has the highest biodiversity in the Iberian Peninsula and Europe, with 66 endemic vascular species, which have remained unaltered due to substrate features, the extreme climate and their inaccessibility over time (Mota et al., 2002).

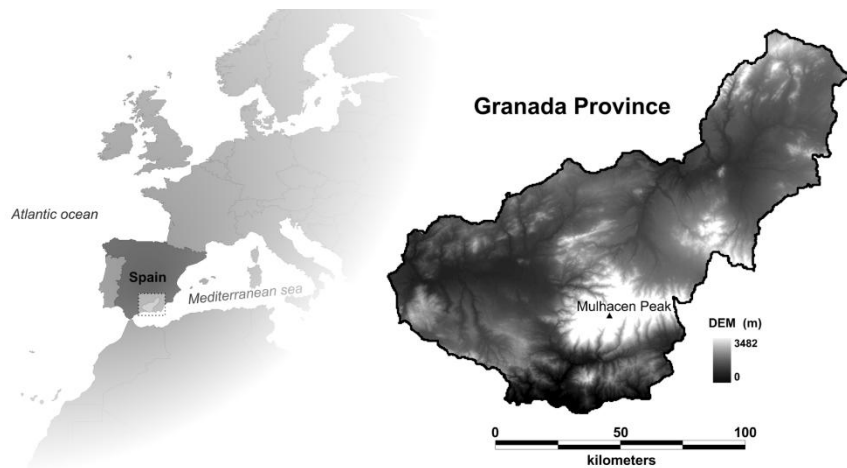


Figure 1. Location of the study area in Spain

Multi-temporal Landsat images are commonly employed to characterize phenological variation in the state of vegetal cover. Several studies have shown that a combination of multi-seasonal images allows for increasing the separation between spectrally similar covers because it represents the phenological vegetation condition (Lunetta y Balogh, 1999a; Oetter et al., 2001; Wolter et al., 1995; Yuan et al., 2005a). In this study, spring and summer images have been employed (April and August respectively) in the land cover classification since these images contain most of the phenological variations (Brewster et al., 1999; Brisco y Brown, 1995; Pax-Lenney et al., 1996; Pax-Lenney y Woodcock, 1997; Schriever y Congalton, 1995). These two dates represent peaks in productivity of the phenological development of the major vegetation types in the area, which is critical for the accurate classification of land cover types. In summer images, annual crops (e.g., tobacco and corn) can be confused with conifer forests and poplar groves. Highly reflective surfaces, such as urban areas, can be confused with bare soils. The inclusion of spring images allows discrimination between annual crops and evergreen natural vegetation. On the other hand, soils, which remain bare during drought periods (summer), are usually covered by grass in spring time, which can facilitate differentiation from urban areas (Yuan et al., 2005a). The definition of summer and spring is related to the Northern Hemisphere.

Two Landsat Thematic Mapper-5 scenes of the same area in southeast Spain were captured. The images were acquired on 18 August and 12 April 2004. Image location corresponds with path 200 row 34 of Landsat Worldwide Reference System (WRS), with coordinates centre 0030822 W 372400 N WGS-84.

Images were independently corrected for geometric offset by using digital orthophotos of 1 m spatial resolution. A number of 150 points for each image provided a third-order polynomial transformation with less than one-half pixel root mean square (RMS) error. Nearest neighbour resampling was chosen to preserve the original values of the pixels. The images were converted to radiance values, and then into reflectance values by using a radiative transfer code based on MODTRAN4 (MODerate Resolution TRANsmittance) (Abreu y Anderson, 1996; Berk y Adler-

Golden, 2002), FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes). The reflectance values obtained for both dates were rescaled from 0 to 255 (8 bit reflectance).

The images were spectrally enhanced using the Thomas linear transformation before being used in classification. This transformation produced six features: summer brightness, summer greenness, summer wetness, spring brightness, and both spring greenness and wetness.

Following Franklin (1998), several topographic variables were included as input variables to each Random Forest classification: elevation, slope and aspect. These ancillary variables were derived from a 20 m resolution digital elevation model (DEM) and rescaled to the resolution of the spectral variables (30 m).

The land cover of the Mediterranean can be very complex and challenging to classify (Berberoglu et al., 2000). Relief complexity and high anthropogenic influence results in a very heterogeneous landscape which makes it possible that fourteen different thematic categories can be distinguished in the study area. The classification scheme was based on Andalusian land cover maps (ALCM) developed in 2003 by the Andalusian Regional Government (Moreira-Madueño, 2006).

Jensen (2005) proposed that the size of training pixels should at least be equal to ten times the number of variables used in the classification model for a parametric classification approach. However, several studies have shown that non parametric machine learning algorithms need a higher training data volume in order to attain optimal results (Foody, 1995a; Foody y Arora, 1997; Pal, 2005; Pal y Mather, 2003).

In order to create an exhaustive database with an optimal size for the training and accuracy assessment it was necessary to resort to auxiliary information due to the retrospective nature of this study. Reference data were obtained from a combination of a set of crop reference sites collected in the summer of 2004 and a stratified random sampling using pre-existing land cover maps (ALCM). More specifically, the ALCM was reclassified into 14 categories, and 150 sites were randomly sampled from each category. The digital true-colour orthophotos (1:10000), corresponding

with the sample sites and acquired during 2004, were then interpreted and 2100 sites were obtained. The ground reference dataset was randomly divided into 2/3 and 1/3 for training and testing, respectively. The number of the training sites per class was kept equal (100 training sites and 50 testing sites per land cover category). McCoy (2005) establishes that the minimum dimensions of the sample areas  $A$  should be estimated as  $A = P(1 + 2L)$ , where  $P$  is the ground sampling distance and  $L$  is the positional accuracy of the geometric registration in terms of pixels. In a multi-temporal context, when at least two image dates are used, the minimum dimension of a sample is equal to the mean value between time periods. In this study, the average between the area of the spring image,  $A_{spring} = 30(1 + 2 * 0.51)$  and the area of the summer image  $A_{summer} = 30(1 + 2 * 0.47)$  results in a minimum size of 59.4 by 59.4 which is roughly equal to 2 pixels. Thus, plot size was fixed on a 90 by 90 m sample area in a conservative way.

### **3. Chapter 3. Machine learning methods for digital classification**

Remote sensing-based mapping of large areas has created new challenges for the remote sensing and land change science communities. The spatial scale and data volumes of large area change monitoring dictate the need for classification algorithms that minimize requirements for human intervention and promote automated classification. Attempts to solve these challenges have led researchers away from accepted and well-understood parametric algorithms, such as maximum likelihood, to newer non-parametric algorithms that offer increased accuracy and performance over large areas and data volumes. At the same time, these algorithms are less understood in the remote sensing context, particularly in land cover change mapping. To address this issue, this study provided insights toward improved understanding of non-parametric algorithms for large area mapping. The objective of this chapter is to compare the performance of four machine learning algorithms; two classification tree methods (C4.5 and Random Forest), an artificial neural network and different types of

support vector machines, in the context of mapping land cover in Granada Province. Comparisons were based on several criteria: overall accuracy, parametrization necessities, sensitivity to data set size and variation, and noise.

The current chapter address the impacts of internal parameterization on the performance of the mentioned machine learning algorithms for land cover classification. A set of classification models with different combinations of parameters, were carefully constructed to classify a Landsat Thematic Mapper image into fourteen major land cover categories using identical training data. The accuracy of each classified map was further evaluated using identical reference data. The results reveal that the combination of parameters can substantially affect the classification accuracy for the entire mosaic and specific classes as well, and that a careful selection of parameter settings can help improve the performance of machine learning classification. These findings reported here can help establish a practical guidance on the use of machine learning algorithms for land cover classification from remote sensor data.

Moreover, this study considered both the overall classification accuracy and the accuracy for specific categories in a way to provide an insight into the performance of machine learning classification concerning land cover types with varying spectral complexities. Random Forest and support vector machines produced the most accurate maps overall (92%), and was most resistant to training data deficiencies. Random Forest appears to be robust and accurate for land cover classification of the study area, with minimal human intervention in the classification process.

The effect of training set size on algorithm performance indicates that large numbers of training and test sites are important in land cover mapping using MLAs. Nonetheless, reasonable accuracies were achieved at certain levels of data reduction, implying that the quality, if not the quantity of sample data was adequate. Results suggest that below a certain size, a data set is less representative of the conditions it is supposed to represent, resulting in reduced map accuracy. It might also suggest that the data sets used here have few redundant observations, or else reducing the size

would have less of an effect. Further, greater error/noise in training data resulted in dramatically lower map accuracy. Support vector machines and Random Forest were least affected by noise while decision trees and neural networks were most affected.

#### **4. Chapter 4. Image fusion methods**

A set of relevant methods, based on different mathematical approaches, for Landsat 7 ETM+ pansharpening, are compared in this chapter. These are procedures based on wavelet transforms: Wavelet à Trous (WAT) and Multidirection-Multiresolution (MDMR); a method of a geostatistical nature, Downscaling Cokriging (DCK); and finally, a Bayesian method (L1COR).

The best reference for assessing the quality of the fused image consists, obviously, in knowing the true or real image ( $M_h$ ) which is wished to be obtained via the fusion method (Wald et al., 1997). However, this is not feasible in practice. For this reason, an experiment was carried out in which the original multispectral ( $M_h$ ) and panchromatic ( $P_h$ ) images were degraded to resolutions of 120m ( $M_l$ ) and 30m ( $P_l$ ), respectively, in order to obtain fused images with a resolution of 30m ( $M_h^*$ ) (Figure 2). Thus, the results of fusion ( $M_h^*$ ) can be compared to the real image ( $M_h$ ). The comparison of the fused images was based on the qualitative and quantitative evaluation of their spatial and spectral characteristics by calculating statistical indexes and parameters that measure the quality and coherence of the images. In Addition, any fused multispectral image once degraded to its original resolution  $l$ , should be as identical as possible to the original multispectral image  $M_l$  (Wald et al., 1997). To measure the coherence between the said images, the ( $M_h^*$ ) images have been degraded to the spatial resolution. Moreover, the quality of the spectral information was studied indirectly, by means of the ISODATA classification of the products of fusion.

The results shows that DCK and L1COR methods yielded better results than the wavelet based did. Particularly, DCK does not introduce artefacts in the estimation of the digital numbers corresponding with the source multispectral image and, therefore,

it can be considered as the most coherent method. Thus, the fused image, once degraded to its original resolution, is identical to the original multispectral image. In terms of mapping accuracy and considering the ISODATA classifier, the algorithms generating the images of the highest spectral quality are LICOR and DCK, with LICOR producing slightly superior results in the classifications.

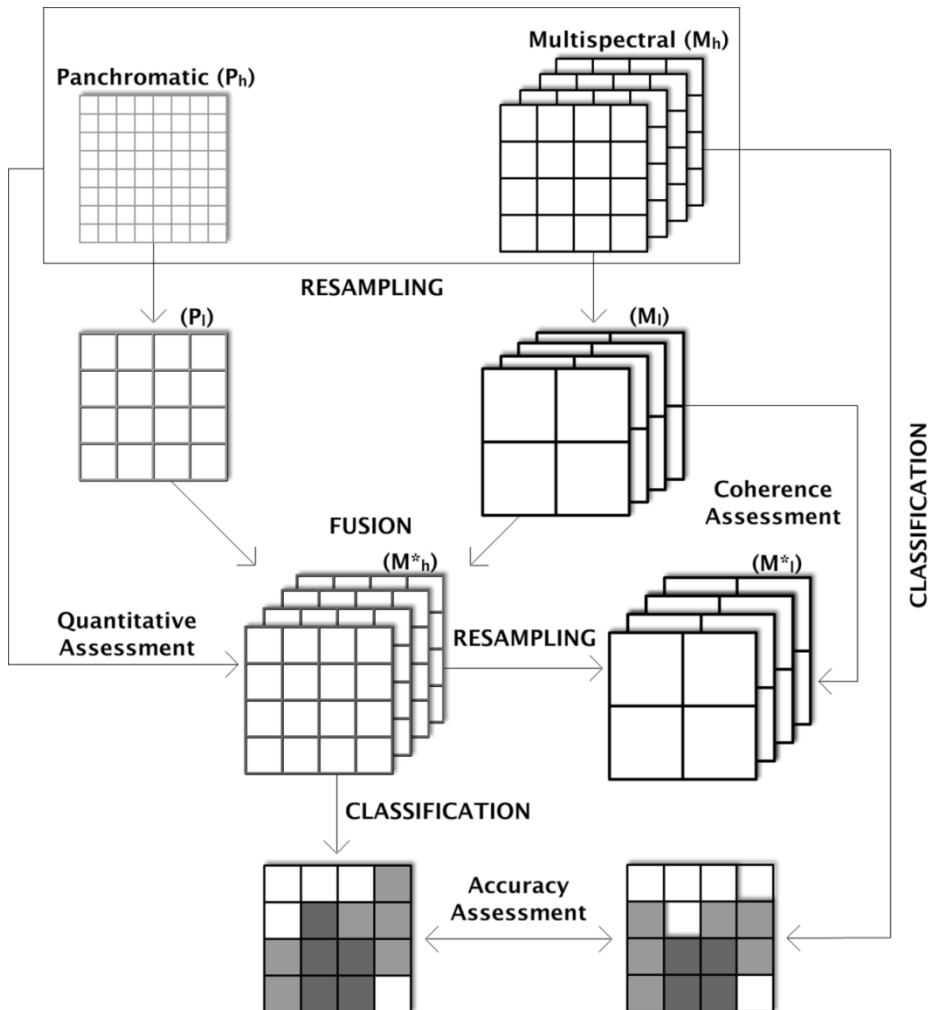


Figure 2. Flowchart of the methodology used for comparative assessment of image fusion algorithms



## 5. Chapter 5. Incorporating the downscaled Landsat TM thermal information in Land cover Classification

Thermal infrared (TIR) satellite images and derived Land Surface Temperature (LST) are variables of great interest in many remote sensing applications. However, the TIR band has a spatial resolution which is coarser than the other multispectral bands for a given satellite sensor (visible, near and shortwave infrared bands); therefore, the spatial resolution of TIR bands from available satellite-borne sensors is not accurate enough to be used in certain applications such as classification. The aim of this study was to assess the improvement that incorporating the thermal information of the Landsat sensor has in the classification of Granada Province.

To incorporate the thermal data into the classification process a method is shown in this chapter for obtaining TIR and LST images with enhanced spatial resolution, using the TIR band and one or more spectral bands of the same scene and better spatial resolution using Cokriging. This method, as it was proven in the previous chapter, is endowed with perfect coherency, implying that if the high spatial resolution cokriged image is degraded by using the point-spread-function, the resulting image will be identical to the experimental image acquired by the satellite sensor. In the case of LST downscaling, this property is of paramount importance, as it has been found that over heterogeneous flat areas, LST at the low scale can be expressed as a simple areal average of the LST at the high scale (Liu et al., 2006; Stathopoulou y Cartalis, 2009)

The general procedure to obtain the Land Surface Temperature image with enhanced spatial resolution is sketched in Figure 3. The predicted image by Cokriging  $\hat{Z}_{u_0}^{k_0}$  is calculated from the experimental images  $Z_{u_j}^{k_j}$ , where  $\lambda_{ji}^0$  are optimal weights obtained by the Cokriging system. In order to solve the Cokriging system it is necessary to calculate the stationary covariance  $C_{uv}^{66}(\mathbf{s})$  from the empirically known covariance  $C_{VV}^{66}(\mathbf{s})$  by numerical deconvolution, which requires several convolutions, the known impulse response functions  $h_u(\mathbf{s})$  and  $h_v(-\mathbf{s})$ , and the known

deterministic covariance  $\rho_V(s) = hV(s) * hV(-s)$ , with  $*$  being the convolution operator. Accepting  $C_{VV}^{66}(s)$  implies accepting the corresponding model  $C_{VV}^{66}(s)$  which was being looked for. The HR LST Image (Ts) is retrieved by the inversion of the radiative transfer equation from the land surface emissivity  $\epsilon$ , whose computation requires the application of the NDVI threshold method, and the atmospheric transmissivity between the surface and the sensor  $\tau$  and the downwelling and upwelling radiance  $L_{\downarrow atm}$  and  $L_{\uparrow atm}$  which were obtained from the Atmospheric Correction Parameter Calculator (ACPC) using in situ atmospheric parameters.

A LST image with perfect consistency has been obtained by applying this method to a Landsat 7 ETM+ TIR band. This implies that, if the downscaled TIR image is degraded to its original resolution, the degraded image obtained is identical to the original. Hence high spatial resolution LST images have been obtained without altering the original radiometry with the inclusion of artifacts. Moreover, values of image fusion quality indexes, such as ERGAS (Relative Dimensionless Global Error) and Average Q (Image Quality Index) equal to 0.22 and 0.99, respectively, were obtained.

Finally, the thermal information was evaluated for contribution to overall and per-class map accuracy using Random Forest classification. The addition of the TIR band to single season and multi-seasonal data leads to an increase in the overall accuracy of 10% and 5%, and to an increase in the kappa index of 10% and 5%, respectively. The increase in per-class kappa for the thermal, single-season, Random Forest model ranged from -3% to 47% and 0% to 12% for the thermal, multi-seasonal model. The thermal information enhanced the map accuracy of the vegetation classes which presented a similar phenological behavior, and decreased the misclassification errors between tropical crops and ligneous irrigated and oak grove and conifers. In addition, the thermal RF models improved the mapping of high reflectivity surfaces such as bare soils and urban areas. These classes have similar reflectivity values (high values), but different values in the TIR band which can be used to differentiate between them. Moreover, the RF classifier provided the means for assessing the

importance of variables in the general classification model and in the classification of each category by using the out of bag (OOB) set. In general, those variables derived from reflective bands have a higher importance than the thermal band in the classification process. However, our analysis has shown that the addition of the TIR data has improved the accuracy of the models over those without the TIR data.

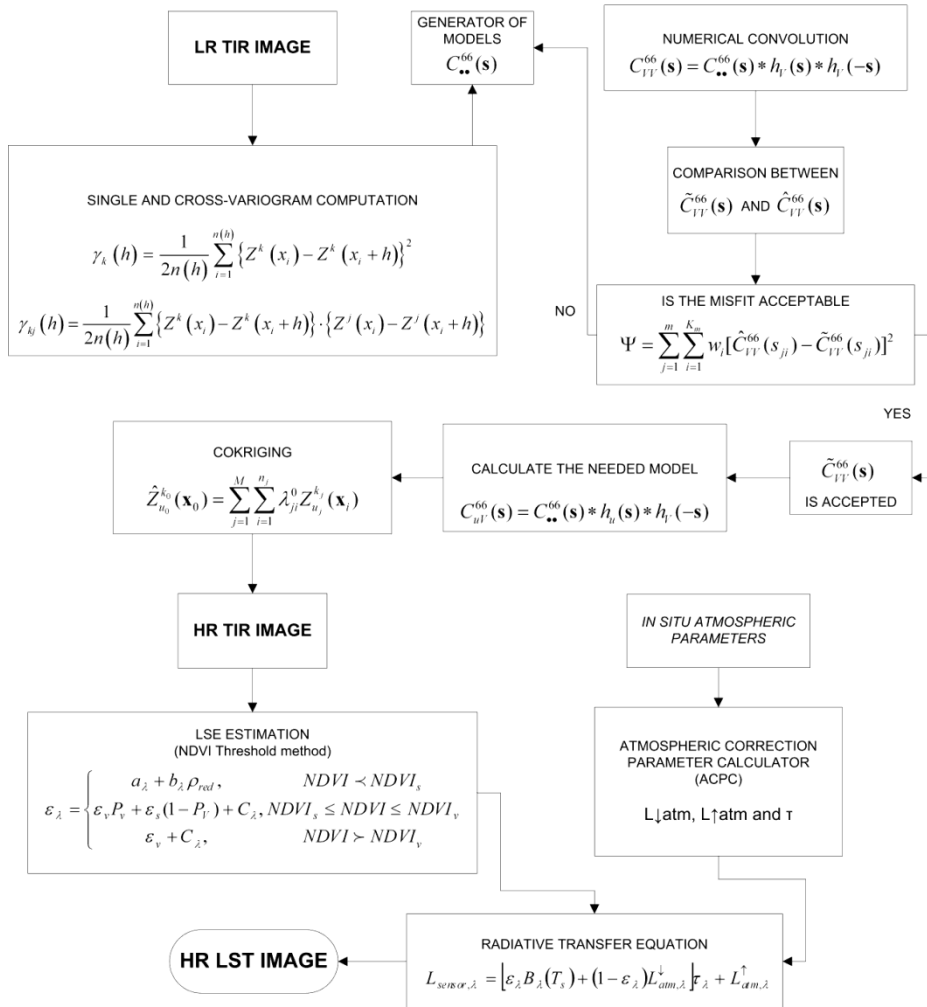


Figure 3. Flowchart for calculating the high resolution Land Surface Temperature Image

## **6. Chapter 6. Incorporating spatial variability measures in land cover classification**

The spatial variability of remotely sensed images provides important information about the arrangement of objects and their spatial relationships. The characterization of spatial variability in such images, through texture measures, is of great potential utility for the discrimination of land cover classes. The aim of this chapter is to assess the increase in accuracy that can be achieved by incorporating geostatistical textural measures in a relatively novel classification approach called a Random Forest. The proposed method is based on the analysis of mono- and multi-seasonal textural features extracted from Landsat TM imagery. For this purpose, geostatistical textural parameters were investigated by computing 5 types of measures over three different window sizes, and three different lags for a total of 978 input features. Random Forest importance measurements made it possible to determine the most important textural features for land cover classification of Granada Province, reducing the “curse of dimensionality”.

Madograms, rodograms and direct variograms for the univariate case and cross- and pseudo-cross variograms for the multivariate case, together with multi-seasonal spectral information, were used in a Random Forest classifier to map land cover types. Pseudo-cross and cross variograms were used to incorporate the seasonal/temporal dimension into the textural measures to classify complex landscapes with a large number of land cover categories with low inter-class separability. Geostatistical-derived texture measures were used to map land cover types and their performance compared with GLCM-based approaches.

The addition of geostatistical texture into the multi-seasonal Random Forest models led to an increase in the Kappa index of 10.71%. The increase in Kappa index for individual categories reached 30% for certain categories. The differences in the Kappa coefficient of textural classification models were statistically evaluated using a pairwise Z-test. The use of geostatistical texture produced a more significant increase in per-class classification accuracy for complex land cover categories than GLCM-

based texture measures. Pseudo-cross variograms between visible and near-infrared bands were the most important textural features for general classification. However, in the classification of the crop classes, the multi-seasonal pseudo-cross variograms had an outstanding importance. The most reliable classification results were obtained using only 30% of the geostatistical textural measures at the 31x31 window size. Therefore, Random Forest increased the mapping accuracy when using a reduced subset of input variables composed of the most informative textural features.

## **7. Chapter 7. Land cover classification and change analysis of the Granada Province**

The importance of accurate and timely information describing the nature and extent of land resources and changes over time is increasing, especially in rapidly growing metropolitan areas. We have developed a methodology to map and monitor land cover change using multiseasonal Landsat Thematic Mapper (TM) and auxiliary information, such as digital terrain models, land surface temperature and textural measures, in the Granada Province for 1998 and 2004. The overall fourteen-class classification accuracies averaged 91% for the map of 1998 and 92% for 2004. The overall accuracy of land cover change maps, generated from post-classification change detection methods was equal to 86%. The maps showed that between 1998 and 2004 the amount of oak grove, urban or developed land, pastures, greenhouses, and shrublands increased 76%, 32%, 30%, 19% and 13% of the total area, while poplar grove, tropical crops, herbaceous dry crops, olive grove, bare soils, and conifers decreased 24%, 23%, 16%, 11%, 8% and 6%. The results quantify the land cover change patterns and demonstrate the potential of multitemporal Landsat data to provide an accurate, economical means to map and analyze changes in land cover over time that can be used as inputs to land management and policy decisions.

## 8. Conclusions

The main objective of this dissertation is to develop an integrated methodology for the mapping and analysis of land cover changes in complex and heterogeneous areas. The Province of Granada is a complex and very heterogeneous area, made up of numerous land covers difficult to map due to spectral similarities between the different categories or land covers. This inherent difficulty to the mapping of areas presenting the abovementioned characteristics has been dealt with by choosing a robust classification method being, in turn, operative, transparent, interpretable and with a high degree of automation. Also, by obtaining and incorporating new variables which allow an improved land cover characterisation: spectral variables corresponding to different stages of land cover phenological development, variables linked to environmental gradients, and spatial variability structure textural measures.

This study has established a comparison between different machine learning methods of a diverse nature: neural networks, decision trees and other more recent algorithms, support vector machines and meta-classifiers composed of decision trees (*Random Forest*). Results of this dissertation show machine learning algorithms present different complexity levels. The training of tree-based classification algorithms is simple, while neural networks and support vector machines are more complex and sensitive to slight parametrization variations, which results in a higher computational cost. In terms of the mapping accuracy resulting from the application of these methods, *Random Forest* and radial kernel-based support vector machines are those with best performance. These two classifiers are also less sensitive to noise and training data reduction. Hence they can be used in those cases in which the quality of calibration data is deficient or unclear.

In addition to the choice of an optimal classification method, considering auxiliary variables in the classification process increases the classifiers' capacity for land cover differentiation. Thus, including spring spectral variables considerably improves vegetal cover characterisation. The differentiation between urban areas and

soils was also improved, as despite both have similar reflectivity values in the summer, soils present vegetal covers in springtime which make them spectrally different. Likewise, the dependence between land covers and land characteristics has also been used. Particularly, the joint use of Remote Sensing imagery and digital terrain models, obtained from the elevation matrix of the Province of Granada by means of GIS, has meant one of the most relevant aspects of this dissertation. However, the availability of digital terrain models in certain areas is limited; hence it may be necessary to include other variables related to environmental gradients, such as temperature, which condition the distribution of land categories.

Some sensors, such as Landsat TM or ETM+, include channels in the thermal infrared, from which it is possible to obtain measures of the Earth's surface temperature. The thermal information of these sensors has been less used in mapping, for its spatial resolution is coarser than that of the rest of channels. However, it is possible to enhance its spatial resolution through the application of image fusion methods. In this regard, image fusion methods of different conceptual bases have been assessed: Wavelet methods, a Bayesian method and a geostatistical method based on cokriging. The assessment of the results derived from the application of fusion methods has been based on visual quality and on different statistical parameters and spectral and spatial quality indexes. Applying the geostatistical and Bayesian methods gives as a result images with an increased spatial resolution whose quality is better. More precisely, the geostatistical method achieved the most coherent images. In other words, if these images were to be resampled to their original resolution, those images obtained would be identical to the initial images.

From the findings presented in the previous paragraph, in this dissertation we decided to develop a method based on cokriging and on the application of the radiative transfer equation to obtain surface temperature images of a resolution equal to that of the rest of bands of the Landsat satellite. The inclusion of these variables brought about an increase in the accuracy of vegetation categories which present a similar spectral behaviour in the visible wavelengths (tropical crops, ligneous irrigated crops, oak grove and conifers), but also, of other high reflectivity covers

such as bare soils and urban areas. In the case of conifers and urban areas, the inclusion of temperature caused a greater increase in the mapping accuracy of these categories than that which resulted from considering spring spectral variables.

As an alternative solution to the use of environmental gradients as input data of classification methods, different textural measures applied to the satellite images' bands have been studied. To this end, several functions based on co-occurrence (GLCM) matrices and others of a geostatistical nature, based on the variogram, have been used. It is worth underlying the newness of the calculation of multi-seasonal textural measures through the application of cross and pseudo-cross variograms between spring and summer satellite images. The inclusion of geostatistical variables into classification models significantly increased the accuracy of those models trained from spectral data only. Particularly, this happened when geostatistical functions were used, being pseudo-cross variograms the most useful. Given the large number of textural variables considered, a method to select characteristics/features based on importance measures calculated by the *Random Forest* classifier was applied, which allowed mitigating the Hughes effect, successfully selecting the most relevant characteristics and significantly reducing data volume.

Lastly, all the variables generated throughout this study were integrated to obtain the mapping of land covers in the Province of Granada between 1998 and 2004. A method to analyse post-classification changes has been developed, which has allowed identifying, localising and quantifying the different change patterns in land covers of the study area, with an overall accuracy of 86%. The findings in this dissertation prove the potential of Remote Sensing data and GIS-based techniques, Artificial Intelligence and Geostatistics to map those transitions which take place between land covers throughout time, in an economical and operative way.



# CAPÍTULO 1.

## Introducción

### **1 Introducción general**

La gestión medioambiental requiere información actualizada y sinóptica del estado del medio ambiente y la extensión y magnitud de los impactos de las políticas medioambientales sobre sus áreas de aplicación. La observación de la Tierra representa una fuente de información inestimable para ello, ya que un gran número de variables importantes para las políticas medioambientales pueden ser estudiadas mediante teledetección. Además, la teledetección permite un seguimiento temporal continuado de los procesos medioambientales a diferentes escalas, y la calidad de la cartografía generada para este seguimiento puede ser evaluada cualitativa y cuantitativamente. Por tanto, es una herramienta con unas características inmejorables para apoyar políticas y decisiones medio-ambientales relacionadas con la gestión y la planificación (de Leeuw et al., 2010; Prenzel, 2004; Rogan y Chen, 2004; Treitz y Rogan, 2004).

El término “cubierta del suelo” hace referencia a las cubiertas físicas y biológicas que recubren la superficie de la Tierra, lo cual incluye agua, vegetación, suelos desnudos, y/o estructuras artificiales, mientras que el término “usos del suelo” tiene un carácter más social y económico que hace referencia a la utilización dada a una determinada cubierta del suelo (Di Gregorio y Jansen, 2000). El seguimiento y la

cartografía de cubiertas y usos del suelo es una de las principales aplicaciones de los datos provenientes de satélites de observación de la Tierra (Anderson et al., 1976). Es esencial para la estimación de los cambios en las cubiertas, los cuales tienen un papel crucial en el estudio del cambio global (Foley et al., 2005). La cartografía de las cubiertas del suelo de áreas extensas es importante, ya que las modificaciones que se producen en ellas, ya sean antrópicas o naturales, afectan a las propiedades biofísicas y bioquímicas de la superficie de la tierra (Bala et al., 2007; Betts et al., 2007; Bonan, 2008; Brovkin et al., 2004). La cartografía de estas áreas es usada en multitud de aplicaciones, como el estudio de los cambios en las cubiertas y la deforestación, la evaluación el inventario forestal, y la determinación de áreas prioritarias para la conservación de la biodiversidad, entre otras (Lambin et al., 2001; Mas et al., 2004; Turner et al., 2007). Por otro lado, los cambios en las cubiertas del suelo, a través de cambios en la composición del dióxido de carbono y otros gases de la atmósfera asociados al efecto invernadero, afectan también al clima (Bala et al., 2007; Betts et al., 2007; Bonan, 2008; Brovkin et al., 2004; Fearnside, 2000). En definitiva, muchas aplicaciones dependen de la existencia de una cartografía exacta y precisa de paisajes extensos y heterogéneos.

La disponibilidad creciente de datos de satélite ha hecho posible el desarrollo de programas de seguimiento de las cubiertas del suelo, los cuales están basados en la cartografía de grandes áreas a intervalos de tiempo repetidos (Friedl et al., 2002a). Pese a que las bases de una cartografía operativa y precisa de estas áreas están bien establecidas (Franklin y Wulder, 2002), aún existen diferentes cuestiones relacionadas con el proceso de cartografía que necesitan ser resueltas.

La cartografía de áreas complejas y heterogéneas es difícil ya que están compuestas por cubiertas del suelo que son difíciles de diferenciar debido a una separabilidad inter-clase baja y una alta variabilidad intra-clase como consecuencia de cambios abruptos en gradientes medioambientales como la humedad, elevación o la temperatura y la presencia de alteraciones originadas por procesos ambientales o antrópicos (Ghimire et al., 2010; Rogan y Miller, 2006). En particular, la cartografía temática de áreas del Mediterráneo, a partir de imágenes de satélite, es especialmente

compleja debido a las características de las cubiertas de estas regiones (Lloyd et al., 2004). Las cubiertas mediterráneas tienen un comportamiento espectral parecido (baja separabilidad inter-clase), a lo que hay que sumar una estructura espacial del paisaje compleja, que presenta una gran variabilidad de patrones espaciales, altamente fragmentados. La baja separabilidad inter-clase de las regiones mediterráneas es una consecuencia directa del clima y de las características de las cubiertas de estas regiones. La escasez de recursos hídricos hace abundante la presencia de suelos desnudos, normalmente calcáreos de tonos muy claros, con una alta reflectividad que puede enmascarar la componente reflejada por la vegetación y hacerla imperceptible e indiferenciable de otras cubiertas de alta reflectividad como las áreas urbanas. Por tanto, la exactitud cartográfica con la que las áreas urbanas, suelos y cubiertas de vegetación no densa (ej. olivares), pueden ser espectralmente separadas es baja (Berberoglu et al., 2007; Berberoglu et al., 2000).

Para incrementar la separabilidad entre clases espectralmente similares se pueden adoptar diferentes aproximaciones. Por un lado, es posible añadir información sobre el estado fenológico de las cubiertas vegetales, por medio de la incorporación de imágenes multi-estacionales. También se pueden incluir variables auxiliares que describan gradientes ambientales que mejoren la caracterización de las cubiertas: temperatura, modelos digitales del terreno, humedad... La caracterización de la variabilidad espacial en estas imágenes, a través de medidas texturales, proporciona información importante sobre la disposición de los objetos y sus relaciones espaciales dentro de la imagen. En definitiva, para la clasificación de las cubiertas y usos del suelo se pueden utilizar un gran número de variables auxiliares. Sin embargo, no es posible construir modelos de forma operativa a partir de un volumen muy elevado de datos, debido a limitaciones computacionales y por otro lado, el uso de un elevado número de variables puede ocasionar una disminución en la exactitud de los clasificadores debido al efecto Hughes (Bellman, 2003; Pacifici et al., 2009). Por tanto, la selección de las variables más apropiadas para clasificar unas determinadas cubiertas merece una consideración especial para ser investigada.

La mayor parte de las aplicaciones de cartografía de cubiertas y usos del suelo sólo usan imágenes de satélite como variables de entrada a la clasificación (Dixon y Candade, 2008; Oetter et al., 2001; Yuan et al., 2005a). A partir de los últimos años es cada vez más frecuente el uso de variables auxiliares para mejorar el proceso de clasificación (Franklin, 1998; Rogan et al., 2008; Rogan et al., 2003; Watanachaturaporn et al., 2008). Los resultados de estudios de cartografía de cubiertas y usos del suelo indican que incluir variables no-espectrales en el proceso de clasificación ayuda a mejorar la discriminación de las clases temáticas y consecuentemente, dar como resultado mapas más exactos (ej. 5-10%) (Franklin, 1995; Rogan et al., 2003; Watanachaturaporn et al., 2008; Wright y Gallant, 2007). Diversos estudios muestran que la combinación de imágenes multi-estacionales permiten una mejor distinción de determinadas cubiertas (Lunetta y Balogh, 1999b; Oetter et al., 2001; Wolter et al., 1995; Yuan et al., 2005a). Adicionalmente, otros estudios de cartografía de cubiertas y usos del suelo han demostrado que incluir variables texturales proporciona información adicional al proceso de clasificación para mejorar la exactitud de la cartografía (Agüera et al., 2008; Asner et al., 2002; Chan et al., 2003; Chica-Olmo y Abarca-Hernández, 2000; Franklin et al., 2000; Johansen et al., 2007).

Otro aspecto fundamental para la cartografía de áreas complejas es la elección de una metodología de clasificación adecuada. La clasificación de este tipo de áreas requiere de metodologías que sean exactas y a su vez operativas, interpretables, transparentes y con alto grado de automatización. Sin embargo, en la mayoría de los casos, la elección del algoritmo de clasificación depende de la disponibilidad de software, la facilidad de uso y la facilidad en la interpretación de sus resultados. La elección de la metodología de clasificación, también debe considerar los posibles errores en los datos de teledetección y las variables auxiliares (Lunetta et al., 1991; Xiaolong y Khorram, 1998). La principal fuente de error es el “ruido” que incorporan los datos a los modelos de clasificación como consecuencia de errores posicionales de las variables independientes (ej. variables espectrales y modelos digitales del terreno). Los errores en la georreferenciación de estas variables hacen que se produzcan

desplazamientos y por tanto que las diferentes capas de entrada no se superpongan exactamente. Otra fuente de ruido ligada a errores posicionales se debe a una deficiente localización de los datos de referencia usados para entrenar los algoritmos de clasificación y validar la exactitud de los mapas producidos (Foody, 2002). Por otro lado, pueden producirse error(es) de medida causados por la interpretación errónea de los datos de campo de referencia o de ortofotografías (Franklin et al., 2001; Lippitt et al., 2008; Rogan et al., 2008). Por último, una fuente de errores frecuente es la presencia de ruido debido a deficiencias en la medida de las variables de entrada, como saturación de la señal recibida por el satélite, líneas perdidas o escaneadas erróneamente, error en el procesado de datos, etc. Por todo lo expuesto anteriormente, la elección de un método de clasificación adecuado para la cartografía de áreas complejas, depende de la capacidad del método para manipular datos con presencia de ruido y espacios de medida complejos (DeFries y Chan, 2000; Rogan et al., 2008).

Existe una amplia gama de algoritmos que han sido usados para la clasificación de cubiertas y usos del suelo, así como para la cartografía de cambios, a partir de datos de teledetección. Estos van desde algoritmos no supervisados, a paramétricos supervisados como el de máxima probabilidad (Jensen, 2005), o algoritmos no paramétricos de aprendizaje automático. Diversos estudios han demostrado que los algoritmos de aprendizaje de máquinas (machine learning) son más exactos que las técnicas de clasificación tradicionales como la de máxima probabilidad (Murthy et al., 2003; Pal, 2005; Pal y Mather, 2003; Seto y Liu, 2003). La superioridad de los algoritmos de aprendizaje de máquinas se debe a su naturaleza no paramétrica, ya que las cubiertas que presentan una variabilidad intra-clase alta, normalmente, no siguen una distribución normal.

El Aprendizaje Automático o Aprendizaje de Máquinas es una rama de la Inteligencia Artificial cuyo objetivo es desarrollar técnicas que permitan aprender. De forma más concreta, se trata de crear algoritmos capaces de generalizar comportamientos a partir de una información no estructurada suministrada en forma de ejemplos. Es, por lo tanto, un proceso de inducción del conocimiento. En muchas

ocasiones el campo de actuación del Aprendizaje Automático se solapa con el de la Estadística, ya que las dos disciplinas se basan en el análisis de datos. Sin embargo, el Aprendizaje Automático se centra más en el estudio de la Complejidad Computacional de los problemas (Sierra-Araujo, 2006).

El aprendizaje automático es un campo de la ciencia relativamente nuevo y en continuo desarrollo. En las últimas décadas han surgido un gran número de metodologías de clasificación para la generación de cartografía temática (Tso y Mather, 2009; Wilkinson, 2005). Entre las más usadas se encuentran los árboles de clasificación (Breiman, 1984), redes neuronales artificiales (Mas y Flores, 2008), máquinas de vectores soporte (Mountrakis et al., 2011) y los clasificadores de conjunto (Breiman, 1996; Chan y Paelinckx, 2008). Estas metodologías parten de bases conceptuales muy diversas y su aplicación es en ocasiones compleja. La exactitud de los modelos inducidos mediante métodos de autoaprendizaje depende fuertemente de la combinación de parámetros empleados. Por tanto, existe la necesidad de estudiar en profundidad el impacto de la parametrización interna de estos algoritmos para la clasificación de cubiertas y usos del suelo, en especial, en el caso de aquellas metodologías que, dada su novedad, su aplicación en la clasificación de datos de teledetección se encuentra en un estado incipiente. Sólo una vez que se ha realizado un estudio detallado de la parametrización interna de estas técnicas de aprendizaje de máquinas, es posible la determinación de que metodologías son más idóneas para la clasificación de datos de teledetección, en términos de su exactitud cartográfica, sensibilidad al ruido y al tamaño de los datos de entrenamiento y de su capacidad de aprender a partir de un volumen elevado de variables y de generalización.

## **1 Antecedentes**

La necesidad creciente de información sobre las cubiertas del suelo y sus dinámicas, junto con el desarrollo y evolución de los satélites de observación de la Tierra, han dado origen a numerosas iniciativas y proyectos de cartografía en los

últimos años. El objetivo de estos proyectos es el desarrollo de mapas de cubiertas del suelo a partir de datos de teledetección, tanto a nivel global como regional (Giri et al., 2005; Neumann et al., 2007; Pérez-Hoyos y García-Haro, 2009). Este tipo de productos son una herramienta esencial en la planificación territorial, gestión sostenible de los recursos y en estudios de diferente naturaleza, como el estudio del cambio climático, la determinación de indicadores ambientales, la evaluación de ecosistemas y biodiversidad y el modelado medioambiental (Giri et al., 2003; Giri et al., 2005; Loveland et al., 1999). El desarrollo de estas iniciativas ha sido dirigido por diversos programas nacionales e internacionales, y la variedad de estándares en la cartografía refleja el amplio rango de intereses, necesidades y metodologías de los diferentes programas (Herold et al., 2006). Como resultados de estas acciones destacan: la base de datos global de cubiertas del suelo para el año 2000 (GLC2000) (Bartholomé y Belward, 2005; JCR, 2010), la base de datos europea CORINE2000 (*Coordination of Information on the Environment*) (EEA, 2010), la base de datos global de cubiertas del suelo de MODIS (Friedl et al., 2002b; MLCG, 2009) y el proyecto GLOBCOVER (ESA, 2010; Herold et al., 2006).

El *Joint Research Center* (JCR) de la Comisión Europea, junto con más de 30 instituciones de todo el mundo, implementó el proyecto GLC-2000, a partir de datos de SPOT (Bartholomé y Belward, 2005). El objetivo principal de GLC-2000 fue preparar una base de datos armonizada de las cubiertas del suelo a nivel mundial para el año 2000, fundamentalmente para que sirviera de soporte para los programas internacionales de evaluación del medio ambiente como *Millennium Ecosystem Assessment* (MA) y las convenciones de Naciones Unidas relacionadas con la gestión de ecosistemas. La base de datos de cubiertas del suelo de MODIS fue creada por la Universidad de Boston (Friedl et al., 2002b). La base de datos de cubiertas del suelo de MODIS se llevó a cabo bajo la supervisión del equipo de ciencias de la tierra del Sistema de Observación de la Tierra de la NASA (EOS). Ambas iniciativas, GLC200 y el producto de cubiertas del suelo de MODIS, parten de fuentes de datos, esquemas de clasificación y metodologías diferentes. Sin embargo, comparten la misma

resolución espacial (1km) y el mismo objetivo fundamental: mejorar el entendimiento de la extensión y distribución de los principales tipos de cubiertas del mundo.

La base de datos global más reciente es GLOBCOVER, obtenida a partir de datos de ENVISAT-MERIS para el año 2005. Su objetivo principal es servir de base para la creación de iniciativas emergentes y fomentar metodologías comparables para la creación de mapas de las cubiertas del suelo (Herold et al., 2006). Las claves del éxito de GLOBCOVER radican en la resolución espacial mejorada de sus datos, 300 m (comparados con la resolución de 1km de los mapas existentes) y en la premisa de desarrollar productos cartográficos a partir de bases de datos actuales y utilizando una leyenda armonizada, cuyo desarrollo se basa en clasificadores comunes a las cubiertas, en lugar de categorías (ej. tipos de usos del suelo: urbano o agrícola; densidad de vegetación; o tipo de hoja). Desde una perspectiva europea, se espera que GLOBCOVER complemente y amplíe las dos iniciativas principales de cartografía global, CORINE y GLC2000 (Neumann et al., 2007).

Todas estas cartografías de escala global son productos derivados de imágenes que provienen de diferentes sensores, por tanto, se parte de datos con características espaciales, temporales y espectrales diversas. La resolución espacial de las mismas es igual a 1 km para GLC2000 y MODIS, 300 m para GLOBCOVER (MERIS-FR) y 250 m (1:100.000) para CORINE. Los datos de GLC corresponden a un periodo comprendido entre 1999 y 2000, GLOBCOVER se basa en datos del 2005 y 2006 y CORINE está disponible para las fechas ambas fechas (2000 y 2006). El producto de cubiertas del suelo de MODIS es el que mayor frecuencia temporal ofrece, ya que se ha venido generando dos veces al año a partir de un año después del lanzamiento de la plataforma TERRA. Respecto al sistema de clasificación, GLC2000 y GLOBCOVER utilizan el sistema LCCS (*Land cover classification system*) desarrollado por la FAO (*Food and Agriculture Organization*) y la UNEP (*United Nations Environment Programme*) (Di Gregorio y Jansen, 2000), el producto de MODIS utiliza el sistema desarrollado por el IGBP (*International Geosphere-Biosphere Programme*) (Loveland y Belward, 1997), mientras que CORINE utiliza un sistema jerárquico, de 44 clases organizado en 3 niveles. Los algoritmos de clasificación empleados en la generación



de estos productos van desde técnicas de fotointerpretación en el caso de CORINE, hasta técnicas digitales de clasificación, tanto supervisadas como no supervisadas para el resto de productos cartográficos (GLC, GLOBCOVER y MODIS). La complejidad de las leyendas es variable, así MODIS presenta 17 clases, GLC 23, CORINE 44 y la clasificación más exhaustiva, es la de GLOBCOVER con 51 clases.

Desde un punto de vista nacional, cabe destacar el proyecto SIOSE (Sistema de Información sobre Ocupación del Suelo de España) enmarcado dentro del Plan Nacional de Observación del Territorio en España (PNOT), que coordina y gestiona el Instituto Geográfico Nacional (IGN) y el Centro Nacional de Información Geográfica (CNIG). El objetivo del SIOSE es integrar la información de las bases de datos de coberturas y usos del suelo de las Comunidades Autónomas y de la Administración General del Estado (IGN, 2005).

Con anterioridad a la fecha de inicio del proyecto SIOSE, la Consejería de Medio Ambiente (CMA), en el año 1987, inició un proyecto para la cartografía de usos y coberturas vegetales de Andalucía (CMA, 2010). A partir de esta fecha la CMA ha elaborado diferentes cartografías de usos del suelo con una periodicidad de entre 3 y 4 años hasta su versión más reciente por el momento, correspondiente al año 2006. Desde su inicio los objetivos del proyecto han cambiado y se han ido haciendo progresivamente más ambiciosos de forma que en la actualidad se han ampliado la escala final del mapa y las fuentes básicas y auxiliares de información para adaptarse a los objetivos del proyecto SIOSE. En un primer período la escala de los mapas de usos del suelo fue 1:50.000, ya que los mapas se generaban casi exclusivamente a partir de imágenes del satélite Landsat. A partir de 1999, con la adquisición de un vuelo fotogramétrico de resolución espacial de 1m, fue posible realizar tareas de fotointerpretación para ampliar la escala de trabajo a 1:25.000. En la actualidad, el proceso de producción de la cartografía de usos del suelo y coberturas vegetales de Andalucía es básicamente un proceso de actualización cartográfica de la versión inmediatamente anterior, basándose en la misma geometría y en la fotointerpretación de composiciones en color de imágenes de satélite y ortofotografías actuales. La cartografía de usos del suelo basada en fotointerpretación requiere de un coste

humano y temporal muy alto y está sujeta a la subjetividad del fotointérprete. Por tanto, es necesario el desarrollo de metodologías que ayuden a automatizar el proceso de cartografiado, y que a la vez garanticen un nivel de exactitud cartográfica aceptable. La disponibilidad de datos de satélite con características de resolución espacial, espectral, geométrica y radiométrica mejoradas, así como de variables auxiliares (MDTs, imágenes térmicas, textura...), datos de verdad terreno, y algoritmos de clasificación cada vez más potentes, ofrece nuevas posibilidades para la generación de cartografía de las cubiertas del suelo que deben ser investigadas.

## **2      Objetivos**

El objetivo final de este trabajo es avanzar en el desarrollo de una metodología precisa y operativa para la cartografía de las cubiertas de la Provincia de Granada, mediante la aplicación de técnicas de Teledetección, Inteligencia Artificial y Geostatística. Para ello, se definieron a su vez una serie de objetivos parciales, entre los que destaca la evaluación de diferentes algoritmos de clasificación basados en aprendizaje de máquinas, la incorporación de nuevas variables ambientales auxiliares en el proceso de clasificación y la integración del análisis de la variabilidad espacial de las imágenes de satélite. Estos objetivos parciales pueden resumirse en los siguientes apartados:

Evaluación de diferentes metodologías de Inteligencia Artificial (aprendizaje de máquinas) en la clasificación de las cubiertas de la Provincia de Granada. Entre los algoritmos de clasificación evaluados se encontraron clasificadores basados en árboles de decisión simples o en conjuntos de árboles de clasificación como Random Forest, Redes Neuronales Artificiales y Máquinas de Vectores soporte. Por otro lado, un objetivo importante de este trabajo fue la determinación de la parametrización óptima de las citadas metodologías y el análisis de su sensibilidad frente a variaciones en los datos de entrenamiento (presencia de ruido y variaciones en el tamaño de los datos).

Evaluación de diferentes metodologías de aumento de la resolución espacial de imágenes de satélite basadas en transformadas wavelet, métodos Bayesianos y Cokrigeaje. Así como su aplicación a un caso especial en el que la correlación entre bandas espectrales es baja, la banda térmica del satélite Landsat TM-5.

Extracción y/o incorporación en el sistema de clasificación de variables (características) ligadas a gradientes ambientales como: la humedad, temperatura, elevación, índices de vegetación... Así como la evaluación de su importancia relativa en el modelo de clasificación y en la clasificación de cada tipo de cubierta del área de estudio.

Comparación de metodologías de extracción de medidas texturales a partir de imágenes digitales basadas en geoestadística y en matrices de co-ocurrencia. Incorporación y evaluación de medidas texturales bi-estacionales mediante el uso de técnicas geoestadísticas.

La aplicación de transformaciones de las bandas originales de las imágenes de satélite incrementa drásticamente la dimensionalidad de los datos, lo cual puede afectar a la exactitud de los clasificadores. En este sentido, un objetivo de este estudio ha sido aplicar un clasificador novedoso (Random Forest) capaz de clasificar a partir de grandes volúmenes de datos y de seleccionar las características texturales más importantes para la clasificación del área de estudio.

Finalmente, se debe señalar que, una vez obtenidos los mapas clasificados, el objetivo último ha sido la localización, análisis post-clasificación y cuantificación de los cambios producidos en las cubiertas del área de estudio entre los años 1998 y 2004.

### **3 Organización de la memoria**

Esta tesis doctoral se compone de ocho capítulos. En un primer capítulo introductorio se presenta la temática general y se sitúa la tesis en el contexto de la clasificación de los usos y coberturas del suelo a partir de datos de Teledetección, así

como, se presentan los objetivos generales de este trabajo. El Capítulo 2 está dedicado a la presentación del área de estudio, y en él se describen el marco medioambiental y socio-económico de la Provincia de Granada. Asimismo se presentan de forma sucinta los datos utilizados. En este capítulo se describen además las principales fuentes de error presentes en las imágenes de satélite y las diferentes etapas necesarias para el procesamiento de datos de Teledetección, en especial, se hace referencia a métodos de corrección geométrica y radiométrica de imágenes de satélite. Entre estos últimos se incluyen métodos de corrección atmosférica relativos y absolutos, basados en técnicas de regresión y en códigos de transferencia radiativa que consideran atmosferas simuladas basadas en datos meteorológicos *in situ*, respectivamente.

Como capítulo final se exponen las conclusiones generales más relevantes de este estudio. El resto, son capítulos más metodológicos, que puesto que no utilizan métodos comunes, se ha optado por una estructura de tesis en la que se presenten de forma independiente en cada capítulo las siguientes partes: introducción, fundamentos, metodología, resultados y por último unas conclusiones específicas. A continuación se expone un resumen de los cinco capítulos restantes:

El Capítulo 3 está íntegramente dedicado a la clasificación temática de imágenes de satélite mediante técnicas de Inteligencia Artificial. En este capítulo se estudian algunas de las técnicas/algoritmos de aprendizaje de máquinas más novedosas que pueden ser aplicadas a la clasificación de las cubiertas del suelo de la Provincia de Granada. Para lo cual es llevado a cabo un análisis comparativo desde diferentes perspectivas: la exactitud cartográfica de las clasificaciones, las necesidades de parametrización de cada técnica y, por último, la sensibilidad al ruido y a la reducción de los datos de entrenamiento.

El Capítulo 4 describe diversas técnicas para el aumento de resolución espacial de imágenes de satélite (*downscaling*). El Capítulo 5 parte de los resultados del capítulo anterior para aplicar una metodología de *downscaling* a la banda térmica del sensor Landsat TM5 para igualar su resolución espacial a la del resto de bandas multi-

espectrales y hacer posible su inclusión en los modelos de clasificación. Por último, en este capítulo se evalúa la aportación de la información térmica a la clasificación de las cubiertas del suelo de la Provincia de Granada.

El Capítulo 6 está dedicado al análisis espacial de las imágenes de satélite, a partir del cual se derivan nuevas variables de información que recogen diferentes medidas texturales aplicadas a las bandas de las imágenes de satélite. De forma complementaria se expone una metodología novedosa para la selección de las variables texturales más importantes para la clasificación (selección de características).

Finalmente, en el capítulo 7, se describen las principales técnicas de detección y análisis de cambios en las cubiertas del suelo a partir de datos de teledetección. Además, en este capítulo se lleva a cabo la localización, análisis post-clasificación y cuantificación de los cambios producidos en las cubiertas del área de estudio entre las clasificaciones realizadas para los años 1998 y 2004.

# CAPÍTULO 2.

## Área de Estudio y Datos

### **1 Área de estudio**

#### **1.1 Localización geográfica y fisiografía**

La provincia de Granada, con una extensión de 12.635 km<sup>2</sup>, pertenece a la comunidad autónoma de Andalucía. Se localiza al sureste peninsular, a orillas del mar Mediterráneo y en plena cordillera Penibética. Administrativamente se divide en 168 municipios agrupados en 10 comarcas (Figura 2.1), denominadas: Huéscar, Baza, Guadix, Iznalloz, La Vega, Valle de Lecrín, La Costa, Las Alpujarras, Montefrío y Alhama.

Desde el punto de vista del relieve, cabe destacar, que la provincia de Granada se encuentra situada en el sector más prominente de las Cordilleras Béticas, por lo que posee una elevada altitud media y un claro predominio de los espacios de montaña (Figura 2.2 y Figura 2.3). Además, la existencia de una serie de cuencas intramontañosas que recorren la provincia desde el oeste al noreste, así como la estrecha fachada litoral, determinan importantes contrastes topográficos y climáticos.



(Mulhacén, 3481 msnm), actúa como barrera entre las tierras llanas del interior y el Mediterráneo, existiendo un único pasillo natural, el Valle de Lecrín. En esta cordillera se distinguen dos alineaciones montañosas, Sierra Nevada y la cadena litoral, en contacto con las depresiones del norte y el litoral. Esta última está formada por (de oeste a este): las sierras de Tejeda, Almirajara, Cázulas, Lújar y Contraviesa. La última unidad de relieve se corresponde con el litoral. Se trata de una cosa alta y abrupta en donde se insertan escasos espacios llanos. La pequeña fachada litoral constituye así una estrecha llanura formada por pequeños deltas o retazos de plioceno adosados a la montaña, entre los que se interponen zonas acantiladas de naturaleza calizo-dolomítica o esquistosa.

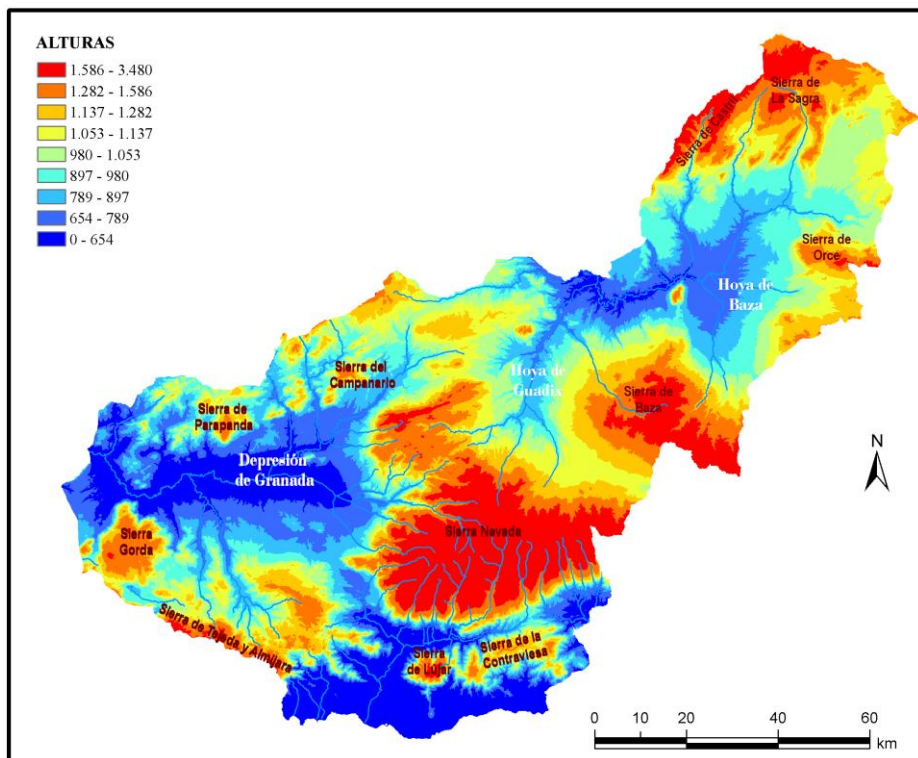


Figura 2.2. Distribución de alturas de la provincia de Granada. Fuente: Mapa Digital de Andalucía (1999), Consejería de Obras públicas y Transportes. Junta de Andalucía, Sevilla.



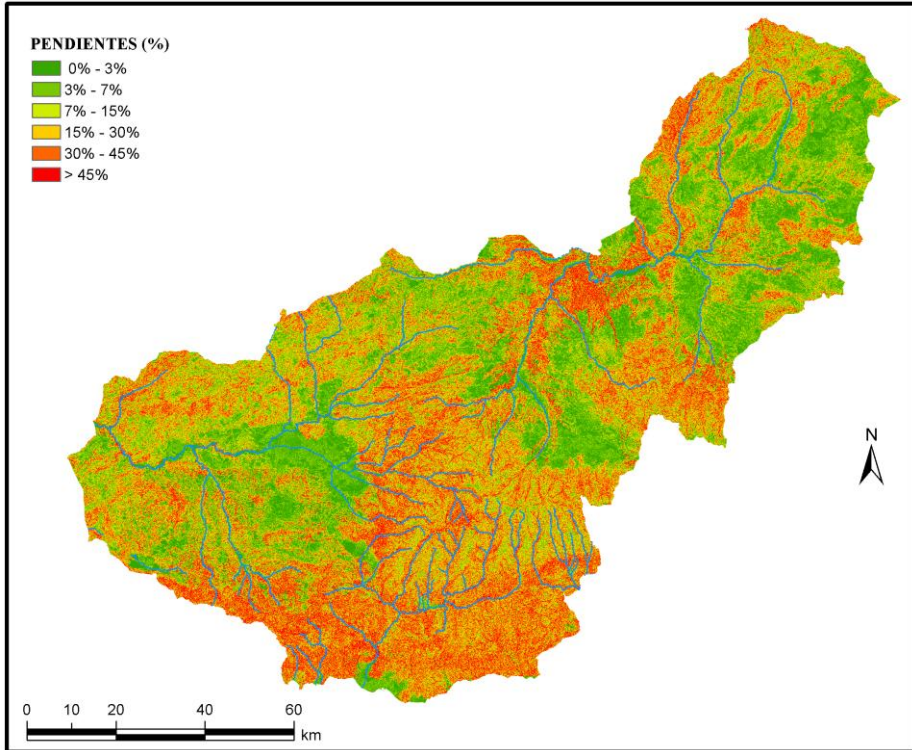


Figura 2.3. Mapa de pendientes de la provincia de Granada.

## 1.2 Geología y litología

La gran complejidad geológica es una de las particularidades que se manifiestan en la tortuosa orografía, variada climatología y diversidad de suelos y hábitats de la provincia de Granada. La estructura geológica del relieve de la provincia es el resultado de los movimientos de placas ocurridos durante el Terciario entre las placas ibérica y africana (Orogenia Alpina).

Desde el Lías y hasta el Mioceno superior, se produce un levantamiento de la península ibérica emergiendo diferentes alineaciones montañosas y áreas deprimidas de las que progresivamente se iría retirando el mar. La concretización del relieve se produjo durante la neotectónica cuaternaria en la que se produce el encajamiento de la

red hidrográfica y se individualizan las tres unidades morfoestructurales principales: Sierra Morena, Depresión del Guadalquivir y Cordilleras Béticas (Sanz de Galdeano y Vera, 1992), en esta última es donde se localiza la provincia de Granada.

Las Cordilleras Béticas constituyen un vasto conjunto de alineaciones montañosas en disposición casi paralela, y con una orientación general SO-NE, que se extienden por el sur de la península Ibérica desde Gibraltar hasta Alicante. Estas alineaciones se subdividen de norte a sur en Zonas Externas que comprenden a la cordillera prebética y subbética: antiguo borde continental de la placa ibérica; y Zonas Internas que comprende a la cordillera penibética: dominios pertenecientes a la placa africana (Figura 2.4).

Las Zonas Externas constituyen la cobertera sedimentaria del margen sudibérico, plegada y despegada de su zócalo. El nivel de despegue corresponde a los materiales del Trias (de facies germánica) de manera que la cobertera está formada por materiales triásicos, jurásicos, cretácicos y terciarios (hasta el Mioceno inferior), mayoritariamente sedimentarios. El zócalo no aflora en ningún punto, pero por los datos de sismica se conoce que es la prolongación hacia el sur del macizo hercínico de la Meseta y que se sitúa a una profundidad media de 3-4 km, hundiéndose progresivamente hacia el sur (Vera, 1994).

Dentro de las Zonas Externas, se diferencian dos grandes unidades (Prebético y Subbético). El Prebético sería la parte del margen continental adyacente al antiguo continente, que en Granada aflora en el margen noreste de la provincia y se caracteriza por el dominio de facies marinas someras. El Subbético se caracteriza por el dominio de las facies pelágicas (desde el Lías superior) y aflora en el noroeste de la provincia.

La estructura de las Zonas Externas es la de una cobertera plegada y desplazada hacia el NNW. Los límites de dominios paleogeográficos en gran parte coinciden con la posición de los frentes de los cabalgamientos de manera que en gran parte las unidades geológicas que se pueden diferenciar coinciden con los dominios paleogeográficos. Los materiales que han sufrido menor desplazamiento son los más

cercanos al antiguo continente (Prebético) en los que la deformación se limita a unas escamas y pliegues fallas vergentes hacia el continente. Los materiales del Dominio Intermedio y los del Subbético cabalgan ampliamente hacia el NW, superponiéndose tectónicamente a materiales de dominios más septentrionales. En algunos sectores la vergencia de las estructuras es contraria, mostrando una cierta simetría. Mediante reconstrucciones palinspásticas (López Garrido et al., 1989; Vera, 1986) se ha calculado que el acortamiento de la cobertera durante la colisión continental ha sido del orden del 70%, de manera que la anchura del margen sería unas tres veces superior a la anchura actual de afloramiento de las Zonas Externas.

Las Zonas Internas afloran al sur de la provincia configurando el relieve de Sierra Nevada y las Alpujarras. Estas zonas están constituidas por un apilamiento de mantos con rocas metamórficas en el que se distinguen tres complejos; en sentido ascendente: Nevado-Filábride, Alpujárride y Maláguide.

El Complejo Nevado-Filábride aflora extensamente en el núcleo del gran antiforme de Sierra Nevada y su continuación hacia el este (sierra de Filabres) y está constituido por rocas metamórficas agrupadas en dos grandes mantos de corrimientos superpuestos (Veleta y Mulhacén) (Fontboté, 1986). Litológicamente dominan los micaesquistos grafitosos y los micaesquistos feldespáticos y en segundo lugar los mármoles; más localmente afloran, también, anfíbolitas y ortogneisses. La edad de los materiales es muy difícil de estimar dada la ausencia de fósiles casi general, aunque se cree muy probable que fuesen paleozoicos y triásicos, sin descartar la presencia de materiales precámbricos.

El Complejo Alpujárride está compuesto por un conjunto de mantos de corrimiento superpuestos, constituidos por materiales que presentan un metamorfismo alpino bastante manifiesto en los términos inferiores y menos acentuado (incluso ausente) en los superiores. En las unidades alpujárrides se suelen diferenciar tres formaciones: la inferior (Paleozoico), muy potente, formada por esquistos y micaesquistos, la segunda (Pérmico-Triásico inferior) de un centenar de metros de

espesor constituida por filitas y cuarcitas y la tercera, también muy potente, formada por calizas y dolomias del Triásico medio y superior.

El Complejo Maláguide aflora en la provincia en una pequeña extensión en el contacto norte de las Zonas Internas. Al contrario que en los dos complejos anteriores, el Complejo Maláguide presenta (aunque solo muy localmente) términos del Jurásico, Cretácico y Terciario con fósiles. Los afloramientos más extensos corresponden al Paleozoico en los que se diferencian: una unidad basal de filitas y areniscas (Ordovícico-Silúrico), una intermedia de calizas y grauvacas (Silúrico-Devónico) y una superior de grauvacas, lutitas y conglomerados (Carbonífero). Los materiales del Pérmico y Triásico son discordantes sobre los anteriores y presentan facies detríticas rojas, con niveles de arcillas y de carbonatos, Los materiales más modernos afloran muy localmente y son calizos (Jurásico-Cretácico inferior), calizo-margosos (Cretácico superior), de calizas y conglomerados (Eoceno) y de margas y lutitas (Oligoceno).

La progresiva retirada del mar provocó la formación de diversas cuencas intramontañosas que se rellenaron de sedimentos del Mioceno, Plioceno y Pleistoceno producto de la erosión de los nuevos relieves. Las principales depresiones neógenas son: la Depresión de Granada, la Hoya de Guadix y la de Baza.

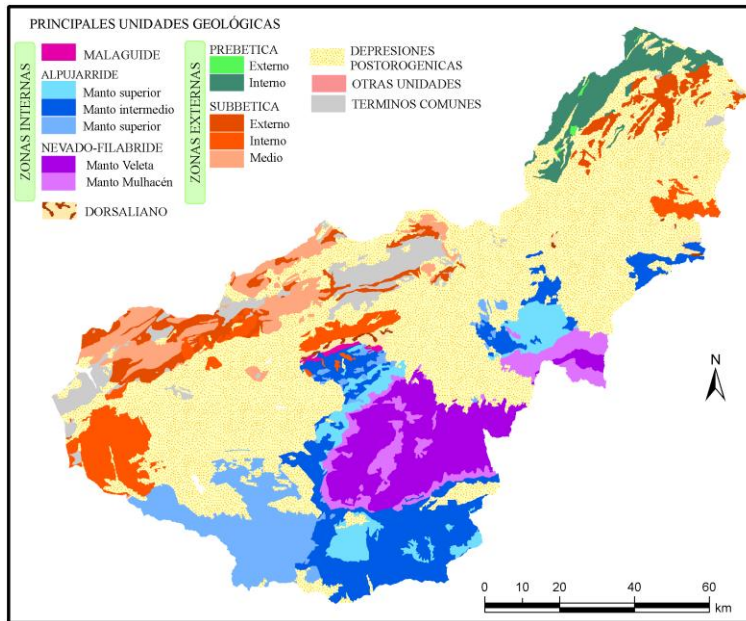


Figura 2.4. Principales unidades geológicas de la provincia de Granada

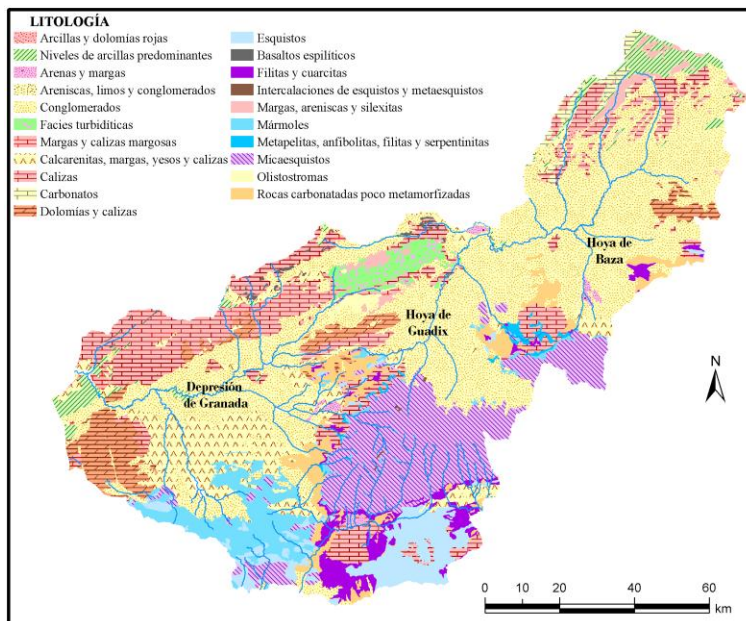


Figura 2.5. Litología de la provincia de Granada. Modificado: Mapa Geológico de Andalucía.

### 1.3 Edafología

La formación de los suelos está condicionada por diversos factores, entre ellos la geología, la pendiente y la altura, así como las condiciones climáticas, lo que se traduce en un panorama edáfico heterogéneo. Estos factores intervienen en el proceso de formación de los suelos y de sus diferentes horizontes edáficos. Así, un suelo con mayor número de horizontes diferenciados será un suelo más maduro y al revés.

De este modo, en el mapa de suelos de Andalucía (1989) de la Consejería de agricultura y pesca reclasificado se representan 12 unidades edáficas entre las que encontramos suelos incipientes, hasta suelos maduros y rejuvenecidos por la erosión (Figura 2.6).

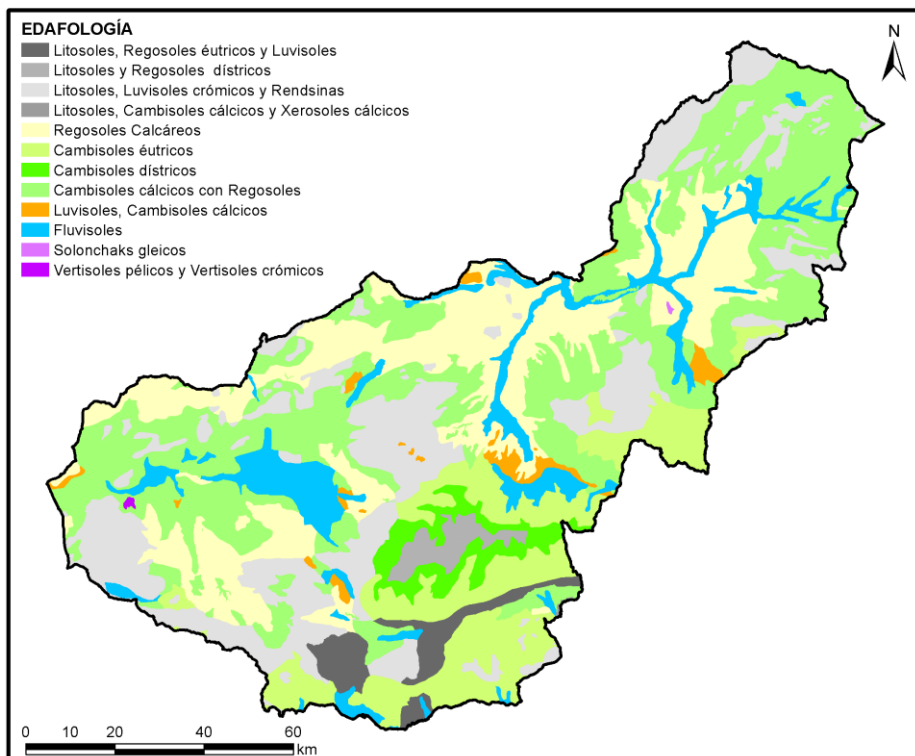


Figura 2.6. Mapa de suelos de Granada. Modificado de: Mapa de suelos de Andalucía (1989), IARA-CSIC

Los suelos menos desarrollados son los litosoles cuyo perfil se reduce a los horizontes A(C). En estos suelos hay pequeñas trazas de materia orgánica en los primeros 20 cm de suelo y no existe la alteración química. La localización de los mismos se sitúa en espacios abruptos de las sierras calizo-dolomíticas y las cumbres de Sierra Nevada. La característica más importante de los mismos es su constante rejuvenecimiento por efecto de la erosión. Estos suelos tienen un escaso recubrimiento vegetal, así los litosoles calizos son los más extendidos con un elevado contenido en carbonatos y los litosoles dístricos aparecen en Sierra Nevada, ligados a un sustrato silíceo y a un clima muy frío.

Otros suelos también poco evolucionados son los regosoles, con un perfil AC algo más complejo. El horizonte A es un horizonte humífero del tipo ócrico, que se caracteriza por ser demasiado delgado, con muy poco carbono orgánico o demasiado claro. Estos suelos aparecen sobre sedimentos limosos, arcillosos, margosos o conglomeráticos, en las principales depresiones de la provincia (Depresión de Granada, Valle de Lecrín, Baza y Guadix).

