



Departamento de Ingeniería Gráfica y Geomática

TESIS DOCTORAL

**EVALUACIÓN DE MÉTODOS BASADOS EN PÍXELES Y OBJETOS  
PARA LA CLASIFICACIÓN DE USOS DE SUELO CON IMÁGENES DE  
SATÉLITE QUICKBIRD, PARA EL SEGUIMIENTO DE MEDIDAS  
AGROAMBIENTALES Y LA OPTIMIZACIÓN DEL USO DE  
HERBICIDAS CON AGRICULTURA DE PRECISIÓN**

*Isabel Luisa Castillejo González*

Córdoba, Mayo 2011

**TITULO:** *Evaluación de métodos basados en píxeles y objetos para la clasificación de usos de suelo con imágenes de satélite Quickbird, para el seguimiento de medidas agroambientales y la optimización del uso de herbicidas con agricultura de precisión.*

**AUTOR:** *Isabel Luisa Castillejo González*

---

© Edita: Servicio de Publicaciones de la Universidad de Córdoba. 2011  
Campus de Rabanales  
Ctra. Nacional IV, Km. 396  
14071 Córdoba

[www.uco.es/publicaciones](http://www.uco.es/publicaciones)  
[publicaciones@uco.es](mailto:publicaciones@uco.es)

---

ISBN-13: 978-84-694-4761-1



UNIVERSIDAD DE CÓRDOBA

Departamento de Ingeniería Gráfica y Geomática

TESIS DOCTORAL

**EVALUACIÓN DE MÉTODOS BASADOS EN PÍXELES Y OBJETOS  
PARA LA CLASIFICACIÓN DE USOS DE SUELO CON IMÁGENES DE  
SATÉLITE QUICKBIRD, PARA EL SEGUIMIENTO DE MEDIDAS  
AGROAMBIENTALES Y LA OPTIMIZACIÓN DEL USO DE  
HERBICIDAS CON AGRICULTURA DE PRECISIÓN**

Directores: Dr. D. Alfonso García-Ferrer Porras

Dra. D<sup>a</sup> Francisca López Granados

Autor: *Isabel Luisa Castillejo González*

Córdoba, Mayo 2011





## **TÍTULO DE LA TESIS:**

EVALUACIÓN DE MÉTODOS BASADOS EN PÍXELES Y OBJETOS PARA LA CLASIFICACIÓN DE USOS DE SUELO CON IMÁGENES DE SATÉLITE QUICKBIRD, PARA EL SEGUIMIENTO DE MEDIDAS AGROAMBIENTALES Y LA OPTIMIZACIÓN DEL USO DE HERBICIDAS CON AGRICULTURA DE PRECISIÓN.

**DOCTORANDO/A:** ISABEL LUISA CASTILLEJO GONZÁLEZ

## **INFORME RAZONADO DEL/DE LOS DIRECTOR/ES DE LA TESIS**

**Alfonso García-Ferrer Porras y Francisca López Granados**, como directores de la tesis titulada “***EVALUACIÓN DE MÉTODOS BASADOS EN PÍXELES Y OBJETOS PARA LA CLASIFICACIÓN DE USOS DE SUELO CON IMÁGENES DE SATÉLITE QUICKBIRD, PARA EL SEGUIMIENTO DE MEDIDAS AGROAMBIENTALES Y LA OPTIMIZACIÓN DEL USO DE HERBICIDAS CON AGRICULTURA DE PRECISIÓN***” realizada por **Isabel Luisa Castillejo González**,

## **INFORMAN:**

Que dicha Tesis Doctoral ha sido realizada bajo nuestra dirección.

Que ha tenido como principal objetivo analizar un conjunto de técnicas de teledetección aplicadas sobre imágenes QuickBird de alta resolución espacial con objeto de evaluar la capacidad de discriminación de distintos usos del suelo para facilitar la toma de decisiones en la gestión de técnicas agrarias. Se han evaluado métodos basados en píxeles y objetos para determinar la capacidad de clasificación de usos de suelo como base del seguimiento de distintas medidas agroambientales propias de la agricultura de conservación. Por otra parte, se ha realizado un estudio multitemporal en el que se ha determinado el estado fenológico propicio para la discriminación de la mala hierba *Avena sterilis* L. en parcelas de trigo (*Triticum durum* L.), la capacidad de discriminación de infestaciones de esta mala hierba mediante técnicas basadas en píxeles y objetos y la estabilidad espacial de las infestaciones, todo ello con objeto de valorar su aplicabilidad en agricultura de precisión mediante el diseño y evaluación de mapas de manejo localizado de malas hierbas.

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

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

### **REVISTAS INCLUIDAS EN EL SCI**

I.L. Castillejo-González, F. López-Granados, A. García-Ferrer, J.M. Peña-Barragán, M. Jurado-Expósito, M. Sánchez De La Orden y M González De Audicana. 2009. Object and pixel-based classification for mapping crops and their agri-environmental associated measures in QuickBird images. *Computers and Electronics in Agriculture* 68, 207-215.

M.T. Gómez-Casero, I.L. Castillejo-González, A. García-Ferrer, J.M. Peña-Barragán, M. Jurado-Expósito, L. García-Torres y F. López-Granados. 2010. Spectral discrimination of wild oat and canary grass in wheat fields for less herbicide application. *Agronomy for Sustainable Development* 30, 689-699.

### **REVISTAS NO INCLUIDAS EN EL SCI (con revisión por pares)**

F. López-Granados, I.L. Castillejo-González, J.M. Peña-Barragán, M. Jurado-Expósito, M. Sánchez De La Orden, L. García-Torres y A. García-Ferrer. 2009. QuickBird image segmentation for mapping crops and their agro-environmental associated measures. *Revista de Teledetección* 31, 52-63.

### **APORTACIONES A CONGRESOS**

M.T. Gómez-Casero, F. López-Granados, I.L. Castillejo-González, J.M. Peña-Barragán, M. Jurado-Expósito, A. Gelan-Begna y L. García-Torres. 2007. Discriminación multiespectral y multitemporal de trigo, *Avena sterilis* y *Phalaris braschystachys* en fase tardía. *XI Congreso de la Sociedad Española de Malherbología*, Albacete, España, pp. 319-322.

I.L. Castillejo-González, A. García-Ferrer, M. Sánchez De La Orden, R. García-Castillo, F. López-Granados. 2008. Análisis de técnicas de clasificación de imágenes satélite basadas en píxeles y objetos para la planificación y gestión de recursos naturales. *XIII Congreso Nacional de Tecnologías de la Información Geográfica*, Las Palmas de Gran Canaria, España, pp. 10-20.

Que consideramos que el trabajo realizado cumple los requisitos necesarios para su presentación y lectura.

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

Córdoba, 13 de mayo de 2011

Firma del/de los director/es

Fdo.: Alfonso García-Ferrer Porras

Fdo.: Francisca López Granados







# Índice

## **Introducción ..... 3**

<b>1. Teledetección.....</b>	<b>3</b>
1.1. <i>Análisis y clasificación digital.....</i>	4
1.2. <i>Clasificación orientada a objetos.....</i>	7
1.3. <i>Espectrorradiometría de campo y firmas espectrales .....</i>	10
<b>2. Nuevas técnicas agrícolas .....</b>	<b>12</b>
2.1. <i>Agricultura de conservación .....</i>	12
2.2. <i>Agricultura de conservación y teledetección .....</i>	14
2.3. <i>Agricultura de precisión .....</i>	15
2.4. <i>Agricultura de precisión y teledetección .....</i>	16
2.5. <i>Control Localizado de Malas Hierbas (CLMH).....</i>	16
2.6. <i>Control Localizado de Malas Hierbas (CLMH) y teledetección.....</i>	17
<b>3. Objetivos y estructura de la tesis.....</b>	<b>19</b>
<b>4. Referencias .....</b>	<b>20</b>

## **Análisis basado en píxeles y objetos para la detección de cultivos y sus medidas agroambientales mediante imágenes QuickBird..... 33**

## **Resumen ..... 33**

<b>1. Introducción.....</b>	<b>34</b>
1.1. Generalidades.....	34
1.2. Agricultura y teledetección .....	34
1.3. Fusión de imágenes .....	35
1.4. Clasificación digital .....	35
1.5. Segmentación .....	36
1.6. Objetivos.....	37
<b>2. Materiales .....</b>	<b>37</b>
2.1. <i>Usos de suelo y adquisición de datos.....</i>	37
2.2. <i>Imágenes de satélite y pre-procesado .....</i>	39
<b>3. Metodología.....</b>	<b>39</b>
3.1. <i>Fusión (pansharpen) .....</i>	39
3.2. <i>Segmentación.....</i>	42
3.3. <i>Clasificación y precisión .....</i>	46
<b>4. Resultados .....</b>	<b>48</b>
<b>5. Discusión.....</b>	<b>58</b>
<b>6. Referencias .....</b>	<b>61</b>

# **Discriminación espectral multitemporal de avena loca (*Avena sterilis* L.) y alpiste (*Phalaris* spp.) en campos de trigo (*Triticum durum* L.) en estados fenológicos tardíos ..... 69**

<b>Resumen</b> .....	<b>69</b>
<b>1. Introducción</b> .....	<b>71</b>
1.1. Generalidades .....	71
1.2. Caracterización espectral del cultivo y las malas hierbas.....	71
1.3. Sensores hiperespectrales vs multiespectrales .....	72
1.4. Utilización de índices de vegetación .....	73
1.5. Objetivos .....	74
<b>2. Materiales</b> .....	<b>74</b>
2.1. Zona de estudio .....	74
2.2. Lecturas espectrales .....	76
<b>3. Metodología</b> .....	<b>77</b>
3.1. Análisis discriminante .....	77
3.2. Escenarios agronómicos considerados .....	79
<b>4. Resultados</b> .....	<b>80</b>
4.1. Análisis hiperespectral y multitemporal.....	80
4.2. Análisis multiespectral y multitemporal con índices de vegetación .....	86
<b>5. Discusión</b> .....	<b>91</b>
<b>6. Referencias</b> .....	<b>95</b>

# **Clasificación de infestaciones de Avena (*Avena sterilis* L.) en trigo (*Triticum durum* L.) mediante técnicas basadas en píxeles y objetos con imágenes QuickBird ..... 103**

<b>Resumen</b> .....	<b>103</b>
<b>1. Introducción</b> .....	<b>105</b>
1.1. Conceptos generales .....	105
1.2. Control Localizado de Malas Hierbas (CLMH).....	106
1.3. Teledetección: discriminación temprana vs tardía de malas hierbas.....	106
1.4. Clasificación digital .....	107
1.5. Segmentación.....	108
1.6. Objetivos.....	109
<b>2. Materiales</b> .....	<b>110</b>
2.1. Zona de estudio .....	110
2.2. Imágenes satélite y pre-procesado .....	112
<b>3. Metodología</b> .....	<b>113</b>
3.1. Clasificación a “escala parcela” .....	113
3.1.1. Análisis de separabilidad espectral .....	113
3.1.2. Segmentación .....	113
3.1.3. Clasificación y verificación.....	115

3.2.	<i>Clasificación a “escala imagen”</i> .....	117
3.2.1.	<i>Detección de parcelas de trigo</i> .....	117
3.2.2.	<i>Discriminación de avenas en parcelas trigo</i> .....	123
<b>4.</b>	<b>Resultados</b> .....	<b>124</b>
4.1.	<i>Clasificación a “escala parcela”</i> .....	124
4.2.	<i>Clasificación a “escala imagen”</i> .....	133
4.2.1.	<i>Discriminación de parcelas de trigo</i> .....	133
4.2.2.	<i>Detección de avena en trigo</i> .....	135
<b>5.</b>	<b>Discusión</b> .....	<b>137</b>
<b>6.</b>	<b>Referencias</b> .....	<b>140</b>

## **Estabilidad de los rodales de *Avena sterilis* en trigo: análisis espacial de la persistencia..... 147**

<b>Resumen</b> .....	<b>147</b>	
<b>1. Introducción</b> .....	<b>149</b>	
1.1.	<i>Control Localizado de Malas Hierbas (CLMH)</i> .....	149
1.2.	<i>Estabilidad de los rodales de malas hierbas</i> .....	149
1.3.	<i>El caso de la Avena loca</i> .....	150
1.4.	<i>Objetivos</i> .....	152
<b>2. Materiales</b> .....	<b>152</b>	
2.1.	<i>Zona de estudio</i> .....	152
2.2.	<i>Imágenes de satélite y pre-procesado</i> .....	153
<b>3. Metodología</b> .....	<b>153</b>	
3.1.	<i>Análisis de persistencia de avena en trigo</i> .....	154
3.1.1.	<i>Detección de cambios</i> .....	154
3.1.2.	<i>Autocorrelación espacial</i> .....	155
3.1.3.	<i>Análisis de la distancia de propagación</i> .....	156
3.2.	<i>Mapas de Control Localizado de Malas Hierbas (CLMH)</i> .....	157
3.3.	<i>Estudio económico</i> .....	158
<b>4. Resultados</b> .....	<b>160</b>	
4.1.	<i>Análisis de persistencia de avena en trigo</i> .....	160
4.1.1.	<i>Detección de cambios</i> .....	160
4.1.2.	<i>Autocorrelación espacial</i> .....	164
4.1.3.	<i>Análisis de la distancia de propagación</i> .....	165
4.2.	<i>Mapas de Control Localizado de Malas Hierbas (CLMH)</i> .....	168
4.3.	<i>Estudio económico</i> .....	172
<b>5. Discusión</b> .....	<b>175</b>	
<b>6. Referencias</b> .....	<b>179</b>	
<b>7. Anexo1</b> .....	<b>183</b>	

## **Conclusiones generales ..... 194**

## Figuras

Figura 1.1: Ejemplo de segmentación de una imagen con distintos parámetros de segmentación. Segmentación ponderando la componente espectral de la imagen en a) un 100%, b) un 50% y c) un 10% respecto a la componente de forma. ....	8
Figura 1.2: Esquema de relaciones entre objetos del mismo o diferente nivel jerárquico. (Definiens, 2007). ....	9
Figura 2.1. Localización del área de estudio en Andalucía. ....	38
Figura 2.2. Ejemplo de los principales usos de suelo agrarios en la zona de estudio: a) girasol; b) olivar; c) viña; d) rastrojo quemado; e) rastrojo y f) suelo desnudo. ....	38
Figura 2.3. Esquema metodológico del proceso de fusión ( <i>pansharpen</i> ) AWLP. ....	41
Figura 2.4. Resultado de la segmentación al variar los parámetros compacidad y suavidad: a) compacidad=1 y suavidad=0; b) compacidad=0.5 y suavidad=0.5 y c) compacidad=0 y suavidad=1. ....	43
Figura 2.5. Resultado de la segmentación al variar los parámetros color y forma: a) color=0.9 y forma=0.1; b) color=0.5 y forma=0.5 y c) color=0.1 y forma=0.9. ....	43
Figura 2.6. Resultado de la segmentación al variar el parámetro factor de escala: a) factor de escala=10; b) factor de escala=30 y c) factor de escala=50. ....	43
Figura 2.7. Direcciones consideradas en el análisis de vecindad para la obtención de variables texturales. ....	45
Figura 2.8. Variables utilizadas en el estudio calculadas a partir de la banda azul: a) media espectral; b) homogeneidad; c) entropía y d) contraste. ....	45
Figura 2.9. Imagen QuickBird (pixel): a) Multiespectral y c) Fusionada. Segmentación en objetos: Imagen b) Multiespectral y d) Fusionada. ....	47
Figura 2.10. Resultado de la clasificación basada en píxel con el método de Máxima Probabilidad de la imagen multiespectral: a) sin filtro de mayoría; b) con filtro de mayoría. ....	48
Figura 2.11. Gráfico de Fiabilidad Global de las variables texturales clasificadas según su dirección con distintos algoritmos de clasificación. ....	51
Figura 2.12. Resultados de las clasificaciones peores (a, b, c, d, e) y mejores (a', b', c', d', e'); a) P*, b) MD*, c) DMA*, d) SAM*, e) MP* para la imagen fusionada y píxel como MIU; a') P, b') MD, c') DMA, d') SAM para la imagen multiespectral y pixel+object como UMI; e') MP para la imagen fusionada y pixel+object como UMI. ....	53
Figura 3.1. Localización del área de estudio en Andalucía. ....	75
Figura 3.2. Situación del trigo en la etapa fenológica S y las malas hierbas en la IS. ....	76
Figura 3.3. Toma de datos en campo con espectrorradiómetro. ....	77
Figura 3.4: Curvas de reflectancia media de (a) Avena loca, (b) Alpiste y (c) Trigo en las diferentes fechas de muestreo. ....	81
Figura 3.5: Curvas de reflectancia media de avena loca, alpiste y trigo en función de las fechas de muestreo: a) 28-Abril, b) 2-Mayo, c) 6-Mayo, d) 10-Mayo, e) 14-Mayo, f) 18-Mayo, g) 22-Mayo, y h) 26-Mayo. ....	82
Figura 3.6: Curvas de reflectancia media de avena loca, alpiste y trigo en función de las fechas de muestreo para las bandas espectrales: a) Azul, b) Verde, c) Rojo y d) Infrarrojo cercano. ....	87

Figura 4.1. Localización del área de estudio en Andalucía. ....	110
Figura 4.2. Zona estudiada (recuadro amarillo) sobre imagen QuickBird (a) de 2006 y (b) de 2008.....	111
Figura 4.3. Estado del trigo y la avena loca en la fecha de estudio.....	111
Figura 4.4. Segmentación jerárquica de la imagen: a) nivel inferior (sub-objetos); b) nivel superior (super-objetos). ....	118
Figura 4.5. Primer nivel de la segmentación: a) Objetos creados en la segmentación y b) clasificación de objetos en las categorías “Trigo-No Trigo”. ....	120
Figura 4.6. Objetos creados en el 2º nivel de segmentación.....	121
Figura 4.7. Comparativa de las clasificaciones “Trigo-No Trigo” obtenidas: a) 1º nivel de segmentación y b) 2º nivel de segmentación.....	123
Figura 4.8. Ejemplo de las clasificaciones basadas en píxeles y objetos de la Parcela 14 de la imagen QuickBird 2008.....	128
Figura 4.9. Fiabilidad Global media de todas las parcelas analizadas en 2006 y 2008 según los métodos de clasificación.....	129
Figura. 4.10: Clasificación más precisa de infestaciones de avena loca en parcelas de trigo para el año: a) 2006 y b) 2008. ....	136
Figura 5.1. Localización del área de estudio en Andalucía. ....	153
Figura 5.2. Parcelas analizadas en los años 2006 y 2008. ....	154
Figura 5.3. Clasificaciones consideradas para el estudio en cada una de las parcelas y para cada año. ....	160
Figura 5.4. Análisis de cambios de usos de suelo en las cuatro parcelas estudiadas. ....	162
Figura 5.5: Histograma de frecuencias y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena 2006 para la Parcela A.....	166
Figura 5.6: Histograma de frecuencias y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena 2006 para la Parcela B.....	166
Figura 5.7: Histograma de frecuencias y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena 2006 para la Parcela C.....	167
Figura 5.8: Histograma de frecuencias y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena 2006 para la Parcela D.....	167
Figura 5.9: Histograma y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena anterior (2006) para el conjunto de parcelas A-D.....	168
Figura 5.10: Acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena anterior (2006) para el conjunto de parcelas A-D. Determinación de las distancias para el 25%, 50%, 75% y 95% de los puntos.....	169
Figura 5.11: Grado de infestación y zona tratada para el tratamiento T1 en la parcela A.	170
Figura 5.12: Curva de equilibrio <i>Coste aplicación herbicidas-Pérdidas por infestación</i> para la Parcela A. ....	173
Figura 5.13: Curva de equilibrio <i>Coste aplicación herbicidas-Pérdidas por infestación</i> para la Parcela B. ....	173
Figura 5.14: Curva de equilibrio <i>Coste aplicación herbicidas-Pérdidas por infestación</i> para la Parcela C. ....	174
Figura 5.15: Curva de equilibrio <i>Coste aplicación herbicidas-Pérdidas por infestación</i> para la Parcela D.....	174

Figura 5.16: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 en la parcela A.....	183
Figura 5.17: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 1 metro en la parcela A.....	184
Figura 5.18: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 4 metros en la parcela A.....	184
Figura 5.19: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 9 metros en la parcela A.....	184
Figura 5.20: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 25 metros en la parcela A.....	185
Figura 5.21: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 en la parcela B.....	185
Figura 5.22: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 1 metro en la parcela B.....	186
Figura 5.23: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 4 metros en la parcela B.....	186
Figura 5.24: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 9 metros en la parcela B.....	187
Figura 5.25: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 25 metros en la parcela B.....	187
Figura 5.26: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 en la parcela C.....	188
Figura 5.27: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 1 metro en la parcela C.....	188
Figura 5.28: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 4 metros en la parcela.....	189
Figura 5.29: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 9 metros en la parcela C.....	189
Figura 5.30: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 25 metros en la parcela C.....	190
Figura 5.31: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 en la parcela D.....	190
Figura 5.32: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 1 metro en la parcela D.....	191
Figura 5.33: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 4 metros en la parcela D.....	191
Figura 5.34: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 9 metros en la parcela D.....	192
Figura 5.35: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 25 metros en la parcela D.....	192