Los diferentes cambisoles se definen por constituir suelos más maduros que poseen un horizonte subsuperficial de alteración moderada, de modo que su perfil es el tipo ABC. Los cambisoles dístricos se caracterizan por tener un grado de saturación inferior al 50% (en  $\text{NH}_4\text{OAc}$ ) y se circunscriben a las laderas montañosas en torno al núcleo de Sierra Nevada. Son suelos climáticos que constituyen una verdadera reserva edáfica en la región y proceden de la degradación de cambisoles húmicos y phaeozems ápicos por pérdida o deterioro de la cubierta vegetal. En el horizonte más bajo que circunscribe a Sierra Nevada aparecen los cambisoles eútricos, En este ámbito, la potencialidad de diversos tipos de vegetación arbórea posibilita la existencia de suelos maduros, si bien estos se encuentran manipulados y modificados por el hombre. En zonas donde persiste el bosque autóctono, donde se ha reforestado el terreno o cuando permanece una cubierta vegetal relativamente protectora, los suelos mayoritarios son los phaeozems hápicos. Por el contrario, cuando las laderas han sido abancaladas y cultivadas es más abundante el cambisol eútrico. A veces el intenso manejo del suelo ha acelerado los procesos erosivos y éstos han evolucionado

a regosoles litosólicos. Los cambisoles cálcicos se desarrollan en las laderas carbonáticas que rodean a la Vega de Granada y en las laderas margosas de las sierras del este (Baza, Orce y Castril). Los cambisoles cálcicos constityen en general buenas tierras de labor aunque existen muchas variedades entre ellos. Pueden haberse generado sobre costras calizas en zonas de glacis, presentar un alto contenido en sales solubles y yesos o mostrar características vérticas. Estas características se definen por las grietas y cutanes de presión y por los deslizamientos que proliferan en las zonas limoarcillosas.

Los luvisoles, o suelos rojos mediterráneos, tienen un perfil evolucionado ABC con un horizonte argílico saturado en bases. Este tipo edáfico se presenta en las proximidades de las turberas del Padul, en las inmediaciones de Iznalloz y Caniles, al norte de Huéneja y a lo largo de la comarca del Marquesado del Zenete. Son suelos muy potentes, pero su impermeabilidad y baja retención de agua los hace deficientes desde el punto de vista agrícola.

Los fluvisoles son los suelos de vega y mayormente calizos. Se extienden por los márgenes de los ríos y ramblas de la provincia y por el fondo aluvial de la Vega de Motril, Guadix-Baza y la Vega de Granada. Son suelos profundos de depósitos aluviales recientes con un A ócrico o úmbrico como único horizonte de diagnóstico. Su perfil presenta una gran profundidad de suelo útil y su fertilidad los convierte en suelos muy antropizados.

Otros tipos edáficos que aparecen son los solochanks gleyco, con escasa representación espacial y perfil ABC. Son suelos con un horizonte sálico, el adjetivo gleyco hace referencia que se encuentran saturados en agua y por tanto con condiciones reductoras.

Por último, los vertisoles crómicos, también con escasa representación, de perfil A(B)C son suelos ricos en arcillas expansivas y son buenas tierras agrícolas.



### 1.4 Climatología

La situación de la provincia de Granada, respecto a los grandes centros de acción atmosférica, así como el fuerte contraste altitudinal, le otorgan a la provincia de Granada una amplia diversidad climática. La compartimentación del espacio por las diferentes cadenas montañosas afecta a los diversos factores que controlan el clima de la provincia, como son: los vientos húmedos del oeste, los vientos fríos del norte, las masas cálidas del Mediterráneo o la radiación solar; creando microclimas muy diferenciados en diferentes zonas. Así por ejemplo, las precipitaciones medias anuales pueden llegar a descender por debajo de los 300 mm en algunas zonas y ser superiores a 1000 mm en otras, y las temperaturas medias anuales se mueven entre los 18°C de la costa y los 3.3°C en Sierra Nevada (Figura 2.7, Figura 2.8, Figura 2.9, Figura 2.10).

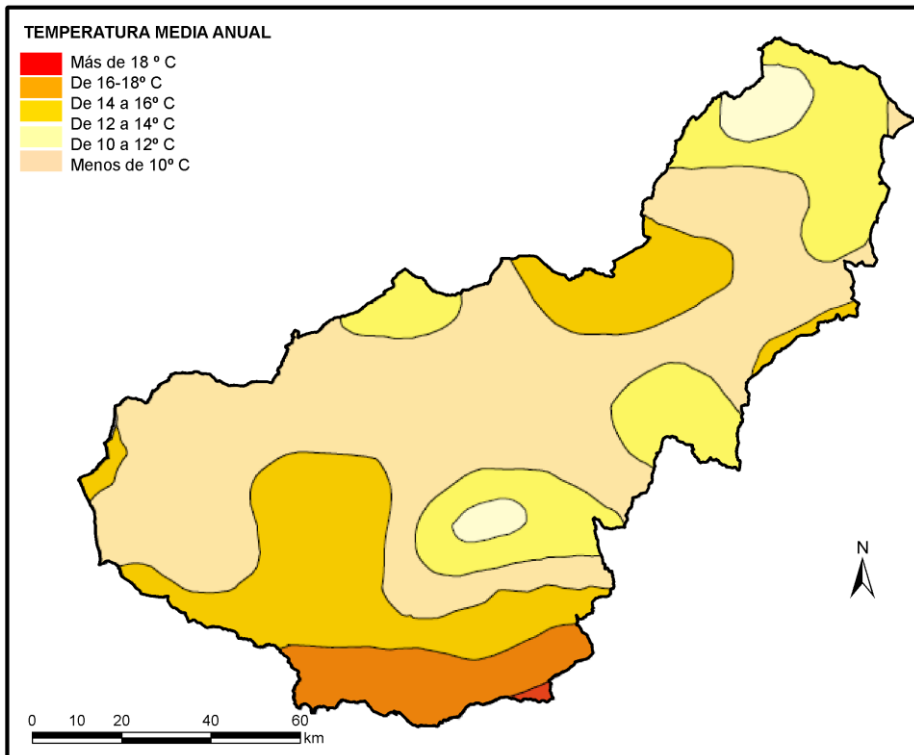


Figura 2.7. Mapa de la temperatura media anual. Fuente: Atlas climático de España (1983), Instituto de Meteorología, Madrid.

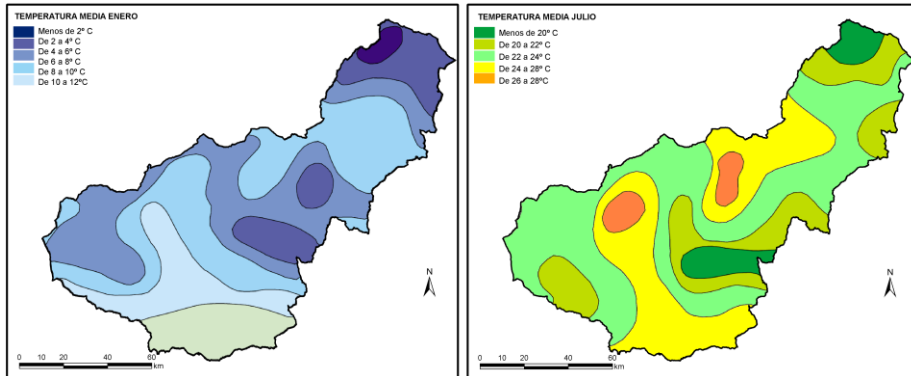


Figura 2.8. Mapas de la temperatura media de enero y julio. Fuente: Atlas climático de España (1983), Instituto de Meteorología, Madrid.

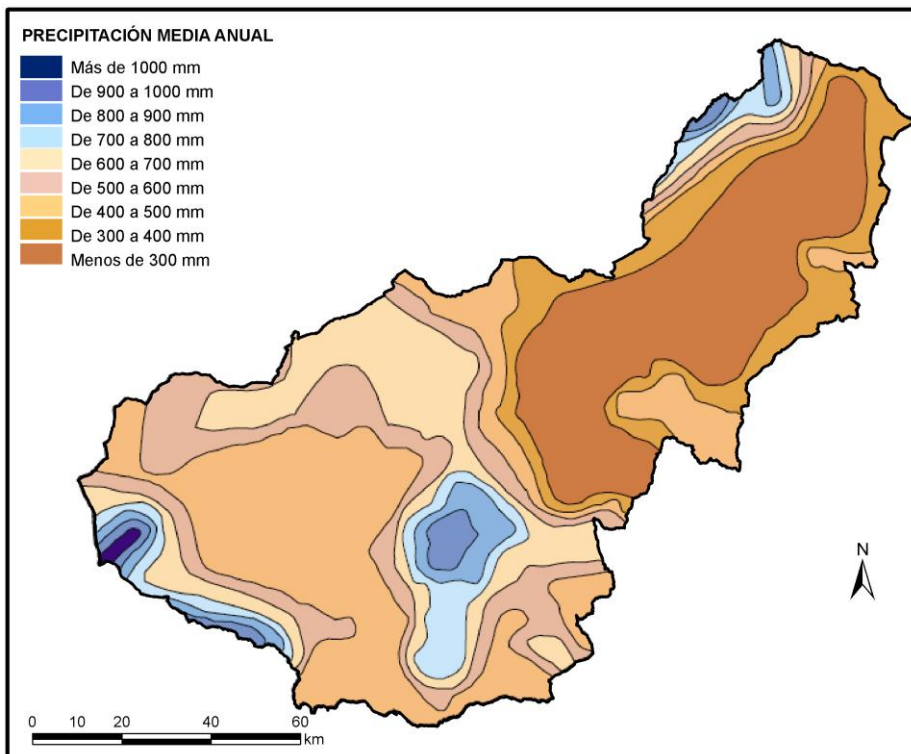


Figura 2.9. Mapa de precipitación de la provincia de Granada. Fuente: Atlas climático de España (1983), Instituto de Meteorología, Madrid

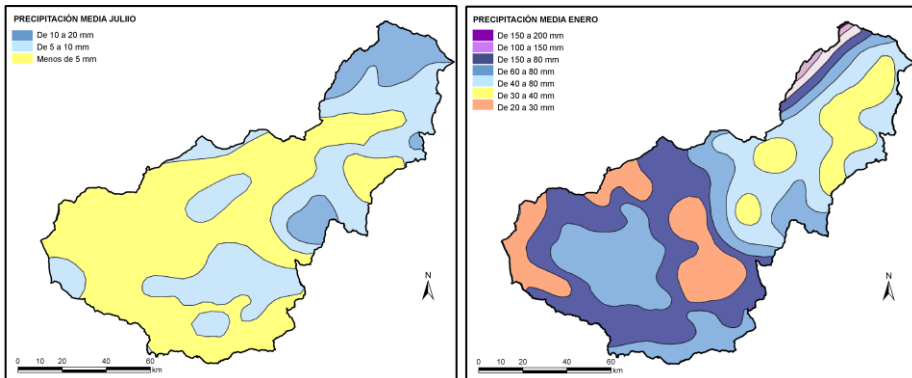


Figura 2.10. Mapas de precipitación de julio y enero de la provincia de Granada. Fuente: Atlas climático de España (1983). Instituto de Meteorología. Madrid.

Los principales tipos climáticos de la provincia están principalmente afectados por la influencia marítima, la altitud y la continentalidad. A continuación se describen las principales variedades climáticas de acuerdo al Atlas Temático de la Provincia de Granada (2003) (Figura 2.11).

El tipo climático más suave corresponde a la franja costera y se define como un tipo de clima mediterráneo subtropical. Las características de este clima penetran hacia el interior por el valle del Guadalfeo y parte del Valle de Lecrín. La templanza de este clima es debida a dos factores. Por un lado, la influencia del mar que por su acción termorreguladora propicia una escasa amplitud térmica. Por otro lado, el macizo montañoso de Sierra Nevada que ejerce de barrera física frente a los vientos fríos del norte. Por estos dos motivos, las laderas meridionales de las sierras Tejeda y Almijara, Lújar y Contraviesa, y la zona de la costa se incluyen dentro de unas zonas con inviernos muy cálidos y veranos muy calurosos. En el litoral granadino coinciden, además, unos volúmenes pluviométricos muy escasos que descienden paulatinamente hacia el este. El régimen pluviométrico muestra un máximo a final de otoño-invierno y un segundo máximo en primavera. Las lluvias que se caracterizan por una elevada torrencialidad que se registran en un escaso número de días, lo que implica un elevado promedio de horas de sol que se estima entre 2800 y 3000 al año. Esta escasez de

precipitaciones se incrementa hacia el límite oriental en donde acusa una degradación semiárida que la aproxima a la variante marítima subdesértica del litoral almeriense.

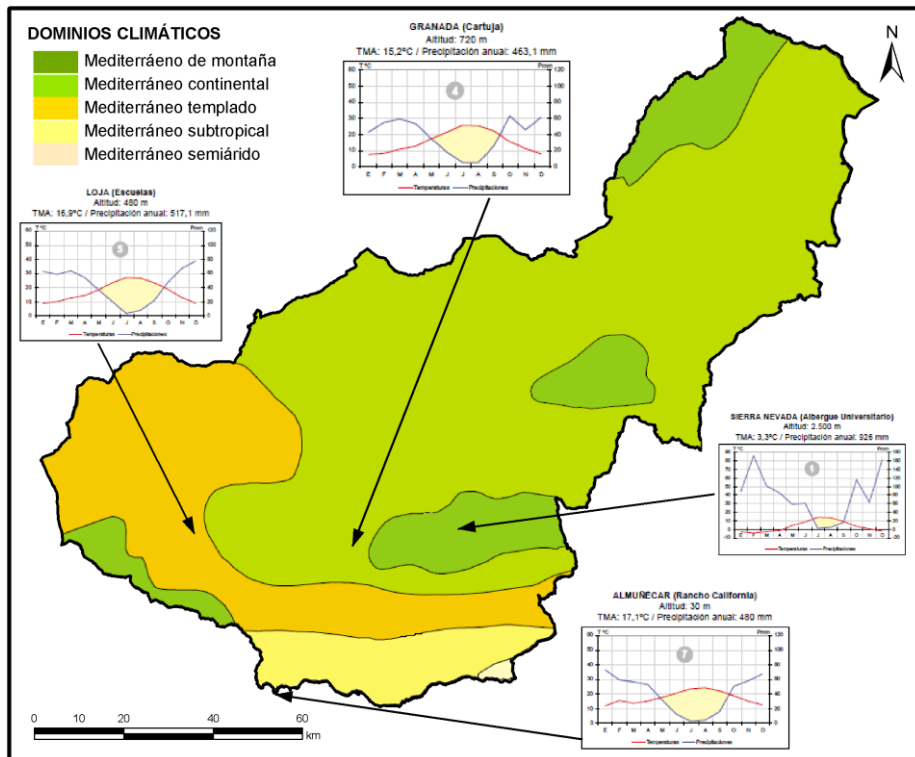


Figura 2.11. Principales dominios climáticos de la provincia de Granada.  
Fuente: Gran Atlas de España (1989), Planeta, Barcelona.

El segundo tipo climático es el mediterráneo templado de matiz continental, que ocupa la porción occidental de la provincia. Al no estar influido por el mar existen fuertes amplitudes térmicas anuales. Se habla de semicontinentalidad debido a que la región se encuentra expuesta a los vientos de Atlántico responsables de unos volúmenes pluviométricos que permiten clasificar a las tierras subbéticas como subhúmedas y a la depresión de Granada como seca. El verano es caluroso y seco y el invierno largo y frío, con mínimas por debajo de 0°C debido a la influencia de los

vientos fríos del Norte. La precipitación media anual oscila entre los 450-600 mm y se concentra a finales de otoño-invierno y en primavera.

La mayor parte del área de estudio correspondiente a la zona oriental de la cadena subbética y del surco intrabético se define como clima mediterráneo continental, más extremo que el anterior por estar más alejado de la influencia atlántica y abierto a los fríos del norte. Además, en esta zona existe una elevada altitud media que le otorga unos inviernos fríos y unos calurosos veranos. Así, las temperaturas medias de enero se sitúan por debajo de los 6°C, en Guadix y de los 3.9°C en Baza con frecuentes heladas entre noviembre y marzo. El verano es cálido, alcanzando en julio temperaturas medias de 25°C. Por otra parte, las precipitaciones son considerablemente bajas, con volúmenes medios de 299 mm en Guadix, o 382 mm en Baza. El reparto de las lluvias en el año hidrológico es muy semejante al de la depresión granadina, si bien aquí se acentúa aún más la importancia de las lluvias de primavera y los registros del verano son ligeramente superiores.

Por último, la variedad climática de montaña afectaría básicamente a las cumbres de Sierra Nevada, Almirajara, Arana, Baza, Castril, La Sagra, Guillimona, Tejeda y Almirajara y Sierra Gorda. En estas sierras los veranos son cortos y las temperaturas moderadas con precipitaciones escasas. Por el contrario, los inviernos se alargan (octubre a abril en el caso de Sierra Nevada) y son muy rigurosos. Las montañas se comportan además como islas húmedas y en algunos casos las precipitaciones pueden superar los 1000 mm en Sierra Nevada, Sierra Gorda y La Sagra. Por otra parte, el conjunto de espacios serranos componen un mosaico climático muy complicado con una amplia diversidad de tipos climáticos según el escalonamiento, solanas, umbrías y vertientes abiertas. En todos los casos, el frío limita el desarrollo vegetal y activa los procesos ligados al hielo-deshielo que afectan al modelado de vertientes y a la evolución de los suelos.

## **1.5 Usos del suelo**

La influencia del clima y el suelo en la vegetación es considerable, pero quizás el elemento más influyente en la provincia de Granada para la configuración del espacio vegetal es la presencia humana. El hecho más llamativo en la provincia de Granada es la gran extensión de terrenos agrícolas que a lo largo de los años se han ido ampliando a costa de la vegetación primigenia. Se observa, además, que los espacios ocupados por la vegetación natural son aquellos en los que el sustrato, lo extremado del clima o las dificultades de acceso, no han permitido una influencia humana tan extensa. De ahí, que en general, las montañas constituyan reservas para el desarrollo de diversos paisajes vegetales.

En los últimos años, cabe destacar también, la competencia del espacio agrícola con el crecimiento urbano, fundamentalmente en las áreas periurbanas. En determinadas zonas, como es el caso de la Vega de Granada, su estructura territorial vertebrada históricamente por la agricultura se ha visto intensamente modificada debido a la expansión urbanizadora. Este crecimiento urbano ha provocado una rápida transformación de los espacios tradicionalmente agrarios, poniendo en peligro el desarrollo sostenible (Menor-Toribio, 1997).

La distribución de las principales coberturas según el “Mapa de usos y coberturas de Andalucía” del 2003, se agrupan en: tejido urbano (1.99%), cultivos en secano (36.53%), cultivos en regadío (4.34%), mezcla de cultivos de regadío y secano (6.18%), matorral denso (12.53%), formaciones arboladas dispersas (1.06%), matorral sin arbolado (16.74%), espacios abiertos con poca vegetación (11.8%) y cursos y láminas de agua (8.75%).

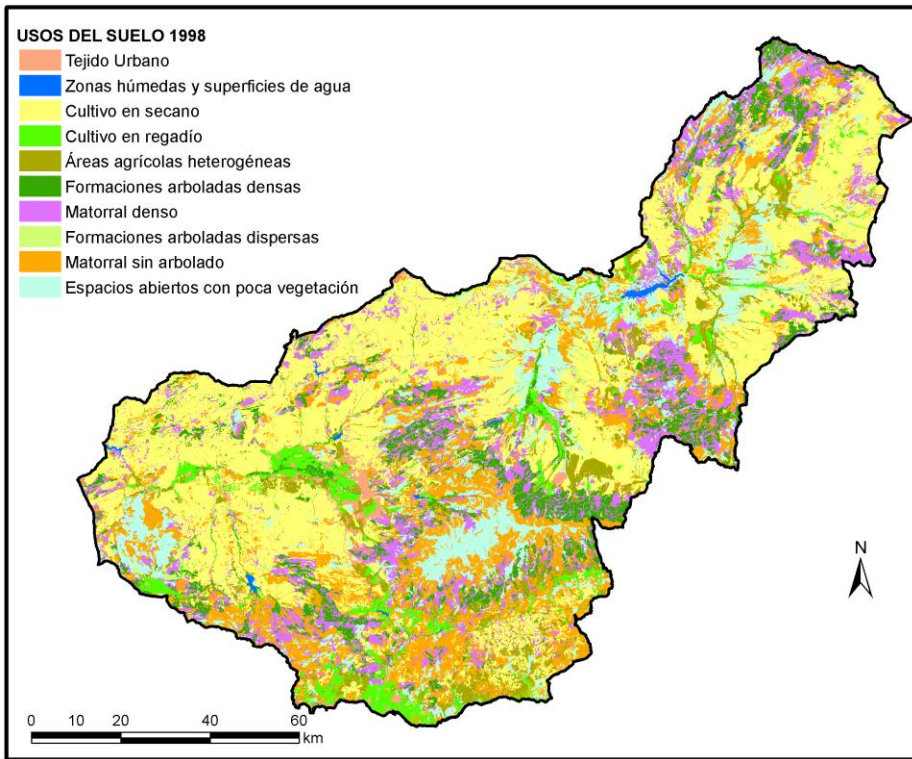


Figura 2.12. Mapa de usos del suelo de la provincia de Granada. Fuente: Modificado de “Mapa de usos y coberturas vegetales del suelo de Andalucía. Escala 1:10.000”

Entre la vegetación natural (Atlas temático de la provincia de Granada) de la zona cabe destacar las quercíneas, que aunque actualmente ocupan un 8% de la superficie provincial, debieron de constituir la vegetación dominante de la provincia debido a que su plasticidad ecológica les permite adaptarse a los distintos suelos y a las diferentes variedades termoclimáticas. Así, en la provincia la encina aparece desde los 200 m de las sierras de la costa hasta los 2000 m de altura en Sierra Nevada. Actualmente quedan pequeños bosquetes o rodales situados en las laderas medias de las montañas. Entre las quercíneas, los robles melojos constituyen pequeños bosques con un grado de conservación aceptable. En Sierra Nevada varios melojares adhesados ocupan los suelos más profundos de los barrancos y de las laderas especialmente húmedas. Los arconocales, por otra parte tienen escasa representación.

Por otra parte, las pináceas han sido muy favorecidos por la acción del hombre, tanto por su interés maderero como ambiental en reforestación de laderas. Desde el litoral hasta los 1.000 m de altura la especie más abundante es el pino carrasco. En posiciones más elevadas (hasta los 1.800 m) aparecen extensiones importantes de pinus alepensis y pinaster, así como pino silvestre en su variedad “nevadensis”. Así, los pinares constituyen el 36,6% del conjunto de la vegetación natural.

Los matorrales y pastizales, incluyendo la vegetación orófila de las cumbres más elevadas suponen un 46,1% de la vegetación natural. Este elevado porcentaje es resultado de la fuerte degradación que han sufrido las especies climáticas por efecto de la intervención humana. La mayoría de las especies de monte bajo corresponden a comunidades subseriales y entre las especies más comunes podemos encontrar: chaparrales arbustivos de escasa talla y gran diseminación, retarnares, aulagas o hiniestas, tomillares con lavandas, salvias y romero o formaciones esteparias de esparto. Sólo en las cumbres más elevadas de las sierras las comunidades de matorral y pastizal constituyen la vegetación climax entre los que se incluyen piornales, tomillares de altura y borreguiles.

La vegetación riparia o ribereña presenta un grado de transformación desigual según se trate de los cursos altos de los ríos o las extensos valles. Así, en las vegas aluviales es frecuente la eliminación de la formación original y la plantación de chopos, y en los cursos altos aún se conservan en muchos tramos en su estructura original especies como las olmedas, saucedas o alamedas, aunque en muchos otros aumente la densidad de la masa arbórea por plantación de especies originarias o cultivadas como el castaño.

Las superficies cultivadas y mixtas ocupan la mitad del espacio provincial. Los cultivos se sitúan en su gran mayoría en los terrenos de los pisos termo, meso y supramediterráneo, y especialmente con el dominio del área potencial del encinar. Así, casi la totalidad de los espacios llanos y alomados de las depresiones y pasillos intramontañosos constituyen terrenos agrícolas, e incluso muchas de las laderas silíceas.



### 1.6 Marco socioeconómico

Según el censo del Instituto Nacional de Estadística (INE), la población a 1 de enero de 2010 asciende a 918.072 habitantes. La distribución de la densidad de población por municipios refleja una mayor concentración de la población en la capital y área metropolitana (La Vega), así como a la zona de La Costa. Esta distribución está ligada las a áreas económicamente más productivas. Las zonas de menor densidad de población son principalmente los municipios pertenecientes a Huéscar y Alhama (Figura 2.13).

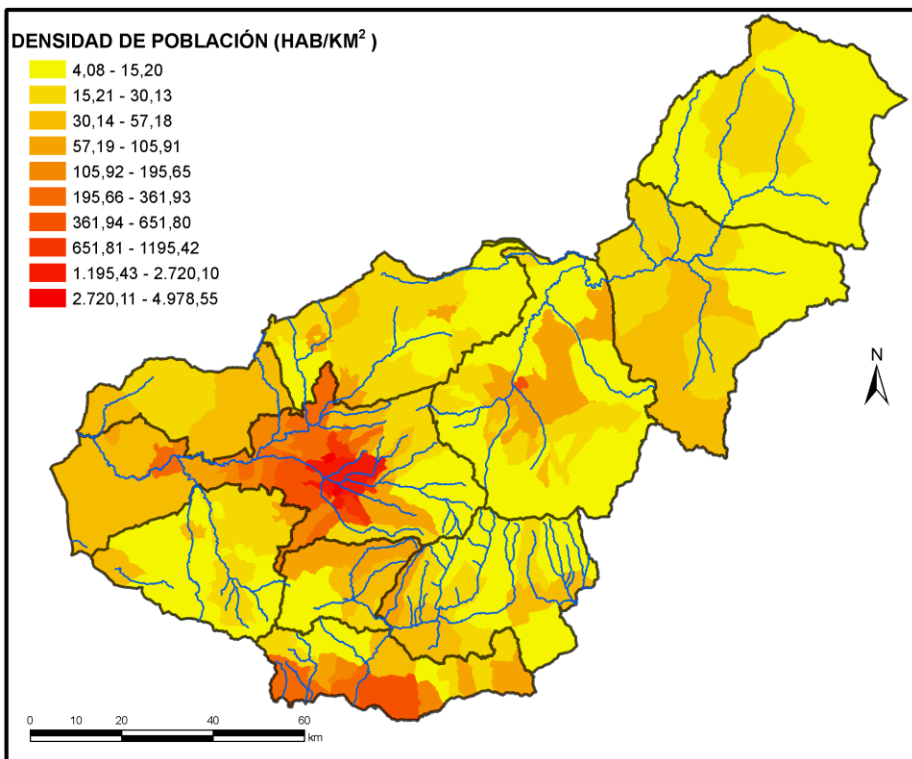


Figura 2.13. Mapa de la densidad de población de Granada en el año 2011 por municipios.

Los años más interesantes relativos a esta tesis de investigación son los años 1998 y 2004, en los que se analizan los cambios según las imágenes Landsat. En este período de tiempo se produce un incremento de la población en 40.510 habitantes a

nivel provincial, según el padrón municipal, que posiblemente afecte también a los usos del suelo y fundamentalmente a lo referente a la superficie construida. La desagregación de esta información por municipios muestra un descenso pronunciado en el número de habitantes del municipio de Granada (-3.179 habitantes) y un fuerte incremento en el área metropolitana (Albolote, Atarfe, Maracena, Peligros, La Zubia, Ogijares, Armilla, Churriana de la Vega, Las Gabias, Cullar Vega, Vegas del Genil, etc.), resultado, posiblemente, del alto coste de vivienda en la capital y la migración hacia los núcleos secundarios.

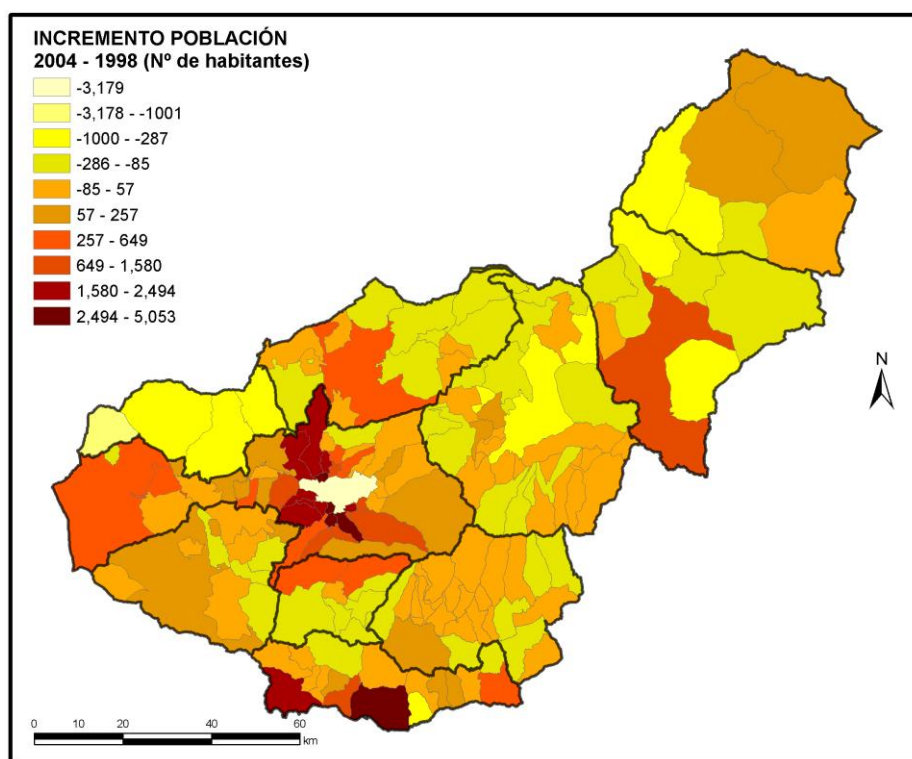


Figura 2.14. Mapa del incremento de la población de Granada en los años 2004 a 1998 por municipios (nº de habitantes).

Respecto a la superficie de parcelas edificadas, según el catastro municipal, el incremento de población y la fuerte inversión en la construcción han supuesto un incremento de la superficie de las parcelas edificadas en cerca de 26.000 ha. A pesar

de este incremento, han existido municipios en los que el incremento de superficie de parcelas edificadas ha disminuido. Los municipios con un descenso de la superficie construida inferior a 1 ha son: Jerez del Marquesado, Churriana de la Vega, Valle del Zalabí, Alhendín y Albolote. Aunque al comparar estos datos con el número de parcelas construidas, sólo Agrón y Piñar poseen una disminución en número, en una parcela menos construida, con un aumento provincial de 28,670 parcelas. Esta aparente contradicción de los datos es debida a que, a efectos de la estadística, las parcelas catastrales con alguna edificación se consideran como parcelas construidas, pudiendo existir una o varias edificaciones dentro de la misma parcela.

Otro dato interesante en este estudio es el análisis de la superficie agrícola. En la distribución por municipios del porcentaje de la superficie agrícola (Figura 2.16) se observa que el mayor porcentaje de superficie agraria corresponde a los municipios del oeste y norte de la provincia entre los que destacan Cúllar Vega, Marchal, Pampaneira y Alfacar.

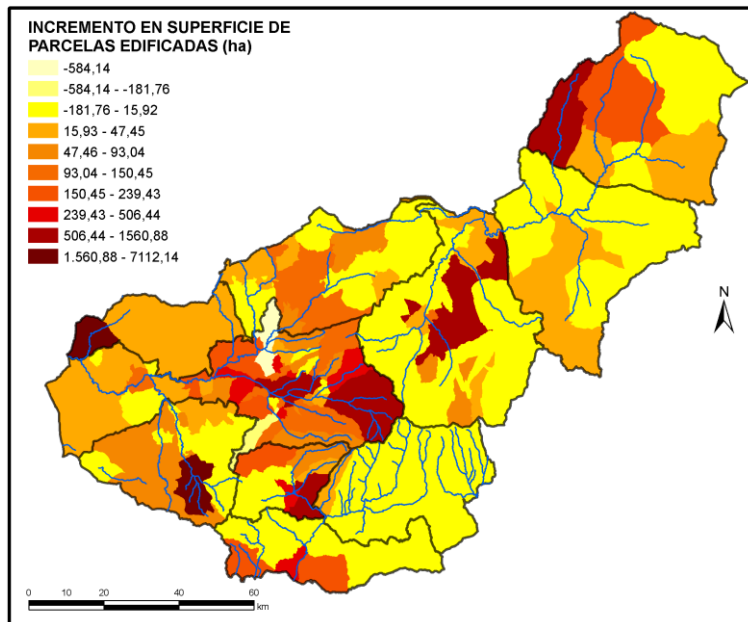


Figura 2.15. Mapa del incremento de la superficie de las parcelas edificadas (ha).

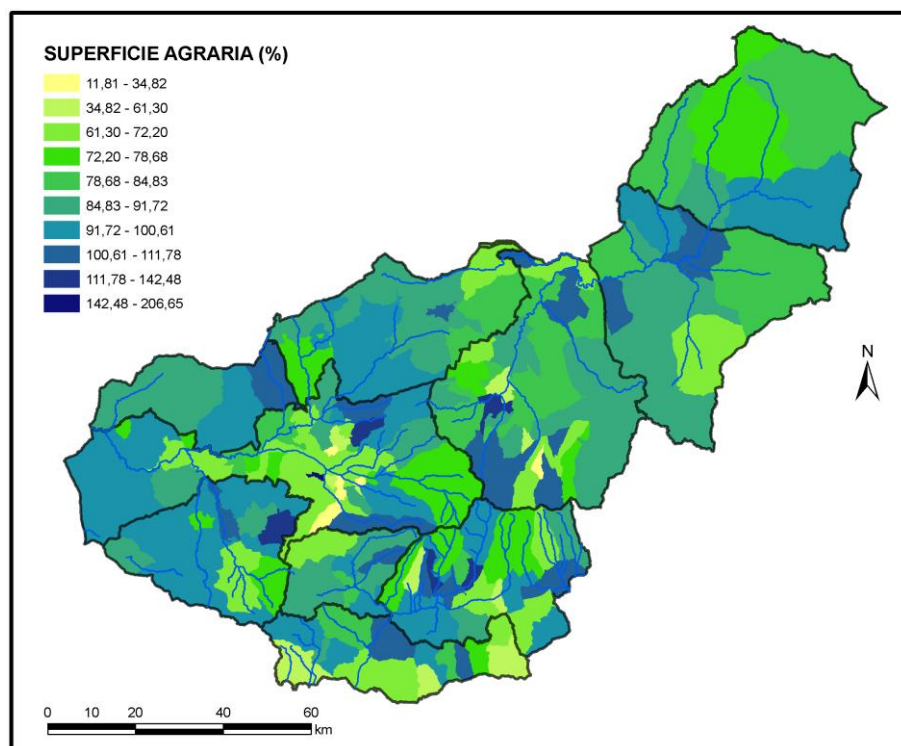


Figura 2.16. Mapa del porcentaje de superficie agrícola.

## 2 Datos

En los últimos años, en la cartografía de las cubiertas y usos del suelo, ha sido relativamente frecuente el uso de imágenes Landsat multi-temporales que representen las distintas variaciones en el estado fenológico de las cubiertas vegetales. Se ha demostrado en numerosos estudios que la combinación de imágenes multi-estacionales permite distinguir coberturas que son muy similares espectralmente si se considera únicamente una imagen “monofecha” (Lunetta y Balogh, 1999a; Moré y Pons, 2007; Oetter et al., 2001; Wolter et al., 1995; Yuan et al., 2005a; Yuan et al., 2005b). Tradicionalmente en los estudios de usos del suelo se han usado imágenes de verano en las que cultivos altamente vigorosos pueden confundirse con bosques y arboledas frondosas. Así como superficies de elevada reflectividad, como las áreas

urbanas, con suelos desnudos. La introducción de imágenes de primavera permite discriminar entre cultivos anuales y vegetación natural de hoja perenne. Por otro lado, los suelos que permanecen desnudos durante los períodos de sequía (verano) se encuentran cubiertos por hierba durante la primavera, lo cual permite diferenciarlos de las áreas urbanas. En esta tesis se ha optado por utilizar imágenes de primavera y verano para la cartografía de áreas agrícolas y urbanas.

Para clasificar el área de estudio y analizar los cambios se han seleccionado dos pares de imágenes Landsat 5 TM biestacionales, una de primavera y otra de verano para cada año: 12 de Abril de 1998, 17 de Julio de 1998, 12 de Abril de 2004 y 18 de Agosto de 2004. Todas ellas presentan una cobertura nubosa muy baja en el área de estudio, a excepción de la imagen de la primavera de 2004, en la que aparecen algunas nubes de escasa importancia en la zona sur cercana a la costa de Granada. Las escenas Landsat fueron seleccionadas atendiendo a tres criterios: estado fenológico de los cultivos, condiciones atmosféricas favorables y disponibilidad de información auxiliar para el entrenamiento y validación de las clasificaciones.

El área de estudio está contenida en una única escena Landsat con path 200 y row 34. Las imágenes poseen un formato jerárquico (Hierarchical Data Format, HDF) con los niveles digitales organizados en la estructura “Band sequential” (BSQ).

La imagen del 17 de Julio de 1998 y la del 18 de Agosto de 1998 han sido adquiridas con un nivel de procesamiento L1R (Radiometrically Corrected), en el cual han sido corregidos los posibles errores presentes en los detectores, el bandeo, efecto de sal y pimienta (striping) y las líneas o píxel perdidos. Las escenas de primavera de primavera de 1998 y 2004 fueron adquiridas con un nivel superior de procesamiento superior, L1G (Systematically Corrected), que introduce una corrección sistemática de la radiometría y la geometría de la escena con datos derivados del sensor.

## **2.1 Fundamentos del procesamiento de imágenes**

Una imagen de satélite presenta una serie de alteraciones radiométricas y geométricas que hacen que la información obtenida aparezca perturbada por una serie de errores. Los cuales pueden ser originados por variados factores: distorsiones originadas por la plataforma (debido a las variaciones en la altitud de la órbita, velocidad u orientación), distorsiones provocadas por el efecto de la rotación terrestre, distorsiones provocadas por el sensor (por ejemplo, anomalías en el funcionamiento de los detectores que generan píxel incorrectos) y distorsiones provocadas por el efecto de la atmósfera y el relieve (Chuvieco, 2008). Por tanto, las correcciones radiométricas y geométricas de la imagen se hacen con el propósito de restaurar la información digital afectada por estas distorsiones.

Las correcciones radiométricas modifican los ND originales con el objetivo de acercarlos a una recepción ideal. Generalmente comprenden la restauración de líneas o píxel perdidos, corrección del bandeo de la imagen, corrección atmosférica y cálculo de reflectividades.

Un paso importante en el desarrollo de métodos para detectar, medir y monitorizar cambios en diferentes coberturas a lo largo del tiempo es la posibilidad de comparar imágenes de diferentes fechas. El paso inicial de cualquier estudio de esta índole es corregir las distorsiones de las imágenes. La mayoría de las veces este paso se consigue utilizando puntos de control. Una vez hecho esto, el investigador puede utilizar una técnica de preprocesado para realzar o normalizar las imágenes, o bien proceder directamente a la detección de cambios.

### **2.1.1 Correcciones geométricas**

El proceso de corrección geométrica de las imágenes de satélite es imprescindible para todo tipo de aplicaciones cartográficas y estudios multi-temporales. La corrección geométrica supone un cambio en la posición que ocupan los píxeles de una imagen. Como la imagen presenta un formato digital, esta

transformación debe basarse en funciones numéricas, siendo la expresión general de este tipo de funciones, la siguiente (Chuvieco, 2008):

$$f(c') = f_1(c, l) \quad (2.1)$$

$$f(x, y) f(l') = f_2(c, l) \quad (2.2)$$

De esta manera, las coordenadas columna y línea ( $c'$  y  $l'$ ) de la imagen corregida son función de las coordenadas columna y línea de la imagen de entrada ( $c, l$ ) o de las coordenadas del mapa al que se pretende superponer la imagen ( $x, y$ ). Esta transformación puede emplearse tanto para corregir cartográficamente una imagen, como para superponer dos o más imágenes entre sí.

### **2.1.2 Correcciones radiométricas**

La señal de la radiación electromagnética solar recogida por los sensores proviene de la reflexión por la superficie de la Tierra de la energía proveniente del Sol. Esta radiación es modificada por la dispersión y absorción de gases y aerosoles mientras viaja a través de la atmósfera hasta llegar al sensor. Por otro lado, la cantidad de energía solar incidente varía a lo largo del año con cambios en el ángulo cenital solar. La medida en que la energía incidente y reflejada se ven afectadas por la dispersión y absorción atmosférica varía con factores meteorológicos tales como la temperatura, humedad, niebla... Por todo ello, se hace necesario corregir las alteraciones radiométricas introducidas como consecuencia de la atmósfera y las condiciones de iluminación de las imágenes de satélite.

La idoneidad de aplicar una determinada metodología de corrección, así como el momento en el que efectuarla, depende de una serie de factores, tales como: las imágenes y los datos atmosféricos disponibles, la información deseada, y los métodos analíticos usados para extraer la información. En algunas aplicaciones relacionadas con clasificaciones y análisis de cambios las correcciones atmosféricas son innecesarias, siempre y cuando los datos de entrenamiento y los datos a ser clasificados estén en la misma escala relativa. En otras circunstancias, las

correcciones son necesarias para convertir datos multi-temporales a la misma escala radiométrica para el estudio de una determinada cobertura a lo largo del tiempo (Song et al., 2001).

Un ejemplo típico de aplicación de teledetección para la cual no es necesaria una corrección atmosférica es clasificar una imagen con un clasificador de máxima probabilidad usando una imagen de una única fecha. Siempre y cuando las áreas de entrenamiento para la clasificación y la imagen estén en la misma escala relativa (corregida o sin corregir), las correcciones atmosféricas tienen un efecto pequeño en la exactitud de la clasificación (Song et al., 2001).

Para el sensor Landsat TM, el efecto dominante es la dispersión, que es aditiva a la señal de teledetección, mientras que los efectos multiplicativos de la absorción se pasan por alto debido a que las bandas TM fueron seleccionadas para evitar efectos debidos a la absorción. Por ello, las correcciones atmosféricas de una imagen de una única fecha son equivalentes a sustraer una constante de todos los píxel en una banda espectral. Aunque las medias de las clases cambian, las matrices de varianza-covarianza permanecen siendo las mismas independientemente de la corrección. De modo que un método como el de la sustracción del objeto oscuro no afectaría a los resultados de una clasificación.

La no obligatoriedad de aplicar un método de corrección atmosférica puede extenderse a la detección de cambios post clasificación (Singh, 1989), donde imágenes de distintas fechas se clasifican individualmente usando píxeles puros (*endmembers*) pertenecientes a la propia imagen y el resultado de la clasificación se compara para identificar cambios. En esencia, siempre y cuando los datos de entrenamiento se deriven de la imagen a ser clasificada, la corrección atmosférica es innecesaria.

La diferencia de imágenes es otra técnica de detección de cambios usada comúnmente (Song et al., 2001), en la cual se resta píxel a píxel el valor de las cuentas digitales de las dos fechas.



$$ND' = (ND_1 - A_1) - (ND_2 - A_2) \quad (2.3)$$

$$ND = (ND_1 - ND_2) + C \quad (2.4)$$

Donde  $ND'$  es el nivel digital de la imagen corregida atmosféricamente y  $ND$  el de la imagen sin corrección.  $ND_1$  y  $ND_2$  son los niveles digitales de la fecha 1 y 2 respectivamente.  $A_1$  y  $A_2$  son los efectos atmosféricos aditivos para cada una de esas fechas. La constante  $C$  es la diferencia de los efectos atmosféricos entre las dos fechas. Considerando que todos los valores explicados con anterioridad son específicos para cada banda del sensor TM. El efecto de la corrección atmosférica es equivalente a cambiar el valor umbral  $C$  en el histograma de la imagen diferencia. De hecho, estos valores umbrales son desconocidos inicialmente y tienen que ser determinados empíricamente (Ekstrand, 1994; Jensen, 2000). En estas circunstancias, las correcciones atmosféricas pueden ser omitidas cuando se usa la diferencia de imágenes para la detección de cambios. Esta conclusión puede ser extrapolada a todos los algoritmos de detección de cambios que impliquen transformaciones lineales. Por el contrario, es necesario corregir los efectos atmosféricos antes de la clasificación y detección de cambios en muchas otras situaciones. En muchos estudios se usa el índice de vegetación normalizado para la detección de cambios. El índice de vegetación normalizado se calcula de la siguiente forma:

$$NDVI = \frac{TM4 - TM3}{TM4 + TM3} \quad (2.5)$$

Considerando los efectos atmosféricos:

$$NDVI = \frac{(TM4 - TM3) - (A4 - A3)}{(TM4 + TM3) - (A4 + A3)} \quad (2.6)$$

Donde  $A3$  y  $A4$  son efectos atmosféricos aditivos para  $TM3$  y  $TM4$ , respectivamente. La ecuación muestra que no hay una relación lineal en el caso de los índices de vegetación.

Dependiendo de la aplicación, las correcciones atmosféricas pueden ser absolutas, donde un nivel digital es convertido a reflectancia de superficie, o relativas,

en las que partiendo de un par de imágenes se considera una relación lineal y se minimizan las diferencias radiométricas existentes.

### **3.1.1.1 Métodos absolutos**

Para entender todo el potencial de los datos espectrales es necesario convertir la salida del sensor (niveles digitales) a valores independientes de las condiciones atmosféricas, valores de reflectancia. Así se pueden comparar tanto imágenes de diferentes fechas, como directamente píxel con medidas de campo y de laboratorio.

La interacción de la radiación solar con la atmósfera ha sido bien caracterizada y se han desarrollado un gran número de códigos, basados en la teoría de transferencia radiativa para corregir los efectos atmosféricos en las imágenes de satélite (Moran et al., 1992). Diversos estudios han mostrado que estos códigos de transferencia radiativa pueden convertir las medidas del satélite a reflectancia de superficie (Moran et al., 1992; Schroeder et al., 2006; Song et al., 2001).

Los procedimientos de corrección absoluta varían en la cantidad y exactitud de los datos atmosféricos requeridos para la aplicación, y pocos se pueden aplicar cuando no hay datos atmosféricos disponibles (Furby y Campbell, 2001). Dependiendo de la metodología a aplicar se hace necesario disponer de información relativa a uno o varios de los puntos siguientes:

- Calibración radiométrica del sensor.
- Medidas simultáneas in situ de parámetros atmosféricos.
- Medidas de reflectancia de superficie in situ.
- Códigos de transferencia radiativa.
- Atmósferas simuladas.

La calibración radiométrica es un proceso que consiste en el uso de ecuaciones estándar para convertir imágenes de 8 bits en reflectancia en el satélite y eliminar de esa forma las discrepancias debidas a las condiciones de adquisición. Una vez corregidas, estas discrepancias pueden aplicarse diferentes técnicas para corregir los

efectos atmosféricos. La corrección atmosférica puede realizarse midiendo el espesor óptico el día del paso del satélite y usando un código de transferencia radiativa para calcular la relación entre la reflectancia de superficie y la radiancia en el sensor. Se ha probado que este procedimiento es efectivo (Moran et al., 1992; Song et al., 2001), pero es demasiado caro y consume mucho tiempo como para ser usado de una forma operativa. Por otro lado, estas medidas no suelen estar disponibles o pueden tener una calidad cuestionable. En ausencia de medidas puede recurrirse al uso de un código de transferencia radiativa con atmósferas simuladas apropiadas. De modo que, algunas aplicaciones en teledetección tienen que confiar en algoritmos que utilizan información derivada de la imagen en si misma para corregir los efectos atmosféricos, evitando la necesidad de medidas atmosféricas y de las condiciones del lugar. Se han propuesto muchos métodos basados en datos de la imagen en el visible y en el infrarrojo (Chavez Jr., 1996).

### **3.1.1.2 Métodos relativos**

Las correcciones atmosféricas requieren el uso de medidas de campo en el tiempo de la adquisición de la imagen para la corrección atmosférica y la calibración del sensor. Esto no es solo costoso sino que también es poco práctico cuando se usan imágenes de archivo para la detección de cambios (Hall et al., 1991). La corrección radiométrica relativa, se prefiere porque no se necesitan medidas de campo simultáneas al paso del sensor. Este método supone normalizar o rectificar las intensidades de los niveles digitales de imágenes multi-fecha banda a banda a una imagen de referencia seleccionada, así las imágenes pueden ser tratadas como si se hubiesen adquirido bajo condiciones atmosféricas y de iluminación similares.

La normalización radiométrica relativa minimiza las diferencias radiométricas entre un par de imágenes causadas por inconsistencias en las condiciones de adquisición. Estos métodos pueden ser divididos en tres grupos:

Las metodologías de ajuste estadístico incluyen métodos que están basados en el ajuste lineal de dos imágenes que se parecen en términos de su rango dinámico, media estadística y desviación Estándar, u otras variables estadísticas posibles. Dos métodos,

la normalización mínima-máxima y la normalización en media-desviación estándar han sido evaluados por Yang y Lo (2000) con resultados poco esperanzadores.

*Histogram matching* es una técnica de realce radiométrico integrada en muchos *software* (Jensen, 2000). Esta transformación no es lineal, es un proceso de determinación de una *lookup table* para que el histograma de una imagen se parezca al de otra. Es una técnica útil para homogeneizar dos imágenes de la misma escena adquiridas en distintas fechas con ligeras diferencias en la iluminación y los efectos atmosféricos.

Las técnicas de regresión lineal incluyen diversos métodos bajo una premisa fundamental, la radiancia medida por un sensor para una determinada banda espectral puede ser expresada como una función lineal de la reflectividad (Casselles y García, 1989; Schott et al., 1988). Las diferencias atmosféricas y de calibración del sensor están linealmente relacionadas. De acuerdo con la ecuación lineal siguiente, que puede ser usada para mejorar la normalización:

$$ND'_k = m_k ND_k + b_k \quad (2.7)$$

Donde  $ND$  es el nivel digital de una banda,  $ND'$  es el nivel digital normalizado,  $m$  es la pendiente o ganancia y  $b$  es el sesgo y  $k$  representa cada una de las bandas del sensor. Los coeficientes  $m$  y  $b$  son calculados mediante las siguientes ecuaciones (Yang y Lo, 2000):

$$m_k = V_{R_k S_k} / V_{S_k S_k} \quad (2.8)$$

$$b_k = R_k - m_k \cdot S_k \quad (2.9)$$

$R_k$  y  $S_k$  son las medias de la imagen de referencia y la imagen sujeto de la corrección y  $V_{R_k S_k}$  y  $V_{S_k S_k}$  la covarianza y la varianza de la imagen sujeto.

Las técnicas de regresión pueden aplicarse a todo el conjunto de datos o a una selección de píxel, pudiendo seguir diversos procedimientos:

• Pseudoinvariant features (PIF), fue desarrollado por Schott et al. (1988). Las características pseudoinvariantes son objetos con una reflectividad casi constante en las diferentes escenas. De acuerdo con Schott et al. (1988), son típicamente objetos cuya reflectancia es independiente de los ciclos estacionales o biológicos. Se asume que las diferencias en el brillo de estos objetos son una función lineal. En Schott et al. (1988) se aislaron los píxel correspondientes a zonas urbanas usando un ratio de imágenes (infrarrojo/rojo) que resultó ser bastante efectivo diferenciando píxel de zonas urbanas y agua de vegetación. Una vez que los píxel de zonas urbanas han sido aislados las ecuaciones de regresión lineal se desarrollan para relacionar las imágenes banda a banda.

$$m_k = \sigma_{R_k} / \sigma_{S_k} \quad (2.10)$$

$$b_k = R_k - m_k S_k \quad (2.11)$$

Donde  $\sigma_{R_k}$  y  $\sigma_{S_k}$  son las desviaciones típicas de la imagen de referencia y la imagen sujeto.

Cuando la clasificación y la detección de cambios supone una generalización en el tiempo y en el espacio (Pax-Lenney et al., 2001), este tipo de corrección relativa generalmente no es aplicable, debido a la dificultad de identificar las PIFs a lo largo de las escenas. Si hay varios sensores involucrados en las imágenes multi-temporales, es aún más complicado aplicarlo. Por lo que, la monitorización de grandes áreas requiere salirse fuera de las metodologías convencionales y aplicar métodos basados en la generalización de los datos de entrenamiento.

• *Radiometric control set* (RCS), fue desarrollado por Hall et al. (1991). Una imagen siempre contiene algunos píxel que tienen la misma reflectancia de superficie media, que se mantienen a lo largo de imágenes de la misma escena para distintas fechas. Esta relación puede observarse comparando banda a banda los diagramas de dispersión, en los que los píxel de la diagonal no tienen apenas variación a través del período de tiempo representado en las fechas de las dos imágenes. A este conjunto de píxel es a lo que se le denomina radiometric control set. Además de tomar un

muestreo simple de píxel brillantes representando los píxel urbanos, este método usa los extremos de la transformación de Kauth-Thomas verdor y brillo que son construidos usando las dos primeras bandas de la transformación Tasseled Cap. El diagrama de dispersión de la transformación Kauth-Thomas aísla un conjunto de píxel oscuros que corresponden a aguas profundas (embalses) y los píxel brillantes representan elementos similares a los definidos por las características pseudoinvariantes (Yang y Lo, 2000).

- La normalización radiométrica mediante píxel de “no-cambio” a partir del diagrama de dispersión, fue desarrollado por Elvidge et al. (1995). El conjunto de no cambio se obtiene de una región identificada en el diagrama de dispersión entre una imagen objeto y la imagen de referencia banda a banda. Un conjunto de píxel de no cambio engloba píxel que ocupan el centro de los clústeres de agua y campo observables en los diagramas de dispersión y las bandas del infrarrojo próximo. El centro de los *clusters* de agua está localizado en los niveles digitales más bajos en la esquina izquierda de los diagramas de dispersión cerca del origen, mientras que el centro de los *clusters* de campo está localizado cerca del centro del diagrama de dispersión.

## **2.2 Medologías de corrección**

### **2.2.1 Corrección atmosférica absoluta**

Las correcciones atmosféricas para la detección de cambios y clasificación no son siempre necesarias, como se vio en la sección 2.1.2. Sin embargo, dependiendo del caso de estudio puede ser recomendable aplicar alguna corrección. En el estudio realizado por Song et al. (2001), todos los métodos de corrección aplicados mejoraron la exactitud de las clasificaciones y de la detección de cambios. En el caso de un estudio de detección de cambios, si bien no es necesario aplicar un método de corrección atmosférica absoluta, si es importante que la radiometría de la imagen esté en una escala radiométrica común.

Para este estudio se han evaluado diferentes métodos de corrección atmosférica, dos métodos de normalización “PIF”, “RCS” y la corrección absoluta aplicando el código de transferencia radiativa MODTRAN4 (Abreu y Anderson, 1996).

La corrección absoluta de una imagen de satélite consiste en convertir los valores de radiancia a reflectividades de superficie y corregirle los efectos producidos por la atmósfera. Para ello, si no se disponen de medidas de reflectividad in situ, se requiere el uso de modelos de transferencia radiativa al objeto de transformar los datos originales de radiancia en valores de reflectividad. Con ello, se consiguen eliminar los efectos atmosféricos y los derivados de la geometría de observación e iluminación.

En este estudio, se ha utilizado el módulo de corrección atmosférica llamado FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes) desarrollado por el Air Force Research Laboratory, Space Vehicles Directorate (AFRL/VS), Hanscom AFB and Spectral Sciences, Inc. (SSI), el cual está basado en el modelo de transferencia radiativa MODTRAN4 (Moderate Resolution Transmittance 4) (Abreu y Anderson, 1996; Berk y Adler-Golden, 2002). Los objetivos principales de este modelo son, en primer lugar, eliminar de la radiancia recibida por el sensor los efectos de la absorción y dispersión de la energía electromagnética, causados por las moléculas y partículas atmosféricas en suspensión y, en segundo lugar, convertir esa radiancia en valores de reflectividad de la superficie. El programa FLAASH procesa la radiancia de las imágenes que cubren el espectro solar, desde las longitudes de onda del ultravioleta hasta el SWIR, omitiendo las emisiones térmicas. De esta manera, la radiancia espectral en un píxel del sensor es definida por medio de los parámetros siguientes (Berk y Adler-Golden, 2002):

$$L^* = (A\rho/1 - \rho_e S) + (B\rho_e/1 - \rho_e S) + L_a^* \quad (2.12)$$

donde  $\rho$  es la reflectividad de la superficie en el píxel,  $\rho_e$  es un promedio de la reflectividad de la superficie en una región circundante al píxel,  $S$  es el albedo esférico de la atmósfera,  $L_a^*$  es la radiancia aportada por la dispersión atmosférica

que no ha alcanzado la superficie y  $A$  y  $B$  son coeficientes independientes de la superficie y que varían con las condiciones atmosféricas y geométricas pero no de la superficie.

Todas las variables de la ecuación son dependientes de la longitud de onda. El primer término de la ecuación corresponde a la radiancia que es reflejada por la superficie y llega directamente al sensor, y el segundo término, corresponde a la radiancia de la superficie que es dispersada por la atmósfera antes de llegar al sensor. La diferencia entre  $\rho$  y  $\rho_e$  viene dada por los efectos de adyacencia (radiancia dispersada procedente de píxel cercanos).

Los valores de  $A$ ,  $B$ ,  $S$  y  $L_a$  son determinados por el algoritmo MODTRAN4, el cual requiere para sus cálculos algunos parámetros de entrada: ángulo solar, ángulo de observación, elevación promedio de la superficie, modelo de atmósfera, tipo de aerosol y el rango de visibilidad horizontal (RSI, 2007). Después de obtener las variables atmosféricas se despeja de la ecuación anteriormente descrita las reflectividades de superficie de cada píxel en todos los canales del sensor.

El programa FLAASH, funciona como un módulo el programa de tratamiento de imágenes ENVI (2007). Previamente al proceso de corrección atmosférica, el módulo FLAASH requiere que los datos de entrada cumplan con las características siguientes: 1) calibrados en valores de radiancia ( $\mu W/(cm^2 * nm * sr)$ ); 2) la imagen en formato BIL o BIP.

Se han considerado para la corrección de la geometría de iluminación y el paso a radiancia, el ángulo de elevación solar y la hora de adquisición especificadas en la cabecera de las imágenes Landsat (Tabla 2.1). La elevación media del terreno fue calculada usando un modelo digital del terreno (MDT) de Andalucía con una resolución de 10x10m con la ayuda del *software* ArcGis 9.1.

Las atmósferas tipo seleccionadas como entrada para el modelo de corrección han sido las de Latitudes Medias de Verano (MLV) para las imágenes del 17-07-1998 y 18-08-2004 y Sub-Ártica de verano para las imágenes del 12-04-1998 y 12-04-2004



atendiendo a la dependencia latitudinal y estacional de la temperatura de superficie (Tabla 2.2 y Tabla 2.3).

Tabla 2.1. Ángulos de elevación solar y horas de adquisición de las imágenes Landsat

Fecha	12-04-1998	17-07-1998	12-04-2004	18-08-2004
Hora adquisición (UTC)	10:25:09	10:26:53	10:29:12	10:32:42
Ángulo elev. solar	52º	61º	53º	57º

Tabla 2.2. Cantidad de Vapor de Agua y Temperaturas de Superficie para los Modelos de Atmósfera de MODTRAN

Modelo de Atmósfera	Vapor de Agua (std atm-cm)	Vapor de Agua (g/cm <sup>2</sup> )	Tº Aire Superficie (ºC)
Sub-ártica de Invierno (SAI)	518	0.42	-16
Latitudes Medias de Invierno (LMI)	1060	0.85	-1
U.S. Standard (US)	1762	1.42	15
Sub-ártica Verano	2589	2.08	14
Latitudes Medias de Verano (LMV)	3636	2.92	21
Tropical (T)	5119	4.11	27

Tabla 2.3. Selección de Modelos de Atmósfera de MODTRAN en función de la dependencia latitudinal y estacional de la temperatura de superficie

Latitud (ºN)	Ene.	Mar.	Mayo	Jul.	Sept.	Nov.
80	SAI	SAI	SAI	LMI	LMI	SAI
70	SAI	SAI	LMI	LMI	LMI	SAI
60	LMI	LMI	LMI	SAI	SAI	LMI
50	LMI	LMI	SAV	SAV	SAV	SAV
40	SAV	SAV	SAV	LMV	LMV	SAV
30	LMV	LMV	LMV	T	T	LMV
20	T	T	T	T	T	T
10	T	T	T	T	T	T
0	T	T	T	T	T	T
-10	T	T	T	T	T	T
-20	T	T	T	LMV	LMV	T
-30	LMV	LMV	LMV	LMV	LMV	LMV
-40	SAV	SAV	SAV	SAV	SAV	SAV
-50	SAV	SAV	SAV	LMI	LMI	SAV
-60	LMI	LMI	LMI	LMI	LMI	LMI
-70	LMI	LMI	LMI	LMI	LMI	LMI
-80	LMI	LMI	LMI	LMI	LMI	LMI

Para la corrección de cada una de las imágenes se ha introducido un factor de ajuste para el contenido en vapor de agua atmosférico de cada atmósfera tipo para extrapolarlo al real medido durante el día de adquisición de la imagen en los casos en los que estaba disponible esta medida (Tabla 2.2 y Tabla 2.4). La cantidad de Vapor de Agua para las imágenes del 2004 fue obtenida del satélite MODIS, más concretamente del producto MODIS Terra Daily Level 3 Water Vapor Clear Sky a través de la aplicación web “GIOVANNI” (Interactive Online Visualization AND aNalysis Infrastructure) desarrollada por el Goddard Earth Sciences Data and Information Services Center que permite obtener diferentes parámetros con una frecuencia diaria y a una resolución espacial de  $1^\circ \times 1^\circ$  (Acker y Leptoukh, 2007; Gao y Kaufman, 1992). Para las imágenes de 1998 no se introdujo ningún factor de corrección del vapor de agua al no haber medidas disponibles, utilizando por tanto en el cálculo el valor por defecto que introduce el modelo de atmósfera Subártico de verano.

Tabla 2.4. Valores de Espesor Óptico Atmosférico (AOD), Vapor de Agua y Visibilidad introducidos en el Modelo

	12-04-1998	17-07-1998	12-04-2004	18-08-2004
AOD (550 nm)	N/A	0.277*	0.167	0.127
Vapor de Agua (cm)	N/A	N/A	0.817	1.989
Visibilidad (km)	N/A	28.23*	46.85	61.61

Uno de los pasos fundamentales de la corrección de imágenes de satélite mediante el uso de un código de transferencia radiativa es la elección de un modelo de aerosoles que aporte información sobre la naturaleza y distribución en tamaño de éstos. El área de estudio es especialmente problemática por presentar intrusiones de polvo sahariano con una frecuencia elevada, por lo que la elección del modelo de aerosoles es aún más crítica. Teniendo en cuenta lo anterior, se han calculado las retro trayectorias de las masas de aire presentes en el área de estudio y el índice de aerosoles de TOMS (*Total Ozone Mapping Spectrometer*) en el momento de adquisición de las imágenes para determinar el origen del aerosol atmosférico y la posible presencia de polvo. Una retro trayectoria permite estudiar la evolución

geográfica de una partícula desde un tiempo  $t$  anterior al momento de estudio  $t_0$ , proporcionando la posición de esta partícula a intervalos periódicos de frecuencia  $f$ , para una partícula que en el instante  $t_0$  y en el lugar de estudio se encuentra a una altura  $h$ , basándose en datos meteorológicos reales. Para el cálculo de las retrotrayectorias se ha utilizado el modelo HYSPLIT (*HYbrid Single-Particle Lagrangian Integrated Trajectory*) (Draxler y Rolph, 2003), disponible a través de <http://www.arl.noaa.gov/ready/hysplit4.html>, desarrollado conjuntamente por la NOAA en Estados Unidos (*Nacional Oceanographic and Atmospheric Administration*) y el *Australia's Bureau of Meteorology*.

Se calcularon retrotrayectorias de 5 días finalizando sobre el centro con coordenadas 37.18 y -3.6 de la escena Landsat, para aproximadamente la hora de adquisición de las imágenes (11:00 UTC), con el fin de interpretar los datos en término de tipos de aerosol según sus orígenes. Se eligieron 3 niveles de cálculo (500, 1500 y 3000 m) lo que permitió representar las masas de aire muestreadas por instrumentación *in situ* así como el transporte a gran distancia de partículas.

De forma complementaria al cálculo de las retrotrayectorias se han obtenido los mapas globales del índice de aerosol medidos por TOMS (desarrollada por el *Goddard Earth Sciences Data and Information Services Center*) para cada una de las fechas de las imágenes Landsat TM 5 a través de la web: [http://jwocky.gsfc.nasa.gov/aerosols\\_v8.html](http://jwocky.gsfc.nasa.gov/aerosols_v8.html), a una resolución de  $1^\circ \times 1.25^\circ$ . El índice de aerosoles del TOMS es una medida de como la dependencia de la longitud de onda de una radiación ultravioleta retrodispersada en una atmósfera que contenga aerosoles (dispersión de Mie, dispersión de Rayleigh y absorción) difiere de la de una atmósfera molecular pura (dispersión de Rayleigh) (Torres et al., 1998; Torres et al., 2002). El índice de aerosoles se expresa como:

$$AI = 100 \log_{10} \left( I_{360}^A / I_{360}^B \right) \quad (2.13)$$

Donde  $I_{360}^A$  = radiancia medida por TOMS a 360 nm e  $I_{360}^B$  = la radiancia calculada para TOMS a 360 nm considerando una atmósfera de Rayleigh.

A partir de las retrotrayectorias calculadas (Figura 2.17), en las que se puede observar las proveniencias de las distintas masas de aire para todas las imágenes, se puede apreciar que la mayoría de las masas de aire presentes en el área de estudio provienen del Atlántico Norte (A.N.), a excepción de las de 500 y 1500 m de altura para el 12-04-1998 que proviene del Norte de Europa. Por otro lado, para la imagen del 18-08-2004 las masas de aire a 3000 m que proceden del Atlántico Sur, aunque no son susceptibles de contener polvo por proceder de una altura elevada.

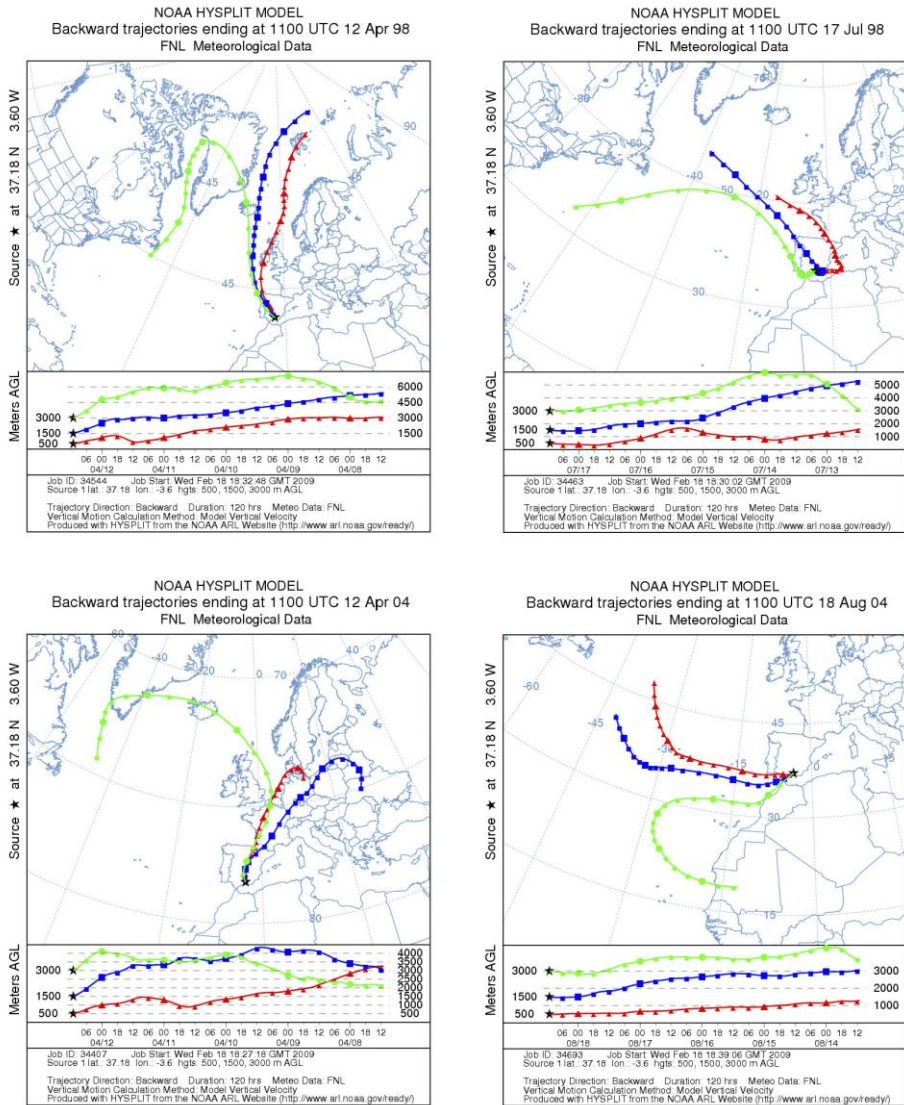


Figura 2.17. Modelo HYSPLIT. Retro trayectorias para las condiciones de adquisición de las imágenes del 12-04-1998, 17-07-1998, 12-04-2004 y 18-08-2004

La Figura 2.18 muestra imágenes globales del índice de aerosol, indicando la localización del aerosol troposférico para las fechas de estudio. Los colores más claros representan pequeñas cantidades de polvo y humo, y los colores más oscuros

las mayores cantidades. De esta figura puede deducirse una atmósfera con una baja concentración de aerosol para las fechas 12-04-1998, 17-07-1998 y 12-04-2004 y una cantidad relativamente pequeña de polvo para la imagen de 18-08-2004.

Teniendo en cuenta lo expuesto en los párrafos anteriores se ha introducido en el módulo FLAASH un modelo de aerosoles rural para cada una de las fechas a corregir. En la selección del modelo de aerosol para la imagen del 18-08-2004 se ha atendido de forma complementaria a la medida de espesor óptico obtenida de MODIS (Tabla 2.4), la cual es inferior a la descrita en Hess et al. (1998) para un modelo de aerosol desértico. El modelo de aerosoles rural representa condiciones de aerosoles que pueden encontrarse en áreas continentales si una fuerte afección por fuentes urbanas o industriales de aerosol. La concentración de partículas de este modelo es fuertemente dependiente de la trayectoria de las masas de aire portadoras del aerosol y se compone de una mezcla de un 70% de sustancias hidrosolubles (amonio, sulfato cálcico y compuestos orgánicos) y un 30% de polvo. La distribución en tamaño de las partículas es una combinación de dos distribuciones log-normales de pequeño y gran tamaño (Abreu y Anderson, 1996; RSI, 2007; Volz, 1972, 1973; Whitby y Cantrell, 1975).

El último parámetro introducido en el modelo ha sido la visibilidad, que viene definida para una longitud de onda igual a 550 nm y está relacionada con el coeficiente de extinción  $\beta$  mediante la siguiente ecuación (Abreu y Anderson, 1996):

$$V = 3,912/\beta \quad (2.14)$$

Donde  $V$  es igual a la visibilidad y  $\beta$  es el coeficiente de extinción, definido como el espesor óptico horizontal para 550 nm por km. Para obtener el coeficiente  $\beta$  se divide el AOD (espesor óptico atmosférico) por la anchura de la capa efectiva de aerosoles, que adopta típicamente un valor de en torno a los 2 km.

Tabla 2.5. Valores de espesor óptico atmosférico (AOD) para el 17-07-1998

Hora	Ta 368 nm	Ta 500 nm	Ta 675 nm	Ta 778 nm	alfa	beta
9:11	0,39408	0,2672	0,33973	0,16969	0,80351	0,17455
12:06	0,45642	0,32038	0,21704	0,22378	1,02714	0,15931
14:53	0,41723	0,28827	0,164	0,20471	1,13089	0,1302

Para el cálculo de de las imágenes de 12-04-2004 y 18-08-2004 se ha considerado los AOD (espesor óptico atmosférico) obtenidos a través de la aplicación web GIOVANNI (Acker y Leptoukh, 2007) de *MODIS Terra Daily Level 3* a 550 nm con una resolución espacial de  $1^\circ \times 1^\circ$  y con centro de coordenadas en  $37^\circ -3^\circ$ . Para la imagen del 17-07-1998 se ha utilizado un valor de espesor óptico medido por el fotómetro solar CIMEL CE-318 en Granada operado por el grupo de Física de la Atmósfera de la Universidad de Granada. Para el 12 de Abril de 1998 al no existir medidas disponibles se asumió una situación atmosférica similar a la del 12 de Abril de 2004, por lo que se introdujeron los parámetros medidos en esa fecha. Como resultado de la aplicación de la ecuación anterior se obtuvieron los valores de visibilidad presentados en la Tabla 2.4.

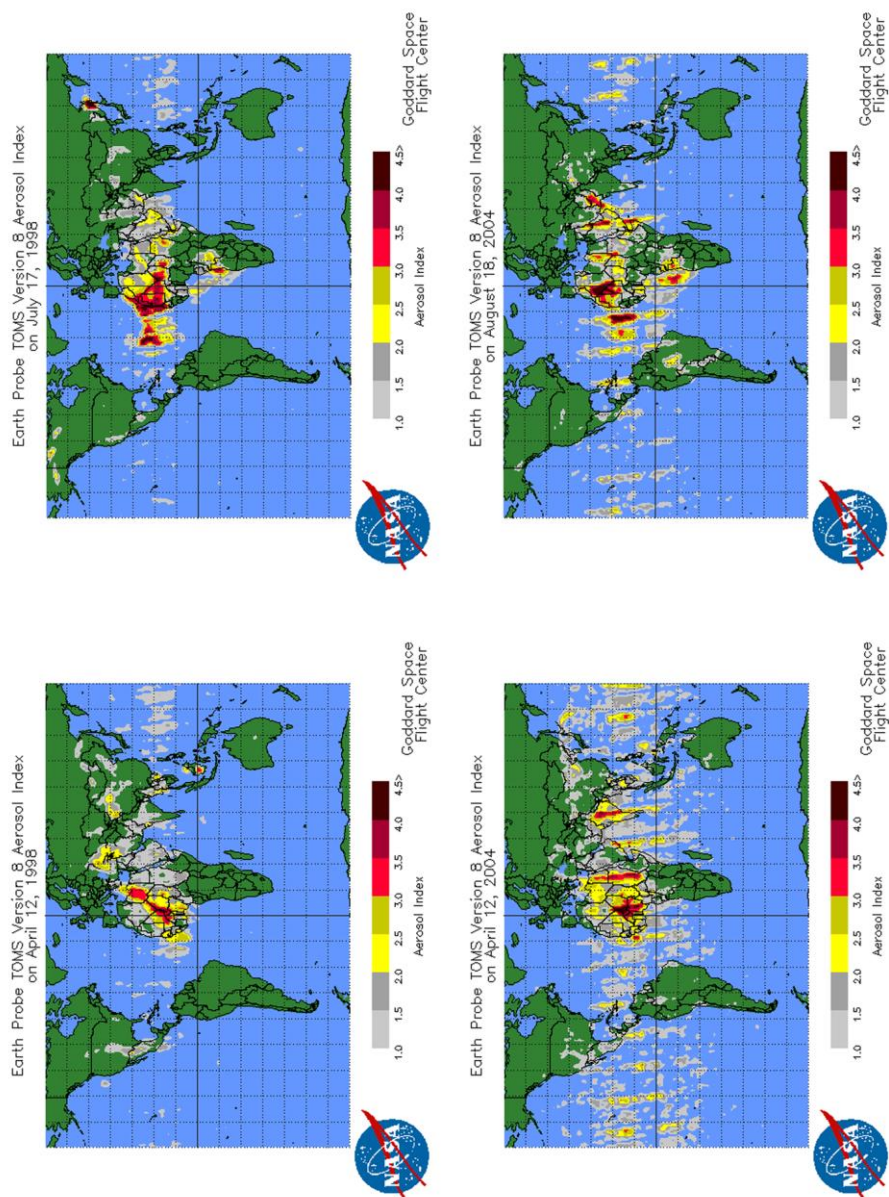


Figura 2.18. Índice de aerosol diario medido por el *Earth Probe* TOMS para las fechas 12-04-1998, 17-07-1998, 12-04-2004 y 18-08-2004



## CAPÍTULO 3.

# Métodos de Inteligencia Artificial para Clasificación Digital

### **1 Introducción**

El seguimiento y la cartografía de cubiertas y usos del suelo necesitan la aplicación de métodos robustos de clasificación, que permitan clasificar de la forma más exacta posible las categorías relacionadas con las cubiertas del suelo (Anderson et al., 1976), que en el caso de este estudio presentan una elevada complejidad. La clasificación digital de estas áreas requiere de metodologías que sean operativas, interpretables, transparentes y susceptibles de tener un alto grado de automatización. Además, la elección de un método de clasificación adecuado para la cartografía de áreas complejas depende de la capacidad del método de enfrentarse a situaciones desfavorables como por ejemplo: datos con una alta proporción de ruido, espacios complejos de medida y conjuntos de datos de entrenamiento reducidos (DeFries y Chan, 2000; Rogan et al., 2008).

En la cartografía de cubiertas del suelo, a partir de datos de teledetección, se ha usado una amplia gama de metodologías que van desde algoritmos no supervisados como ISODATA o K-medias, a algoritmos paramétricos supervisados como el de máxima probabilidad (Jensen, 2005), o a algoritmos de aprendizaje de máquinas

como: redes neuronales artificiales (Mas y Flores, 2008), árboles de decisión (Breiman, 1984), máquinas de vectores soporte (Mountrakis et al., 2011) o clasificadores de conjunto (Breiman, 1996), entre otros. Debido a la alta disponibilidad de datos, consecuencia del elevado desarrollo tecnológico acaecido en los últimos años, los algoritmos de aprendizaje de máquinas han surgido como alternativas exactas y eficientes a las técnicas paramétricas convencionales en la cartografía de áreas a partir de espacios de datos complejos de alta dimensionalidad (Hansen et al., 1996; Huang et al., 2002; Rogan et al., 2003). Estos algoritmos no necesitan de la asunción de ningún tipo de distribución (ej. normalidad), y estudios previos dan cuenta de su superioridad en términos de exactitud cartográfica en la clasificación de datos de satélite (Foody, 1995a; Friedl y Brodley, 1997). Sin embargo, algunas de estas técnicas de aprendizaje de máquinas (ej. redes neuronales artificiales o máquinas de vectores soporte) son difíciles de aplicar debido a la necesidad de ajustar un alto número de parámetros, lo cual hace difícil su automatización (Atkinson y Tatnall, 1997; Foody, 2004; Yang, 2011; Zhou y Yang, 2010). Por otro lado, también se ha descrito que algunos de estos algoritmos (ej. árboles de clasificación) tienen tendencia a sobre-ajustarse a los datos (Breiman et al., 1984). Como alternativa a las técnicas de clasificación anteriormente citadas, en los últimos años, un grupo de algoritmos denominados “clasificadores de conjunto” o “meta-clasificadores” (ej. *random forest*, *bagging* y *boosting*) han despertado el interés de la comunidad científica en el ámbito de la teledetección (Friedl et al., 1999; Ghimire et al., 2010; Gislason et al., 2006; Na et al., 2010; Sesnie et al., 2008; Wang et al., 2009a). Estos algoritmos, basados en aprendizaje de conjunto, utilizan un clasificador de base para producir múltiples clasificaciones a partir de subconjuntos aleatorios de los datos de entrada (Breiman, 2001; Friedl et al., 1999). Estas clasificaciones múltiples son agregadas en una clasificación única, a través de procedimientos como votación mayoritaria (ej. *random forest*), o mediante una técnica de minimización de error iterativa, en la que se aumentan los pesos asignados a los ejemplos que han sido clasificados erróneamente (ej. *boosting*) (Friedl et al., 1999; Ghimire et al., 2010; Hastie et al., 2009). La filosofía de los meta-clasificadores

se fundamenta en la premisa de que un grupo de clasificadores clasifican mejor que cualquier clasificador individual. Aprovechan las ventajas de la agrupación de los clasificadores, mientras que al mismo tiempo eluden algunos puntos débiles de la utilización de un clasificador simple (ej. sobreajuste a los datos o sensibilidad al ruido) (Ghimire et al., 2010; Kotsiantis y Pintelas, 2004). Además, los metaclasificadores basados en árboles de decisión son fáciles de aplicar puesto que sólo necesitan el ajuste de un reducido número de parámetros y por tanto poseen altos grados de automatización (DeFries y Chan, 2000; Prasad et al., 2006).

El objetivo de este capítulo es evaluar la idoneidad de diferentes algoritmos de aprendizaje de máquinas para la clasificación de las cubiertas del suelo de la Provincia de Granada; un área compleja con un alto número de cubiertas o categorías. El análisis comparativo de algoritmos realizado, se ha llevado a cabo desde diferentes perspectivas: la exactitud cartográfica de las clasificaciones, las necesidades de parametrización de cada técnica y, por último, la sensibilidad al ruido y a la reducción de los datos de entrenamiento.

## **2 Fundamentos de los métodos de evaluación de la exactitud cartográfica**

La evaluación de la exactitud es una parte importante del análisis de los datos de teledetección. Hay muchas razones que apoyan esta idea, la más obvia de ellas, es que, sin el conocimiento de la veracidad de la información (clasificaciones), no es posible confiar en la exactitud de la cartografía. A esto hay que unirle la necesidad de incrementar la calidad de la información proporcionada por los mapas identificando y corrigiendo las fuentes de error. Por otro lado, los analistas e investigadores, a menudo necesitan comparar que nuevas técnicas o algoritmos funcionan mejor. En definitiva la evaluación de la exactitud determina la calidad de la información derivada de los datos de teledetección (Congalton y Green, 2009).

Actualmente, la evaluación de la exactitud se realiza a través del cálculo y el posterior análisis de las matrices de error. Una matriz de error es una tabla de

números cuadrada, ordenada en filas y columnas que expresa un conjunto de píxel o polígonos asignados a una categoría particular en relación a la misma categoría de datos reales o de referencia (Story y Congalton, 1986). A partir de la matriz de error se puede calcular la exactitud global (*overall accuracy*) sumando la diagonal principal y dividiendo el resultado por el total de las filas y columnas. Además también se pueden calcular los errores de omisión y comisión derivados de la matriz de error.

El coeficiente Kappa es una medida del acuerdo global de una matriz de error una vez descontadas las coincidencias que puedan ser debidas al azar (Cohen, 1960). En otras palabras, kappa intenta proporcionar una medida de la exactitud de una clasificación ajustando la exactitud global a la esperada por efecto de la suerte. Para el cálculo del coeficiente kappa, se compara el número total a lo largo de la diagonal (combinaciones en las que los valores de la clasificación coinciden con la verdad terreno) con el número total de píxeles de la matriz. El índice kappa se obtiene de comparar la proporción observada a lo largo de la diagonal ( $P_0$ ) menos la proporción que se espera obtener por azar, dividido por la máxima posibilidad de acuerdo que puede esperarse para los totales marginales ( $1-P_e$ ). La proporción esperada por suerte es estimada sumando el producto de filas y columnas para cada categoría:

$$K = \frac{P_0 - P_e}{1 - P_e} \quad (1.1)$$

$$P_0 = \sum_{i=1}^m P_{ii} \quad (1.2)$$

$$P_e = \sum_{i=1}^c P_i P \quad (1.3)$$

El índice Kappa varía entre -1 y 1, entendiendo que para valores de k próximos a -1 los datos a comparar son totalmente diferentes y para valores cercanos a 1 existe un elevado acuerdo entre la cartografía y los datos de referencia. Para valores de k iguales a 0 se asume que las coincidencias existentes son producto del azar.

También es posible evaluar la exactitud de las diferentes categorías de la clasificación de una forma individualizada. Al número total de píxel clasificados correctamente en una clase divididos por el número total de píxel de los datos de referencia para esa categoría se le denomina “exactitud del productor”. Este índice cuantifica el error de omisión para una determinada categoría, midiendo la probabilidad de que un determinado píxel de los datos de referencia sea correctamente clasificado, es decir de que se incluya en una categoría equivocada. Por otra parte, si se divide el número de los píxel correctos para una categoría entre el número total de píxel clasificados para esa categoría, se obtiene una medida del error de comisión. El índice resultante de esta operación, “exactitud del usuario” o “fiabilidad”, es indicativo de la probabilidad de que un píxel clasificado del mapa represente fielmente al mismo píxel en la realidad.

### **3 Fundamentos de los métodos de clasificación basados en aprendizaje de máquinas**

Muchos estudios dan cuenta de las ventajas de los métodos de aprendizaje automático frente a métodos estadísticos convencionales, en especial cuando el espacio de características es complejo y los datos tienen distribuciones estadísticas diferentes. Diversas técnicas de aprendizaje automático han sido comparadas en numerosos trabajos con clasificadores de máxima verosimilitud, en los cuales se muestra la superioridad de estas metodologías, en lo que a exactitud cartográfica se refiere (Benediktsson et al., 1990; Frizzelle y Moody, 2001; Huang et al., 2002; Na et al., 2010; Pal y Mather, 2003; Seto y Liu, 2003).

La proliferación en el campo de la teledetección de este tipo de métodos en los últimos años se debe a diferentes factores (Mas y Flores, 2008; Mountrakis et al., 2011): a) la habilidad de estas técnicas para aprender patrones complejos, considerando relaciones no lineales entre las variables explicativas y las variables dependientes (bandas de la imagen y clases temáticas); b) la capacidad de generalización de estos algoritmos hace posible su aplicación en bases de datos

incompletas o ruidosas (DeFries y Chan, 2000); c) permiten la incorporación en el análisis de información *a priori* (Foody, 1995a; Foody, 1995b); d) y debido a la ausencia de asunciones sobre los datos usados (ej. normalidad) permiten la integración de diferentes tipos de datos en el análisis (Benediktsson y Sveinsson, 1997; Rogan et al., 2003). Esta última característica posibilita la incorporación de datos de diferentes sensores y de variables auxiliares como la elevación, pendiente, temperatura, emisividad, textura, así como mapas temáticos (Pacifci et al., 2009; Rogan et al., 2008).

En esta sección se presentan los fundamentos teóricos de algunos métodos de clasificación basados en aprendizaje de máquinas, que son usados para la generación de cartografía a partir de imágenes de satélite.

## **3.1 Clasificadores en árbol**

### **3.1.1 Árboles de decisión**

Los árboles de decisión (AD) constituyen uno de los métodos más utilizados en la clasificación de coberturas del suelo a partir de imágenes de satélite (Friedl y Brodley, 1997; Hansen et al., 1996; Lippitt et al., 2008; Pal y Mather, 2003; Rogan et al., 2003; Wessels et al., 2004), debido a su escaso coste computacional, su simplicidad e interpretabilidad y a la posibilidad de ser representados gráficamente.

Un AD representa un conjunto de restricciones o condiciones que se organizan de forma jerárquica, y que se aplican sucesivamente desde una raíz hasta llegar a un nodo terminal u hoja del árbol (Breiman, 1984; Quinlan, 1993).

Los árboles de decisión se representan mediante un grafo con estructura arbórea que ha sido inducido desde un conjunto de datos. Todo AD comienza con un nodo al que pertenecen todos los casos de la muestra que se quiere clasificar, a este nodo se le denomina nodo raíz. Además del nodo raíz, en un AD pueden distinguirse nodos internos y nodos terminales, que también se denominan hojas. Los nodos internos se corresponden con una condición elegida en el conjunto de atributos, y cada

ramificación de un nodo interno representa un valor del dominio de la condición del atributo. Los nodos terminales u hojas contienen una única etiqueta. Desde la raíz del árbol hasta una determinada hoja, el camino conforma una regla de clasificación.

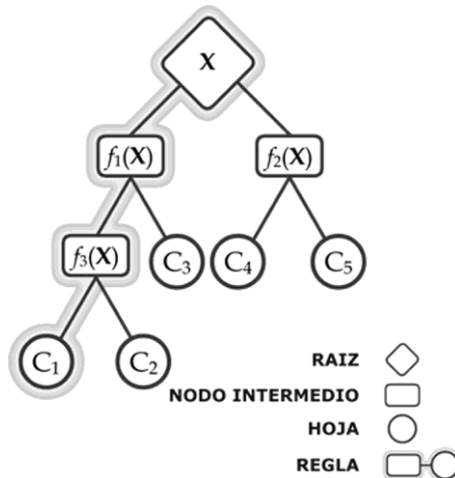


Figura 3.1. Esquema conceptual de un árbol de decisión.

Para inducir el AD, a partir de un conjunto de datos, es necesario utilizar una medida de evaluación de cada uno de los atributos de condición que maximice la heterogeneidad entre clases. Hay muchas aproximaciones para seleccionar atributos, que pueden ser usadas en la inducción de los modelos de árboles de decisión. Algunas de las más frecuentes son “*gain-ratio*” (Quinlan, 1993), índice Gini (Breiman et al., 1984) y Chi-cuadrado (Mingers, 1989).

Una vez que se ha elegido la medida de evaluación, es necesario determinar la variable por la que se va a empezar las divisiones (nodo raíz). El caso ideal sería encontrar la variable para la que todos los nodos hijos estuvieran formados por casos de una única clase. A partir del nodo raíz, el proceso de división de los datos en cada uno de los nodos internos de una regla de clasificación del árbol, se repite hasta que todos los ejemplos presenten la misma etiqueta, o se alcance una condición de parada previamente especificada. Una vez finalizado el proceso de inducción del árbol, se aplica la poda con la intención de mejorar la capacidad de generalización del árbol

mediante la reducción de su complejidad estructural. Como criterio de poda se pueden tomar factores como el número de nodos hoja, el número de nodos internos o la profundidad del árbol.

### **3.1.2 Random Forest**

Las técnicas de clasificación basadas en aprendizaje de conjunto (ej. random forest, bagging y *boosting*) han probado ser más exactas y robustas frente al ruido que los clasificadores simples basados en árboles de decisión (Breiman, 1996; Dietterich, 2000). Dentro del campo de los meta-clasificadores, Random Forest (RF)(Breiman, 2001) es una técnica de clasificación, que ha sido incorporada recientemente al campo de la teledetección para la creación de cartografía a partir de imágenes multi- e hiperespectrales (Chan y Paelinckx, 2008; Ghimire et al., 2010; Lawrence et al., 2006; Pal, 2005; Sesnie et al., 2008), y de datos lidar y radar (Guo et al., 2011; Latifi et al., 2010; Martinuzzi et al., 2009; Waske y Braun, 2009). RF presenta numerosas ventajas para su aplicación en teledetección (Breiman, 2001; Breiman y Cutler, 2004):

- Puede aplicarse a grandes bases de datos
- Puede utilizar un gran número de variables sin necesidad de un filtrado previo
- Produce estimaciones de que variables son más importantes en clasificación
- Genera una estimación interna insesgada del error de generalización (error OOB)
- Calcula las proximidades entre pares de ejemplos que puede usarse para la localización de outliers
- Es robusto frente a los outliers y el ruido
- Tiene un menor coste computacional que otros meta-clasificadores (ej. boosting)



La mayor parte de los estudios que han utilizado RF como método de clasificación se han centrado en áreas de pequeña extensión (Pal, 2005; Waske y Braun, 2009), con un pequeño número de categorías (Gislason et al., 2006; Lawrence et al., 2006; Prasad et al., 2006), o han usado imágenes de una única estación (Chapman et al., 2010; Ghimire et al., 2010; Ham et al., 2005). Por otro lado, la mayoría de estos estudios no han tratado de comprender el comportamiento de los clasificadores RF, mediante la evaluación de la calidad, así como las variaciones en el tamaño del conjunto de datos de entrenamiento (Chan y Paelinckx, 2008; Gislason et al., 2006; Ham et al., 2005; Lawrence et al., 2006; Pal, 2005; Prasad et al., 2006; Sesnie et al., 2008).

RF es un meta-clasificador que utiliza árboles de decisión como clasificadores base, en el que cada clasificador contribuye con un voto para la asignación de la clase más frecuente al vector de entrada  $\hat{C}_{rf}^K(\mathbf{x}) = \text{voto mayoritario} \left\{ \hat{C}_k(\mathbf{x}) \right\}_1^K$ , donde  $\hat{C}_k(\mathbf{x})$  es la clase predicha por el árbol de clasificación  $b$ , perteneciente al conjunto de árboles que forman el bosque (B). RF incrementa la diversidad de los árboles de decisión haciéndolos crecer a partir de diferentes subconjuntos de datos creados mediante un procedimiento denominado *bagging* o *bootstrap aggregating* (Breiman, 1996). *Bagging* es una técnica diseñada para la creación de datos de entrenamiento que remuestra aleatoriamente el conjunto de datos originales con reemplazamiento, es decir, sin borrar el conjunto de datos seleccionados de forma previa a la elección del siguiente subconjunto  $\{h(\mathbf{x}, \Theta_k), k = 1, \dots\}$ , donde  $\mathbf{x}$  es un vector de entrada y  $\{\Theta_k\}$  son vectores aleatorios independientes que presentan la misma distribución (Breiman, 2001; Hastie et al., 2009). Por tanto, algunos datos pueden ser usados más de una vez en el entrenamiento de los clasificadores individuales. Esta propiedad de RF lo hace menos sensible a ligeras variaciones de los datos de entrada (cambios en el entrenamiento, *outliers*, ruido...), y, al mismo tiempo, incrementa la exactitud de las clasificaciones (Breiman, 2001). Diversos estudios han probado que los métodos basados en *bagging* como RF, a diferencia de otros basados en *boosting*, son menos

sensibles al ruido o al sobre-entrenamiento (Briem et al., 2002; Chan y Paelinckx, 2008; Pal y Mather, 2003).

Cada subconjunto seleccionado mediante *bagging* para hacer crecer cada árbol individual normalmente contiene  $2/3$  de conjunto de entrenamiento. Las muestras que no son incluidas en el subconjunto de entrenamiento muestreado, se incluyen en otro subconjunto denominado “*out of bag*” (OOB). Estos elementos OOB, que no han sido considerados para el entrenamiento del árbol, pueden ser clasificados para evaluar la bondad del modelo. Al final del proceso, cada elemento de entrada del subconjunto OOB ha sido clasificado en media por un tercio del total de los árboles que forman RF (Peters et al., 2007). La proporción entre los ejemplos mal clasificados y el total de elementos del subconjunto OOB constituye una estimación insesgada del error de generalización (Breiman, 2001). El error de generalización siempre converge cuando el número de árboles aumenta, por lo que RF no se sobreajusta a los datos. Además, cuando RF crea un árbol de clasificación, usa la mejor división de un conjunto de variables o características aleatorias en la división de cada nodo (utiliza el índice de Gini; ver sección 3.1.1), en lugar de usar las mejores variables de división. Por lo que, por una parte, este hecho puede disminuir la exactitud de cada árbol individual, pero por otro lado, también reduce la correlación entre los árboles, y por tanto el error de generalización (Breiman, 2001). Otra característica de interés es que los árboles generados por RF crecen sin poda, lo cual reduce el coste computacional.

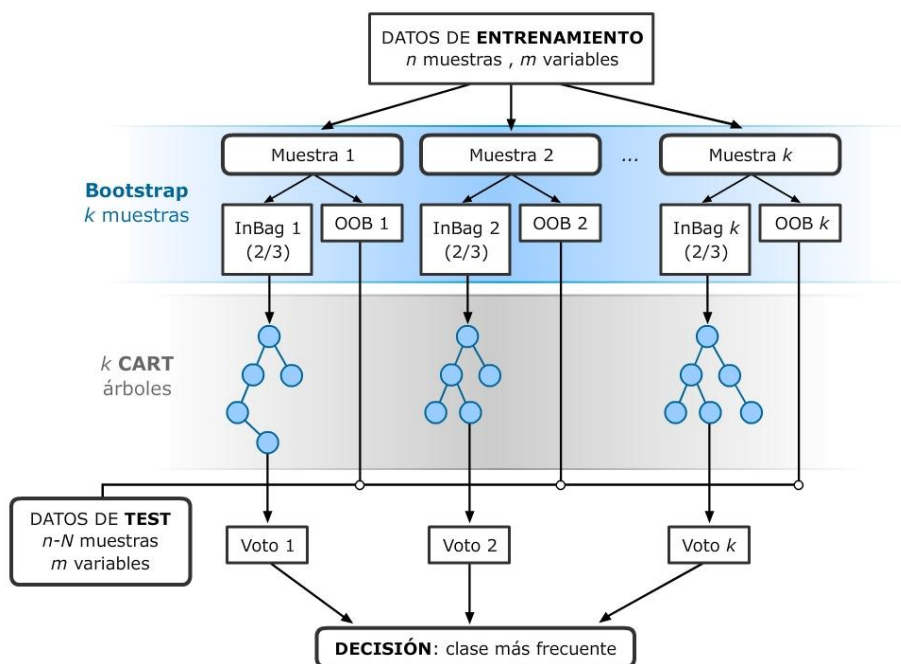


Figura 3.2. Esquema de la metodología de clasificación basada en RF.

RF evalúa la importancia relativa de las diferentes variables durante el proceso de clasificación. Este aspecto es muy útil para los estudios multi-fuente, donde la dimensionalidad de los datos es muy alta, y es importante conocer como cada variable predictiva influye en la exactitud del modelo final, para de esta forma poder seleccionar las mejores variables (Ghimire et al., 2010; Gislason et al., 2004; Gislason et al., 2006; Ham et al., 2005; Pal, 2005). Para evaluar la importancia de cada característica (ej. banda de una imagen de satélite), RF elimina una de las variables de entrada al modelo mientras que mantiene el resto constantes, y después mide el decrecimiento en exactitud derivado, mediante la estimación del error OOB o mediante el decrecimiento en Gini (Breiman, 2001).

Finalmente, RF también puede medir la “proximidad” entre cada par de casos. Para calcular la proximidad entre dos muestras de la misma clase, RF cuenta el

número de veces en que dichas muestras aparecen en un nodo terminal; es decir, cuantos árboles etiquetan cada posible par de casos de la misma clase con la misma regla de división. Una vez que cada árbol ha sido construido, y se han calculado las proximidades para cada par de casos, estas son normalizadas por el número de árboles. Estas medidas de proximidad son susceptibles de ser usadas para el reemplazamiento de valores perdidos y localización de *outliers* (ej., muestras erróneamente clasificadas en los datos de entrenamiento).

### **3.2 Redes neuronales**

Las redes neuronales artificiales, RNA (*artificial neural networks*) se han convertido en una herramienta muy popular en el análisis de datos de teledetección (Atkinson y Tatnall, 1997; Mas y Flores, 2008). A partir de los años 90 ha venido siendo cada vez más frecuente la aplicación de diferentes tipos de redes en la clasificación de cubiertas y usos del suelo (Atkinson y Tatnall, 1997; Benediktsson et al., 1990; Chen et al., 2009; Filippi y Jensen, 2006; Foody y Arora, 1997; Kanellopoulos y Wilkinson, 1997; Pacifici et al., 2009).

En su forma más general, las RNA son algoritmos diseñados para emular la actividad de sistemas neuronales biológicos. Las RNA se inspiran en el hecho de que el cerebro humano procesa de forma muy eficiente grandes cantidades de datos que proceden de fuentes muy diferentes (Atkinson y Tatnall, 1997). Las neuronas del cerebro humano reciben información de otras neuronas y a su vez, producen información de salida (si la suma de la información de entrada supera un cierto umbral), que pasará de nuevo a otras neuronas. Aunque las RNA están biológicamente inspiradas, la mayor parte de las arquitecturas de RNA no tratan de imitar fidedignamente un modelo biológico, sino que más bien pueden ser consideradas simplemente como una clase de algoritmos paralelos (Bishop, 1995).

Hay muchos tipos diferentes de RNA, sin embargo, no es el objetivo de este estudio describir los distintos tipos de redes, que pueden consultarse en bibliografía. Esta sección proporciona una breve descripción de una de las RNA más usadas en

teledetección, la red neuronal de propagación hacia delante (*feed-forward propagation*) (Venables y Ripley, 2002).

Como en el cerebro, los elementos básicos de procesamiento de una red neuronal artificial son las neuronas (unidades o nodos). Estas unidades están interconectadas por enlaces o conexiones ponderados para generar así una red, en analogía a la forma en que las neuronas biológicas están interconectadas a través de las dendritas (prolongaciones dendriformes que sirven de conexión con otras neuronas) y el axón (canal por el que fluyen impulsos eléctricos o información). Las células neuronales funcionan acumulando señales entrantes provenientes de conexiones con otras neuronas, de forma que cuando se supera un cierto umbral, se produce el disparo o transmisión de la señal recibida a todas las neuronas con las que está conectada. Los primeros modelos de neuronas, formulados en los años cuarenta, simulaban el funcionamiento de las células actuando como una unidad de cálculo que suma el producto de todas las entradas por un peso, y se dispara si este producto es mayor que un umbral. Así, si  $w_i$  son los pesos,  $\mathbf{x}_i$  son las entradas, y  $\theta$  el umbral, una neurona se dispara si:

$$\sum_i w_i \times \mathbf{x}_i \geq \theta \quad (3.4)$$

Estas unidades, interconectadas, podrían simular cualquier función lógica booleana (AND, OR, etc.) si se asignaran a los pesos valores adecuados, aunque, debido a que sus conexiones (pesos) están preestablecidas, estas neuronas no “aprendían”. Posteriormente, en los años sesenta, se añadió a este modelo una regla de aprendizaje para crear lo que se conoce como perceptrón, que sí era capaz de efectuar algunas tareas de reconocimiento de patrones activando la neurona correspondiente (es decir, decidir a qué clase pertenece un vector de entrada presentado a la red). El método de aprendizaje, muy simple, consiste en los siguientes pasos: ( $t$  indica cada vez que se presentan las entradas;  $\mathbf{x}_i$ ,  $y_j$  y  $d_j$  pueden presentar sólo valores 0 o 1):

Paso 1. Presentar a la red el vector (patrón; 0/1) de entrada,  $\mathbf{x}_i$ , y calcular la salida  $y_j$  multiplicando por los pesos  $w_{ij}$ :

$$y_j = \sum_i w_{ij} \mathbf{x}_i(t); \quad j = 1, \dots, n \quad (3.5)$$

Paso 2. Si la salida es correcta, es decir, si  $d_j = y_j \forall j$ , ir al paso 1, en caso contrario, es decir, si  $d_j \neq y_j$ :

Paso 2.1. Si la salida  $y_j$  es igual a 0, añadir cada entrada al peso correspondiente:

$$w_{ij}(t+1) = w_{ij}(t) + \mathbf{x}_i(t)$$

Paso 2.1. Si la salida  $y_j$  es igual a 1, restar cada entrada al peso correspondiente:

$$w_{ij}(t+1) = w_{ij}(t) - \mathbf{x}_i(t)$$

Paso 3. Si hay cambios en los pesos ir al paso 1, en caso contrario salir.

Una red de este tipo puede aprender, ya que las neuronas están conectadas con todas las entradas a través de un peso que evoluciona según va aprendiendo (Bishop, 1995). Sin embargo, este perceptrón monocapa sólo puede distinguir entradas que son linealmente separables y no puede, por ejemplo, aprender la función XOR. Además, con este modelo no era posible repartir el error entre las neuronas (entrenar los pesos mediante su ajuste) en caso de que hubiera distintas capas de neuronas (perceptrón multicapa).

En la Figura 3.3 se muestra una unidad o neurona y la arquitectura de una configuración simple, denominada, como se ha indicado anteriormente, perceptrón multicapa. En la misma, las unidades se sitúan en capas y están conectadas de forma que la información fluye unidireccionalmente, desde las unidades de entrada a través de la unidad o unidades situadas en la capa o capas ocultas hasta las unidades en la capa de salida.

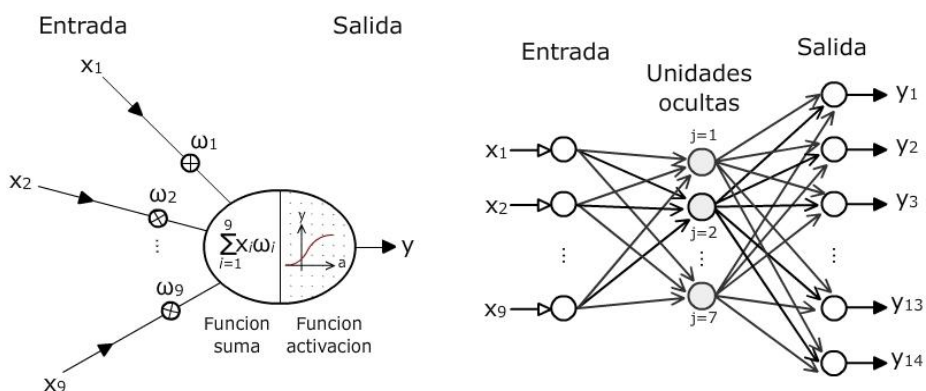


Figura 3.3. Esquema de la metodología de clasificación basada en RNA

Las unidades de entrada distribuyen la señal a las unidades ocultas de la segunda capa. Estas unidades suman las entradas, añaden una constante (el sesgo) y aplican una función fija  $\phi_h$  al resultado. Las unidades de salida presentan la misma forma pero con una función de salida  $\phi_o$ . Por tanto:

$$y_k = \phi_o \left( \alpha_k + \sum_h w_{hk} \phi_h \left( \alpha_h + \sum_i w_{ih} x_i \right) \right) \quad (3.6)$$

La función de activación de las unidades de la capa oculta,  $\phi_h$ , suele ser una función logística  $\ell(z) = \exp(z)/1 + \exp(z)$ . Por tanto, se aplica una función no lineal a la activación de la neurona, activación que se halla sumando el producto de las entradas por el valor de los pesos. La función logística se caracteriza por ser creciente y acotada. Por tanto, una unidad en la red suma las entradas ponderadas de las conexiones que le llegan, y transforma el valor sumado mediante una función no lineal. La salida sirve entonces de entrada a otras unidades conectadas a ésta.

La definición de esta red no impone restricciones en cuanto al número de unidades de entrada, ocultas o de salida. Es posible además enlazar unidades de entrada con unidades de salida, o unidades en la misma capa. En este modelo, el

“conocimiento” o la “memoria” se distribuye a través de toda la red, almacenado en la propia topología de la red y en los pesos de las interconexiones y umbrales de las unidades. Todas las unidades de una capa calculan su estado en paralelo, pero ciertas capas calculan su estado secuencialmente, empezando por abajo (izquierda) y realizando las operaciones hacia arriba (derecha), hasta que se determinan los estados de las unidades de salida (conexiones entre nodos de la misma capa). Por tanto, la entrada total,  $\mathbf{x}_j$ , a una unidad  $j$  es una función lineal de las salidas,  $y_i$ , de las unidades que están conectadas a  $j$  y de los pesos,  $w_{ji}$ , de esas conexiones. A las unidades se les puede proporcionar umbrales introduciendo una entrada extra a cada unidad que siempre presenta el valor 1. El peso en esta unidad extra se llama sesgo (bias), es equivalente a un umbral (threshold) de signo contrario, que puede ser tratado como cualquier otro peso. La salida de la unidad  $j$  es un número real,  $y_j$ , que es sin embargo una función no lineal de su entrada total, como aparece en la ecuación de la Figura 3.3, correspondiente a la función logística, frecuentemente empleada.

$$y_k = \phi_o \left( \alpha_k + \sum_{i \rightarrow k} w_{ik} \mathbf{x}_i + \sum_{j \rightarrow k} w_{jk} \phi_h \left( \alpha_j + \sum_{i \rightarrow j} w_{ij} \mathbf{x}_i \right) \right) \quad (3.7)$$

Para que la red pueda representar cualquier función útil, sus pesos han de ser ajustados. Para ello, se presentan a la red ejemplos consistentes en pares entrada-salida: un vector de entrada y la correspondiente salida deseada para la red. Por ejemplo, el vector de entrada puede ser los valores de las bandas espectrales de las áreas de entrenamiento, y el de salida las categorías temáticas correspondientes a las diferentes cubiertas del suelo. Entonces, la entrada se propaga a través de la red como se ha descrito antes, y la red produce su propia salida. La salida es comparada con la salida deseada. Si no hay diferencia, no hay aprendizaje. En caso contrario, los pesos de las conexiones son modificados para reducir la diferencia. Esto es conseguido de manera iterativa, minimizando el error total, típicamente calculado como la suma de los errores al cuadrado, para todos los pares entrada-salida con respecto a los pesos de la red, mediante el uso métodos de optimización no lineal. Es importante destacar que en esta aproximación no se hace ningún supuesto sobre la forma de las distribuciones



de los datos (normal), ni sobre la independencia de las observaciones. Pueden ser, por tanto, más robustas que las técnicas clásicas, y trabajan bien cuando las entradas están generadas por mecanismos físicos no lineales.

El objetivo del algoritmo es encontrar un conjunto de pesos que asegure que para cada vector de entrada el vector producido por la red es el mismo, o suficientemente cercano, del vector de salida deseado. Si hay un conjunto definido y finito de casos (patrones) entrada-salida, el error total en el funcionamiento de la red con un conjunto particular de pesos puede ser calculado comparando los vectores de salida real y deseada para cada patrón, por ejemplo por mínimos cuadrados.

El error total,  $E$ , se define entonces como:

$$E = \sum_j \|d_j - y_j\|^2 \quad (3.8)$$

donde  $j$  es un índice sobre los patrones (pares entrada-salida),  $y_j$  es el estado real de una unidad de salida y  $t_j$  es el estado deseado. Se han propuesto otras aproximaciones, que incluyen para  $y \in [0,1]$  máxima verosimilitud o la medida de distancia de Kullback-Leibler, que trata de minimizar:

$$E = \sum_j \sum_k \left[ t_j^k \log \frac{t_j^k}{y_j^k} + (1-t_j^k) \log \frac{1-t_j^k}{1-y_j^k} \right] \quad (3.9)$$

Esto es la mitad de la desviación para un modelo logístico binario con predictores lineales dados por las ecuaciones (3.6) y (3.7). Para un modelo log-lineal multinomial con  $K$  clases se puede usar una red neuronal con  $K$  salidas y la log-vecindad negativa condicional:

$$E = \sum_j \sum_k -t_j^k \log p_j^k, \quad p_j^k = \frac{e^{y_j^k}}{\sum_{c=1}^K e^{y_j^c}} \quad (3.10)$$

Una forma alternativa de asegurar que la función  $f$  es “suave” (*smooth*), es la regularización, en la cual el criterio de ajuste es:

$$E + \lambda C(f) \tag{3.11}$$

Donde  $C$  es una función de coste que controla la suavidad de  $f$ . El decaimiento de los pesos usa como coste la suma de los cuadrados de los pesos  $w_{ij}$ . Esto sólo tiene sentido si las entradas son re-escaladas a un rango de valores entre 0 y 1, para que sean comparables con la salida de las unidades internas. El uso del decaimiento de pesos contribuye a ayudar a la optimización del proceso, a la vez que evita el sobreajuste. Ripley (1993, 1994) basándose en una interpretación Bayesiana sugiere valores de  $\lambda \approx 10^{-4}$ - $10^{-2}$ , y para un ajuste por mínimos cuadrados de  $\lambda \approx 10^{-3}$ - $10^{-2}$ .

### 3.3 Máquinas de vectores soporte

En la última década las máquinas de vectores soporte (MVS; *Support Vector Machines*, SVM) han surgido como una alternativa a las RNA para la clasificación de datos de teledetección (Mountrakis et al., 2011; Pal y Mather, 2003). Los MVS han sido aplicados a diferentes fuentes de datos de teledetección como imágenes hiperespectrales (Melgani y Bruzzone, 2004; Pal y Mather, 2003; Plaza et al., 2009), multispectrales de resolución espacial media (ej. Landsat y ASTER) (Dixon y Candade, 2008; Huang et al., 2002; Kavzoglu y Colkesen, 2009; Keuchel et al., 2003; Marçal et al., 2005; Pal y Mather, 2003) e imágenes de alta (Huang et al., 2008; Li et al., 2010) y baja resolución espacial (Carrão et al., 2008; Dash et al., 2007).

Las Máquinas de Vectores Soporte son un conjunto de algoritmos de aprendizaje automático introducidos por Vapnik a principios de los 90 (Boser et al., 1992; Cortes y Vapnik, 1995). Los MVS se basan en el principio de Minimización del Riesgo Estructural (Sierra-Araujo, 2006), puesto que pretenden producir predicciones en las que se pueda tener mucha confianza, aun a riesgo de cometer algunos errores.

Las MVS se fundamentan en encontrar el hiperplano óptimo de separación entre las clases; es decir, el plano para el cual la separabilidad entre clases es máxima. Para facilitar la comprensión de los MVS, imaginemos el caso más sencillo de clasificación, en el cual dos clases son separables linealmente. Para este caso, el

hiperplano óptimo estaría definido por una línea recta equidistante de las rectas que delimitan la frontera entre muestras de clases diferentes. A estas muestras que se encuentran en la frontera se le denominan vectores soportes ( $\mathbf{x}$ ). Estos ejemplos son los más difíciles de clasificar puesto que presentan una menor separabilidad. En este caso, al estar los vectores definidos por características mono-dimensionales (una variable;  $x \in \mathfrak{R}$ ), la ecuación del hiperplano óptimo vendría representada por una recta en el plano. Sin embargo, si los vectores de características tuvieran dos componentes ( $x \in \mathfrak{R}^2$ ), la frontera de separación entre las dos clases sería un plano en un espacio tridimensional. A la distancia de separación entre el plano y los vectores soporte se le denomina margen ( $\tau$ ). El hiperplano óptimo sería aquel cuya distancia a los vectores soporte fuese máxima. Dado un conjunto de entrenamiento  $S = \{(\Phi(\mathbf{x}_i), y_i) [i \in 1, N]\}$ , donde cada  $\mathbf{x}_i$  es un vector de entrada que pertenece al espacio de entrada  $X$ ,  $N$  es el tamaño de la muestra de datos de entrenamiento y  $y_i$  es una constante que toma los valores 1 ó -1, que denotan la clase a la que el vector  $\mathbf{x}_i$  pertenece, si los vectores de características pertenecen a un espacio multidimensional ( $\mathbf{x} \in \mathbb{R}^n, n > 2$ ), cada hiperplano en  $\mathbb{R}^{n+1}$  puede expresarse como:

$$\mathbf{w} \cdot \mathbf{x} + b = 0 \quad (3.12)$$

Desde un punto de vista intuitivo, cuanto mayor sea  $\tau$  mayor poder de generalización tendrá el clasificador, y menor número de errores cometerá en la clasificación de datos futuros. Por tanto, el problema de encontrar el hiperplano óptimo se reduce a encontrar un vector perpendicular al hiperplano ( $\mathbf{w}$ ) que maximice  $\tau$ .

Los datos de teledetección son especialmente complejos, no tienen únicamente dos dimensiones, ni tampoco el objetivo último de la clasificación suele ser diferenciar únicamente dos clases. Los MVS en la clasificación de datos procedentes de satélite deben tratar con múltiples variables predictoras, y, en ocasiones, también con variables auxiliares (textura, modelos digitales del terreno, variables

climáticas...). Por otro lado, en determinados casos la separabilidad entre las categorías puede ser baja, con curvas no lineales de separación.

Para datos de alta dimensionalidad, si se cumplen determinadas condiciones de convexidad, es posible trasladar el problema a una forma dual en la que sea resoluble de forma equivalente (Steinwart y Christmann, 2008). En este caso, el problema de la optimización se plantea en base a multiplicadores de Lagrange, y equivale a maximizar la siguiente expresión:

$$\Phi(\alpha) = \sum_{k=1}^m \alpha_k - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (3.13)$$

Sujeto a las restricciones

$$\left. \begin{array}{l} \alpha_k \geq 0, k=1, \dots, N \\ \sum_{k=1}^m \alpha_k y_k = 0 \end{array} \right\} \quad (3.14)$$

Donde  $\alpha_k$  son los multiplicadores de Lagrange y  $N$  es el número de datos de entrenamiento

Cortes y Vapnik (1995), para resolver el problema de la clasificación de muestras que son separables linealmente cometiendo algunos errores, introdujeron un método basado en un margen blando (*soft margin*). En este caso, para encontrar el hiperplano que cometa el mínimo número de errores, se introducen un conjunto de variables escalares no negativas, una por cada muestra de entrenamiento  $\xi_k \geq 0, k = 1, \dots, m$ . El cálculo del hiperplano de separación requiere determinar los  $\mathbf{w}$  que minimicen el funcional:

$$\Phi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{k=1}^m \xi_k, k = 1, \dots, m \quad (3.15)$$

Sujeto a las restricciones  $y_k (\mathbf{w} \cdot \mathbf{x}_k + b) \geq 1 - \xi_k, k = 1, \dots, m$ , donde  $C$  es una constante de regularización. La constante  $C$ , también denominada coste, controla la solución de compromiso entre la complejidad de la MVS y el número de ejemplos no

separables. Para valores altos de  $C$  el hiperplano se sobreajusta más a los datos, es decir, considera en mayor medida los *outliers* de cada clase presentes en el conjunto de entrenamiento. Por el contrario, valores bajos en la constante  $C$  harán que el sistema busque una hipótesis más simple y por tanto más generalizable a riesgo de subajustarse a los datos. Si la función coste es lineal, el dual de la optimización ha de maximizar el funcional:

$$\Phi(\alpha) = \sum_{k=1}^m \alpha_k - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (3.16)$$

Sujeto a las restricciones

$$\left. \begin{aligned} 0 \leq \alpha_k \leq C, \quad k=1, \dots, N \\ \sum_{k=1}^m \alpha_k y_k = 0 \end{aligned} \right\} \quad (3.17)$$

Cuando las muestras de entrenamiento no pueden separarse mediante una función lineal, es necesaria la aplicación de funciones de transformación no lineales denominadas *kernels*, que transforman el espacio de entrada ( $X$ ) en un espacio de Hilbert de mayor dimensionalidad en el que los datos son separables linealmente (Muller et al., 2001). A este nuevo espacio se le denomina espacio de características para distinguirlo del espacio de entrada. De forma que, usando funciones *kernels* ( $K$ ), es posible calcular el producto escalar en el espacio de Hilbert. Para que una función sea una función *kernel* ha de ser simétrica y semidefinida positiva (Schölkopf y Smola, 2001). Algunas de las funciones *kernel* más comúnmente utilizadas son:

$$K_{linear}(\mathbf{x}, \mathbf{x}') = \mathbf{x} \cdot \mathbf{x}' \quad (3.18)$$

$$K_{polynomial}(\mathbf{x}, \mathbf{x}') = (\gamma \mathbf{x} \mathbf{x}' + \mathbf{r})^p \quad (3.19)$$

$$K_{RBF}(\mathbf{x}, \mathbf{x}') = \exp\left(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2\right) \quad (3.20)$$

$$K_{sigmoid}(\mathbf{x}, \mathbf{x}') = \tanh(\gamma \mathbf{x} \mathbf{x}' + \mathbf{r}) \quad (3.21)$$

Donde  $\mathbf{x}$  y  $\mathbf{x}'$  son vectores pertenecientes al espacio de entrada y al de características, respectivamente,  $\rho$  es el grado del polinomio y  $\gamma$  y  $r$  son parámetros que permiten maximizar la exactitud del MVS.

Los MVS, originalmente, tenían una naturaleza dicotómica y, por tanto, sólo podían distinguir entre dos clases. Ante la necesidad de resolver problemas de clasificación multiclase, se han propuesto diversas técnicas para combinar clasificadores binarios diferentes. Las técnicas más conocidas son “una frente a todas” (*one-versus-all*) y “una frente a una” (*one-versus-one*). El primer método construye un conjunto de clasificadores binarios en los cuales cada una de las clases se enfrenta al resto. Para que una clasificación se considere admisible es necesario que el elemento a clasificar sólo esté asociado a una clase en un clasificador, mientras que en los demás biclasificadores, el elemento debe pertenecer a la categoría resto. El segundo método construye una MVS para cada par de enfrentamientos posibles entre clases, posteriormente se someten los nuevos ejemplos a cada uno de los clasificadores y se asigna un voto a la clase ganadora para cada caso. De forma que al final se asigna la clase que más votos ha sacado del total de votos asignados por los clasificadores.

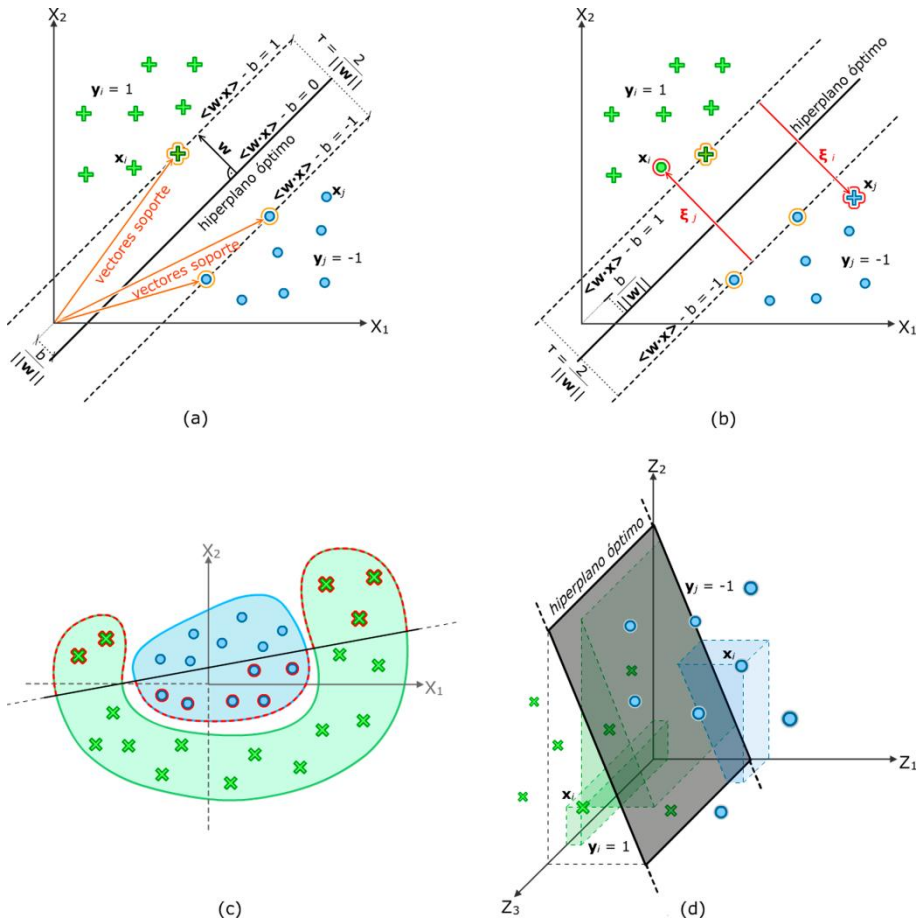


Figura 3.4. Esquema de la metodología de clasificación basada en MVS.

## 4 Aplicación metodológica de los algoritmos de clasificación

Para estudiar la bondad de los diferentes algoritmos de aprendizaje de máquinas para la clasificación de datos de satélite, fueron usadas diferentes variables espectrales y auxiliares. Por una parte, las variables espectrales consistieron en las componentes Kauth Thomas de las imágenes de primavera y verano. Por la otra, las variables incluidas en el análisis fueron la elevación, pendiente y orientaciones, derivadas del

modelo digital del terreno (MDT) de la Provincia de Granada (Sección 2 del Capítulo 2).

## **4.1 Clasificadores en árbol**

### **4.1.1 Árboles de decisión**

En el caso de los árboles de decisión, es necesario establecer una serie de parámetros para su entrenamiento, como son la medida de disimilitud, la profundidad del árbol y el número mínimo de observaciones por nodo. La medida de disimilitud o heterogeneidad influye en la forma en la que el algoritmo realiza las divisiones de los datos a nivel de cada nodo. La profundidad del árbol y el número mínimo de observaciones son parámetros ligados a la complejidad estructural de los árboles, cuanto mayor sea el número de niveles y menor el número de observaciones mínimas en los nodos mayor será la complejidad estructural del modelo. Por tanto, es necesario establecer estos parámetros para que se pueda conseguir la mayor exactitud en la clasificación de los datos de entrenamiento, evitando la creación de estructuras de árbol complejas que se sobreajusten a los datos y pierdan generalidad (Pal y Mather, 2003). En este estudio se construyeron modelos de árboles de decisión de tipo CART (Breiman, 1984). Para la inducción de los árboles se contemplaron dos tipos de medidas de disimilitud diferente, el índice Gini y la ganancia de información (Breiman, 1984; Quinlan, 1993). Con el objeto de obtener modelos robustos y generalizables se evaluaron todos los modelos de árboles de decisión posibles para profundidades de árbol de 2 a 29 y el mínimo número de observaciones por nodo entre 1 a 50, lo que dio lugar a 2700 modelos de árboles de decisión diferentes. La exactitud cartográfica de los modelos fue evaluada mediante su aplicación a un test independiente (Capítulo 2).

### **4.1.2 Random Forest**

A diferencia de la mayor parte de las metodologías basadas en aprendizaje de máquinas (ver sección 3), RF sólo necesita la definición de dos parámetros para la



generación de un modelo de predicción: el número de árboles de clasificación ( $k$ ) y el número de variables predictivas ( $m$ ) que son usadas en cada nodo para hacer crecer los árboles de decisión. En otras palabras, para clasificar un conjunto de datos de entrada se usa un número constante de variables predictivas y cada uno de los ejemplos es clasificado por un número  $k$  de árboles definido por el usuario. De esta forma el valor final de la clase asignada a cada ejemplo es igual al valor más frecuente del total de árboles  $k$  generados. Breiman (1996) demostró que al incrementar el número de árboles el error de generalización siempre converge por lo que el sobreentrenamiento no es un problema. Por otra parte, al reducir el número de variables predictivas ( $m$ ) se reduce la correlación entre los árboles, lo que aumenta la exactitud del modelo. Por tanto, es necesario optimizar los valores de los parámetros  $k$  y  $m$  para minimizar el error de generalización.

Para establecer el valor óptimo de  $m$ , se llevó a cabo un gran número de experimentos usando diferentes números de árboles y de variables de división. El rango del número de árboles se fijó entre 1 y 1000 y el número de variables de división de 1 a 9, a intervalos de 1. Esta combinación de parámetros dio lugar a 9000 modelos diferentes RF para la clasificación del área de estudio. Los modelos resultantes fueron evaluados usando el índice Kappa (Congalton y Green, 2009). Para la determinación del mejor modelo se escogió aquel con un índice Kappa más alto y un número de variables de división más bajo. Este criterio fue adoptado para garantizar la máxima exactitud de los mapas generados, a la vez que se evitó que la correlación entre los árboles fuese alta.

## **4.2 Redes neuronales**

Existen diferentes factores que afectan a la capacidad de las RNA para generalizar, es decir para clasificar nuevos datos a partir del aprendizaje realizado con los datos de entrenamiento. Entre ellos, se encuentran los factores intrínsecos al diseño de las redes: el número de nodos y la arquitectura de la red. Puesto que el número de unidades de entrada y de salida viene determinado por las variables predictoras y el número de categorías a clasificar, el problema de la definición de la

arquitectura de red más adecuada está únicamente relacionado con la naturaleza de la capa oculta, es decir, cuantas capas ocultas y unidades usar en el diseño de la RNA. No hay ninguna regla para la determinación del número de capas ocultas, pero teóricamente una única capa oculta puede representar cualquier función Booleana (Atkinson y Tatnall, 1997). En términos generales cuanto mayor sea el número de unidades de la capa oculta, mayor será la capacidad de la red para representar los patrones de los datos de entrenamiento. Sin embargo, el hecho de que la capa oculta tenga un número elevado de unidades, también produce una pérdida en el poder de generalización de las redes (Atkinson y Tatnall, 1997; Foody y Arora, 1997).

Con el objetivo de encontrar una solución de compromiso entre la exactitud de la red y el poder de generalización, se construyeron diferentes modelos de redes neuronales de propagación hacia delante, usando una función de transferencia sigmoidea estándar. Para ello, se entrenaron redes neuronales de arquitecturas diferentes, formadas por una única capa oculta, cuyo número de unidades fue fijado desde 1 hasta 20. Del mismo modo, para optimizar el entrenamiento de la red, el rango de pesos iniciales asignados por la red fue fijado entre el intervalo comprendido entre -1 y 1, con incrementos de 0.02. A partir de estos valores iniciales, se consideraron diferentes valores de decaimiento de los pesos, (desde 0.01 a 0.1 a intervalos de 0.005). El valor óptimo de los pesos fue establecido mediante una función de mínimos cuadrados, que minimizó las diferencias entre las salidas de la red real y deseada (ver sección 3.2). Esta combinación de parámetros dio lugar a un total de 15.580 modelos de redes neuronales diferentes.

### **4.3 Máquinas de vectores soporte**

Las MVS necesitan del ajuste de un elevado número de parámetros para su optimización: a) funciones *kernels*, del tipo lineal, polinomial, sigmoidea y de base radial (RBF), b) coste c) gamma de la función *kernel*, a excepción del kernel lineal, d) sesgo en la función *kernel*, sólo aplicable al kernel polinomial y sigmoideo y, por último, e) grado del polinomio, sólo aplicable al kernel polinomial. El valor adecuado de estos parámetros es específico de la naturaleza de los datos, por lo que es necesaria

su optimización para obtener modelos generalizables; es decir, que no sobreajusten o subajusten a los datos y sean por tanto exactos (Yang, 2011).

Para evaluar el impacto en la exactitud cartográfica de cada uno de los parámetros mencionados en el párrafo anterior se construyeron un conjunto de 621.000 MVS para las diferentes combinaciones de parámetros. Para evaluar cada uno de los MVS construidos, estos fueron aplicados a la clasificación de un conjunto de áreas test, independiente de la calibración de los modelos. En la construcción de los MVS el coste fue fijado entre 0.1 y 100 a intervalos de 0.1, gamma entre 0.05 y 1 a intervalos de 0.05. En el caso del kernel polinomial se calcularon los modelos considerando las distintas combinaciones de parámetros anteriores para cada uno de los 10 grados posibles del polinomio (número de variables +1). El sesgo, que también tomó valores entre 1 y 10, se aplicó a cada uno de los modelos del kernel sigmoideo. Sin embargo, en el caso del kernel polinomial, el sesgo sólo se aplicó al grado del polinomio para el cual se obtuvieron los mejores resultados derivados del test.

## **5 Resultados de las clasificaciones**

### **5.1 Parametrización de los algoritmos**

Uno de los objetivos de este estudio es evaluar los parámetros internos de configuración de los algoritmos de clasificación y su influencia en la creación de modelos robustos y generalizables; y por tanto, conocer como pueden afectar a la exactitud de la clasificación de las cubiertas del área de estudio. A continuación se detallan los parámetros utilizados en la construcción de los diferentes tipos de modelos.

## 5.1.1 Clasificadores en árbol

### 5.1.1.1 Árboles de decisión

Los parámetros considerados en la construcción de los modelos CART fueron: el tipo de medida de heterogeneidad, el número mínimo de observaciones por nodo y la profundidad de los árboles (sección 4.1.1). El modelo con un índice Kappa mayor (0.85) se creó a partir del índice Gini como medida de heterogeneidad, 6 variables como mínimo en cada nodo y una profundidad del árbol de 7. Los modelos construidos usando la medida de heterogeneidad, “ganancia de información”, dieron lugar a índices Kappa menores (0.83).

La Figura 3.5A muestra como el error de clasificación aumenta, una vez que se ha alcanzado un mínimo en torno a los 6 niveles de profundidad, hasta alcanzar un máximo en torno a diez, a partir del cual el error converge. Por tanto, es preferible limitar la profundidad de los árboles para que no sobreajusten a los datos y así, el modelo no pierda generalidad (Pal y Mather, 2003). Los modelos que utilizaron la ganancia de información como medida de heterogeneidad, se sobreajustaron más a los datos, lo cual queda reflejado en los errores de clasificación, que fueron mayores a los del índice Gini; el error mínimo de clasificación se obtuvo para valores de profundidad mayores y de  $m$  menores (ver sección 4.1.1). La Figura 3.5B representa el error derivado de fijar el número mínimo de observaciones en cada nodo, considerado el valor de profundidad para el cual se alcanzó el máximo de exactitud para los modelos basados en Gini y en ganancia de información. A partir de esta figura, se pueden apreciar como el error de los modelos de árboles de decisión basados en Gini es menor que el de los modelos basados en ganancia de información. Los modelos basados en ganancia de información alcanzan un error mínimo para valores de  $n$  iguales a 1, lo que indica que estos modelos necesitan crear reglas de división para clasificar únicamente una observación, por lo que se sobreajustan mucho a los datos y, por tanto, pierden generalización y su exactitud cartográfica es menor. Por otro lado, los modelos basados en Gini alcanzaron un error mínimo para

valores de  $n$  iguales a 7, de lo que puede deducirse un menor ajuste a los datos en relación con los modelos anteriores.

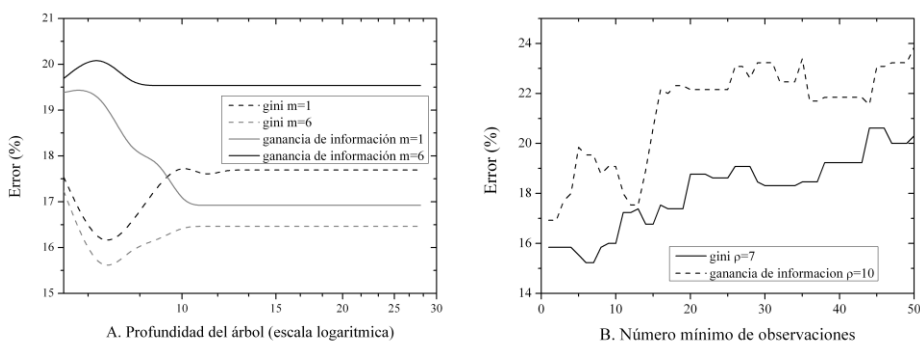


Figura 3.5. A. Efecto de la profundidad de los árboles y número de observaciones mínimas en los nodos ( $n$ ) en el error del test independiente. B. Efecto del número de observaciones mínimas en los nodos.

### 5.1.1.2 Random Forest

Como ya se ha explicado en las secciones 3.1.2 y 4.1.2, RF incorpora un parámetro adicional que no se contempla en los árboles de decisión tradicionales, el parámetro  $m$ . Este valor  $m$  permanece constante mientras que el árbol crece y la selección de las variables se hace de forma aleatoria. La Figura 3.6 muestra el error en función del número de árboles para el valor mínimo y máximo de  $m$ . Se puede distinguir entre dos medidas de error diferentes: la estimación a partir de un test independiente y la estimación a partir del subconjunto OOB. Aproximadamente, a partir de 100 árboles el error OOB converge hasta el 8 y 9% para  $m$  igual a 1 y 9, respectivamente. La adición de más árboles ni incrementó ni disminuyó el error de generalización. Sin embargo, el tiempo de cómputo aumenta considerablemente para valores altos de  $k$ . Los valores muy pequeños de  $k$  dieron lugar a resultados pobres, mientras que los valores altos de  $k$  produjeron clasificaciones más exactas. Las otras dos curvas muestran el error estimado a partir del conjunto test, es decir representa la proporción de muestras del test que fueron clasificadas erróneamente. Los errores en

el test fueron aproximadamente iguales al 9% y 11% para valores de  $m$  iguales a 1 y 9, respectivamente. De manera similar al caso del error OOB, el error del test converge a partir de 100 árboles. En cualquier caso, dado que RF no se sobreajusta a los datos al añadir más árboles de decisión, es posible añadir más árboles y sobrepasar el punto en el que el error converge para obtener estimaciones del error OOB insesgadas, lo cual es de gran utilidad para la estimación de la importancia relativa a partir de la medida OOB (Breiman, 2001).

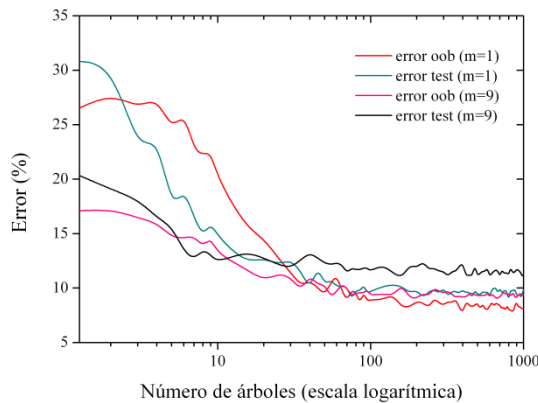


Figura 3.6. Efecto del número de árboles ( $k$ ) y variables aleatorias ( $m$ ) en el error OOB y del test independiente.

El promedio de las diferencias absolutas entre la estimación del error OOB y test fue igual al 1.8% y 2% para  $m$  igual a 1 y 9, respectivamente. Por lo que puede concluirse que la estimación OOB es tan exacta como la estimación basada en el test independiente (Breiman, 1996; Breiman, 2001). Sin embargo, a diferencia de la estimación test, la estimación OOB es insesgada. Teniendo en cuenta esto, no es necesario usar un test independiente, por lo que el uso de RF supone una ventaja comparativa en relación a otros algoritmos para la clasificación de áreas en las que el número de datos es reducido. El promedio de las diferencias absolutas del error de la estimación OOB entre el mínimo y el máximo de  $m$  a partir de 100 árboles es igual al 1%, de lo que se puede deducir que una vez que se ha alcanzado el punto de convergencia RF no es sensible al valor de  $m$ .

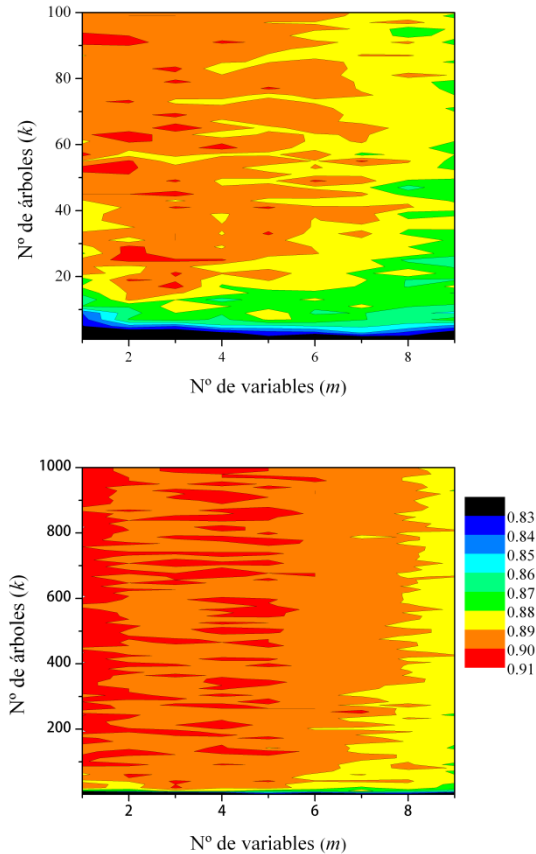


Figura 3.7. Resultados del índice Kappa en relación con el número de árboles ( $k$ ) y el número de variables aleatorias ( $m$ ).

La Figura 3.7 muestra la relación entre el número de árboles y el número de variables de división y la exactitud cartográfica (Kappa). El valor de Kappa más alto fue obtenido cuando se usaron 479 árboles de decisión y una única variable aleatoria. Pese a que en numerosos estudios se ha demostrado la superioridad de los árboles de decisión multivariados (Breiman et al., 1984; Pal y Mather, 2003; Utgoff y Brodley, 1990), en este caso el uso de una única variable en la división de cada nodo produjo mejores resultados que el uso de múltiples variables en la clasificación del área de

estudio. Esto es debido a que RF puede combinar las decisiones de un conjunto de árboles univariados, lo cual le confiere un carácter multivariado.

### ***Medida de la importancia relativa de las variables predictoras mediante RF***

La disposición de las variables predictoras en los árboles de decisión proporciona información sobre la importancia de estas variables o características en el modelo general de clasificación y en la clasificación de cada categoría (Pal y Mather, 2003). Sin embargo, es casi imposible llevar a cabo este análisis a partir de metaclasificadores basados en múltiples árboles de decisión. En el caso del metaclasificador RF es posible evaluar la importancia de las variables mediante el índice Gini y el subconjunto OOB (sección 3.1.2).

Para el cálculo de la importancia relativa de las variables se utilizó la mejor combinación de parámetros obtenida a partir del análisis de la sección anterior, es decir 479 árboles y una variable aleatoria. La Figura 3.8A y Figura 3.8B muestran las contribuciones de las variables espectrales y topográficas al modelo de clasificación RF. De acuerdo con el índice Gini, las variables con una mayor contribución son las bandas de verdor y brillo de verano seguidas de la elevación y el verdor de primavera, con valores iguales a 164 y 156 respectivamente. La contribución de la humedad, pendiente y orientación es menos importante que la del resto de bandas. En relación a la medida OOB, la mayor contribución es la aportada por las bandas de verdor (primavera y verano), con valores iguales a 0.9 en ambos casos. La elevación tiene también una importancia destacada, con un valor igual a 0.89, aunque la orientación tuvo una importancia menor (0.74).



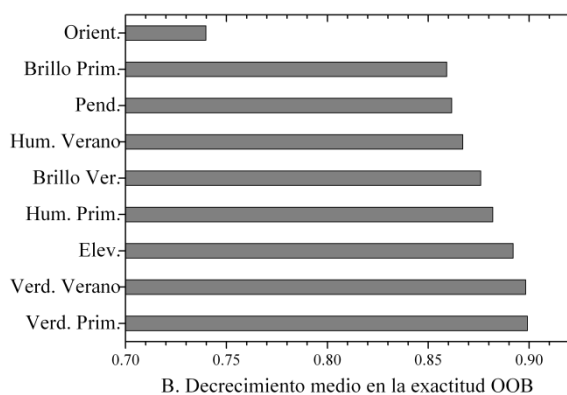
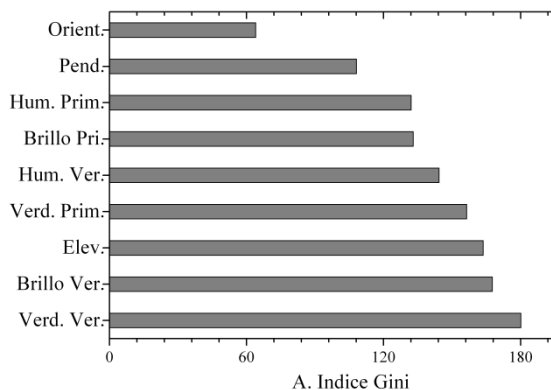


Figura 3.8. Importancia relativa de las variables en la clasificación del área de estudio en función del índice de Gini (A) y del decrecimiento en exactitud del subconjunto OOB (B).

La Tabla 3.1 muestra la contribución de las variables en la clasificación de cada cobertura. En términos generales, se puede observar el mismo patrón que en el caso de la clasificación general del área de estudio (Figura 3.8), las bandas derivadas de la transformación Kauth Thomas tuvieron una importancia relativa mayor. Cabe destacar el caso de las categorías con una distribución condicionada al relieve o la temperatura, para las que las variables relieve y verdor de primavera tuvieron una importancia mayor. Las categorías quercíneas, cultivos leñosos en regadío y cultivos

tropicales se localizan en áreas caracterizadas por una determinada elevación. Las quercíneas y los regadíos leñosos se distribuyen a lo largo de áreas montañosas, mientras que los cultivos tropicales se presentan a lo largo de la costa. Por otro lado, la pendiente tuvo una gran importancia en la clasificación de las áreas urbanas, chopos y de los cultivos herbáceos en secano, que aparecen en áreas llanas de escaso relieve. La variable verdor de primavera tuvo un interés especial para la clasificación de los cultivos herbáceos en secano y el pastizal, ya que son categorías que presentan su máximo vigor durante la estación húmeda (primavera), y por tanto no pueden ser caracterizadas adecuadamente en una imagen de verano. Además, el verdor de primavera ayudó a diferenciar entre áreas urbanas y suelos desnudos, ya que estos últimos permanecen cubiertos de vegetación durante la primavera (Yuan et al., 2005a).

Tabla 3.1. Importancia relativa de las variables en la clasificación de cada tipo de cobertura.

Id. Clase	Clase	Brillo Ver.	Verd. Ver.	Hum. Ver.	Brillo Prim.	Verd. Prim.	Hum. Pri.	Elev.	Pend.	Orient.
1	Urbano	2.81	3.11	2.80	2.83	3.09	3.00	2.49	2.52	1.06
2	Chopos	2.94	2.73	2.78	1.90	2.51	2.18	2.55	2.76	1.30
3	Coníferas	3.15	2.90	2.80	2.72	2.55	2.62	2.74	1.63	-0.03
4	Invernaderos	2.66	2.38	2.67	2.41	2.12	2.60	2.83	1.39	2.01
5	Matorral	2.76	2.95	2.81	2.36	2.79	2.63	2.37	2.72	0.70
6	Olivar	2.80	3.01	2.58	2.84	2.79	2.80	2.47	1.95	0.90
7	Pastizal	2.75	2.78	2.94	2.58	3.08	2.78	2.92	1.53	0.36
8	Quercíneas	2.51	2.91	2.39	1.47	2.37	1.94	3.00	2.45	1.57
9	C. Herb. Reg.	2.76	2.93	2.65	2.53	2.56	2.54	2.62	2.90	1.62
10	C. Leñ. Reg.	2.76	2.68	2.83	2.84	2.72	2.89	2.89	2.73	2.20
11	C. Herb. Sec.	2.92	2.19	2.72	2.50	3.06	2.70	2.50	2.35	0.15
12	S. desnudos	2.90	2.95	1.75	2.42	2.76	1.73	2.24	1.42	0.78
13	C. Tropicales	2.52	2.76	2.36	2.56	2.28	2.01	3.27	1.69	1.35
14	Agua	3.39	3.24	3.48	3.29	3.45	3.20	2.90	2.29	2.63

### **Medida de outliers**

Desde el punto de vista de RF un *outlier* es un caso para el que la proximidad con el resto de casos de la misma categoría es baja (sección 3.1.2). Esta medida se calcula como el número de casos dividido por la suma al cuadrado de las proximidades entre esa observación y todas las observaciones de esa misma clase; se normaliza sustrayendo la media y dividiendo por la desviación absoluta con respecto

a la mediana de cada clase. La medida *outlier* será grande (normalmente mayor de 10) si la proximidad es baja, y en ese caso se considera como un *outlier*.




Figura 3.9. Análisis outlier del total de las áreas de entrenamiento utilizadas en la clasificación con Random Forest.

Como se puede observar en la Figura 3.9, casi todas las áreas de entrenamiento son correctas, ya que la proximidad entre las áreas pertenecientes a la misma clase es alta. Sin embargo las áreas número 347 y 1015 se pueden considerar como valores *outlier*, las cuales pertenecen a las clases invernaderos y cultivos herbáceos de secano, respectivamente.