## Tablas

Tabla 2.1- Variables basadas en objetos.....	44
Tabla 2.2- Fiabilidad Global (%) obtenida de la clasificación de la imagen multiespectral y fusionada con parámetros de escala de 40-100.....	48
Tabla 2.3- Fiabilidad Global (%) obtenida de la clasificación de la imagen multiespectral y fusionada con parámetros de escala de 45-55.....	49
Tabla 2.4- Fiabilidad Global (%) obtenida de la clasificación de las variables texturales obtenidas en distintas direcciones.....	50
Tabla 2.5- Resumen de los resultados más precisos de las clasificaciones realizadas con el filtro de mayoría aplicado.....	52
Tabla 2.6- Fiabilidad del Productor (%) de los cinco métodos de clasificación.....	55
Tabla 2.7: Fiabilidad del Usuario (%) de los cinco métodos de clasificación.....	57
Tabla 3.1: Etapas fenológicas del trigo, avena loca y alpiste desde el 28 de abril al 26 de mayo.....	75
Tabla 3.2: Resultados del análisis discriminante sobre los datos hiperespectrales para avena loca, alpiste y trigo de acuerdo a diferentes escenarios de clasificación.....	85
Tabla 3.3: Resultados del análisis discriminante sobre bandas multiespectrales e índices de vegetación con diferentes escenarios de clasificación.....	90
Tabla 4.1-Parámetros de segmentación de las 11 parcelas clasificadas en 2006.....	114
Tabla 4.2-Parámetros de segmentación de las 15 parcelas clasificadas en 2008.....	114
Tabla 4.3- Parámetros de segmentación para el 1 <sup>er</sup> nivel de la red jerárquica.....	119
Tabla 4.4- Comparativa de los parámetros de segmentación del 1 <sup>er</sup> nivel (sub-objetos) y 2 <sup>o</sup> nivel (super-objetos) de la red jerárquica.....	121
Tabla 4.5- Separabilidad espectral medida con la distancia espectral <i>Jeffries-Matusita</i> entre los usos Trigo-Avena en las 11 parcelas analizadas en 2006.....	124
Tabla 4.6- Separabilidad espectral medida con la distancia espectral <i>Jeffries-Matusita</i> entre los usos Trigo-Avena en las 15 parcelas analizadas en 2008.....	124
Tabla 4.7- Resultados obtenidos en la clasificación de infestaciones de avena loca en parcelas de trigo de las 11 parcelas analizadas en 2006.....	126
Tabla 4.8- Resultados obtenidos en la clasificación de infestaciones de avena loca en parcelas de trigo de las 15 parcelas analizadas en 2008.....	127
Tabla 4.9- Comparativa de las precisiones obtenidas con las clasificaciones basadas en objetos respecto a las basadas en píxeles para las 11 parcelas analizadas en 2006.....	131
Tabla 4.10- Comparativa de las precisiones obtenidas con las clasificaciones basadas en objetos respecto a las basadas en píxeles para las 15 parcelas analizadas en 2008.....	132
Tabla 4.11- Resultados obtenidos en la clasificación de parcelas de trigo con las imágenes de 2006 y 2008.....	133
Tabla 4.12- Resultados de Fiabilidad Global (%) y Fiabilidad del Productor (%) en parcelas de trigo, obtenidos a partir del análisis jerárquico con distintas proporciones de trigo (RAT).....	134
Tabla 4.13- Resultados obtenidos de la clasificación de infestaciones de avena loca en parcelas de trigo con las imágenes de 2006 y 2008.....	135



Tabla 5.1- Características del análisis de cambio.....	155
Tabla 5.2- Grados de infestación considerados para el CLMH.....	157
Tabla 5.3- Análisis de superficies clasificadas para cada parcela y cada año estudiado....	161
Tabla 5.4 – Resumen de las estadísticas de cambio para las cuatro parcelas estudiadas en los años 2006 y 2008.....	163
Tabla 5.5 – Análisis de la autocorrelación espacial de las cuatro parcelas estudiadas en los años 2006 y 2008.....	164
Tabla 5.6 – Características de los tratamientos para el CLMH.....	169
Tabla 5.7 – Resumen de la superficies consideradas como posiblemente infestadas ( $S_i$ ) y superficies tratadas ( $S_t$ ) por los distintos tratamientos en las cuatro parcelas.....	171

# **Introducción**

---

## **CAPÍTULO I**



# Introducción

La agricultura ha estado íntimamente ligada al hombre desde el periodo neolítico, siendo siempre una actividad estratégica que ha permitido el desarrollo autosuficiente de las regiones. Conforme la sociedad ha ido evolucionando a lo largo de la historia, también la agricultura ha sufrido esa evolución, pasando de los primeros cultivos trabajados con técnicas rudimentarias en la época prehistórica hasta el moderno y tecnificado sistema de producción agrícola actual. Esta evolución agraria fue equilibrada hasta mediados del siglo XX, cuando la llamada revolución verde trajo consigo un salto cualitativo en la tecnificación de la agricultura como base de la agricultura industrial o de mercado. Este tipo de agricultura presenta como único objetivo maximizar los rendimientos de los cultivos, sin prestar atención a la conservación de los recursos naturales (suelo, agua, atmósfera, biodiversidad) sobre los que se sustenta (García-Olmedo, 1998). Sin embargo, una actividad agrícola tan intensiva como ésta ha acarreado graves problemas medioambientales tales como erosión y salinización de suelos, contaminación de suelos y acuíferos y drástica reducción de la biodiversidad, lo que ha obligado a plantear el desarrollo de nuevas técnicas agrícolas. Desde finales del siglo XX, poco a poco se ha ido observando un crecimiento considerable de la sensibilización y búsqueda de conocimientos respecto a la relación agricultura-medioambiente, lo que ha llevado a una fase de compensación o búsqueda de equilibrio entre la tendencia productivista tradicional y las actuales exigencias medioambientales (García-Torres *et al.*, 2004). Este completo conocimiento del medio y el posterior diseño de técnicas agrícolas adecuadas ha sido posible gracias al desarrollo de distintas técnicas geomáticas como los Sistema de Posicionamiento Global (GPS), los Sistemas de Información Geográfica (SIG), la geoestadística, y, por supuesto, la teledetección.

## 1. Teledetección

Con el paso del tiempo, la teledetección se ha convertido en una herramienta muy útil para la agricultura. A partir de la medida de la señal espectral reflejada o emitida por las cubiertas y la combinación de técnicas de teledetección, es posible identificar los distintos usos agrícolas así como numerosos parámetros y anomalías que éstos presenten.

La teledetección se basa en la observación remota de la superficie terrestre y la captura de imágenes mediante un sistema sensor acoplado a un satélite espacial, a un vehículo aeroportado (avión, UAV, etc.) e incluso a vehículos y plataformas terrestres. Estas imágenes se someten a un análisis digital en el que se analiza el comportamiento espectral de cada píxel en las distintas regiones del espectro electromagnético en el que se ha registrado información. La base de la teledetección radica en que cada cuerpo presenta un patrón de energía reflejada/emitada propio y diferente que lo distingue del resto de los materiales cuando sobre él incide energía electromagnética (Chuvienco y Huete, 2010). La curva de reflectancia de una planta (o cultivo) está directamente relacionada con sus características fenológicas, fisiológicas y morfológicas, por lo que cualquier cambio en la

planta también perturbará su reflectancia (Lass y Callihan, 1997; Schmidt y Skidmore, 2003). Estas diferencias de comportamiento espectral intrínseco de cada especie y/o planta individual son las que permiten su discriminación y mapeo mediante técnicas de análisis y clasificación digital.

### *1.1. Análisis y clasificación digital*

A la hora de realizar un estudio basado en teledetección, en la mayoría de los casos el principal objetivo que se persigue es obtener la localización y características de las distintas variables objeto de estudio. Esta información puede ser obtenida a partir de diferentes técnicas, entre las que destaca la clasificación digital de imágenes. El objetivo de la clasificación es el reconocimiento de clases cuyos elementos (píxeles) tengan ciertas características en común, de manera que se crea una nueva imagen del mismo tamaño y características que la original, con la importante diferencia de que el nivel digital que define a cada píxel no tiene relación con la radiancia detectada por el sensor, sino que se trata de una etiqueta que identifica la categoría o clase, normalmente cualitativa, asignada a ese píxel (Chuvienco y Huete, 2010).

Antes de realizar una clasificación digital de una imagen, ésta suele someterse a tratamientos de corrección y realce para facilitar el proceso. Sin embargo, la clasificación puede abordarse exclusivamente a partir de los niveles digitales de la imagen, sin sufrir correcciones (ej. correcciones atmosféricas) o conversión a parámetros físicos (ej. reflectividad), ya que las categorías temáticas suelen definirse de modo relativo a las condiciones específicas de la escena a clasificar. En muchos casos la clasificación digital no busca una definición absoluta de cada cubierta que pueda ser aplicable a cualquier imagen, sino una caracterización relativa, válida para una determinada imagen y un territorio concreto (Robinove, 1981; Duggin and Robinove, 1990; Song *et al.*, 2001). Existen distintos métodos de clasificación en función de la metodología utilizada en la caracterización espectral de las diferentes cubiertas a clasificar. La clasificación **no supervisada** obtiene la caracterización espectral de las cubiertas a partir del agrupamiento de píxeles que presenten unas mismas características espectrales en la imagen (*clusters*), no teniendo en cuenta información alguna sobre el terreno. El proceso de agrupamiento se realiza mediante un algoritmo de *clustering* o agrupamiento que tiene en cuenta medidas de similitud entre píxeles, las cuales se basan en mediciones de distancia espectrales entre los distintos niveles digitales que componen la imagen. Los algoritmos de clasificación no supervisada más ampliamente utilizados son K-Means e ISODATA (*Interactive Self Organizing Data Analysis Techniques*) basados en la búsqueda automática de grupos de valores digitales homogéneos. En este caso el intérprete es el que tiene que determinar la correspondencia entre las clases obtenidas en la clasificación (clases espectrales) y las clases buscadas en la clasificación (clases informacionales), pudiendo no coincidir unas con otras. Al definir el tipo de análisis, normalmente se designa un número de clases superior al que realmente se desea clasificar para, posteriormente, agrupar las clases resultantes en grupos más homogéneos a partir de un análisis visual del mapa resultante. Algunos de los ejemplos más actuales de aplicación de clasificación no supervisada a objetivos agrícolas se encuentran recogidos en los trabajos de Guastafero *et al.* (2010);

Panda *et al.* (2010), Pedroso *et al.* (2010) y Taylor y Whean (2010). Debido a que la precisión obtenida en las clasificaciones no supervisadas no es muy alta, la mayor parte de los estudios con clasificadores no supervisados van acompañados de otros tipos de clasificaciones.

En el **método supervisado**, la selección de las muestras para cada categoría de la clasificación se realiza a partir del conocimiento previo del terreno, lo que permite definir en la imagen una serie de localizaciones denominadas áreas de entrenamiento. A partir de los valores digitales de los píxeles que definen cada clase en las áreas de entrenamiento se calculan, para todas las bandas, una serie de parámetros estadísticos elementales (media, desviación típica, matriz de varianza-covarianza...) que caracterizan cada clase. Posteriormente se asigna el resto de los píxeles de la imagen a una determinada categoría en función de la similitud espectral que presente cada píxel con los extraídos como referencia en el entrenamiento. En esta clasificación es fundamental la correcta selección de las muestras, ya que en caso contrario, las estadísticas no caracterizarán correctamente las distintas categorías y los resultados pueden ser completamente erróneos (Muchoney y Strahler, 2002). Hay diferentes métodos para definir las zonas de entrenamiento (McCoy, 2005), si bien uno de los más empleados se basa en definir que las zonas de entrenamiento sean preferentemente de pequeño tamaño y distribuidas por toda la imagen, que contengan píxeles puros que sólo muestren información de la cubierta que se pretende determinar, aunque dentro de cada categoría deben mostrar cualquier variabilidad que presente dicha cubierta. Existen multitud de algoritmos tanto numéricos como estadísticos de clasificación supervisada: Paralelepípedos, Mínima Distancia, Máxima Probabilidad, *Spectral Angle Mapper*, etc. (más detalles en Chuvieco y Huete, 2010). Aunque se conoce el comportamiento general de cada clasificador, a la hora de decidir un algoritmo de asignación, no se puede decir que exista una rutina de clasificación ideal. El mejor clasificador dependerá de las necesidades y requerimientos de cada estudio. En diversos estudios se concluye que la elección de un método de clasificación puede influir significativamente en los resultados y que esta elección debe hacerse siempre teniendo en cuenta la estructura del uso del territorio y sus unidades (Hubert-Moy *et al.*, 2001).

En los **capítulos 2 y 4** de esta Tesis Doctoral se han realizado diversas clasificaciones supervisadas utilizando distintos algoritmos de clasificación. La utilización de tantos clasificadores diferentes se debe a que en ambos capítulos se ha tratado de determinar el método de asignación que mejor se ajusta a las características de cada trabajo según la relación coste computacional/fiabilidad. La elección de dichos clasificadores se ha basado tanto en la comparación de distintas metodologías de clasificación así como su disponibilidad en los principales programas informáticos de tratamiento de imágenes. South *et al.* (2004) resumió la mayoría de las rutinas de clasificación supervisada en tres grupos: las reglas de decisión basadas en distancias, las basadas en probabilidades y las basadas en ángulos. Los clasificadores basados en distancias como el de Mínima Distancia o Distancia de Mahalanobis dependen principalmente de los valores espectrales medios de cada una de las distintas categorías, ignorando la varianza que existe en cada clase. Las rutinas de clasificación basadas en probabilidades como la de Máxima Probabilidad incorpora en las reglas de decisión tanto la media de cada una de las categorías de clasificación como la varianza. Finalmente, los

clasificadores basados en ángulos como el *Spectral Angle Mapper* (SAM) crean la regla de decisión a partir de la medida de ángulos espectrales formados entre un valor espectral de referencia y el valor de un píxel sin clasificar. Además de estos tres grupos de clasificadores, existen otros que no fueron recogidos en el estudio de South et al. (2004) como los algoritmos de aprendizaje automático (*data mining*), entre otros. Los algoritmos de aprendizaje automático como el *Support Vector Machine* (SVM) o algunos árboles de decisión generados con este sistema se basan en el análisis de un conjunto de datos iniciales (áreas de entrenamiento) para descubrir patrones, relaciones, reglas, asociaciones o incluso excepciones útiles para la clasificación (Pan y Jiao, 2011).

Las aplicaciones de la teledetección en el ámbito agrario son inmensas y así se ha constatado en los numerosos trabajos e investigaciones que se han desarrollado desde su origen hasta la actualidad. La teledetección es una herramienta muy válida para la clasificación de usos de suelo y entre sus aplicaciones están la monitorización y el control de cultivos (Li et al., 2010; López-Granados 2010), la elaboración de mapas de las características del suelo (Leon et al., 2003; López-Granados et al., 2005), el estudio del estado fitosanitario de los cultivos (Feng et al., 2010; Jing et al., 2010), el seguimiento y predicción de cosechas (Chaudhari et al., 2010; Huang et al., 2011), y la evaluación de cambios en el paisaje agrario (Ducrot et al., 2010; Pôças et al., 2011), entre otros.

La mayoría de los métodos de clasificación utilizados en estudios de discriminación de usos del suelo se basan en clasificaciones supervisadas. Entre los más recientes cabe destacar el estudio realizado por Yang et al. (2011), donde se analizó la capacidad de discriminación de 5 cultivos con imágenes del satélite SPOT5 aplicando 5 clasificadores supervisados diferentes: Mínima Distancia, Distancia de Mahalanobis, Máxima Probabilidad, *Spectral Angle Mapper* y *Support Vector Machine*. En dicho estudio se observó que todos los clasificadores obtuvieron precisiones superiores al 70%, siendo los clasificadores Máxima Probabilidad y *Support Vector Machine* los que ofrecieron los mejores resultados con fiabilidades globales superiores al 90%. Soria-Ruiz et al., (2010) muestran otro estudio interesante para la discriminación de zonas agrícolas basado en la fusión de imágenes ópticas con imágenes radar. En este trabajo se observó que la combinación de imágenes ópticas y radar mejoraba la precisión de las clasificaciones respecto a las mismas realizadas sobre la imagen multiespectral, pudiendo ser muy interesante en aquellas zonas donde se localizan coberturas de nubes muy frecuentemente.

La clasificación de cultivos con objeto de realizar estimaciones de área sembrada y de estadísticas agrarias es una de las aplicaciones más frecuentes de los sensores remotos. Las estimaciones pueden alcanzar carácter operativo y las cifras se consideran más precisas que las estimaciones convencionales (Brizuela et al., 1997). Actualmente el Gobierno Español ha promovido distintos proyectos basados en teledetección y apoyados con visitas a campo para el control de cultivos en el marco de la PAC y para el seguimiento de variables relacionadas directamente con ellos como la evolución de la superficie de cultivos de secano y regadío (MARM, 2011).

## 1.2. Clasificación orientada a objetos

La mayoría de las clasificaciones del uso del suelo mediante técnicas de teledetección están basadas en la información de cada píxel de la imagen como una unidad básica e independiente de estudio. Sin embargo, y debido a que el terreno es continuo, en muchos casos es importante tener en cuenta información semántica que no se encuentra representada en los píxeles individuales, sino que está contenida en la relación entre píxeles adyacentes, lo que permite la identificación de objetos formados por píxeles con características comunes. Para generar estos **objetos** sobre la imagen es necesario realizar un proceso de generalización de regiones o **segmentación** en el que se extrae información de una imagen a partir de su división en diferentes regiones homogéneas, que se corresponden con zonas de interés en la misma. Este proceso sirve para generar una imagen de objetos como primer paso para una clasificación posterior u otro procesamiento (Batz y Schäpe, 2000). Por tanto, la unidad básica de asignación ya no es cada píxel individualmente, sino que son regiones homogéneas capaces de representar de forma resumida las entidades y relaciones presentes en la imagen, es decir, la variabilidad del fenómeno estudiado.

En el proceso de segmentación, la delimitación de los distintos objetos homogéneos se basa en criterios de similitud espacial y contigüidad espectral. Los algoritmos de segmentación pueden clasificarse en los basados en determinación de contornos (*boundary-based*) y en los basados en crecimiento de regiones (*region-based*). Los algoritmos basados en contornos se caracterizan por determinar los límites o contornos de los objetos en base a un estudio de discontinuidad entre píxeles, mientras que los basados en regiones generan los objetos en base al análisis de similitud entre ellos (Zhang, 1997). Todos los algoritmos basados en contornos se basan en alguna técnica de detección de bordes, quedando definido el objeto como la porción de imagen incluida dentro de la línea que define dicho borde. El gran problema que presenta este tipo de algoritmo es su dificultad para cerrar los bordes de forma automática y, por tanto, definir correctamente el objeto. Por su parte, los algoritmos basados en regiones generan una segmentación de la imagen directa, asignando cada píxel a una única región (Cocquerez y Philipp, 1995).

En función del criterio de agrupación de los píxeles, los algoritmos de segmentación basados en regiones se pueden clasificar en algoritmos descendentes o de arriba hacia abajo (*top-down*) y ascendentes o de abajo hacia arriba (*bottom-up*). Los algoritmos descendentes realizan la agrupación de los píxeles a partir del conocimiento del usuario de las regiones presentes en la imagen, siendo necesario que previo al proceso de segmentación, éste defina las características espectrales, de forma, texturales, entre otras, que deben cumplir los objetos que desea extraer de la imagen. Este tipo de segmentación genera objetos con significado real. Por su parte, los algoritmos ascendentes no precisan que el usuario tenga un conocimiento previo de las características de los objetos que desea extraer de la imagen. La agrupación de píxeles se realiza de forma automática mediante métodos de clusterizado que agrupan píxeles de similares características espectrales o texturales en función de ciertos criterios de homogeneidad.



Los objetos creados por este tipo de segmentación no tienen un significado real y es el propio usuario el que determina qué elemento del territorio representa cada objeto resultante del proceso de segmentación. La segmentación ascendente es la que se encuentra implantada en la mayoría de los programas informáticos comerciales de tratamiento de imagen debido a su mayor versatilidad en el tratamiento de distintos tipos de imágenes. Además, sólo este tipo de segmentaciones puede asegurar la segmentación de la imagen completa.