### 5.1.2 Redes neuronales

Como se vio en las secciones 3.2 y 4.2, la arquitectura de una red neuronal tiene una incidencia destacada en su habilidad para clasificar correctamente datos de teledetección. En esta sección se muestra el efecto que tienen los parámetros de diseño de las RNAs en la exactitud de la clasificación de datos de satélite. En general, las redes más grandes y complejas son más efectivas para caracterizar un conjunto de datos de entrenamiento, pero, por otro lado, también generalizan peor que las redes más pequeñas y simples. La Tabla 3.2 y Figura 3.10 muestran el valor del coeficiente Kappa del mejor modelo construido para las distintas configuraciones de la capa

oculta (4.2). Puede apreciarse que la exactitud cartográfica aumenta con la complejidad de la red; es decir, al hacerlo el número de unidades de la capa oculta. El valor máximo de Kappa se alcanzó para redes neuronales con un número de unidades en la capa oculta igual o superior a 5. A partir de este valor el error de la red converge y la adición de más unidades no tiene una incidencia significativa sobre la exactitud de las clasificaciones de la red.

Tabla 3.2. Exactitud cartográfica y parámetros de ajuste de los mejores modelos de RNA para diferentes números de unidades de la capa oculta.

Nº unidades	1	2	3	4	5	6	7	8	9	10
Rango	0.9	0.4	0.1	0.55	0.2	0.1	0.6	0.75	0.4	0.1
Decaimiento	0.03	0.01	0.01	0.035	0.01	0.015	0.02	0.01	0.045	0.035
Kappa	0.33	0.72	0.84	0.87	0.90	0.90	0.90	0.90	0.90	0.89
Nº unidades	11	12	13	14	15	16	17	18	19	20
Rango	0.65	0.45	0.1	0.35	0.5	0.1	0.4	0.55	0.1	0.9
Decaimiento	0.01	0.01	0.015	0.05	0.02	0.01	0.055	0.065	0.02	0.025
Kappa	0.90	0.90	0.91	0.89	0.89	0.88	0.89	0.89	0.89	0.89




Figura 3.10. Exactitud cartográfica (Kappa) de las RNAs en función del número de unidades de la capa oculta.

La Figura 3.11 muestra la incidencia de la configuración de los pesos en la exactitud de las RNAs. Las líneas continuas representan los coeficientes Kappa de RNAs de una capa oculta compuesta por 8 unidades cuyos decaimiento (a) y valores iniciales de los pesos (b) fueron fijados a su valor óptimo (ver Tabla 3.2). Las líneas de puntos representan, de forma análoga al caso anterior, la influencia de las

variaciones en los parámetros decaimiento de pesos (a) y rango de valores iniciales de los pesos (b) en los coeficientes Kappa de las clasificaciones. En estos casos las RNAs estaban compuestas de una capa oculta con 20 unidades, las cuales fueron entrenadas a partir de un conjunto de entrenamiento que contenía un 20% de ruido. El valor inicial de los pesos tuvo una incidencia importante en el índice Kappa, para valores negativos de pesos se produjo un mínimo en Kappa (0.08), mientras que para valores positivos superiores a 0.5 se alcanzó el máximo Kappa, tanto para los datos de entrenamiento, como para los datos modificados con la inclusión de un 20% de ruido (Figura 3.11 arriba). Estos resultados contrastan con las recomendaciones de Venables and Ripley (2002) que sugieren fijar el rango de valores de pesos entre -1 y 1. La Figura 3.11 (abajo; línea continua) muestra como las RNAs alcanzan un Kappa máximo para valores de decaimiento de pesos muy pequeños (0.01), a partir de este umbral la exactitud cartográfica tiende a disminuir hasta alcanzar un valor de decaimiento de pesos igual a 0.2, a partir del cual permaneció más o menos constante. En el caso de los datos de entrenamiento con ruido (línea de puntos), el valor del decaimiento de pesos juega un papel muy importante en la exactitud cartográfica de las redes neuronales, produciéndose oscilaciones del índice Kappa de  $\pm 0.23$ .




Figura 3.11. Exactitud cartográfica (Kappa) de las RNAs en función del rango (A) y del decaimiento de pesos (B).

### 5.1.3 Máquinas de vectores soporte

Los parámetros implicados en la optimización de cada función kernel fueron evaluados individualmente. A partir de esta evaluación inicial, fue posible construir los modelos óptimos para cada kernel, en los cuales fue basada la comparación.

Como fue argumentado en la sección 4. El grado del polinomio sólo es necesario para la optimización del kernel polinomial. Se evaluaron kernels polinomiales con grados de 1 a 10, para todas las posibles combinaciones de gamma y coste, lo que dio lugar a un total de 200000 modelos MVS diferentes. La Tabla 3.3 y Figura 3.12 muestran los valores de Kappa para la combinación de parámetros óptima resultante del entrenamiento y validación de cada uno de los modelos de kernel polinomial. Se puede apreciar como el índice Kappa disminuye a medida que el grado del polinomio aumenta (a excepción del polinomio de grado 3). El kernel lineal ( $\rho=1$ ) superó en todo los casos a los modelos no lineales ( $\rho \neq 1$ ), lo que sugiere que las variables espectrales MKT junto con las auxiliares derivadas del MDT son separables linealmente. Esto contrasta con los resultados de Yang y Huang et al. (2002; 2011), quienes utilizando las bandas brutas de una escena Landsat TM 5 y un número limitado de clasificadores MVS, obtuvieron mejores resultados para límites de separación entre clases no lineales, es decir, usando kernels polinomiales de grado mayor a 1. Los resultados de este estudio junto con los de los mencionados previamente, sugieren que el grado del polinomio puede tener un impacto diferente dependiendo de las categorías temáticas a clasificar.

Tabla 3.3. Exactitud cartográfica y parámetros de ajuste de los mejores modelos de MVS para los diferentes grados posibles de los kernels polinomiales.

Grado	1	2	3	4	5	6	7	8	9	10
MKT+MDT										
Coste	0.5	3.5	1.7	1.2	0.9	3.7	12.7	30.6	8.2	13.9
Gamma	0.9	0.15	0.25	0.3	0.35	0.25	0.25	0.15	0.3	0.3
Kappa	0.9	0.87	0.89	0.83	0.85	0.79	0.82	0.75	0.72	0.72
MKT										
Coste	16.8	52.2	3.9	0.5	1.4	0.4	2.3	---	---	---
Gamma	1	0.4	0.95	1	0.75	0.9	1	---	---	---
Kappa	0.83	0.80	0.83	0.78	0.80	0.75	0.76	---	---	---

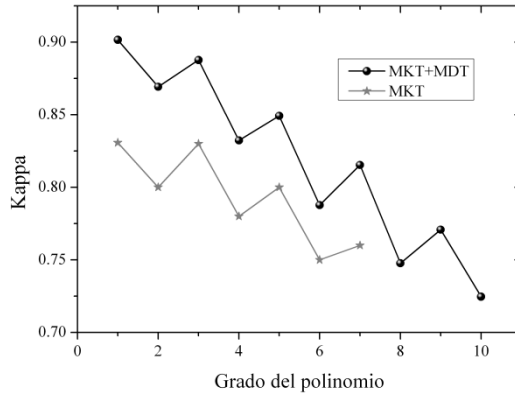


Figura 3.12. Exactitud cartográfica (Kappa) de los MVS polinomiales en función del grado del polinomio.

Por otro lado, de la Tabla 3.3 y Figura 3.13 también se deduce que al aumentar el grado del polinomio la función coste (C) también aumenta, lo cual se traduce en una pérdida de generalización y un mayor sobreajuste a los datos. Para comprobar la influencia de las variables derivadas del modelo digital del terreno se llevó cabo el mismo análisis efectuado en el párrafo anterior, incluyendo únicamente las variables espectrales, es decir las bandas verdor, brillo y humedad de las imágenes de verano y primavera. La Tabla 3.3 y Figura 3.12 muestran los valores de Kappa para la combinación de parámetros óptima resultante del entrenamiento y validación de cada uno de los modelos de kernel polinomial considerando únicamente las variables derivadas de las bandas espectrales del satélite (MKT). Se puede apreciar como en este caso el índice Kappa toma valores iguales para los grados del polinomio 1 y 3. De este resultado se puede deducir que las variables espectrales (MKT) son separables, tanto con modelos lineales como no lineales (grado3). Sin embargo, puede apreciarse a partir de las Tabla 3.3 como el coste del modelo MVS lineal óptimo entrenado únicamente a partir de los datos espectrales, es considerablemente mayor al del modelo lineal entrenado a partir de los datos espectrales más los derivados del MDT (16.8 y 0.5, respectivamente). Por tanto, el modelo entrenado a partir del subconjunto de datos MKT es menos generalizable. Para el resto de polinomios no

lineales el índice Kappa toma valores menores que los correspondientes al modelo lineal, produciéndose la misma tendencia que en el caso anterior (MKT+MDT).




Figura 3.13. Exactitud cartográfica (Kappa) de los MVS polinomiales en función del coste.

En el caso de los kernels polinomiales y sigmoideos, es posible incluir un término sesgo que ayude a maximizar el hiperplano de separación. En el caso de los modelos polinomiales se consideraron únicamente polinomios de grado 1, puesto que fueron los que mejor se ajustaron a los datos de entrada y, por otro lado, la consideración de los 10 grados de polinomio posibles implicarían construir 2 millones de modelos MVS polinomiales. De esta forma se construyeron 200.000 nuevos modelos polinomiales MVS y otros 200.000 modelos sigmoideos para todas las combinaciones posibles de sesgo, coste y gamma. La Tabla 3.4 muestra el impacto en la exactitud cartográfica sobre los modelos MVS polinomiales y sigmoideos. A partir de esta tabla se puede apreciar como el sesgo no afectó a la exactitud cartográfica de los modelos polinomiales, mientras que en el caso de los modelos sigmoideos la introducción de este parámetro produjo en todos los casos un decrecimiento en la exactitud cartográfica (Kappa). Estos resultados coinciden con los obtenidos por Yang (2011) para el caso del kernel sigmoideo, aunque en relación al kernel polinomial, en su caso si hubo una variación en el índice Kappa en función del sesgo y obtuvo un Kappa máximo para un valor de sesgo igual a 1.



Tabla 3.4. Exactitud cartográfica (Kappa) de los mejores modelos de MVS para los diferentes valores posibles de sesgo.

Sesgo	0	1	2	3	4	5	6	7	8	9	10
Polinomial	0.90	0.90	0.90	0.90	0.90	0.90	0.90	0.90	0.90	0.90	0.90
Sigmoideo	0.86	0.83	0.82	0.82	0.71	0.60	0.60	0.60	0.60	0.39	0.38

Una vez determinados los mejores valores para el grado de los modelos polinomiales y el sesgo de los modelos polinomiales y sigmoideo, la evaluación se centró en los parámetros gamma y coste, que son comunes a todos los tipos de kernels (a excepción de gamma para el kernel lineal). La Tabla 3.5 recoge la parametrización óptima de los modelos para cada uno de los tipos de kernels utilizados en este estudio. Con objeto de evaluar la dependencia del índice Kappa con respecto a los parámetros coste y gamma, se fijaron para cada uno de los tipos de kernel el valor óptimo del resto de parámetros, incluyendo en cada caso el parámetro coste o gamma (Figura 3.14<sup>a</sup> y B, respectivamente). La Figura 3.14A muestra como el parámetro coste tiene una incidencia importante en la exactitud del clasificador. Para valores de coste iguales a 0 no se permite ningún error en la clasificación, por lo que el clasificador, en función de los datos de entrada, podrá no generalizar bien. A medida que el coste aumente, y se permitan un mayor número de errores, la exactitud del clasificador aumentará hasta alcanzar el equilibrio entre el número de errores permitidos y el poder de generalización del clasificador (Cortes y Vapnik, 1995). Se puede observar, para los datos de este estudio, como se alcanzan los máximos valores de Kappa para costes inferiores a 10. Lo cual indica que los datos de entrenamiento y test usados en la calibración del modelo contienen un número muy bajo de *outliers* (ver capítulo de ruido). En general, para el conjunto de los datos usados en este estudio, los kernels lineal, radial y polinomial experimentan una tendencia decreciente del índice Kappa. Sin embargo, en el caso del kernel sigmoideo, para valores de coste altos se produce un descenso de la exactitud cartográfica bastante más acusado. Por otro lado, la Figura 3.14B muestra la relación entre el índice Kappa y el parámetro gamma. Los mejores valores de Kappa se alcanzan para valores de gamma muy pequeños de entre 0.05 y 0.1 (ver Tabla 3.5), a partir de los cuales se aprecia una tendencia decreciente más importante que el caso del parámetro coste, que es especialmente notable para los

kernels sigmoideo y polinomial. Este parámetro, gamma, tradicionalmente es fijado al valor de la inversa del número de variables de entrada al clasificador (Yang, 2011). Sin embargo, a la vista de nuestros resultados, creemos que es más adecuado el ajuste de ambos parámetros: coste y gamma.

Tabla 3.5. Mejores modelos MVS en función del tipo de kernel.

	Lineal	Polinomial	Radial	Sigmoideo
Coste	0.9	8.7	3.1	2.3
Gamma	--	0.05	0.1	0.05
Sesgo	--	1	--	0
Grado	--	1	--	--
Kappa	0.9	0.9	0.91	0.86

A la vista de los resultados de este estudio, se puede concluir que la elección del kernel es importante, ya que afecta significativamente a la exactitud cartográfica de los modelos MVS. La Tabla 3.5 muestra como el kernel radial fue el que obtuvo el mejor índice Kappa, seguido por los kernels polinomial y lineal. El kernel sigmoideo se comportó peor que el resto y sólo consiguió un Kappa de 0.86. Por otro lado, los valores óptimos de los parámetros de ajuste varían en función del tipo de kernel utilizado. El kernel polinomial necesita de un mayor número de parámetros de ajuste (grado, coste, gamma y sesgo), seguido del sigmoideo, lo cual se traduce en un mayor tiempo de cómputo y una mayor dificultad en su parametrización. Los kernels lineal y radial, al necesitar sólo del ajuste del coste y coste y gamma (respectivamente) son los más simples. Si bien es cierto que, dependiendo de la calidad de los datos utilizados para entrenar los modelos, es posible que las muestras de entrenamiento no sean separables linealmente. Por tanto, el kernel radial es el que mayor potencialidad ofrece, a tenor del índice Kappa y de la simplicidad de su parametrización.

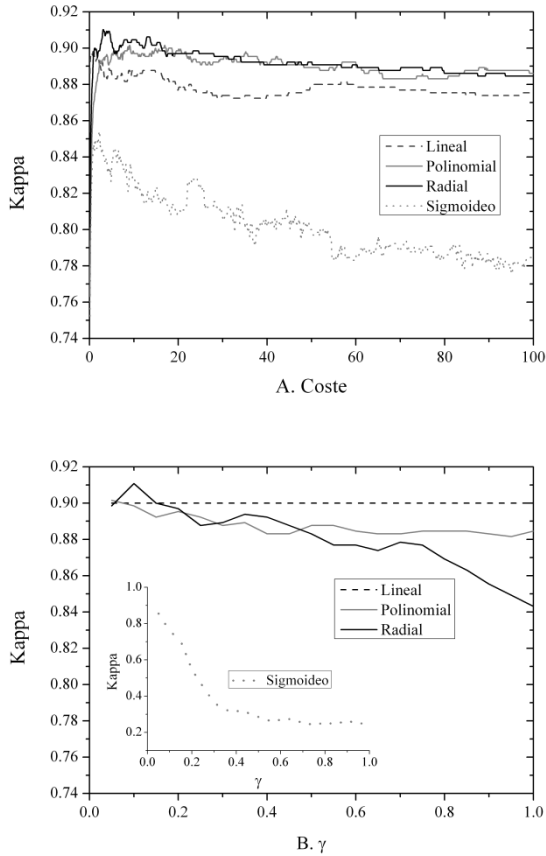


Figura 3.14. Exactitud cartográfica en función del tipo de kernel y el coste (A) y del tipo de kernel y  $\gamma$  (B).

## 5.2 Evaluación de la exactitud cartográfica

Como se ha descrito anteriormente en el Capítulo 2, con objeto de llevar a cabo la evaluación de la exactitud cartográfica, se formó un conjunto independiente del entrenamiento de los modelos, integrado por 700 polígonos, cada uno compuesto de 9 píxeles. La evaluación de la exactitud se efectuó en base a las matrices de confusión, a partir de las cuales se calcularon la exactitud global, exactitudes del usuario y el

productor, y el índice Kappa general y por categorías (Congalton, 1991; Congalton y Green, 2009).

Los resultados obtenidos de la evaluación de la exactitud cartográfica pueden considerarse, en general, como muy positivos, teniendo en cuenta la complejidad del área de estudio y el elevado número de categorías. La exactitud global y el índice Kappa de todas las metodologías de clasificación, a excepción de AD, fueron superiores a 0.9. La clasificación generada por RF fue la más exacta con coeficientes de exactitud global y Kappa iguales a 0.92 (Tabla 3.7), seguida de las clasificaciones efectuadas con MVS (Radial) y RNA con valores de exactitud global iguales a 0.92 y 0.91 e índices Kappa de 0.91 y 0.90, respectivamente (Tabla 3.9 y Tabla 3.8). La clasificación realizada por el árbol de decisión (AD) tuvo una exactitud cartográfica significativamente menor que la del resto de metodologías (ver sección 5.3) con coeficientes de exactitud global y Kappa iguales a 0.86 y 0.85, respectivamente.

La Tabla 3.10 muestra los valores de la exactitud del productor, usuario, y del índice Kappa de las cubiertas del área de estudio. El promedio de la exactitud del productor y usuario y el índice Kappa por categorías de las clasificaciones realizadas por AD, RF, RNA y MVS fueron iguales a 0.86, 0.92, 0.91 y 0.92; 0.87, 0.93, 0.91, y 0.92; y 0.85, 0.92, 0.90 y 0.91, respectivamente. Las desviaciones estándar de estos parámetros fueron iguales a 0.10, 0.08, 0.09 y 0.08; 0.12, 0.07, 0.07 y 0.07; y 0.11, 0.08, 0.09 y 0.09, respectivamente.

Puede observarse un patrón común en la clasificación por los diferentes algoritmos, independientemente de la exactitud relativa de cada metodología en la clasificación de cada cubierta, consecuencia de la separabilidad espectral de las categorías. Las cubiertas mejor clasificadas por las diferentes metodologías comparadas fueron los chopos, invernaderos y agua. En concreto, las clasificaciones efectuadas por RF y MVS dieron lugar a valores de exactitud del productor y el usuario y a coeficientes Kappa iguales a 1, lo cual indica que todas las áreas correspondientes a estas categorías fueron clasificadas correctamente. Los regadíos herbáceos clasificados por RF también presentaron valores de exactitud del productor

y Kappa iguales a 1, pero en este caso la exactitud del usuario fue igual a 0.98, lo cual indica que pese a que el 100% de las áreas test fueron clasificadas correctamente el 2% de las áreas clasificadas como regadíos herbáceos pertenecen a otras categorías. Las cubiertas más difíciles de clasificar fueron las de mayor variabilidad intraclase y las que presentan un comportamiento espectral similar, como matorral, pastizal, suelos, quercíneas y urbano. Así, la clase urbano fue clasificada en algunas ocasiones como suelos y viceversa, ya que ambas cubiertas presentan valores altos de reflectividad (Yuan et al., 2005a). Por otro lado, la alta reflectividad de los suelos del área de estudio puede enmascarar la respuesta espectral de parches de vegetación de escasa cobertura como es el caso del olivar y dificultar su clasificación. Las cubiertas matorral, quercíneas y coníferas debido a su alto parecido espectral también fueron clasificadas menos exactamente. De igual forma, las cubiertas con un alto parecido en su comportamiento espectral y estacional, los cultivos herbáceos en seco y el pastizal (vegetación herbácea con un elevado vigor en primavera), también fueron confundidos entre sí.

En cuanto a las diferencias en la exactitud de la clasificación de las cubiertas en relación a la metodología de clasificación utilizada, en términos generales, RF y MVS fueron los que mejor clasificaron las cubiertas del área de estudio. Las cubiertas coníferas, olivar, suelos y cultivos tropicales fueron clasificadas de forma más exacta por RF. MSV mejoró la clasificación del resto de metodologías para la cubierta urbano. Sin embargo, las RNA clasificaron de forma más exacta las quercíneas.

Tabla 3.6. Matriz de confusión de la mejor clasificación obtenida por AD.

	Datos de Referencia														TOT.
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
1	37	0	0	1	0	0	0	0	0	0	0	4	0	0	42
2	0	49	0	0	0	0	0	0	0	0	0	0	0	1	50
3	0	0	36	0	4	0	0	5	0	0	0	0	0	0	45
4	0	0	0	48	0	0	0	0	0	0	0	0	0	0	48
5	1	0	3	0	43	1	3	9	0	0	1	4	0	0	65
6	0	0	0	0	0	42	0	0	0	0	0	3	0	0	45
7	0	0	0	0	0	0	40	0	0	0	1	1	0	0	42
8	0	0	11	0	1	1	0	36	3	2	0	0	0	0	54
9	1	0	0	0	0	0	0	0	46	0	0	0	1	0	48
10	0	1	0	0	0	1	0	0	0	43	0	1	2	0	48
11	0	0	0	0	0	3	6	0	0	0	47	0	0	0	56
12	11	0	0	1	2	2	1	0	1	0	1	37	0	0	56
13	0	0	0	0	0	0	0	0	0	5	0	0	47	0	52
14	0	0	0	0	0	0	0	0	0	0	0	0	0	49	49
TOT.	50	50	50	50	50	50	50	50	50	50	50	50	50	50	700
E. G.	Kappa														
0.86	0.85														

Tabla 3.7. Matriz de confusión de la mejor clasificación obtenida por RF.

	Datos de Referencia														TOT.
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
1	44	0	0	0	0	0	0	0	0	0	0	5	0	0	49
2	0	50	0	0	0	0	0	0	0	0	0	0	0	0	50
3	0	0	46	0	3	0	0	3	0	0	0	0	0	0	52
4	0	0	0	50	0	0	0	0	0	0	0	0	0	0	50
5	0	0	1	0	40	0	2	4	0	0	0	1	0	0	48
6	1	0	0	0	1	49	0	0	0	0	0	3	0	0	54
7	0	0	0	0	0	0	42	0	0	0	0	0	0	0	42
8	0	0	3	0	4	0	0	43	0	1	0	0	0	0	51
9	0	0	0	0	0	0	0	0	50	1	0	0	0	0	51
10	0	0	0	0	0	0	0	0	0	43	0	0	1	0	44
11	0	0	0	0	0	0	6	0	0	0	50	0	0	0	56
12	5	0	0	0	2	1	0	0	0	0	0	41	0	0	49
13	0	0	0	0	0	0	0	0	0	5	0	0	49	0	54
14	0	0	0	0	0	0	0	0	0	0	0	0	0	50	50
TOT.	50	50	50	50	50	50	50	50	50	50	50	50	50	50	700
E. G.	Kappa														
0.92	0.92														

Tabla 3.8. Matriz de confusión de la mejor clasificación obtenida por RNA.

		Datos de Referencia														
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	TOT.
1	43	0	0	1	0	0	0	0	0	0	0	0	7	0	0	51
2	0	49	0	0	0	0	0	0	0	0	0	0	0	0	0	49
3	0	0	44	0	2	0	0	2	0	0	0	0	0	0	0	48
4	0	0	0	48	0	0	0	0	0	0	0	0	0	0	0	48
5	0	0	0	0	44	0	2	2	0	0	0	0	3	0	0	51
6	1	0	0	0	1	47	0	0	0	0	0	6	0	0	55	
7	0	0	0	0	1	0	43	0	0	0	1	1	0	0	46	
8	0	0	6	0	2	0	0	46	0	1	0	0	0	0	55	
9	0	0	0	0	0	0	0	0	50	1	0	0	4	0	55	
10	0	1	0	0	0	0	0	0	0	45	0	0	1	0	47	
11	0	0	0	0	0	0	5	0	0	0	49	0	0	0	54	
12	6	0	0	1	0	3	0	0	0	0	0	33	0	0	43	
13	0	0	0	0	0	0	0	0	0	3	0	0	45	0	48	
14	0	0	0	0	0	0	0	0	0	0	0	0	0	50	50	
TOT.	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	700
E. G.	Kappa															
0.91	0.90															

Tabla 3.9. Matriz de confusión de la mejor clasificación obtenida por MVS.

		Datos de Referencia														
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	TOT.
1	47	0	0	0	0	1	0	0	0	0	0	8	0	0	56	
2	0	50	0	0	0	0	0	0	0	0	0	0	0	0	50	
3	0	0	45	0	2	0	0	3	0	0	0	0	0	0	50	
4	0	0	0	50	0	0	0	0	0	0	0	0	0	0	50	
5	0	0	1	0	44	1	1	2	0	0	0	5	0	0	54	
6	1	0	0	0	0	46	1	0	0	0	0	3	0	0	51	
7	0	0	0	0	0	0	43	0	0	0	0	0	0	0	43	
8	0	0	4	0	2	0	0	44	0	1	0	0	0	0	51	
9	0	0	0	0	0	0	0	0	46	1	0	0	1	0	48	
10	0	0	0	0	0	0	0	0	0	45	0	0	1	0	46	
11	0	0	0	0	0	0	5	0	0	0	50	0	0	0	55	
12	2	0	0	0	2	2	0	1	0	0	0	34	0	0	41	
13	0	0	0	0	0	0	0	0	4	3	0	0	48	0	55	
14	0	0	0	0	0	0	0	0	0	0	0	0	0	50	50	
TOT.	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	700
E. G.	Kappa															
0.92	0.91															

Tabla 3.10. Resumen de la exactitud cartográfica por categorías obtenida por las diferentes metodologías de clasificación. E.P.: exactitud productor, E.U.: exactitud usuario y K.: Kappa

Id. Clase	AD			RF			RNA			SVM		
	E.P.	E. U.	K.	E.P.	E. U.	K.	E.P.	E. U.	K.	E.P.	E. U.	K.
1	0.74	0.88	0.72	0.88	0.90	0.87	0.86	0.84	0.85	0.94	0.84	0.93
2	0.98	0.98	0.98	1.00	1.00	1.00	0.98	1.00	0.98	1.00	1.00	1.00
3	0.72	0.80	0.70	0.92	0.88	0.91	0.88	0.92	0.87	0.90	0.90	0.89
4	0.96	1.00	0.96	1.00	1.00	1.00	0.96	1.00	0.96	1.00	1.00	1.00
5	0.86	0.66	0.85	0.80	0.83	0.79	0.88	0.86	0.87	0.88	0.81	0.87
6	0.84	0.93	0.83	0.98	0.91	0.98	0.94	0.85	0.93	0.92	0.90	0.91
7	0.80	0.95	0.79	0.84	1.00	0.83	0.86	0.93	0.85	0.86	1.00	0.85
8	0.72	0.67	0.70	0.86	0.84	0.85	0.92	0.84	0.91	0.88	0.86	0.87
9	0.92	0.96	0.91	1.00	0.98	1.00	1	0.91	1.00	0.92	0.96	0.91
10	0.86	0.90	0.85	0.86	0.98	0.85	0.9	0.96	0.89	0.90	0.98	0.89
11	0.94	0.84	0.93	1.00	0.89	1.00	0.98	0.91	0.98	1.00	0.91	1.00
12	0.74	0.66	0.72	0.82	0.84	0.81	0.66	0.77	0.64	0.68	0.83	0.66
13	0.94	0.90	0.94	0.98	0.91	0.98	0.9	0.94	0.89	0.96	0.87	0.96
14	0.98	1.00	0.98	1.00	1.00	1.00	1	1.00	1.00	1.00	1.00	1.00

### 5.2.1 Comparación de Random Forest con Árboles de Decisión

Con objeto de evaluar la mejora que supone el uso de un meta-clasificador en relación con un clasificador simple, en este caso RF y un AD se compararon los resultados obtenidos en la clasificación del área de estudio por cada uno de estos clasificadores.

Los resultados expresados en la Tabla 3.6 y Tabla 3.7 (matrices de confusión) muestran que el clasificador RF fue más exacto que AD con valores de Kappa iguales al 0.92 y 0.86, respectivamente. La Tabla 3.11 muestra los valores del índice Kappa por categorías así como los incrementos en Kappa que supone la sustitución del clasificador AD por RF. Las categorías ligadas a las cubiertas coníferas, quercíneas, urbano, olivar y suelos desnudos presentaron incrementos de Kappa por encima del 10%, con valores iguales al 30%, 22%, 20%, 18% y 12%, respectivamente. La Figura



3.15 y Figura 3.16 muestran las pérdidas y ganancias entre categorías como consecuencia de la sustitución del clasificador AD a favor de RF. Los mapas clasificados de la Figura 3.15 representan las transiciones derivadas de la aplicación de los algoritmos mencionados. La Figura 3.16 muestra el porcentaje de cambios entre ambas clasificaciones tomando como referencia la clasificación hecha con AD. Se puede apreciar a partir de las figuras como RF supuso una ganancia promedio del 35% para las coberturas. El árbol de clasificación, sobre-estimó en forma significativa la clasificación de los cultivos leñosos de regadío y las áreas urbanas (182% y 151%, respectivamente). Por una parte, RF permitió una mejor diferenciación entre los diferentes tipos de vegetación leñosa que habían sido erróneamente clasificados por AD: regadíos leñosos, matorral, cultivos tropicales y quercíneas. Por la otra, AD no pudo diferenciar entre categorías con una alta reflectividad como son los suelos desnudos y las áreas urbanas.

Tabla 3.11. Valores e incrementos del índice Kappa por categorías para los clasificadores AD y RF

Id. Clase	AD	RF	Inc. en Kappa de RF respecto a AD
1	0.72	0.87	20.40
2	0.98	1.00	2.20
3	0.70	0.91	30.37
4	0.96	1.00	4.49
5	0.85	0.79	-7.14
6	0.83	0.98	18.01
7	0.79	0.83	5.41
8	0.70	0.85	21.88
9	0.91	1.00	9.40
10	0.85	0.85	0.11
11	0.93	1.00	6.98
12	0.72	0.81	12.41
13	0.94	0.98	4.61
14	0.98	1.00	2.20

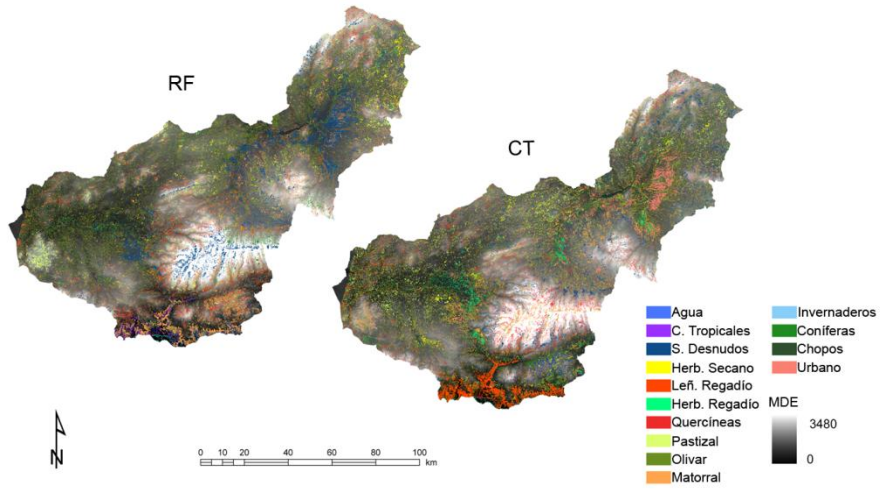


Figura 3.15. Mapas de cambio entre las clasificaciones producidas a partir de los clasificadores RF y AD




Figura 3.16. Comparación de las clasificaciones efectuadas por AD y RF, en términos de porcentaje de píxeles que cambiaron al usar RF

### **5.3 Análisis de la significatividad de las diferencias en exactitud entre algoritmos**

Los estudios comparativos entre nuevas metodologías de clasificación tienden a estar sesgados, ya que normalmente el investigador suele estar más familiarizado con algunos de los algoritmos que propone para la comparación. Por otro lado, los trabajos que presentan un nuevo método de clasificación que mejora ampliamente otros métodos convencionales son más susceptibles de ser publicados que aquellos en los que los resultados se igualan o las diferencias no son muy significativas (Mas y Flores, 2008). Wilkinson (2005) llevó a cabo una comparación entre 500 clasificadores que habían aparecido durante los 15 años anteriores y concluyó que durante ese período de tiempo no se había experimentado una mejora real en la exactitud de las clasificaciones. Con posterioridad al estudio anteriormente citado se han comenzado a utilizar en teledetección metodologías de clasificación más novedosas como RF y MVS (Breiman, 2001; Mountrakis et al., 2011). Por tanto, es necesario realizar una evaluación en profundidad de la mejora que suponen estas nuevas metodologías respecto a sus predecesoras (AD y RNA entre otras).

La evaluación de la exactitud de los mapas temáticos, generados a partir de la clasificación de datos de teledetección por diferentes algoritmos, normalmente se realiza en base al cálculo y comparación de los coeficientes Kappa, y la proporción de casos correctamente clasificados (exactitud global) derivados de cada mapa. Esta aproximación asume que las muestras utilizadas para el cálculo del índice Kappa (test) son independientes, lo cual en muchos casos no se cumple, puesto que se usa el mismo conjunto test en la evaluación de la exactitud de cada mapa. En los casos en los que los test no son independientes la significatividad estadística de las diferencias en exactitud de dos mapas clasificados puede ser evaluada mediante el test de McNemar (Foody, 2004; Foody, 2009). Este test considera que las diferencias en exactitud son estadísticamente significativas para un nivel de confianza del 5%, es decir para valores de Z mayores de 1.96.

De forma complementaria a la comparación de la exactitud cartográfica realizada en la sección 5.2, se ha evaluado la significatividad de las diferencias en

exactitud de los resultados obtenidos por las diferentes metodologías de clasificación a través de la aplicación del test de McNemar. La Tabla 3.12 muestra los valores de Z calculados entre los resultados de la aplicación de las diferentes metodologías de clasificación, una vez se seleccionaron los parámetros óptimos relativos a cada clasificador (sección 5.1). Como puede observarse a partir de esta tabla, todos los clasificadores fueron significativamente más exactos que AD y MVS sigmoideo, que pueden considerarse equivalentes. En términos generales, los resultados de la exactitud cartográfica derivada de RF, RNA y MVS polinomial y MVS radial pueden considerarse al mismo nivel. En cuanto a los que a las MVS se refiere, las diferencias en la exactitud cartográfica entre los kernels lineal, polinomial y radial no fueron estadísticamente significativas. Sin embargo, si fueron significativas las diferencias en exactitud entre RF y MVS con tipo de kernel lineal.

Tabla 3.12. Resultados de la evaluación de la significatividad estadística (Z) de las diferencias en los coeficientes Kappa de los mapas temáticos clasificados por los diferentes algoritmos de auto-aprendizaje.

	AD	RF	RNA	MVS Lin.	MVS Pol.	MVS Rad.
RF	4.96	--	--	--	--	--
RNA	3.63	1.48	--	--	--	--
MVS Lin.	3.62	1.73	0.14	--	--	--
MVS Pol.	3.75	1.6	0	0.26	--	--
MVS Rad.	4.4	0.93	0.7	1.3	1.13	--
MVS Sig.	0.48	4.61	3.64	4.23	4.63	4.65

## 5.4 Sensibilidad al ruido de los clasificadores

La información necesaria para entrenar los algoritmos de clasificación se obtiene a través de trabajos de campo, o mediante la interpretación de fotografías aéreas. En cualquiera de estos dos casos, incluso asumiendo que esta información es correcta, se pueden producir errores en el etiquetado de los tipos de cubiertas, sobre todo en aquellas circunstancias en que las categorías son muy heterogéneas y el paisaje es complejo (Lippitt et al., 2008; Rogan et al., 2008). El etiquetado erróneo de algunas áreas de entrenamiento, produce un aumento de la variabilidad intracalse y, por tanto, tiene un efecto directo en la exactitud de los mapas clasificados. Los algoritmos de

aprendizaje de máquinas pueden aprender en mayor o menor medida estos “patrones ruidosos”, lo cual da lugar a una disminución de su habilidad para clasificar correctamente. Son numerosos los estudios que dan cuenta del efecto negativo que tiene el ruido en la clasificación de datos de satélite por algoritmos de autoaprendizaje (DeFries y Chan, 2000; Miller y Franklin, 2002; Simard et al., 2000), aunque en ninguno de ellos evalúan la significatividad estadística de los resultados.

La robustez frente al ruido de los clasificadores fue evaluada mediante la inclusión de áreas erróneamente etiquetadas (ruido). La Figura 3.17 muestra el estadístico Kappa resultante de las clasificaciones efectuadas a partir de los subconjuntos de entrenamiento con diferentes proporciones de ruido. Todos los clasificadores se vieron afectados negativamente con la adición de ejemplos mal etiquetados. La Tabla 3.13 muestra la evaluación de la significatividad de las diferencias entre los estadísticos Kappa de las clasificaciones efectuadas a partir de los datos originales y las de los datos que incluyen ruido (véase sección 5.3). A partir de esta figura se puede apreciar que RF y MVS son los clasificadores más robustos frente al ruido. Si no se superan porcentajes de ruido superiores al 25 o 30% no se produce un decrecimiento de la exactitud cartográfica significativo. Sin embargo, en el caso de AD o RNA, la adición de sólo un 5% de casos etiquetados erróneamente produjo una disminución significativa en la exactitud cartográfica, lo cual indica que ambos algoritmos tienden a sobre-ajustarse a los datos. Por otro lado, cabe destacar que para umbrales de ruido inferiores al 40%, RF y MVS resultaron ser más exactos que el clasificador AD aplicado a los datos originales. La mayor estabilidad de RF y MVS se debe a causas diferentes. Por un lado, RF sólo usa dos tercios de los ejemplos de entrenamiento en la clasificación hecha por cada árbol de decisión, por lo que al aumentar la diversidad de patrones de los que aprenden los árboles que constituyen el clasificador la probabilidad de aprender el ruido es menor (Breiman, 2001). Por otro lado, los MVS utilizan márgenes blandos en la búsqueda de un hiperplano que puede contener un cierto número de errores, de forma que incluyen una constante (coste) que controla la solución de compromiso entre la complejidad del modelo y el número de

ejemplos mal clasificados (Cortes y Vapnik, 1995). De esta forma, optimizando esta constante el aprendizaje del ruido por parte de lo MVS puede atenuarse.




Figura 3.17. Efecto en la exactitud cartográfica de la adición de ruido en los datos de entrenamiento

Tabla 3.13. Valores de Z obtenidos para los datos clasificados a partir de datos de entrenamiento con diferentes proporciones de ruido respecto a los resultados originales.

% Ruido	5	10	15	20	25	30	35	40	45
AD	2.36	2.29	2.32	3.20	4.90	4.24	5.61	6.49	6.73
RF	0.33	0.28	1.15	1.98	2.69	2.78	3.54	3.68	4.30
RNA	1.84	2.01	3.50	4.39	5.18	5.84	7.13	7.54	9.17
MVS (RBF)	0.00	1.22	1.35	1.10	2.20	3.04	4.13	3.83	4.18
% Ruido	50	55	60	65	70	75	80	85	90
AD	6.86	8.99	7.49	9.35	10.52	11.99	18.45	20.09	22.07
RF	5.67	8.64	9.10	11.46	13.38	16.04	18.39	21.83	23.37
RNA	8.59	10.94	12.42	13.03	14.63	17.36	18.63	19.65	22.41
MVS (RBF)	5.17	6.20	7.46	14.63	9.34	10.61	12.92	18.29	22.90

## **5.5 Efecto de la reducción de áreas de entrenamiento en los clasificadores**

La adquisición de datos de referencia que puedan ser usados en el entrenamiento y validación del proceso de clasificación es una tarea costosa en lo que se refiere a tiempo y coste económico. Por una parte, es necesario que las áreas de entrenamiento sean lo suficientemente numerosas y diversas como para representar toda la variabilidad presente en cada cubierta o categoría (Foody y Arora, 1997; Pal y Mather, 2003). Por otra parte, es fundamental el diseño de un muestreo que permita alcanzar un nivel aceptable de exactitud cartográfica, que a su vez sea operativo en términos económicos y temporales.

El número de datos de entrenamiento no es un problema para la clasificación de categorías homogéneas. Sin embargo, el volumen de datos necesario para clasificar cubiertas con una alta variabilidad es elevado. El efecto del tamaño del conjunto de datos de entrenamiento en la exactitud de las clasificaciones realizadas por los diferentes algoritmos de autoaprendizaje se evaluó mediante el índice Kappa.

La Figura 3.18 y Tabla 3.14 muestran, de forma análoga a la sección anterior, los resultados del índice Kappa y del test de McNemar obtenidos de las clasificaciones de los diferentes subconjuntos de datos de tamaño reducido. Como puede apreciarse a partir de la Figura 3.18 La exactitud de las clasificaciones decrece cuando lo hace el tamaño de los datos de entrenamiento, aunque este efecto es más leve que el que produce la adición de ruido (Figura 3.17). En términos absolutos, MVS, RF y RNA presentan un patrón similar, el índice Kappa permanece estable hasta alcanzar un umbral de reducción en torno al 50% de los datos, aunque el clasificador RNA a partir de dicho umbral decrece a un ritmo mayor. Sin embargo, AD es mucho más sensible al tamaño de los datos y su exactitud decrece para valores de reducción del 15%. La Tabla 3.14 muestra la significatividad de las diferencias relativas en el índice Kappa. Estas diferencias entre clasificaciones fueron significativas a partir de diferentes umbrales, dependiendo del clasificador utilizado. Estos umbrales para los clasificadores MVS, RF, RNA y AD fueron iguales al 80, 50, 40 y 25%, respectivamente. Cabe destacar que en el caso de la reducción de los datos

se aprecian mayores diferencias en el comportamiento de los clasificadores MVS y RF que en lo que al ruido se refiere, lo cual es lógico teniendo en cuenta que RF ya lleva implícita una reducción de los datos del 33% (*bagging*). No obstante, la proporción entre los datos de entrenamiento y OOB puede adaptarse para condiciones en las que los datos son escasos.




Figura 3.18. Efecto en la exactitud cartográfica de la reducción de los datos de entrenamiento

Tabla 3.14. Valores de Z obtenidos para los datos clasificados a partir de conjuntos de entrenamiento de tamaño reducido respecto a los resultados originales.

% Reducción	5	10	15	20	25	30	35	40	45
AD	0.22	0.56	1.95	1.17	2.10	2.71	1.86	1.48	1.69
RF	0.00	1.39	0.00	0.45	0.77	0.58	0.69	1.46	1.62
RNA	0.28	0.46	1.24	0.62	1.18	1.02	1.73	2.03	2.03
MVS (RBF)	0.26	0.00	0.22	0.76	0.77	0.89	0.60	0.78	0.38
% Reducción	50	55	60	65	70	75	80	85	90
AD	1.35	3.11	3.21	3.94	4.31	5.96	6.98	7.54	7.03
RF	2.40	3.09	1.86	2.87	3.16	4.44	4.64	5.66	6.48
RNA	2.32	2.42	3.97	4.13	3.49	5.80	7.69	8.40	9.51
MVS (RBF)	0.35	1.62	0.85	0.93	1.57	1.90	2.99	4.45	5.97



## 6 Conclusiones

En este capítulo se han evaluado de forma detallada diferentes algoritmos de aprendizaje de máquinas, basados en bases conceptuales diversas: máquinas de vectores soporte, clasificadores basados en árboles de decisión (AD y RF) y redes neuronales artificiales. El análisis comparativo de algoritmos realizado se ha llevado a cabo desde diferentes perspectivas: las necesidades de parametrización de cada técnica, la exactitud cartográfica de las clasificaciones y, por último, la sensibilidad al ruido y a la reducción de los datos de entrenamiento.

Los algoritmos de clasificación evaluados llevan asociada una dificultad en su entrenamiento diferente. Los algoritmos basados en árboles de clasificación entrañan una menor dificultad en su entrenamiento, tanto los árboles de decisión simples como los meta-clasificadores basados en árboles. AD únicamente necesita del establecimiento de la medida de heterogeneidad, el número mínimo de observaciones en cada nodo, y la profundidad de los árboles. RF, por definición, utiliza una medida de heterogeneidad fija (el índice de Gini), y los árboles que lo componen crecen hasta su máxima profundidad sin poda, por lo que sólo necesita del establecimiento de dos parámetros, el número de árboles que componen el *ensemble* y el número de variables aleatorias consideradas en la división de cada nodo. Los árboles de decisión, una vez alcanzado un cierto umbral, son más estables que el resto de los algoritmos frente a variaciones en sus parámetros (AD y RF). Así, la exactitud de las clasificaciones de RF permanece estable a partir de un determinado número de árboles para cualquier número de variables aleatorias. Sin embargo, las redes neuronales y las máquinas de vectores soporte son más complejas y sensibles a pequeñas variaciones en su parametrización, lo cual se traduce en un mayor coste computacional. Las redes neuronales necesitan de un diseño óptimo de la arquitectura de red (número de capas y unidades ocultas) y del establecimiento de los valores óptimos del coste y decaimiento de pesos. Por último, las máquinas de vectores soporte se basan en diferentes tipos de *kernels*, en función de los cuales la combinación de parámetros a optimizar es diferente; desde el grado del polinomio, y los parámetros coste y gamma del *kernel* polinomial, a un único parámetro de coste para el caso del *kernel* lineal.

Random Forest, además de la simplicidad de su parametrización, a diferencia del resto de clasificadores presenta otras ventajas añadidas derivadas de su diseño: incluye una medida interna muy robusta de error de clasificación (error OOB), genera una medida que permite detectar la presencia de *outliers* en los datos y mide la importancia relativa de cada variable predictiva en el modelo de clasificación general y en la clasificación de cada categoría.

La mayor exactitud de las clasificaciones fue alcanzada por RF y MVS radial, con valores de Kappa iguales a 0.92 en ambos casos. Las redes neuronales también consiguieron un alto nivel de exactitud cartográfica (Kappa igual a 0.91), aunque únicamente para una combinación muy concreta de sus parámetros de ajuste. Por último, el índice Kappa máximo derivado de las clasificaciones de los árboles de decisión fue considerablemente menor que el del resto de clasificadores (0.83). En cuanto a los resultados de las clasificaciones por categorías, este estudio demuestra que la elección del clasificador da lugar a diferencias en la exactitud de las clasificaciones en función del tipo de cubierta. Así, RF y MVS fueron los que mejor clasificaron las cubiertas del área de estudio. Las cubiertas coníferas, olivar, suelos y cultivos tropicales fueron clasificadas de forma más exacta por RF. MSV mejoró la clasificación del resto de metodologías para las cubiertas urbanas. Por último, las RNA clasificaron de forma más exacta las quercíneas.

Los clasificadores evaluados respondieron de forma diferente a la adición de ruido y reducción del número de áreas de entrenamiento. Los clasificadores MSV y RF fueron los más robustos frente al ruido y presentaron diferencias significativas en el índice Kappa para valores de ruido superiores al 20-25%. Por otro lado, las RNA y AD experimentaron decrecimientos significativos para valores iguales al 5-10%. En cuanto a la reducción de los datos de entrenamiento las MVS fueron los clasificadores más robustos obteniendo valores significativos de diferencia únicamente para umbrales de reducción superiores al 80%, seguidos de RF (50%), RNA (40%) y AD (25%).

## CAPÍTULO 4.

# Métodos de Fusión de Imágenes de Satélite

### 1 Introducción

En las últimas décadas, la aparición de nuevos sensores ha incrementado la disponibilidad de imágenes con características de resolución espacial y espectral muy variadas. Un uso eficiente de dicha información puede requerir la integración o fusión de distintas imágenes, para conseguir la resolución espacial y espectral requerida para una determinada aplicación. Un ejemplo clásico es la fusión de imágenes multispectrales y pancromáticas. Estas metodologías comprenden un conjunto de procedimientos de bases conceptuales diversas, que van desde técnicas basadas en operaciones aritméticas simples, hasta algoritmos complejos basados en la aplicación de convoluciones y filtros.

Entre las técnicas más sencillas de fusión, se encuentran la mera sustitución directa de las bandas para la visualización, o transformaciones aritméticas como el método de Brovey (Ehlers, 1991) o el método FastIHS (Tu et al., 2005). Algo más complejos son los algoritmos de fusión basados en transformaciones de las imágenes y sustitución. El procedimiento general de este tipo de algoritmos es transformar la imagen original multispectral a un nuevo sistema de coordenadas, en el cual uno de

los ejes representa la intensidad (Chica-Olmo y Abarca-Hernandez, 1998; Pellemans y Jordans, 1993). La imagen generada en dicha transformación es equivalente a la imagen pancromática: componente Intensidad, primera componente de PCA; de tal forma que al ser sustituida por la componente de alta resolución espacial y realizar la operación de transformación inversa se consigue una imagen multiespectral de mayor resolución espacial.

Durante la última década, las técnicas basadas en transformadas wavelet han proliferado como métodos de fusión de imágenes pancromáticas y multiespectrales (Aiazzi et al., 2002; Amolins et al., 2007; Garguet-Duport et al., 1996; Ranchin et al., 2003; Ranchin y Wald, 2000; Simone et al., 2002). Estos algoritmos de fusión se pueden considerar como una extensión del método *High Pass Filtering* (Chavez et al., 1991), que considera que la información espacial está contenida en las altas frecuencias. Las transformadas Wavelet extraen información de detalle de la imagen pancromática, para posteriormente integrarla en la imagen multiespectral usando métodos de sustitución, adición o una selección de métodos basados en la frecuencia o el contexto espacial. Por otro lado, una ventaja de estas técnicas sobre las anteriores es que la función wavelet puede ser modificada para tener propiedades específicas, que puedan ser útiles para alguna aplicación particular de la transformación (Amolins et al., 2007; Lillo-Saavedra y Gonzalo, 2006; Lillo-Saavedra y Gonzalo, 2007; Mallat, 1999).

Una alternativa metodológica a las anteriores se fundamenta en los métodos geoestadísticos, que a diferencia de los métodos presentados en párrafos anteriores, considera explícitamente las características de variabilidad espacial de las imágenes a fusionar (Chica-Olmo y Abarca-Hernandez, 1998; Memarsadeghi et al., 2005; Nishii et al., 1996). Este modelo geoestadístico de fusión se basa en el método de cokriging (Atkinson et al., 1992, 1994; P. y Delfiner, 1999). Una variante a esta metodología es la propuesta por Pardo-Igúzquiza et al. (2006) (*Downscaling CoKriging*, DCK), que a diferencia de las anteriores, considera aspectos relevantes en la fusión como el tamaño del soporte (tamaño del píxel), la correlación entre bandas, las correlaciones cruzadas y las funciones de respuesta espectral de los sensores.

Aunque se han publicado diferentes estudios comparativos de métodos de fusión de imágenes, únicamente unos pocos incluyen una evaluación comparativa detallada de los resultados obtenidos por una representación significativa de distintos algoritmos. Chavez et al., (1991), Ehlers (1991) y Rigol y Chica-Olmo (1998) compararon resultados basados en métodos clásicos como el de Brovey, Análisis de Componentes Principales, *Intensity Hue Saturation* y *High Pass Filtering*. Mientras que Yocky (1996), Garguet-Duport (1996) y Ranchin y Wald (2000) realizaron estudios comparativos de métodos clásicos con transformadas wavelet. Alparone et al., (2007) probó diferentes algoritmos más recientes para la integración de imágenes QuickBird y Pléiades simuladas.

El objetivo de este capítulo es realizar un análisis comparativo de diferentes algoritmos de integración de imágenes. En particular, se ha llevado a cabo una comparación entre cuatro técnicas de fusión diferentes, que representan aproximaciones metodológicas de diferente naturaleza: dos métodos basados en transformadas wavelet, *Wavelet à Trous* (WAT) y *Multidirección-Multiresolución* (MDMR); un método geoestadístico, Downscaling Cokriging (DCK) y un método Bayesiano (L1COR).

La comparativa llevada a cabo en este estudio se ha efectuado a partir de las fusiones realizadas entre las bandas multispectrales y la pancromática de una imagen Landsat 7 *Enhanced Thematic Mapper* (ETM+). La imagen fue adquirida el 20 de Julio de 2002 sobre el área metropolitana de Granada. Esta sub-escena corresponde al *path 200 row 34* del *Landsat Worldwide Reference System* (WRS). Para el análisis se seleccionó un sector de la imagen Landsat de 944 km<sup>2</sup> (1024x1024 píxeles de 30x30 m<sup>2</sup>), que incluye áreas urbanas y pequeñas parcelas agrícolas (Figura 4.1).

Los resultados de la fusión se han evaluado desde diferentes perspectivas (Ranchin et al., 2003; Wald et al., 1997): desde un punto de vista cualitativo, mediante el análisis de la calidad visual de las imágenes; y cuantitativamente, mediante la aplicación de un remuestreo de los datos a una resolución más grosera y la aplicación posterior de diferentes índices y estadísticos para medir la calidad

espacial y espectral de la fusión. Además, se ha llevado a cabo un experimento para calcular “medidas de coherencia”, degradando las imágenes fusionadas a su resolución original. Finalmente, la calidad espectral de las imágenes también fue evaluada indirectamente mediante la clasificación digital de las imágenes fusionadas.




Figura 4.1. Composición en falso color 432 (RGB) de la imagen Landsat 7 ETM+ del área de estudio (944 km<sup>2</sup>)

## 2 Fundamentos de los métodos de fusión de imágenes

En esta sección, se describen brevemente los cuatro métodos elegidos como técnicas de fusión y la comparación de sus resultados. Estos algoritmos presentan diferentes complejidades computacionales y de aplicación.

### 2.1 Método WAT

Las transformadas Wavelet pueden considerarse como un conjunto de filtros, que aplicados a una secuencia de niveles de descomposición de una imagen, dividen la señal (ej. imagen de satélite) en sus componentes de alta y baja frecuencia (Amolins et al., 2007). Esta descomposición, al aplicarse a diferentes niveles, se conoce como descomposición multi-resolución.

La transformada Wavelet à Trous, o WAT (Nunez et al., 1999) implica la aplicación de una serie de convoluciones y deconvoluciones para los diferentes niveles de degradación de la imagen (Chibani y Houacine, 2002; Garzelli et al., 2004; Gonzalez-Audicana et al., 2005; Nunez et al., 1999; Ranchin et al., 2003). WAT requiere un proceso de filtrado iterativo, en el cual se usa una serie de filtros de degradación para obtener los coeficientes wavelet. Puesto que es un algoritmo no-decimado, el proceso empieza con un filtro inicial, al cual se le insertan filas y columnas de ceros entre las filas y columnas del filtro de la iteración previa hasta que se consigue la resolución deseada.

El método WAT a diferencia de otros algoritmos como el piramidal de Mallat (Gonzalez-Audicana et al., 2005; Mallat, 1999), está caracterizado por la independencia direccional del proceso de filtrado y por la no compresión espacial de los diferentes niveles de degradación. Por ello, la imagen resultante de cada nivel de degradación tiene la mitad de resolución que la imagen anterior, pero el mismo tamaño, de forma que la información contenida en cada uno de los niveles es redundante.

Los coeficientes wavelet  $A_{uj+n}^{kj}(\mathbf{x})$  se calculan como diferencia entre dos niveles consecutivos de degradación:

$$A_{uj+n}^{kj}(\mathbf{x}) = Z_{uj+n-1}^{kj}(\mathbf{x}) - Z_{uj+n}^{kj}(\mathbf{x}) \quad (4.1)$$

$Z_{uj}^k(x)$  representa el nivel digital de un pixel en una localización  $\mathbf{x} = (x,y)$  que pertenece a la banda espectral  $k_j$  de la imagen original.

Considerando un criterio aditivo, si  $Z_{uj+n}^{kj}(\mathbf{x})$  representa los niveles de degradación que contiene la información de las bajas frecuencias de la imagen original multiespectral, y  $A_{uj+n}^{kj}(\mathbf{x})$  los coeficientes wavelet respectivos que contienen la información de las altas frecuencias, es posible obtener una imagen fusionada de alta resolución  $\hat{Z}_{u_0}^{k_0}(\mathbf{x})$ , por medio de la suma de las bajas frecuencias contenidas en la

imagen degradada multiespectral y las altas frecuencias extraídas de la imagen pancromática.

$$\hat{Z}_{u_0}^{k_0}(\mathbf{x}) = Z_{u_j+n}^{k_j}(\mathbf{x}) + \sum_{k=1}^n A_{u_j+n}^{k_j}(\mathbf{x}) \quad (4.2)$$

## 2.2 Método MDMR

El algoritmo Multidirección-Multirresolución (Lillo-Saavedra y Gonzalo, 2007) es una modificación del método WAT que incorpora transformadas direccionales. El algoritmo intenta encontrar un equilibrio óptimo entre el contenido espacial y espectral de las imágenes combinadas, por medio de la aplicación de filtros direccionales elipsoidales.

El proceso de fusión, como se muestra en las ecuaciones siguientes, es similar al del método WAT:

$$A_{\theta_n}^{k_j}(\mathbf{x}) = Z_{\theta_n}^{k_j}(\mathbf{x}) - Z_{\theta_{n-1}}^{k_j}(\mathbf{x}) \quad (4.3)$$

$$\hat{Z}_{u_0}^{k_0}(\mathbf{x}) = Z_{\theta_l}^{k_j}(\mathbf{x}) + \sum_{k=1}^l A_{\theta_n}^{k_j}(\mathbf{x}) \quad (4.4)$$

Sin embargo, como puede observarse, los niveles de degradación han sido reemplazados por filtros direccionales de orientación  $\theta$ . A pesar de que WAT es un algoritmo altamente anisotrópico, que permite ponderar la resolución espacial y espectral deseada. Lakshmanan (2004) propuso la ecuación (4.5) para introducir una aproximación separable a un filtro de paso bajo direccional (ecuaciones (4.7) and (4.8)).

$$F(x, y) = \begin{cases} 1 & \text{if } \frac{(x \cos \theta - y \sin \theta)^2}{a^2} + \frac{(x \sin \theta + y \cos \theta)^2}{b^2} \leq 1 \\ 0 & \text{otherwise} \end{cases} \quad (4.5)$$



Donde  $a$  y  $b$  definen la escala del filtro y su ratio la elongación de la elipse.

$$f(x, y) = f_1(x) \times f_2(y) - \alpha x f_1(x) \times y f_2(y) \quad (4.6)$$

Donde  $\alpha$  viene dado por  $(a^2 - b^2) \sin(2\theta) / a^2 b^2$  y  $f_1(x)$  y  $f_2(y)$  por:

$$f_1(x) = \exp\left(-x^2 \left(\frac{\cos^2 \theta}{a^2} + \frac{\sin^2 \theta}{b^2}\right)\right) \quad (4.7)$$

$$f_2(y) = \exp\left(-y^2 \left(\frac{\cos^2 \theta}{b^2} + \frac{\sin^2 \theta}{a^2}\right)\right) \quad (4.8)$$

### 2.3 Método DCK

La imagen fusionada de alta resolución espacial obtenida mediante el método geoestadístico DCK, se expresa como una combinación lineal de las imágenes experimentales (Atkinson et al., 2008a; Pardo-Iguzquiza et al., 2006):

$$\hat{Z}_{u_0}^{k_0}(\mathbf{x}_0) = \sum_{j=1}^M \sum_{i=1}^{n_j} \lambda_{ji}^0 Z_{u_j}^{k_j}(\mathbf{x}_i) \quad (4.9)$$

donde:

$Z_a^b(\mathbf{x})$ : representa el nivel digital de una imagen de satélite para la banda espectral  $b$  de resolución espacial (tamaño de pixel)  $a$  para una localización espacial particular  $\mathbf{x} = \{x, y\}$ . El símbolo circunflejo sobre  $\mathbf{Z}$  denota que es la imagen estimada/fusionada mediante cokrigeaje; mientras que en caso contrario se trata de la imagen experimental. Otras anotaciones son:

$b = k_0$  banda espectral cuya resolución espacial se desea mejorar.

$b = k_j$  banda espectral experimental incluida en el proceso de fusión por cokrigeaje.

$a = u_0$  resolución espacial o tamaño de pixel de la imagen fusionada.

$a = u_j$  resolución espacial o tamaño de pixel de una imagen experimental usada en la fusión.

$M$ : número de bandas experimentales usadas en la fusión.

$n_j$  : número de píxeles de la vecindad usados para la imagen experimental de la banda espectral  $k_j$  . Normalmente, estas vecindades son ventanas móviles  $3 \times 3$ ,  $5 \times 5$ ,  $7 \times 7$ , etc.

$\lambda_{ji}^0$  : pesos óptimos aplicados a  $Z_{u_j}^{k_j}(\mathbf{x}_i)$  para la estimación de  $Z_{u_0}^{k_0}(\mathbf{x}_0)$  .

Estos pesos óptimos se obtienen a partir de la resolución de un sistema lineal de ecuaciones, conocido como sistema de cokrigeaje. Dicho sistema se resuelve imponiendo la condición de que el estimador sea insesgado:

$$E\{\hat{Z}_{u_0}^{k_0}(\mathbf{x}_0) - Z_{u_0}^{k_0}(\mathbf{x}_0)\} = 0 \quad (4.10)$$

y minimizando la varianza de estimación

$$E\{[\hat{Z}_{u_0}^{k_0}(\mathbf{x}_0) - Z_{u_0}^{k_0}(\mathbf{x}_0)]^2\} \rightarrow \text{mínimo} \quad (4.11)$$

donde  $E\{.\}$  es el operador de esperanza matemática.

El sistema de cokrigeaje se representa en forma matricial como sigue:

$$\begin{bmatrix} \mathbf{C}_{u_1 u_1}^{k_1 k_1} & \cdots & \mathbf{C}_{u_1 u_M}^{k_1 k_M} & \mathbf{I}_{n_1} & \cdots & \mathbf{0}_{n_1} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{C}_{u_M u_1}^{k_M k_1} & \cdots & \mathbf{C}_{u_M u_M}^{k_M k_M} & \mathbf{0}_{n_M} & \cdots & \mathbf{I}_{n_M} \\ \mathbf{I}_{n_1}^t & \cdots & \mathbf{0}_{n_1}^t & 0 & \cdots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{0}_{n_1}^t & \cdots & \mathbf{I}_{n_1}^t & 0 & \cdots & 0 \end{bmatrix} \begin{bmatrix} \lambda_1^0 \\ \vdots \\ \lambda_M^0 \\ \mu_1 \\ \vdots \\ \mu_M \end{bmatrix} = \begin{bmatrix} \mathbf{C}_{u_0 u_1}^{k_0 k_1} \\ \vdots \\ \mathbf{C}_{u_0 u_M}^{k_0 k_M} \\ 1 \\ \vdots \\ 0 \end{bmatrix} \quad (4.12)$$

donde:

$\mathbf{C}_{u_i u_j}^{k_i k_j}$  : matriz  $(n_i \times n_j)$  de la varianza cruzada entre los píxeles  $n_i$  de una banda espectral  $k_i$  con una resolución espectral  $u_i$  y los píxeles  $n_j$  de una banda espectral

$k_j$  de resolución espectral  $u_j$ . Cabe destacar que la covarianza directa es equivalente a la covarianza cruzada de una imagen con respecto a si misma.

$\mathbf{I}_{n_i}^t$  :  $(1 \times n_i)$  vector de unos.

$\mathbf{0}_{n_i}^t$  :  $(1 \times n_i)$  vector de ceros.

El super índice  $t$  denota que se trata de un vector traspuesto.

$\mu_k$  :  $(k=1, \dots, M)$  multiplicadores de Lagrange.

Una explicación más detallada sobre la resolución del sistema de cokrigeaje (ecuación (4.12)) puede consultarse en Pardo-Igúzquiza et al., (2006; 2011) y Atkinson (2008b). Este método tiene en cuenta tres aspectos claves para la fusión de imágenes: el tamaño de pixel de las imágenes experimentales (tamaño de soporte), los variogramas simples y cruzados de las bandas radiométricas y la función de respuesta espectral del sensor.

## 2.4 Método L1COR

En el marco de la formulación Bayesiana, el problema de aumento de resolución de una imagen empieza con la definición de la distribución de probabilidad conjunta  $p(\mathbf{y}, \mathbf{Y}, \mathbf{x})$ , donde  $\mathbf{y}$  es la imagen multiespectral de alta resolución que se pretende estimar, la cual tiene  $M$  bandas  $\mathbf{y}_k$ ,  $k = 1, \dots, M$ .  $\mathbf{Y}$  es la imagen multiespectral observada de baja resolución y  $\mathbf{x}$  es la banda pancromática. Esta probabilidad conjunta se define como el producto de la distribución condicional de la imagen multiespectral de alta resolución y las bandas pancromáticas, dada la imagen observada y su probabilidad a priori, que se expresa formalmente como:

$$p(\mathbf{y}, \mathbf{Y}, \mathbf{x}) = p(\mathbf{y})p(\mathbf{Y}, \mathbf{x} | \mathbf{y}) \quad (4.13)$$

El método Bayesiano se basa en el cálculo de la distribución de probabilidad a posteriori, que en virtud del teorema de Bayes, puede calcularse en función de la verosimilitud como:

$$p(\mathbf{y}|\mathbf{Y}, \mathbf{x}) = p(\mathbf{y})p(\mathbf{Y}, \mathbf{x}|\mathbf{y}) / p(\mathbf{Y}, \mathbf{x}) \quad (4.14)$$

El método LICOR (Vega et al., 2010) propone un modelo híbrido, basado en la norma L1 que aporta información sobre el suavizado espacial dentro de cada banda, y un modelo autorregresivo (AR) que añade información sobre la correlación entre las bandas de la imagen que permite escribir la probabilidad a priori como:

$$p(\mathbf{y}) \propto \exp \left\{ \sum_{\substack{k, k'=1 \\ k' > k}}^M \frac{v_{kk'}}{2} \|\mathbf{y}_b - \mathbf{y}_{k'}\|^2 \right\} \prod_{k=1}^M \exp \left\{ - \sum_{i=1}^P \left[ \alpha_k^h \|\Delta_i^h(\mathbf{y}_k)\| + \alpha_k^v \|\Delta_i^v(\mathbf{y}_k)\| \right] \right\} \quad (4.15)$$

donde los términos cuadráticos correspondientes al modelo AR definen la correlación o similitud entre píxeles en la misma posición de las bandas  $k$  y  $k'$ , y  $v_{kk'} > 0$  es un peso que controla su contribución. Mientras que el término lineal de la norma L1 impone el desenfoque de cada banda. En la expresión previa,  $\Delta_i^h(\mathbf{y}_k)$  y  $\Delta_i^v(\mathbf{y}_k)$  representan, respectivamente, las diferencias horizontales y verticales de primer orden en el pixel  $i$ ,  $p$  el número de píxeles de la imagen de alta resolución, y  $\alpha_k^h$  y  $\alpha_k^v$  son los parámetros de los modelos horizontales y verticales para la banda  $k$ . La contribución del modelo L1 refuerza el suavizado espacial de los objetos en cada banda, controlando el ruido a la vez que preserva los bordes; mientras que los términos cuadráticos del modelo AR refuerzan el suavizado espectral.

Puesto que la imagen pancromática observada y la imagen multiespectral de baja resolución son independientes, podemos escribir la verosimilitud como el producto  $p(\mathbf{Y}, \mathbf{x}|\mathbf{y}) = p(\mathbf{Y}|\mathbf{y})p(\mathbf{x}|\mathbf{y})$ . La distribución condicional de la imagen multiespectral observada,  $\mathbf{Y}$ , dada la imagen multiespectral real de alta resolución,  $\mathbf{y}$ , viene dada por

$$p(\mathbf{Y}|\mathbf{y}) \propto \prod_{k=1}^M \exp \left\{ - \frac{1}{2} \beta_k \|\mathbf{Y}_k - \mathbf{H}\mathbf{y}_k\|^2 \right\} \quad (4.16)$$

donde  $\beta_k$  es la inversa de la varianza del ruido Gaussiano independiente en cada banda  $k$ , y  $\mathbf{H} = \mathbf{DB}$ , con  $\mathbf{B}$  una matriz de emborronamiento que tienen en cuenta la

respuesta espectral del sensor y cualquier otro desenfoque que puede degradar la imagen y  $D$  un operador que define el ratio de fusión.

La distribución condicional de la imagen pancromática  $\mathbf{x}$  dada  $\mathbf{y}$ , se define como

$$p(\mathbf{x} | \mathbf{y}) \propto \exp \left\{ -\frac{1}{2} \gamma \left\| \mathbf{x} - \sum_{k=1}^M \lambda_k \mathbf{y}_k \right\|^2 \right\} \quad (4.17)$$

Donde  $\gamma$  es la inversa de la varianza del ruido Gaussiano de media cero de la imagen pancromática y  $\lambda_k \geq 0$  son valores conocidos que ponderan la contribución de cada banda multiespectral de alta resolución  $\mathbf{y}_k$  a la imagen pancromática  $\mathbf{x}$ . Estos valores son calculados a partir de la respuesta espectral del sensor.

Una vez conocidos los parámetros, o previamente estimados (Molina et al., 2008; Vega et al., 2010), el paradigma Bayesiano impone que la inferencia en  $\mathbf{y}$  debe basarse en la distribución a posteriori  $p(\mathbf{y} | \mathbf{Y}, \mathbf{x})$ . Como  $p(\mathbf{y} | \mathbf{Y}, \mathbf{x})$  no puede ser calculada analíticamente en una forma cerrada, se aplican métodos variacionales para aproximar esta distribución por medio de otra distribución,  $q(\mathbf{y})$ , que minimiza la divergencia de Kullback-Leibler de  $p(\mathbf{y} | \mathbf{Y}, \mathbf{x})$  y  $q(\mathbf{y})$  y que hace el proceso de inferencia tratable. La imagen multiespectral de alta resolución estimada puede ser obtenida como la media de la distribución  $q(\mathbf{y})$ .

### **3 Parámetros e índices para evaluar la calidad de las imágenes fusionadas**

Una metodología de fusión óptima no debe alterar la información de la imagen original (tanto espacial como espectral), lo que permite su uso en aplicaciones como la clasificación temática, o la detección de cambios. Es por ello que se ha realizado un análisis detallado de la calidad de los resultados obtenidos por los cuatro métodos de fusión descritos en la sección anterior. Con este objetivo, se han aplicado los siguientes criterios, basados en la calidad visual y aspectos numéricos. Estos últimos

por medio de índices y parámetros estadísticos. El procedimiento general se esquematiza en la Figura 4.2.

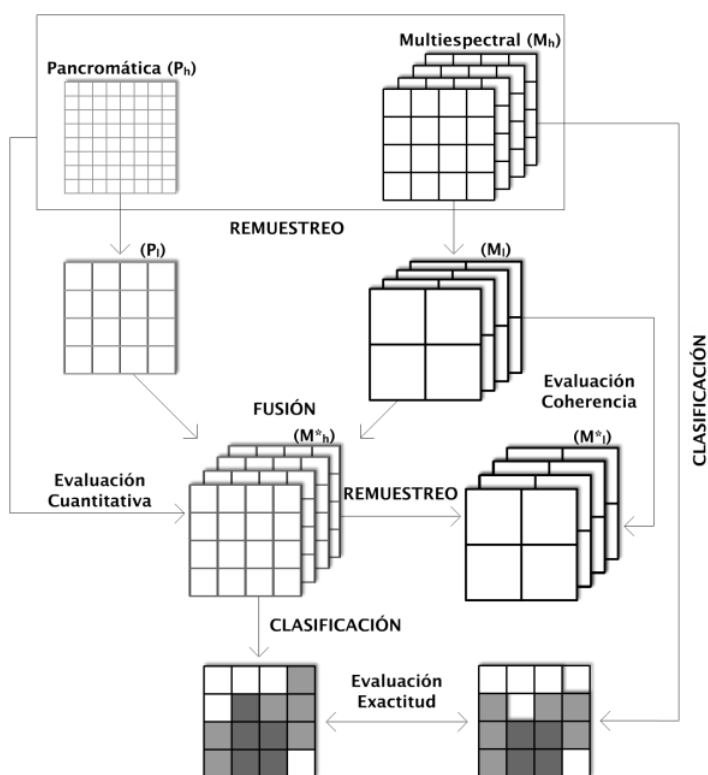


Figura 4.2. Esquema de la metodología seguida para la evaluación comparativa de los algoritmos de fusión.

La calidad de los resultados generados por las diferentes metodologías de fusión ha sido evaluada inicialmente de modo visual. Los criterios usados en la comparación fueron el tono, contraste, saturación, nitidez y textura entre las imágenes fusionadas.

También se ha realizado una evaluación numérica de la calidad de las imágenes multiespectrales. Para ello se consideraron medidas de calidad espacial y espectral. Para cuantificar las diferencias entre la información espectral de las imágenes fusionadas ( $M_h^*$ ) y la imagen real que el sensor ETM+ observaría si tuviese una

resolución espacial ( $M_h$ ) se calcularon un conjunto de parámetros estadísticos e índices:

-Coeficiente de correlación (C).

-Error Cuadrático Medio (RMSE).

-El índice ERGAS (Erreur Relative Globale Adimensionnelle de Synthèse) (Ranchin et al., 2003; Wald, 2000):

$$ERGAS_{spectral} = 100 \frac{h}{l} \sqrt{\frac{1}{N} \sum_{k=1}^N \frac{(RMSE_{spectral}(\mathbf{B}_k))^2}{M_k^2}} \quad (4.18)$$

Donde  $h/l$  es el ratio entre la resolución de la imagen pancromática y la imagen multiespectral,  $N$  el número de bandas espectrales ( $\mathbf{B}_k$ ) de la imagen fusionada,  $M_k$  el valor medio de cada banda espectral y RMSE el error cuadrático medio calculado entre la imagen fusionada y la multiespectral original.

Cuanto menor es el valor de ERGAS mejor es la calidad de la imagen fusionada. Wald (1999, 2000), en sus estudios sobre la calidad en fusión de imágenes, determina que un valor de ERGAS  $< 3$  corresponde a imágenes fusionadas de calidad satisfactoria.

-El índice de calidad de imagen (Q), propuesto por Wang y Bovik (2002) como alternativa al error cuadrático medio, modela las diferencias entre dos imágenes monocromáticas como una combinación de tres factores diferentes: pérdida de correlación, distorsión lumínica y distorsión del contraste.

$$Q = \frac{4\sigma_{OF}\bar{O}\bar{F}}{(\sigma_O^2 + \sigma_F^2)[(\bar{O})^2 + (\bar{F})^2]} \quad (4.19)$$

Donde  $\bar{O}$  y  $\bar{F}$  son la media de la imagen original y fusionada respectivamente,  $\sigma_O^2$  y  $\sigma_F^2$  son las varianzas y  $\sigma_{OF}$  la covarianza entre la imagen original y la fusionada. Para evitar errores ligados a la dependencia espacial del índice, Wang y

Bovik recomiendan utilizar ventanas móviles de diferentes tamaños. Se usaron ventanas de 8x8, 16x16, 32x32, 64x64 y 128x128, por lo que el índice resultante fue producto de la media de todos los índices parciales (Gonzalez-Audicana et al., 2005).

-El índice de similitud estructural (SSIM) (Wang et al., 2004) considera la luminancia, contraste y las diferencias estructurales entre cada banda de la imagen fusionada y la imagen original multiespectral.

$$SSIM(\mathbf{x}, \mathbf{y}) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (4.20)$$

Donde  $\mathbf{x}$  e  $\mathbf{y}$  son dos señales de imagen no negativas,  $\mu_x$  y  $\mu_y$  son la luminancia de las imágenes  $\mathbf{x}$  e  $\mathbf{y}$ ,  $\sigma_{xy}$ ,  $\sigma_x$  y  $\sigma_y$  con la covarianza y las varianzas de las imágenes  $\mathbf{x}$  e  $\mathbf{y}$ , respectivamente y, por último,  $C_1$  y  $C_2$  son constantes. El índice SSIM toma valores entre -1 y 1, cuanto más cercano a 1 mejor es la calidad de la fusión.

-La calidad espacial fue evaluada por medio de la correlación entre la componente de alta frecuencia (HFC) de las imágenes fusionadas ( $M_h^*$ ) y la pancromática original ( $P_l$ ).

-La medida de coherencia, entre las imágenes fusionadas degradadas  $M_l^*$  y la imagen original ( $M_l$ ) se obtuvo mediante el cálculo del coeficiente de correlación (C) y del error cuadrático medio (RMSE).

Por último, se ha considerado la mediada de la exactitud cartográfica de la clasificación digital de las imágenes fusionadas como criterio de calidad (Congalton, 1991; Congalton y Green, 2009).

## 4 Resultados de las fusiones

La mejor referencia para evaluar la calidad de las imágenes fusionadas consiste, obviamente, en conocer la imagen verdadera o real ( $M_h$ ) que se desearía obtener



mediante el método de fusión (Wald et al., 1997). Sin embargo, esto en la práctica no es posible. Por esta razón, se realizó un experimento en el cual la imagen original multiespectral ( $M_h$ ) y la pancromática original ( $P_h$ ), fueron degradadas a resoluciones espaciales iguales a 120 m ( $M_l$ ) y 30 m ( $P_l$ ), respectivamente, para obtener imágenes fusionadas con una resolución de 30m ( $M_h^*$ ) (véase Figura 4.2). De esta forma, los resultados de la fusión sí pueden ser comparados ( $M_h^*$ ) con la imagen real ( $M_h$ ).

Por otro lado, cualquier imagen multiespectral, una vez degradada a su resolución original  $l$ , debería ser tan parecida como fuese posible a la imagen multiespectral original ( $M_l$ ) (Wald et al., 1997). Para medir la coherencia entre dichas imágenes los resultados de las fusiones ( $M_h^*$ ) fueron degradados a la resolución espacial  $l$ .

## **4.1 Parametrización de los algoritmos de fusión**

### **4.1.1 WAT**

En la aplicación del método WAT, se consideró un ratio de fusión 4:1 entre la imagen Landsat multiespectral (120 m) y pancromática (30m) degradadas. Por tanto, se aplicaron dos niveles de degradación a la imagen multiespectral, por lo que se obtuvieron dos conjuntos de coeficientes wavelet. El primero contiene el detalle espacial entre los 120 y los 60 m, y el segundo, el detalle entre los 60 m y 30 m (Gonzalez-Audicana et al., 2005; Lillo-Saavedra y Gonzalo, 2006).

### **4.1.2 MDMR**

De acuerdo con el trabajo de Lillo-Saavedra y Gonzalo (2007), para establecer la direccionalidad y los parámetros óptimos del filtro, se efectuaron un gran número de ensayos aplicados a los diferentes niveles de degradación ( $l = 2^1, 2^2, 2^3, 2^4$ ) para

diferentes combinaciones de  $a$  y  $b$  (véase la sección 2.2). Estos valores óptimos del filtro se establecieron mediante un procedimiento denominado *simulated annealing*, para garantizar una solución equilibrada entre la resolución espacial y espectral de la imagen. Cabe mencionar que este método permite ajustar los valores de  $a$  y  $b$  de forma que se asigna un peso mayor al contenido en información espacial o espectral (Figura 4.3).




Figura 4.3. Planos espectral y espacial para el nivel de degradación  $k=2$  del método Multidirección-Multirresolución.

### 4.1.3 DCK

Este método requiere el análisis variográfico de la imagen multiespectral y pancromática. Los variogramas simples experimentales de las bandas de la imagen multiespectral y pancromática se muestran en la Figura 4.4, y los variogramas cruzados entre estas imágenes en la Figura 4.5. Se usó un modelo de correogionalización lineal con dos estructuras anidadas: una de corto alcance (45 m) y otra de largo alcance (728 m). Los alcances prácticos fueron iguales a 135 y 2184 m, respectivamente. Las mesetas de los variogramas de las bandas multiespectrales y pancromática, para soporte puntual, fueron calculadas usando un proceso de deconvolución numérica y un ajuste por mínimos cuadrados.

La fusión mediante DCK se llevó a cabo usando dos bandas en cada caso: la banda cuya resolución espacial se deseaba mejorar y la banda pancromática. Los resultados del sistema de cokrigearse proporcionaron los pesos que fueron aplicados a la imagen de alta y baja resolución. Después de efectuar diferentes pruebas, se consideraron vecindades de 3x3 y 5x5 píxeles para las imágenes de baja y alta resolución espacial, respectivamente.

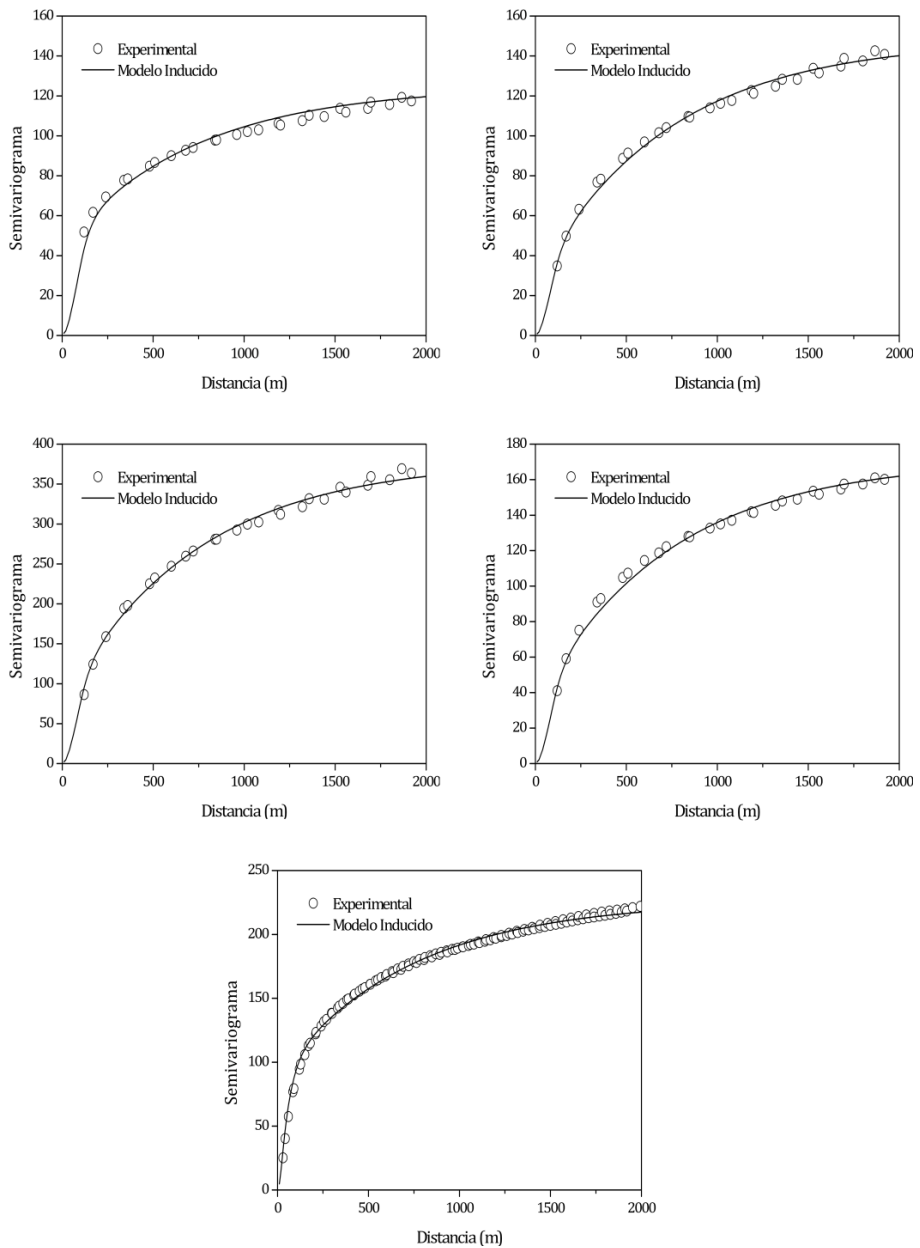


Figura 4.4. Variogramas experimentales y modelos inducidos de las bandas de la imagen multispectral (azul, verde, rojo e infrarrojo próximo) y de la imagen pancromática (de izquierda a derecha y de arriba abajo).

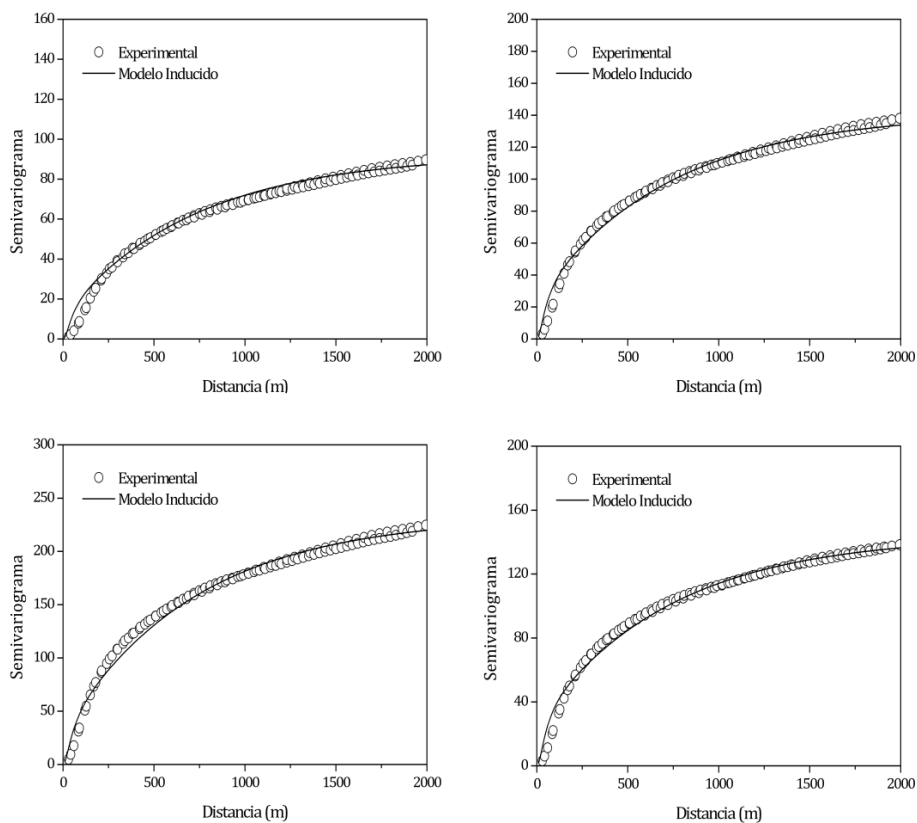


Figura 4.5. Variogramas cruzados experimentales y modelos inducidos entre las bandas de la imagen multispectral (azul, verde, rojo e infrarrojo próximo) y la imagen pancromática (de izquierda a derecha y de arriba abajo).

#### 4.1.4 L1COR

Las distribuciones de probabilidad condicionada, expresadas en las ecuaciones (4.15) y (4.16), dependen de un conjunto de parámetros que modelan la relación entre

la imagen multiespectral de alta resolución, la banda pancromática y la imagen multiespectral de baja resolución. Los valores de  $\lambda_k$ ,  $k = 1, \dots, 4$ , de la ecuación (4.16) fueron calculados a partir de la función de respuesta espectral del sensor ETM+, según el procedimiento descrito en Vega et al. (2010). Los valores obtenidos fueron 0,0078, 0,242, 0,2239 y 0,5263, para las bandas 1 a 4, respectivamente. El valor bajo de  $\lambda_1$  es debido al solapamiento reducido entre la banda azul y la banda pancromática. La matriz H se obtuvo mediante la simulación del proceso de degradación, usando  $0,125 \times 14 \times 4$ , como función de integración del sensor, el sub-muestreo por un factor igual a 4 y el descarte de cada uno de los otros tres píxeles en cada dirección. Puesto que no se añadió ruido durante el proceso se asignaron valores a  $\beta_k$  y  $\gamma$  iguales a 100 y 10, respectivamente.

Los valores para los parámetros del modelo de probabilidad a priori se seleccionaron de la forma siguiente. Los valores para  $\alpha_k^h$  y  $\alpha_k^v$  se determinaron como  $1 / \sum_{i=1}^P \|\Delta_i^d(\mathbf{Y}_b)\|^2$ , para las direcciones  $d = \{h, v\}$ , respectivamente, con P igual al número de píxeles de  $\mathbf{Y}_b$ . Una vez estimados estos valores, se seleccionaron los valores para  $v_{kk}$ , como  $v_{k,k} = C / \|\mathbf{Y}_k - \mathbf{Y}_k\|^2$ ; el valor del parámetro C se estableció para maximizar la relación señal/ruido de la reconstrucción obtenida. Siguiendo este procedimiento se obtuvieron  $\alpha_h = \{0,13, 0,1, 0,07, 0,1\}_t$ ,  $\alpha_v = \{0,13, 0,11, 0,07, 0,11\}_t$  y  $\{v_{12}, v_{13}, v_{14}, v_{23}, v_{24}, v_{34}\} = \{1,031, 0,0001, 0,005, 0,0001, 0,03, 0,0001\}_t$ .

## 4.2 Evaluación de la calidad de las imágenes fusionadas

### 4.2.1 Evaluación cualitativa

Se seleccionaron dos subsectores del área de estudio, con contextos ambientales diferentes, para facilitar la interpretación visual de la calidad de las imágenes fusionadas (ver la Figura 4.1 y Figura 4.6). En el sector A, la parte norte está ocupada por estructuras urbanas principalmente, y la parte sur por cultivos en regadío. El

sector B se caracteriza por una amplia variedad de cubiertas naturales, con áreas distintivas de vegetación alrededor de un cuerpo de agua central. La Figura 4.6 muestra una composición en color real 321 (RGB) de los subsectores A y B de las cinco imágenes fusionadas.

Para todos los casos estudiados, la imagen interpolada mediante convolución cúbica produjo imágenes con un efecto de suavizado importante. Las imágenes fusionadas mostraron diferencias considerables en su calidad visual, en función de la técnica de fusión aplicada. Los métodos WAT y MDMR tuvieron un impacto negativo en el color de la imagen, reduciendo el contraste, incrementando la saturación del color e introduciendo distorsiones cromáticas, que pueden estar asociadas a una pérdida de calidad espectral de la imagen. Sin embargo, estos métodos consiguieron un mejor detalle espacial y dieron lugar a imágenes más angulosas, lo cual se reflejó más notablemente en las características lineales presentes en las zonas urbanas (subsector A). Sin embargo, cuando mayor fue el realce espacial, mayores fueron también las distorsiones espectrales, la reducción del contraste, y el efecto de homogeneización radiométrica, que causó una pérdida de textura en las imágenes (Zhang y Hong, 2005). Este efecto fue particularmente apreciable en las imágenes fusionadas mediante el método MDMR, donde los campos de cultivo aparecen emborronados y casi imperceptibles en algunos sectores (sector B de la Figura 4.6). Los métodos Bayesiano y geoestadístico mejoraron la calidad visual de la interpolación bicúbica y dieron lugar a imágenes fusionadas más parecidas a la imagen original de referencia, preservando el contraste, la saturación y la textura.




Figura 4.6. Detalles en color real de la imagen multispectral original y las imágenes fusionadas de los sectores A y B. Se muestran las siguientes imágenes de arriba abajo y de izquierda a derecha: la imagen multispectral de referencia, las imágenes fusionadas por LICOR, DCK, WAT y MDMR, respectivamente; así como la imagen multispectral original remuestreada.



### **4.2.2 Evaluación cuantitativa directa**

En la cuantificación de la calidad espectral y espacial de las imágenes fusionadas, se utilizaron diversos índices y parámetros estadísticos calculados a partir de los resultados de la fusión y de la imagen de referencia (Tabla 4.1 y Tabla 4.2). Los índices espectrales fueron calculados a partir de la imagen Landsat ETM+ real ( $M_h$ ) y los espaciales a partir de la imagen pancromática ( $P_h$ ) (véase Figura 4.2).

Los coeficientes de correlación indicaron una correlación relativamente alta para las bandas del infrarrojo cercano (IR), obtenidas por todos los métodos de fusión analizados (de 0,926 a 0,963). Sin embargo, las correlaciones fueron considerablemente más altas para las bandas del verde (de 0,942 a 0,966) y el rojo visible (de 0,951 a 0,972), debido a una mejor correspondencia espectral con la banda pancromática. El realce de la banda azul dio como resultado una pérdida de correlación importante, especialmente notable para los métodos WAT y MDMR, debido a que esta banda visible tiene un menor peso en la banda pancromática. Con respecto a la imagen multiespectral, en general, MDMR fue el que produjo coeficientes de correlación menores para todas las bandas (de 0,890 a 0,951). Por el contrario, los métodos DCK y LICOR obtuvieron coeficientes de correlación mayores con las bandas multiespectrales originales (de 0,955 a 0,972 y de 0,953 a 0,971, respectivamente).

En cuanto a los errores cuadráticos medios (RMSE), éstos fueron menores para los métodos DCK y LICOR, mientras que para el resto de algoritmos, en especial para el algoritmo MDMR, fueron mayores (Tabla 4.1).

Los resultados de la correlación con las altas frecuencias (HFC), mostraron que los métodos wavelet (WAT y MDMR) incorporaron una mayor cantidad de información de la banda pancromática que DCK y LICOR. El método LICOR dio como resultado los valores más bajos de HFC, en especial para las bandas azul y verde, cuyos coeficientes de correlación fueron iguales a 0,833 y 0,837, respectivamente.

Tabla 4.1. Valores de los coeficientes de correlación (C), error cuadrático medio (RMSE) y coeficientes de correlación de las altas frecuencias (HFC) para las bandas multispectrales azul (A), verde (V), roja (R) e infrarroja (IR).

	C A	C V	C R	C IR	RMSE A	RMSE V	RMSE R	RMSE IR	HFC A	HFC V	HFC R	HFC IR
L1COR	0,953	0,966	0,971	0,948	4,093	4,638	6,98	6,04	0,833	0,837	0,944	0,958
DCK	0,955	0,965	0,972	0,963	3,963	4,675	6,796	4,891	0,933	0,913	0,951	0,957
WAT	0,915	0,952	0,962	0,941	5,611	5,425	8,059	6,086	0,994	0,995	0,996	0,997
MDMR	0,890	0,942	0,951	0,926	6,675	5,979	9,16	6,836	0,997	0,997	0,993	0,994

Valores de ERGAS bajos y de Q y SSIM altos son indicativos de imágenes fusionadas de buena calidad. Obviamente, un resultado óptimo del proceso de fusión daría valores de ERGAS y Q y SSIM iguales a 0 y 1, respectivamente.

Según Wald et al. (1997), los valores de ERGAS superiores a tres corresponden a imágenes fusionadas de baja calidad, mientras que si el valor de ERGAS es inferior a este umbral, la calidad es satisfactoria. De acuerdo con esta idea previa, los métodos DCK y L1COR mejoraron los resultados del resto de métodos en lo que al índice ERGAS se refiere (Tabla 4.2).

Para facilitar la comparación sobre la base del índice Q, la Tabla 4.2 muestra los valores promedio para todos los diferentes tamaños de ventanas móviles (Q Med). No obstante, los valores de Q para cada tamaño de ventana de las imágenes fusionadas y de la imagen remuestreada, usando una convolución bicúbica, se muestran en la Figura 4.7. Como puede observarse, a partir de la citada figura, todos los métodos de fusión mejoraron el método de convolución bicúbica. El valor del índice Q promedio más alto fue obtenido por el método DCK (0,962). En cuanto al índice Q para cada banda, todos los métodos obtuvieron los valores más bajos para la banda azul, en especial MDMR (0,887). La banda roja resultó ser la mejor fusionada por todos los métodos, alcanzando el valor más alto de Q para la fusión realizada por DCK (0,972). Del mismo modo, el resto de bandas también alcanzaron los mejores resultados en términos de Q usando el método DCK (oscilaron entre 0,955 y 0,972).




Figura 4.7. Valores promedio del índice Q para los diferentes tamaños de ventanas móviles usadas.

A diferencia del índice Q, los resultados del cálculo del índice SSIM (Tabla 4.2) variaron en función del método y la banda objeto de la fusión; aunque en todos los casos DCK y L1COR fueron superiores a los métodos wavelet. Los valores más altos de DCK ocurrieron para la banda del infrarrojo próximo, mientras que L1COR lo hizo para la banda roja, obteniendo valores similares para el resto de bandas. En promedio, los valores de SSIM del método DCK fueron ligeramente mayores que los de L1COR. El método L1COR obtuvo sus peores resultados para la banda infrarroja, mientras que el resto de métodos lo obtuvieron para la banda roja. Los valores promedio de SSIM fueron muy similares a los resultados de ERGAS y Q. En función de estos índices espectrales se pudo establecer una ordenación de los métodos de fusión, en la que el método WAT fue mejor que MDMR; y que DCK y L1COR fueron mejores que los métodos wavelet, aunque muy similares entre sí.

Tabla 4.2. Valores del índice ERGAS, de calidad universal (Q) y de similitud estructural (SSIM), para las bandas multispectrales azul (A), verde (V), roja (R), infrarroja (IR) y el promedio de las bandas (Med).

	ERGAS	Q A	Q V	Q R	Q IR	Q Med	SSIM A	SSIM V	SSIM R	SSIM IR	SSIM Med
L1COR	3,085	0,953	0,964	0,971	0,947	0,959	0,885	0,873	0,851	0,836	0,861
DCK	2,914	0,955	0,964	0,972	0,962	0,963	0,888	0,87	0,842	0,875	0,869
WAT	3,603	0,914	0,952	0,958	0,94	0,941	0,83	0,851	0,805	0,832	0,83
MDMR	4,107	0,887	0,942	0,945	0,925	0,925	0,819	0,852	0,788	0,83	0,822

Otro aspecto de interés que se consideró en este análisis fue el estudio de la coherencia entre la imagen original ( $M_l$ ) y las imágenes fusionadas tras ser degradadas a la resolución  $l$  (véase Figura 4.2). La estimación de las medidas de coherencia se basó en el cálculo de  $C$  y RMSE de las bandas estimadas con respecto a sus correspondientes bandas multispectrales (Tabla 4.3). De acuerdo con esta idea, el método DCK es el más coherente, ya que presentó valores de  $C$  prácticamente iguales a 1 y de RMSE menores que 0,8 para todas las bandas. El resto de métodos tuvieron coeficientes de correlación menores y RMSE mayores. L1COR y WAT fueron métodos menos “coherentes” que MDMR. Los errores más altos en L1COR pueden ser atribuidos a que este método, a la vez que incorpora la información de la banda pancromática, reduce el ruido que puede haber presente en la imagen fusionada.

Tabla 4.3. Valores de los coeficientes de correlación (C) y error cuadrático medio (RMSE), entre la imagen multispectral original y las imágenes fusionadas degradadas, para las bandas multispectrales azul (A), verde (V), roja (R) e infrarroja (IR).

	C A	C V	C R	C IR	RMSE A	RMSE V	RMSE R	RMSE IR
L1COR	0,926	0,953	0,92	0,884	5,11	5,12	11,564	8,804
DCK	0,999	1	1	0,999	0,693	0,684	0,798	0,773
WAT	0,835	0,888	0,933	0,879	7,59	7,958	9,872	8,289
MDMR	0,937	0,974	0,977	0,963	4,608	3,74	5,962	4,469

### **4.2.3 Evaluación cuantitativa indirecta**

En algunas aplicaciones de teledetección, no solo importa la calidad visual de las imágenes, sino que también se requiere que las imágenes fusionadas sean susceptibles de ser usadas en clasificación, para generar cartografía con una exactitud adecuada (ej. clasificación de los usos y las cubiertas del suelo, análisis de cambios, etc). Con el objetivo de evaluar los métodos de fusión, desde el punto de vista de la exactitud de las clasificaciones derivadas de los productos de la fusión, se aplicó un método de clasificación no supervisada denominado ISODATA (Lillesand y Keifer, 1994). Se eligió este procedimiento de clasificación, debido a que, es capaz de determinar la separabilidad espectral entre clases sin necesidad de intervención del especialista, que pueda sesgar la exactitud de la clasificación. Para la evaluación de la exactitud cartográfica de los mapas clasificados, a partir de las imágenes fusionadas, se usó como referencia la clasificación efectuada usando la imagen multiespectral original, puesto que ésta presenta el máximo alcanzable de resolución espacial y espectral. Por tanto, en teoría, podría alcanzarse un nivel de calidad comparable al de la imagen original si los algoritmos de fusión maximizasen la separabilidad potencial entre clases espectrales.

La Figura 4.8 muestra los resultados de las clasificaciones de la imagen original y las imágenes fusionadas por las diferentes metodologías analizadas. La visualización simple de los mapas sugiere que la distribución espacial de las clases espectrales varía notablemente dependiendo del método de fusión utilizado. En la clasificación de la imagen original se pudieron distinguir seis clases: las clases 1 y 2 corresponden con áreas de vegetación densas (cultivos en regadío y zonas de vegetación natural, respectivamente); el resto de las clases corresponden a áreas de alta reflectividad sin vegetación o donde la vegetación es escasa: zonas urbanas (representadas por la clase 3 principalmente), suelos desnudos (clase 6), cultivos en secano y olivares (clases 4 y 5).

La exactitud cartográfica se evaluó mediante el cálculo de la matriz de confusión y los estadísticos kappa (Congalton, 1991; Congalton y Green, 2009). Los valores del

índice kappa para los métodos L1COR, DCK y WAT fueron similares, con valores de kappa iguales a 0,78, 0,76, y 0,73, respectivamente. En el caso de la imagen fusionada mediante MDMR, el índice kappa resultó ser mucho más bajo (0,44), lo cual quiere decir que más de la mitad de los píxeles fueron erróneamente clasificados, (tomada como referencia la clasificación de la imagen original).

Del mismo modo, se calcularon los estadísticos kappa por categorías (Tabla 4.4). Las clases correspondientes a píxeles de mayor reflectividad (clases 3 a 6) fueron las que presentaron los valores de kappa más bajos para las clasificaciones de las imágenes fusionadas L1COR, DCK y MDMR. Para estos métodos, la clase 3 (áreas urbanas) y la 4 y 5 (cultivos en secano y olivares) fueron las que presentaron una correspondencia menor con la clasificación de la imagen original. En el caso de la clasificación de la imagen fusionada por MDMR, no fue posible diferenciar entre clases de vegetación vigorosa, por lo que las clases 1 y 2 aparecen agrupadas en una única clase (clase 1).




Figura 4.8. Mapas derivados de las clasificaciones de la imagen original y de las imágenes fusionadas por L1COR, DCK, WAT y MDMR (de arriba abajo y de izquierda a derecha).

Tabla 4.4. Valores del estadístico kappa por categorías derivados de las clasificaciones ISODATA de las imágenes fusionadas.

Class Id.	1	2	3	4	5	6
L1COR	0,79	0,81	0,75	0,75	0,76	0,85
DCK	0,81	0,78	0,73	0,72	0,75	0,85
WAT	0,76	0,76	0,7	0,69	0,71	0,82
MDMR	0,35	0,18	0,32	0,44	0,56	0,69

## 5 Conclusiones

En este capítulo se han comparado métodos con bases conceptuales diferentes para la fusión de las bandas multispectrales y pancromática del sensor Landsat 7 ETM+. Este análisis se ha llevado a cabo desde diferentes perspectivas. Por una parte, se ha evaluado cualitativamente la calidad visual de las imágenes fusionadas. Por otra, se ha llevado a cabo una evaluación cuantitativa de la calidad espacial y espectral, la coherencia y la exactitud cartográfica de las imágenes derivadas de los diferentes procedimientos de fusión.

La evaluación de la calidad global de las imágenes fusionadas ha demostrado que el algoritmo geoestadístico (DCK) y el algoritmo Bayesiano (L1COR), dan lugar a imágenes fusionadas de mayor calidad que los métodos wavelet comparados en este estudio (WAT y MDMR). Estos métodos wavelet consiguieron realzar mejor el detalle espacial de ciertas zonas que presentaban un patrón espacial específico, como el patrón reticulado de las áreas urbanas. Sin embargo, introdujeron distorsiones importantes en el color de otras zonas más homogéneas, como las áreas de vegetación natural o los campos de cultivos, que aparecieron borrosos.

Los resultados de los parámetros e índices: C, RMSE, ERGAS, Q y SSIM, han mostrado que el método DCK, es el algoritmo que mejor preserva la información multispectral de la imagen de referencia. Los métodos wavelet han sido los que más eficientemente han incrementado la resolución espacial de las imágenes (como así lo indicaron las correlaciones con las componentes de altas frecuencias). Finalmente,



desde el punto de vista del análisis conjunto de los índices espectrales y espaciales, el método DCK ha sido el que ha obtenido resultados más equilibrados.

DCK también ha sido el método más coherente de los analizados en este estudio, puesto que no introdujo artefactos en la estimación de los niveles digitales de las imágenes fusionadas. Este hecho se constató en que las imágenes fusionadas por DCK, una vez han sido degradadas a la resolución espacial de la imagen de partida, son prácticamente idénticas a ésta. Sin embargo también hay que considerar que este método es computacionalmente complejo, ya que requiere el análisis variográfico y el ajuste de modelos de variogramas simples y cruzados.

En términos de la exactitud cartográfica de las clasificaciones realizadas por el clasificador denominado ISODATA, los métodos de fusión de los cuales se derivaron imágenes clasificadas de forma más correcta fueron LICOR y DCK. El algoritmo MDMR ha dado lugar a clasificaciones que no son aceptables desde el punto de vista de su exactitud.

En resumen, se puede concluir que DCK y LICOR producen imágenes fusionadas de calidad óptima, con una mayor resolución espacial, a la vez que mantienen el contenido espectral de las imágenes multiespectrales de partida. En este sentido, DCK sobresale, puesto que la coherencia entre la imagen estimada y la real es prácticamente perfecta. En cualquier caso, el uso de un método u otro vendrá determinada por las necesidades de la aplicación en cuestión que se pretenda llevar a cabo.

## CAPÍTULO 5.

# Mejora de la Resolución Espacial de la Información Térmica para la Obtención de Mapas de Temperatura

### **1 Introducción**

Existen numerosas aplicaciones que utilizan como fuente de información imágenes del infrarrojo térmico (TIR, Thermal Infrared) de resolución espacial media, como por ejemplo: el seguimiento de la actividad volcánica (Pieri y Abrams, 2005; Vaughan et al., 2010), la detección de la temperatura superficial del mar y la salinidad (Zhang et al., 2004a), los estudios climatológicos (Arnfield, 2003), la estimación de la evapotranspiración (Allen et al., 2007; Hong et al., 2009; Tang et al., 2009), los estudios de ecología del paisaje (Quattrochi y Luvall, 1999), la predicción de terremotos (Lü et al., 2000) y el seguimiento de áreas y procesos urbanos (Gamba et al., 2005; Voogt y Oke, 2003), entre otras.

Para muchas de las aplicaciones mencionadas, la resolución espacial y/o temporal de las imágenes térmicas de los satélites actualmente operativos no es suficiente. Existe una necesidad emergente de mejorar la resolución espacial de las

imágenes térmicas, mediante el desarrollo de metodologías que permitan aumentar su resolución. Para ello, es posible incorporar información con mayor resolución espacial de otras regiones del espectro (visible, infrarrojo cercano, infrarrojo medio), a partir de imágenes del mismo u otro sensor (Agam et al., 2007; Gowda et al., 2007; Nichol y Wong, 2005; Stathopoulou y Cartalis, 2009; Tang et al., 2009).

Las imágenes térmicas miden la radiación emitida por la superficie terrestre en un rango de 8 a 15  $\mu\text{m}$ , para el cual la cantidad de energía reflejada es casi inexistente. La energía emitida por la tierra está relacionada con la temperatura de superficie (LST, *Land Surface Temperature*) y la emisividad de los objetos o las cubiertas del terreno (LSE, del inglés *Land Surface Emissivity*). El contenido energético de estas longitudes de onda es inferior al del resto de bandas espectrales, que incluyen los sensores de teledetección, lo cual implica que los sensores satelitales tengan normalmente peor resolución en el térmico (Tabla 5.1). Por ejemplo, el sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) proporciona imágenes TIR con tamaño de pixel de 1000 m (en nadir), mientras que para el resto de bandas su resolución espacial es de 250 m. Las imágenes TIR del sensor ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) tienen una resolución media igual a 90 m, con 15 metros en las bandas visibles (VIS) e infrarrojas (IR). Sin embargo, ASTER, solo está disponible bajo demanda, por lo que no pueden usarse en estudios que requieran una continuidad temporal y/o tengan una naturaleza retrospectiva. Por tanto, si la aplicación deseada requiere de imágenes TIR de resolución media, continuas en el tiempo y con una cobertura global, sólo es posible utilizar imágenes del satélite Landsat. En el caso de Landsat ETM+ (*Enhanced Thematic Mapper Plus*) la banda TIR (o banda 6, 10.4-12.5  $\mu\text{m}$ ) tiene una resolución de 60 m, mientras que el resto de bandas multiespectrales ( 1, 2, 3, 4, 5 y 7; 0,45-0,52, 0,53-0,61, 0,63-0,69, 0,78-0,90, 1,55-1,75 y 2,09-2,35  $\mu\text{m}$ , respectivamente) tienen una resolución igual a 30 metros y una banda pancromática (o banda 8; 0,52-0,90  $\mu\text{m}$ ) con 15 m de resolución espacial (Goward et al., 2001).

Tabla 5.1. Características técnicas de sensores con diferente resolución espacial en el visible e infrarrojo cercano (VNIR) y el infrarrojo térmico (TIR).

Plataforma/Sensor	Resolución espacial VNIR (m)	Resolución espacial TIR (m)	Resolución temporal
Terra/MODIS	250-500	1000	1-2 días
Terra/ASTER	15	90	16 días
Landsat5/TM	30	120	16 días
Landsat7/ETM+	30	60	16 días

Por tanto, dentro del campo del procesado de imágenes de teledetección, un objetivo lógico es el desarrollo de metodologías de fusión de imágenes TIR Landsat 7 ETM+, que permitan mejorar su resolución espacial, a la vez que preserven la coherencia o integridad de su contenido espectral. De esta forma, la imagen TIR proporcionará una descripción de la variabilidad espacial de la temperatura de los objetos del terreno (Ranchin et al., 2003; Stathopoulou y Cartalis, 2009; Wald et al., 1997).

Con el fin de obtener imágenes fusionadas de mayor resolución espacial se han propuesto diversas metodologías (Agam et al., 2007; Gowda et al., 2007; Nichol y Wong, 2005; Pardo-Iguzquiza et al., 2006; Pardo-Iguzquiza et al., 2011; Stathopoulou y Cartalis, 2009; Tang et al., 2009). De entre todas ellas, en este estudio se ha considerado la aplicación de un método geoestadístico multivariante basado en Cokrigeaje, que fue propuesto por Pardo-Igúzquiza et al. (2006; 2011) y que ha sido descrito con anterioridad en el Capítulo 4.

El coeficiente de correlación entre la banda TIR y el resto de bandas espectrales es muy bajo, comparado con las correlaciones entre dichas bandas (Drury, 1987). Sin embargo, existe un patrón de variabilidad conjunta entre la banda TIR y el resto de bandas multiespectrales, que puede ser demostrado en términos de covarianzas cruzadas o variogramas cruzados. Este hecho hace que el Cokrigeaje sea una técnica adecuada para incorporar el detalle espacial de las bandas con mayor resolución espacial. Además, el Cokrigeaje posee otras ventajas añadidas, como son la consideración explícita del tamaño de pixel (efecto de soporte en el argot geoestadístico), así como la función de respuesta espectral del sensor. Por último y no menos importante, cabe señalar que este método tiene la propiedad de ser coherente

(Wald et al., 1997), lo cual implica que si la imagen de alta resolución espacial obtenida por cokrigeaje es degradada mediante la función de respuesta espectral del sensor, la imagen resultante es idéntica a la imagen experimental adquirida por el sensor. En el caso del aumento de resolución de la variable LST, esta propiedad es de gran importancia, puesto que se ha demostrado que para áreas planas y heterogéneas, la temperatura superficial a menor escala puede ser expresada como un promedio de las temperaturas a escalas mayores (Liu et al., 2006; Stathopoulou y Cartalis, 2009).

El efecto de soporte (cambio en el tamaño de pixel) se denomina *upsampling* o *downsampling*, en función de si el tamaño de pixel aumenta o disminuye. Este estudio se ha centrado en *downsampling*, lo cual implica que la imagen resultante debe mostrar una mayor variabilidad espacial que la imagen con mayor tamaño de pixel, tanto en térmicos espaciales como radiométricos.

Puesto que en el capítulo anterior se han comparado diferentes metodologías de fusión. El objetivo de este capítulo no es realizar una comparación de métodos de aumento de resolución de la información térmica, sino mostrar los resultados de una aplicación basada en Cokrigeaje, para la obtención de imágenes LST de mayor resolución (30m) a partir de imágenes Landsat 7 ETM+. De esta forma, se pretende contribuir a un uso mayor de esta variable (LST) en aplicaciones medioambientales, que necesiten de una mayor resolución espacial. Cabe mencionar que esta metodología es aplicable a todos los sensores mostrados en la Tabla 5.1.

## **2 Fundamentos**

### **2.1 Fundamentos del aumento de resolución de la banda térmica TIR**

Aunque el método de Cokrigeaje ya ha sido expuesto de forma resumida en el Sección 2.3 del Capítulo 4. En esta Sección se realiza una exposición más detallada de *Downsampling Cokriging* aplicado al aumento de resolución de la banda térmica. La

imagen fusionada de alta resolución espacial obtenida mediante el método geoestadístico DCK, puede expresarse como una combinación lineal de diferentes bandas del sensor ETM+:

$$\hat{Z}_{u_0}^{k_0}(\mathbf{x}_0) = \sum_{j=1}^M \sum_{i=1}^{n_j} \lambda_{ji}^0 Z_{u_j}^{k_j}(\mathbf{x}_i) \quad (5.1)$$

Donde  $Z$  representa el nivel digital de una imagen de satélite, modelada como una variable aleatoria en una localización espacial particular  $\mathbf{x}_0$ ; y como una función aleatoria, cuando se consideran todas las localizaciones del espacio  $\mathbf{x} \in \mathfrak{R}^2$ . El superíndice de  $Z$  indica la banda espectral. Por ejemplo,  $k_0$  igual a 6 para la banda TIR. El subíndice de  $Z$  indica el tamaño de píxel o soporte geoestadístico. Por ejemplo  $u_0=30$  m. El símbolo circunflejo indica que la imagen ha sido estimada por Cokrigeaje.  $M$  es el número de bandas experimentales usadas en el Cokrigeaje, por ejemplo, se podrían usar únicamente dos bandas (la banda TIR y la banda ETM7), o 4 (las bandas TIR, ETM5, ETM6, ETM8) o cualquier otra combinación siempre y cuando se incluya la banda cuya resolución se desea mejorar (TIR). Para cada imagen  $\{j=1, \dots, M\}$ ,  $n_j$  representa el número de píxeles vecinos usados en Cokrigeaje. Normalmente, este número adopta valores de vecindad iguales a 3x3, 5x5 o 7x7 píxeles.  $Z_{u_j}^{k_j}(\mathbf{x})$ : imágenes experimentales para las bandas espectrales  $\{k_j, j=1, \dots, M\}$  con resolución espacial  $\{u_j, j=1, \dots, M\}$ .  $\lambda_{ji}^0$ : pesos óptimos aplicados a  $Z_{u_j}^{k_j}(\mathbf{x}_i)$  para la estimación de  $Z_{u_0}^{k_0}(\mathbf{x}_0)$ . Estos pesos óptimos se obtienen a partir de la resolución de un sistema lineal de ecuaciones, conocido como sistema de cokrigeaje. Dicho sistema se resuelve bajo la condición impuesta de que el estimador sea insesgado y de que se minimice la varianza de estimación.

El sistema de cokrigeaje se representa en forma matricial como sigue:

$$\begin{bmatrix} \mathbf{C}_{u_1 u_1}^{k_1 k_1} & \dots & \mathbf{C}_{u_1 u_M}^{k_1 k_M} & \mathbf{1} & \dots & \mathbf{0} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{C}_{u_M u_1}^{k_M k_1} & \dots & \mathbf{C}_{u_M u_M}^{k_M k_M} & \mathbf{0} & \dots & \mathbf{1} \\ \mathbf{1} & \dots & \mathbf{0} & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \dots & \mathbf{1} & 0 & \dots & 0 \end{bmatrix} \begin{bmatrix} \lambda_1^0 \\ \vdots \\ \lambda_M^0 \\ \mu_1 \\ \vdots \\ \mu_M \end{bmatrix} = \begin{bmatrix} \mathbf{C}_{u_0 u_1}^{k_0 k_1} \\ \vdots \\ \mathbf{C}_{u_0 u_M}^{k_0 k_M} \\ 1 \\ \vdots \\ 0 \end{bmatrix} \quad (5.2)$$

donde:

$\mathbf{C}_{u_i u_j}^{k_i k_j}$ : matriz  $(n_i \times n_j)$  de la varianza cruzada entre los píxeles  $n_i$  de una banda espectral  $k_i$  con una resolución espectral  $u_i$  y los píxeles  $n_j$  de una banda espectral  $k_j$  de resolución espectral  $u_j$ . Cabe destacar que la covarianza directa es equivalente a la covarianza cruzada de una imagen con respecto a si misma. Esta matriz también podría expresarse en términos de semivariogramas y semivariogramas cruzados. En condiciones estacionarias de segundo orden, se cumple la relación  $C(h) = C(0) - \gamma(h)$ ; es decir, la covarianza es igual a la varianza (covarianza en el origen) menos el semivariograma. Para clarificar algunas ideas relacionadas con la resolución de este sistema, se indica más abajo una ejemplificación de su aplicación al aumento de resolución de la banda TIR del sensor ETM+:

$k_0$ : es la banda térmica (10,40 a 12,5  $\mu\text{m}$ )

$u_0$ : pixel de 30 m de lado

Bandas usadas en la predicción ( $M=4$ ):

$k_1$ : banda térmica (TIR)

$u_1$ : pixel de 60 m de lado

$k_2$ : banda del infrarrojo medio (ETM7)

$u_2$ : pixel de 30 m de lado

Por otro lado, cabe destacar que:

$\mathbf{C}_{u_0 u_1}^{k_0 k_1}$  : es la matriz de covarianza cruzada entre la banda TIR experimental y la imagen de alta resolución que se pretende calcular (TIR AR), con resoluciones espaciales iguales a 60 y 30 m, respectivamente.

$\mathbf{C}_{u_0 u_2}^{k_0 k_2}$  : es la matriz de covarianza cruzada entre la banda experimental ETM7 y la (TIR AR), con resoluciones espaciales iguales a 30 m.

Todas estas covarianzas cruzadas no son accesibles experimentalmente, ya que la imagen TIR de resolución 30 m no existe *a priori*. Sin embargo, teóricamente es posible su estimación a partir de las imágenes experimentales, mediante la aplicación de la teoría de sistemas lineales, como se describe en el trabajo de Pardo-Igúzquiza et al. (2006).

En teledetección se asume que para una banda dada del espectro, el valor de un pixel mide la radiancia correspondiente a la superficie del suelo que ocupa, la cual es un promedio de la radiancia de los puntos contenidos en dicho pixel. Por tanto:

$$Z_u^k(\mathbf{x}) = \frac{1}{|u(\mathbf{x})|} \int_{u(\mathbf{x})} Z_\bullet^k(\mathbf{y}) d\mathbf{y} \quad (5.3)$$

$$Z_v^k(\mathbf{x}) = \frac{1}{|V(\mathbf{x})|} \int_{V(\mathbf{x})} Z_\bullet^k(\mathbf{y}) d\mathbf{y} \quad (5.4)$$

Donde  $Z_\bullet^k(\mathbf{y})$  es una función aleatoria de la banda  $k$  de resolución espacial puntual ( $\bullet \ll u < V$ ), es decir un píxel de tamaño infinitesimal.

El proceso descrito en las ecuaciones (5.3) y (5.4) se conoce en la teoría de sistemas lineales como integración o promediado, mientras que en geoestadística como regularización. Este proceso de integración puede interpretarse como un sistema lineal donde la entrada es una función aleatoria puntual y la salida es un valor promediado o filtrado, que puede ser descrito como la convolución (en dos dimensiones) entre la función aleatoria puntual y una función determinística conocida como la función de respuesta espectral del sensor:



$$C_{VV}^{66}(\mathbf{s}) = C_{\bullet\bullet}^{66}(\mathbf{s}) * h_V(\mathbf{s}) * h_V(-\mathbf{s}) \quad (5.5)$$

Donde \* es el operador de convolución,  $C_{VV}^{66}(\mathbf{s})$  es la covarianza estacionaria de un vector de distancia  $\mathbf{s}$  para la banda TIR (ETM6) y un pixel cuyo tamaño es 60 m (V). Esta covarianza puede ser estimada a partir de la imagen TIR y está representada por la expresión:  $\hat{C}_{VV}^{66}(\mathbf{s})$ .  $C_{\bullet\bullet}^{66}(\mathbf{s})$  es la covarianza estacionaria de la banda TIR, pero para un tamaño de pixel infinitesimal (soporte puntual). Esta covarianza es desconocida, aunque puede ser estimada como se explica más abajo. Por último,  $h_V(\mathbf{s})$  es la función de respuesta espectral del sensor. Existen diferentes filtros que pueden ser aplicados como aproximación a esta función. Una aproximación simple, aunque para muchas aplicaciones suficiente, a la respuesta espectral del sensor ETM+, viene dada por:

$$h_V(\mathbf{s}) = \begin{cases} \frac{1}{V} & \text{si } \mathbf{s} \in V \\ 0 & \text{si no} \end{cases} \quad (5.6)$$

O una aproximación más realista vendría dada por la función de respuesta Gaussiana:

$$h_V(\mathbf{s}) = \begin{cases} \frac{1}{2\pi\sigma_x\sigma_y} \exp\left\{-\frac{1}{2}\left[\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right]\right\} & \text{si } \mathbf{s} = \{x, y\} \in V' \\ 0 & \text{si no} \end{cases} \quad (5.7)$$

Donde  $V \subseteq V'$  y  $\sigma_x, \sigma_y$  son las desviaciones estándar a lo largo de los ejes x e y, respectivamente, que definen el ancho de la función de respuesta espectral Gaussiana.

El propósito de la Ecuación (5.5) es estimar  $C_{\bullet\bullet}^{66}(\mathbf{s})$  usando un procedimiento de deconvolución numérica. Este método consiste en proponer modelos de  $C_{\bullet\bullet}^{66}(\mathbf{s})$  que, al ser insertados en la Ecuación (5.5), producen un modelo inducido  $\tilde{C}_{VV}^{66}(\mathbf{s})$ . Este

modelo inducido puede ser comparado con la covarianza experimental real  $\hat{C}_{VV}^{66}(\mathbf{s})$  mediante un criterio de ajuste:

$$\Psi = \sum_{j=1}^m \sum_{i=1}^{K_m} w_i [\hat{C}_{VV}^{66}(s_{ji}) - \tilde{C}_{VV}^{66}(s_{ji})]^2 \quad (5.8)$$

Donde  $m$  es el número de direcciones geográficas para las cuales la covarianza o (semivariograma) es estimada;  $k_m$  número de pasos para los que la covarianza (o variograma) es estimada;  $w_i$  pesos aplicados a la covarianza para, si se desea, dar más importancia a un cierto paso, aunque en general  $w_i$  es igual a 1.

El modelo de  $C_{\bullet\bullet}^{66}(\mathbf{s})$  que minimiza la Ecuación (5.8) se adopta como modelo estimado. Entonces, la covarianza buscada se calcula mediante el uso de este modelo estimado y un procedimiento de convolución numérica:

$$C_{uV}^{66}(\mathbf{s}) = C_{\bullet\bullet}^{66}(\mathbf{s}) * h_u(\mathbf{s}) * h_V(-\mathbf{s}) \quad (5.9)$$

Donde  $u$  es el tamaño de pixel de la imagen de alta resolución (30m);  $V$  es el tamaño de pixel de la imagen experimental (60m);  $h_u(\mathbf{s})$  es una función de respuesta espectral similar a la dada en la Ecuación (5.7), pero sustituyendo  $V$  por  $u$ .  $C_{uV}^{66}(s_{ij})$  es el elemento de fila  $i$ -ésima y columna  $j$ -ésima de la matriz  $C_{uV}^{66}$ . El resto de covarianzas necesarias se pueden calcular aplicando el mismo procedimiento como se muestra en Pardo-Igúzquiza et al. (2006)

## 2.2 Fundamentos del cálculo de la Temperatura de Superficie (LST)

El procedimiento más adecuado para la obtención de LST, a partir de una única banda, es la inversión de la ecuación de transferencia radiativa dada por la siguiente ecuación:

$$L_{sensor,\lambda} = \left[ \varepsilon_\lambda B_\lambda(T_s) + (1 - \varepsilon_\lambda) L_{atm,\lambda}^\downarrow \right] \tau_\lambda + L_{atm,\lambda}^\uparrow \quad (5.10)$$

Donde  $L_{\text{sensor}}$  es la radiancia medida por el sensor o radiancia en el techo de la atmósfera (TOA; del inglés *Top of Atmosphere*);  $\varepsilon$  es la emisividad en superficie;  $B(T_s)$  es la radiancia de un cuerpo negro de acuerdo a la ley de Planck;  $T_s$  es la temperatura de superficie (LST);  $L_{\downarrow\text{atm}}$  es la radiancia atmosférica descendente;  $\tau$  es la transmisividad atmosférica total entre la superficie y el sensor;  $L_{\uparrow\text{atm}}$  es la radiancia atmosférica ascendente y  $\lambda$  es la longitud de onda. Cabe destacar que la Ecuación (5.10) depende de la longitud de onda considerada, pero también del ángulo de observación, en el caso de Landsat, nadir (Jimenez-Munoz et al., 2009; Sobrino et al., 2006).

Como puede deducirse a partir de la Ecuación (5.10), es necesario calcular la emisividad antes de poder obtener la LST. Existen varias metodologías para el cálculo de LSE (Sobrino y Raissouni, 2000; Valor y Caselles, 1996; Van De Griend y Owe, 1993). En el caso de Landsat, la emisividad de superficie se puede obtener mediante el método de umbrales de NDVI (del inglés *Normalized Difference Vegetation Index*) (Sobrino et al., 2004; Sobrino et al., 2008). Este método considera diferentes casos:

$$\varepsilon_{\lambda} = \begin{cases} a_{\lambda} + b_{\lambda} \rho_{\text{rojo}}, & NDVI < NDVI_s \\ \varepsilon_v P_v + \varepsilon_s (1 - P_v) + C_{\lambda}, & NDVI_s \leq NDVI \leq NDVI_v \\ \varepsilon_v + C_{\lambda}, & NDVI > NDVI_v \end{cases} \quad (5.11)$$

Donde  $\varepsilon_v$  y  $\varepsilon_s$  son la emisividad de la vegetación y los suelos, respectivamente, y  $P_v$  es la proporción de vegetación obtenida de acuerdo con la siguiente expresión (Carlson y Ripley, 1997):

$$P_v = \left[ \frac{(NDVI - NDVI_{\min})}{(NDVI_{\max} - NDVI_{\min})} \right]^2 \quad (5.12)$$

La inversión de la ecuación de transferencia radiativa también requiere conocer los parámetros  $\tau$ ,  $L_{\downarrow\text{atm}}$  y  $L_{\uparrow\text{atm}}$ , lo cual no es siempre posible. Para resolver este problema, éstos parámetros pueden ser calculados mediante el uso de códigos de transferencia radiativa como MODTRAN (Berk et al., 1998) y a partir de variables

como la temperatura ambiente, presión, contenido en vapor de agua, etc., que pueden ser obtenidas a partir de radio sondeos *in situ* o modelos de perfiles atmosféricos.

La temperatura de superficie ( $T_s$ ) se puede obtener finalmente mediante la inversión de la ley de Planck de acuerdo con la siguiente expresión:

$$B_\lambda(T) = c_1 / \lambda^5 \exp(c_2 / \lambda T_s) - 1 \quad (5.13)$$

Siendo  $c_1$  y  $c_2$  las constantes de Planck, con valores iguales a  $1,19104 \cdot 10^8 \text{ W} \cdot \mu\text{m}^4 \cdot \text{m}^{-2} \cdot \text{sr}^{-1}$  y  $14387,7 \mu\text{m} \cdot \text{K}$ , respectivamente. En la expresión previa,  $\lambda$  es la longitud de onda efectiva del sensor, que se define como la función de respuesta espectral del sensor para un canal determinado. La Figura 5.1 muestra las funciones de respuesta espectral y la longitud de onda efectiva para las bandas TIR de los sensores TM y ETM+. Para una mayor profundización en la obtención de LST a partir de bandas térmicas de la serie Landsat se pueden consultar los trabajos de Li et al. (2004) y Jiménez Muñoz et al. (2009).




Figura 5.1. Función de respuesta espectral de la banda TIR de Landsat 5 y 7.

### 3 Área de estudio y datos

El objetivo de este estudio ha sido la aplicación de una metodología basada en el método *Downscaling Cokriging* (DCK) para obtener imágenes LST de alta resolución (30m), a partir de las bandas del satélite Landsat 7. Con este objetivo, se seleccionó un sector de 1024x1024 píxeles (tamaño de pixel de 30m), a partir de una imagen del 20 de Julio de 2002. El área de estudio coincide con la comarca de la “Vega de Granada”, situada en el centro de la Provincia de Granada, al sur de España. Las coordenadas de las esquinas de este sector están comprendidas entre las latitudes 37.36° y 37.04° N, y longitudes 3.84 N y 3.56 W. Esta área de estudio coincide morfológicamente con un acuífero detrítico de importancia regional, atravesado longitudinalmente por el río Genil. La relativa abundancia de recursos hídricos, junto con las buenas aptitudes agronómicas del suelo, hacen que la agricultura sea el uso del suelo mayoritario de esta área, que compite con los usos urbanos, especialmente en las zonas cercanas al área metropolitana de Granada.

### 4 Metodología

La Figura 5.2 muestra un esquema de la metodología general seguida en este caso de estudio, en el que se pretende la obtención de imágenes LST con resolución mejorada a partir de imágenes TIR con resolución más grosera. La imagen TIR estimada por Cokrigeaje,  $\hat{Z}_{u_0}^{k_0}$ , es calculada a partir de las imágenes experimentales  $Z_{u_j}^{k_j}$ , donde  $\lambda_{ji}^0$  son los pesos obtenidos por el sistema de Cokrigeaje. Para resolver el sistema de Cokrigeaje es necesario calcular la covarianza estacionaria  $C_{uV}^{66}(\mathbf{s})$ , mediante deconvolución numérica, a partir de la covarianza conocida empíricamente  $C_{VV}^{66}(\mathbf{s})$ . Este último procedimiento requiere la aplicación de diferentes convoluciones, el conocimiento de la función de respuesta espectral  $h_u(\mathbf{s})$  y  $h_v(-\mathbf{s})$ , y la covarianza determinísticamente conocida

$\rho V(s) = hV(s) * hV(-s)$ , siendo  $*$  el operador de convolución. Para una mejor descripción del método *Downscaling Cokriging* se puede consultar la Sección 2.3 del capítulo 4 y los trabajos de Pardo Igúzquiza et al. (2006; 2011) y Atkinson et al. (2008b). Aceptar  $C_{VV}^{66}(s)$  implica aceptar el modelo  $C_{\bullet\bullet}^{66}(s)$ . La imagen LST de alta resolución ( $T_s$ ) se calcula mediante la inversión de la ecuación de transferencia radiativa, una vez conocida la emisividad de superficie ( $\epsilon$ ). Su cálculo requiere la aplicación del método de umbrales de índices de vegetación normalizados (NDVI), el conocimiento de la transmisividad atmosférica entre la superficie y el sensor ( $\tau$ ) y las radiancias atmosféricas descendentes y ascendentes,  $L_{\downarrow\text{atm}}$  and  $L_{\uparrow\text{atm}}$ . Estos últimos parámetros son obtenidos a partir de la calculadora de parámetros atmosféricos de corrección (CPAC), usando parámetros meteorológicos medidos en el área de estudio (Sección 2.2).

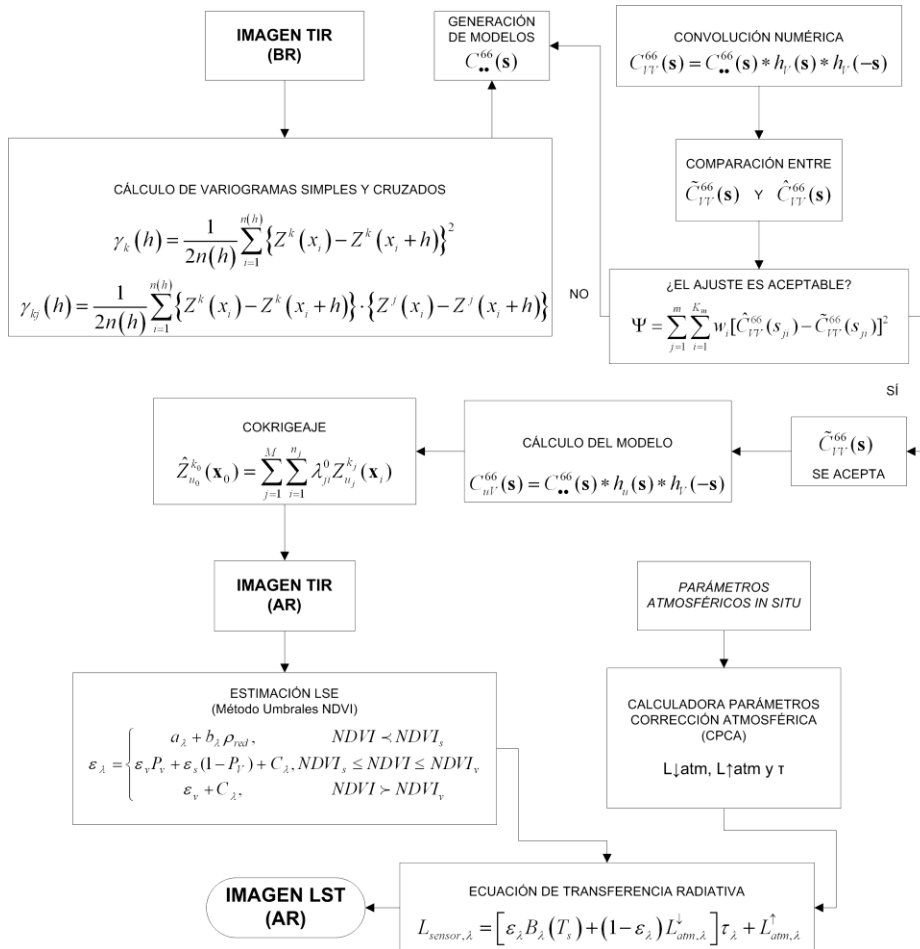


Figura 5.2. Esquema de la metodología seguida para la obtención de las imágenes de LST de alta resolución (AR).

## 5 Resultados y Discusión

### 5.1 Downscaling de la información TIR

Aunque en principio todas las bandas del sensor ETM+ pueden ser usadas en el Cokrigeaje, al igual que ocurre en regresión múltiple, incrementar el número de

variables predictoras no necesariamente implica una mejora en la predicción. Esto, en nuestro caso, puede ser debido a que un predictor tiene una correlación muy pequeña con la variable, o a que dos predictores están muy correlacionados entre sí y, por tanto, la información que aportan es redundante. Teniendo en cuenta estas consideraciones, la banda ETM1 no se usó en el realce de la banda TIR (o ETM6), debido a la baja correlación entre el azul visible y el infrarrojo térmico. Por otro lado, las bandas ETM2 y ETM3, también se descartaron del análisis, ya que la información espectral que contienen es redundante con respecto a la información de la banda pancromática (ETM8, que además tiene mejor resolución espacial). Por tanto, se pueden considerar tres posibilidades en la predicción de la imagen TIR de alta resolución: usar la banda pancromática o las bandas ETM5 o ETM7, correspondientes al infrarrojo medio. Entre estas posibilidades, se seleccionó la banda ETM 7, ya que presenta un coeficiente de correlación con la banda térmica mayor.

Tabla 5.2. Coeficientes de correlación entre los canales espectrales de la imagen Landsat 7 ETM+.

	ETM1	ETM2	ETM3	ETM4	ETM5	ETM6	ETM7	ETM8
ETM1	1	0,978	0,930	0,628	0,812	0,594	0,843	0,865
ETM2		1,000	0,973	0,691	0,863	0,630	0,878	0,915
ETM3			1,000	0,685	0,911	0,696	0,913	0,914
ETM4				1,000	0,705	0,330	0,622	0,877
ETM5					1,000	0,708	0,961	0,880
ETM6						1,000	0,723	0,555
ETM7							1,000	0,844
ETM8								1,000

Los variogramas experimentales de la banda TIR y la banda ETM7 se muestran en la Figura 5.3 (a) y (b). La Figura 5.3(c) representa el variograma cruzado entre la banda TIR y la ETM7.



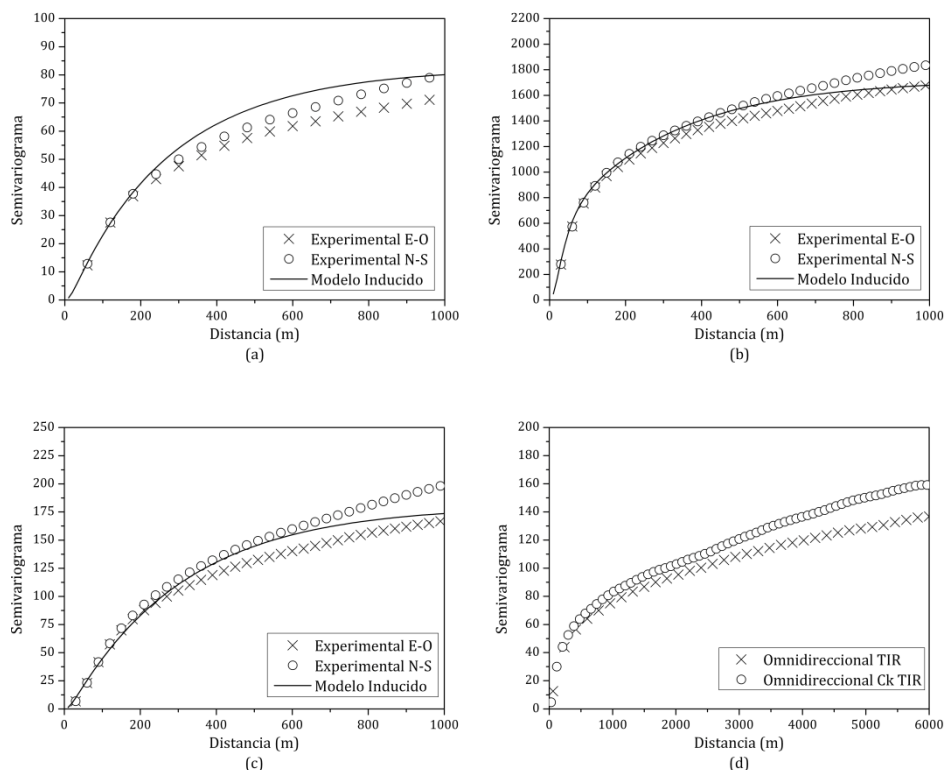


Figura 5.3. Variogramas de las variables implicadas en el Cokrigeaje de la banda TIR (ETM6). A: semivariograma de la imagen TIR de resolución 60 m. B: semivariograma de la Banda ETM7 de resolución 30m. C: semivariograma cruzado entre las bandas TIR y ETM7. D: semivariogramas omnidireccionales de la banda TIR de resolución 60 m y la banda TIR de resolución espacial mejorada (30 m).

Los modelos de covarianza puntual y covarianza puntual cruzada (o semivariogramas puntuales y semivariogramas cruzados puntuales) se calcularon mediante la aplicación de los procedimientos de deconvolución y convolución (ecuaciones (5.5) a (5.9)). Se adoptó un modelo e correogionalización lineal (Wackernagel, 2003), en el que se utilizó la misma estructura de semivariograma cruzado para modelar cada variograma. Los variogramas experimentales se modelaron como variogramas con dos estructuras básicas anidadas. La primera

estructura fue exponencial, con un alcance de 30 m y 150 m para la banda ETM7 y la banda térmica, respectivamente (alcances prácticos de 90 y 450 m). La segunda estructura, fue una estructura común a todos los variogramas, con un alcance de 300 m (alcance práctico de 900 m). Como resultado de esta combinación de estructuras se obtuvieron los siguientes modelos de correogionalización:

$$\gamma_{\bullet\bullet}^{kl}(\mathbf{h}) = b_1^{kl} \text{Exp}(h; a_1, c_1, d_1) + b_2^{kl} \text{Exp}(h; a_2, c_2, d_2) \quad (5.14)$$

$\text{Exp}(h; a_i, c_i, d_i)$ : semivariograma exponencial (para  $k=l$ ) o semivariograma cruzado (para  $k \neq l$ ), siendo  $a_i$  el alcance,  $c_i$  el ángulo de anisotropía y  $d_i$  el ratio de anisotropía. Por tanto,  $a_i$  es el eje mayor de la elipse de anisotropía que forma un ángulo  $c_i$  con el eje x (medido en sentido horario). El eje menor es perpendicular al eje mayor y su longitud es igual a  $a_i / d_i$ . Si  $d_i$  es igual a 1, la estructura es isótropa.

$b_i^{kl}$  es el coeficiente de correogionalización lineal (meseta o varianza parcial) de la estructura  $i$ -ésima para el variograma entre las bandas  $k$  y  $l$ . El conjunto de estos coeficientes se muestran en la Tabla 5.3.

Tabla 5.3. Coeficientes de correogionalización lineal.

	$b_1$		$b_2$	
	TIR	ETM7	TIR	ETM7
TIR	15	0	73	190
ETM7	0	956	190	1191

Por ejemplo, el semivariograma cruzado puntual entre la banda TIR y la banda ETM7 sería igual a:

$$\gamma_{\bullet\bullet}^{67}(\mathbf{h}) = 190 \text{Exp}(\mathbf{h}; 300, 0^\circ, 1) \quad (5.15)$$

La covarianza  $\tilde{C}_{Vi}^{67}(\mathbf{s})$ , que junto con la covarianza experimental  $\hat{C}_{Vi}^{67}(\mathbf{s})$ , se representa en forma de semivariograma en la Figura 5.3(c), se obtuvo por

convolución del semivariograma cruzado, de forma similar a la Ecuación (5.5), usando la siguiente relación lineal:

$$C_{vu}^{67}(\mathbf{s}) = C_{\bullet\bullet}^{67}(\mathbf{s}) * h_v(\mathbf{s}) * h_u(-\mathbf{s}) \quad (5.16)$$

Los resultados de la covarianza  $\tilde{C}_{vu}^{67}(\mathbf{s})$  se representan junto con la covarianza experimental  $\hat{C}_{vu}^{67}(\mathbf{s})$  en forma de semivariograma en la Figura 5.3(b).

La imagen TIR de alta resolución espacial (tamaño de pixel igual a 30 m) obtenida mediante *Downscaling Cokriging* tuvo una coherencia perfecta, lo cual implica que, si la imagen resultado es degradada usando la misma función de respuesta espectral utilizada, se obtiene una nueva imagen de resolución espacial igual a 60 m, que es idéntica a la imagen TIR experimental.

Tabla 5.4. Estadísticos de la imagen TIR original y de la imagen TIR de resolución espacial mejorada mediante *Downscaling Cokriging*. ND: Número Digital.

Banda	Tamaño	Resolución	Med(ND)	Var(ND)	Min(DN)	Max(ND)
TIR	256 <sub>x</sub> 256	60 m	196,79	148,60	154	238
TIR (ck)	1024 <sub>x</sub> 1024	30 m	196,81	151,04	153	242

Idealmente, para evaluar la calidad de la imagen obtenida como resultado se debería disponer de una imagen TIR real como referencia, que además, tenga la misma resolución espacial. En la práctica esto no es posible, ya que, si se desea mejorar la resolución espacial de la imagen TIR es precisamente porque éstas tienen una resolución más grosera. En este estudio, para evaluar la calidad de la imagen obtenida, se calcularon diferentes estadísticos e índices entre la imagen cokrigada y la imagen TIR original: coeficientes de correlación, ERGAS (*Relative Dimensionless Global Error*) (Ranchin et al., 2003; Wald, 2000) y el índice Q (Wang y Bovik, 2002).

Como se ha expuesto con anterioridad en el capítulo anterior, los valores bajos de ERGAS y altos de los coeficientes de correlación y de Q son indicativos de una fusión satisfactoria. En un caso hipotético el mejor resultado posible del proceso de fusión produciría valores de ERGAS iguales a 0 y coeficientes de correlación y Q iguales a 1. Para el caso de la imagen TIR obtenida por *Downsacaling Cokriging* se obtuvieron valores de ERGAS y coeficientes de correlación y Q iguales a 0,22, y 0,99, respectivamente.

## 5.2 Obtención de la imagen LST de alta resolución

De forma previa a la obtención de emisividades y temperaturas, se llevó a cabo un proceso de corrección atmosférica consistente en la aplicación del método propuesto por Chávez (1996), ya que no se necesita de datos externos a los datos de satélite. La conversión a radiancias se efectuó utilizando los parámetros presentes en la cabecera de la imagen.

Para calcular la emisividad de superficie (LSE) se aplicó el método de umbrales de NDVI propuesto por Sobrino et al. (2004) (Sección 2.2 y Ecuación (5.11)). En este método, los valores de emisividad de superficie se calculan en función del valor del NDVI de cada píxel. Los píxeles con valores de NDVI menores de 0,2 ( $NDVI_s$ ) se consideraron como suelos desnudos, los valores entre 0,2 y 0,5 como píxeles mixtos (vegetación + suelos) y los mayores a 0,5 ( $NDVI_v$ ), como píxeles totalmente cubiertos por vegetación (Sobrino y Raissouni, 2000). En el cálculo de la emisividad de los píxeles correspondientes a suelo, se consideró la reflectividad de la banda roja (ETM3) y los parámetros a y b se fijaron en valores iguales a 0,979 y 0,04, respectivamente. Estos valores se obtuvieron a partir de la media de los espectros de suelo incluidos en la librería espectral de ASTER (<http://asterweb.jpl.nasa.gov>) y su adaptación a la respuesta espectral de la banda térmica de Landsat 7 ETM+. Para los píxeles considerados como completamente cubiertos por vegetación ( $P_v=1$  y  $NDVI > NDVI_v$ ), se tomaron valores de emisividad iguales a 0,99, deducidos de la constante  $\epsilon_v$  (0,985) y C (0,005). Para obtener valores coherentes de  $P_v$ , los píxeles con valores de  $NDVI < NDVI_s$ , se fijaron a 0 y los valores de  $NDVI > NDVI_v$  se

fijaron a valores iguales a 1 (Sobrino et al., 2008). La emisividad de los píxeles mixtos se calculó en función del porcentaje de vegetación ( $P_v$ ), la emisividad de la vegetación ( $\epsilon_v$ ) y la de los suelos de los suelos ( $\epsilon_s$ ). Aunque existen estimaciones directas de LSE disponibles para evaluar el cálculo de LSE llevado a cabo en este estudio, el estudio realizado por Sobrino et al. (2008) cuantificó el error entre la estimación y medidas directas de campo en un 1%.