Una parte muy significativa de los trabajos presentados en los **capítulos 2 y 4** de esta Tesis Doctoral se basan en la segmentación de imágenes en función de las características requeridas y el posterior análisis de los datos. En todos los casos se ha utilizado la técnica de *Segmentación Multirresolución* (Batz y Schäpe, 2000), la cual se encuentra recogida dentro de los algoritmos basados crecimiento de regiones (*region-based*) y con agrupación ascendente (*bottom-up*). La creación de los distintos objetos parte de regiones de un único píxel (píxel semilla). El crecimiento de dichas regiones se realiza a través de sucesivas iteraciones y evaluaciones de cada píxel semilla con los píxeles adyacentes, observándose una agregación de píxeles hasta que se supera un grado de heterogeneidad definido en el proceso (Yu *et al.*, 2006). Este método genera regiones no determinísticas que, de acuerdo con parámetros de escala y homogeneidad definidos por el intérprete, permite generar sobre una imagen objetos irregulares, es decir, de distinto tamaño y con diferente configuración de parámetros, normalmente variaciones espectrales y de forma (Fig. 1.1). La combinación óptima de dichos parámetros dependerá de diversos factores como las resoluciones espacial y espectral de la imagen, el tipo de objetos de interés y las condiciones ambientales en el momento de la toma de la imagen (Al Khudhairy *et al.*, 2005; Budreski *et al.*, 2007; Dobrowski *et al.*, 2008).



Figura 1.1: Ejemplo de segmentación de una imagen con distintos parámetros de segmentación. Segmentación ponderando la componente espectral de la imagen en a) un 100%, b) un 50% y c) un 10% respecto a la componente de forma.

El proceso de segmentación se dirige mediante la ponderación de distintos parámetros como el factor de escala (control de tamaño de los objetos), color (grado de influencia de la información espectral en la segmentación) y forma (grado de influencia de la forma, es decir, suavidad y compacidad de los objetos) en función de las características de la imagen y de los requerimientos buscados en los objetos. El proceso de segmentación comienza formando un objeto por cada píxel de la imagen. En cada fase del proceso un par de objetos adyacentes de la imagen se unen en un objeto más grande. La decisión de unión entre objetos se basa en un criterio de homogeneidad local, la cual se centra en la similaridad entre objetos adyacentes. Este proceso de unión continúa hasta que se alcanza el umbral definido por los parámetros del usuario (Baatz y Schäpe, 2000). Por lo tanto, la segmentación multirresolución es un procedimiento de optimización que reduce al mínimo la media de la heterogeneidad para un determinado número de objetos de la imagen (Definiens, 2007) y produce imágenes de objetos muy homogéneos, en una resolución arbitraria, a partir de diferentes tipos de datos (Baatz y Shäpe, 2000).

Algunos objetos presentan diferente comportamiento en función de la escala de estudio, lo que impide aplicar una segmentación teniendo en cuenta un único criterio de homogeneidad. Este problema se resuelve con la segmentación multiresolución, ya que como se ha indicado anteriormente, ésta permite generar distintos niveles de segmentación con objetos generados a partir de diferentes parámetros de homogeneidad. Estos niveles se relacionan entre sí mediante una red jerárquica de objetos en la que se establecen relaciones entre ellos y que representa la información contenida en una imagen a distintas escalas simultáneamente (Fig. 1.2). Estos objetos conforman una red perfectamente jerarquizada desde el punto de vista topológico, lo que implica que de cada objeto perteneciente a un nivel se conocen perfectamente sus sub-objetos (niveles inferiores), sus objetos vecinos (mismo nivel) y sus súper-objetos (niveles superiores). Esta información espacial se basa en tamaño, forma y contexto de los objetos y puede ser calculada como información relativa de un objeto, sub-objeto o súper-objeto en el caso de que se haya creado una jerarquía multinivel de imágenes segmentadas (Chubey *et al.*, 2006).

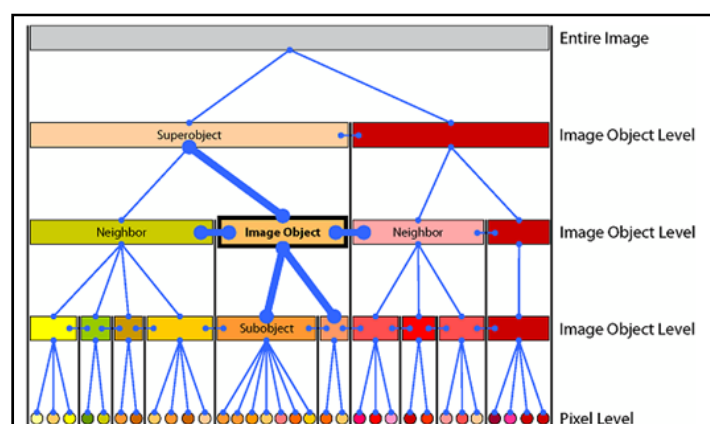


Figura 1.2: Esquema de relaciones entre objetos del mismo o diferente nivel jerárquico. (Definiens, 2007).

En comparación con las clasificaciones basadas en píxeles, en los análisis basados en objetos existe la posibilidad de introducir en el análisis nueva información espectral, textural, contextual y jerárquicamente relacionada. La elección de unas variables u otras para introducir en el análisis dependerá de las características del estudio. La información textural ofrece información sobre las características de los objetos que puede ser muy útil para la discriminación de parcelas de cultivo heterogéneas (Pacifi *et al.*, 2009), aunque en comparación con otras variables obtenidas de la segmentación presentan la gran desventaja de requerir un alto coste computacional.

Aún siendo una técnica muy reciente y todavía poco implementada, desde el año 2000 cada vez hay más trabajos que se centran en clasificar distintos usos del suelo a partir de imágenes segmentadas y no sobre la imagen original (técnicas basadas en píxeles). Blaschke (2010) publicó una revisión sobre el desarrollo de los métodos basados en objetos y sugirió que el análisis de imágenes basado en píxeles está superado y que actualmente los análisis basados en objetos representan una tendencia imparable para multitud de objetivos diferentes. Entre los últimos estudios donde se aplican técnicas basadas en objetos para discriminar cultivos se destaca el de Peña-Barragán *et al.* (2011), trabajo que muestra cómo información espectral y textural derivada de la segmentación de las imágenes junto con índices de vegetación y un clasificador basado en un árbol de decisión son capaces de discriminar 13 tipos de cultivos diferentes a partir de imágenes ASTER registradas en 3 periodos entre primavera y verano. Por su parte, Maxwell (2010) analizó distintas segmentaciones sobre imágenes ópticas de alta y media resolución espacial con el fin de discriminar distintos usos del suelo para diseñar aplicaciones pesticidas sobre cultivos. Estas técnicas también se están utilizando como parte de la metodología de actualización automática del inventario de cultivos permanente donde Ciriza *et al.* (2009) analizan la capacidad de la segmentación a nivel parcela y el análisis de texturas para la caracterización y discriminación de cultivos arbóreos.

### 1.3. Espectrorradiometría de campo y firmas espectrales

Un mayor conocimiento del comportamiento real de la respuesta espectral de las plantas durante el ciclo del cultivo permite mejorar el ajuste de los parámetros usados en los métodos de clasificación de imágenes. Al caracterizar la variación temporal de dicha respuesta es posible mejorar sustancialmente la calidad y oportunidad de los datos tomados en campo o procedentes de imágenes, logrando clasificaciones más exactas. Estas medidas espectrales se realizan con un espectrorradiómetro de campo que es capaz de registrar la señal reflejada por las distintas cubiertas. Al igual que ocurre con los sensores captadores de imágenes, los espectrorradiómetros presentan diferentes resoluciones espectrales que les permitirán registrar datos de regiones del espectro más o menos anchas. En el **capítulo 3** de esta Tesis Doctoral se ha realizado un estudio del comportamiento espectral de distintas especies vegetales (cultivo y malas hierbas) durante una fase concreta de su ciclo vegetativo a partir de las medidas realizadas con un espectrorradiómetro HandHeld FieldSpec de la empresa Analytical Spectral Devices, Inc. (ASD). Este espectrorradiómetro mide el dominio de longitud de onda entre 325 – 1075nm (visible e infrarrojo cercano), dividiéndolo en 512 canales, con una resolución espectral de 3nm para los 750nm de dominio espectral medidos (más información en ASD, 2003).

El espectro de reflectancia de cualquier cubierta se obtiene a partir de la reflectividad relativa de la muestra respecto a la medida en un panel de referencia (blanco de referencia con máxima reflectividad). Para obtener la reflectividad absoluta es necesario conocer la curva de reflectancia del panel de referencia, multiplicándose el espectro relativo por dicha curva. En el espectroradiómetro usado en esta Tesis Doctoral, se puede configurar la captura de reflectividad absoluta durante la toma de datos. Una amplia descripción de los conceptos básicos sobre espectrorradiometría y del procedimiento para el uso y cuidado del instrumental se puede consultar en el manual de Salisbury (1999).

La energía reflejada por la vegetación está relacionada con su estado fenológico, la altura de la planta, la cobertura del suelo, su estado nutricional y su contenido hídrico. Otros factores que modifican la respuesta son la asociación con otras especies, la pendiente y la orientación de la parcela y la geometría de plantación. El comportamiento espectral de la vegetación vigorosa muestra reducida reflectancia en la banda visible con un máximo relativo en la porción verde del espectro (550nm). Este pico alrededor de la región del verde está altamente influenciado por la cantidad de pigmentos, clorofila y carotenoides principalmente, que presente la hoja (Moran *et al.*, 2000; Sims y Gamon, 2002), ya que muestran diferentes características de absorción. Por otra parte, en la región del infrarrojo cercano se produce un aumento muy marcado de la reflectividad que va reduciéndose paulatinamente hacia el infrarrojo medio debida a la propia estructura de la hoja. Además, el mayor contraste en la reflectancia de la vegetación vigorosa y sana se produce entre la porción del rojo dentro de la zona visible y el infrarrojo cercano. Según esto, es de esperar que en las imágenes se observe mayor contraste entre ambas bandas cuanto mayor sea el vigor y/o densidad de la vegetación. Por otra parte, este tipo de comportamiento espectral tan diferenciado no se repite en ningún otro tipo de cubierta, lo que facilita la detección de zonas vegetales respecto a otras cubiertas. Por ejemplo, en los suelos desnudos la respuesta espectral es más uniforme que en la vegetación e intervienen factores como la composición química, textura, estructura y contenido de humedad del suelo (Asner, 1998; Ben-Dor *et al.*, 2008).

Existen estudios cuyo objetivo es valorar los factores que influyen en la respuesta espectral, de manera que se pueda aislar o reducir su efecto sobre la señal medida. Para ello, se han llevado a cabo experimentos controlados en condiciones de laboratorio y exteriores (Daughtry y Walthall, 1998; Vaughan, 2001). La medida en campo se verá interferida por factores externos, pero es necesario asumir dicha variabilidad cuando el objetivo es aplicar los resultados en el análisis y tratamiento posterior de imágenes, las cuales son adquiridas en condiciones abiertas sin posibilidad de controlar los factores referidos. Debido a este escenario, es necesario determinar mediante análisis estadístico si las diferencias existentes entre los usos del suelo medidos son mayores que la variabilidad dentro de las medidas de cada uso del suelo (Schmidt y Skidmore, 2003). Este estudio se puede llevar a cabo mediante el análisis de separación de medias (Brown *et al.*, 1994) o el análisis discriminante (Girma *et al.*, 2005), entre otros posibles métodos estadísticos.

Diversos estudios sugieren que la reflectancia espectral de los cultivos puede ser utilizada para detectar algunas de sus características como el estrés biótico y no biótico (Filella *et al.*, 1995; Osborne *et al.*, 2002), el estado de nutrientes de la planta (Zhao *et al.*, 2005), el crecimiento y las características fisiológicas de la planta (Serrano *et al.*, 2000; Broge y Leblanc, 2001; Zhao *et al.*, 2003; Zhao *et al.*, 2007) y la predicción del rendimiento de la cosecha (Ma *et al.*, 2001; Plant *et al.*, 2001; Zhao *et al.*, 2007). En el mismo sentido, muchos investigadores han medido y estudiado la firma espectral que identifica cada especie en un determinado estado fenológico (Koger *et al.*, 2003; Hunt *et al.*, 2004; Koger *et al.*, 2004; Itano y Tomimatsu, 2011), lo que demuestra el enorme potencial de estas técnicas para la discriminación de distintos cultivos (López-Granados *et al.*, 2010) y de distintas especies vegetales, especialmente, de malas hierbas (Felton *et al.*, 2002; Radhakrishnan *et al.*, 2002; Thorp y Tian, 2004 y Brown y Noble, 2005). Algunos autores como Smith y Blackshaw (2003); Peña-Barragán *et al.* (2006) y López-Granados *et al.* (2008) ya han aplicado estas técnicas para la discriminación de cultivos y sus malas hierbas asociadas.

## 2. Nuevas técnicas agrícolas

La actividad agrícola siempre ha tenido un gran impacto en el medio ambiente. Este impacto ha estado desatendido por investigadores, administración y agricultores hasta mediados del siglo XX cuando apareció la agricultura industrial o de mercado, agricultura que ha perdurado hasta nuestros días en la mayoría de los países industrializados o en vía de desarrollo. El principal objetivo de estas técnicas agrícolas es la obtención del máximo de producción a base de una alta tecnificación (maquinaria, semillas, tratamientos agroquímicos entre otros. Sin embargo, una producción intensiva de este tipo trae consigo grandes problemas medioambientales tales como la erosión, el agotamiento de la fertilidad y la salinización de los suelos, la contaminación con nitrógeno y fósforo de las aguas subterráneas, ríos y lagos y potenciales riesgos de contaminación por plaguicidas y herbicidas. Este tipo de desequilibrios medioambientales no es rentable a largo plazo, por lo que desde finales del siglo XX han ido apareciendo nuevas técnicas de agricultura cuyo objetivo principal es garantizar una producción agrícola adecuada, optimizando los recursos y sin degradar el medioambiente.

### 2.1. Agricultura de conservación

La agricultura convencional, al incluir prácticas como el laboreo intensivo, incrementa considerablemente la escorrentía y la erosión del suelo así como la contaminación de los ríos por sedimentos, fertilizantes y pesticidas. Dichas prácticas, además de reducir la sostenibilidad de la agricultura, disminuyen la biodiversidad e incrementan las emisiones de CO<sub>2</sub> a la atmósfera, contribuyendo al calentamiento global del planeta (IDAE, 2009). Ante esta situación, la **agricultura de conservación** se presenta como una alternativa viable desde el punto de vista medioambiental y económico. El objetivo fundamental de esta agricultura es conservar, mejorar y hacer un uso más eficiente de los recursos naturales mediante un manejo integrado del suelo, el agua, los

agentes biológicos y los “inputs” externos (FAO, 2001). La agricultura de conservación se basa en la integración de técnicas de manejo ecológicas a una producción agrícola moderna y científica. Es decir, esta agricultura emplea las más modernas tecnologías para mejorar la calidad e integridad ecológica de los suelos, siempre basándose en el conocimiento tradicional de generaciones de agricultores (Dumanski, 2006). Por todo esto, estas técnicas se centran en el manejo de agro-ecosistemas para una productividad mejorada y sostenible, mayor rentabilidad económica y seguridad alimentaria, conservando y reforzando al mismo tiempo los recursos naturales y el medio ambiente (FAO, 2011).

La agricultura de conservación está siendo cada vez más promovida en el mundo debido a que constituye un conjunto de principios y prácticas que pueden contribuir a una intensificación de la producción sostenible (FAO, 2008, Pretty, 2008). De hecho, las técnicas de conservación están cada vez más presentes en el mundo. Por ejemplo, a nivel mundial se ha pasado de cultivar 45 millones de hectáreas con sistemas de no laboreo en el año 1999 a 106 millones de hectáreas en el 2008 (Sombbrero, 2010). Este tipo de agricultura vuelve a plantear técnicas agrícolas que han ido desapareciendo a medida que se ha ido intensificando la agricultura. En las diversas técnicas de agricultura de conservación se incluyen: la siembra directa (no laboreo), el mínimo laboreo (laboreo reducido en donde no se incorporan, o sólo parcialmente y en muy breves periodos, los residuos de cosecha) y el establecimiento de cubiertas vegetales entre sucesivos cultivos anuales o entre hileras de árboles en plantaciones de cultivos leñosos. En España, la Asociación de Agricultura de conservación-Suelos vivos (AEAC-SV, 2011) es muy activa en la transferencia de estas técnicas agrícolas a los agricultores.

Desde 1999, la Unión Europea ha desarrollado una serie de disposiciones para promover la conservación del suelo agrícola y reducir su erosión: Reglamentos Europeos 1257/1999 (CUE, 1999a), 1259/1999 (CUE, 1999b), 1782/2003 (CUE, 2003) y finalmente el 796/2004 (CUE, 2004). Esta normativa poco a poco se ha ido incorporando a la Normativa Española en los Reales Decretos RD4/2001 (MAPA, 2001), RD708/2002 (MAPA, 2002a), modificado por el RD172/2004 (MAPA, 2004a), y RD1322/2002 (MAPA, 2002b), derogado por el RD2352/2004 (MAPA, 2004b), y más recientemente el RD486/2009 (MAMRM, 2009). En este último Real Decreto viene a sustituir al RD 2352/2004 para incluir las modificaciones de la legislación comunitaria, tener en cuenta las recomendaciones de la Comisión Europea en relación a la aplicación de condicionalidad, y simplificar y clarificar algunos requisitos con el objetivo de favorecer su cumplimiento y control.

El **capítulo 2** de esta Tesis Doctoral se centrará en aplicar nuevas técnicas de teledetección para el control de las medidas de condicionalidad, concretamente las referidas al mantenimiento de la materia orgánica del suelo mediante la aplicación de prácticas oportunas. Dentro de las condiciones exigibles por el RD 486/2009 para conservar la materia orgánica del suelo se recoge la orden de *“No quemar rastrojos en todo el ámbito nacional, salvo que, por razones fitosanitarias, la quema esté autorizada por la autoridad competente en cuyo caso estará condicionada al cumplimiento de las normas*

establecidas en materia de prevención de incendios, y en particular, las relativas a la anchura mínima de una franja perimetral cuando los terrenos colinden con terrenos forestales” (MAMRM, 2009). Según el RD 486/2009, el sistema de control de la aplicación de las normas de condicionalidad estará regulado por el reglamento (CE) 796/2004 (CUE, 2004). Este reglamento indica que el sistema de control del establecimiento de las medidas agroambientales se efectuará mediante visitas sobre el terreno a una muestra que recoja como mínimo el 1% del número total de explotaciones que presenten la solicitud de ayuda. Dado el elevado número de explotaciones que se acogen a estas ayudas, esta muestra es muy pequeña y está limitada porque el seguimiento mediante visitas en campo (*in situ*) resulta prácticamente inviable desde un punto de vista técnico y económico.

Actualmente, el seguimiento de algunas de las medidas agroambientales subvencionadas se podría llevar a cabo mediante la aplicación de técnicas de teledetección (Peña-Barragán *et al.*, 2004; Barbero *et al.*, 2005; García-Torres y López-Granados, 2005), por los siguientes motivos: 1) el sensor utilizado (satélite o fotografía aérea) registra aquello que existe en el campo (objetividad), 2) las imágenes remotas abarcan grandes superficies de terreno con información continua de todos sus puntos, 3) el procedimiento de análisis de la imagen obtenida es rápido y automático (o semi-automático) una vez que se ha puesto el método a punto, 4) se puede trabajar de forma secuencial, 5) se disminuyen los muestreos en campo (se eluden problemas meteorológicos), y 6) se posibilita la planificación de la toma de imágenes en el momento oportuno, retrasando si fuera necesario el análisis el tiempo necesario sin perder por ello información. En el **capítulo 2** de esta Tesis Doctoral se pretende evaluar la capacidad que presentan nuevas técnicas de teledetección para discriminar satisfactoriamente 2 medidas agroambientales fundamentales: el mantenimiento de los restos de cultivos herbáceos (rastros) y el control de las zonas donde se ha producido la quema de dichos restos.