La imagen LST se obtuvieron mediante la inversión de la ecuación de transferencia radiativa (Ecuación (5.10)). Los parámetros  $L_{\downarrow atm}$ ,  $L_{\uparrow atm}$  y  $\tau$  se obtuvieron a partir de la Calculadora de Parámetros Atmosféricos de Corrección (CPAC) desarrollada por Barsi et al. (2003; 2005) (<http://atmcorr.gsfc.nasa.gov>). Esta herramienta usa perfiles atmosféricos del *National Center for Environmental Prediction* (NCEP), interpolados para la localización del área de estudio, y la fecha y hora de la adquisición de las imágenes y usa el código de transferencia radiativa MODTRAN-4 (Berk et al., 1998). En este estudio también se introdujeron en la CPAC los parámetros atmosféricos *in situ* medidos en una estación meteorológica local, que fueron interpolados para la hora de adquisición de la imagen (10:39 GMT). De esta forma se obtuvieron valores de  $L_{\downarrow atm}$  and  $L_{\uparrow atm}$  iguales a 2,24 y 1,33  $W m^{-2} sr^{-1} \mu m^{-1}$ , respectivamente, and  $\tau$  iguales a 0,82. Los resultados del estudio realizado por Coll et al. (2010) estimaron el error del cálculo de LST de la CPAC en 1 K.

Esta metodología para la estimación de imágenes LST fue aplicada tanto a la imagen TIR de baja resolución (60 m) como a la imagen de resolución mejorada por *Downscaling Cokriging* (30 m). Por tanto, se obtuvieron imágenes LST de baja y alta resolución. La imagen LST de alta resolución se muestra en la Figura 5.4. Los colores más fríos (tonos azules) corresponden principalmente a áreas de vegetación densa: choperas, zonas en regadío y bosques densos de coníferas. Los valores de mayor temperatura (colores rojizos) se presentan en las zonas ocupadas por suelos desnudos, donde los recursos hídricos son escasos. Por último, las zonas de temperaturas intermedias son zonas de mezcla entre vegetación y suelos desnudos.

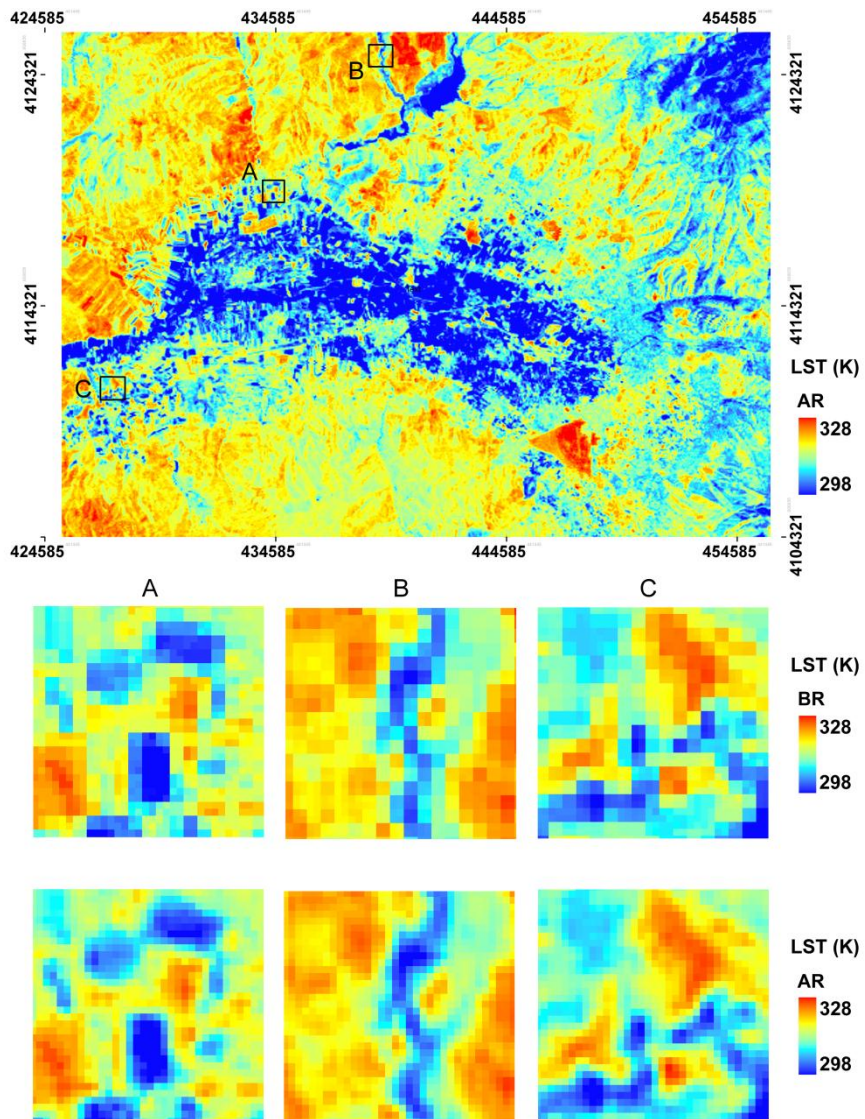


Figura 5.4. Imagen LST de resolución espacial igual a 30 m. Los colores cálidos y fríos representan las áreas de mayor y menor temperatura, respectivamente.

Para realizar una evaluación cualitativa de los resultados, se delinearon tres subsectores de la imagen correspondientes a contextos medioambientales diferentes: el subsector A está compuesto por parcelas de cultivos y suelos desnudos; el subsector B por un río que atraviesa la imagen de Norte a Sur y es flanqueado por vegetación de ribera, y por mezclas de suelos y arbustos; el subsector C está caracterizado por una variedad de cubiertas de vegetación naturales, coníferas densas, pastos y mezclas de suelo y vegetación. La imagen LST de alta resolución obtenida puede ser evaluada en términos de su calidad visual atendiendo a los subsectores de la Figura 5.4. La imagen LST obtenida por *Downscaling Cokriging* es idéntica a la imagen LST de baja resolución en cuanto a tono, contraste y saturación, lo cual prueba que no se introdujeron artefactos en la mejora de la resolución de la imagen TIR. Sin embargo, el método de Cokrigeaje consiguió un mejor detalle espacial y dio lugar a imágenes cuya resolución espacial fue mayor, lo cual puede apreciarse en los contornos de las estructuras presentes en las imágenes y los límites de las cubiertas, que aparecen resaltados.

Por otro lado, además de la evaluación visual anterior, también se llevó a cabo una evaluación estadística de la calidad de los resultados (Wald et al., 1997). La propiedad de coherencia del método *Downscaling Cokriging*, junto con el decrecimiento del tamaño de pixel, implican desde un punto de vista estadístico lo siguiente:

- La media se mantiene constante
- La varianza se incrementa
- El histograma tiene una forma similar pero con mayor varianza
- El semivariograma es menos continuo.

Tabla 5.5. Estadísticos de la imagen LST de resolución más grosera y de la imagen LST de resolución mejorada mediante *Downscaling Cokriging*. ND: Número Digital.

Banda	Tamaño	Resolución	Med(ND)	Var(ND)	Min(DN)	Max(ND)
LST	256x256	60 m	314,92	148,60	299,47	4,42
LST (ck)	1024x1024	30 m	314,92	151,04	298,82	4,45

Los primeros tres puntos se pueden corroborar a partir de la Tabla 5.5. Con respecto a la comparación entre semivariogramas, la Figura 5.3(d) muestra que la imagen cokrigada es menos continua, como podría esperarse desde un punto de vista teórico, y presenta una mayor variabilidad espacial que la imagen TIR bruta debido a un decrecimiento en el tamaño de pixel.

## 6 Conclusiones

En este capítulo se muestra una aplicación para el aumento de resolución de imágenes TIR Landsat 7 ETM+ para la obtención de imágenes LST de alta resolución mediante *Downscaling Cokriging* y la inversión de la ecuación de transferencia radiativa.

*Downscaling Cokriging* es un método geoestadístico que permite el incremento de la resolución espacial de imágenes mediante el uso de una banda experimental, cuya resolución se pretende aumentar, y otra banda de mayor resolución que contenga el detalle espacial. DCK usa la autocorrelación de las imágenes, así como las correlaciones cruzadas, de forma que solamente se incluye en la imagen fusionada el detalle espacial que es coherente con la correlación experimental. El proceso de aumento de resolución preserva la coherencia de la radiometría original de la imagen bruta (baja resolución), ya que el promedio de los valores subpíxeles de la imagen de alta resolución es igual al valor del pixel de la imagen original. Para este caso de estudio, se obtuvieron valores óptimos de los índices de calidad de las fusiones: coeficiente de correlación, ERGAS y Q iguales a 0,99, 0,22 y 0,99, respectivamente.



La imagen LST obtenida a partir de la imagen TIR cokrigada es acorde con todos los requerimientos estadísticos esperados del modelo adoptado. Además, las imágenes de alta resolución obtenidas tienen una coherencia perfecta, (ej. si la imagen de alta resolución es degradada a la resolución espacial inicial, ésta es idéntica a la imagen original). Desde el punto de vista de la calidad visual y cuantitativa de los resultados, la imagen LST de alta resolución puede considerarse como una mejora respecto a la imagen bruta inicial. La imagen LST de alta resolución mantiene las características radiométricas de la imagen original de baja resolución.

## CAPÍTULO 6.

# Aplicación de Medidas Texturales a la Clasificación de Imágenes de Satélite

### **1 Introducción**

La clasificación temática de áreas complejas con paisajes altamente fragmentados, como es el caso de las áreas mediterráneas, es particularmente difícil a partir de imágenes de satélite (Berberoglu et al., 2000; Lloyd et al., 2004). Sin embargo, esta complejidad de patrones de las cubiertas del suelo puede ser incorporada en el proceso de clasificación para incrementar su exactitud. Las imágenes de teledetección representan, mediante matrices regulares de píxeles, paisajes continuos formados por diferentes cubiertas del suelo. El tamaño del pixel es normalmente mucho más pequeño que los “parches” de las cubiertas del suelo que representan. En consecuencia, existen numerosos píxeles que codifican la radiancia de una misma cubierta y, por tanto, las imágenes llevan implícitos patrones de autocorrelación espacial (Stuckens et al., 2000). La autocorrelación espacial en las bandas espectrales de las imágenes de satélite ocurre a diferentes escalas espaciales, que dependen del tamaño y la forma de las cubiertas del suelo (Strahler et al., 1986; Woodcock y Strahler, 1987). Esta información multi-escala es recogida mediante el

cálculo de medidas texturales a partir de ventanas móviles de diferentes tamaños. La incorporación de medidas texturales en la clasificación temática puede mejorar la separabilidad de las cubiertas del suelo, como así lo han demostrado numerosos estudios de cartografía temática (Agüera et al., 2008; Asner et al., 2002; Chan et al., 2003; Chica-Olmo y Abarca-Hernández, 2000; Franklin et al., 2000; Ghimire et al., 2010; Johansen et al., 2007).

Las medidas texturales proporcionan una descripción cuantitativa de características visuales de una imagen, como la homogeneidad, heterogeneidad, simetría, regularidad, etc... Existen una gran variedad de medidas texturales: estadísticos simples, como la desviación estándar (Sun y Qin, 1993), transformadas de Fourier (Matsuyama et al., 1983), fractales (Parrinello y Vaughan, 2002), matrices de co-ocurrencia de los niveles de gris de una imagen (GLCM, *Grey Level Co-occurrence Matrix*) (Haralick et al., 1973; Irons y Petersen, 1981) o funciones geoestadísticas basadas en el variograma (Abarca-Hernández y Chica-Olmo, 1999; Carr, 1996; Lark, 1996; Miranda et al., 1998; Miranda et al., 1992). Entre todas las medidas anteriores, destaca la función variograma, ya que puede ser calculada no sólo para una banda simple, sino también para dos bandas de una misma imagen, e incluso entre bandas de imágenes distintas correspondientes a estados fenológicos diferentes de las cubiertas (“cotextura”). Por tanto, la aplicación de las medidas texturales geoestadísticas supone una ventaja añadida para aquellos casos en los que las diferencias estacionales entre los tipos de cubiertas sean importantes (Culbert et al., 2009).

En este estudio se evalúa la utilidad de incorporar diferentes medidas texturales, tanto mono como multi-estacionales, a los datos espectrales para la clasificación de área de estudio. Pese a que cabría esperar que la adición de nuevas variables texturales al proceso de clasificación, produjese un aumento en su exactitud, un incremento elevado de la dimensionalidad de los datos puede causar una disminución en la exactitud cartográfica, conocida como efecto Hughes (Bellman, 2003; Pacifici et al., 2009). Este problema con la dimensionalidad de los datos, derivado de la inclusión de un número elevado de variables texturales, puede ser resuelto desde dos

vías diferentes: la selección de un clasificador robusto y la reducción de las variables de entrada. Como ya se ha visto previamente en el Capítulo 3, en el que se han comparado diferentes algoritmos de clasificación aplicados a datos de teledetección, *Random Forest* es un clasificador muy robusto, que además incluye una medida para evaluar la importancia de las variables en el proceso de clasificación y por tanto seleccionar las variables más representativas (Breiman, 2001; Cutler et al., 2007; Hastie et al., 2009). Estas cualidades de *Random Forest*, hacen que sea un clasificador idóneo para ser aplicado a problemas de clasificación multi-fuente, en los que el volumen de datos es elevado. Por ello, *Random Forest* ha sido el algoritmo de clasificación elegido para este estudio.

En este capítulo se han abordado diferentes cuestiones relacionadas con la incorporación de medidas texturales al proceso de clasificación. Por un lado, se ha investigado tanto la variación espacial como temporal de las categorías del área de estudio, para lo que se ha analizado la idoneidad del uso de medidas texturales geoestadísticas mono y/o bi-estacionales en la clasificación de cada una de las distintas cubiertas del área de estudio. La mejora en la exactitud cartográfica de estas medidas texturales, basadas en el variograma, ha sido comparada con las medidas de textura más usuales en teledetección, las medias basadas en las matrices GLCM (Agüera et al., 2008; Ghimire et al., 2010; Pacifici et al., 2009). Por otro lado, esta investigación también se ha centrado en la evaluación de *Random Forest*, para la clasificación de datos texturales de alta dimensionalidad. Igualmente se ha estudiado el uso de “medidas de importancia” obtenidas por este clasificador para conocer que variables texturales son más importantes para la clasificación general del área de estudio y la clasificación de cada cubierta del suelo de forma aislada. Por último, estas medidas de importancia relativa, han sido aplicadas a la reducción de la dimensionalidad del espacio de datos; es decir, a la eliminación de las variables texturales que menos aportan al proceso de clasificación, para así atenuar el efecto Hughes y mejorar la exactitud cartográfica.

## **2 Fundamentos**

### **1.1 Fundamentos de la textura geoestadística**

La Geoestadística se basa en la Teoría de Variables Regionalizadas propuesta por Matheron (1970), que fue introducida a la comunidad científica del área de teledetección a finales de los años 80 (Curran, 1988a; Woodcock et al., 1988a, b). La hipótesis básica de la geoestadística, en el campo de la teledetección, se fundamenta en que el nivel digital de una imagen (ND) se puede interpretar como una variable regionalizada (Atkinson y Lewis, 2000; Chica-Olmo et al., 2004). Por tanto, la imagen completa se considera una regionalización particular de la variable aleatoria  $ND(x)$ , que proporciona el ND correspondiente a la radiometría de un pixel  $x$  referenciado espacialmente por un sistema de coordenadas, y que está caracterizado por aspectos aleatorios y de correlación espacial. La textura, puede ser analizada, desde un punto de vista geoestadístico, en términos de dos características esenciales del ND: la variabilidad local o global y la autocorrelación espacial. La primera característica está estrechamente relacionada con la dispersión estadística, frecuentemente caracterizada por la varianza. La segunda característica, correlación espacial, asume que los ND de una imagen no se distribuyen espacialmente de acuerdo a un proceso aleatorio (s. estricto), sino que existe una estructura de dependencia o variabilidad espacial asociada a cada cubierta del suelo. En este sentido, Lark (1996) demostró que la variabilidad existente entre dos píxeles depende de sus relaciones espaciales y, por tanto, es susceptible de ser usada como descriptor textural. Consecuentemente, la geoestadística es útil para análisis textural, puesto que ofrece la ventaja de que la variabilidad y la autocorrelación espacial se analizan de forma conjunta. Estos dos aspectos están implícitos en el variograma y el variograma cruzado.

Aunque las medidas texturales geoestadísticas, aplicadas a datos de teledetección, no han tenido la misma difusión que otras metodologías como las GLCM, existen numerosos estudios que informan de la utilidad de la función variograma para incorporar información textural en los modelos de clasificación y

mejorar así la separabilidad de las cubiertas del suelo (Carr, 1996; Chica-Olmo y Abarca-Hernández, 2000; Li et al., 2009; Miranda et al., 1996; Miranda et al., 1992).

La interpretación del variograma, normalmente, se centra en identificar algunas características que puedan estar relacionadas con los elementos de la imagen. La meseta y la pendiente en el origen proporcionan una medida de la variabilidad del ND y están asociadas a la complejidad de las cubiertas del suelo (Colombo et al., 2004; Chen y Gong, 2004; de Wasseige y Defourny, 2002; Pasher y King, 2010; Treitz y Howarth, 2000). El alcance indica la distancia a la que los píxeles dejan de estar correlacionados. Por lo que, proporciona una estimación del tamaño (en media) de los objetos o los patrones de una imagen, y a menudo está relacionado con el tamaño o la escala de los elementos más dominantes de la escena (Curran, 1988b; Jupp et al., 1988, 1989; Woodcock y Strahler, 1987). El alcance del variograma también se ha usado para estimar la escala óptima de estudios de teledetección (Rahman et al., 2003), y las dimensiones de las ventanas móviles aplicadas en el análisis textural (Dell'Acqua et al., 2006; Franklin et al., 1996; Johansen et al., 2007). Los coeficientes de los modelos ajustados a los variogramas pueden ser también efectivos para la identificación de las cubiertas del suelo (Cohen et al., 1990; Herzfeld y Higginson, 1996; Ramstein y Raffy, 1989).

Estudios más recientes de teledetección han usado características derivadas del variograma, estimadas sobre vecindades cuadradas de píxeles, para la clasificación *per pixel*, a partir de diferentes tipos de imágenes. Algunos autores han aplicado características básicas del variograma en la clasificación de imágenes de radar de apertura sintética (SAR) (Dekker, 2003; Miranda et al., 1998; Miranda et al., 1992) e imágenes multiespectrales (Zhang et al., 2004b). Otros estudios han empleado estimadores, tanto uni-variantes como multi-variantes de la función variograma como: semivariograma, madograma, semivariograma cruzado y semivariograma pseudo-cruzado (Abarca-Hernández y Chica-Olmo, 1999; Ashoori et al., 2008; Chica-Olmo y Abarca-Hernández, 2000; Chica-Olmo et al., 2004). Buddenbaum et al. (2005) aplicaron una nueva función denominada pseudo-cross madogram a la clasificación de especies de coníferas a partir de datos hiper-espectrales. Berberoglu et al. (2007)

evaluaron la utilidad de incorporar medidas texturales derivadas del variograma a la clasificación de tres entornos Mediterráneos diferentes, mediante el uso de un clasificador de máxima probabilidad y una red neuronal. Por otro lado, Berberoglu et al. (2010) aplicaron una metodología que incluía variables texturales derivadas del variograma y GLCM para detectar cambios en las cubiertas del suelo. Por último, algunos estudios han explorado la posibilidad de incluir variables geoestadísticas en clasificación orientada a objetos (Balaguer et al., 2010; Berberoglu et al., 2000; Lloyd et al., 2004; Xie et al., 2008).

## **1.2 Fundamentos de las matrices de co-ocurrencia**

Las imágenes texturales basadas en relaciones de vecindad entre píxeles se clasifican en dos grupos: medidas de primer orden o de ocurrencia, las cuales describen una propiedad estadística dentro de una vecindad específica (Asner et al., 2002; Wright y Gallant, 2007); y medidas de segundo orden o de co-ocurrencia, que caracterizan las frecuencias relativas entre dos valores de brillo unidos por una relación espacial determinada (Augusteijn et al., 1995; Baraldi y Parmiggiani, 1995; Clausi, 2002). Aunque ambos tipos de medidas se implementan como ventanas móviles, las medidas de primer orden son menos costosas computacionalmente que las de segundo. Sin embargo, las medidas de primer orden sólo incluyen estadísticos básicos como la media, varianza, rango, mínimo, máximo..., sin considerar las relaciones de vecindad entre píxeles. Por tanto, generalmente, estas aproximaciones no son tan efectivas como las matrices de co-ocurrencia (Culbert et al., 2009; Gong et al., 1992; Rajesh et al., 2001). Por esta razón, desde que fueran propuestas por Haralyck et al. en los años 70 (Haralick et al., 1973), las medidas de co-ocurrencia (GLCM) han sido las más usadas como medidas texturales en la clasificación de datos de teledetección.

Las bases de la metodología basada en GLCM están bien establecidas, y existen numerosos estudios que las usan, aplicados al modelado de la estructura de los bosques (Castillo-Santiago et al., 2010; Kayitakire et al., 2006; Ozdemir et al., 2008; Pasher y King, 2010; Wunderle et al., 2007), modelado de hábitats (Estes et al., 2008;

Estes et al., 2010) y clasificación de las cubiertas del suelo (Beekhuizen y Clarke, 2010; Johansen et al., 2007; Kimothi y Dasari, 2010; Pacifici et al., 2009; Zhang et al., 2010; Zhang et al., 2009).

### **1.3 Fundamentos de la selección de características**

La inclusión de variables texturales auxiliares en estudios de teledetección implica un gran incremento en la dimensionalidad de los datos que se usan en los procesos de clasificación (en ocasiones cientos de variables). Este gran volumen de datos excede frecuentemente la capacidad de los clasificadores. Por una parte, una mayor cantidad de información puede ser útil para el proceso de clasificación; pero por otra, el incremento de las variables de entrada introduce también una mayor complejidad, que afecta al tiempo de cómputo y produce el denominado efecto Hughes (Bellman, 2003). Esta alta dimensionalidad de los datos puede contrarrestar el incremento en la exactitud que cabría esperar como consecuencia de la inclusión de nuevas variables.

La selección de características (SC), también denominada selección de variables, reducción de características o selección de atributos, es una técnica que tiene por objetivo seleccionar un subconjunto compuesto por las características más relevantes en el proceso de clasificación para construir modelos de aprendizaje más robustos (Blum y Langley, 1997; Guyon y Elisseeff, 2003; Saeys et al., 2007). En los estudios de teledetección normalmente se aplican un número variable de funciones a las bandas de las imágenes de satélite para obtener diferentes parámetros texturales. Como resultado, además del incremento obvio del número de variables, éstas suelen ser redundantes o estar correlacionadas (Pacifici et al., 2009). Por tanto, un objetivo lógico dentro del proceso de clasificación, a partir de espacios de datos de alta dimensionalidad, debería ser la selección de las características o variables más relevantes. Bajo este escenario, SC ayuda a incrementar la exactitud de los modelos de clasificación, ya que: reduce el efecto Hughes, aumenta la capacidad de generalización, acelera el proceso de aprendizaje e incrementa la interpretabilidad del modelo.



Las técnicas de SC se dividen en: filtros, *wrappers* y *embedded* (Blum y Langley, 1997; Guyon y Elisseeff, 2003; Kohavi y John, 1997). Los filtros buscan a través del espacio de características y evalúan cada subconjunto de información en base a medidas estadísticas derivadas de dichas características. Los *wrappers* son similares a los filtros en el procedimiento de búsqueda, pero en lugar de evaluar utilizando un criterio estadístico lo hacen a través de la exactitud de clasificaciones iterativas. Las técnicas *embedded* también son aproximaciones basadas en clasificación, pero a diferencia de los *wrappers* la selección se produce durante la fase de entrenamiento. Dentro de estas agrupaciones se han propuesto técnicas de SC de muy diversa naturaleza. En teledetección, probablemente la técnica de SC más común, es el uso de la primera componente de un análisis de componentes principales en lugar de las características originales (Benediktsson y Sveinsson, 1997; Berberoglu et al., 2007; Chica-Olmo et al., 2004; Zhang et al., 2009). Los métodos más recientes, fundamentalmente son de tipo *wrappers*, e incluyen algoritmos no paramétricos como: árboles de decisión, redes neuronales o máquinas de vectores soporte (Bazi y Melgani, 2006; De Stefano et al., 2007; Del Frate et al., 2005; Pal y Foody, 2010; Yu et al., 2002). Entre todo este conjunto de técnicas, en este estudio se ha considerado la aplicación de *Random Forest*, que entre sus funcionalidades incorpora un método de SC de tipo *embedded* (Sección 3.1.2 del Capítulo 3).

## 2 Metodología

### 2.1 Análisis textural

Para introducir información textural en el proceso de clasificación se calcularon un conjunto de medidas texturales a diferentes escalas. Por un lado, se calcularon diferentes medidas texturales geoestadísticas, tanto mono como multi-estacionales: variogramas, rodogramas, madogramas, variogramas cruzados y variogramas pseudo-cruzados. Por otro, a efectos de comparación, se calcularon también ocho medidas texturales GLCM diferentes: media, varianza, homogeneidad, contraste, disimilitud, entropía, momento segundo y correlación. Este conjunto de características texturales

se calculó a partir de las bandas brutas multiespectrales (bandas 1 a 7) de las imágenes Landsat TM5 de primavera y verano. Para recoger información sobre las diferentes escalas en los patrones de variabilidad espacial de las cubiertas del suelo del área de estudio, las medidas texturales se calcularon para tres tamaños de ventana diferentes: 5x5, 15x15 y 31x31.

### **2.1.1 Cálculo de las medidas derivadas del variograma**

Según el estudio realizado por Chica-Olmo y Abarca-Hernández (2000) el cálculo de las medidas derivadas del variograma debería considerar aspectos como el tamaño de las ventanas móviles, el paso y las distancias de cálculo. La selección del tamaño de ventana más adecuado es un problema práctico, que depende de las características del paisaje y la resolución espacial de las imágenes. Por lo que es específico de cada escena a clasificar y debe ser resuelto empíricamente. En cuando a los pasos ( $h$ ) usados en el cálculo de las imágenes de textura, su número dependerá del tamaño de la ventana considerada. Para tamaños de ventana grandes es posible considerar un elevado número de pasos en el cálculo de los variogramas. Sin embargo, usar todos los valores posibles de las semi-varianzas es complicado, debido fundamentalmente a dos factores: la escasez de parejas para pasos grandes, que introduce incertidumbre en su cálculo y el tiempo de cálculo. La dirección de la estimación del variograma experimental es otro punto que debe ser tomado en consideración, cuando la distribución espacial de los niveles digitales señala la existencia de anisotropías en las direcciones principales (N-S, E-O, NE, NO). En cualquier caso, para los primeros pasos, pueden calcularse variogramas omnidireccionales puesto que las anisotropías son normalmente imperceptibles para distancias más pequeñas de unos pocos píxeles.

En este estudio, se obtuvieron un conjunto de variables texturales geoestadísticas, que fueron obtenidas mediante el cálculo de las medidas derivadas de variogramas omnidireccionales, considerando el primer y el segundo paso y la pendiente entre ambos. En concreto, se consideraron las siguientes medidas derivadas del variograma (Abarca-Hernández y Chica-Olmo, 1999; Chica-Olmo y Abarca-Hernández, 2000):

-Variograma:

$$\gamma_k(\mathbf{h}) = \frac{1}{2N(\mathbf{h})} \sum_{i=1}^{N(\mathbf{h})} \{DN_k(\mathbf{x}_i) - DN_k(\mathbf{x}_i + \mathbf{h})\}^2 \quad (6.1)$$

Donde  $N(\mathbf{h})$  es el número de parejas que distan entre sí la distancia  $h$  (paso),  $DN(\cdot)$  son los niveles digitales de los píxeles  $\mathbf{x}_i$  y  $\mathbf{x}_i + \mathbf{h}$  (realización experimental de la función aleatoria  $DN(\mathbf{x})$ , y  $k$  es la banda del sensor.

-Madograma:

El madograma es similar al variograma, pero en lugar de usar diferencias cuadráticas toma el valor absoluto de las diferencias (Deutsch y Journel, 1992).

$$\gamma_k(\mathbf{h}) = \frac{1}{2N(\mathbf{h})} \sum_{i=1}^{N(\mathbf{h})} |DN_k(\mathbf{x}_i) - DN_k(\mathbf{x}_i + \mathbf{h})| \quad (6.2)$$

-Rodograma:

Esta medida también es similar al variograma, pero considera la raíz cuadrada de las diferencias absolutas en lugar de las diferencias al cuadrado.

$$\gamma_k(\mathbf{h}) = \frac{1}{2N(\mathbf{h})} \sum_{i=1}^{N(\mathbf{h})} \sqrt{|DN_k(\mathbf{x}_i) - DN_k(\mathbf{x}_i + \mathbf{h})|} \quad (6.3)$$

-Variograma cruzado:

El variograma cruzado es una función bivariada que cuantifica la variabilidad espacial conjunta (correlación cruzada) entre dos bandas. Se define como la mitad del producto promedio de las diferencias entre dos bandas radiométricas,  $j$ ,  $k$ .

$$\gamma_{jk}(\mathbf{h}) = \frac{1}{2N(\mathbf{h})} \sum_{i=1}^{N(\mathbf{h})} \{DN_j(\mathbf{x}_i) - DN_j(\mathbf{x}_i + \mathbf{h})\} \cdot \{DN_k(\mathbf{x}_i) - DN_k(\mathbf{x}_i + \mathbf{h})\} \quad (6.4)$$

- Variograma pseudo-cruzado

El variograma pseudo-cruzado representa la semivarianza de los incrementos cruzados en lugar de la covarianza directa del cruzado:

$$\gamma_{jk}(\mathbf{h}) = \frac{1}{2N(\mathbf{h})} \sum_{i=1}^{N(\mathbf{h})} \{DN_j(\mathbf{x}_i) - DN_k(\mathbf{x}_i + \mathbf{h})\}^2 \quad (6.5)$$

Ambas medidas (variograma cruzado y pseudo-cruzado) han sido calculadas para las diferentes combinaciones posibles de parejas de bandas de una imagen y, para las mismas bandas de las imágenes de primavera y verano (textura multi-estacional)

### 2.1.2 Cálculo de las medidas GLCM

A efectos de comparación con las variables geoestadísticas, se calcularon las medidas texturales basadas en las matrices de co-ocurrencia de los niveles de gris (Haralick et al., 1973). Las GLCM son una tabulación de la frecuencia relativa de pares de niveles digitales de píxeles que están separados por una cierta distancia en una dirección determinada. Formalmente, los elementos de una matriz GLCM  $\mathbf{G}(i,j)$  para un vector desplazamiento  $(a,b)$  vienen definidos por (Zhang et al., 2009):

$$G(i, j) = \left| \{(x, y), (t, v) : \mathbf{I}(r, s) = i \& \mathbf{I}(t, v) = j\} \right| \quad (6.6)$$

Donde  $(t,v)=(x+a, y+b)$  y  $(a,b)$  es el vector desplazamiento, expresado en coordenadas polares como  $(d, \theta)$ . Normalmente las GLCM se calculan en cuatro direcciones, 0 (horizontal), 45 (diagonal derecha), 90 (vertical), y 135 (diagonal izquierda). Las medidas GLCM se calcularon considerando un parámetro de distancia igual a 1 pixel, de forma que se compararon píxeles adyacentes, para los tres tamaños de ventana especificados en la Sección 2.1. Las medidas GLCM fueron calculadas para las cuatro direcciones principales (0, 45, 90 y 135) y promediadas después, de esta forma se evitó el problema de la elección de la dirección más adecuada (Anys et al., 1994).

Haralick et al. (1973) propuso originalmente 14 medidas texturales GLCM: uniformidad (también conocida como energía), contraste, correlación, sumatoria de cuadrados, varianza, homogeneidad, suma de los promedios, suma de varianza, suma de entropía, entropía, diferencia de la varianza, diferencia de la entropía, y dos medidas de correlación y del coeficiente de correlación máximo. Se ha demostrado

que muchas de estas medidas de segundo orden están altamente correlacionadas, es decir, son redundantes (Clausi, 2002). Para evitar la correlación entre las medidas texturales sólo se seleccionaron las más relevantes de acuerdo a los estudios de Baraldi y Parmiggiani (1995) y Kayikatiire et al. (2006):

- Media:

$$\sum_{i=0}^{ng-1} \sum_{j=0}^{ng-1} ip(i, j) \quad (6.7)$$

Donde  $ng$  es el número de niveles digitales y  $p(i, j)$  es la probabilidad de co-ocurrencia de los niveles digitales  $i$  y  $j$ .

- Varianza:

$$\sum_{i=0}^{ng-1} \sum_{j=0}^{ng-1} \left( i * \left( \sum_{i=0}^{ng-1} \sum_{j=0}^{ng-1} ip(i, j) \right) - p(i, j) \right)^2 \quad (6.8)$$

La varianza denota la dispersión de los niveles digitales. Generalmente las texturas más groseras están asociadas a varianzas mayores.

- Contraste:

$$\sum_{i=0}^{ng-1} \sum_{j=0}^{ng-1} (i - j)^2 p(i, j) \quad (6.9)$$

El contraste es una medida de la frecuencia espacial, que es igual a la diferencia en amplitud entre los valores mayores y más pequeños de un conjunto de píxeles contiguos. Una imagen con un contraste bajo, presenta una matriz GLCM concentrada en la diagonal principal. Esto significa que los valores altos de contraste implican una textura grosera.

- Correlación:

$$\sum_{i=0}^{ng-1} \sum_{j=0}^{ng-1} [(i - \mu)(j - \mu) p(i, j)] / \sigma_i \sigma_j \quad (6.10)$$

Donde  $\sigma_i$  y  $\sigma_j$  son la media y la desviación estándar. La correlación es una medida de la dependencia lineal de los ND de una imagen. Las correlaciones altas implican una relación lineal entre los pares de ND.

-Disimilitud:

$$\sum_{i=0}^{ng-1} \sum_{j=0}^{ng-1} |(i-j) p(i, j)| \quad (6.11)$$

La disimilitud, al igual que el contraste, informa sobre la heterogeneidad de los niveles digitales. Los valores altos en la disimilitud son indicadores de texturas groseras.

- Entropía:

$$\sum_{i=0}^{ng-1} \sum_{j=0}^{ng-1} p(i, j) \log(p(i, j)) \quad (6.12)$$

La entropía mide el desorden dentro de una imagen. Cuando la imagen no es uniforme, muchos elementos de la matriz GLCM tienen valores muy pequeños lo que implica que la entropía es alta.

- Homogeneidad:

$$\sum_{i=0}^{ng-1} \sum_{j=0}^{ng-1} p(i, j) / [1 + (i - j)^2] \quad (6.13)$$

La homogeneidad toma valores altos para pequeñas diferencias entre pares de elementos, Por tanto, este parámetro es muy sensible a los elementos presentes cerca de la diagonal de la matriz GLCM.

- Uniformidad:

$$\sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} p(i, j)^2 \quad (6.14)$$

La uniformidad es una mediada de la homogeneidad en la textura (ej. la repetición entre pares de píxeles). Los valores altos de uniformidad ocurren cuando la

imagen no es homogénea y existe un contraste en la distribución de los ND o su distribución es periódica.

### **3 Resultados y discusión**

Como se ha comentado en la introducción de este capítulo, para una mejor caracterización de la complejidad de los patrones de las cubiertas mediterráneas, es necesario extraer información adicional de la imagen que mejore la separabilidad de las categorías del área de estudio. Las medidas derivadas del variograma han sido comparadas con las características derivadas de las matrices GLCM para determinar cuáles de ellas son más adecuadas para el objeto de esta investigación. Las características más importantes para la clasificación general del área de estudio y de cada categoría se muestran en la Sección 3.3. El cálculo de la importancia de las variables se llevó a cabo por medio del clasificador RF, que fue usado también para evaluar el impacto en la exactitud de las clasificaciones de la reducción de características y para seleccionar el subconjunto óptimo de variables texturales.

#### **3.1 Clasificación de las medidas texturales con RF**

Como ya se indicó en el Capítulo 3, el clasificador RF sólo necesita la determinación de dos parámetros básicos para generar un modelo de predicción: el número de árboles ( $k$ ), y el número de variables predictivas usadas en cada nodo para hacer crecer el árbol ( $m$ ). En otras palabras, para clasificar un nuevo conjunto de datos, cada uno de los nuevos ejemplos es clasificado por un número  $k$  de árboles usando un número constante de variables aleatorias  $m$  definidas por el usuario. De esta forma, el valor final de la clase asignada a cada ejemplo será igual al valor más frecuente del total de los árboles generados.

Para evaluar el valor óptimo de  $m$ , se crearon un elevado número de modelos de clasificación RF para cada conjunto de datos texturales, cada uno de ellos compuesto por 5000 árboles para diferentes valores posibles de  $m$  (de 1 a 30). Los modelos

resultantes se evaluaron en términos del índice kappa (Congalton y Green, 2009). Los mejores modelos fueron aquellos que produjeron un índice kappa mayor.

### **3.2 Comparación entre las medidas derivadas del variograma y las GLCM**

Como se ha explicado en la Sección 2.1, se calcularon un conjunto de características texturales basadas en geoestadística y en matrices GLCM, para el promedio de las direcciones (NS, EO, NE, y NW) a partir de las imágenes Landsat TM5 de primavera y verano para tamaños de ventana de 5x5, 15x15 y 31x31.

Las medidas geoestadísticas se calcularon para el primer y segundo paso (30 m y 60 m, respectivamente) y para la pendiente entre dichos pasos. Estas medidas se usaron junto con los datos espectrales (bandas Kauth Thomas multi-estacionales, MKT) en la clasificación con RF. La primera columna de la Tabla 6.1 muestra los resultados de la clasificación RF usando sólo las bandas MKT. Los valores mayores de kappa se obtuvieron a partir de los datos que incluían los datos espectrales junto con las medidas geoestadísticas calculadas para el primer paso, lo cual puede ser debido a que el cálculo del variograma es más robusto y está menos afectado por variaciones en las clases (Lloyd et al., 2004). Las medidas geoestadísticas calculadas a partir del segundo paso, produjeron kappas ligeramente menores y los resultados de la pendiente entre el primer y segundo paso no produjeron una mejora significativa en la exactitud cartográfica. Lo cual apoya los resultados del estudio de Berberoglu et al. (2000), en el cual, a partir también de datos del sensor TM5 de Landsat, se concluye que la exactitud decrece con el incremento en el paso del variograma. La pendiente no supuso una contribución significativa para la diferenciación de las categorías, ya que, para pasos cercanos al origen, existe un efecto proporcional entre los variogramas de cada categoría, y la pendiente es muy similar. Por ello, para la comparación con las matrices GLCM, se seleccionaron las medidas geoestadísticas calculadas para el primer paso del variograma.



Tabla 6.1. Parámetros del clasificador Random Forest para los modelos más exactos (exactitud global y kappa) a partir de los datos de textura geoestadística para los diferentes pasos. MKT se refiere al conjunto de datos únicamente espectrales. G, G5, G15 y G31 se refiere a los modelos texturales multi-escala y a los modelos para tamaños de ventana de 5x5, 15x15 y 31x31, respectivamente.

	Paso 1				Paso 2				Pendiente entre el paso 1 y 2			
	G	G5	G15	G31	G	G5	G15	G31	G	G5	G15	G31
K	5000	5000	5000	5000	5000	5000	5000	5000	5000	5000	5000	5000
m	20	15	22	13	20	17	10	14	19	18	14	18
E.G.	0,91	0,88	0,91	0,92	0,90	0,88	0,89	0,91	0,87	0,84	0,87	0,88
Kp.	0,91	0,87	0,90	0,91	0,90	0,87	0,88	0,91	0,86	0,83	0,86	0,87

Tabla 6.2. Parámetros del clasificador Random Forest, exactitud cartográfica e incrementos en la exactitud (exactitud global y kappa) y valores de Z, para evaluar la significativdad de las diferencias entre los coeficientes kappa de las clasificaciones obtenidas a partir de los subconjuntos de datos MKT y de los modelos texturales (Z) y entre los coeficientes kappa de los subconjuntos con características geoestadísticas y los que contienen características GLCM (Z\*).

	MKT	G	G5	G15	G31	GLCM	GLCM 5	GLCM 15	GLCM 31
Nº Variables	6	330	114	114	114	294	102	102	102
K	5000	5000	5000	5000	5000	5000	5000	5000	5000
m	2	20	15	22	13	20	13	21	18
Ex. Glob.	0,85	0,91	0,88	0,91	0,92	0,89	0,85	0,88	0,88
kappa	0,84	0,91	0,87	0,90	0,91	0,89	0,84	0,88	0,89
Inc. en Ex. Glob. (%)	--	7,04	3,35	7,04	7,54	4,02	0,17	3,69	6,03
Inc. en kappa (%)	--	7,68	3,66	7,68	8,23	4,39	0,18	4,02	6,58
Z	--	4,86	2,39	4,45	4,49	3,03	0	2,20	3,43
Z*	--	1,98	2,54	2,61	1,71	--	--	--	--

La Tabla 6.2 muestra una tendencia general al incremento de la exactitud cartográfica al añadir características texturales a los modelos RF multi-estacionales. Los valores de la exactitud global del modelo geoestadístico multi-escala (G) y de los modelos para los tamaños de ventana de 5x5 (G5), 15X15 (G15) y 31x31 (G31), fueron iguales a 0,91, 0,88, 0,91 y 0,92, respectivamente, con valores del estadístico kappa iguales a 0,91, 0,87, 0,91 and 0,91. La inclusión de las características texturales geoestadísticas supuso un incremento del 7,04%, 3,35%, 7,04% y 7,54% en la exactitud global y del 7,68%, 3,66%, 7,68% y 8,23% en el índice kappa para G, G5,

G15 y G31, respectivamente. Las medidas de co-ocurrencia usadas, dieron lugar a modelos de clasificación menos exactos que las medidas basadas en geoestadística. La exactitud global del modelo multi-escala GLCM, y de los modelos de tamaño de ventana 5X5 (GLCM5), 15X15 (GLCM15) y 31x31 (GLCM31) fueron iguales a 0,89, 0,85, 0,88 y 0,88, respectivamente, con estadísticos kappa iguales a 0,89, 0,84, 0,88 y 0,89. Las matrices GLCM sólo incrementaron parcialmente la exactitud cartográfica. El incremento en kappa y en la exactitud global para GLCM5 fue prácticamente nulo. Los modelos GLCM, GLCM15 y GLCM31 mejoraron al anterior con incrementos en la exactitud global y kappa iguales a 4,02%, 3,69% y 6,03% y 4,39%, 4,02% y 6,58%, respectivamente (Tabla 6.2).

Como se indicó en el Capítulo 2, se ha usado el mismo conjunto de datos de “verdad terreno” en el entrenamiento y la validación de cada modelo, por lo que los datos usados en la validación de los diferentes modelos no son independientes. Para comparar las diferencias en la exactitud de los modelos de forma rigurosa, se aplicó el test de McNemar. Este test considera que las diferencias en la exactitud de dos clasificaciones son estadísticamente significativas para niveles de significatividad del 5%, es decir, para valores de Z mayores de 1.96 (Foody, 2004; Foody, 2009). Los valores de Z incluidos en la Tabla 6.2 evalúan las diferencias en exactitud entre el modelo MKT y los modelos texturales; y los valores de Z\* las diferencias entre los modelos de la misma escala, geoestadísticos y GLCM. Los valores de Z, a excepción del valor del modelo GLCM5, indican que el incremento en la exactitud derivado de los modelos texturales es significativo. La significatividad de las diferencias es mayor para los modelos multi-escala y aumenta cuando lo hace el tamaño de ventana. De los resultados del test de McNemar también puede concluirse que los modelos geoestadísticos mejoran los resultados de los modelos GLCM, y proporcionan una diferenciación más significativa de las cubiertas del suelo del área de estudio. Además, los valores de Z\* muestran que las clasificaciones llevadas a cabo por los modelos geoestadísticos son significativamente diferentes, es decir, que las medidas texturales geoestadísticas mejoran a las GLCM.

La matriz de error del modelo no textural MKT se muestra en la Tabla 6.3. Para este modelo, las exactitudes del productor y del usuario de algunas clases individuales fueron relativamente bajas, con valores promedios iguales a 0.85 y 0.88, y desviaciones estándar del 0.10, en ambos casos. Los cultivos leñosos en regadío, inicialmente, se confundieron con cultivos tropicales y especies de quercíneas; la clase urbana con suelos desnudos; y los bosques de coníferas con quercíneas. La Tabla 6.4 y Tabla 6.5 muestran los estadísticos kappa por categorías y el incremento en kappa de los modelos geoestadísticos y de co-ocurrencia, respectivamente. Ambos tipos de medidas texturales incrementaron la separabilidad de las categorías más difíciles de clasificar con respecto al modelo MKT. Los modelos multi-escala produjeron el mayor incremento en la separabilidad inter-clase, mientras que los modelos para escalas simples produjeron un incremento más modesto. El orden de incrementos en kappa para cada categoría varió en función del tamaño de ventana utilizado. Los cultivos leñosos en regadío, las áreas urbanas y los suelos experimentaron los mayores incrementos en kappa para los modelos multi-escala (G y GLCM), con incrementos del 31%, 29% y 18% para G y 34%, 26% y 15% para GLCM, respectivamente. Los modelos para tamaños de ventana de 5x5, caracterizaron mejor las categorías más heterogéneas con una mayor variabilidad espacial, las zonas urbanas y los suelos desnudos (21% y 18% para G5 y GLCM5, respectivamente). Otras categorías más heterogéneas como los cultivos leñosos en regadío y los cultivos tropicales fueron mejor caracterizadas con tamaños de ventana iguales a 31x31, con incrementos iguales a 28% y 23% para G31, y 34% y 23% para GLCM31. Esto contrasta con los resultados del estudio de Berberoglu et al. (2007), en el cual, fueron clasificadas diferentes sub-escenas correspondientes a áreas urbanas, agrícolas y semi-naturales, a partir de imágenes Landsat TM5, concluyó que las medidas texturales sólo incrementaron la exactitud de la clasificación de las áreas urbanas. Por último, a partir de la Tabla 6.4 y Tabla 6.5 se puede comprobar que la inclusión de medidas texturales no afectó a la clasificación de los matorrales y los cuerpos de agua, para los cuales la información espectral fue suficiente.

Tabla 6.3. Matriz de confusión del modelo MKT.

	Datos de Referencia														TOT.
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
1	38	0	0	0	0	0	1	0	0	0	0	7	0	0	46
2	0	49	0	0	0	0	0	0	0	1	0	0	0	0	50
3	0	1	39	0	3	0	0	5	0	0	0	0	0	0	48
4	0	0	0	49	0	0	0	0	0	0	0	0	0	0	49
5	0	0	0	0	41	2	1	2	0	0	1	1	0	0	48
6	0	0	0	0	1	45	1	0	0	0	0	3	0	0	50
7	0	0	0	0	0	1	41	0	0	0	1	0	0	0	43
8	0	0	8	0	2	1	0	39	2	5	0	0	2	0	59
9	0	0	0	0	0	0	0	0	45	1	0	0	2	0	48
10	0	0	3	0	0	0	0	2	0	35	0	0	7	0	47
11	0	0	0	0	0	0	6	0	0	0	48	0	0	0	54
12	12	0	0	1	2	1	0	0	0	0	0	39	0	0	55
13	0	0	0	0	1	0	0	2	3	8	0	0	39	0	53
14	0	0	0	0	0	0	0	0	0	0	0	0	0	50	50
TOT.	50	50	50	50	50	50	50	50	50	50	50	50	50	50	700
E. G.	Kappa														
0.85	0.84														

Tabla 6.4. Resultados del estadístico kappa por categorías del modelo MKT y de los modelos texturales geoestadísticos e incrementos en kappa de los modelos texturales respecto al modelo MKT.

Id. Clase	MKT	GO	G5	G15	G31	Inc. en kappa GO	Inc. en kappa G5	Inc. en kappa G15	Inc. en kappa G31
1	0.74	0.96	0.89	0.94	0.91	29	21	26	24
2	0.94	1.00	0.94	0.96	0.98	6	0	2	4
3	0.76	0.83	0.85	0.81	0.87	9	12	6	15
4	0.98	1.00	1.00	1.00	1.00	2	2	2	2
5	0.85	0.78	0.81	0.81	0.78	-8	-5	-5	-8
6	0.91	0.98	0.93	0.98	0.96	8	3	8	5
7	0.81	0.85	0.83	0.91	0.85	5	2	13	5
8	0.76	0.81	0.74	0.78	0.81	6	-2	3	6
9	0.89	0.91	0.91	0.89	0.94	3	3	0	5
10	0.7	0.91	0.79	0.87	0.89	31	12	24	28
11	0.94	0.98	0.94	0.98	1.00	4	-1	4	6
12	0.72	0.85	0.85	0.81	0.81	18	18	12	12
13	0.78	0.85	0.76	0.96	0.96	9	-2	23	23
14	1	0.98	0.98	1.00	1.00	-2	-2	0	0

Tabla 6.5. Resultados del estadístico kappa por categorías del modelo MKT y de los modelos texturales de co-ocurrencia e incrementos en kappa de los modelos texturales respecto al modelo MKT.

Id. Clase	MKT	GLCM	GLCM5	GLCM15	GLCM31	Inc. en Kappa GLCM	Inc. en Kappa GLCM5	Inc. en Kappa GLCM15	Inc. en Kappa GLCM31
1	0.74	0.94	0.89	0.94	0.89	26	21	26	21
2	0.94	1.00	0.94	0.98	0.98	6	0	4	4
3	0.76	0.83	0.87	0.81	0.85	9	15	6	12
4	0.98	1.00	1.00	1.00	0.98	2	2	2	0
5	0.85	0.83	0.87	0.85	0.81	-3	2	0	-5
6	0.91	1.00	0.93	0.96	0.96	10	3	5	5
7	0.81	0.85	0.83	0.91	0.85	5	2	13	5
8	0.76	0.83	0.74	0.81	0.83	9	-2	6	9
9	0.89	0.91	0.91	0.89	0.94	3	3	0	5
10	0.7	0.94	0.81	0.85	0.94	34	15	21	34
11	0.94	0.98	0.94	1.00	1.00	4	-1	6	6
12	0.72	0.83	0.85	0.76	0.77	15	18	6	6
13	0.78	0.89	0.78	0.91	0.96	14	1	17	23
14	1	0.98	0.98	0.98	1.00	-2	-2	-2	0

### 3.3 Importancia de las medidas texturales

El clasificador *Random Forest* ha permitido la evaluación de la importancia de las variables de entrada mediante el índice de Gini y las medida oob (Sección 5.1.1.2 del Capítulo 3). Para calcular la importancia de las variables predictivas en el modelo general de clasificación, y en la clasificación de cada categoría, se utilizaron modelos RF compuestos por 5000 árboles y una variable aleatoria (Breiman, 2001).

Para analizar la importancia de las características texturales, en relación con el tamaño de ventana y el tipo de función, la contribución relativa de las variables de entrada al modelo se representó en función del decrecimiento medio producido en el subconjunto oob. La Figura 6.1 muestra la contribución relativa de las variables de entrada, considerando el modelo multi-escala (Figura 6.1a) y los modelos de escala simple (Figura 6.1b). A partir de estas figuras se puede observar como la importancia relativa de cada parámetro en el modelo multi-escala es menor que la de los modelos para diferentes escalas (modelos de escala simple). Esto es debido a que el modelo multi-escala tiene en cuenta un elevado número de variables (330 variables), mientras

que en el caso de los modelos simples el número de variables es notablemente inferior (114 variables). Así pues, la eliminación de una característica en el modelo multi-escala tiene un impacto menor. Respecto al tamaño de ventana, para el modelo multi-escala, las características estimadas a partir de vecindades de 5x5 píxeles tuvieron una importancia relativa mayor que el resto (Figura 6.1a) Sin embargo, si se consideran los modelos para diferentes escalas de forma aislada, es el modelo para tamaños de ventana de 31x31 píxeles el que afecta más a la exactitud de las clasificaciones. Este efecto puede ser debido a una relación de interdependencia o sinergia entre las características de diferentes escalas del modelo multi-escala, que hace que ciertas características sean sólo importantes en combinación o presencia de otras (Pacifi et al., 2009). La importancia de cada parámetro textural fue evaluada de la misma manera. Como puede apreciarse a partir de las figuras mencionadas, la diferencia entre las características mono- y bi-variadas es notable. Los variogramas pseudo-cruzados (PC) son las funciones texturales más importantes, lo cual señala la necesidad de incluir este tipo de medidas, entre dos bandas de la misma imagen o entre bandas de imágenes de diferentes estaciones, en los estudios de teledetección. La mejor caracterización de la variabilidad espacial de las imágenes llevada a cabo por PC, se debe probablemente al hecho de que las diferencias mostradas en la Ecuación (6.5) son bi-variadas. En cuanto al resto de funciones, los madogramas también destacaron por su mayor exactitud para el modelo multi-escala y para los modelos de vecindades iguales a 5x5 y 31x31.

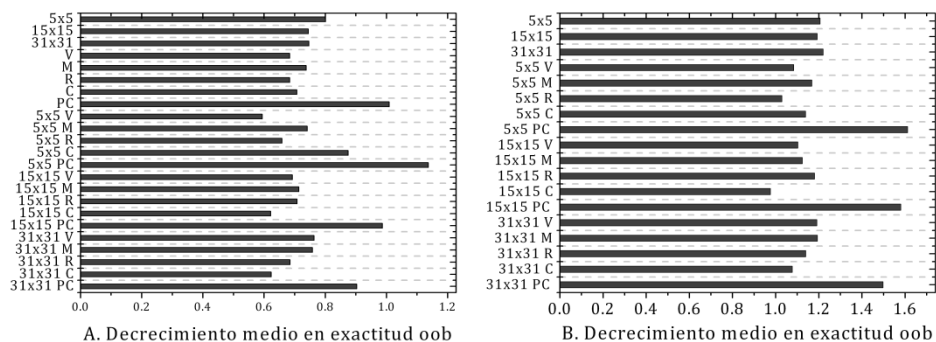


Figura 6.1. Importancia de las características texturales con respecto a la función utilizada y el tamaño de ventana. A. Contribución de los parámetros

texturales del modelo multi-escala. B. Contribución de los parámetros texturales de los modelos de escala simple. V, M, R, C, y PC se refieren al Variograma, Madograma, Rodograma Variograma Cruzado y Variograma Pseudo-cruzado, respectivamente.

### 2.1.3 Análisis de las 10 medidas texturales más importantes

La Figura 6.2 muestra la importancia relativa de la contribución a los modelos de clasificación de las diez variables más importantes, incluidas tanto las variables texturales como las espectrales. Como cabría esperar, las variables espectrales derivadas de la transformación Kauth-Thomas tuvieron una mayor influencia en la separabilidad entre clases. La Figura 6.2 muestra como la eliminación de algunas variables texturales, en especial los variogramas pseudo-cruzados, produjo un decrecimiento relativamente importante (en torno al 2%) de la exactitud cartográfica del subconjunto oob. Cabe destacar que, atendiendo a la medida de importancia oob, la textura multi-estacional de la banda infrarroja fue una de las características más importantes para la clasificación del área de estudio. La medida de importancia basada en el índice Gini (Figura 6.2b) muestra un patrón de importancia ligeramente diferente al del caso anterior. Las variables espectrales, seguidas de los variogramas pseudo-cruzados, fueron también las más importantes. Para ambas medidas de importancia, oob y Gini, la textura bi-variada entre las bandas infrarroja y azul visible; la banda azul y verde; y verde visible e infrarroja fueron las características texturales más importantes.





Figura 6.2. Medidas de importancia relativa basadas en oob (A) y el índice de Gini (B). Los acrónimos Ver., Pri., MS., VERD., y HUM., se refieren a verano, primavera, multi-estacional, verdor y humedad, respectivamente. Los números detrás de los acrónimos se refieren a las bandas Landsat TM5 usadas en el cálculo de las medidas texturales.

La Figura 6.3 muestra la importancia de la contribución de las diez variables más significativas en la clasificación de cada categoría. En términos generales, se puede apreciar el mismo comportamiento que para la clasificación general del área de estudio (Figura 6.2). Las variables espectrales fueron las más importantes, seguidas también de los variogramas pseudo-cruzados. Sin embargo, existen algunas diferencias notables. En la clasificación de las categorías compuestas por cultivos: chopos, regadíos herbáceos, regadíos leñosos, secano herbáceos, y cultivos tropicales, caracterizadas por un marcado comportamiento estacional que causa una gran variabilidad inter-clase en sus propiedades espaciales y espectrales, las variables texturales multi-estacionales tuvieron una importancia destacada. La textura de la banda del infrarrojo medio de las imágenes de primavera produjo una mejor diferenciación de la categoría urbana, ya que, esta puede ser confundida con suelos desnudos si sólo se consideran variables de verano.



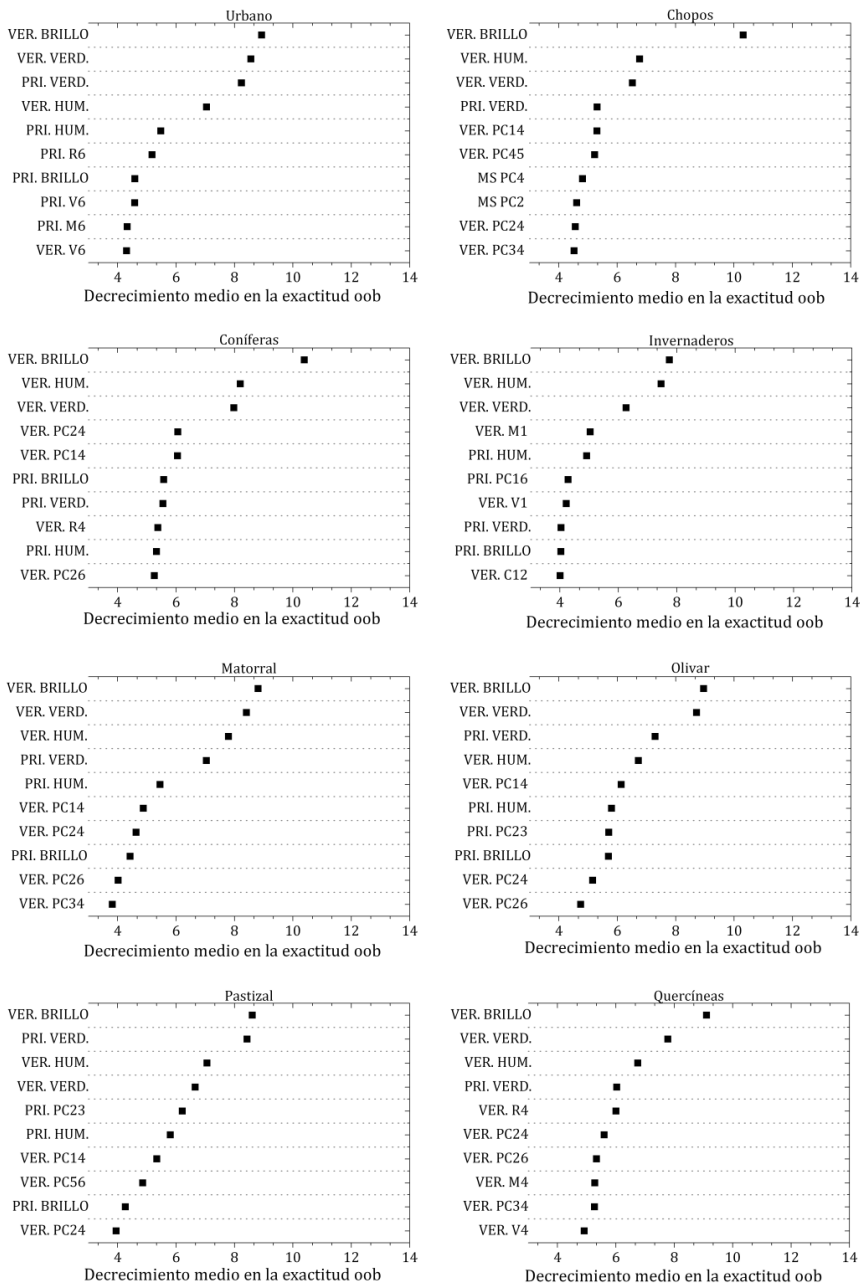


Figura6.3. Medidas oob de importancia relativa para la clasificación de las categorías del área de estudio.

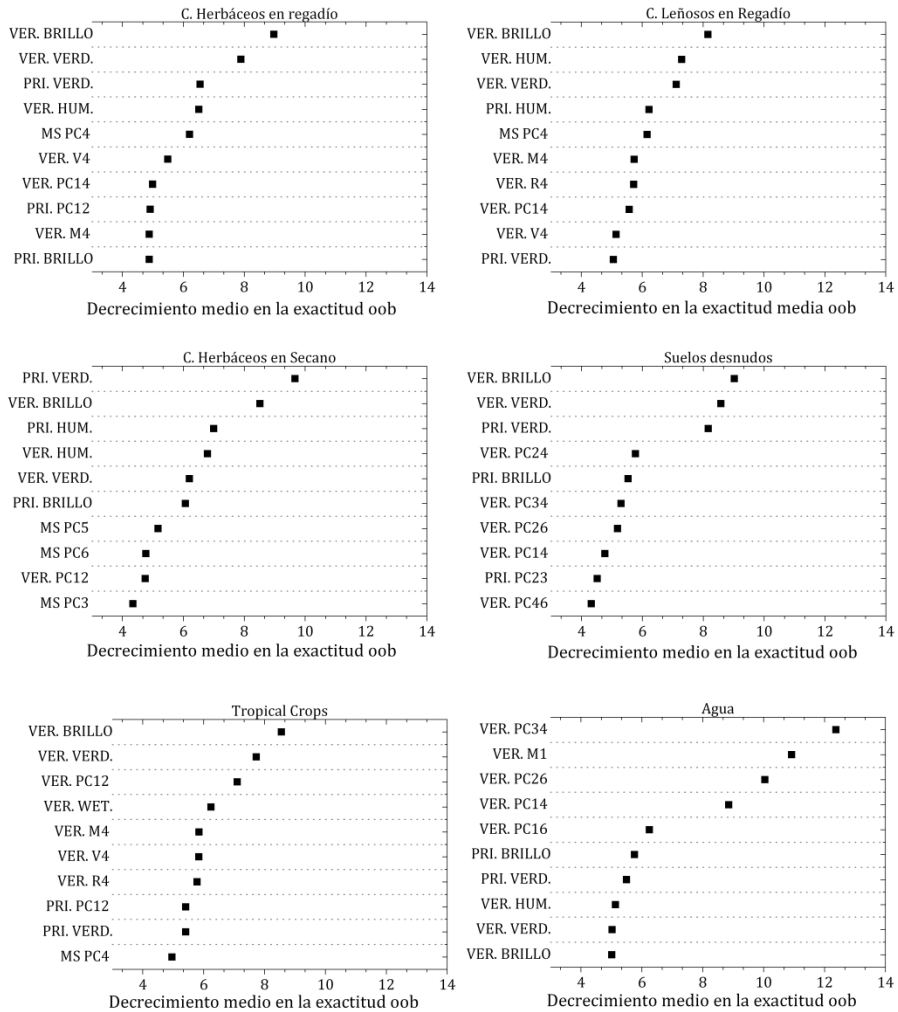


Figura 6.3 (Continuación). Medidas oob de importancia relativa para la clasificación de las categorías del área de estudio.

### 3.4 Selección de las características texturales geoestadísticas más importantes

En los estudios de teledetección, cada vez es más común incluir medidas de la estructura de variabilidad espacial (ej. textura geoestadística) para mejorar los resultados de las clasificaciones de las cubiertas del suelo. Estas medidas consideran múltiples combinaciones de parámetros como el tamaño de ventana, la dirección o el

paso. La aplicación de estas transformaciones a las bandas originales de las imágenes de satélite produce multitud de bandas transformadas, que pueden llegar a ser del orden de cientos, lo cual incrementa considerablemente las variables de entrada de los clasificadores. Este elevado número de características o variables, en ocasiones muy correlacionadas, produce un efecto conocido como efecto Hughes (Bellman, 2003). El cual consiste en que la exactitud de los clasificadores decrece cuando aumenta el número de variables de entrada (Sección 1.3). Afortunadamente, la dimensionalidad de los datos puede reducirse mediante la aplicación de técnicas de Selección de Características (SC). Las técnicas SC engloban un conjunto de procedimientos, usados comúnmente en “aprendizaje de máquinas”, que tienen por objetivo la selección de un subconjunto óptimo de las variables de entrada, eliminando para ello aquellas cuya información es irrelevante o redundante. Por tanto, estas técnicas pueden ser aplicadas a este estudio, en el que el número de variables texturales es demasiado elevado. Así, es posible utilizar únicamente como variables de entrada al clasificador RF, las variables más importantes obtenidas de una primera aplicación de dicho clasificador.

Con el objetivo de reducir el efecto Hughes, y el tiempo de entrenamiento de los modelos de clasificación, se seleccionaron las características predictivas más importantes mediante el uso de las medidas de importancia del clasificador RF, oob y Gini. Para ello se eliminaron a intervalos del 10% las variables menos importantes de los modelos texturales, G, G5, G15 y G31. La Figura 6.4 muestra la evolución del estadístico kappa, derivada de la eliminación de las variables espurias. Como puede observarse, las medidas de importancia oob y Gini, mostraron tendencias similares. La reducción de variables efectuada en base a la medida oob produjo la mayor exactitud cartográfica para todos los casos, a excepción del modelo G5. El mejor ajuste de la medida Gini para las características texturales calculadas sobre vecindades de 5x5 pudo ser debido a que la correlación para esta escala es mayor que para el resto de tamaños de ventana. El índice kappa permaneció más o menos constante hasta alcanzar un punto en el que decreció bruscamente. Los mejores resultados para los modelos G y G15 (kappa igual a 0,91) se obtuvieron considerando la medida oob, tras eliminar el 80% de las características, es decir a partir de un

conjunto de 66 y 23 características, respectivamente. A partir del modelo G5 se obtuvo también un kappa igual a 0,91, pero en esta ocasión usando el índice de Gini, a partir de un conjunto de 23 variables. El mejor resultado, kappa igual a 0.92, se obtuvo para el modelo de tamaño de ventana igual a 31x31 (G31) y 34 variables texturales (70% reducción), elegidas en base a la medida oob. Cabe destacar que el resultado de la reducción de variables del modelo G31 fue más exacto que el modelo G y cualquier otro modelo de escala simple (G5 y G15), aun incluyendo todas las variables.

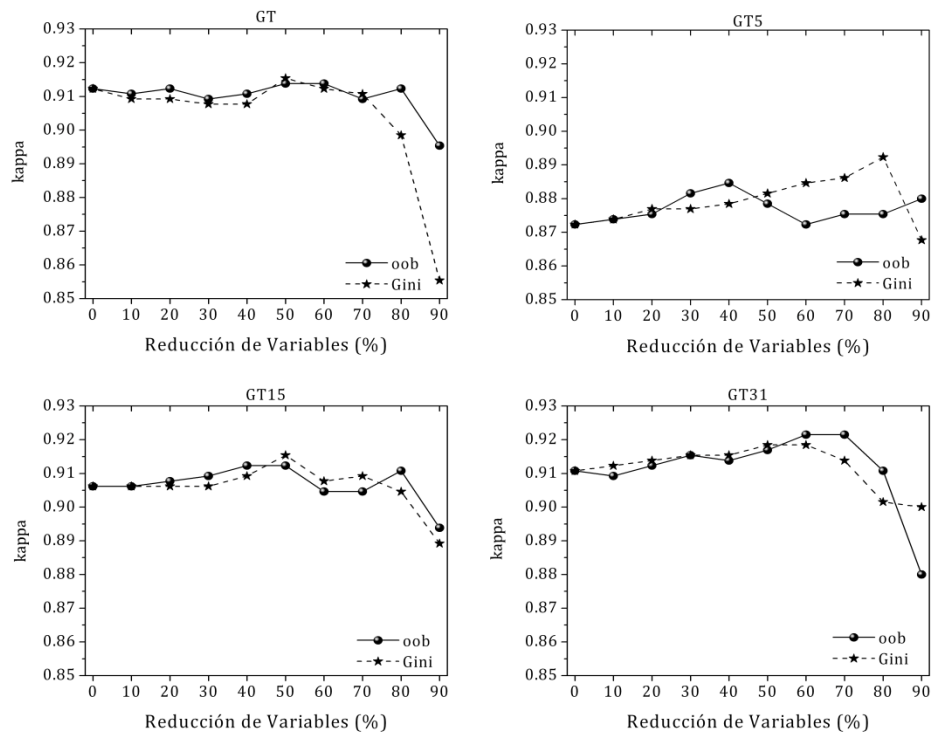


Figura 6.4. Exactitud cartográfica derivada de la selección de características llevada a cabo en base a la reducción de las variables menos importantes estimadas por las medidas oob y Gini.

## 4 Conclusiones

Esta investigación evalúa el potencial del uso de variables texturales geoestadísticas, tanto mono- como multi-estacionales, junto con una técnica de clasificación relativamente nueva (*Random Forest*), para clasificar un conjunto de características muy heterogéneas desde el punto de vista de su variabilidad espacial y espectral. Los resultados de este estudio aportan nuevos puntos de vista a la aplicación de *Random Forest* en la clasificación de cubiertas del suelo mediante la selección de características a partir de espacios de datos texturales con una alta dimensionalidad.

La metodología descrita en este capítulo hace uso de información textural para caracterizar las cubiertas del suelo de la Provincia de Granada. Para ello, se han calculado cinco tipos diferentes de funciones geoestadísticas texturales, para tres pasos diferentes y en base a tres tipos de vecindad correspondientes a escalas diferentes (978 variables). La clasificación de las cubiertas a partir de medidas texturales geoestadísticas, tanto mono- como multi-estacional, ha sido comparada con la de variables texturales basadas en GLCM. Los resultados de esta comparación muestran claramente que la textura geoestadística permite una mejor caracterización de la variabilidad espacial de las cubiertas objeto de estudio. La inclusión de las variables geoestadísticas en los modelos de clasificación RF incrementó significativamente la exactitud de los modelos entrenados únicamente a partir de datos espectrales. Este incremento significativo se ha obtenido, tanto para el modelo multi-escala, como para modelos de tamaños de ventana iguales a 5x5, 15x15 y 31x31. La diferencias entre el kappa obtenido por los modelos geoestadísticos y los GLCM también ha sido estadísticamente significativa para todos los casos.

Los modelos texturales geoestadísticos han conseguido una clasificación más exacta de las categorías más heterogéneas, y, por tanto, más difíciles de clasificar, como los cultivos leñosos, las zonas urbanas o los suelos desnudos, con incrementos en su exactitud del 31%, 29% y 18%, respectivamente. La clase urbana y los suelos desnudos han sido mejor caracterizados considerando tamaños de ventana de 5x5,

mientras que otras categorías más homogéneas como los cultivos leñosos y los tropicales lo fueron para tamaños de ventana de 31x31.

Las medidas de importancia relativa, oob y Gini, del clasificador RF han sido usadas para estimar la importancia de las características o variables en la clasificación general del área de estudio y de cada categoría de forma individual. Este estudio muestra como los variogramas pseudo-cruzados son las funciones texturales que tienen una mayor capacidad para la separabilidad entre las clases del área de estudio; en particular los PC multi-estacionales entre las bandas infrarrojas han sido unas de las características texturales más útiles. Aunque los madogramas son también muy importantes en la clasificación de ciertas categorías. Las clases con un marcado carácter estacional como los cultivos, fueron mejor clasificadas con la inclusión de PC multi-estacionales. Para los tamaños de ventana considerados, desde el punto de vista de los modelos de escala simple, los mayores tamaños de ventana obtuvieron mejores resultados que los de tamaños de ventana menor. Sin embargo, considerando el modelo multi-estacional, las características calculadas a partir de vecindades de 5x5 píxeles tuvieron una mayor importancia, que puede ser debida en parte a la sinergia de éstas con características correspondientes a otras escalas.

La selección y reducción de aproximadamente un tercio de las variables de entrada a los modelos RF ha conseguido atenuar el efecto de Hughes y ha dado lugar a modelos de clasificación más exactos. Los resultados obtenidos para el modelo G31 tras eliminar las características espurias han sido mejores que los del resto de modelos.

# CAPÍTULO 7.

## Análisis de Cambios en la Provincia de Granada entre 1998 y 2004

### **1 Introducción**

Durante las últimas décadas se ha producido una importante transformación de las áreas rurales y litorales de España. Este proceso de transformación, que afecta esencialmente al uso del suelo, es aún más notorio en las áreas periurbanas, donde el proceso de expansión urbana hace difícil compatibilizar el uso del suelo de estas regiones, que siendo eminentemente agrícolas se ven fuertemente influenciadas por los espacios urbanos limítrofes. Este es el caso que, desde hace años, viene dándose en la provincia de Granada, especialmente en las regiones costeras y, de forma también muy notoria, en la “Vega de Granada”. La Vega de Granada es un espacio geográfico de gran valor socio-económico en el que, históricamente, la agricultura ha vertebrado su estructura territorial. Sin embargo, el rápido crecimiento urbano de la ciudad de Granada, y de sus aglomeraciones periurbanas e industriales a partir de los años 80, ha provocado una rápida transformación de los espacios tradicionalmente agrarios, poniendo en peligro el desarrollo sostenible (Menor-Toribio, 1997).

La importancia de contar con información cartográfica precisa y actualizada que describa la naturaleza y extensión de los recursos agrícolas y naturales en general se está incrementando especialmente en las áreas metropolitanas sujetas a un rápido crecimiento. En estas situaciones es crucial contar con información geoespacial detallada de los patrones y tendencias de los usos del suelo, que constituya una base

de información para la toma de decisiones en la gestión y la ordenación territorial. En este contexto, en que se hace necesario el seguimiento de los cambios ambientales, que posibilite una planificación territorial adecuada y que sienta las bases para la conservación, al tiempo que garantice la pervivencia de los espacios naturales, la teledetección ha probado ser la técnica más eficiente y menos costosa (Fung y LeDrew, 1988).

Aunque el seguimiento de las cubiertas y usos del suelo, se puede realizar mediante muestreos e inventarios tradicionales, la teledetección proporciona grandes cantidades de información sobre la distribución de las cubiertas y sus cambios, que permite cartografiar áreas extensas con un bajo coste de tiempo y recursos económicos. Una forma de usar la teledetección para estudiar el medio ambiente es el uso de las técnicas de detección de cambios. La detección de cambios es el proceso de identificación de diferencias en el estado de un objeto o fenómeno observándolo en diferentes fechas (Singh, 1989). En teledetección, cuando se habla de cambios, son importantes tres aspectos: “detectar los cambios que han ocurrido”, “identificar la naturaleza del cambio” y “medir el área total de cambio” (Malila, 1980). La teledetección ha sido un método muy popular para monitorizar los cambios, debido a que tiene un gran potencial para el estudio de estos tres aspectos. La importancia de inventariar, cuantificar y hacer un seguimiento de los cambios en las características físicas de las cubiertas terrestres ha sido ampliamente reconocida por la comunidad científica internacional como un elemento clave en el estudio del cambio global (Fearnside, 2000; Foley et al., 2005; IPCC, 2000). En este contexto del análisis de los procesos de transformación territorial, la teledetección constituye una aproximación metodológica de indiscutible valor.

Las fotografías aéreas y las imágenes de satélite son los dos soportes de teledetección que han sido más usadas para la detección de cambios. La asunción de la que se parte en la detección de cambios con fotografía aérea e imágenes de satélite es que un cambio en la superficie terrestre se traduce en un cambio en la energía reflejada. Aunque existen otros factores que pueden cambiar la energía electromagnética detectada por el sensor, que no están asociados con un cambio del paisaje, sino con variaciones en las condiciones atmosféricas, en el ángulo solar y diferencias en la humedad del suelo (Singh, 1989). El uso de la teledetección como técnica de detección de cambios comenzó en los años 50. Los primeros estudios



usaban fotografías aéreas para el seguimiento de la expansión urbana (Avery, 1965; Richter, 1969; Wagner, 1963). El muestreo de campo y el levantamiento de planos eran muy costosos económicamente y poco prácticos para estudiar la expansión urbana. El uso de fotografías aéreas para detectar cambios resultó ser la forma más económica y factible de llevar a cabo esta tarea (Falkner, 1968). En un principio se aplicaron técnicas post-clasificación a las fotografías aéreas. Las imágenes una vez clasificadas eran comparadas visual o mecánicamente. Se adoptó una técnica llamada *flicker* o *blink*, heredada de los astrofísicos (Masry et al., 1975). El método *blink* muestra las fotos alternativamente, de modo que las áreas de cambio parpadean en la pantalla. Más recientemente, con el desarrollo de los sistemas de información geográfica (SIG), se aplicaron técnicas informáticas para eliminar el tedioso proceso de comparación (Lo y Shipman, 1990). Los primeros estudios de detección de cambios usaron técnicas para tratar problemas que son relevantes aun a día de hoy. Wagner (1963) usó una matriz de cambio para mostrar cambios en el uso del suelo, que también fue utilizada por Jensen (1993). Con el lanzamiento del satélite Landsat en 1972, las técnicas digitales de detección y análisis de cambios experimentaron un elevado desarrollo (Crapper y Hynson, 1983; Howarth y Boasson, 1983; Singh, 1989; Wickware y Howarth, 1981).

La detección de cambios en una superficie, a partir de imágenes de satélite obtenidas en fechas distintas, se hace a través de la aplicación de métodos y algoritmos numéricos que, en esencia, producen una imagen (o multi-imagen) en la que pueden analizarse los cambios observados. Esta imagen resultante debe ser analizada para determinar e interpretar los cambios producidos, o bien en el seguimiento de algún proceso natural (desertización) o antrópico (urbanización). Las metodologías utilizadas en el análisis de detección de cambios son variadas, algunas de ellas pueden verse en (Collins y Woodcock, 1996; Coppin et al., 2004; Kennedy et al., 2009; Lu et al., 2004; Mas, 1999; Rogan y Chen, 2004; Rogan et al., 2002; Singh, 1989).

## **2 Fundamentos de los métodos de detección y análisis de cambios**

La detección de los cambios es un proceso de identificación de los diferentes estados de un objeto o fenómeno observándolo en diferentes tiempos (Singh, 1989).

El análisis de cambios puede estar encaminado tanto a detectar cambios en los rasgos espectrales de la imagen como en los rasgos espaciales. Los primeros hacen referencia a modificaciones en la señal reflejada o emitida por una determinada superficie, como consecuencia de cambios de uso del suelo en la cubierta, o bien variaciones en la densidad o estado fenológico de la vegetación. En este sentido, la detección de cambios es útil en muchas aplicaciones como el análisis del cambio de los usos del suelo, seguimiento de los cultivos cambiantes, evaluación de la deforestación, estudio de los cambios en la fenología de la vegetación, evaluación de daños, detección de la vigorosidad del cultivo, etc. Los cambios espaciales implican transformaciones de la forma o el tamaño de las parcelas, y se analizan mediante técnicas de segmentación multi-temporal (Chuvieco, 2008). La premisa básica en la utilización de datos de satélite para la detección de cambios espectrales, es que los cambios en los usos del suelo tienen que resultar en cambios en los valores de radiancia y los cambios en la radiancia causados por los cambios en los usos del suelo tienen que ser significativos respecto a los cambios en la radiancia producidos por otros factores. Esos otros factores incluyen: diferencias en las condiciones atmosféricas, diferencias en el ángulo solar y diferencias en la humedad del suelo. El impacto de esos factores tiene que ser reducido parcialmente, seleccionando los datos apropiados y/o llevando a cabo la corrección atmosférica de los datos. Por ejemplo, trabajando con datos Landsat adquiridos en una misma fecha del año reduce problemas de las diferencias en el ángulo solar y los cambios en la fenología de la vegetación.

Muchos investigadores han usado datos de satélite para abordar problemas de detección de cambios de las cubiertas del suelo (Kennedy et al., 2009; Rogan y Chen, 2004). Estos métodos incluyen comparación entre clasificaciones de usos del suelo, clasificación multi-temporal, diferencia/ratio de imágenes, diferencia de índices de vegetación, análisis de componentes principales y análisis del vector de cambio.

Las técnicas de detección de cambios espectrales multi-temporales pueden agruparse en dos categorías principales. El primer grupo está compuesto por los métodos categóricos, también conocidos como técnicas post-clasificación, que consisten en el análisis comparativo de dos clasificaciones diferentes correspondientes a fechas distintas. El segundo taxón, correspondiente a cambios continuos, también conocido como técnicas de realce pre-clasificación, tiene por objetivo medir el grado de cambio producido en algún atributo relacionado con las cubiertas del suelo, que

pueda ser medido de forma continua, por ejemplo, la cantidad o la concentración de vegetación o cobertura urbana. Aunque, normalmente, estas medidas continuas de la magnitud del cambio son reagrupadas en categorías de cambio, lo cual disminuye su potencial frente a las técnicas discretas (Kennedy et al., 2009). La elección de la metodología de cambios a aplicar vendrá determinada por las necesidades del usuario.

## 2.1 Técnicas de realce de cambios pre-clasificación

### 2.1.1 Diferencia entre imágenes

La diferencia de imágenes es la técnica más ampliamente utilizada para la detección de cambios y ha sido aplicada en diferentes ambientes geográficos (Fung y LeDrew, 1988; Macleod y Congalton, 1998; Mas, 1999; Singh, 1986).

Es una técnica que sustrae el valor de un píxel de una determinada fecha ( $t$ ) del correspondiente a la misma banda de una imagen con fecha posterior ( $t$ ). Se aplica a imágenes previamente homogeneizadas radiométrica y geoméricamente, para producir una imagen residual que representa el cambio entre dos fechas, en la que las zonas estables presentarán valores cercanos a cero, mientras que las que hayan experimentado cambios ofrecerán valores significativamente distintos de cero (positivos o negativos).

$$Dx_{ij}^k = x_{ij}^k(t_2) - x_{ij}^k(t_1) + C \quad (7.1)$$

Donde  $x_{ij}^k$  es igual al valor del píxel en la banda  $k$ ,  $i$  y  $j$  son las coordenadas de fila y columna del píxel respectivamente,  $t_1$  y  $t_2$  son la primera y segunda fecha y  $C$  es una constante para obtener valores positivos en la operación.

Este procedimiento produce diferentes distribuciones para cada banda. En cada distribución, los píxeles que presentan cambios en la reflectancia se encuentran en los límites de la distribución, mientras que los píxeles que no presentan cambios en la reflectancia tienden a estar agrupados alrededor de la media.

### 2.1.2 Cocientes multi-temporales

La diferencia entre imágenes es una técnica simple para observar cambios entre fechas; si bien tiene el problema de reflejar únicamente las diferencias absolutas de un

modo equivalente, pero no ofrece la significación del cambio frente a los valores originales. Por ejemplo, una diferencia de 2 unidades entre el mismo píxel correspondiente a imágenes de diferentes fechas con valores 2 y 4 puede no ser equivalente a la misma diferencia de 2 unidades entre píxeles con valores 100 y 102. Si estos valores representasen niveles de vegetación, en el primer caso esa diferencia representaría el doble de biomasa, mientras que en el segundo caso la diferencia en el nivel de biomasa sería mínima. Para posibilitar una mejor interpretación de la magnitud del cambio, puede ser más conveniente en ocasiones emplear cocientes multi-temporales, que ofrecen una valoración relativa del cambio.

En esta técnica se dividen los píxeles equivalentes de las bandas de interés de dos imágenes de diferentes fechas corregidas:

$$Cx_{ij}^k = x_{ij}^k(t_1) / x_{ij}^k(t_2) \quad (7.2)$$

Donde  $x_{ij}^k$  es el valor del píxel situado en la fila  $i$  columna  $j$  de la banda  $k$  y  $t_1$  y  $t_2$  son las fechas inicial y final, respectivamente.

Para aquellas zonas en las que no se haya producido un cambio representativo el cociente toma valores próximos a 1, en las áreas de cambio el valor de la división será significativamente mayor o menor que 1, dependiendo de la naturaleza de los cambios entre las dos fechas.

El elemento crítico de esta metodología es la selección de valores apropiados del umbral, en los límites inferiores y superiores de la distribución que presenta los valores de cambios en los píxeles. Una práctica usual ha sido seleccionar arbitrariamente los valores del umbral, y examinarlos empíricamente para determinar si la detección de cambios ha sido realizada correctamente (Fung y LeDrew, 1988).

### 2.1.3 Regresión de imágenes

Las técnicas de regresión se emplean para estimar los niveles digitales de una determinada banda de una imagen, a partir de otra que está fuertemente correlacionada con ella. Esa asociación se mide a partir de unas observaciones comunes a ambas variables, a partir de las cuales se ajusta una función que las relaciona numéricamente.

Se supone que los píxeles de una fecha inicial ( $t_1$ ), están linealmente correlacionados con los píxeles correspondiente a la otra fecha ( $t_2$ ). De modo que, puede predecirse el valor de un píxel para la fecha final ( $\hat{x}_{ij}^k(t_1)$ ), considerando que no se hubiesen producido cambios, mediante la relación establecida entre  $x_{ij}^k(t_1)$  y  $x_{ij}^k(t_2)$ .

Teniendo en cuenta todo lo anterior, la diferencia entre los valores predichos por la regresión para la fecha 2 y los valores originales de tal fecha, sería igual a los cambios producidos en las cubiertas objeto de estudio (Eastman et al., 1995):

$$Rx_{ij}^k = \hat{x}_{ij}^k(t_2) - x_{ij}^k(t_1) + C \quad (7.3)$$

Para este caso también se aplica la técnica de los umbrales mencionada anteriormente. Como se ha visto previamente en el Capítulo 2, la regresión de imágenes puede ser usada también como técnica de pre-procesamiento, ya que elimina las diferencias producidas como consecuencia de las variaciones en las condiciones de adquisición de las imágenes a comparar. Singh (1986, 1989) dio cuenta de que el procedimiento de regresión fue ligeramente mejor que la técnica de diferencia uni-variante de imágenes, para detectar cambios en las superficies urbanas y cambios en las coberturas forestales tropicales.

### 2.1.4 Vectores multitemporales

Hasta este punto se han expuesto técnicas para el estudio del cambio a partir de imágenes únicas correspondientes a la misma estación. Sin embargo, puede haber ocasiones en las que se disponga o se requiera de dos conjuntos de datos para cada una de las fechas, es en este caso en el que puede aplicarse el análisis de vectores multi-temporales (He et al., 2011; Li y Xu, 2010; Malila, 1980; Ozyavuz et al., 2011; Xian y Homer, 2010).

Cada píxel tiene una localización en el espacio multidimensional determinado por las bandas espectrales, por lo que si representamos en un eje bidimensional la posición de un determinado píxel respecto a dos bandas originales de las escenas a comparar, la diferencia puede ser expresada por su distancia euclídea (magnitud del cambio):

$$Vx_{ij} = \sqrt{\left(x_{ij}^k(t_2) - x_{ij}^k(t_1)\right)^2 + \left(x_{ij}^l(t_2) - x_{ij}^l(t_1)\right)^2} \quad (7.4)$$

Donde  $x_{ij}^k(t_2)$  es el valor del píxel de coordenadas  $i$  y  $j$  para la banda  $k$  en la imagen de la fecha 2;  $x_{ij}^k(t_1)$  el valor del píxel de coordenadas  $i$  y  $j$  para la banda  $k$  en la imagen de la fecha 1;  $x_{ij}^l(t_2)$  el valor del píxel de coordenadas  $i$  y  $j$  para la banda  $l$  en la imagen de la fecha 2; y por último,  $x_{ij}^l(t_1)$  es el valor del píxel de coordenadas  $i$  y  $j$  para la banda  $l$  en la imagen de la fecha 1.

Es una técnica que incorpora no sólo la importancia del cambio, sino también la dirección de éste entre imágenes. En este sentido la dirección del vector contiene información sobre el tipo de cambio, y un valor de magnitud por encima de un umbral espectral determinado define la existencia del cambio.

Se representan en un eje bidimensional dos bandas originales, cada píxel viene definido por un punto. Si ese píxel cambia su cobertura entre dos fechas, también modificará su emplazamiento espectral. La magnitud del cambio vendrá dada por la longitud del vector que separa ambos puntos. El sentido del cambio se define por el ángulo que forma con el eje de referencia.

### 2.1.5 Componentes principales

El análisis de componentes principales (ACP) es una técnica estadística multivariante empleada especialmente para reducir la cantidad de información de que se dispone. Este tipo de análisis crea nuevas imágenes o componentes principales a partir de una selección de las bandas originales de una o varias escenas, eliminando las que contienen información redundante. Con esto se consiguen dos objetivos: imágenes mucho más contrastadas que las iniciales, y la reducción del volumen de los datos a tratar sin pérdida significativa de la información.

El análisis de componentes principales se puede efectuar de dos formas diferentes. La forma más común de aplicar un análisis de componentes principales orientado a clasificación es usar la matriz de varianza-covarianza para calcular los vectores propios; también puede llevarse a cabo un análisis de componentes estandarizado, que tiene en cuenta la matriz de correlación, asignando a cada banda el mismo peso para el cálculo de los vectores propios. No obstante, el segundo método

da mejores resultados en relación al ruido (Eastman et al., 1995; Eklundh y Singh, 1993).

En el caso de las aplicaciones multi-temporales el ACP se utiliza de un modo un tanto particular, ya que no se pretende retener la información común entre fechas, sino precisamente la que cambia. Además, es una técnica que puede tener una interpretación compleja, por lo que para conseguir resultados fiables es necesario un conocimiento en profundidad del área de estudio y de las componentes. Otra desventaja de este método es que únicamente se basa en las propiedades estadísticas de los datos, y por tanto, no puede ser extrapolado a datos o áreas de estudio diferentes.

### **2.1.6 Transformación Kauth Thomas multi-temporal**

Algunas de los problemas asociados al análisis de componentes principales para la detección de cambios se solventan con la transformación Kauth Thomas multi-temporal. Este índice se basa en la ortogonalización de un conjunto de datos multi-fecha (Collins y Woodcock, 1996). Esta técnica produce diferentes variables relacionadas con el cambio, a diferencia de otras que utilizan solo una (ej. diferencia en los índices de vegetación normalizados). De esta forma, a partir de las 12 bandas de un conjunto de datos Landsat TM se obtienen seis características de: brillo estable, verdor estable, humedad estable, cambios en brillo, cambios en verdor y cambios en humedad. Esta técnica se ha aplicado en diversos estudios (Rogan et al., 2002; Rogan et al., 2008), ya que no depende de la escena aplicada, puesto que el uso de los coeficientes de transformación hace posible su aplicación a regiones y fechas diferentes.

## **2.2 Análisis Compuesto**

Este método consiste en agrupar todas las bandas o variables en un único conjunto de datos multi-fecha, el cual puede estar compuesto tanto por las bandas brutas del satélite, como por transformaciones de éstas (Yuan y Elvidge, 1998). A continuación, se aplica una metodología de clasificación para obtener las categorías de cambio deseadas. La metodología de clasificación a aplicar puede ser tanto supervisada, si se dispone de información de campo sobre las categorías de cambio, como no supervisada, si no se dispone de esta información, lo cual suele ser lo

habitual. A diferencia de los demás métodos de realce de cambios, esta metodología no necesita una normalización robusta entre las imágenes (Sección 4.1.1.1 del Capítulo 2), aunque sus resultados son difíciles de interpretar y, generalmente, son sólo aplicables al espacio de datos utilizado (Coppin et al., 2004; Fung y Siu, 2000). Además, la principal desventaja de esta metodología es que las clases asociadas a zonas sin cambio suelen ser mucho más abundantes, y, por tanto, enmascaran la varianza estadística de las clases de cambio.

### **2.3 Técnicas post-clasificación.**

La detección de cambios a partir de técnicas de clasificación puede abordarse comparando imágenes previamente clasificadas, o clasificando conjuntamente imágenes de distintas fechas. De esta forma, el analista puede producir mapas de cambio y sus correspondientes matrices de confusión, por lo que es posible estudiar los tipos de transiciones que intervienen en los cambios producidos entre las diferentes clases. De esta forma, los cambios se refieren a las categorías cartográficas y, por tanto, son fáciles de interpretar por los gestores medio-ambientales (Crabtree et al., 2009; Nagler et al., 2009; Nemani et al., 2009; Svancara et al., 2009; Townsend et al., 2009; Wang et al., 2009b).

Estas técnicas proporcionan información sobre la naturaleza del cambio, mediante la comparación de dos mapas, obtenidos mediante un proceso de clasificación automático o supervisado (Hepcan et al., 2011; Potapov et al., 2011; Yuan et al., 2005b). La exactitud de esta técnica depende de la exactitud de las clasificaciones originales, por lo que el mapa de cambios será tan exacto como lo sean las clasificaciones previas, ya que su exactitud será igual al producto de las exactitudes de cada clasificación individual (Mas, 1999; Rogan y Chen, 2004). La principal ventaja es que estas técnicas son capaces de producir información descriptiva del tipo de cambio, y no requieren que las imágenes sean normalizadas con anterioridad, ya que suprimen los errores introducidos por el efecto atmosférico o las diferencias en la calibración del sensor. Algunos aspectos negativos de estas técnicas son, el tiempo empleado en clasificar exactamente las imágenes y el hecho de que algunos errores producidos en la clasificación pasen a formar parte del mapa de cambios. Por tanto, la precisión del método depende de la exactitud de las



clasificaciones en cada una de las fechas, y los errores son multiplicativos (Lunetta et al., 1991; Serra et al., 2003). Por lo tanto, se pueden producir indicaciones erróneas de cambio. De ahí la importancia de obtener una clasificaciones individuales para cada fecha lo más exactas posibles (Capítulo 3).

### **3 Metodología**

Como se ha visto en la Sección 2, hay diferentes metodologías para detectar y analizar los cambios que se han producido en un área, a partir de imágenes de distintas fechas: el análisis comparativo de dos clasificaciones independientes y el análisis simultáneo de datos multiespectrales o técnicas de realce de cambios. Ambas técnicas cuentan con limitaciones. Así, las técnicas basadas en clasificación no detectan diferencias sutiles dentro de una clase vegetal y el mapa final de cambios acumula los errores de las clasificaciones independientes, a partir de las cuales se ha elaborado. Por otro lado, los métodos cuantitativos no aportan información sobre la naturaleza de las transiciones que se han producido entre las diferentes clases que dan lugar al cambio y, por tanto, son de menos utilidad para los gestores medioambientales.

La idoneidad de aplicar una metodología u otra, viene determinada por las necesidades de la aplicación. En este trabajo se ha optado por desarrollar una metodología basada en el análisis de cambios post-clasificación. Por un lado, esta metodología proporciona información detallada sobre las transiciones producidas entre las cubiertas del suelo, que puede ser de gran utilidad para los gestores locales. Por otro lado, no necesita la aplicación de una normalización radiométrica robusta, que en ocasiones puede ser una complicación añadida, especialmente si se trabaja con imágenes multi-estacionales (Sección 2.1.1 del Capítulo 2).

Como se ha argumentado en secciones anteriores, si se opta por la aplicación de una metodología basada en el análisis de cambios, es fundamental que las clasificaciones implicadas en este procedimiento sean lo más exactas posibles, ya que la exactitud del mapa de cambios final dependerá de las exactitudes individuales de los mapas a comparar. Por este motivo, basándonos en los resultados obtenidos en el Capítulo 3, se optó por aplicar el clasificador Random Forest al conjunto de variables

espectrales y auxiliares, que han sido identificadas a lo largo de esta Tesis como las que mejor caracterizan las cubiertas del suelo del área de estudio.

La Tabla 7.1 muestra las variables predictoras utilizadas en las clasificaciones de 1998 y 2004, entre las que se encuentran la temperatura de superficie (Capítulo 5), las variables espectrales derivadas de la transformación de Kauth-Thomas, las variables derivadas del modelo digital de elevaciones del área de estudio, y por último, una selección de variables texturales tanto mono- como multi-estacionales (Capítulo 6). Puesto que como se vio en el Capítulo 3, el error de clasificación de Random Forest converge a partir de un número elevado de árboles, en la clasificación se utilizaron modelos Random Forest compuestos por 5000 árboles de decisión y se consideraron todas las combinaciones posibles de variables aleatorias para la división de cada nodo (1 a 38).

Los mapas obtenidos del proceso de clasificación expuesto en el párrafo anterior fueron comparados entre sí, para crear un mapa final que represente todas las transiciones ocurridas en las cubiertas de la Provincia de Granada entre 1998 y 2004. A partir de dicho mapa se creó también la matriz de cambios entre dichas fechas, para hacer posible la cuantificación de su extensión. Para evaluar la exactitud cartográfica de los cambios se multiplicaron las exactitudes de las clasificaciones individuales para estimar la exactitud esperada del mapa de cambios. Pese a que existen otras aproximaciones más rigurosas, basadas en muestreos aleatorios de las áreas clasificadas como cambios, su aplicación es muy compleja cuando el número de categorías es elevado. Por otro lado, diversos estudios avalan la fiabilidad del método basado en la multiplicación de exactitudes individuales cuando no se utilizan más de dos fechas en el análisis de cambios (Yuan y Elvidge, 1998; Yuan et al., 2005b).

Tabla 7.1. Variables utilizadas en las clasificaciones correspondientes a los años 1998 y 2004.

Espectrales	Brillo de Verano	Verdor de Verano	Humedad de Verano	
	Brillo de Primavera	Verdor de Primavera	Humedad de Primavera	
	Temperatura de Superficie			
MDE	Elevación	Pendiente	Orientaciones	
Texturales	Verano	Variograma TM4	Variograma TM7	Madrograma TM1
		Madrograma TM4	Rodograma TM4	Pseudo-cruzado TM1-TM2
		Pseudo-cruzado TM1-TM2	Pseudo-cruzado TM1-TM3	Pseudo-cruzado TM1-TM4
		Pseudo-cruzado TM2-TM4	Pseudo-cruzado TM2-TM7	Pseudo-cruzado TM3-TM4
		Pseudo-cruzado TM3-TM5	Pseudo-cruzado TM3-TM7	
	Primavera	Rodograma TM7	Pseudo-cruzado TM1-TM2	Pseudo-cruzado TM1-TM3
		Pseudo-cruzado TM1-TM7	Pseudo-cruzado TM2-TM3	Pseudo-cruzado TM2-TM5
		Pseudo-cruzado TM3-TM4	Pseudo-cruzado TM4-TM5	Pseudo-cruzado TM4-TM7
	Multi-estacionales	Pseudo-cruzado TM1-TM1	Pseudo-cruzado TM2-TM2	Pseudo-cruzado TM3-TM3
		Pseudo-cruzado TM4-TM4	Pseudo-cruzado TM5-TM5	Pseudo-cruzado TM7-TM7

## 4 Resultados

### 4.1 Generación de los mapas clasificados de 1998 y 2004

La Figura 7.1 y Figura 7.2 muestran los mapas de las cubiertas del suelo obtenidos para 1998 y 2004, respectivamente. Los resultados de la evaluación de su exactitud cartográfica fueron muy positivos, a la luz de la complejidad del área de estudio y el elevado número de categorías existentes. La exactitud cartográfica para ambos mapas fue muy similar, con exactitudes globales e índices kappa iguales a 0.92 y 0.91 para 1998 y 0.93 y 0.92 para 2004, respectivamente.

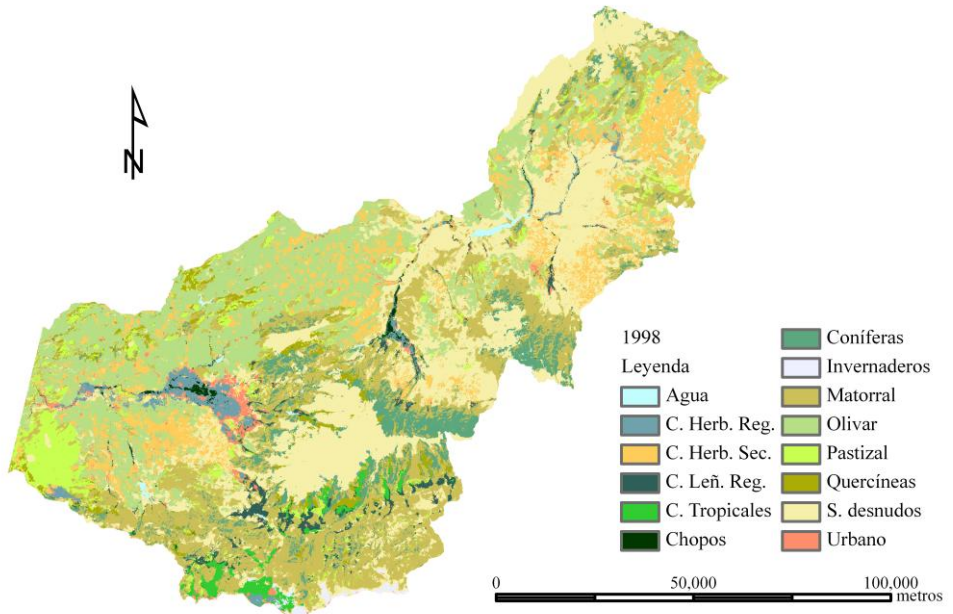


Figura 7.1. Mapa clasificado correspondiente a 1998.

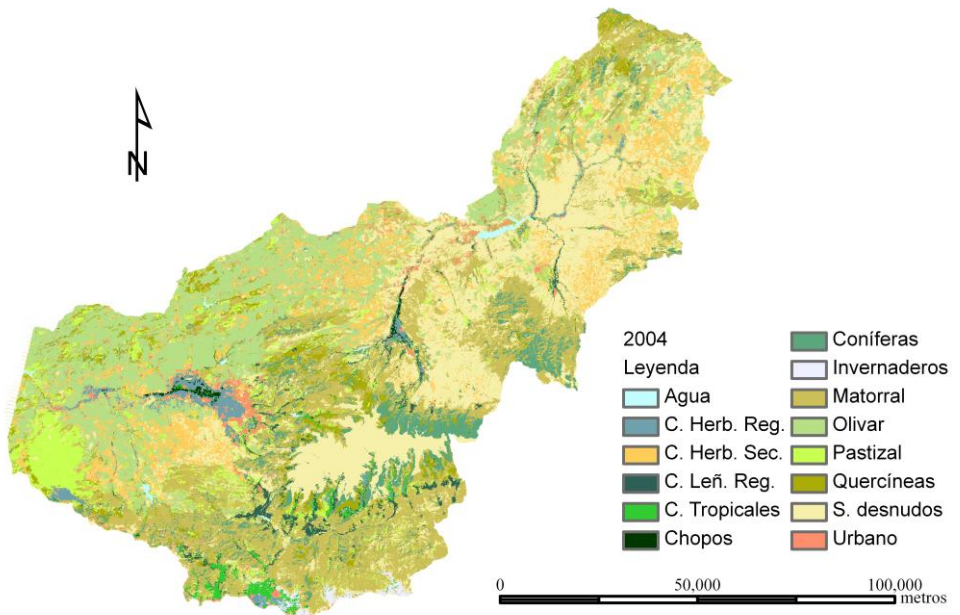


Figura 7.2. Mapa clasificado correspondiente a 2004.

Tabla 7.2. Estadísticos de la exactitud cartográfica por categorías de las clasificaciones de 1998 y 2004.

Id. Clase	Clase	1998			2004		
		E. Omisión	E. Comisión	K	E. Omisión	E. Comisión	K
1	Urbano	0.1	0.08	0.89	0.06	0.04	0.94
2	Chopos	0.02	0	0.98	0	0	1
3	Coníferas	0.12	0.12	0.87	0.12	0.15	0.87
4	Invernaderos	0.02	0	0.98	0.02	0.02	0.98
5	Matorral	0.24	0.19	0.74	0.18	0.18	0.81
6	Olivar	0.1	0.12	0.89	0.04	0.04	0.96
7	Pastizal	0.02	0.06	0.98	0.12	0.02	0.87
8	Quercíneas	0.18	0.16	0.81	0.14	0.16	0.85
9	C. Herb. Reg.	0.1	0.12	0.89	0.02	0.04	0.98
10	C. Leñ. Reg.	0.08	0	0.91	0.12	0.02	0.87
11	C. Herb. Sec.	0	0.04	1	0	0.06	1.00
12	S. desnudos	0.14	0.16	0.85	0.14	0.16	0.85
13	C. Tropicales	0.04	0.11	0.96	0.06	0.11	0.94
14	Agua	0	0	1	0	0	1

La Tabla 7.3 y Tabla 7.4 muestran las matrices de confusión para las cartografías de 1998 y 2004, respectivamente. A partir de estas tablas se pueden deducir los orígenes en los errores de comisión y omisión de las categorías de estudio. Así pues, se aprecia como algunas de las áreas correspondientes a matorral fueron clasificadas como coníferas, quercíneas o suelos desnudos en ambos mapas (errores de omisión) y viceversa (errores de comisión). Del mismo modo, las quercíneas también se confundieron con coníferas y matorral. Estos errores se deben a la baja separabilidad inter-clase entre estas categorías. Por un lado, las clases matorral, quercíneas y coníferas, tienen el mismo ámbito de distribución y en ocasiones aparecen entremezcladas, por lo que puede haber un número relativamente elevado de píxeles de mezcla para estas categorías (píxeles cuyo nivel digital es igual al promedio de la respuesta espectral de categorías diferentes). Por otro lado, en ocasiones la densidad de la cobertura vegetal de estas categorías es relativamente escasa, por lo que alta reflectividad de la componente de suelo desnudo puede enmascarar el comportamiento de dichas coberturas vegetales, lo que las hace indistinguibles de los suelos, desde el punto de vista del proceso de clasificación (Berberoglu et al., 2000).

Tabla 7.3. Matriz de confusión de la mejor clasificación obtenida para la imagen de 1998.

		Datos de Referencia														
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	TOT.
1	45	0	0	0	1	2	0	0	0	0	0	1	0	0	0	49
2	0	49	0	0	0	0	0	0	0	0	0	0	0	0	0	49
3	0	0	44	0	2	0	0	4	0	0	0	0	0	0	0	50
4	0	0	0	49	0	0	0	0	0	0	0	0	0	0	0	49
5	0	0	2	0	38	0	0	3	0	0	0	4	0	0	0	47
6	0	0	0	0	2	45	0	2	0	0	0	2	0	0	0	51
7	0	0	0	0	2	1	49	0	0	0	0	0	0	0	0	52
8	0	0	4	0	3	0	0	41	1	0	0	0	0	0	0	49
9	1	0	0	0	0	0	0	0	45	3	0	0	2	0	0	51
10	0	0	0	0	0	0	0	0	0	46	0	0	0	0	0	46
11	0	0	0	0	0	1	1	0	0	0	50	0	0	0	0	52
12	4	0	0	1	2	1	0	0	0	0	0	43	0	0	0	51
13	0	1	0	0	0	0	0	0	4	1	0	0	48	0	0	54
14	0	0	0	0	0	0	0	0	0	0	0	0	0	50	0	50
TOT.	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	700
E. G.	Kappa															
0.92	0.91															

Tabla 7.4. Matriz de confusión de la mejor clasificación obtenida para la imagen de 2004.

		Datos de Referencia														
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	TOT.
1	47	0	0	0	0	0	0	0	0	0	0	2	0	0	0	49
2	0	50	0	0	0	0	0	0	0	0	0	0	0	0	0	50
3	0	0	44	0	4	0	0	3	0	1	0	0	0	0	0	52
4	0	0	0	49	0	0	0	0	0	0	0	1	0	0	0	50
5	0	0	1	0	41	0	2	4	0	0	0	2	0	0	0	50
6	0	0	0	0	0	48	1	0	0	0	0	1	0	0	0	50
7	0	0	0	0	0	0	44	0	0	0	0	1	0	0	0	45
8	0	0	5	0	2	1	0	43	0	0	0	0	0	0	0	51
9	0	0	0	0	0	0	0	0	49	0	0	0	2	0	0	51
10	0	0	0	0	0	0	0	0	0	44	0	0	1	0	0	45
11	0	0	0	0	0	0	3	0	0	0	50	0	0	0	0	53
12	3	0	0	1	3	1	0	0	0	0	0	43	0	0	0	51
13	0	0	0	0	0	0	0	0	1	5	0	0	47	0	0	53
14	0	0	0	0	0	0	0	0	0	0	0	0	0	50	0	50
TOT.	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	700
E. G.	Kappa															
0.93	0.92															

La Tabla 7.5 muestra la extensión de las categorías cartografiadas, así como el porcentaje que suponen respecto al total del área de estudio. Como puede observarse, las cubiertas del suelo representadas en ambos mapas tienen extensiones parecidas. Los suelos desnudos fueron la categoría más abundante en el área, con 3.325 km<sup>2</sup> en 1998 (26.66 %) y 3.065 km<sup>2</sup> en 2004 (24.58 %), seguidos del matorral y el olivar, con 2.786 y 2.516 (22,34 % y 20,17%) y 3.161 y 2.244 km<sup>2</sup> (25,34 y 17,99 %) para 1998 y 2004, respectivamente. Por tanto, el total de estas tres categorías supondría el 69.17 % del mapa clasificado de 1998 y el 67,91 % del de 2004. La suma de los cultivos en secano (considerando todo el olivar como de secano y los cultivos herbáceos), dio como resultado una superficie en secano igual a 3.819,4 km<sup>2</sup> (30,62 %) de la provincia en 1998 y de 3.342,41 (26,79 %) en 2004. Por otro lado, las zonas en regadío, que engloban las ocupadas por chopos, cultivos tropicales y cultivos herbáceos y leñosos en regadío, ocuparon una extensión igual a 640,7 km<sup>2</sup> (5,14%) en 1998 y 593,11 km<sup>2</sup> (4,75 %) en 2004. La superficie total de tierras agrícolas, suma de los cultivos en secano y regadío, junto con los invernaderos, fue igual a 4.509,5 km<sup>2</sup> (36,15 %) en 1998 y de 3.994,18 km<sup>2</sup> (32,01 %). Por otro lado la vegetación natural, coníferas, matorral y pastizal, tuvo una extensión igual a 4.416 km<sup>2</sup> (35 %) en 1998 y de 5.132 km<sup>2</sup> (41 %) en 2004. Por último, la clase urbana ocupó una extensión de 185,25 km<sup>2</sup> (1,49 %) en 1998 frente a 244,43 en 2004 (1,96 %).

Tabla 7.5. Estadísticas de las categorías de los mapas de 1998 y 2004

Id. Clase	Clase	1998			2004		
		Nº píxeles	%	Área (km <sup>2</sup> )	Nº píxeles	%	Área (km <sup>2</sup> )
1	Urbano	205.832	1,49	185,25	271.589	1,96	244,43
2	Chopos	46.915	0,34	42,22	34.571	0,25	31,11
3	Coníferas	820.700	5,92	738,63	771.628	5,57	694,47
4	Invernaderos	54.594	0,39	49,13	65.183	0,47	58,66
5	Matorral	3.095.373	22,34	2.785,84	3.512.040	25,34	3.160,84
6	Olivar	2.795.213	20,17	2.515,69	2.493.581	17,99	2.244,22
7	Pastizal	704.341	5,08	633,91	915.463	6,61	823,92
8	Quercíneas	285.944	2,06	257,35	502.835	3,63	452,55
9	C. Herb. Reg.	264.353	1,91	237,92	261.126	1,88	235,01
10	C. Leñ. Reg.	241.238	1,74	217,11	239.870	1,73	215,88
11	C. Herb. Sec.	1.448.566	10,45	1.303,71	1.220.207	8,80	1.098,19
12	S. desnudos	3.694.570	26,66	3.325,11	3.405.703	24,58	3.065,13
13	C. Tropicales	159.686	1,15	143,72	123.451	0,89	111,11
14	Agua	40.905	0,30	36,81	40.983	0,30	36,88

### 4.1.1 Importancia de las variables en los modelos de clasificación

El algoritmo de clasificación Random Forest (Sección 3.1.2 del Capítulo 3) permite la estimación de la importancia de cada variable en la clasificación de las cubiertas del suelo. Esta estimación de significatividad se hace en base a dos medidas de importancia diferentes, el decrecimiento que se produciría, si se eliminase de los datos de entrada la variable objeto de estudio, en la exactitud del conjunto OOB y en el índice de Gini (Breiman, 2001; Cutler et al., 2007; Chan y Paelinckx, 2008; Gislason et al., 2006). La Figura 7.3 muestra la significatividad de las 10 variables más relevantes de los modelos de clasificación, aunque cabe mencionar que pese a que solo se muestran diez variables, en la clasificación, y por tanto, en la estimación de la importancia, se consideraron las 38 variables que se detallan en la Tabla 7.1. Las variables más importantes para la clasificación del conjunto de las categorías del área de estudio fueron las bandas resultantes de la transformación de Kauth Thomas, la elevación y las medidas texturales derivadas del variograma pseudo-cruzado, calculado entre algunas bandas de la imagen de verano, en especial la banda del infrarrojo cercano (Figura 7.3). Como puede observarse a partir de la gráfica, la importancia de cada una de las variables en el modelo de clasificación de 2004, respecto a 1998, fue mayor (Figura 7.3 C y D); es decir, el impacto en la clasificación de la eliminación de una de ellas sería mayor para el modelo de 2004 que para el modelo de 1998. Estas diferencias pudieron deberse en parte a una mayor complejidad, consecuencia de cambios ambientales en las cubiertas, y/o a diferencias en las áreas de entrenamiento utilizadas en la clasificación. Pese a que el orden de importancia puede variar ligeramente entre ambas fechas, en términos generales, las variables más importantes fueron las mismas, a excepción de la medida textural derivada del variograma pseudo-cruzado de las bandas del infrarrojo cercano de primavera y verano de 1998 (Figura 7.3 A), y el madograma de la banda TM1 de las imágenes de verano de 2004 (Figura 7.3 C y D). El patrón de importancia relativa estimado a partir del subconjunto OOB fue ligeramente diferente al estimado por el índice de Gini; así la variable más importante para el primer caso fue el verdor de primavera, mientras que para el segundo, lo fue el brillo de verano.

La Tabla 7.6 muestra la contribución de las variables a la clasificación de cada categoría cartográfica. En general, se aprecia la misma tónica en la distribución de la



importancia relativa que en el modelo de clasificación general, aunque para algunas categorías destacaron especialmente las variables derivadas del MDT y de transformaciones texturales. La elevación fue la variable más importante para los cultivos leñosos en regadío, que se presentan fundamentalmente en la ladera sur de Sierra Nevada, así como para los invernaderos y los cultivos tropicales, localizados en zonas más bajas, concretamente en la costa tropical. La pendiente del terreno tuvo una importancia relativa mayor para los chopos y cultivos herbáceos, situados en las zona llanas de las vegas de los ríos Genil, Fardes y Guadix, Los variogramas cruzados multi-estacionales tuvieron un mayor peso en la clasificación de las cubiertas relacionadas con cultivos, como los cultivos herbáceos en regadío y en secano. Por último, las variables texturales de la banda del infrarrojo medio de las imágenes de primavera y verano también desempeñaron un papel importante en la clasificación de las áreas urbanas.




Figura 7.3. Medidas de importancia de las 10 variables más significativas para la clasificación de 1998 (A y B) y de 2004 (C y D). VER: verano, PRI: primavera, ME: multi-estacional, M: madograma y PC: variograma pseudo-cruzado.

Tabla 7.6. Medidas de importancia de las 10 variables más significativas para la clasificación de las categorías de los mapas de 1998 y de 2004. VER: verano, PRI: primavera, ME: multi-estacional, V: variograma, R: rodograma, M: madograma y PC: variograma pseudo-cruzado

1998													
1	2	3	4	5	6	7	8	9	10	11	12	13	14
Ver. Verd.	Ver. Hum.	Ver. Brillo	Ver. Hum.	Ver. Brillo	Ver. Verd.	Pri. Verd.	Ver. Brillo	ME PC4	Elev.	Pri. Verd.	Ver. Verd.	Elev.	Ver. Brillo
Pri. Verd.	Ver. Brillo	Pri. Brillo	Ver. Brillo	Ver. Hum.	Pri. Verd.	Ver. Brillo	Pri. Brillo	Ver. Verd.	Ver. Verd.	Pri. Hum.	Pri. Verd.	Ver. Verd.	Ver. Hum.
Pri. Hum.	Pri. Verd.	Ver. Hum.	Elev.	Ver. Verd.	Ver. Brillo	Ver. Hum.	Elev.	Elev.	Ver. Hum.	Ver. PC13	Pri. Brillo	Ver. Brillo	Pri. Brillo
Ver. Hum.	Ver. Verd.	Elev.	Ver. Verd.	Pri. Verd.	Ver. Hum.	Ver. Verd.	Ver. Hum.	Pri. Verd.	Ver. Brillo	Ver. Hum.	Ver. Brillo	Ver. R4	Pri. Verd.
Pri. Brillo	Pri. Brillo	Pri. Hum.	Pri. Hum.	Ver. PC34	ME PC6	Ver. PC56	Ver. PC34	Ver. Brillo	ME PC4	Ver. Verd.	Pri. PC12	Ver. Hum.	Ver. Verd.
Ver. Brillo	Elev.	Ver. Verd.	Pri. Brillo	Ver. PC24	Pri. Hum.	Pri. Brillo	Ver. Verd.	Ver. Hum.	Ver. R4	Pri. Brillo	Ver. PC34	Ver. M4	Pri. Hum.
Ver. V6	Pri. Hum.	Ver. PC24	Ver. M1	Ver. PC14	T <sup>a</sup>	Pri. Hum.	Pri. Verd.	Ver. PC34	Pri. Verd.	Ver. Brillo	Ver. PC24	Pri. Verd.	Elev.
Pri. R6	Ver. PC34	Ver. PC14	Ver. PC12	Pri. Hum.	Ver. PC34	Elev.	Ver. R4	Ver. PC14	Ver. M4	Pri. PC34	Elev.	Ver. V4	T <sup>a</sup>
Ver. M1	Ver. PC24	Ver. R4	Ver. M4	Pri. Brillo	Ver. PC14	Ver. R4	Ver. PC24	Pri. Hum.	Pri. Brillo	ME PC3	Pri. PC13	ME PC4	Ver. PC34
Ver. R4	Ver. PC14	Ver. PC34	Ver. V4	Pri. PC34	Ver. PC24	Ver. PC12	Ver. M4	Ver. PC24	Pri. Hum.	ME PC5	Ver. PC14	Pri. Brillo	Ver. PC24
2004													
1	2	3	4	5	6	7	8	9	10	11	12	13	14
Ver. Brillo	Ver. Brillo	Ver. Brillo	Elev.	Ver. Brillo	Ver. Brillo	Pri. Verd.	Ver. Brillo	Ver. Brillo	Elev.	Pri. Verd.	Ver. Brillo	Elev.	Ver. Brillo
Pri. Verd.	Elev.	Ver. Hum.	Ver. Brillo	Ver. Verd.	Ver. Verd.	Ver. Brillo	Elev.	Ver. Verd.	Ver. Brillo	Ver. Brillo	Ver. Verd.	Ver. Brillo	Ver. Verd.
Ver. Verd.	Ver. Hum.	Ver. Verd.	Ver. Hum.	Ver. Hum.	Pri. Verd.	Ver. Hum.	Ver. Verd.	Elev.	Ver. Verd.	Ver. Hum.	Pri. Verd.	Ver. Verd.	Ver. Hum.
Ver. Hum.	Ver. Verd.	Elev.	Ver. Verd.	Pri. Verd.	Ver. Hum.	Pri. PC23	Ver. Hum.	Pri. Verd.	Ver. Hum.	Pri. Hum.	Elev.	Ver. Hum.	Pri. Verd.
Pri. R6	Pend.	Ver. PC24	Ver. M1	Elev.	Pri. PC23	Ver. Verd.	Pri. Verd.	Pend.	Pri. Hum.	Pri. Brillo	Ver. PC24	Ver. PC12	Elev.
Pend.	Pri. Verd.	Pri. Hum.	Pri. Hum.	Pri. Hum.	Ver. PC14	Pri. Hum.	Ver. PC24	Ver. Hum.	Ver. PC14	Ver. Verd.	Pri. Brillo	Pri. Verd.	Pri. Brillo
Pri. Hum.	Ver. PC14	Ver. PC14	Pri. PC16	Ver. PC14	Pri. Brillo	Ver. PC14	Ver. PC26	ME PC4	Pend.	Elev.	Ver. PC34	Pri. Brillo	Ver. M1
Ver. V6	Ver. PC24	Pri. Verd.	Pri. Brillo	Ver. PC24	Pri. Hum.	Ver. PC56	Ver. R4	Ver. V4	Pri. Verd.	Ver. PC12	Ver. PC26	Ver. R4	Ver. PC14
Ver. M1	Ver. PC34	Pri. Brillo	Pri. Verd.	Pri. Brillo	Elev.	Elev.	Ver. PC34	Pri. Brillo	Pri. Brillo	ME PC5	Ver. PC14	Ver. V4	Pri. Hum.
Pri. Brillo	Ver. PC26	Ver. PC26	Ver. PC12	Pend.	Ver. PC24	Pri. Brillo	T <sup>a</sup> Superf.	Ver. PC14	Ver. R4	ME PC6	Pri. PC23	T <sup>a</sup>	Ver. PC24

## 4.2 Análisis de cambios entre 1998 y 2004

La exactitud global del mapa de cambios obtenido fue igual al 86%, resultado de multiplicar las exactitudes de las clasificaciones individuales de 1998 y 2004. El porcentaje de aciertos del mapa resultado puede considerarse como muy satisfactorio, dada la complejidad del área a clasificar, debido a su extensión y al elevado número de categorías. La Figura 7.4 muestra los cambios producidos entre 1998 y 2004. La clase urbano se incrementó en 59,18 km<sup>2</sup> (31,95 %), los invernaderos 9,53 km<sup>2</sup> (19,40%), el matorral 375 km<sup>2</sup> (13,46 %), el pastizal 190,01 km<sup>2</sup> (29,97 %), las quercíceas 195,2 km<sup>2</sup> (75,85 %) y los cultivos herbáceos y leñosos en regadío y los cuerpos de agua permanecieron con aproximadamente la misma extensión, mientras que, los chopos decrecieron 11,11 km<sup>2</sup> (23,61 %), las coníferas 44,15 km<sup>2</sup> (5,98 %), el olivar 271,47 km<sup>2</sup> (10,79 %), los suelos desnudos 259,98 km<sup>2</sup> (7,82 %), los cultivos herbáceos en secano 205,52 km<sup>2</sup> (15,76 %) y por último, los tropicales 32,61 km<sup>2</sup> (22,69 %). Aunque las quercíceas y el matorral pueden fluctuar considerablemente en un período de tiempo de seis años, estas variaciones tan significativas, en especial para las quercíceas, pudieron deberse en parte a errores en las clasificaciones, puesto que estas categorías presentaron los mayores errores de comisión y omisión para ambas fechas (Tabla 7.2).




Figura 7.4. Cambios netos en las cubiertas del suelo entre 1998 y 2004.

Para una mejor evaluación de los resultados de las conversiones de las cubiertas del suelo, la Tabla 7.7 muestra la matriz de cambios en las cubiertas entre 1998 y 2004. En esta tabla las áreas que permanecen constantes se presentan en la diagonal principal, mientras que los cambios se presentan a ambos lados de dicha diagonal. Los resultados indican que en el período de seis años estudiado, la práctica totalidad de los

incrementos experimentados en la clase urbano, invernaderos y matorral provino de conversiones de suelos desnudos (59 km<sup>2</sup>, 8 km<sup>2</sup> y 375 km<sup>2</sup>, respectivamente). Los suelos desnudos y el matorral aportaron en términos absolutos 48 y 50 km<sup>2</sup> al incremento del pastizal. El aumento de las quercíneas se produjo fundamentalmente a partir de conversiones provenientes de suelos desnudos (71 km<sup>2</sup>), coníferas (55 km<sup>2</sup>) y matorral (36 km<sup>2</sup>). El decrecimiento de los chopos estuvo vinculado principalmente a un aumento de los cultivos herbáceos en regadío (3 km<sup>2</sup>) y olivar (2 km<sup>2</sup>). El decrecimiento de la categoría olivar en 2004 pudo estar debido a una sobreestimación del olivar en 1998, en detrimento de los suelos desnudos (ver errores de comisión para el olivar en la clasificación de 1998; Tabla 7.2). Por otro lado, 177 km<sup>2</sup> que permanecían en barbecho en 1998 y, por tanto, fueron entonces clasificados como suelos desnudos fueron cultivados en 2004 (c. herbáceos en secano). Por último, el decrecimiento en la extensión de los cultivos tropicales se debió a pequeños aumentos en el resto de categorías de vegetación, en especial de cultivos herbáceos en regadío (9 km<sup>2</sup>).

Tabla 7.7. Matriz de cambios entre las clasificaciones de 1998 y 2004 (km<sup>2</sup>)

		Clasificación 1998														TOT.
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	
Clasificación 2004	1	88	1	0	1	8	38	1	0	10	1	15	79	1	0	244
	2	0	17	0	0	0	0	0	0	11	1	0	0	0	0	31
	3	0	0	512	0	102	2	0	18	0	3	0	56	0	0	694
	4	2	0	0	38	2	0	0	0	1	0	0	12	4	0	59
	5	12	0	119	3	2134	66	73	36	1	32	15	658	10	1	3161
	6	26	2	0	0	30	1655	56	8	24	6	274	161	2	0	2244
	7	13	1	1	0	123	74	390	9	6	22	42	135	9	0	824
	8	1	1	73	0	72	30	11	165	4	15	4	73	3	0	453
	9	7	14	0	1	2	12	1	3	140	7	17	14	17	0	235
	10	2	2	8	0	24	2	3	11	8	114	7	19	17	0	216
	11	14	1	0	0	3	295	11	1	21	1	638	113	0	0	1098
	12	20	1	25	4	283	341	87	2	5	5	291	1997	3	2	3065
	13	1	2	0	2	3	0	0	4	7	10	0	5	77	0	111
	14	0	0	0	0	1	0	0	0	0	0	0	2	0	33	37
TOT.	185	42	739	49	2786	2516	634	257	238	217	1304	3325	144	37	12472	

La distribución espacial de los principales cambios producidos en las cubiertas del suelo se muestra en la Figura 7.5. La mayoría de estos cambios corresponden a

conversiones de las cubiertas del suelo, aunque algunos de ellos pueden ser atribuidos a errores derivados de una clasificación incorrecta en 1998 o 2004.

Como se ha visto previamente en la sección 4.1, la clase olivar es una de las categorías más difíciles de clasificar (vegetación+suelo), puesto que se caracteriza por cultivos dispuestos en hileras con un alto porcentaje de suelo desnudo, que, en ocasiones, puede estar cubierto total o parcialmente por vegetación herbácea. Las transiciones de cultivos herbáceos en seco a olivar y viceversa se localizaron en las proximidades del límite entre la provincia de Granada y Jaén, donde los olivares son más abundantes. Probablemente, estas conversiones no se deban a un cambio de uso del suelo, sino a una cobertura de hierba mayor durante la estación de primavera en algunos de los campos de olivos en 1998 o 2004. Por otro lado, los cambios de cubiertas entre olivares y suelos desnudos se produjeron en partes más céntricas de la provincia, así, algunas zonas de olivares jóvenes, en un estado de desarrollo incipiente, fueron clasificados como suelos desnudos en 1998, en los municipios de Huetor-Tajar, Moraleda de Zafayona, Guevejar y Peligros. Del mismo modo, las conversiones de olivar a suelos desnudos, en los términos municipales de Guadix y Gor, se produjeron también en áreas de olivares jóvenes, con suelos de colores muy claros, donde la alta componente de reflectividad del suelo enmascaró la respuesta espectral de los olivos.

En cuanto a las transiciones entre suelos y cultivos herbáceos, fundamentalmente debidas a alternancias entre barbecho y cultivo, los cambios se produjeron fundamentalmente en la Vega de Granada, más concretamente en los términos municipales de Alhendín, Otura, las Gabias, la Malá, Padul y Escuzar y en el marquesado del Cenete, en Cogollos y Albuñán. Asimismo, la conversión inversa, de herbáceos en seco a suelos desnudos, además de en las comarcas anteriores, ocurrió en la comarca de Huescar, especialmente en los municipios de Huescar, Puebla de Don Fabrique, Orce, Castillejar y Galera.

Las transiciones entre las cubiertas de vegetación natural, como cabía esperar, se produjeron en zonas de sierra. Los cambios de suelo desnudo a matorral se localizaron fundamentalmente en las sierras de Castril, la Sagra, de Taibilla y de Baza y en la vertiente noroeste de Sierra Nevada. Las transiciones entre coníferas y matorral en Sierra Nevada y Sierra de Baza. Las conversiones de matorral a pastizal en las Alpujarras (Sierra de la Contraviesa), Sierra de Almiar y Tejada y la Sierra de

Loja. Por último, los cambios de suelo a pastizal se dieron fundamentalmente en Loja y las Alpujarras.

## 5 Conclusiones

Los resultados de este estudio demuestran que las imágenes Landsat, junto con otros datos auxiliares, como imágenes de temperatura, MDTs e imágenes texturales, pueden ser utilizadas para detectar y analizar cambios en las cubiertas del suelo y generar una cartografía exacta, y de utilidad para la gestión y la ordenación territorial.

El método de análisis de cambios empleado ha sido el de post-clasificación, mediante el cual se han comparado dos clasificaciones supervisadas obtenidas de la aplicación del clasificador Random Forest a los datos de 1998 y 2004. La exactitud global estimada de esta técnica ha sido del 86%.

En este estudio se han analizado los patrones de cambios entre las cubiertas del suelo de la Provincia de Granada y se ha obtenido el mapa de cambios final, a partir del cual se han determinado la naturaleza y extensión de los cambios producidos. Atendiendo al mapa de cambios post-clasificación, las superficies de quercíneas y pastizal han sido las que más han incrementado su extensión, con aumentos del orden de los 200 km<sup>2</sup>. Los olivares, junto con los suelos desnudos y los cultivos herbáceos en secano son las categorías de estudio que más han mermado su extensión, al cual decreció en 271, 259 y 205 km<sup>2</sup>, respectivamente. En términos relativos, la clase urbano se incrementó en un 32% (59 km<sup>2</sup>), como consecuencia fundamentalmente de conversiones de suelos desnudos. Por el contrario, los chopos decrecieron un 26 % (10 km<sup>2</sup>) a favor de cultivos herbáceos en regadío. No obstante, algunos de estos cambios no estuvieron relacionados con conversiones en las cubiertas del suelo, sino que fueron consecuencia de los errores de omisión y comisión derivados de las clasificaciones individuales.

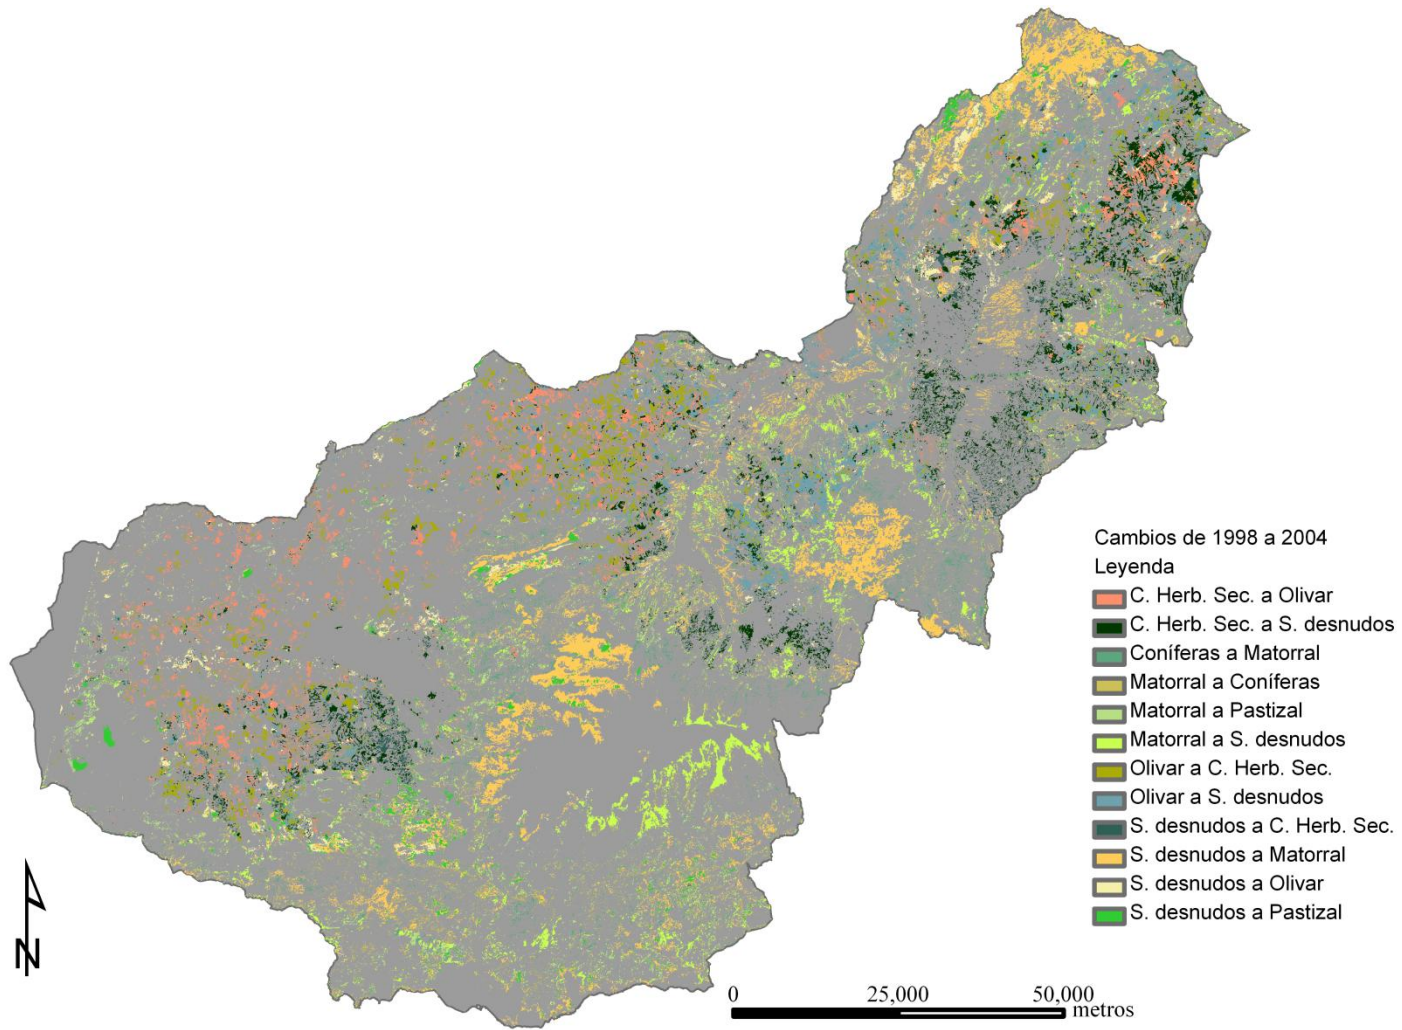


Figura 7.5. Mapa de cambios entre 1998 y 2004.

## CAPÍTULO 8.

# Conclusiones Generales

En esta tesis se ha elaborado una metodología integrada para la cartografía y análisis de cambios de las cubiertas del suelo de áreas complejas y heterogéneas. El área de estudio seleccionada para esta investigación es la Provincia de Granada, aunque las metodologías propuestas tienen carácter general y pueden ser aplicadas a otras áreas de características similares. El término “integrada” se refiere, en este caso, a la unión de distintas técnicas de análisis de datos, entre las que se incluyen la teledetección, el análisis espacial de datos (geoestadística), los sistemas de información geográfica (SIG) y los métodos de inteligencia artificial (aprendizaje de máquinas). El término “cubiertas del suelo” alude a las coberturas físicas y biológicas que recubren la superficie terrestre, incluidas por tanto la vegetación, los cuerpos de agua, suelos y superficies construidas, entre otras. La metodología desarrollada tiene un indudable interés socio-económico, puesto que pretende facilitar a las instituciones públicas, relacionadas con la gestión del medio ambiente, la cartografía precisa de las cubiertas del suelo y el control de los cambios que se producen en éstas, a un bajo coste económico y humano.

La Provincia de Granada es un área compleja, muy heterogénea, compuesta por numerosas cubiertas del suelo que son difíciles de cartografiar, debido a similitudes espectrales entre las diferentes categorías o cubiertas del suelo. Estas similitudes se producen especialmente entre distintos tipos de cubiertas de vegetación, o entre



cubiertas de otra naturaleza, como los suelos desnudos y las zonas urbanas, que presentan un comportamiento espectral muy similar, caracterizado por reflectividades altas. Por otro lado, la estructura del paisaje es compleja, y presenta una gran variabilidad de patrones espaciales, ya que como consecuencia de cambios abruptos en gradientes medioambientales (elevación, temperatura, humedad...), las cubiertas del suelo se disponen muy entremezcladas, formando “parches” de tamaño y forma irregular. Esta dificultad intrínseca a la cartografía de zonas con las características anteriormente expuestas, se ha abordado mediante: la elección de una metodología de clasificación robusta, que a su vez es operativa, transparente, interpretable y con un alto grado de automatización; y la obtención e incorporación de nuevas variables que permitan una mejor caracterización de las cubiertas del suelo: variables espectrales correspondientes a diferentes estadios del desarrollo fenológico de las cubiertas, variables relacionadas con gradientes medioambientales y medidas texturales de la estructura de variabilidad espacial.

Numerosas aplicaciones, como por ejemplo, la gestión y ordenación territorial o el análisis de cambios de las cubiertas del suelo, dependen de la existencia de cartografía precisa y actualizada. Para la generación de estas cartografías, es necesaria la aplicación de metodologías de clasificación, que además de generar productos cartográficos de alta calidad, puedan ser aplicados a espacios de datos complejos, es decir, que sea posible incluir un elevado número de variables descriptivas de las cubiertas del suelo. Además, estas metodologías deben ser aplicables en condiciones desfavorables, ruido en los datos, carestía de datos para la calibración de los modelos de clasificación, etc.

Tradicionalmente, para la cartografía a partir de datos de teledetección, se han usado metodologías de clasificación paramétricas, como el algoritmo de máxima probabilidad o el de máxima verosimilitud. Sin embargo, este conjunto de técnicas, al ser dependientes de la normalidad de los datos, no responden a las necesidades actuales de los programas de observación de la Tierra, ya que cada vez es posible, y por tanto necesario, incluir un mayor número de variables de diferente naturaleza en los sistemas de clasificación. Como alternativa a las metodologías paramétricas, en

los últimos años han surgido del campo de la informática/estadística, más concretamente, de la inteligencia artificial, un conjunto de técnicas denominadas de aprendizaje de máquinas o autoaprendizaje. En esta investigación se han comparado diferentes metodologías de aprendizaje de máquinas de naturaleza diversa: redes neuronales, árboles de decisión y otros algoritmos de más reciente aparición, las máquinas de vectores soporte y meta-clasificadores compuestos por árboles de decisión (*Random Forests*). Estas metodologías presentan numerosas ventajas, puesto que pueden ser aplicadas a mayores volúmenes de datos, con independencia de las distribuciones que sigan. Sin embargo, su aplicación es en ocasiones difícil, debido a la necesidad de ajuste de un elevado número de parámetros. Por otro lado, la potencialidad para la generación de cartografía de algunas de ellas, debido a su novedad, aún no ha sido evaluada en profundidad. Para evaluar la idoneidad de estas técnicas para la clasificación de las cubiertas del suelo se ha llevado a cabo un análisis comparativo desde diferentes perspectivas: la exactitud cartográfica de las clasificaciones, las necesidades de parametrización de cada técnica y, por último, la sensibilidad al ruido y a la reducción de los datos de entrenamiento.

Los resultados de este estudio muestran que los algoritmos de aprendizaje de máquinas presentan diferentes niveles de complejidad. El entrenamiento de los algoritmos basados en árboles de clasificación es sencillo, mientras que las redes neuronales y las máquinas de vectores soporte son más complejas y sensibles a pequeñas variaciones en su parametrización, lo cual se traduce en un mayor coste computacional. *Random Forest*, además de la simplicidad de su parametrización, incluye una medida interna muy robusta del error de clasificación, genera una medida que permite detectar la presencia de *outliers* en los datos y mide la importancia relativa de cada variable predictiva en el modelo de clasificación general y en la clasificación de cada categoría. Desde el punto de vista de la exactitud de la cartografía generada mediante la aplicación de estas metodologías, *Random Forest* y las máquinas de vectores soporte de kernel radial, son las que producen la cartografía más exacta. Estos dos últimos clasificadores son también menos sensibles al ruido y a

la reducción de los datos de entrenamiento, por lo que pueden ser usados en casos en los que la calidad de los datos de calibración sea deficiente o dudosa.

De forma complementaria a la elección de una metodología de clasificación óptima, la consideración de variables auxiliares en el proceso de clasificación ha incrementado la capacidad de los clasificadores para la discriminación de las cubiertas del suelo. Así, la inclusión de variables espectrales de primavera mejora considerablemente la caracterización de las cubiertas vegetales. También, mejoró la diferenciación entre las áreas urbanas y los suelos, puesto que pese a que ambos tienen valores de reflectividad similares en verano, en primavera los suelos presentan coberturas de vegetación que los hacen diferentes espectralmente. Del mismo modo, también ha sido utilizada la dependencia existente entre las cubiertas del suelo y las características del terreno. En particular, la utilización conjunta de imágenes de teledetección y los modelos digitales del terreno, obtenidos a partir de la matriz de elevaciones de la Provincia de Granada mediante el uso de los SIG, ha supuesto unos de los aspectos relevantes de esta investigación. Sin embargo, la disponibilidad de modelos digitales del terreno en determinadas áreas es limitada, por lo que puede ser necesaria la inclusión de otras variables relacionadas con gradientes medioambientales, como la temperatura, que condicionen la distribución de las categorías del suelo.

Algunos sensores de teledetección, como el TM o el ETM+ de Landsat, incluyen canales en el infrarrojo térmico, a partir de los cuales es posible obtener medidas de la temperatura de la superficie terrestre. La información térmica de estos sensores ha sido menos usada en cartografía, ya que su resolución espacial es más grosera que la del resto de canales. Sin embargo, es posible realzar su resolución espacial mediante la aplicación de métodos de fusión de imagen. En este sentido, se han evaluado metodologías de bases conceptuales diferentes: métodos wavelet, un método Bayesiano, y otro geoestadístico basado en cokriging. La valoración de los resultados de la aplicación de los métodos de fusión se ha basado en la calidad visual y en diferentes parámetros estadísticos e índices de calidad espectral y espacial. La aplicación del método geoestadístico y el Bayesiano da lugar a imágenes de mayor

resolución espacial con mayor calidad. En concreto, el método geoestadístico consiguió las imágenes más coherentes, es decir si estas imágenes son remuestreadas a su resolución original se obtienen imágenes idénticas a las de partida.

A partir de las conclusiones expuestas en el párrafo anterior, en este trabajo se optó por desarrollar una metodología basada en cokrigeaje y en la aplicación de la ecuación de transferencia radiativa para obtener imágenes de temperatura de superficie de resolución igual al resto de bandas del satélite Landsat. La inclusión de estas variables produjo un aumento en la exactitud de las categorías de vegetación que tienen un comportamiento espectral similar en el visible: los cultivos tropicales, los cultivos leñosos en regadío, las quercíneas y las coníferas, pero también de otras cubiertas de alta reflectividad como los suelos desnudos y las áreas urbanas. En el caso concreto de las coníferas y las áreas urbanas, la inclusión de la temperatura produjo un aumento mayor en la exactitud cartográfica de estas categorías del que supuso la consideración de las variables espectrales de primavera.

Como solución alternativa a la utilización de gradientes medioambientales como datos de entrada de los modelos de clasificación, se han estudiado diferentes medidas texturales aplicadas a las bandas de las imágenes de satélite. Para ello se han aplicado diversas funciones basadas en las matrices de co-ocurrencia (GLCM) y otras de naturaleza geoestadística, basadas en el variograma. Cabe destacar la novedad del cálculo de medidas texturales multi-estacionales, mediante la aplicación de los variogramas cruzados y pseudo-cruzados entre las imágenes de satélite de primavera y verano. La inclusión de las variables geoestadísticas en los modelos de clasificación incrementó significativamente la exactitud de los modelos entrenados únicamente a partir de datos espectrales. En especial cuando se usaron las funciones geoestadísticas, siendo los variogramas pseudo-cruzados los más útiles. Debido al elevado número de variables texturales consideradas, se aplicó un método de selección de características basado en las medidas de importancia calculadas por el clasificador *Random Forest*, que permitió paliar el efecto de “Hughes”, seleccionando con éxito las características más relevantes y reduciendo significativamente el volumen de datos.

En resumen, en este trabajo se han mostrado diferentes aproximaciones posibles para la generación de nueva información que pueda ser incluida en modelos de clasificación de las cubiertas del suelo. Estas nuevas variables contemplan desde la inclusión de variables auxiliares independientes a la teledetección, como los modelos digitales del terreno, a otras variables obtenidas a partir de las imágenes de teledetección (temperatura de superficie y variables texturales), y que por tanto pueden ser aplicadas en la clasificación de cualquier zona para la que haya disponibilidad de imágenes de satélite. Los resultados obtenidos en este estudio muestran que se puede obtener el mismo nivel de exactitud cartográfica a partir del uso combinado de imágenes de satélite con modelos digitales del terreno y con medidas texturales. Sin embargo, la inclusión de la temperatura de superficie tuvo un efecto más moderado, y solo mejoró la cartografía de algunas cubiertas del suelo. Por tanto, la elección de las variables auxiliares dependerá de la disponibilidad de la información, en el caso de los modelos digitales del terreno, y las necesidades de la aplicación.

Por último, todas las variables generadas a lo largo de este trabajo, se integraron para la obtención de la cartografía de las cubiertas del suelo de la Provincia de Granada en 1998 y 2004. Se ha desarrollado una metodología de análisis de cambios post-clasificación, que ha permitido identificar, localizar y cuantificar los diferentes patrones de cambio existentes en las cubiertas del suelo del área de estudio con una exactitud global del 86%. El nivel de exactitud adquirido puede considerarse como muy satisfactorio, dado el alto número de categorías contempladas y la complejidad del área de estudio. La extensión ocupada por quercíneas, áreas urbanas, pastizales, invernaderos y matorral se incrementó un 76%, 32%, 30%, 19% y 13%, mientras que chopos, cultivos tropicales, cultivos herbáceos en secano, olivares, suelos desnudos y coníferas decrecieron un 24%, 23%, 16%, 11%, 8% y 6%, respecto a su superficie original. Los resultados de este estudio demuestran el potencial de los datos de teledetección y de las técnicas basadas en SIG, inteligencia artificial y geoestadística, para cartografiar de forma económica y operativa las transiciones producidas en el tiempo entre las cubiertas del suelo.

## REFERENCIAS

Abarca-Hernández, F., Chica-Olmo, M., 1999. Evaluation of Geostatistical Measures of Radiometric Spatial Variability for Lithologic Discrimination in Landsat TM images. *Photogrammetric Engineering & Remote Sensing* 65 (6), 705-711.

Abreu, L.W., Anderson, G.P., 1996. The MODTRAN 2/3 Report and LOWTRAN 7 MODEL.

Acker, J.G., Leptoukh, G., 2007. Online Analysis Enhances Use of NASA Earth Science Data. *Eos, Transactions of the American Geophysical Union* 88 (2), 14--17.

Agam, N., Kustas, W.P., Anderson, M.C., Li, F.Q., Neale, C.M.U., 2007. A vegetation index based technique for spatial sharpening of thermal imagery. *Remote Sensing of Environment* 107 (4), 545-558.