### 2.2. Agricultura de conservación y teledetección

Algunos autores han empleado la teledetección para el seguimiento de prácticas de manejo y conservación del suelo agrícola. Por ejemplo, Aguilar *et al.*, (2010) dentro de un proyecto conjunto del USDA Agricultural Research Station-Hydrology y el Laboratorio de Teledetección ARS-HRSL, analizaron la capacidad de detectar y medir cubiertas de residuos de cultivos de secano mediante el índice CAI (*Cellulose Absorption Index*) con imágenes multiespectrales aéreas. A partir de imágenes con características similares, Peña-Barragán *et al.* (2004) detectaron variaciones de cubiertas vegetales en olivar mediante el uso de distintos índices de vegetación. Por su parte, Pacheco *et al.*, (2010) emplearon imágenes radar del satélite TerraSAR-X para la discriminación entre zonas agrarias donde se aplicaron métodos de cultivo tradicionales con laboreo y zonas donde se aplicaron técnicas de conservación (no laboreo). Un análisis agronómicamente más completo lo desarrollaron Hache *et al.* (2005) los cuales usaron imágenes aéreas multiespectrales para la discriminación entre zonas de agricultura tradicional y zonas de agricultura de conservación, con el objetivo de determinar las relaciones entre las prácticas de manejo del suelo y la aplicación de nutrientes más adecuada.

### 2.3. Agricultura de precisión

La **agricultura de precisión** tiene como principal objetivo la aplicación selectiva o localizada de agroquímicos con el fin de reducir costes, optimizar el rendimiento de los cultivos, aumentar la rentabilidad para los productores y obtener beneficios ecológicos y ambientales (Robert, 2002). Está conceptualizada como un sistema agronómico orientado hacia una agricultura de bajos inputs, alta eficiencia y sostenibilidad (Shibusawa, 1998). El concepto de agricultura de precisión apareció en los años 80, aunque hasta 5 años más tarde no comenzó a aplicarse. La tecnología ligada a estas técnicas surgió ante la necesidad de mejorar el proceso de producción agrícola y controlar la sobreaplicación de agroquímicos que dañan el medioambiente y producen pérdidas económicas (NRC, 1997). Esto ha llevado a la introducción y aplicación de nuevas tecnologías en la agricultura.

Para aplicar la agricultura de precisión es necesario conocer a fondo la variabilidad espacial y temporal de los distintos componentes que conforman la productividad de un cultivo, como las características del suelo, la dosis de siembra, el contenido o estrés hídrico, las infestaciones de malas hierbas y plagas, entre otros (Zhang *et al.*, 2002). La agricultura de precisión basada en tratamientos en tiempo real consiste en monitorizar la variable de interés, tomar la decisión sobre qué aplicar y llevar a cabo el tratamiento adecuado mientras el vehículo se mueve a una velocidad constante. Por el contrario, la agricultura de precisión basada en mapas consiste en desarrollar métodos robustos para la adquisición de datos, su análisis y el diseño de zonas de manejo localizado (López-Granados, 2011) Por tanto, si se está interesado en la obtención de mapas de la variable objeto de interés, éstos deben ser precisos. A partir de los diferentes mapas obtenidos se pueden estimar en cada punto de la parcela, y con suficiente antelación y fiabilidad, distintos parámetros de interés agronómico, tales como las necesidades de riego, nutrientes y productos fitosanitarios o, incluso, la cosecha final del cultivo. La obtención de esta información tan detallada del terreno sólo es posible con la combinación de distintas tecnologías tales como los Sistemas de Posicionamiento Global (GPS) para situar geográficamente las variables, la teledetección para recoger información del terreno tanto a nivel imagen como a nivel puntual-continuo y los Sistemas de Información Geográfica (SIG) para el análisis de esos datos y la toma de decisiones. Cabe destacar que la agricultura de precisión sólo tiene sentido en el estudio de parámetros con dependencia espacial, es decir, cuando los factores de interés estén distribuidos en agregados y existan zonas con más o menos concentración de variables (nutrientes y malas hierbas entre otros). Cuando no existe dicha dependencia espacial, las aplicaciones localizadas no pueden llevarse a cabo y la parcela ha de considerarse como un todo (Pierce y Nowak, 1999).

Pese a los grandes beneficios que supone la agricultura de precisión, ésta no ha sufrido una expansión tan grande como las técnicas de agricultura de conservación. Este crecimiento más ralentizado se debe principalmente a problemas de rentabilidad. Aunque el pilar básico de esta agricultura es la reducción de costes aplicando la cantidad necesaria de productos únicamente en la localización que la demande, estas técnicas requieren de una inversión inicial de tecnología que se debe amortizar. Esta amortización dependerá



de: 1) número y coste de las tecnologías a usar, ya que esta nueva tecnología supone una inversión inicial considerable; 2) dimensiones de la parcela, ya que cuanto mayor sea la superficie donde se aplica, más rápida será la amortización de los equipos; y 3) rendimiento productivo de los cultivos sobre los que se aplica, ya que mayores rendimientos ofrecerán mayores márgenes de beneficio que podrán incrementarse más rápidamente con estas técnicas, 4) mayores requisitos de formación para técnicos y usuarios que en otros tipos de agricultura, 5) falta de compatibilidad entre la actual y la nueva maquinaria y entre vehículos de distintas empresas (Valero, 2004, López-Granados, 2011). Sin embargo, pese a las desventajas existentes frente a la agricultura de mercado, el consumo masivo actual de insumos origina una gran preocupación ambiental y económica en distintos ámbitos administrativos que está dando lugar a nuevas normativas de control.

### *2.4. Agricultura de precisión y teledetección*

Hasta hace poco tiempo, la teledetección se restringía al estudio de zonas amplias. Con el incremento de la resolución espacial y espectral, actualmente es posible desarrollar técnicas de agricultura de precisión con exactitudes por debajo del metro. En este sentido, diversos autores han realizado trabajos basados en el análisis de variables agronómicas que afectan directamente al cultivo para optimizar su manejo. Por ejemplo, existen trabajos que se centran en determinar las necesidades nutricionales precisas de una parcela para proponer aplicaciones variables de fertilizante a lo largo del cultivo (Li *et al.*, 2010; Schumann, 2010; Schmit *et al.*, 2011) o en las deficiencias hídricas para determinar las necesidades de riego (Yang *et al.*, 2010; Nahry *et al.*, 2011). En otros casos, el manejo preciso se centra en agentes bióticos que pueden alterar y/o menguar la producción agrícola como es el caso de la detección de cultivos afectados por algún tipo de plaga (Du *et al.*, 2008; Lan *et al.*, 2009). Dentro de este grupo, y mucho más frecuentes son los estudios centrados en la detección de plantas invasoras (Lass *et al.*, 2005; Wang *et al.*, 2008) o malas hierbas (López-Granados *et al.*, 2006; Peña-Barragán *et al.*, 2007; López-Granados *et al.*, 2008; De Castro *et al.*, 2009; Peña-Barragán *et al.*, 2010) que compiten directamente por los mismos recursos del cultivo.

### *2.5. Control Localizado de Malas Hierbas (CLMH)*

Una de las características que se puede controlar con la agricultura de precisión es la existencia o no de malas hierbas en el cultivo e incluso su densidad, de manera que se optimice económica y medioambientalmente el uso de herbicidas y se aplique sólo la dosis necesaria en las zonas que lo requieran. La discretización de la superficie agraria en distintas zonas según la distribución de malas hierbas es la primera etapa para aplicar las técnicas de agricultura de precisión. Esta información puede ser obtenida mediante sensores próximos (Srinivasan, 2006), sensores y cámaras acopladas a maquinaria de campo (tractores, cosechadoras, robots). Estas técnicas tienen su principal potencial en la posibilidad de capturar los datos o la imagen, analizarla y tomar la decisión en tiempo real, de manera que, por ejemplo, se pueda discriminar la presencia de malas hierbas en un cultivo y en el mismo momento aplicar la dosis necesaria de herbicida mientras que el

vehículo sigue su movimiento a una velocidad constante (Lee *et al.*, 1999). Sin embargo, la tecnología de sensores en campo exige una puesta a punto más compleja y costosa con resultados no siempre satisfactorios, aunque es una alternativa con un potencial de desarrollo muy elevado.

Por otra parte, otro método muy efectivo para obtener la distribución espacial de las características de los cultivos y el mapa correspondiente sobre el que diseñar un posterior tratamiento, es la teledetección aplicada a imágenes aéreas o satelitales (López-Granados, 2011). Para la caracterización espacial de la parcela, las técnicas de teledetección son muy adecuadas en aquellos casos en que los usos de suelo sean detectables por el sensor remoto ya que eliminan el duro y costoso muestreo en campo (Seelan *et al.*, 2003). La obtención de mapas de infestaciones de malas hierbas en cultivos tiene utilidad no sólo para realizar aplicaciones localizadas de herbicida, sino también para planificar futuras estrategias de manejo y conocer la ecología de la mala hierba en cuestión. Por ello, la aplicación de la teledetección en la obtención de mapas de infestaciones de malas hierbas es un objetivo ampliamente perseguido por muchos científicos expertos en malherbología (López-Granados *et al.*, 2006; Peña-Barragán *et al.*, 2007; López-Granados *et al.*, 2008; De Castro *et al.*, 2009; Martin *et al.*, 2009; Peña-Barragán *et al.*, 2010).

El consumo masivo actual de productos fitosanitarios en general, y de herbicidas en particular, origina una gran preocupación ambiental y económica en distintos ámbitos administrativos. Esto ha dado lugar al Reglamento (CE) 1107/2009 (CUE, 2009) para la Comercialización de Productos Fitosanitarios y dentro de éste la Directiva 2009/128/CE para el uso sostenible de Plaguicidas, donde se observa legislación específica para los herbicidas. En ella se destacan como elementos clave “*el fomento del bajo consumo (reducción de las aplicaciones) y la utilización de dosis adecuadas en función de las infestaciones de malas hierbas*”.

El **capítulo 4** de esta Tesis Doctoral está dedicado a la obtención de mapas de infestaciones avena loca (*Avena sterilis*), mala hierba muy común en campos de trigo (*Triticum durum*). Como continuación de este estudio, el **capítulo 5** se centra en el análisis de la estabilidad espacial de los rodales de dichas malas hierbas y la propuesta de mapas de tratamientos localizados basados en la agricultura de precisión. Así mismo, incluirá el desarrollo de un método robusto que incluya la metodología de adquisición de información de las malas hierbas, el análisis de los datos y el diseño de unas zonas de tratamiento para su uso posterior.

## 2.6. Control Localizado de Malas Hierbas (CLMH) y teledetección

Como se ha comentado anteriormente, un uso muy extendido de la teledetección se centra en la identificación y discriminación de los rodales de malas hierbas presentes en los cultivos, con el objetivo de elaborar mapas de infestaciones y futuros tratamientos localizados. Los primeros trabajos se llevaron a cabo por Menges *et al.* (1985) y Everitt *et*

*al.* (1987) que utilizaron fotografías aéreas en color e infrarrojo-color para detectar malas hierbas problemáticas (venenosas o invasoras) presentes en distintos ecosistemas agrarios o forestales. Actualmente, otros investigadores siguen empleando la teledetección para propósitos similares, centrándose los análisis en dos situaciones diferentes: 1) detección de malas hierbas en estado fenológico temprano (plántula), y 2) detección en estado fenológico tardío de malas hierbas. La detección de malas hierbas en cultivos en estados tempranos es bastante complejo y en muchos casos demanda tecnologías muy concretas como sensores de muy alta resolución espacial o hiperespectrales, ya que se suele observar una reflectancia similar entre malas hierbas y cultivos, una ocupación del suelo muy pequeña al no estar totalmente desarrolladas y una señal espectral adicional al existir en estos periodos tan iniciales superficies de suelo desnudo sin cubrir con material vegetal (Thorp y Tian, 2004). Gray *et al.* (2008), analizaron la capacidad de discriminación entre suelo, cultivo de soja y seis especies en varias fechas con imágenes multiespectrales aéreas de alta resolución espacial, indicando que el grado de discriminación aumentaba a medida que la planta iba creciendo. Sin embargo, en ese trabajo se concluyó que la utilización de imágenes hiperespectrales ofrecería más posibilidades para este tipo de estudios. A partir de imágenes hiperespectrales, Martin *et al.* (2009) mapearon tres tipos distintos de malas hierbas en estado de plántula en cultivo temprano de maíz con el sensor AHS (*Airborne Hyperspectral Scanner*), mientras que Goel *et al.* (2003) y Karimi *et al.* (2005) también mapearon distintos tipos de malas hierbas tempranas en maíz con el sensor CASI (*Compact Airborne Spectral Imager*). Por otra parte, la alternativa de discriminar las malas hierbas en un periodo tardío está más estudiada. En este periodo, las diferencias entre el ciclo de vida del cultivo y de la mala hierba es más marcado, lo que suele acarrear una diferencia en la señal espectral de ambas especies (López-Granados, 2011). En estos casos es necesario caracterizar el estado fenológico más adecuado para aumentar la probabilidad de discriminar las malas hierbas presentes en el cultivo mediante algún método como la medida de firmas espectrales con espectrorradiómetro de campo. López-Granados *et al.* (2006) centraron su trabajo en discriminar malas hierbas gramíneas en trigo a partir de índices de vegetación obtenidos con una imagen aérea multiespectral de muy alta resolución espacial. También con imágenes aéreas, Peña-Barragán *et al.* (2007) discriminó malas hierbas en cultivos de girasol mediante índices de vegetación. Con características similares de estudio pero incorporando técnicas de análisis de imágenes más avanzadas como las redes neuronales, Gutiérrez-Peña *et al.* (2008) incrementaron hasta un 15% la precisión en la discriminación de malas hierbas en girasol. Otros estudios se han centrado en analizar la estabilidad espacial de los rodales en el tiempo (Barroso *et al.*, 2004; Jurado-Expósito *et al.*, 2004, 2005; Heijtin *et al.*, 2007), observando que muchas malas hierbas suelen encontrarse agrupadas en rodales y su situación suele ser bastante estable a lo largo del tiempo, lo que facilita el diseño de mapas de Control Localizado de Malas Hierbas (CLMH) para posteriores aplicaciones. (Una revisión más completa de estas técnicas se puede consultar en López-Granados, 2011).

### 3. Objetivos y estructura de la tesis

Bajo la consideración de todo lo recogido anteriormente, el objetivo de esta Tesis Doctoral ha sido analizar un conjunto de técnicas de teledetección aplicadas sobre imágenes QuickBird de alta resolución espacial para evaluar la capacidad de discriminación de distintos usos del suelo que faciliten la toma de decisiones en la gestión de técnicas agrarias guiadas hacia la agricultura de conservación y agricultura de precisión. Este objetivo general se ha desarrollado a través de los siguientes objetivos específicos:

1. Discriminar distintos usos de suelo en régimen de agricultura de conservación, evaluando diferentes técnicas de clasificación basadas en píxeles y objetos con imágenes multiespectrales y fusionadas, y proponer la más adecuada para la detección de técnicas relacionadas con este tipo de agricultura.
2. Medir la firma espectral del trigo y de las principales malas hierbas gramíneas presente en dicho cultivo, *Avena sterilis*, *Phalaris* spp, y *Lolium rigidum*, en sus diferentes estados fenológicos mediante el empleo de espectrorradiómetro de campo y analizar estadísticamente los datos hiperespectrales y multiespectrales obtenidos para seleccionar las longitudes de onda, bandas e índices de vegetación, así como la fecha de medida más adecuada para la discriminación entre las especies consideradas.
3. Evaluar el uso de imágenes multiespectrales de alta resolución espacial QuickBird para elaborar mapas de rodales de *Avena sterilis* en trigo a escala parcela y a escala imagen mediante la evaluación de distintas técnicas de clasificación basadas en píxeles y objetos.
4. Analizar la estabilidad espacial presente en las infestaciones de *Avena sterilis* en trigo para valorar su aplicabilidad en agricultura de precisión mediante el diseño y evaluación de mapas de manejo localizado de malas hierbas.

Esta Tesis Doctoral está estructurada en seis capítulos. El **capítulo 1** es el capítulo actual, donde se recogen los principales conceptos así como una breve revisión bibliográfica de los temas básicos referidos en este trabajo: teledetección en la agricultura, agricultura de conservación y agricultura de precisión. En los capítulos siguientes se presentan los cuatro trabajos que forman el núcleo de la Tesis. Así, en el **capítulo 2** se desarrolla una evaluación de técnicas que permitan optimizar el análisis de distintos cultivos junto con sus medidas agroambientales asociadas bajo régimen de agricultura de conservación. En el **capítulo 3** se lleva a cabo un estudio multitemporal de las firmas espectrales que caracterizan el cultivo de trigo y sus malas hierbas gramíneas más destacadas (avena loca y alpiste) en Andalucía, para determinar tanto el rango de longitudes de onda como el momento fenológico más apropiado para la discriminación

entre dichas especies. En el **capítulo 4**, y conociendo los datos propuestos en el **capítulo 3**, se evalúan diversas técnicas de clasificación basadas en píxeles y objetos para discriminar y elaborar mapas de infestaciones de avena loca en el cultivo de trigo utilizando imágenes de satélite QuickBird. En el **capítulo 5**, y tras obtener los mapas de infestación, se analiza la estabilidad espacial de dichos rodales de malas hierbas y se propone una alternativa de Control Localizado de Malas Hierbas (CLMH). Finalmente, en el **capítulo 6** se analizan conjuntamente los resultados de los capítulos anteriores para extraer las conclusiones generales acerca de la viabilidad del uso de la teledetección para la discriminación y clasificación de los usos de suelo estudiados.

## 4. Referencias

AEAC-SV. 2011 Beneficios de la agricultura de conservación. <http://www.agriculturadeconservacion.org/quienes-somos/beneficios-de-la-ac.html>.

Aguilar, J., Evans, R., Daughtry, C.S.T. 2010. Evaluation of CAI method of crop residue assessment as a tool for soil and water conservation management in the dryland agriculture of the Northern Great Plains. American Society of Agricultural and Biological Engineers Annual International Meeting 2010 1, 749-756.

Al-Khudhairi, D.H.A., Caravaggi, I., Giada, S. 2005. Structural damage assessments from Ikonos data using change detection, object-oriented segmentation, and classification techniques. Photogrammetric Engineering and Remote Sensing 71, 825-837.

ASD (Analytical Spectral Devices). 2003. HandHeld Spectroradiometer. User's Guide. Analytical Spectral Devices, Inc. 5335 Sterling Drive, USA.

Asner, G.P. 1998. Biophysical and biochemical sources of variability in canopy reflectance. Remote Sensing of Environment 64, 234-253.

Baatz, M., Schäpe, A. 2000. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: Proceedings of the 12th Symposium for Applied Geographic Information Processing (Angewandte Geographische Informationsverarbeitung XII. AGIT 2000), Salzburg, Austria, 12-23.

Barbero, R.S., Checa-Alonso, M.J., Gragera-Ibáñez, F. 2005. Control por teledetección de las medidas agroambientales y buenas prácticas agrícolas. In: Actas del XI Congreso Nacional de Teledetección, Tenerife, España, 97-100.

Barroso, J., Fernández-Quintanilla, C., Ruíz, D., Hernaiz, P., Rew, L.J. 2004. Spatial stability of *Avena sterilis* ssp. *ludoviciana* populations under annual applications of low rates of imazamethabenz. Weed Research 44, 178-186.

Ben-Dor, E., Taylor, R.G., Hill, J., Demattê, J.A.M., Whiting, M.L., Chabrillat, S., Sommer, S. 2008. Imaging Spectrometry for Soil Applications. Advances in Agronomy 97, 321-392.

Blaschke, T. 2010. Object based image analysis for remote sensing. *Journal of Photogrammetry and Remote Sensing* 65, 2-16.

Brizuela, A.B., Carñel, G.E., Aguirre, C.A., Romero, E.C., Sione, W.F. 1997. Procesamiento digital de fotografías aéreas pancromáticas visible e infrarrojo cercano. *Información Tecnológica CIT Revista Internacional* 8, 165-170.

Broge, N.H., Leblanc, E. 2001. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment* 76, 156-172.

Brown, R.B., Steckler, J.P.G.A., Anderson, G.W. 1994. Remote sensing for identification of weeds in no-till corn. *Transactions of the ASAE* 37, 297-302.

Brown, R.B., Noble, S.D. 2005. Site-specific weed management: sensing requirements-what do we need to see?. *Weed Science* 53, 252-258.

Budreski, K.A., Wynne, R.H., Browder, J.O., Campbell, J.B. Comparison of segment and pixel-based non-parametric land cover classification in the Brazilian Amazon using multitemporal Landsat TM/ETM+ imagery. *Photogrammetric Engineering and Remote Sensing* 73, 813-827.

Chaudhari, K.N., Tripathy, R., Patel, N.K. 2010. Spatial wheat yield prediction using crop simulation model GIS remote sensing and ground observed data. *Journal of Agrometeorology* 12, 174-180.

Chubey, M.S., Franklin, S.E., Wulder, M.A. 2006. Object-based analysis of Ikonos-2 imagery for extraction of forest inventory parameters. *Photogrammetric Engineering and Remote Sensing* 72, 383-394.

Chuvieco, E., Huete, A. 2010. *Fundamentals of Satellite Remote Sensing*. CRC Press. Taylor and Francis Group. EE.UU.

Ciriza, R., Albizua, L., González de Audicana, M. 2009. Análisis de la utilidad de los descriptores texturales de Haralick para la localización de arranques de frutales en ortofoto. In: *Actas XIII Congreso de la Asociación Española de Teledetección*, Calatayud, España, pp. 597-600.

Cocquerez, J.P., Philipp, S. 1995. *Analyse d'images: filtrage et segmentation*, Masson, Paris.

CUE (Consejo de la Unión Europea). 1999a. Reglamento (CE) nº 1257/1999, del Consejo de 17 de mayo, sobre la ayuda al desarrollo rural a cargo del Fondo Europeo de Orientación y de Garantía Agrícola (FEOGA) y por el que se modifican y derogan determinados Reglamentos. *Diario Oficial de las Comunidades Europeas*, Bruselas, 160, 80-102.

CUE (Consejo de la Unión Europea). 1999b. Reglamento (CE) nº 1259/1999, del Consejo de 17 de mayo, por el que se establecen las disposiciones comunes aplicables a los regímenes de ayuda directa en el marco de la política agrícola común. Diario Oficial de las Comunidades Europeas, Bruselas, 160, 113–118.

CUE (Consejo de la Unión Europea). 2003. Reglamento (CE) nº 1782/2003, del Consejo de 29 de septiembre, por el que se establecen disposiciones comunes aplicables a los regímenes de ayuda directa en el marco de la política agrícola común y se instauran determinados regímenes de ayuda a los agricultores y por el que se modifican los Reglamentos (CEE) nº 2019/93, (CE) nº 1452/2001, (CE) nº 1453/2001, (CE) nº 1454/2001, (CE) nº 1868/94, (CE) nº 1251/1999, (CE) nº 1254/1999, (CE) nº 1673/2000, (CEE) nº 2358/71 y (CE) nº 2529/2001. Diario Oficial de las Comunidades Europeas, Bruselas, 270, 1–69.

CUE (Consejo de la Unión Europea). 2004. Reglamento (CE) nº 796/2004, del Consejo de 21 de abril, por el que se establecen disposiciones para la aplicación de la condicionalidad, la modulación y el sistema integrado de gestión y control previstos en el Reglamento (CE) nº 1782/2003 del Consejo por el que se establecen disposiciones comunes aplicables a los regímenes de ayuda directa en el marco de la política agrícola común y se instauran determinados regímenes de ayuda a los agricultores. Diario Oficial de las Comunidades Europeas, Bruselas, 141, 18–58.

CUE (Consejo de la Unión Europea). 2009. Reglamento (CE) nº 1107/2009, del Parlamento Europeo y del Consejo de 21 de octubre, relativo a la comercialización de productos fitosanitarios y por el que se derogan las Directivas 79/117/CEE y 91/414/CEE del Consejo. Diario Oficial de la Unión Europea, Estrasburgo 309, 1–50.

Daughtry, C.S.T., Walthall, C.L. 1998. Spectral discrimination of Cannabis sativa L. leaves and canopies. *Remote Sensing of Environment* 64, 192–201.

De Castro, A.I., Jurado-Expósito, M., Peña-Barragán, J.M., García-Torres, L., López-Granados, F. 2009. Discriminación de malas hierbas crucíferas en cultivos de invierno para su aplicación en agricultura de precisión. In: *Actas XIII Congreso de la Asociación Española de Teledetección*, Calatayud, España, pp. 61–65.

Definiens. 2007. *Definiens Developer 7 Reference Book*. Definiens AG., München.

Dobrowski, S.Z., Safford, H.D., Cheng, Y.B., Ustin, S.L. 2008. Mapping mountain vegetation using species distribution modeling, image-based texture analysis, and object-based classification. *Applied Vegetation Science* 11, 499–508.

Du, Q., Chang, N.B., Yang, C., Srilakshmi, K.R. 2008. Combination of multispectral remote sensing, variable rate technology and environmental modeling for citrus pest management *Journal of Environmental Management* 86, 14–26.

Ducrot, D., Masse, A., Ceschia, E., Marais-Sicre, C., Krystof, D. 2010. A methodology for the detection of land cover changes: Application to the Toulouse southwestern region. *Proceedings of SPIE - The International Society for Optical Engineering* Volume 7830, Article number 78301J.

Duggin, M.J., Robinove, C.J. 1990. Assumptions implicit in remote sensing data acquisition and analysis. *Int. J. Remote Sensing of Environment* 11, 1669–1694.

Dumanski, J.R. Peiretti, J. Benetis, D. McGarry, Pieri, C. 2006. The paradigm of conservation tillage. *Proceedings of World Association of Soil and Water Conservation*, 58-64.

Everitt, J.H., Villareal, R. 1987. Detecting huisache (*Acacia farnesiana*) and mexican palo-verde (*Parkinsonia aculeata*) by aerial photography. *Weed Science* 35, 427-432.

FAO. 2001. Conservation agriculture, matching production with sustainability. <ftp://ftp.fao.org/agl/agll/ch10/ch104.pdf>.

FAO. 2008. Investing in Sustainable Crop Intensification: The Case for Soil Health. Report of the International Technical Workshop, FAO, Rome. *Integrated Crop Management* 6.

FAO. 2011. What is Conservation Agriculture?. <http://www.fao.org/ag/ca/1a.html>.

Felton, W.L., Alston, C.L., Haigh, C.B.M., Nash, P.G., Wicks, G.A., Hanson, G.E. 2002. Using reflectance sensors in agronomy and weed science. *Weed Technology*. 16, 520-527.

Feng, L., Wu, W., Chen, X., Tian, L., Cai, X., Su, G. 2010. Diseases and insect pests area monitoring for winter wheat based on HJ-CCD imagery. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering* 26, 213-219.

Filella, I., Serrano, L., Serra, J., Penuelas, J. 1995. Evaluating wheat nitrogen status with canopy reflectance indices and discriminant analysis. *Crop Science* 35, 1400–1405.

García-Olmedo, F. 1998. *La tercera revolución verde*. Temas de debate, Madrid.

García-Torres, L., López Granados, F., Peña-Barragán, J. M., Jurado-Expósito, M., García-Ferrer, A., Sánchez-de la Orden, M. 2004. Seguimiento administrativo de medidas agroambientales por teledetección. *Agricultura* 866, 706-711.

García-Torres, L., López-Granados, F. 2005. Discriminación de usos del suelo para su seguimiento administrativo mediante teledetección. In: *Actas del congreso internacional sobre agricultura de conservación*, Córdoba, España, pp. 44-53.

Girma, K., Mosali, J., Raun, W.R., Freeman, K.W., Martín, K.L., Solie, J.B., Stone, M.L. 2005. Identification of optical spectral signatures for detecting cheat and ryegrass in winter wheat. *Crop Science* 18, 477-485.

Gray, J.C.J., Shaw, D.R., Gerad, P.D., Bruce, L.M. 2008. Utility of multispectral imagery for soybean and weed species differentiation. *Weed Technology* 22, 713–718.



Goel, P.K., Prasher, S.O., Landry, J.A., Patel, R.M., Bonnel, R.B., Viau, A.A., Miller, J.R. 2003. Potential of airborne hyperspectral remote sensing to detect nitrogen deficiency and weed infestation in corn. *Computers and Electronics in Agriculture* 38, 99-124.

Guastaferrò, F., Castrignanò, A., de Benedetto, D., Sollitto, D., Troccoli, A., Cafarelli, B. 2010. A comparison of different algorithms for the delineation of management zones. *Precision Agriculture* 11, 600-620.

Gutiérrez-Peña, P.A., López-Granados, F., Peña-Barragán, J.M., Jurado-Expósito, M., Hervás-Martínez, C. 2008. Logistic regression product-unit neural networks for mapping *Ridolfia segetum* infestations in sunflower crop using multitemporal remote sensed data. *Computers and Electronics in Agriculture* 64, 293-306.

Hache, C., Shibusawa, S., Sasao, A. 2005. Discriminating conventional and conservation agricultural management practices with airborne multispectral imagery. *Agriculture, Ecosystems and Environment* 111, 354-366.

Heijting, S., Werf, W.V., Stein, A., Kropff, M.J. 2007. Are weed patches stable in location? Application of an explicitly two-dimensional methodology. *Weed Research* 47, 381-395.

Huang, Y., Zhu, Y., Wang, H., Yao, X., Cao, W., Hannaway, D.B., Tian, Y. 2011. Predicting winter wheat growth based on integrating remote sensing and crop growth modeling techniques. *Shengtai Xuebao/ Acta Ecologica Sinica* 31, 1073-1084.

Hubert-Moy, L., Cotonnec, A., Le Du, L., Chardin, A., Pérez, P. 2001. A comparison of parametric classification procedures of remotely sensed data applied on different landscape units. *Remote Sensing of Environment* 75, 174-187.

Hunt, E.R., McMurtrey, J.E., Parker-Williams, A.E., Corp, L.A. 2004. Spectral characteristic of leafy spurge (*Euphorbia esula*) leaves and flower bracts. *Weed Science* 51, 492-497.

IDAE (Instituto para la Diversificación y Ahorro de la Energía). 2009. Ahorro y Eficiencia Energética con Agricultura de Conservación. Fondo editorial del IDAE, en la serie "Ahorro y Eficiencia Energética en la Agricultura". Madrid.

Itano, S., Tomimatsu, H. 2011. Reflectance spectra for monitoring green herbage mass in *Zoysia*-dominated pastures. *Grassland Science* 57, 9-17.

Jing, X., Huang, W., Ju, C., Xu, X. 2010. Remote sensing monitoring severity level of cotton verticillium wilt based on partial least squares regressive analysis. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering* 26, 229-235.

Jurado-Expósito, M., López-Granados, F., González-Andújar, J.L., García-Torres, L. 2004. Spatial and temporal analysis of *Convolvulus arvensis* L. populations over four growing seasons. *European Journal of Agronomy* 21, 287-296.

Jurado-Expósito, M., López-Granados, F., González-Andújar, J.L., García-Torres, L. 2005. Characterizing population growth rate of *Convolvulus arvensis* L. in wheat-sunflower no-tillage systems. *Crop Science* 45, 2106–2112.

Karimi, Y.A., Prasher, S.O., McNaim, H., Bonnell, R.B., Dutilleul, P., Goel, P.K. 2005. Discriminant analysis of hyperspectral data for assessing water and nitrogen stresses in corn. *Transactions of the ASAE* 48, 805–813.

Koger, H.K., Shaw, D.R., Watson, C.E., Reddy K.N. 2003. Detecting late-season weed infestations in soybean (*Glycine max*). *Weed Technology* 17, 696-704.

Koger, H.K., Shaw, D.R., Reddy K.N., Bruce, L.M. 2004. Detection of pitted morningglory (*Ipomea lacunosa*) with hyperspectral remote sensing. II. Effects of vegetation ground cover and reflectance properties. *Weed Science*. 52, 230-235.

Lan, Y., Huang, Y., Martin, D.E., Hoffmann, W.C. 2009. Development of airborne remote sensing system for crop pest management: System integration and verification *Applied Engineering in Agriculture* 25, 607-615.

Lass, L.W., Prather, T.S., Glenn, N.F., Weber, K.T., Mundt, J.T., Pettingill, J. 2005. A review of remote sensing of invasive weeds and example of the early detection of spotted knapweed (*Centaurea maculosa*) and babysbreath (*Gypsophila paniculata*) with a hyperspectral sensor. *Weed Science* 53, 242-251.

Lee, W., Slaughter, D., Giles, D. 1999. Robotic weed control system for tomatoes. *Precision Agriculture* 1, 95–113.

Leon, C.T., Shaw, D.R., Cox, M.S., Abshire, M.J., Ward, B., Wardlaw III, M.C. 2003. Utility of remote sensing in predicting crop and soil characteristics. *Precision Agriculture* 4, 359-384.

Li, S., Li, M., Ding, Y., Zhao, R. 2010. Variable rate fertilization based on spectral index and remote sensing. *Proceedings of SPIE - The International Society for Optical Engineering* 7857, Article number 785719.

Li, Y., Jiang, N., Shi, H., Lü, H., Xue, C., Wang, N. 2010. Crops distribution in large scale based on SPOT/VGT NDVI. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering* 26, 242-247.

López-Granados, F., Jurado-Expósito, M., Peña-Barragán, J. M., García-Torres, L., 2005. Using geostatistical and remote sensing approaches for mapping soil properties. *European Journal of Agronomy* 23, 279-289.

López-Granados, F., Jurado-Expósito, M., Peña-Barragán, J.M., García-Torres, L. 2006. Using remote sensing for identification of late-season grass weed patches in wheat. *Weed science* 54, 346–353.

López-Granados, F., Peña-Barragán, J.M., Jurado-Expósito, M., Francisco-Fernández, M., Cao, R., Alonso-Betanzos, A., Fontenla-Romero, O. 2008. Multispectral classification of grass weeds and wheat (*Triticum durum*) using linear and nonparametric functional discriminant analysis and neural networks. *Weed Research* 48, 28-37.

López-Granados, F., Gómez-Casero, M.T., Peña-Barragán, J.M., Jurado-Expósito, M., García-Torres, L. 2010. Classifying irrigated crops as affected by phenological stage using discriminant analysis and neural networks. *Journal of the American Society for Horticultural Science* 135, 465-473.

López-Granados, F. 2011. Weed detection for site-specific weed management: mapping and real-time approaches. *Weed research* 51, 1-11.

Ma, B.L., Dwyer, L.M., Costa, C., Cober, E.R., Morrison, M.J. 2001. Early prediction of soybean yield from canopy reflectance measurements. *Agronomy Journal* 93, 1227-1234.

MAMRM. 2009. Real Decreto 486/2009, de 3 de abril, por el que se establecen los requisitos legales de gestión y las buenas condiciones agrarias y medioambientales que deben cumplir los agricultores que reciban pagos directos en el marco de la política agrícola común, los beneficiarios de determinadas ayudas de desarrollo rural, y los agricultores que reciban ayudas en virtud de los programas de apoyo a la reestructuración y reconversión y a la prima por arranque del viñedo. *Boletín Oficial del Estado*, Madrid, 94, 35451-35466.

MAMR. 2011. <http://www.marm.es/es/>

MAPA. 2001. Real Decreto 4/2001, de 12 de enero, por el que se establece un régimen de ayudas a la utilización de métodos de producción agraria compatibles con el medio ambiente. *Boletín Oficial del Estado*, Madrid, 12, 1587-1617.

MAPA. 2002a. Real Decreto 708/2002, de 19 de julio, por el que se establecen medidas complementarias al programa de desarrollo rural para las medidas de acompañamiento de la política agraria común. *Boletín Oficial del Estado*, Madrid, 175, 27004-27033.

MAPA. 2002b. Real Decreto 1322/2002, de 13 de diciembre, sobre requisitos agroambientales en relación con las ayudas directas en el marco de la política agraria común. *Boletín Oficial del Estado*, Madrid, 311, 45776-45777.

MAPA. 2004a. Real Decreto 172/2004, de 30 de enero, por el que se modifica el Real Decreto 708/2002, de 19 de julio, por el que se establecen medidas complementarias al programa de desarrollo rural para las medidas de acompañamiento de la política agraria común. *Boletín Oficial del Estado*, Madrid, 37, 6357-6383.

MAPA. 2004b. Real Decreto 2352/2004, de 23 de diciembre, sobre la aplicación de la condicionalidad en relación con las ayudas directas en el marco de la política agrícola común. *Boletín Oficial del Estado*, Madrid, 309, 41690-41698.

Martín, P., Barreto, L., Riaño, D., Fernández-Quintanilla, C., Vaughan, P., Santis, A. 2009. Cartografía de malas hierbas en cultivos de maíz mediante imágenes hiperespectrales aeroportadas (AHS). In: Actas XIII Congreso de la Sociedad Española de Teledetección, Calatayud, España, pp. 41-44.

Maxwella, S.K. 2010. Generating land cover boundaries from remotely sensed data using object-based image analysis: Overview and epidemiological application. *Spatial and Spatio-temporal Epidemiology* 1, 231-237.

McCoy, R.M. 2005. *Field methods in remote sensing*. The Guilford Press, New York, EE.UU.

Menges, R.M., Nixon, P.R., Richardson, A.J. 1985. Light reflectance and remote sensing of weeds in agronomic and horticultural crops. *Weed Science* 33, 569-581.

Moran, J.A, Mitchell, A.K., Goodmanson, G., Stockburger, K.A. 2000. Differentiation among effects of nitrogen fertilization treatments on conifer seedlings by foliar reflectance: a comparison of methods. *Tree Physiology* 20, 1113-1120.

Muchoney, D.M., Strahler, A.H. 2002. Pixel- and site-based calibration and validation methods for evaluating supervised classification of remotely sensed data. *Remote Sensing of Environment* 81, 290-299.

Nahry, A.H.E., Ali, R.R., Baroudy, A.A.E. 2011. An approach for precision farming under pivot irrigation system using remote sensing and GIS techniques *Agricultural Water Management* 98, 517-531.

NRC (National Research Council). 1997. *Precision agriculture in the 21st century*. National Academy Press, Washington, DC, EE.UU.

Osborne, S.L., Schepers, J.S., Francis, D.D., Schlemmer, M.R. 2002. Use of spectral radiance to estimate in-season biomass and grain yield in nitrogen and water-stressed corn. *Crop Science* 42, 165-171.

Pacheco, A.M., McNairn, H., Merzouki, A. 2010. Evaluating TerraSAR-X for the identification of tillage occurrence over an agricultural area in Canada. *Proceedings of SPIE - The International Society for Optical Engineering* 7824, Article number 78240P.

Pacifici, F., Chini, M., Emery, W. J. 2009. A neural network approach using multiscale textural metrics from very high-resolution panchromatic imagery for urban land-use classification. *Remote Sensing of Environment* 113, 1276-1292.

Pan, X., Jiao, L. 2011. A granular agent evolutionary algorithm for classification. *Applied Soft Computing* Volume 11, 3093-3105.

Panda, S.S., Panigrahi, S., Ames, D.P. 2010. Crop yield forecasting from remotely sensed aerial images with self-organizing maps. *Transactions of the ASABE* 53, 323-338.

Peña-Barragán, J.M., Jurado-Expósito, M., López-Granados, F., Atenciano, S., Sánchez de la Orden, M., García-Ferrer, A., García-Torres, L. 2004. Assessing land-use in olive groves from aerial photographs. *Agriculture, Ecosystems and Environment* 103, 117-122.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2006. Spectral discrimination of *Ridolfia segetum* and sunflower as affected by phenological stage. *Weed Research* 46, 10-21.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2007. Mapping *Ridolfia segetum* patches in sunflower crop using remote sensing. *Weed Research* 47, 164-172.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2010. Sunflower yield related to multi-temporal aerial photography, land elevation and weed infestation. *Precision Agriculture* 11, 568-585.

Pedroso, M., Taylor, J., Tisseyre, B., Charnomordic, B., Guillaume, S. 2010. A segmentation algorithm for the delineation of agricultural management zones. *Computers and Electronics in Agriculture* 70, 199-208.

Pierce, F.J., Novak, P. 1999. Aspects of precision agriculture. *Advances in Agronomy* 67, 1-85.

Plant, R.E., Munk, D.S., Roberts, B.R., Vargas, R.N., Travis, R.L., Rains, D.W., Hutmacher, R.B. 2001. Application of remote sensing to strategic questions in cotton management and research. *Journal of Cotton Science* 5, 30-41.

Pôças, I., Cunha, M., Pereira, L.S. 2011. Remote sensing based indicators of changes in a mountain rural landscape of Northeast Portugal. *Applied Geography* 31, 871-880.

Pretty, J. 2008. Agricultural sustainability: concepts, principles and evidence. *Philosophical Transactions of the Royal Society of London B* 363, 447-466.

Radhakrishnan, J., Liang, S., Teasdale, J.R., Shuey C.J. 2002. Remote sensing of weed canopies. In: Ranjan S. Mittriah, ed. *From laboratory Spectroscopy to Remotely Sensed Spectra of Terrestrial Ecosystem*, Netherlands. Holanda.

Robert, P.C. 2002. Precision agriculture: a challenge for crop nutrition management. *Precision Agriculture* 247, 143-149.

Robinove, C. 1981. The logic of multispectral classification and mapping the land. *Remote sensing of Environment* 11, 231-24.

Salisbury, J. W. 1999. Spectral measurements field guide. In: Report No. ADA362372, Defense Technology Information Center, Fort Bervoir, EE.UU.