Agüera, F., Aguilar, F.J., Aguilar, M.A., 2008. Using texture analysis to improve per-pixel classification of very high resolution images for mapping plastic greenhouses. *ISPRS Journal of Photogrammetry and Remote Sensing* 63 (6), 635-646.

Aiazzi, B., Alparone, L., Baronti, S., Garzelli, A., 2002. Context-driven fusion of high spatial and spectral resolution images based on oversampled multiresolution analysis. *Geoscience and Remote Sensing, IEEE Transactions on* 40 (10), 2300-2312.

Alparone, L., Wald, L., Chanussot, J., Thomas, C., Gamba, P., Bruce, L.M., 2007. Comparison of Pansharpening Algorithms: Outcome of the 2006 GRS-S Data-Fusion Contest. *Geoscience and Remote Sensing, IEEE Transactions on* DOI - 10.1109/TGRS.2007.904923 45 (10), 3012--3021.

Allen, R.G., Tasumi, M., Trezza, R., 2007. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC)---Model. *Journal of Irrigation and Drainage Engineering* 133 (4), 380-394.

Amolins, K., Zhang, Y., Dare, P., 2007. Wavelet based image fusion techniques -- An introduction, review and comparison. *ISPRS Journal of Photogrammetry and Remote Sensing* 62 (4), 249--263.

Anderson, J., Hardy, E., Roach, J., Witmer, R., 1976. A land use and land cover classification system for use with remote sensor data.).

Anys, H., Bannari, A., He, D.C., Morin, D., 1994. Texture analysis for the mapping of urban areas using airborne MEIS-II images, First International Airborne Remote Sensing Conference and Exhibition Strasbourg, Strasbourg, France. pp. 231-245.

Arnfield, A.J., 2003. Two decades of urban climate research: a review of turbulence, exchanges of energy and water, and the urban heat island. *International Journal of Climatology* 23 (1), 1-26.

Ashoori, H., Fahimnejad, H., Alimohammadi, A., Soofbaf, S.R., 2008. Evaluation of the usefulness of texture measures for crop type classification by hyperion data, *Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, China. pp. 999-1006.

Asner, G.P., Keller, M., Pereira Jr., R., Zweede, J.C., 2002. Remote sensing of selective logging in Amazonia: Assessing limitations based on detailed field observations, Landsat ETM+, and textural analysis. *Remote Sensing of Environment* 80 (3), 483-496.

Atkinson, P., Tatnall, A., 1997. Introduction neural networks in remote sensing. *International Journal of Remote Sensing* 18 (4), 699-709.

Atkinson, P.M., Lewis, P., 2000. Geostatistical classification for remote sensing: an introduction. *Computers & Geosciences* 26 (4), 361-371.

Atkinson, P.M., Pardo-Iguzquiza, E., Chica-Olmo, M., 2008a. Downscaling Cokriging for Super-Resolution Mapping of Continua in Remotely Sensed Images. *Geoscience and Remote Sensing, IEEE Transactions on* 46 (2), 573--580.

Atkinson, P.M., Pardo-Iguzquiza, E., Chica-Olmo, M., 2008b. Downscaling Cokriging for Super-Resolution Mapping of Continua in Remotely Sensed Images. *Geoscience and Remote Sensing, IEEE Transactions on* 46 (2), 573-580.

Atkinson, P.M., Webster, R., Curran, P.J., 1992. Cokriging with ground-based radiometry. *Remote Sensing of Environment* 41 (1), 45-60.

Atkinson, P.M., Webster, R., Curran, P.J., 1994. Cokriging with airborne MSS imagery. *Remote Sensing of Environment* 50 (3), 335-345.

Augusteijn, M.F., Clemens, L.E., Shaw, K.A., 1995. Performance evaluation of texture measures for ground cover identification in satellite images by means of a

neural network classifier. *Geoscience and Remote Sensing, IEEE Transactions on* 33 (3), 616-626.

autores, V., 1989. *Gran Atlas de España*, Barcelona.

Avery, G., 1965. Measuring land use changes on USDA photographs. *Photogrammetric Engineering* 31, 620--624.

Bala, G., Caldeira, K., Wickett, M., Phillips, T., Lobell, D., Delire, C., Mirin, A., 2007. Combined climate and carbon-cycle effects of large-scale deforestation. *Proceedings of the National Academy of Sciences* 104 (16), 6550-6555.

Balaguer, A., Ruiz, L.A., Hermosilla, T., Recio, J.A., 2010. Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification. *Computers & Geosciences* 36 (2), 231-240.

Baraldi, A., Parmiggiani, F., 1995. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *Geoscience and Remote Sensing, IEEE Transactions on* 33 (2), 293-304.

Barsi, J.A., Barker, J.L., Schott, J.R., 2003. An Atmospheric Correction Parameter Calculator for a single thermal band earth-sensing instrument, *Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International DOI - 10.1109/IGARSS.2003.1294665*. pp. 3014--3016 vol.3015.

Barsi, J.A., Schott, J.R., Palluconi, F.D., Hook, S.J., 2005. Validation of a web-based atmospheric correction tool for single thermal band instruments, In: Butler, J.J. (Ed.). *SPIE*. p. 58820E.

Bartholomé, E., Belward, A.S., 2005. GLC2000: a new approach to global land cover mapping from Earth observation data. *International Journal of Remote Sensing* 26 (9), 1959 - 1977.

Bazi, Y., Melgani, F., 2006. Toward an Optimal SVM Classification System for Hyperspectral Remote Sensing Images. *Ieee Transactions On Geoscience And Remote Sensing* 44, 3374-3385.

Beekhuizen, J., Clarke, K.C., 2010. Toward accountable land use mapping: Using geocomputation to improve classification accuracy and reveal uncertainty. *International Journal of Applied Earth Observation and Geoinformation* 12 (3), 127-137.

Bellman, R., 2003. *Dynamic Programming*, 2 nd ed. Dover Publications, Mineola, NY.



Benediktsson, J.A., Sveinsson, J.R., 1997. Feature extraction for multisource data classification with artificial neural networks. *International Journal of Remote Sensing* 18 (4), 727-740.

Benediktsson, J.A., Swain, P.H., Ersoy, O.K., 1990. Neural Network Approaches Versus Statistical Methods In Classification Of Multisource Remote Sensing Data. *Geoscience and Remote Sensing, IEEE Transactions on* 28 (4), 540-552.

Berberoglu, S., Akin, A., Atkinson, P.M., Curran, P.J., 2010. Utilizing image texture to detect land-cover change in Mediterranean coastal wetlands. *International Journal of Remote Sensing* 31 (11), 2793-2815.

Berberoglu, S., Curran, P.J., Lloyd, C.D., Atkinson, P.M., 2007. Texture classification of Mediterranean land cover. *International Journal of Applied Earth Observation and Geoinformation* 9 (3), 322-334.

Berberoglu, S., Lloyd, C.D., Atkinson, P.M., Curran, P.J., 2000. The integration of spectral and textural information using neural networks for land cover mapping in the Mediterranean. *Computers & Geosciences* 26 (4), 385-396.

Berk, A., Adler-Golden, S.M., 2002. Exploiting MODTRAN radiation transport for atmospheric correction: The FLAASH algorithm, *Fifth International Conference on Information Fusion, Annapolis*. pp. 798-803.

Berk, A., Bernstein, L.S., Anderson, G.P., Acharya, P.K., Robertson, D.C., Chetwynd, J.H., Adler-Golden, S.M., 1998. MODTRAN Cloud and Multiple Scattering Upgrades with Application to AVIRIS. *Remote Sensing of Environment* 65 (3), 367-375.

Betts, R., Falloon, P., Goldewijk, K., Ramankutty, N., 2007. Biogeophysical effects of land use on climate: Model simulations of radiative forcing and large-scale temperature change. *Agricultural and Forest Meteorology* 142 (2-4), 216-233.

Bishop, C.M., 1995. *Neural networks for pattern recognition*, 1 st ed. Oxford University Press, New York, USA.

Blum, A.L., Langley, P., 1997. Selection of relevant features and examples in machine learning. *Artificial Intelligence* 97 (1-2), 245-271.

Bonan, G., 2008. Forests and climate change: forcings, feedbacks, and the climate benefits of forests. *Science* 320 (5882), 1444-1449.

Boser, B.E., Guyon, I.M., Vapnik, V.N., 1992. A training algorithm for optimal margin classifier, *Fifth ACM Annual Workshop on Computational Learning, Pittsburgh, PA, USA* pp. 144--152.

- Breiman, L., 1984. Classification and regression trees. Chapman & Hall/CRC.
- Breiman, L., 1996. Bagging predictors. *Machine Learning* 24 (2), 123-140.
- Breiman, L., 2001. Random forests. *Machine Learning* 45 (1), 5-32.
- Breiman, L., Cutler, A., 2004. Random Forest, [http://www.stat.berkeley.edu/~breiman/RandomForests/cc\\_home.htm](http://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm). (Accessed 10 April, 2010).
- Breiman, L., Friedman, J., Stone, C.J., Olshen, R.A., 1984. Classification and Regression Trees, 1st ed. Chapman and Hall/CRC, Belmont, CA.
- Brewster, C.C., Allen, J.C., Kropp, D.D., 1999. IPM from space: using satellite imagery to construct regional crop maps for studying crop insect interaction. *American Entomologist* 45 (2), 105-117.
- Briem, G.J., Benediktsson, J.A., Sveinsson, J.R., 2002. Multiple classifiers applied to multisource remote sensing data. *Geoscience and Remote Sensing, IEEE Transactions on* 40 (10), 2291-2299.
- Brisco, B., Brown, R.J., 1995. Multidate SAR/TM synergism for crop classification in western Canada. *Photogrammetric Engineering & Remote Sensing* 61 (8), 1009-1014.
- Brovkin, V., Sitch, S., Von Bloh, W., Claussen, M., Bauer, E., Cramer, W., 2004. Role of land cover changes for atmospheric CO<sub>2</sub> increase and climate change during the last 150 years. *Global Change Biology* 10 (8), 1253-1266.
- Buddenbaum, H., Schlerf, M., Hill, J., 2005. Classification of coniferous tree species and age classes using hyperspectral data and geostatistical methods. *International Journal of Remote Sensing* 26 (24), 5453-5465.
- Carlson, T.N., Ripley, D.A., 1997. On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment* 62 (3), 241-252.
- Carr, J.R., 1996. Spectral and textural classification of single and multiple band digital images. *Computers & Geosciences* 22 (8), 849-865.
- Carrão, H., Gonçalves, P., Caetano, M., 2008. Contribution of multispectral and multitemporal information from MODIS images to land cover classification. *Remote Sensing of Environment* 112 (3), 986-997.

Casseltes, V., García, M.J.L., 1989. An alternative simple approach to estimate atmospheric correction in multitemporal studies. *International Journal of Remote Sensing* 10, 1127--1134.

Castillo-Santiago, M.A., Ricker, M., de Jong, B.H.J., 2010. Estimation of tropical forest structure from SPOT-5 satellite images. *International Journal of Remote Sensing* 31 (10), 2767-2782.

Clausi, D.A., 2002. An analysis of co-occurrence texture statistics as a function of grey level quantization. *Canadian Journal of Remote Sensing* 28 (1), 45-62.

Cohen, J., 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement* 20, 37--46.

Cohen, W.B., Spies, T.A., Bradshaw, G.A., 1990. Semivariograms of digital imagery for analysis of conifer canopy structure. *Remote Sensing of Environment* 34 (3), 167-178.

Colombo, S., Chica-Olmo, M., Abarca, F., Eva, H., 2004. Variographic analysis of tropical forest cover from multi-scale remotely sensed imagery. *ISPRS Journal of Photogrammetry and Remote Sensing* 58 (5-6), 330-341.

Coll, C., Galve, J.M., Sanchez, J.M., Caselles, V., 2010. Validation of Landsat-7/ETM+ Thermal-Band Calibration and Atmospheric Correction With Ground-Based Measurements. *Geoscience and Remote Sensing, IEEE Transactions on DOI - 10.1109/TGRS.2009.2024934* 48 (1), 547--555.

Collins, J.B., Woodcock, C.E., 1996. An assessment of several linear change detection techniques for mapping forest mortality using multitemporal landsat TM data. *Remote Sensing of Environment* 56 (1), 66--77.

Congalton, R., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment* 37 (1), 35-46.

Congalton, R.G., Green, K., 2009. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, 2nd ed. CRC Press, Boca Raton, Florida.

Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., Lambin, E., 2004. Review Article Digital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing* 25 (9), 1565--1596.

Cortes, C., Vapnik, V., 1995. Support-Vector Networks. *Machine Learning* 20 (3), 273-297.

- Crabtree, R., Potter, C., Mullen, R., Sheldon, J., Huang, S., Harmsen, J., Rodman, A., Jean, C., 2009. A modeling and spatio-temporal analysis framework for monitoring environmental change using NPP as an ecosystem indicator. *Remote Sensing of Environment* 113 (7), 1486-1496.
- Crapper, P.F., Hynson, K.C., 1983. Change detection using Landsat photographic imagery. *Remote Sensing of Environment* 13 (4), 291-300.
- CSIC-IARA, 1989. Mapa de Usos del Suelo de Andalucía, In: Ambiente, C.d.M. (Ed.), Sevilla.
- Culbert, P.D., Pidgeon, A.M., St-Louis, V., Bash, D., Radeloff, V.C., 2009. The Impact of Phenological Variation on Texture Measures of Remotely Sensed Imagery. *Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE Journal of 2 (4), 299-309.
- Curran, P.J., 1988a. The semivariogram in remote sensing: An introduction. *Remote Sensing of Environment* 24 (3), 493--507.
- Curran, P.J., 1988b. The semivariogram in remote sensing: An introduction. *Remote Sensing of Environment* 24 (3), 493-507.
- Cutler, D.R., Edwards, T.C., Beard, K.H., Cutler, A., Hess, K.T., 2007. Random forests for classification in ecology. *Ecology* 88, 2783-2792.
- Chan, J.C.-W., Paelinckx, D., 2008. Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment* 112 (6), 2999-3011.
- Chan, J.C.W., Laporte, N., Defries, R.S., 2003. Texture classification of logged forests in tropical Africa using machine-learning algorithms. *International Journal of Remote Sensing* 24 (6), 1401-1407.
- Chapman, D.S., Bonn, A., Kunin, W.E., Cornell, S.J., 2010. Random Forest characterization of upland vegetation and management burning from aerial imagery. *Journal Of Biogeography* 37 (1), 37-46.
- Chavez Jr., P.S., 1996. Image-Based Atmospheric Corrections-Revisited and Improved. *Photogrammetric Engineering & Remote Sensing* 62 (9), 1025--1036.
- Chavez, P.S., Sides, S.C., Anderson, J.A., 1991. Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic. *Photogrammetric Engineering & Remote Sensing* 57, 295-303.

Chen, H.W., Chang, N.B., Yu, R.F., Huang, Y.W., 2009. Urban land use and land cover classification using the neural-fuzzy inference approach with Formosat-2 data. *Journal of applied remote sensing* 3.

Chen, Q., Gong, P., 2004. Automatic variogram parameter extraction for textural classification of the panchromatic IKONOS imagery. *Ieee Transactions On Geoscience And Remote Sensing* 42 (5), 1106-1115.

Chibani, Y., Houacine, A., 2002. The joint use of IHS transform and redundant wavelet decomposition for fusing multispectral and panchromatic images. *International Journal of Remote Sensing* 23 (18), 3821 - 3833.

Chica-Olmo, M., Abarca-Hernandez, F., 1998. Radiometric coregionalization of Landsat TM and SPOT HRV images. *International Journal of Remote Sensing* 19 (5), 997--1005.

Chica-Olmo, M., Abarca-Hernández, F., 2000. Computing geostatistical image texture for remotely sensed data classification. *Computers & Geosciences* 26 (4), 373-383.

Chica-Olmo, M., Ruiz-Castellano, J.P., Rigol-Sánchez, J.P., 2004. Aplicación de la función variograma al análisis de cambios espacio-temporales en imágenes Landsat TM. *Revista de Teledetección* 22, 41-46.

Chuvieco, E., 2008. *Teledetección ambiental: La observación de la Tierra desde el Espacio*, 3rd ed. Editorial Ariel, S.A.

Dash, J., Mathur, A., Foody, G.M., Curran, P.J., Chipman, J.W., Lillesand, T.M., 2007. Land cover classification using multi-temporal MERIS vegetation indices. *International Journal of Remote Sensing* 28 (6), 1137 - 1159.

de Leeuw, J., Georgiadou, Y., Kerle, N., de Gier, A., Inoue, Y., Ferwerda, J., Smies, M., Narantuya, D., 2010. The Function of Remote Sensing in Support of Environmental Policy. *Remote Sensing* 2 (7), 1731-1750.

De Stefano, C., Fontanella, F., Marrocco, C., Schirinzi, G., 2007. A feature selection algorithm for class discrimination improvement, *Geoscience and Remote Sensing Symposium, 2007. IGARSS 2007. IEEE International*. pp. 425-428.

de Wasseige, C., Defourny, P., 2002. Retrieval of tropical forest structure characteristics from bi-directional reflectance of SPOT images. *Remote Sensing of Environment* 83 (3), 362-375.

DeFries, R.S., Chan, J.C.-W., 2000. Multiple Criteria for Evaluating Machine Learning Algorithms for Land Cover Classification from Satellite Data. *Remote Sensing of Environment* 74 (3), 503-515.

Dekker, R.J., 2003. Texture analysis and classification of ERS SAR images for map updating of urban areas in The Netherlands. *Geoscience and Remote Sensing, IEEE Transactions on* 41 (9), 1950-1958.

Del Frate, F., Iapaolo, M., Casadio, S., Godin-Beekmann, S., Petitdidier, M., 2005. Neural networks for the dimensionality reduction of GOME measurement vector in the estimation of ozone profiles. *Journal of Quantitative Spectroscopy and Radiative Transfer* 92 (3), 275-291.

Dell'Acqua, F., Gamba, P., Trianni, G., 2006. Semi-automatic choice of scale-dependent features for satellite SAR image classification. *Pattern Recognition Letters* 27 (4), 244-251.

Deutsch, C.V., Journel, A.G., 1992. *GSLIB. Geostatistical Software Library and User's Guide*. Oxford University Press, New York.

Di Gregorio, A., Jansen, L.J.M., 2000. Land Cover Classification System (LCCS): Classification Concepts and User Manual, In: Department, N.R.M.a.E. (Ed.). FAO.

Dietterich, T.G., 2000. An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, and Randomization. *Machine Learning* 40 (2), 139-157.

Dixon, B., Candade, N., 2008. Multispectral landuse classification using neural networks and support vector machines: one or the other, or both? *International Journal of Remote Sensing* 29 (4), 1185--1206.

Draxler, R.R., Rolph, G.D., 2003. *HYSPLIT (HYbrid Single-Particle Lagrangian Integrated Trayectory)*.

Drury, S.A., 1987. *Image Interpretation in Geology*, 1 ed ed, London.

Eastman, J.R., McKendry, J.E., Fulk, M.A., 1995. *Change and Time Series Analysis, Segunda Edición ed*. Clark Labs for Cartographic Technology and Geographic Analysis, Clark University, Worcester, MA 01610 USA.

EEA, 2010. CORINE Land Cover, <http://www.eea.europa.eu/publications/COR0-landcover>. (Abril 2011).

Ehlers, M., 1991. Multisensor Image Fusion Techniques in Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 46, 19-30.

Eklundh, L., Singh, A., 1993. A comparative analysis of standardised and unstandardised principal components analysis in remote sensing. *International Journal of Remote Sensing* 14, 1359--1370.

Ekstrand, S., 1994. Assessment of forest damage with Landsat TM: correction for varying forest stand characteristics. *Remote Sens. Environ.* 47:291–302. *Remote Sensing of Environment* 47, 291--302.

Elvidge, C.D., Yuan, D., Ridgeway, D.W., Lunetta, R.S., 1995. Relative radiometric normalization of Landsat Multispectral Scanner (MSS) data using an automatic scattergram-controlled regression. *Photogrammetric Engineering & Remote Sensing* 61, 1255--1260.

ESA, 2010. GLOBCOVER, (April 2011).

Estes, L.D., Okin, G.S., Mwangi, A.G., Shugart, H.H., 2008. Habitat selection by a rare forest antelope: A multi-scale approach combining field data and imagery from three sensors. *Remote Sensing of Environment* 112 (5), 2033-2050.

Estes, L.D., Reillo, P.R., Mwangi, A.G., Okin, G.S., Shugart, H.H., 2010. Remote sensing of structural complexity indices for habitat and species distribution modeling. *Remote Sensing of Environment* 114 (4), 792-804.

Falkner, E., 1968. Landuse changes in parkway school district. *Photogrammetric Engineering* 34, 52--57.

Fearnside, P.M., 2000. Global Warming and Tropical Land-Use Change: Greenhouse Gas Emissions from Biomass Burning, Decomposition and Soils in Forest Conversion, Shifting Cultivation and Secondary Vegetation. *Climatic Change* 46 (1), 115-158.

Filippi, A.M., Jensen, J.R., 2006. Fuzzy learning vector quantization for hyperspectral coastal vegetation classification. *Remote Sensing of Environment* 100 (4), 512-530.

Foley, J.A., DeFries, R., Asner, G.P., Barford, C., Bonan, G., Carpenter, S.R., Chapin, F.S., Coe, M.T., Daily, G.C., Gibbs, H.K., Helkowski, J.H., Holloway, T., Howard, E.A., Kucharik, C.J., Monfreda, C., Patz, J.A., Prentice, I.C., Ramankutty, N., Snyder, P.K., 2005. Global consequences of land use. *Science* 309 (5734), 570-574.

Font Tullot, I., 1983. Atlas Climático de España.

Fontboté, J.M., 1986. Las Zonas Internas de la Cordillera Bética, Geología de España, Libro Homenaje J.M. Ríos. IGME, pp. 251-343.

- Foody, G.M., 1995a. Land cover classification by an artificial neural network with ancillary information. *International Journal of Geographical Information Systems* 9 (5), 527-542.
- Foody, G.M., 1995b. Using prior knowledge in artificial neural network classification with a minimal training set. *International Journal of Remote Sensing* 16 (2), 301 - 312.
- Foody, G.M., 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment* 80 (1), 185-201.
- Foody, G.M., 2004. Thematic Map Comparison: Evaluating the Statistical Significance of Differences in Classification Accuracy. *Photogrammetric Engineering and Remote Sensing* 70 (5), 627-633.
- Foody, G.M., 2009. Sample size determination for image classification accuracy assessment and comparison. *International Journal of Remote Sensing* 30 (20), 5273-5291.
- Foody, G.M., Arora, M.K., 1997. An evaluation of some factors affecting the accuracy of classification by an artificial neural network. *International Journal of Remote Sensing* 18 (4), 799-810.
- Franklin, J., 1995. Predictive vegetation mapping: geographic modelling of biospatial patterns in relation to environmental gradients *Progress In Physical Geography* 19 (4), 474-499.
- Franklin, J., 1998. Predicting the distribution of shrub species in southern California from climate and terrain-derived variables. *Journal Of Vegetation Science* 9 (5), 733-748.
- Franklin, J., Simons, D.K., Beardsley, D., Rogan, J.M., Gordon, H., 2001. Evaluating Errors in a Digital Vegetation Map with Forest Inventory Data and Accuracy Assessment Using Fuzzy Sets. *Transactions in GIS* 5 (4), 285-304.
- Franklin, S., Wulder, M., 2002. Remote sensing methods in medium spatial resolution satellite data land cover classification of large areas. *Progress in Physical Geography* 26 (2), 173-205.
- Franklin, S.E., Hall, R.J., Moskal, L.M., Maudie, A.J., Lavigne, M.B., 2000. Incorporating texture into classification of forest species composition from airborne multispectral images. *International Journal of Remote Sensing* 21 (1), 61-79.



- Franklin, S.E., Wulder, M.A., Lavigne, M.B., 1996. Automated derivation of geographic window sizes for use in remote sensing digital image texture analysis. *Computers & Geosciences* 22 (6), 665-673.
- Friedl, M., Brodley, C., Strahler, A., 2002a. Maximizing land cover classification accuracies produced by decision trees at continental to global scales. *Geoscience and Remote Sensing, IEEE Transactions on* 37 (2), 969-977.
- Friedl, M.A., Brodley, C.E., 1997. Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment* 61 (3), 399-409.
- Friedl, M.A., Brodley, C.E., Strahler, A.H., 1999. Maximizing land cover classification accuracies produced by decision trees at continental to global scales. *Geoscience and Remote Sensing, IEEE Transactions on* 37 (2), 969-977.
- Friedl, M.A., McIver, D.K., Hodges, J.C.F., Zhang, X.Y., Muchoney, D., Strahler, A.H., Woodcock, C.E., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F., Schaaf, C., 2002b. Global land cover mapping from MODIS: algorithms and early results. *Remote Sensing of Environment* 83 (1-2), 287-302.
- Frizzelle, B.G., Moody, A., 2001. Mapping continuous distributions of land cover: a comparison of maximum-likelihood estimation and artificial neural networks. *Photogrammetric Engineering and Remote Sensing* 67 (6), 693-705.
- Fung, T., LeDrew, E., 1988. The Determination of Optimal Threshold Levels for Change Detection Using Various Accuracy Indices. *Photogrammetric Engineering & Remote Sensing* 54, 1449--1454.
- Fung, T., Siu, W., 2000. Environmental quality and its changes, an analysis using NDVI. *International Journal of Remote Sensing* 21 (5), 1011 - 1024.
- Furby, S.L., Campbell, N.A., 2001. Calibrating images from different dates to 'like-value' digital counts. *Remote Sensing of Environment* 77 (2), 186--196.
- Gamba, P., Dell'Acqua, F., Dasarathy, B.V., 2005. Urban remote sensing using multiple data sets: Past, present, and future. *Information Fusion* 6 (4), 319-326.
- Gao, B.C., Kaufman, Y.J., 1992. Remote Sensing of Water Vapor in the Near IR from EOS/MODIS. *IEEE Transactions on Geoscience and Remote Sensing* 30 (5), 871--884.
- Garguet-Duport, B., Girel, J., Chasseny, J.M., Pautou, G., 1996. The use of multiresolution analysis and wavelets transform for merging SPOT panchromatic and multispectral image data. *Photogrammetric Engineering and Remote Sensing* 62, 1057--1066.

- Garzelli, A., Nencini, F., Alparone, L., Aiazzi, B., Baronti, S., 2004. Pan-sharpening of multispectral images: a critical review and comparison, *Geoscience and Remote Sensing Symposium, 2004. IGARSS '04. Proceedings. 2004 IEEE International*. pp. --84.
- Ghimire, B., Rogan, J., Miller, J., 2010. Contextual land-cover classification: incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic. *Remote Sensing Letters* 1, 45-54.
- Giri, C., Defourny, P., Shrestha, S., 2003. Land cover characterization and mapping of continental Southeast Asia using multi-resolution satellite sensor data. *International Journal of Remote Sensing* 24 (21), 4181 - 4196.
- Giri, C., Zhu, Z., Reed, B., 2005. A comparative analysis of the Global Land Cover 2000 and MODIS land cover data sets. *Remote Sensing of Environment* 94 (1), 123-132.
- Gislason, P.O., Benediktsson, J.A., Sveinsson, J.R., 2004. Random forest classification of multisource remote sensing and geographic data, *Igarss 2004: Ieee International Geoscience And Remote Sensing Symposium, Anchorage, AK, 20-24 September*. pp. 1049-1052.
- Gislason, P.O., Benediktsson, J.A., Sveinsson, J.R., 2006. Random Forests for land cover classification. *Pattern Recognition Letters* 27 (4), 294-300.
- Gong, P., Marceau, D.J., Howarth, P.J., 1992. A comparison of spatial feature extraction algorithms for land-use classification with SPOT HRV data. *Remote Sensing of Environment* 40 (2), 137-151.
- Gonzalez-Audicana, M., Otazu, X., Fors, O., Seco, A., 2005. Comparison between Mallat's and the  $\tilde{A}$  trous<sup>TM</sup> discrete wavelet transform based algorithms for the fusion of multispectral and panchromatic images. *International Journal of Remote Sensing* 26 (3), 595--614.
- Goward, S.N., Masek, J.G., Williams, D.L., Irons, J.R., Thompson, R.J., 2001. The Landsat 7 mission: Terrestrial research and applications for the 21st century. *Remote Sensing of Environment* 78 (1-2), 3--12.
- Gowda, P.H., Chavez, J.L., Colaizzi, P.D., Evett, S.R., Howell, T.A., Tolk, J.A., 2007. Remote sensing based energy balance algorithms for mapping ET: Current status and future challenges. *Transactions Of The Asabe* 50 (5), 1639--1644.
- Guo, L., Chehata, N., Mallet, C., Boukir, S., 2011. Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests. *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (1), 56-66.

Guyon, I., Elisseeff, A., 2003. An Introduction to Variable and Feature Selection *Journal of Machine Learning Research* 3, 1157-1182.

Hall, F.G., Strelbel, D.E., Nickeson, J.E., Goetz, S.J., 1991. Radiometric rectification: Toward a common radiometric response among multitemporal, multisensor images. *Remote Sensing of Environment* 35 (1), 11--27.

Ham, J., Yangchi, C., Crawford, M.M., Ghosh, J., 2005. Investigation of the random forest framework for classification of hyperspectral data. *Geoscience and Remote Sensing, IEEE Transactions on* 43 (3), 492-501.

Hansen, M., Dubayah, R., Defries, R., 1996. Classification trees: an alternative to traditional land cover classifiers. *International Journal of Remote Sensing* 17 (5), 1075-1081.

Haralick, R.M., Shanmugam, K., Dinstein, I.H., 1973. Textural Features for Image Classification. *Systems, Man and Cybernetics, IEEE Transactions on* 3 (6), 610-621.

Hastie, T., Tibshirani, R., Friedman, J., 2009. *Random Forests, The Elements of Statistical Learning*. Springer New York, pp. 587-604.

He, C., Wei, A., Shi, P., Zhang, Q., Zhao, Y., 2011. Detecting land-use/land-cover change in rural-urban fringe areas using extended change-vector analysis. *International Journal of Applied Earth Observation and Geoinformation* 13 (4), 572-585.

Hepcan, C.C., Turan, I.A., Ozkan, M.B., 2011. Monitoring land use change in the Cesme coastal zone, Turkey using aerial photographs and satellite imaging. *Land Degradation & Development* 22 (3), 326-333.

Herold, M., Woodcock, C.E., Antonio di, G., Mayaux, P., Belward, A.S., Latham, J., Schmullius, C.C., 2006. A joint initiative for harmonization and validation of land cover datasets. *Geoscience and Remote Sensing, IEEE Transactions on* 44 (7), 1719-1727.

Herzfeld, U.C., Higginson, C.A., 1996. Automated geostatistical seafloor classification--Principles, parameters, feature vectors, and discrimination criteria. *Computers & Geosciences* 22 (1), 35-41.

Hess, M., Koepke, P., Schult, I., 1998. Optical Properties of Aerosols and Clouds: The Software Package OPAC. *Bulletin of the American Meteorological Society* 79 (5), 831--844.

- Hong, S.H., Hendrickx, J.M.H., Borchers, B., 2009. Up-scaling of SEBAL derived evapotranspiration maps from Landsat (30 m) to MODIS (250 m) scale. *Journal Of Hydrology* 370 (1-4), 122--138.
- Howarth, P.J., Boasson, E., 1983. Landsat digital enhancements for change detection in urban environments. *Remote Sensing of Environment* 13 (2), 149-160.
- Huang, C., Davis, L.S., Townshend, J.R.G., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing* 23 (4), 725-749.
- Huang, X., Zhang, L., Li, P., 2008. A multiscale feature fusion approach for classification of very high resolution satellite imagery based on wavelet transform. *International Journal of Remote Sensing* 29 (20), 5923 - 5941.
- IGN, 2005. Sistema de información de Ocupación del Suelo en España, <http://www.siose.es>. (Abril 2011).
- IPCCC, 2000. Land use, land-use change, and forestry. 184.
- Irons, J.R., Petersen, G.W., 1981. Texture transforms of remote sensing data. *Remote Sensing of Environment* 11, 359-370.
- JCR, 2010. Global Land Cover 2000, <http://bioval.jrc.ec.europa.eu/products/glc2000/glc2000.php>. (Abril 2011).
- Jensen, J.R., 2000. *Remote Sensing of the Environment: An Earth Resource Perspective*. Prentice Hall.
- Jensen, J.R., 2005. *Introductory Digital Image Processing*, 3rd ed. Prentice Hall, Upper Saddle River, NJ.
- Jensen, J.R., J. D. Althausen S. Narumalani, Weatherbee, O., 1993. An Evaluation of CoastWatch Change Detection Protocol in South Carolina. *Photogrammetric Engineering & Remote Sensing* 59, 1039--1046.
- Jimenez-Munoz, J.C., Cristobal, J., Sobrino, J.A., Soria, G., Ninyerola, M., Pons, X., 2009. Revision of the Single-Channel Algorithm for Land Surface Temperature Retrieval From Landsat Thermal-Infrared Data. *Geoscience and Remote Sensing, IEEE Transactions on DOI - 10.1109/TGRS.2008.2007125* 47 (1), 339--349.
- Johansen, K., Coops, N.C., Gergel, S.E., Stange, Y., 2007. Application of high spatial resolution satellite imagery for riparian and forest ecosystem classification. *Remote Sensing of Environment* 110 (1), 29-44.

Jupp, D.L.B., Strahler, A.H., Woodcock, C.E., 1988. Autocorrelation and regularization in digital images. I. Basic theory. *Geoscience and Remote Sensing, IEEE Transactions on* 26 (4), 463-473.

Jupp, D.L.B., Strahler, A.H., Woodcock, C.E., 1989. Autocorrelation and regularization in digital images. II. Simple image models. *Geoscience and Remote Sensing, IEEE Transactions on* 27 (3), 247-258.

Kanellopoulos, I., Wilkinson, G.G., 1997. Strategies and best practice for neural network image classification. *International Journal of Remote Sensing* 18 (4), 711--725.

Kavzoglu, T., Colkesen, I., 2009. A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation* 11 (5), 352-359.

Kayitakire, F., Hamel, C., Defourny, P., 2006. Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. *Remote Sensing of Environment* 102 (3-4), 390-401.

Kennedy, R.E., Townsend, P.A., Gross, J.E., Cohen, W.B., Bolstad, P., Wang, Y.Q., Adams, P., 2009. Remote sensing change detection tools for natural resource managers: Understanding concepts and tradeoffs in the design of landscape monitoring projects. *Remote Sensing of Environment* 113 (7), 1382-1396.

Keuchel, J., Naumann, S., Heiler, M., Siegmund, A., 2003. Automatic land cover analysis for Tenerife by supervised classification using remotely sensed data. *Remote Sensing of Environment* 86 (4), 530-541.

Kimothi, M.M., Dasari, A., 2010. Methodology to map the spread of an invasive plant (*Lantana camara* L.) in forest ecosystems using Indian remote sensing satellite data. *International Journal of Remote Sensing* 31 (12), 3273-3289.

Kohavi, R., John, G.H., 1997. Wrappers for feature subset selection. *Artificial Intelligence* 97 (1-2), 273-324.

Kotsiantis, S., Pintelas, P., 2004. Combining bagging and boosting. *International Journal of Computational Intelligence* 1 (4), 324-333.

Lakshmanan, V., 2004. A separable filter for directional smoothing. *Geoscience and Remote Sensing Letters, IEEE* 1 (3), 192--195.

Lambin, E., Turner, B., Geist, H., Agbola, S., Angelsen, A., Bruce, J., Coomes, O., Dirzo, R., Fischer, G., Folke, C., 2001. The causes of land-use and land-cover change: moving beyond the myths. *Global environmental change* 11 (4), 261-269.

- Lark, R.M., 1996. Geostatistical description of texture on an aerial photograph for discriminating classes of land cover. *International Journal of Remote Sensing* 17 (11), 2115-2133.
- Latifi, H., Nothdurft, A., Koch, B., 2010. Non-parametric prediction and mapping of standing timber volume and biomass in a temperate forest: application of multiple optical/LiDAR-derived predictors. *Forestry* 83 (4), 395-407.
- Lawrence, R., Wood, S., Sheley, R., 2006. Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (RandomForest). *Remote Sensing of Environment* 100 (3), 356-362.
- Li, F., Jackson, T.J., Kustas, W.P., Schmugge, T.J., French, A.N., Cosh, M.H., Bindlish, R., 2004. Deriving land surface temperature from Landsat 5 and 7 during SMEX02/SMACEX. *Remote Sensing of Environment* 92 (4), 521--534.
- Li, H., Gu, H., Han, Y., Yang, J., 2010. Object-oriented classification of high-resolution remote sensing imagery based on an improved colour structure code and a support vector machine. *International Journal of Remote Sensing* 31 (6), 1453 - 1470.
- Li, P., Guo, J., Cheng, T., 2009. Multivariate Image Texture by Multivariate Variogram for Multispectral Image Classification. *Photogrammetric Engineering and Remote Sensing* 75 (2), 147-157.
- Li, P.J., Xu, H.Q., 2010. Land-Cover Change Detection using One-Class Support Vector Machine. *Photogrammetric Engineering and Remote Sensing* 76 (3), 255-263.
- Lillesand, T., Keifer, R., 1994. *Remote Sensing And Image Interpretation*, 3 ed. John Wiley & Sons.
- Lillo-Saavedra, M., Gonzalo, C., 2006. Spectral or spatial quality for fused satellite imagery? A trade-off solution using the wavelet *À trous* algorithm. *International Journal of Remote Sensing* 27 (7), 1453--1464.
- Lillo-Saavedra, M., Gonzalo, C., 2007. Multispectral images fusion by a joint multidirectional and multiresolution representation. *International Journal of Remote Sensing* 28 (18), 4065 - 4079.
- Lippitt, C.D., J., R., Li, Z., Eastman, J.R., Jones, T.G., 2008. Mapping Selective Logging in Mixed Deciduous Forest: A Comparison of Machine Learning Algorithms. *Photogrammetric Engineering and Remote Sensing* 74 (10), 1201-1211.

Liu, Y., Hiyama, T., Yamaguchi, Y., 2006. Scaling of land surface temperature using satellite data: A case examination on ASTER and MODIS products over a heterogeneous terrain area. *Remote Sensing of Environment* 105 (2), 115--128.

Lo, C.P., Shipman, R.L., 1990. A GIS approach to land-use change dynamics detection. *Photogrammetric Engineering & Remote Sensing* 56, 1483--1491.

López Garrido, A.C., Ruiz Ortiz, P.A., Martín Algarra, A., Molina Cámara, J.M., García-Hernández, M., Vera Ferrándiz, J.A., 1989. Las discontinuidades mayores del Jurásico de las Zonas Externas de las Cordilleras Béticas: análisis e interpretación de los ciclos sedimentarios. *Cuadernos de geología ibérica = Journal of iberian geology: an international publication of earth sciences* 13, 35-52.

Loveland, T.R., Belward, A.S., 1997. The IGBP-DIS global 1km land cover data set, DISCover: First results. *International Journal of Remote Sensing* 18 (15), 3289 - 3295.

Loveland, T.R., Estes, J.E., Scepán, J., 1999. Global land cover mapping and validation: Foreword. *Photogrammetric Engineering and Remote Sensing* 65 (9), 1011-1012.

Lu, D., Mausel, P., Brondízio, E., Moran, E., 2004. Change detection techniques. *International Journal of Remote Sensing* 25 (12), 2365--2401.

Lü, Q.-Q., Ding, J.-H., Cui, C.-Y., 2000. Probable satellite thermal infrared anomaly before the Zhangbei  $M=6.2$  earthquake on January 10, 1998. *Acta Seismologica Sinica* 13 (2), 203-209.

Lunetta, R.S., Balogh, M., 1999a. Application of multi-temporal Landsat 5 TM imagery for wetland identification. *Photogrammetric Engineering and Remote Sensing* 65 (11), 1303-1310.

Lunetta, R.S., Balogh, M.E., 1999b. Application of Multi-Temporal Landsat 5 TM Imagery for Wetland Identification. *Photogrammetric Engineering & Remote Sensing* 65, 1303-1310.

Lunetta, R.S., Congalton, R.G., Fenstermaker, L.K., Jensen, J.R., Mcgwire, K.C., Tinney, L.R., 1991. Remote sensing and geographic information system data integration: error sources and research issues. *Photogrammetric Engineering & Remote Sensing* 57, 677-687.

Lloyd, C.D., Berberoglu, S., Curran, P.J., Atkinson, P.M., 2004. A comparison of texture measures for the per-field classification of Mediterranean land cover. *International Journal of Remote Sensing* 25 (19), 3943-3965.

- Macleod, R.D., Congalton, R.G., 1998. A quantitative comparison of Change Detection algorithms for monitoring Eelgrass from remotely sensed data. *Photogrammetric Engineering & Remote Sensing* 64 (3), 207-216.
- Malila, W.A., 1980. Change vector analysis: an approach for detecting forest changes with Landsat, Proceedings of the 6th Annual Symposium on Machine Processing of Remotely Sensed data. pp. 326--335.
- Mallat, S.G., 1999. *A Wavelet Tour of Signal Processing*. Academic Press, San Diego.
- Marçal, A.R.S., Borges, J.S., Gomes, J.A., Costa, J.F.P.D., 2005. Land cover update by supervised classification of segmented ASTER images. *International Journal of Remote Sensing* 26 (7), 1347 - 1362.
- Martinuzzi, S., Vierling, L., Gould, W., Falkowski, M., Evans, J., Hudak, A., Vierling, K., 2009. Mapping snags and understory shrubs for a LiDAR-based assessment of wildlife habitat suitability. *Remote Sensing of Environment* 113 (12), 2533-2546.
- Mas, J., Velázquez, A., Díaz-Gallegos, J., Mayorga-Saucedo, R., Alcántara, C., Bocco, G., Castro, R., Fernández, T., Pérez-Vega, A., 2004. Assessing land use/cover changes: a nationwide multidecade spatial database for Mexico. *International Journal of Applied Earth Observation and Geoinformation* 5 (4), 249-261.
- Mas, J.F., 1999. Monitoring land-cover changes: a comparison of change detection techniques. *International Journal of Remote Sensing* 20, 139-152.
- Mas, J.F., Flores, J.J., 2008. The application of artificial neural networks to the analysis of remotely sensed data. *International Journal of Remote Sensing* 29 (3), 617-663.
- Masry, S.E., Crawley, B.G., W.H., H., 1975. Difference detection. *Photogrammetric Engineering & Remote Sensing* 45, 1145--1148.
- Matheron, G., 1970. *The Theory of the Regionalized Variables and its Applications*, Fontainebleau.
- Matsuyama, T., Miura, S.-I., Nagao, M., 1983. Structural analysis of natural textures by Fourier transformation. *Computer Vision, Graphics, and Image Processing* 24 (3), 347-362.
- McCoy, R.M., 2005. *Field Methods in Remote Sensing*, 1st ed. The Guilford Press, New York.



Melgani, F., Bruzzone, L., 2004. Classification of hyperspectral remote sensing images with support vector machines. *Geoscience and Remote Sensing, IEEE Transactions on* 42 (8), 1778-1790.

Memarsadeghi, N., Le Moigne, J., Mount, D., Morisette, J., 2005. A new approach to image fusion based on cokriging, *The Eighth International Conference on Information Fusion*, Philadelphia, PA, USA, 25-29 July 2005.

Menor-Toribio, J., 1997. Transformaciones recientes en la organización territorial de la Vega de Granada: del espacio agrario territorial a la aglomeración urbana actual. *Estudios regionales* 48, 189-214.

Miller, J., Franklin, J., 2002. Modeling the distribution of four vegetation alliances using generalized linear models and classification trees with spatial dependence. *Ecological Modelling* 157 (2-3), 227-247.

Mingers, J., 1989. An empirical comparison of selection measures for decision-tree induction. *Machine Learning* 3 (4), 319-342.

Miranda, F.P., Fonseca, L.E.N., Carr, J.R., 1998. Semivariogram textural classification of JERS-1 (Fuyo-1) SAR data obtained over a flooded area of the Amazon rainforest. *International Journal of Remote Sensing* 19 (3), 549-556.

Miranda, F.P., Fonseca, L.E.N., Carr, J.R., Taranik, J.V., 1996. Analysis of JERS-1 (Fuyo-1) SAR data for vegetation discrimination in northwestern Brazil using the semivariogram textural classifier (STC). *International Journal of Remote Sensing* 17 (17), 3523-3529.

Miranda, F.P., MacDonald, J.A., Carr, J.R., 1992. Application Of The Semivariogram Textural Classifier (Stc) For Vegetation Discrimination Using Sir-B Data Of Borneo. *International Journal of Remote Sensing* 13 (12), 2349-2354.

MLCG, 2009. MODIS Land Cover Group, <http://www-modis.bu.edu/landcover/>. (April 2011).

Molina, R., Vega, M., Mateos, J., Katsaggelos, A.K., 2008. Variational posterior distribution approximation in Bayesian super resolution reconstruction of multispectral images. *Applied and Computational Harmonic Analysis* 24 (2), 251--267.

Moran, M.S., Jackson, R.D., Slater, P.N., Teillet, P.M., 1992. Evaluation of simplified procedures for retrieval of land surface reflectance factors from satellite sensor output. *Remote Sensing of Environment* 41 (2-3), 169--184.

- Moré, G., Pons, X., 2007. Influencia del número de imágenes en la calidad de la cartografía detallada de vegetación forestal. *Revista de Teledetección* 28, 61-68.
- Moreira-Madueño, J.M., 2006. El sistema de información geográfica-ambiental de Andalucía. Del SINAMBA a la Red de Información Ambiental de Andalucía. *Geofocus* 6, 4-10.
- Mota, J.F., Pérez-García, F.J., Jiménez, M.L., Amate, J.J., Peñas, J., 2002. Phytogeographical relationships among high mountain areas in the Baetic Ranges (South Spain). *Global Ecology and Biogeography* 11 (6), 497-504.
- Mountrakis, G., Im, J., Ogole, C., 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (3), 247-259.
- Muller, K.R., Mika, S., Ratsch, G., Tsuda, K., Scholkopf, B., 2001. An introduction to kernel-based learning algorithms. *Neural Networks, IEEE Transactions on* 12 (2), 181-201.
- Murthy, C.S., Raju, P.V., Badrinath, K.V.S., 2003. Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks. *International Journal of Remote Sensing* 24 (23), 4871 - 4890.
- Na, X.D., Zhang, S.Q., Li, X.F., Yu, H.A., Liu, C.Y., 2010. Improved Land Cover Mapping using Random Forests Combined with Landsat Thematic Mapper Imagery and Ancillary Geographic Data. *Photogrammetric Engineering & Remote Sensing* 76 (7), 833-840.
- Nagler, P.L., Glenn, E.P., Hinojosa-Huerta, O., 2009. Synthesis of ground and remote sensing data for monitoring ecosystem functions in the Colorado River Delta, Mexico. *Remote Sensing of Environment* 113 (7), 1473-1485.
- Nemani, R., Hashimoto, H., Votava, P., Melton, F., Wang, W., Michaelis, A., Mutch, L., Milesi, C., Hiatt, S., White, M., 2009. Monitoring and forecasting ecosystem dynamics using the Terrestrial Observation and Prediction System (TOPS). *Remote Sensing of Environment* 113 (7), 1497-1509.
- Neumann, K., Herold, M., Hartley, A., Schmullius, C., 2007. Comparative assessment of CORINE2000 and GLC2000: Spatial analysis of land cover data for Europe. *International Journal of Applied Earth Observation and Geoinformation* 9 (4), 425-437.
- Nichol, J., Wong, M.S., 2005. Modeling urban environmental quality in a tropical city. *Landscape and Urban Planning* 73 (1), 49--58.

Nishii, R., Kusanobu, S., Tanaka, S., 1996. Enhancement of low spatial resolution image based on high resolution-bands. *Geoscience and Remote Sensing, IEEE Transactions on DOI - 10.1109/36.536531* 34 (5), 1151--1158.

Nunez, J., Otazu, X., Fors, O., Prades, A., Pala, V., Arbiol, R., 1999. Multiresolution-based image fusion with additive wavelet decomposition. *Geoscience and Remote Sensing, IEEE Transactions on* 37 (3), 1204-1211.

Oetter, D.R., Cohen, W.B., Berterretche, M., Maierperger, T.K., Kennedy, R.E., 2001. Land cover mapping in an agricultural setting using multiseasonal Thematic Mapper data. *Remote Sensing of Environment* 76 (2), 139-155.

Ozdemir, I., Norton, D.A., Ozkan, U.Y., Mert, A., Senturk, O., 2008. Estimation of tree size diversity using object oriented texture analysis and aster imagery. *Sensors* 8 (8), 4709-4724.

Ozyavuz, M., Satir, O., Bilgili, B.C., 2011. A change vector analysis technique to monitor land-use/land-cover in the Yildiz mountains, Turkey. *Fresenius Environmental Bulletin* 20 (5), 1190-1199.

P., C.J., Delfiner, P., 1999. *Geostatistics: modelling spatial uncertainty*, 1 st ed. John Wiley and Sons, New York.

Pacifici, F., Chini, M., Emery, W.J., 2009. A neural network approach using multi-scale textural metrics from very high-resolution panchromatic imagery for urban land-use classification. *Remote Sensing of Environment* 113 (6), 1276-1292.

Pal, M., 2005. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing* 26 (1), 217-222.

Pal, M., Foody, G.M., 2010. Feature Selection for Classification of Hyperspectral Data by SVM. *Geoscience and Remote Sensing, IEEE Transactions on* 48 (5), 2297-2307.

Pal, M., Mather, P.M., 2003. An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment* 86 (4), 554-565.

Pardo-Iguzquiza, E., Chica-Olmo, M., Atkinson, P.M., 2006. Downscaling cokriging for image sharpening. *Remote Sensing of Environment* 102 (1-2), 86--98.

Pardo-Iguzquiza, E., Rodríguez-Galiano, V.F., Chica-Olmo, M., Atkinson, P.M., 2011. Image fusion by spatially adaptive filtering using downscaling cokriging. *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (3), 337-346.

- Parrinello, T., Vaughan, R.A., 2002. Multifractal analysis and feature extraction in satellite imagery. *International Journal of Remote Sensing* 23 (9), 1799-1825.
- Pasher, J., King, D.J., 2010. Multivariate forest structure modelling and mapping using high resolution airborne imagery and topographic information. *Remote Sensing of Environment* 114 (8), 1718-1732.
- Pax-Lenney, Woodcock, C.E., Collins, J.B., Hamdi, H., 1996. The status of agricultural lands in Egypt: The use of multitemporal NDVI features derived from landsat TM. *Remote Sensing of Environment* 56 (1), 8-20.
- Pax-Lenney, M., Woodcock, C.E., 1997. Monitoring agricultural lands in Egypt with multitemporal Landsat TM imagery: How many images are needed? *Remote Sensing of Environment* 59 (3), 522-529.
- Pax-Lenney, M., Woodcock, C.E., Macomber, S.A., Gopal, S., Song, C., 2001. Forest mapping with a generalized classifier and Landsat TM data. *Remote Sensing of Environment* 77 (3), 241--250.
- Pellemans, A.H.J.M., Jordans, R.W.A., R., 1993. Merging Multispectral and Panchromatic SPOT Images with respect to the Radioelectric Properties of the Sensor. *Photogrammetric Engineering & Remote Sensing* 59, 81-87.
- Pérez-Hoyos, A., García-Haro, F.J., 2009. Análisis Comparativo de las Principales Cartografías de Coberturas del Suelo en la Península Ibérica, In: Hornos, S.M.A.y.L.F. (Ed.), *Teledetección: Agua y desarrollo sostenible*. XIII Congreso de la Asociación Española de Teledetección, Calatayud, 23-26 de Septiembre. pp. 209-212.
- Peters, J., De Baets, B., Verhoest, N.E.C., Samson, R., Degroeve, S., De Becker, P., Huybrechts, W., 2007. Random forests as a tool for ecohydrological distribution modelling. *Ecological Modelling* 207 (2-4), 304-318.
- Pieri, D., Abrams, M., 2005. ASTER observations of thermal anomalies preceding the April 2003 eruption of Chikurachki volcano, Kurile Islands, Russia. *Remote Sensing of Environment* 99 (1-2), 84-94.
- Plaza, A., Benediktsson, J.A., Boardman, J.W., Brazile, J., Bruzzone, L., Camps-Valls, G., Chanussot, J., Fauvel, M., Gamba, P., Gualtieri, A., Marconcini, M., Tilton, J.C., Trianni, G., 2009. Recent advances in techniques for hyperspectral image processing. *Remote Sensing of Environment* 113 (Supplement 1), S110-S122.
- Potapov, P., Turubanova, S., Hansen, M.C., 2011. Regional-scale boreal forest cover and change mapping using Landsat data composites for European Russia. *Remote Sensing of Environment* 115 (2), 548-561.

- Prasad, A.M., Iverson, L.R., Liaw, A., 2006. Newer Classification and Regression Tree Techniques: Bagging and Random Forests for Ecological Prediction. *Ecosystems* 9 (2), 191-199.
- Prenzel, B., 2004. Remote sensing-based quantification of land-cover and land-use change for planning. *Progress in Planning* 61 (4), 281-299.
- Quattrochi, D.A., Luvall, J.C., 1999. Thermal infrared remote sensing for analysis of landscape ecological processes: methods and applications. *Landscape Ecology* 14 (6), 577-598.
- Quinlan, J.R., 1993. *C4.5 Programs for Machine Learning*, 1st ed. Morgan Kaufmann, San Mateo, CA.
- Rahman, A.F., Gamon, J.A., Sims, D.A., Schmidts, M., 2003. Optimum pixel size for hyperspectral studies of ecosystem function in southern California chaparral and grassland. *Remote Sensing of Environment* 84 (2), 192-207.
- Rajesh, K., Jawahar, C.V., Sengupta, S., Sinha, S., 2001. Performance analysis of textural features for characterization and classification of SAR images. *International Journal of Remote Sensing* 22 (8), 1555-1569.
- Ramstein, G., Raffy, M., 1989. Analysis of the structure of radiometric remotely-sensed images. *International Journal of Remote Sensing* 10 (6), 1049-1073.
- Ranchin, T., Aiazzi, B., Alparone, L., Baronti, S., Wald, L., 2003. Image fusion--the ARSIS concept and some successful implementation schemes. *ISPRS Journal of Photogrammetry and Remote Sensing* 58 (1-2), 4--18.
- Ranchin, T., Wald, L., 2000. Fusion of high spatial and spectral resolution images: the ARSIS concept and its implementation. *Photogrammetric Engineering and Remote Sensing* 66, 49--61.
- Richter, D.M., 1969. Sequential urban change. *Photogrammetric Engineering* 35, 764-770.
- Ripley, B.D., 1993. Statistical aspects of neural networks, *Networks and Chaos — Statistical and Probabilistic Aspects*. Chapman & Hall, London, pp. 40-123.
- Ripley, B.D., 1994. Neural networks and flexible regression and discrimination, *Statistics and Images Carfax*, Abingdon, pp. 39-57.
- Rodríguez-Martínez, F., 2003. Reseña de "Atlas Temático de la Provincia de Granada". *Cuadernos Geográficos* 33, 163-166.

- Rogan, J., Chen, D., 2004. Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in Planning* 61 (4), 301-325.
- Rogan, J., Franklin, J., Roberts, D.A., 2002. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. *Remote Sensing of Environment* 80 (1), 143-156.
- Rogan, J., Franklin, J., Stow, D., Miller, J., Woodcock, C., Roberts, D., 2008. Mapping land-cover modifications over large areas: A comparison of machine learning algorithms. *Remote Sensing of Environment* 112 (5), 2272-2283.
- Rogan, J., Miller, J., 2006. Integrating GIS and remotely sensed data for mapping forest disturbance and change, In: Franklin, M.W.a.S. (Ed.), *Understanding Forest Disturbance and Spatial Pattern: Remote Sensing and GIS Approaches*. CRC Press, Boca Raton, FL, pp. 133--172.
- Rogan, J., Miller, J., Stow, D., Franklin, J., Levien, L., Fischer, C., 2003. Land-Cover Change Monitoring with Classification Trees Using Landsat TM and Ancillary Data. *Photogrammetric Engineering and Remote Sensing* 69 (7), 793-784.
- RSI, 2007. *FLAASH Module User's Guide*, ITT Visual Information Solutions ed. ITT Visual Information Solutions, ITT Visual Information Solutions.
- Saeys, Y., Inza, I., Larrañaga, P., 2007. A review of feature selection techniques in bioinformatics. *Bioinformatics* 23 (19), 2507-2517.
- Sanz de Galdeano, C., Vera, J.A., 1992. Stratigraphic record and palaeogeographical context of the Neogene basins in the Betic Cordillera, Spain. *Basin Research* 4 (1), 21-36.
- Schölkopf, B., Smola, A.J., 2001. *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*, 1st ed. The MIT Press, Cambridge, MA, USA.
- Schott, J.R., Salvaggio, C., Volchok, W.J., 1988. Radiometric scene normalization using pseudoinvariant features. *Remote Sensing of Environment* 26 (1), 1--14.
- Schriever, J.R., Congalton, R.G., 1995. Evaluating seasonal variability as an aid to cover-type mapping from Landsat Thematic Mapper data in the Northeast. *Photogrammetric Engineering and Remote Sensing* 61 (3), 321-327.
- Schroeder, T.A., Cohen, W.B., Song, C., Canty, M.J., Yang, Z., 2006. Radiometric correction of multi-temporal Landsat data for characterization of early successional forest patterns in western Oregon. *Remote Sensing of Environment* 103 (1), 16--26.

Serra, P., Pons, X., Saurí, D., 2003. Post-classification change detection with data from different sensors: some accuracy considerations. *International Journal of Remote Sensing* 24 (16), 3311-3340.

Sesnie, S., Gessler, P., Finegan, B., Thessler, S., 2008. Integrating Landsat TM and SRTM-DEM derived variables with decision trees for habitat classification and change detection in complex neotropical environments. *Remote Sensing of Environment* 112 (5), 2145-2159.

Seto, K.C., Liu, W., 2003. Comparing ARTMAP Neural Network with the Maximum-Likelihood Classifier for Detecting Urban Change. *Photogrammetric Engineering and Remote Sensing* 69 (9), 981-990.

Sierra-Araujo, B., 2006. *Aprendizaje Automático: Conceptos Básicos y Avanzados*, 1st ed. Pearson Prentice Hall, Madrid.

Simard, M., Saatchi, S.S., De Grandi, G., 2000. The use of decision tree and multiscale texture for classification of JERS-1 SAR data over tropical forest. *Geoscience and Remote Sensing, IEEE Transactions on* 38 (5), 2310-2321.

Simone, G., Farina, A., Morabito, F.C., Serpico, S.B., Bruzzone, L., 2002. Image fusion techniques for remote sensing applications. *Information Fusion* 3 (1), 3-15.

Singh, A., 1986. *Remote Sensing and Tropical Land Management*, In: Eden, M.J., Parry, J.T. (Eds.). John Wiley & Sons, pp. 237--254.

Singh, A., 1989. Digital change detection techniques using remotely-sensed data. *International Journal of Remote Sensing* 10, 989--1003.

Sobrino, J.A., Jiménez-Muñoz, J.C., Paolini, L., 2004. Land surface temperature retrieval from LANDSAT TM 5. *Remote Sensing of Environment* 90 (4), 434-440.

Sobrino, J.A., Jiménez-Muñoz, J.C., Zarco-Tejada, P.J., Sepulcre-Cantó, G., de Miguel, E., 2006. Land surface temperature derived from airborne hyperspectral scanner thermal infrared data. *Remote Sensing of Environment* 102 (1-2), 99--115.

Sobrino, J.A., Jimenez-Muoz, J.C., Soria, G., Romaguera, M., Guanter, L., Moreno, J., Plaza, A., Martinez, P., 2008. Land Surface Emissivity Retrieval From Different VNIR and TIR Sensors. *Geoscience and Remote Sensing, IEEE Transactions on* DOI - 10.1109/TGRS.2007.904834 46 (2), 316--327.

Sobrino, J.A., Raissouni, N., 2000. Toward remote sensing methods for land cover dynamic monitoring: Application to Morocco. *International Journal of Remote Sensing* 21 (2), 353 - 366.

Song, C., Woodcock, C.E., Seto, K.C., Lenney, M.P., Macomber, S.A., 2001. Classification and Change Detection Using Landsat TM Data: When and How to Correct Atmospheric Effects? *Remote Sensing of Environment* 75 (2), 230--244.

Stathopoulou, M., Cartalis, C., 2009. Downscaling AVHRR land surface temperatures for improved surface urban heat island intensity estimation. *Remote Sensing of Environment* 113 (12), 2592--2605.

Steinwart, I., Christmann, A., 2008. *Support Vector Machines*, 1st ed. Springer.

Story, M., Congalton, R., 1986. Accuracy Assessment: A User's Perspective. *Photogrammetric Engineering & Remote Sensing* 52 (3), 397-399.

Strahler, A.H., Woodcock, C.E., Smith, J.A., 1986. On the nature of models in remote sensing. *Remote Sensing of Environment* 20 (2), 121-139.

Stuckens, J., Coppin, P.R., Bauer, M.E., 2000. Integrating Contextual Information with per-Pixel Classification for Improved Land Cover Classification. *Remote Sensing of Environment* 71 (3), 282-296.

Sun, X.H., Qin, P., 1993. Texture analysis for remotely sensed imagery, Ninth Thematic Conference on Geological Remote Sensing, Pasadena, CA. pp. 311-322.

Svancara, L.K., Scott, J.M., Loveland, T.R., Pidgorna, A.B., 2009. Assessing the landscape context and conversion risk of protected areas using satellite data products. *Remote Sensing of Environment* 113 (7), 1357-1369.

Tang, Q.H., Peterson, S., Cuenca, R.H., Hagimoto, Y., Lettenmaier, D.P., 2009. Satellite-based near-real-time estimation of irrigated crop water consumption. *JOURNAL OF GEOPHYSICAL RESEARCH-ATMOSPHERES* 114.

Torres, O., Bhartia, P.K., Herman, J.R., Ahmad, Z., 1998. Derivation of aerosol properties from satellite measurements of backscattered ultraviolet radiation. Theoretical Basis. *J. Geophys. Res* 103, 17099--17110.

Torres, O., Bhartia, P.K., Herman, J.R., Sinyuk, A., Holben, B., 2002. A long term record of aerosol optical thickness from TOMS observations and comparison to AERONET measurements. *J. Atm. Sci.* 59, 398--413.

Townsend, P.A., Lookingbill, T.R., Kingdon, C.C., Gardner, R.H., 2009. Spatial pattern analysis for monitoring protected areas. *Remote Sensing of Environment* 113 (7), 1410-1420.



- Treitz, P., Howarth, P., 2000. High Spatial Resolution Remote Sensing Data for Forest Ecosystem Classification: An Examination of Spatial Scale. *Remote Sensing of Environment* 72 (3), 268-289.
- Treitz, P., Rogan, J., 2004. Remote sensing for mapping and monitoring land-cover and land-use change--an introduction. *Progress in Planning* 61 (4), 269-279.
- Tso, B., Mather, P.M., 2009. *Classification Methods for Remotely Sensed Data*, 2nd ed. CRC Press, New York.
- Tu, T.-M., Lee, Y.-C., Chang, C.-P., Huang, P.S., 2005. Adjustable intensity-hue-saturation and Brovey transform fusion technique for IKONOS/QuickBird imagery. *Optical Engineering* 44 (11), 116201-116201 to 116021-116210.
- Turner, B., Lambin, E., Reenberg, A., 2007. The emergence of land change science for global environmental change and sustainability. *Proceedings of the National Academy of Sciences* 104 (52), 20666.
- Utgoff, P.E., Brodley, C.E., 1990. An Incremental Method for Finding Multivariate Splits for Decision Trees, *Proceedings of the Seventh International Conference on Machine Learning*. Morgan Kaufmann, Austin, TX. pp. 58-65.
- Valor, E., Caselles, V., 1996. Mapping land surface emissivity from NDVI: Application to European, African, and South American areas. *Remote Sensing of Environment* 57 (3), 167-184.
- Van De Griend, A.A., Owe, M., 1993. On the relationship between thermal emissivity and the normalized difference vegetation index for natural surfaces. *International Journal of Remote Sensing* 14 (6), 1119 - 1131.
- Vaughan, R.G., Keszthelyi, L.P., Davies, A.G., Schneider, D.J., Jaworowski, C., Heasler, H., 2010. Exploring the limits of identifying sub-pixel thermal features using ASTER TIR data. *Journal of Volcanology and Geothermal Research* 189 (3-4), 225--237.
- Vega, M., Mateos, J., Molina, R., Katsaggelos, A.K., 2010. Super Resolution of Multispectral Images using 11 Image Models and interband correlations. *Journal of Signal Processing Systems*.
- Venables, W.N., Ripley, B.D., 2002. *Modern Applied Statistics with S*, 4th ed. Springer, New York, USA.
- Vera, J.A., 1986. Las Zonas Externas de la Cordillera Bética, In: IGME (Ed.), *Geología de España*, Libro Homenaje J.M. Ríos, pp. 218-251.

- Vera, J.A., 1994. Geología de Andalucía. Enseñanza de las ciencias de la tierra: Revista de la Asociación Española para la Enseñanza de las Ciencias de la Tierra 2 (2-3), 306-315.
- Volz, F.E., 1972. Infrared Absorption by Atmospheric Aerosol Substances. *J. Geophys. Res.* 77, 1017-1031.
- Volz, F.E., 1973. Infrared Optical Constants of Ammonium Sulfate, Sahara Dust, Volcanic Pumice, and Flyash. *Appl. Opt.* 12, 564-568.
- Voogt, J.A., Oke, T.R., 2003. Thermal remote sensing of urban climates. *Remote Sensing of Environment* 86 (3), 370-384.
- Wackernagel, H., 2003. *Multivariate Geostatistics: An Introduction with Applications*, 3rd ed. Springer, New York.
- Wagner, R.R., 1963. Using aerial photos to measure changes in land use around highway interchanges. *Photogrammetric Engineering* 29, 645-649.
- Wald, L., 1999. Some terms of reference in data fusion. *Geoscience and Remote Sensing, IEEE Transactions on* 37 (3), 1190-1193.
- Wald, L., 2000. Quality of high resolution synthesized images: is there a simple criterion?, *International Conference on Fusion of Earth Data*, Nice, France, 26-28 January 2000.
- Wald, L., Ranchin, T., Mangolini, M., 1997. Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images. *Photogrammetric Engineering & Remote Sensing* 63 (6), 691-699.
- Wang, X.L., Waske, B., Benediktsson, J.A., 2009a. Ensemble Methods for Spectral-Spatial Classification of Urban Hyperspectral Data. 2009 *Ieee International Geoscience and Remote Sensing Symposium*, Vols 1-5), 3324-3327.
- Wang, Y., Mitchell, B.R., Nugranad-Marzilli, J., Bonyng, G., Zhou, Y., Shriver, G., 2009b. Remote sensing of land-cover change and landscape context of the National Parks: A case study of the Northeast Temperate Network. *Remote Sensing of Environment* 113 (7), 1453-1461.
- Wang, Z., Bovik, A.C., 2002. A universal image quality index. *Signal Processing Letters, IEEE* 9 (3), 81--84.
- Wang, Z., Bovik, A.C., Sheikh, H.R., Simoncelli, E.P., 2004. Image quality assessment: from error visibility to structural similarity. *Image Processing, IEEE Transactions on DOI - 10.1109/TIP.2003.819861* 13 (4), 600--612.

Waske, B., Braun, M., 2009. Classifier ensembles for land cover mapping using multitemporal SAR imagery. *ISPRS Journal of Photogrammetry and Remote Sensing* 64 (5), 450-457.

Watanachaturaporn, P., Arora, M.K., Varshney, P.K., 2008. Multisource Classification Using Support Vector Machines: An Empirical Comparison with Decision Tree and Neural Network Classifiers. *Photogrammetric Engineering and Remote Sensing* 74 (2), 239-246.

Wessels, K.J., De Fries, R.S., Dempewolf, J., Anderson, L.O., Hansen, A.J., Powell, S.L., Moran, E.F., 2004. Mapping regional land cover with MODIS data for biological conservation: Examples from the Greater Yellowstone Ecosystem, USA and Pará State, Brazil. *Remote Sensing of Environment* 92 (1), 67-83.

Whitby, K.T., Cantrell, B., 1975. Atmospheric Aerosols-Characteristics and Measurement, International Conf. on Environmental Sensing and Assessment, Las Vegas, Nevada.

Wickware, G.M., Howarth, P.J., 1981. Change detection in the Peace-Athabasca delta using digital Landsat data. *Remote Sensing of Environment* 11 (1), 9-25.

Wilkinson, G.G., 2005. Results and implications of a study of fifteen years of satellite image classification experiments. *Geoscience and Remote Sensing, IEEE Transactions on* 43 (3), 433-440.

Wolter, P.T., Mladenoff, D.J., Host, G.E., G.E., T.R., 1995. Improved forest classification in the Northern Lake States using multi-temporal Landsat imagery. *Photogrammetric Engineering & Remote Sensing* 61 (9), 1129-1143.

Woodcock, C.E., Strahler, A.H., 1987. The factor of scale in remote sensing. *Remote Sensing of Environment* 21 (3), 311-332.

Woodcock, C.E., Strahler, A.H., Jupp, D.L.B., 1988a. The use of variograms in remote sensing: I. Scene models and simulated images. *Remote Sensing of Environment* 25 (3), 323-348.

Woodcock, C.E., Strahler, A.H., Jupp, D.L.B., 1988b. The use of variograms in remote sensing: II. Real digital images. *Remote Sensing of Environment* 25 (3), 349-379.

Wright, C., Gallant, A., 2007. Improved wetland remote sensing in Yellowstone National Park using classification trees to combine TM imagery and ancillary environmental data. *Remote Sensing of Environment* 107 (4), 582-605.

- Wunderle, A.L., Franklin, S.E., Guo, X.G., 2007. Regenerating boreal forest structure estimation using SPOT-5 pan-sharpened imagery. *International Journal of Remote Sensing* 28 (19), 4351-4364.
- Xian, G., Homer, C., 2010. Updating the 2001 National Land Cover Database Impervious Surface Products to 2006 using Landsat Imagery Change Detection Methods. *Remote Sensing of Environment* 114 (8), 1676-1686.
- Xiaolong, D., Khorram, S., 1998. The effects of image misregistration on the accuracy of remotely sensed change detection. *Geoscience and Remote Sensing, IEEE Transactions on* 36 (5), 1566-1577.
- Xie, Z., Roberts, C., Johnson, B., 2008. Object-based target search using remotely sensed data: A case study in detecting invasive exotic Australian Pine in south Florida. *ISPRS Journal of Photogrammetry and Remote Sensing* 63 (6), 647-660.
- Yang, X., 2011. Parameterizing Support Vector Machines for Land Cover Classification. *Photogrammetric Engineering and Remote Sensing* 77 (1), 27--37.
- Yang, X., Lo, C.P., 2000. Relative radiometric normalization performance for change detection from multi-date satellite images. *Photogrammetric Engineering & Remote Sensing* 66, 967--980.
- Yocky, D.A., 1996. Multiresolution wavelet decomposition image merger of Landsat Thematic Mapper and SPOT panchromatic data. *Photogrammetric Engineering and Remote Sensing* 62, 1067--1074.
- Yu, S., De Backer, S., Scheunders, P., 2002. Genetic feature selection combined with composite fuzzy nearest neighbor classifiers for hyperspectral satellite imagery. *Pattern Recognition Letters* 23 (1-3), 183-190.
- Yuan, D., Elvidge, C., 1998. NALC Land Cover Change Detection Pilot Study: Washington D.C. Area Experiments. *Remote Sensing of Environment* 66 (2), 166-178.
- Yuan, F., Bauer, M.E., Heinert, N.J., Holden, G., 2005a. Multi-level land cover mapping of the Twin Cities (Minnesota) metropolitan area with multi-seasonal Landsat TM/ETM + data. *Geocarto International* 20 (2), 5-14.
- Yuan, F., Sawaya, K.E., Loeffelholz, B.C., Bauer, M.E., 2005b. Land cover classification and change analysis of the Twin Cities (Minnesota) Metropolitan Area by multitemporal Landsat remote sensing. *Remote Sensing of Environment* 98 (2-3), 317-328.

Zhang, B., Zhang, Y., Song, K., Zhang, B., 2004a. Detection of Sea Surface Temperature (SST) and Salinity Using Thermal Infrared Data of AVHRR and MODIS in the Gulf of Bohai Sea of China. *International Journal of Infrared and Millimeter Waves* 25 (1), 129-137.

Zhang, C., Franklin, S.E., Wulder, M.A., 2004b. Geostatistical and texture analysis of airborne-acquired images used in forest classification. *International Journal of Remote Sensing* 25 (4), 859-865.

Zhang, X., Feng, X., Jiang, H., 2010. Object-oriented method for urban vegetation mapping using IKONOS imagery. *International Journal of Remote Sensing* 31 (1), 177-196.

Zhang, Y., Hong, G., 2005. An IHS and wavelet integrated approach to improve pan-sharpening visual quality of natural colour IKONOS and QuickBird images. *Information Fusion* 6 (3), 225-234.

Zhang, Y.D., Wu, L.N., Neggaz, N., Wang, S.H., Wei, G., 2009. Remote-Sensing Image Classification Based on an Improved Probabilistic Neural Network. *Sensors* 9 (9), 7516-7539.

Zhou, L.B., Yang, X.J., 2010. Training Algorithm Performance for Image Classification by Neural Networks. *Photogrammetric Engineering and Remote Sensing* 76 (8), 945-951.