Schmidt, K.S., Skidmore, A.K. 2003. Spectral discrimination of vegetation types in a coastal wetland. *Remote Sensing of Environment* 85, 92-108.

Schmidt, J., Beegle, D., Zhu, Q., Sripada, R. 2011. Improving in-season nitrogen recommendations for maize using an active sensor *Field Crops Research* 120, 94-101.

Schumann, A.W. 2010. Precise placement and variable rate fertilizer application technologies for horticultural crops. *HortTechnology* 20, 34-40.

Seelan, S.K., Laguetta, S., Casady, G.M., Seielstad, G.A. 2003. Remote sensing applications for precision agriculture: a learning community approach. *Remote Sensing of Environment* 88, 157-169.

Serrano, L., Filella, I., Peñuelas, J. 2000. Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. *Crop Science* 40, 723-731.

Sims, D.A., Gamon, J.A. 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment* 81, 337-354.

Shibusawa, S. 1998. Precision farming and terramechanics. Fifth ISTVS Asia-Pacific Regional Conference, Seoul, Korea, 251-261.

Smith, A.M., Blackshaw, R.E. 2003. Weed-crop discrimination using remote sensing: a detached leaf experiment. *Weed Technology* 17, 811-820.

Sombrero, A., de Benito, A., Díez, M.C., Fernández, M. 2010. La agricultura de conservación en el mundo, en España y en Castilla y León: evolución y tendencias. In: Seminario sobre la Agricultura de Conservación como sistema para ahorrar energía y mejorar la sostenibilidad y rentabilidad de la agricultura en Castilla y León, Valladolid, España, sp.

Song, C., Woodcock, C.E., Seto, K.C., Lenney, M.P., Macomber, S.A. 2011. Classification and Change Detection Using Landsat TM Data: When and How to Correct Atmospheric Effects? *Remote Sensing of Environment* 75, 230-244.

Soria-Ruiz, J., Fernandez-Ordoñez, Y., Woodhouse, I.H. 2010. Land-cover classification using radar and optical images: A case study in Central Mexico. *International Journal of Remote Sensing* 31, 3291-3305.

South, S., Qi, J., Lusch, D.P. 2004. Optimal classification methods for mapping agricultural tillage practises. *Remote Sensing of Environment* 91, 90-97.

Srinivasan, A. 2006. Precision Agriculture: an Overview. In: *Handbook of Precision Agriculture: Principles and Applications* (ed. A SRINIVASAN), 3-18. Food Products Press, The Haworth Press. New York.

Taylor, J.A., Whelan, B.M. 2010. Selection of ancillary data to derive production management units in sweet corn (*Zea Mays* var. *rugosa*) using MANOVA and an information criterion. *Precision Agriculture* (in press).

Thorp, K.R., Tian, L.F. 2004. A review of remote sensing of weeds in agriculture. *Precision Agriculture* 5, 477-508.

Vaughan, P. 2001. Estimación del contenido de humedad de la vegetación mediante radiometría de campo. Tesis doctoral, Departamento de geografía, Universidad de Alcalá de Henares, Madrid.

Valero, C., 2004. Situación actual de la agricultura de precisión en España. *Vida Rural* 192, 17-20.

Wang, C., Zhou, B., Palm, H.L. 2008. Detecting invasive sericea lespedeza (*Lepedeza cuneata*) in Mid-Missouri pastureland using hyperspectral imagery. *Environmental Management* 41, 853-862.

Yang, C., Everitt, J.H., Murden, D. 2011. Evaluating high resolution SPOT 5 satellite imagery for crop identification. *Computers and Electronics in Agriculture* 75, 347-354.

Yang, G.J., Xing, Z.R., Feng, Y.G., Huang, W.J. 2010. Estimation of spring wheat water use efficiency by remote sensing in the yingke oasis of heihe drainage area. *Sensor Letters* 8, 6-10.

Zhang, Y.J. 1997. Evaluation and comparison of different segmentation algorithms. *Pattern Recognition Letters* 18, 963-974.

Zhang, N., Wang, M., Wang, N. 2002. Precision agriculture, a worldwide overview. *Computers and Electronics in Agriculture* 36, 113-132.

Zhao, D., Reddy, K.R., Kakani, V.G., Read, J.J., Carter, G.A. 2003. Corn (*Zea mays* L.) growth, leaf pigment concentration, photosynthesis and leaf hyperspectral reflectance properties as affected by nitrogen supply. *Plant Soil* 257, 205-217.

Zhao, D., Reddy, K.R., Kakani, V.G., Read, J.J., Koti, S. 2005. Selection of optimum reflectance ratios for estimating leaf nitrogen and chlorophyll concentrations of field-grown cotton. *Agronomy Journal* 97, 89-98.

Zhao, D., Reddy, K.R., Kakani, V.G., Read, J.J., Koti, S. 2007. Canopy reflectance in cotton for growth assessment and lint yield prediction. *European Journal of Agronomy* 26, 335-344.

**Análisis basado en píxeles y objetos para  
la detección de cultivos y sus medidas  
agroambientales mediante imágenes  
QuickBird**

---

## **CAPÍTULO II**





# Análisis basado en píxeles y objetos para la detección de cultivos y sus medidas agroambientales mediante imágenes QuickBird

## Resumen

Con la finalidad de mejorar la producción agrícola y reducir los efectos debidos a la erosión que actualmente se observan en algunas zonas sometidas a sistemas de cultivo intensivos, la Unión Europea sólo subvenciona aquellos cultivos que no presentan laboreo y en los que se están aplicando determinadas medidas agroambientales, tales como el mantenimiento de los residuos del cereal de invierno y la no quema de rastrojos. El sistema actual de control de estas ayudas está basado principalmente en visitas a campo dirigidas, lo que lo hace un sistema lento y costoso. Con objeto de mejorar este procedimiento de control y valorar si la teledetección a través de imágenes de satélite ofrece la capacidad de identificar de forma eficiente los cultivos y medidas agroambientales típicos mediterráneos, en el presente trabajo se ha realizado un análisis de fiabilidad de cinco métodos de clasificación digital (Paralelepípedos, Mínima Distancia, Distancia de Mahalanobis, *Spectral Angle Mapper* y Máxima Probabilidad). Al estudio se añadió la segmentación de las imágenes de satélite para analizar el comportamiento de los píxeles, objetos y píxeles+objetos como unidades mínimas de información en la clasificación. Para analizar las distintas metodologías de clasificación propuestas se utilizó una imagen QuickBird multiespectral y otra fusionada (pansharpen) con resolución espacial de 2.8m y 0.7m respectivamente tomada a principios de verano. La evaluación de la precisión de las clasificaciones se obtuvo mediante una matriz de confusión y el cálculo del coeficiente Kappa.

Los resultados obtenidos mostraron claramente que para la clasificación de todos los usos de suelo presentes en la imagen, tanto los análisis basados en objetos como los basados en píxeles+objetos fueron más precisos que los únicamente basados en píxeles, con una fiabilidad global superior al 85% en la mayoría de las clasificaciones realizadas. El método de Máxima Probabilidad fue el que mejor comportamiento presentó, obteniendo una fiabilidad global de 94.51% y un coeficiente Kappa de 0.94 en la clasificación basada en píxeles+objetos de la imagen fusionada. Sin embargo, cuando se evaluaron los usos de suelo por separado, el aumento de la resolución espacial que proporcionó la imagen fusionada en comparación con la imagen multiespectral, no mejoró la precisión de la clasificación en la mayoría de las situaciones estudiadas. Por ejemplo, el *rastrojo* de cereal de invierno fue discriminado con una fiabilidad global del 100% al clasificar la imagen multiespectral considerando cualquier unidad mínima de información. Los resultados obtenidos sugieren que la elección de una determinada metodología de clasificación (algoritmo, imagen y unidad mínima de información) puede influir notablemente en la precisión de la clasificación, siendo el objetivo final del estudio que se esté realizando el que determinará la mejor metodología de clasificación a aplicar, no sólo en función de la precisión requerida sino también en función de las limitaciones técnicas y computacionales.

## 1. Introducción

### 1.1. Generalidades

La cuenca mediterránea está ocupada principalmente por cultivos intensivos de secano con laboreo, el cual influye considerablemente en los procesos de degradación del suelo y desertificación (Hill *et al.*, 1995). Diversos autores han estudiado las implicaciones agroambientales de estos sistemas de cultivo tradicionales respecto a problemas de erosión y pérdida de suelo (Gómez *et al.*, 2003), distribución de herbicidas (Arora *et al.*, 1996), transporte de sedimentos (Mickelson *et al.*, 2003) y sobreexplotación agronómica (Castillejo *et al.*, 2004). Debido a los grandes desequilibrios medioambientales que se están produciendo en la agricultura actual, la Unión Europea (U.E.) ha ido modificando su sistema de ayudas, subvencionando los cultivos que integren medidas agroambientales tales como cubiertas vegetales en olivar, la no quema de rastrojos o el no laboreo, medidas principalmente enfocadas a mantener los residuos de cultivo después de la cosecha (BOJA, 2007). Actualmente, alrededor del 45% de la superficie Andaluza se dedica a la producción agraria intensiva y para poder controlar la implantación de estas medidas agroambientales es necesario un seguimiento preciso de los inventarios y sistemas de cultivo por parte de la U.E. y las administraciones locales. Los sistemas actuales utilizados para el control de cultivos y prácticas agrarias suelen basarse en visitas de los técnicos a una muestra de parcelas escogidas a lo largo del territorio. En algunos países, los métodos de control se basan en la visita de parcelas a lo largo de transectos a partir de las cuales se estiman y extrapolan los sistemas agrarios existentes en un área más amplia (South *et al.*, 2004). En el sur de Europa, los métodos de seguimiento de sistemas agrarios realizados por técnicos de las distintas administraciones consisten en el muestreo y posterior visita a campo de determinadas parcelas seleccionadas. Sin embargo, este procedimiento es costoso, requiere mucho tiempo y ofrece resultados inconsistentes debido a que controla áreas relativamente pequeñas (parcelas seleccionadas) y no obtiene datos de áreas inaccesibles. Por este motivo, la teledetección surge como un conjunto de técnicas que pueden, de forma eficiente, identificar y cartografiar cultivos y sistemas agrarios a lo largo de grandes superficies (South *et al.*, 2004, Peña-Barragán *et al.*, 2008). Estas técnicas pueden abaratar los costes y reducir el tiempo de trabajo obteniendo mejores precisiones en el conocimiento del uso del suelo que las visitas a campo de un limitado número de parcelas. En este caso, la precisión del mapa temático obtenido es extremadamente importante porque este mapa puede ser usado como herramienta administrativa de control y seguimiento para tomar la decisión de Conceder /No Conceder la prestación del cultivo.

### 1.2. Agricultura y teledetección

Actualmente existen distintos estudios orientados al seguimiento de temas agrarios mediante técnicas de teledetección que buscan cartografiar distintos aspectos agronómicos tales como los usos de suelo y los sistemas de cultivo (Oetter *et al.*, 2001; Schmidt *et al.*, 2003; South *et al.*, 2004; Brickleyer *et al.*, 2006), las infestaciones de malas

hierbas en cultivos (Koger *et al.*, 2003; Henry *et al.*, 2004; López-Granados *et al.*, 2006; Peña Barragán *et al.*, 2006; Yu *et al.*, 2006; Peña Barragán *et al.*, 2007), los diferentes estados fenológicos de un cultivo mediante firmas espectrales (Schmidt *et al.*, 2003; Hunt *et al.*, 2004; Koger *et al.*, 2004) o el control del agua de riego (Martín de Santa Olalla *et al.*, 2003; Garatuza-Payan *et al.*, 2005). Satélites de resolución espacial media como Landsat Thematic Mapper y Spot a menudo han demostrado no ofrecer una adecuada precisión para estudios de detalle de vegetación (Harvey y Hill, 2001). Sin embargo, satélites de alta resolución espacial como QuickBird o IKONOS son considerados como una fuente de información muy útil que determina con precisión variables ecológicas, agronómicas y forestales (Chubey *et al.*, 2006; Yang *et al.*, 2006; Mallinis *et al.*, 2008).

### 1.3. Fusión de imágenes

Normalmente, las compañías que distribuyen imágenes de satélite ofrecen a los usuarios dos productos por separado: imágenes pancromáticas monobanda de alta resolución espacial e imágenes multiespectrales de mayor resolución espectral pero de menor resolución espacial. Una alta resolución espectral facilita la discriminación de los distintos tipos de cubiertas, pero la alta resolución espacial es también necesaria para poder delimitar con precisión las distintas áreas ocupadas por cada tipo de suelo, así como para localizar las diferentes características y estructuras del terreno (González-Audicana *et al.*, 2004). La **fusión** de imágenes se ha utilizado ampliamente para proporcionar una única imagen que combine simultáneamente alta información espectral procedente de imágenes multiespectrales o hiperespectrales con alta información espacial procedente de imágenes pancromáticas (Chavez *et al.*, 1991; Robinson *et al.*, 2000). A lo largo de los últimos años se han ido desarrollado un gran número de métodos de fusión. Para que un método de fusión se considere aceptable, éste tiene que garantizar la preservación de la información espectral de la imagen multiespectral al incrementarse la información espacial. Por tanto, un buen método de fusión debe permitir la inyección, en cada una de las bandas de la imagen multiespectral, de información de detalle espacial que no esté presente en la imagen multiespectral procedente de la imagen pancromática (Otazu *et al.*, 2005). Entre los distintos métodos de fusión existentes, algunos autores han demostrado que los métodos basados en funciones *wavelet* ofrecen de forma satisfactoria imágenes de alta resolución espacial manteniendo las propiedades espectrales de la imagen multiespectral original (Núñez *et al.*, 1999; Vijayaraj *et al.*, 2004; Choi *et al.*, 2005; Otazu *et al.*, 2005; Vijayaraj *et al.*, 2006).

### 1.4. Clasificación digital

Existen distintos métodos de **clasificación supervisada y no supervisada** que han sido utilizados en estudios de discriminación de usos de suelo (Thomlinson *et al.*, 1999; Oetter *et al.*, 2001; Sohn y Rebello, 2002; Tran *et al.*, 2003; South *et al.*, 2004; Zambon *et al.*, 2006). La clasificación supervisada es un proceso en el cual se identifican zonas espectralmente parecidas de una imagen a partir de datos controlados por el usuario. Éste define algunos ejemplos de usos de suelo sobre la imagen como zonas de

entrenamiento para que, posteriormente, el algoritmo de clasificación extrapole esas características espectrales a otras áreas de clasificación. Por su parte, la clasificación no supervisada realiza la categorización de la imagen a partir de un proceso basado únicamente en estadísticas de la imagen, sin que exista una intervención directa del usuario en la determinación de las categorías. South *et al.* (2004) resumió la mayoría de las rutinas de clasificación supervisada en tres grupos: las reglas de decisión basadas en distancias, las basadas en probabilidades y las basadas en ángulos. Los clasificadores basados en distancias dependen principalmente de los valores espectrales medios de cada una de las distintas categorías, ignorando la varianza que existe en cada clase. Las rutinas de clasificación basadas en probabilidades incorporan en las reglas de decisión tanto la media de cada una de las categorías de clasificación como la varianza. Finalmente, los clasificadores basados en ángulos crean la regla de decisión a partir de la medida de ángulos espectrales formados entre un valor espectral de referencia y el valor de un píxel sin clasificar. Aunque se conoce el comportamiento general de cada clasificador, a la hora de decidir un algoritmo de asignación no se puede decir que exista una rutina de clasificación ideal. El mejor clasificador dependerá de las necesidades y requerimientos de cada estudio.

### 1.5. Segmentación

Durante mucho tiempo, la mayor parte de estudios de clasificación de usos de suelo se han basado únicamente en los valores de los píxeles. Sin embargo, el aumento de la resolución espacial ha propiciado un aumento de la variabilidad espectral dentro de cada categoría que conlleva, en el caso de análisis basados en píxeles, un aumento en la dificultad de interpretación de los datos y una reducción en la precisión de las clasificaciones. Para superar esta dificultad, podría ser útil agrupar píxeles adyacentes en objetos homogéneos tanto desde un punto de vista espectral como espacial. Estos objetos se crean a partir de un proceso de **segmentación** en el que el algoritmo de unión/crecimiento de los objetos parte de unos píxeles semilla, permitiendo el crecimiento alrededor de ellos sobre la base de ciertos criterios de homogeneidad (Yu *et al.*, 2006). A partir de este proceso, la clasificación ya no se basa en los píxeles individualmente, sino en los objetos como Unidad Mínima de Información (UMI). Esta idea implica realizar una segmentación de la imagen para delinear objetos homogéneos de la misma forma que la visión humana tiende a generalizar la información en zonas homogéneas (Laliberte *et al.*, 2004). Los objetos generados son homogéneos en lo que respecta a las características tanto espaciales como espectrales. Mientras que los análisis de imágenes basados en píxeles utilizan como información sólo la respuesta espectral de cada píxel en cada banda, los análisis basados en objetos obtienen también información adicional derivada de los objetos de la imagen en base a cálculos estadísticos centrados en valores espectrales de los distintos píxeles que forman los objetos, de su posición y de su forma. Por lo tanto, los objetos no son caracterizados por un valor uniforme de reflectancia, sino por una cierta autocorrelación espacial (Lobo, 1997). Esta información espacial se basa en tamaño, forma y contexto de los objetos y puede ser calculada como información relativa de un objeto, sub-objeto o super-objeto en el caso de que se haya creado una jerarquía multinivel de imágenes segmentadas (Chubey *et al.*, 2006). Según

Benz *et al.*, (2004), el enfoque orientado a objetos puede contribuir a análisis automáticos y semi-automáticos muy potentes para la mayoría de las aplicaciones de la teledetección. Esto se debe a que se puede reducir el tiempo de trabajo y favorecer el análisis subjetivo, aumentando la calidad de la información geográfica final, al mismo tiempo que se reducen los costes.

Desde Kettig y Landgrebe (1976), los enfoques basados en objetos casi no se han usado en favor de los más sencillos análisis basados en píxeles. Sin embargo, recientemente, y probablemente debido a la disponibilidad actual de programas de tratamiento de imágenes más potentes, algunas investigaciones han demostrado que las técnicas de segmentación usadas para posteriores clasificaciones reducen la variación local debida a texturas y sombras en clasificaciones agrarias (Ciriza *et al.*, 2009; Maxwell, 2010; Peña-Barragán *et al.*, 2011;), forestales (Bunting *et al.*, 2006; Chubey *et al.*, 2006; Yu *et al.*, 2006), de paisajes (Burnett y Blaschke, 2003; Hay *et al.*, 2003), de humedales y masas de agua (Harken *et al.*, 2005; van der Werff y van der Meer, 2008) y de zonas costeras (Lathrop *et al.*, 2006). Sin embargo, se carece de estudios de clasificación basados en objetos en típicas zonas agrícolas mediterráneas de secano para la discriminación de los sistemas de cultivo y sus principales medidas agroambientales con imágenes de alta resolución espacial.

### 1.6. *Objetivos*

Por tanto, un primer **objetivo** de este estudio fue examinar cinco algoritmos de clasificación supervisada (Paralelepípedos, Mínima Distancia, Distancia de Mahalanobis, *Spectral Angle Mapper* y Máxima Probabilidad) sobre píxeles, objetos y píxeles+objetos como UMI para determinar qué método se ajustaba mejor para la identificación y cartografiado de los sistemas de cultivo y sus principales medidas agroambientales a partir de imágenes QuickBird. Como segundo objetivo se planteó comparar las precisiones de esas rutinas de clasificación y UMI aplicadas a imágenes QuickBird multiespectrales y fusionadas para analizar si un aumento de la resolución espacial mejoraba la fiabilidad de la clasificación.

## 2. Materiales

### 2.1. *Usos de suelo y adquisición de datos*

Se ha elegido como área de estudio una zona agrícola representativa de los cultivos de secano más comunes en Andalucía. El estudio se ha realizado sobre una superficie aproximada de 8271ha (15.3 x 5.7km) localizada cerca de Montilla, en la provincia de Córdoba (Fig. 2.1). Esta zona situada a una altura media de 380m sobre el nivel del mar se caracteriza por presentar un relieve relativamente plano y un clima Mediterráneo continental caracterizado por largos veranos secos e inviernos suaves.

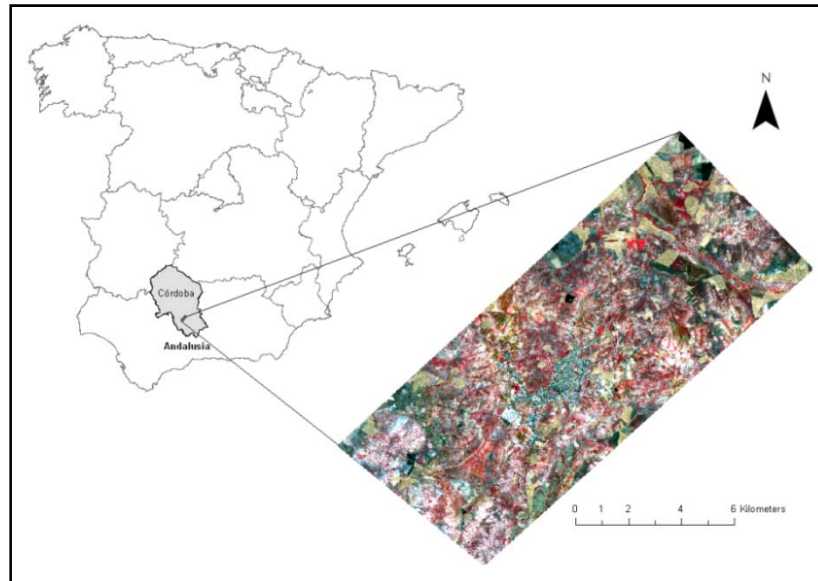


Figura 2.1. Localización del área de estudio en Andalucía.

En la imagen, se analizaron 10 usos del suelo: 1) girasol (*Helianthus annuus* L.), 2) olivar (*Olea europaea* L.), 3) viña (*Vitis vinifera* L.), 4) rastrojo quemado procedente de cultivos (normalmente de cereales de invierno: trigo, *Triticum durum* L.), 5) rastrojo de cereal de invierno, 6) suelo urbano, 7) carreteras, 8) arbolado de ribera que comprende moreras (*Morus alba* L.), eucaliptos (*Eucalyptus globules* Labill) y chopos (*Populus nigra* L.), 9) suelo agrícola desnudo de tonalidades oscuras, y 10) suelo agrícola desnudo de tonalidades claras (Fig.2.2). Los suelos agrícolas desnudos presentaban señales radiométricas tan diferentes que se han tenido que dividir en dos categorías para su mejor identificación.




Figura 2.2. Ejemplo de los principales usos de suelo agrarios en la zona de estudio: a) girasol; b) olivar; c) viña; d) rastrojo quemado; e) rastrojo y f) suelo desnudo.

La zona comprendida en la imagen fue visitada para determinar los usos de suelo *in situ*. La localización de las parcelas verdad terreno de cada uso de suelo fueron definidas de forma aleatoria para ser utilizada tanto en el proceso de clasificación (entrenamiento) como en el de verificación. En total se muestreó una superficie aproximada de 130 ha distribuidas a lo largo de toda la imagen, georreferenciado las parcelas verdad terreno con un GPS TRIMBLE PRO-XRS submétrico diferencial. Treinta hectáreas de la superficie muestreada fueron utilizadas para analizar la firma espectral de los usos de suelo en la fase de entrenamiento de la clasificación. Por su parte, las 100 ha restantes se utilizaron para determinar la precisión de la clasificación.

### 2.2 Imágenes de satélite y pre-procesado

El satélite QuickBird adquirió la imagen digital utilizada para el estudio el 10 de julio de 2004. El conjunto de datos consistió en una banda única pancromática de 0.7 m de resolución espacial y 4 bandas multiespectrales de 2.8 m de resolución espacial que recogieron información del espectro electromagnético en las bandas azul (A: 450 a 520nm), verde (V: 520 a 600nm), rojo (R: 630 a 690nm) e infrarrojo (IRc: 760 a 900nm). La resolución radiométrica de la imagen era de 8 bit. Puesto que este trabajo tuvo como objetivo caracterizar unos usos de suelo respecto a otros en una determinada imagen de forma relativa, no fue necesario realizar más correcciones que las que ya se habían realizado al adquirir dicha imagen (Robinove, 1981; Duggin and Robinove, 1990; Song et al., 2001).

## 3. Metodología

### 3.1. Fusión (*pansharpen*)

Con objeto de obtener una imagen de alta resolución espectral y espacial para este estudio, se realizó una fusión de las imágenes pancromática y multiespectral utilizando el método AWLP (*Proportional Additive Wavelet on the Lightness component*) (Otazu et al., 2005), una generalización del método AWL (*Additive Wavelet on the Lightness component*) descrito previamente por Núñez et al. (1999). Este método de fusión basado en técnicas *wavelet* preserva la información espectral de la imagen multiespectral original al inyectar, en cada una de las bandas de baja resolución espacial, el detalle espacial de la imagen pancromática. Las funciones *wavelet* permiten dividir o descomponer datos o funciones en componentes de distinta frecuencia y estudiar cada componente a una resolución acorde con su escala (Graps, 1995). En el caso de aplicarlas sobre una imagen, estas funciones permiten realizar análisis a diferentes resoluciones espaciales. Según Mallat (1989), el detalle de una imagen (componentes de alta frecuencia) caracteriza distintas estructuras de la escena en función de la resolución de ésta. Así, en el caso de trabajar con resoluciones groseras, el detalle corresponde a estructuras o elementos de mayor tamaño, mientras que con resoluciones finas, el detalle muestra estructuras de menor tamaño. El análisis multiresolución con transformadas *wavelet* permite extraer el detalle espacial que se pierde al pasar de una resolución espacial a otra menor.



Una aproximación discreta de la transformación wavelet puede realizarse a partir del algoritmo “à trous” (Holschneider y Tchamitchian, 1990; Starck y Murtagh, 1994), el cual descompone las imágenes en componentes de alta frecuencia (detalle espacial) y de baja frecuencia mediante la aplicación de determinados filtros. De esta forma, si sobre una imagen inicial de resolución  $2^j$  se le aplica un filtro bidimensional de paso bajo asociado a una función de escala, se pueden obtener imágenes de aproximación con el mismo número de filas y columnas pero cuya resolución sea  $2^{j-1}$ ,  $2^{j-2}$ ,... En este proceso se pierde detalle espacial, por lo que la diferencia entre una imagen y su imagen degradada (ej. imagen resolución  $2^j$  - imagen resolución  $2^{j-1}$ ) generará la imagen de detalle resultante, denominada “plano *wavelet*” o “coeficiente *wavelet*”. Los dos primeros planos *wavelets* de la imagen pancromática de alta resolución han sido los añadidos a la imagen multiespectral. Como resultado de este proceso de fusión se obtuvieron 4 bandas multiespectrales con una resolución espacial de 0.7 m (Fig. 2.3).

Para determinar la calidad global de la imagen fusionada obtenida se calculó el índice ERGAS (*Erreur Relative Globale Adimensionnelle de Synthèse*) espectral, el cual compara la variaciones espectrales observadas entre la nueva imagen y la imagen multiespectral original. El valor del índice obtenido fue de 2.107. Cuanto menor sea el valor ERGAS obtenido, mayor será la calidad espectral de la imagen fusionada. Una imagen fusionada de buena calidad debe presentar un valor ERGAS espectral menor de 3 (Wald, 2002). Todos los procesos necesarios para la fusión de la imagen se realizaron con el software de procesamiento de imagen ENVI 4.3 (Research Systems Inc. 2006), mientras que el índice ERGAS espectral se calculó con la hoja de cálculo Excel 2007 (Microsoft® Office Excel® 2007).

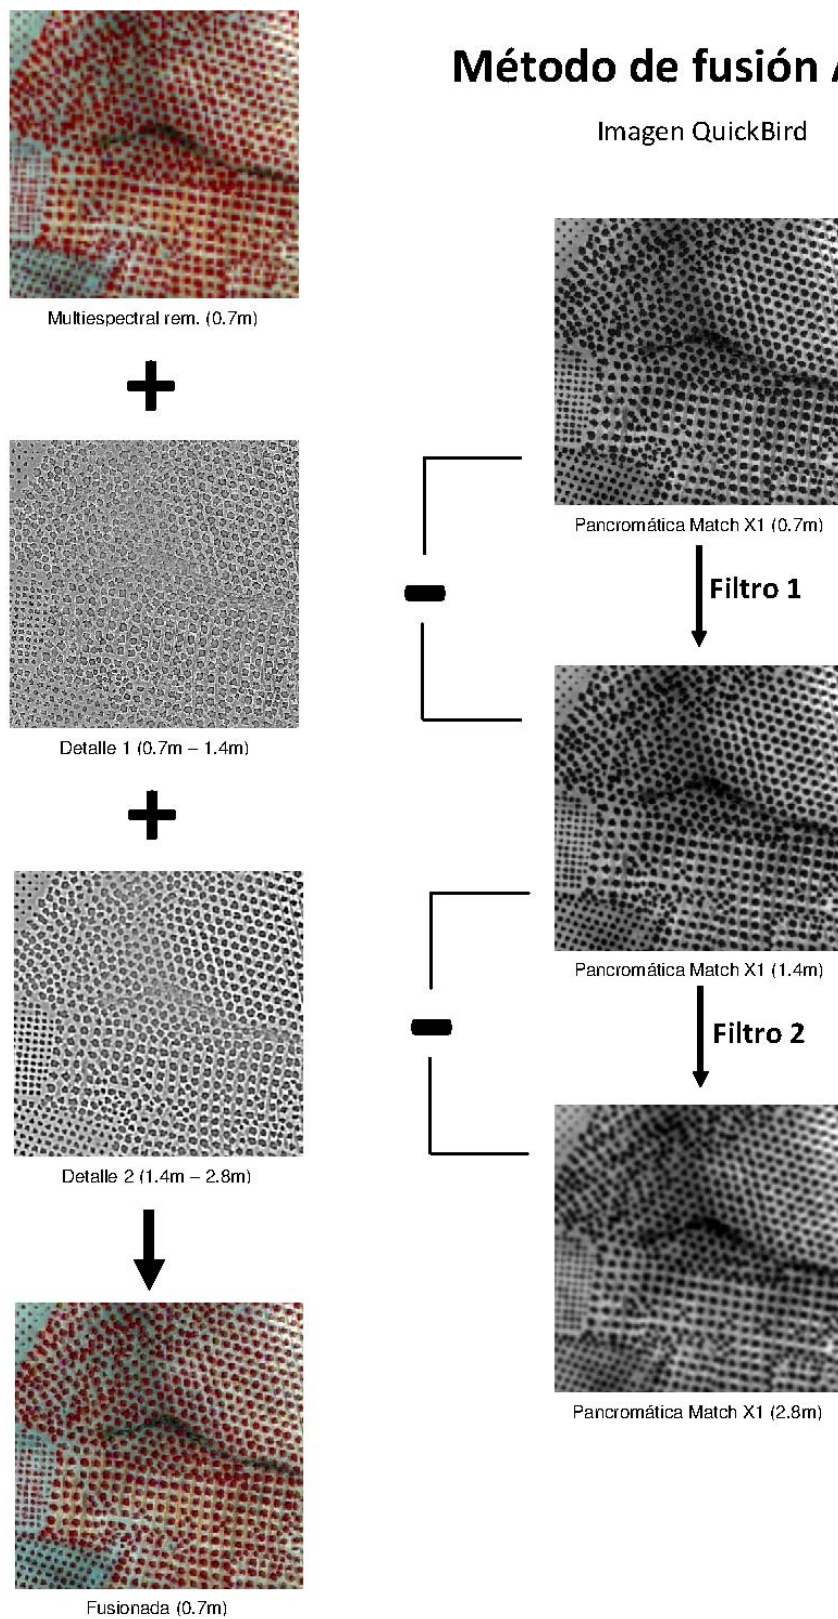


Figura 2.3. Esquema metodológico del proceso de fusión (*pansharpen*) AWLP.

### 3.2. Segmentación

Con el software Definiens Developer 7 (Definiens AG 2007) se dividió la imagen QuickBird en objetos utilizando el algoritmo de segmentación *Fractal Net Evolution Approach* (FNEA) (Benz et al., 2004). La segmentación subdivide una imagen en regiones compuestas por varios píxeles que se caracterizan por ser homogéneas en base a unos requisitos definidos por el usuario. Éste puede influir en el resultado del proceso de segmentación ponderando los datos de entrada y controlando determinados parámetros para la formación de los objetos de la imagen resultante tales como el factor de escala (control de tamaño de los objetos), color (grado de influencia de la información espectral en la segmentación) y forma (grado de influencia de la forma -suavidad y compacidad- de los objetos).

Los ajustes de los parámetros de segmentación se determinaron a partir del ensayo de diferentes escenarios con distintos parámetros de entrada. Mediante la evaluación de la capacidad de discriminar elementos agrícolas significativos se determinó la configuración de parámetros para la segmentación. Este proceso se realizó en base a clasificaciones y validaciones con el clasificador Máxima Probabilidad. Puesto que la combinación de estos parámetros de segmentación da lugar a un número muy elevado de escenarios posibles, se procedió a simplificar el número de escenarios a estudiar analizando los parámetros por grupos. En primer lugar se obtuvo un factor de escala genérico que consiguió delimitar regiones suficientemente homogéneas para clasificar los usos de suelo de la imagen con precisión. A partir de este factor de escala, se evaluaron cada uno de los parámetros: color, forma, suavidad y compacidad, de forma independiente para definir los mejores datos para la clasificación. En primer lugar se realizó un estudio de las variaciones de los parámetros suavidad y compacidad, ambos integrados en el parámetro forma. Tras los análisis se observó que la variación de estos parámetros no ofrecía diferencias significativas de precisión en las clasificaciones, por lo que se dejó su valor repartido en partes iguales (compacidad 50%, suavidad 50%) (Fig. 2.4).

Partiendo de esta base, a continuación se evaluaron los efectos que producían las variaciones de los parámetros color y forma en las fiabilidades de las clasificaciones, obteniéndose que el valor espectral (color) era más importante para esta segmentación que la forma de los objetos (forma), al crear un número menor de objetos más ajustados a la realidad (Fig. 2.5). Finalmente, y con los parámetros color y forma definidos, se procedió a evaluar variaciones en el factor de escala hasta obtener el que mejor clasificación ofreció (Fig. 2.6). Tras evaluar este conjunto de parámetros de entrada, finalmente los valores utilizados en los análisis llevados a cabo en las imágenes multiespectral y fusionada fueron 50 para el parámetro de escala, 0.8 para el de color, 0.2 para el de forma y 0.5 tanto para definir la suavidad como la compacidad. Estos parámetros medios representaron la combinación más satisfactoria de todas las evaluadas para la segmentación de ambas imágenes, aunque crearon objetos muy diferentes en ambas debido a las diferentes características espaciales y espectrales de éstas. Junto a estos parámetros, la segmentación también estuvo asistida por la capa vectorial del parcelario de Catastro, la cual proporcionó información muy útil del límite de las parcelas que facilitó la creación de los

objetos en base a esos límites (Fig. 2.6c). A partir de un determinado factor de escala, la formación de los objetos está totalmente definida por el parcelario y no por los parámetros de segmentación.




Figura 2.4. Resultado de la segmentación al variar los parámetros compacidad y suavidad: a) compacidad=1 y suavidad=0; b) compacidad=0.5 y suavidad=0.5 y c) compacidad=0 y suavidad=1.




Figura 2.5. Resultado de la segmentación al variar los parámetros color y forma: a) color=0.9 y forma=0.1; b) color=0.5 y forma=0.5 y c) color=0.1 y forma=0.9.



Figura 2.6. Resultado de la segmentación al variar el parámetro factor de escala: a) factor de escala=10; b) factor de escala=30 y c) factor de escala=50.

De la gran cantidad de información que se genera en el proceso de segmentación, en este estudio sólo se utilizaron dos tipos de datos: espectrales y texturales (Tabla 2.1). Para describir los objetos de la imagen a partir de la información derivada de sus propiedades espectrales, se analizó el valor espectral medio de cada objeto en cada banda. Para detectar el contraste espacial entre los píxeles que componen cada objeto se analizaron 3 parámetros texturales: homogeneidad, entropía y contraste. La homogeneidad y el contraste muestran información sobre la variación local entre píxeles. Los valores de homogeneidad serán más altos cuanto mayores sean los valores de la diagonal central de la matriz de concurrencia. Por el contrario, los valores de contraste presentarán valores más altos cuanto mayores sean los valores de las diagonales más alejadas de la diagonal central en la matriz. La entropía muestra información sobre la semejanza en los valores de la imagen y mostrará valores más altos cuanto más se parezcan entre sí los valores de la matriz de concurrencia.

Tabla 2.1- Variables basadas en objetos.

Categorías	Descripción	
<i>Espectrales</i>	Media	$\frac{1}{\# P_v} \sum_{(x,y) \in P_v} c_k(i, j)$
<i>Texturales</i>	Homogeneidad	$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2}$
	Contraste	$\sum_{i,j=0}^{N-1} P_{i,j} (i-j)^2$
	Entropía	$\sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j})$

#P<sub>v</sub>: número total de píxeles contenidos en un objeto de la imagen v, c<sub>k</sub>(i,j): valor de la imagen en el píxel (i,j) en la banda k, i: número de fila, j: número de columna, N: números de filas y columnas, P<sub>i,j</sub>: valor normalizado del píxel.

Esta información textural se calculó a partir de la matriz de concurrencia de Haralick. Esta matriz es una tabulación que representa la frecuencia con la que se producen diferentes combinaciones de niveles de grises, es decir, frecuencia con la que ND<sub>i</sub> es contiguo a ND<sub>j</sub>, a lo largo de la imagen (*Definiens*, 2007). Existen diferentes matrices de concurrencia en función de la dirección considerada para el análisis de vecindad: 0°, 45°, 90° y 135° (Fig.2.7). El software de segmentación *Definiens Developer 7* también permite calcular la textura teniendo en cuenta todas las direcciones. La determinación de la dirección más apropiada de cada variable textural para las clasificaciones se decidió en base al comportamiento de éstas con los distintos métodos de clasificación. Esta evaluación se realizó en base a ensayos de la capacidad de discriminación de los distintos usos de suelo con las diferentes variables texturales obtenidas en cada dirección con distintos métodos de clasificación.




Figura 2.7. Direcciones consideradas en el análisis de vecindad para la obtención de variables texturales.

El valor espectral medio de cada objeto se utilizó como parámetro básico de clasificación. En primer lugar, se llevaron a cabo diferentes clasificaciones utilizando únicamente la media espectral de cada objeto para, a continuación, añadirle todas las posibles combinaciones entre el valor medio espectral y los restantes parámetros; es decir, todas las clasificaciones se basaron en una combinación entre los valores medios espectrales y el resto de parámetros texturales. En conclusión, para cada una de las 4 bandas de la imagen multispectral original o de la imagen fusionada (B, G, R, NIR) se obtuvieron 4 variables basadas en objetos (media espectral, homogeneidad, entropía y contraste) (Fig.2.8), resultando 16 bandas para la imagen multispectral y 16 bandas para la imagen fusionada.




Figura 2.8. Variables utilizadas en el estudio calculadas a partir de la banda azul: a) media espectral; b) homogeneidad; c) entropía y d) contraste.

### 3.3. Clasificación y precisión

Para analizar el comportamiento de esta información en el proceso de clasificación se seleccionaron 5 métodos de clasificación supervisada: **Paralelepípedos (P)**, **Mínima Distancia (MD)**, **Distancia de Mahalanobis (DMa)**, **Máxima Probabilidad (MP)** y **Spectral Angle Mapper (SAM)**. La elección de estos algoritmos se basó en que todos se caracterizan por estar implementados en la mayoría de los software de tratamiento de imágenes a la vez que presentan un coste computacional medio-bajo. Los tres primeros métodos, P, MD y DMa son clasificadores basados en distancias espectrales. Mientras que el método P se caracteriza por crear un área de dominio para cada categoría en base a los valores de centralidad y dispersión del entrenamiento, los métodos MD y DMa determinan la asignación de cada píxel a una categoría en base a una medida de similitud espectral basada en el cálculo de la distancia espectral, distancia euclidiana para MD y distancia de Mahalanobis para DMa. El método MP presenta un clasificador basado en probabilidades que define una función de probabilidad para cada categoría en función de la media y la matriz de varianza-covarianza, asignando cada píxel a la categoría cuya probabilidad sea mayor. Finalmente, el clasificador SAM se engloba dentro del grupo de clasificadores basados en ángulos espectrales, el cual asigna cada píxel a una determinada categoría en función del ángulo formado (similaridad espectral) entre el píxel a clasificar y un píxel de referencia para cada una de las bandas que intervienen en la clasificación.

Las imágenes QuickBird multiespectral y fusionada fueron clasificadas aplicando independientemente cada una de las reglas de decisión anteriores sobre los píxeles, los objetos y los píxeles+objetos como UMI. Para el análisis basado en píxeles de la imagen multiespectral y de la imagen fusionada se utilizaron las 4 bandas (B, G, R, NIR) correspondientes de cada imagen (Fig. 2.9a y 2.9c). En el análisis basado en objetos, la clasificación de la imagen multiespectral y fusionada se realizó a partir de las 16 bandas descritas anteriormente (Fig. 2.9b y 2.9d). Finalmente, en el análisis basado en píxeles +objetos se unieron las 16 bandas segmentadas con las 4 bandas multiespectrales o fusionadas quedando, por tanto, 20 bandas para ser analizadas en la clasificación de la imagen multiespectral o de la fusionada.

La precisión de las clasificaciones se obtuvo a partir del cálculo de la matriz de confusión de cada una de ellas y el análisis de éstas. Dicho análisis se basó principalmente en la Fiabilidad global (FG) de la clasificación, la cual indica el porcentaje total de píxeles clasificados correctamente en la imagen, Fiabilidad del Productor (FP), que muestra la probabilidad de que un píxel clasificado represente esa categoría en la realidad y la Fiabilidad del Usuario (FU), que indica la probabilidad de clasificar algún píxel en una categoría diferente a la real (Rogan *et al.*, 2002). Además también se calculó el coeficiente Kappa (K) que permitió determinar si los resultados en la matriz de confusión eran significativamente mejores que los producidos en una clasificación realizada al azar (Congalton, 1991).

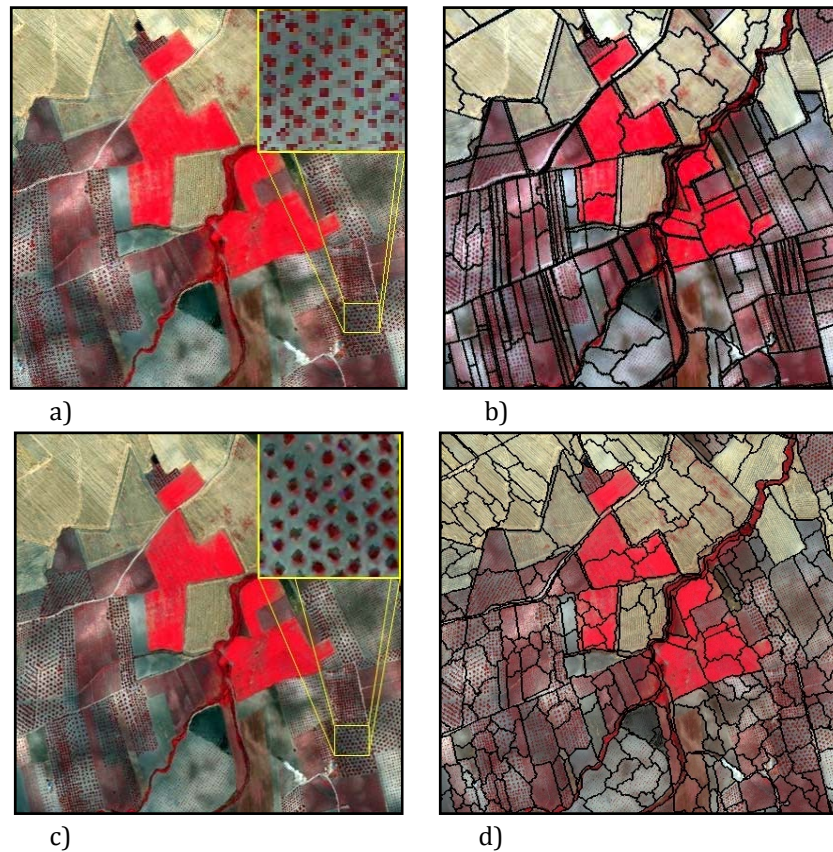


Figura 2.9. Imagen QuickBird (pixel): a) Multiespectral y c) Fusionada. Segmentación en objetos: Imagen b) Multiespectral y d) Fusionada.

El proceso de verificación fue idéntico en cada una de las clasificaciones. En las clasificaciones basadas en píxeles, para evaluar la precisión de la clasificación se realizó un análisis estadístico a partir de la respuesta espectral de todos los píxeles de la imagen que formaban las áreas de validación. Por otro lado, teniendo en cuenta que cada uno de los objetos de la imagen segmentada se compone de píxeles con un mismo valor definido por el parámetro estudiado en dicho objeto, el proceso de verificación se basó en la respuesta espectral de los mismos píxeles de las áreas de validación que se encontraron repartidos por los distintos objetos creados en la segmentación.

En teledetección, el ruido denominado sal y pimienta se refiere a situaciones en las que píxeles aislados y, en muchos casos erróneamente clasificados, se encuentran dispersos dentro de otra categoría de clasificación. En satélites de alta resolución espacial, estos errores en la clasificación pueden ser considerables. Para mejorar los mapas de clasificación reduciendo este ruido mediante la generalización de la imagen y, por tanto, obtener mejores precisiones, se aplicó sobre cada clasificación obtenida un filtro de mayoría de tamaño 5x5 (Fig. 2.10). El software utilizado para este procesado de la imagen fue ENVI 4.3 (Research Systems Inc. 2006).



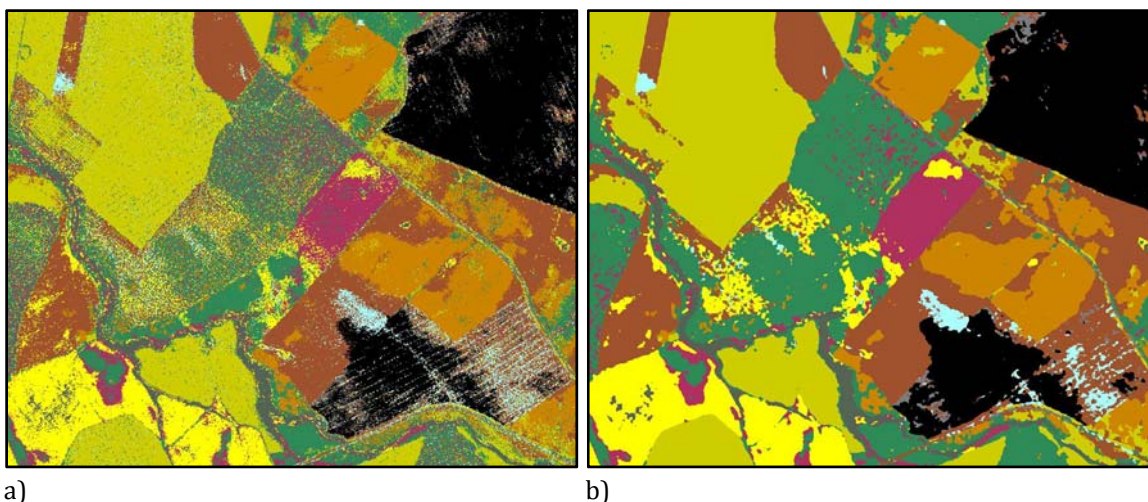


Figura 2.10. Resultado de la clasificación basada en píxel con el método de Máxima Probabilidad de la imagen multiespectral: a) sin filtro de mayoría; b) con filtro de mayoría.

## 4. Resultados

La determinación del factor de escala más apropiado para la segmentación de la imagen multiespectral y fusionada se realizó mediante la clasificación y evaluación de distintos escenarios en los que se mantuvieron estables todos los parámetros excepto el factor de escala. La Tabla 2.2 resume los valores de FG obtenidos para ambas imágenes al analizar variaciones del factor de escala cada 10 unidades.

Tabla 2.2- Fiabilidad Global (%) obtenida de la clasificación de la imagen multiespectral y fusionada con parámetros de escala de 40-100.

	Parámetro de escala						
	40	50	60	70	80	90	100
<i>Tipo de imagen</i>							
Multiespectral	88.52	89.56	88.90	88.87	86.70	86.31	86.07
Fusionada	74.97	84.39	79.94	77.76	5.61	5.61	5.61

Como puede observarse en la tabla, el comportamiento de la segmentación en las dos imágenes es muy diferente. La imagen multiespectral presentó un crecimiento de los objetos muy estable y poco marcado que se deduce de la poca variación en la FG de las distintas clasificaciones evaluadas, un 3.5% entre la mejor y la peor. Sin embargo, los mismos parámetros de segmentación sobre la imagen fusionada produjeron un resultado muy diferente, con objetos muy poco parecidos a las divisiones agrícolas a partir del factor de escala 80.

El valor de factor de escala que mejor resultado presentó en ambas imágenes fue 50 con un 89.56% de FG para la imagen multiespectral y un 84.39% para la fusionada. Para afinar más la segmentación se procedió a probar nuevos escenarios de segmentación en los que el valor de escala estuviera alrededor del valor 50, evaluando el intervalo de factor de escala entre 45 y 55 (Tabla 2.3).

Tabla 2.3- Fiabilidad Global (%) obtenida de la clasificación de la imagen multiespectral y fusionada con parámetros de escala de 45-55.

	Parámetro de escala						
	40	50	60	70	80	90	100
<i>Tipo de imagen</i>							
Multiespectral	88.52	89.56	88.90	88.87	86.70	86.31	86.07
Fusionada	74.97	84.39	79.94	77.76	5.61	5.61	5.61

Los resultados de fiabilidad de la tabla 2.3 muestran como variaciones pequeñas en el factor de escala de la segmentación no proporcionaron grandes variaciones en la formación de los objetos, aunque esta variación fue más importante al aumentar la resolución espacial de la imagen. La imagen multiespectral obtuvo los objetos más ajustados a las necesidades del estudio con el factor de escala 51, que presentó un 90.23% de FG, mientras que en la fusionada fue con el factor de escala 50 el más preciso con un 84.71% de FG.

Tras la elección de los parámetros de segmentación y la creación de los objetos se obtuvieron 4 variables basadas en dichos objetos: media, homogeneidad, contraste y entropía para cada una de las bandas. Las variables texturales se calcularon teniendo en cuenta distintas direcciones. La determinación de la dirección óptima para el análisis se realizó a partir de las precisiones en las clasificaciones de cada variable en cada dirección obtenidas con cada método de clasificación. La Tabla 2.4 muestra los valores de FG obtenidos por cada variable calculada en una dirección con los distintos métodos de clasificación. La Figura 2.11 representa dichos valores en un gráfico para analizar más fácilmente la direccionalidad predominante de cada variable textural con cada método de clasificación.

Tabla 2.4- Fiabilidad Global (%) obtenida de la clasificación de las variables texturales obtenidas en distintas direcciones.

Método	Variables texturales	Direcciones texturales				
		All	0°	45°	90°	135°
<i>Paralelepípedos</i>	Homogeneidad	42.13	39.42	38.42	32.40	35.60
	Entropía	42.45	32.62	39.13	38.06	41.51
	Contraste	36.35	32.1	35.58	32.54	31.15
<i>Mínima Distancia</i>	Homogeneidad	64.96	62.37	66.30	59.91	63.80
	Entropía	57.69	59.77	55.77	57.55	58.31
	Contraste	60.72	51.26	59.23	50.97	51.02
<i>Distancia de Mahalanobis</i>	Homogeneidad	77.88	75.08	71.33	75.57	77.75
	Entropía	76.96	73.34	70.94	69.36	70.70
	Contraste	63.60	63.20	62.48	61.07	66.79
<i>Máxima Probabilidad</i>	Homogeneidad	81.50	80.13	81.19	80.44	80.51
	Entropía	80.07	78.03	80.13	77.60	79.68
	Contraste	71.10	72.98	73.70	69.10	72.09
<i>Spectral Angle Mapper</i>	Homogeneidad	63.82	62.50	66.51	61.24	50.38
	Entropía	52.79	50.22	53.06	52.46	52.70
	Contraste	54.48	46.57	52.26	52.66	48.39

Como muestra la Tabla 2.4, el comportamiento de las variables texturales calculadas en distintas direcciones es diferente en función del método de clasificación analizado. Esta información queda plasmada gráficamente con la Figura 2.11, donde se representan las precisiones de las clasificaciones realizadas sobre cada variable textural calculada en distintas direcciones y con distintos clasificadores. En ella se puede observar que no existe ningún patrón especial que indique que una dirección es más adecuada para una variable textural que otra. Así, mientras que al clasificar las variables con el método P se observa que todas direcciones (All) es la mejor opción para las tres variables texturales analizadas, con los clasificadores MD, DMA, MP y SAM no existe una direccionalidad clara. Con estos clasificadores, el cálculo de las variables en todas direcciones es el que mejores valores presenta para la homogeneidad con los clasificadores DMA y MP, Entropía con MP y correlación con MD y SAM. Algo parecido le ocurre a la dirección 45°, que ofrece muy buenos resultados para homogeneidad clasificada con MD y SAM, entropía con MP y SAM, y correlación con MP. Sólo la dirección 135° presentó los valores más altos con la correlación clasificada con DMA.

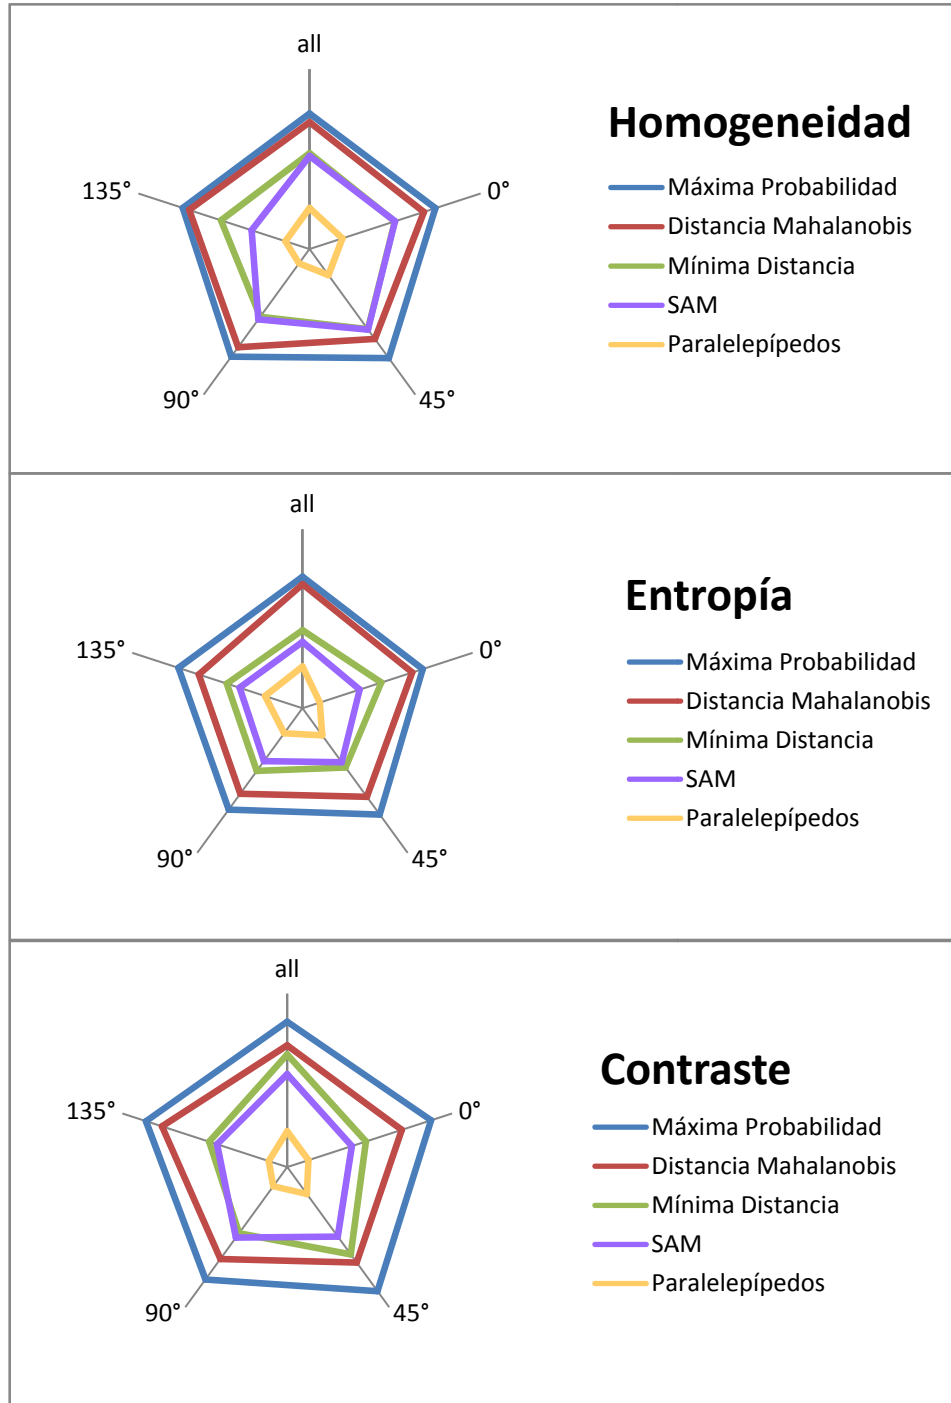


Figura 2.11. Gráfico de Fiabilidad Global de las variables texturales clasificadas según su dirección con distintos algoritmos de clasificación.

Tras la elección de la dirección más adecuada para cada variable, se procedió a clasificar la imagen multispectral y fusionada para obtener los usos de suelo y sus medias agroambientales. La tabla 2.5 resume los mejores resultados de clasificación, valores de Fiabilidad Global (FG) e índice Kappa (K) con el filtro de mayoría aplicado para cada método de clasificación y UMI, tanto para la imagen multispectral como para la fusionada. Como se puede observar claramente, los mejores resultados se obtuvieron en las clasificaciones basadas en objetos y en píxeles+objetos. La Figura 2.12 muestra detalles de

las clasificaciones más desfavorables y de las más favorables, mostrando las precisiones más bajas (a, b, c, d, e) y las más altas (a', b', c', d', e') de las clasificaciones de usos de suelo realizadas. La Tabla 2.5 muestra diferencias importantes en la precisión de las clasificaciones entre los distintos métodos de clasificación. La diferencia de precisión más marcada se observó en la clasificación basada en píxeles+objetos de la imagen QuickBird fusionada, donde se observaron los valores de FG y K más bajos con el método P, 37.70% y 0.31, y los valores más altos con el método MP, 94.5% y 0.94, observándose más de un 56% de FG de diferencia entre ellos (Figs. 2.12a y 2.12e'). En general se puede observar que los mejores valores de FG y K se obtuvieron al evaluar la mayoría de los clasificadores con la imagen multiespectral (Figs. 2.12a', 2.12b', 2.12c', 2.12d'), excepto en el caso del clasificador MP (Fig. 2.12e'), que obtuvo su máxima precisión con la imagen fusionada.

Tabla 2.5- Resumen de los resultados más precisos de las clasificaciones realizadas con el filtro de mayoría aplicado.

	Paralelepípedos		Mínima Distancia		Distancia de Mahalanobis		Spectral Angle Mapper		Máxima Probabilidad	
	FG <sup>(2)</sup>	K	FG	K	FG	K	FG	K	FG	K
<i>Imagen multiespectral</i>										
Píxel	46.89	0.39	59.21	0.54	72.31	0.69	61.85	0.56	89.60	0.88
Objetos	69.90	0.66	86.68	0.85	89.99	0.88	89.00	0.87	90.66	0.89
Píxel+objetos	73.52	0.70	89.71	0.88	91.55	0.90	89.55	0.88	91.71	0.90
<i>Imagen fusionada</i>										
Píxel	37.70	0.31	51.71	0.45	64.77	0.60	58.52	0.53	82.55	0.80
Objetos	66.11	0.62	77.79	0.74	88.29	0.86	78.12	0.75	93.69	0.93
Píxel+objetos	66.71	0.62	78.75	0.75	88.02	0.86	82.26	0.79	94.51	0.94

(1) Métodos de clasificación: P: Paralelepípedos, MD: Mínima Distancia, DMA: Distancia de Mahalanobis, SAM: Spectral Angle Mapper, MP: Máxima Probabilidad.

(2) Valores de precisión: FG: Fiabilidad Global (%), K: coeficiente Kappa.

Los análisis basados en objetos mostraron mejores resultados en la clasificación de usos de suelo que los basados en píxeles. Analizando la clasificación de la imagen multiespectral basada en objetos, cuatro de los cinco algoritmos de clasificación consiguieron valores de FG superiores al 85% con la imagen multiespectral. Para los clasificadores MD, SAM, DMA y MP se obtuvieron valores del 86.68%, 89.00%, 89.99% y 90.66%, respectivamente y valores de K superiores al 0.85 en todos los casos. Sin embargo, la clasificación basada en objetos con la imagen fusionada arrojó peores resultados que la misma clasificación de la imagen multiespectral con los clasificadores P, MD, DMA y SAM. Sólo el clasificador MP mostró mejores precisiones en la imagen fusionada que en la multiespectral, con valores de FG del 93.69% y 90.66%, y valores de K de 0.93 y 0.89, respectivamente.

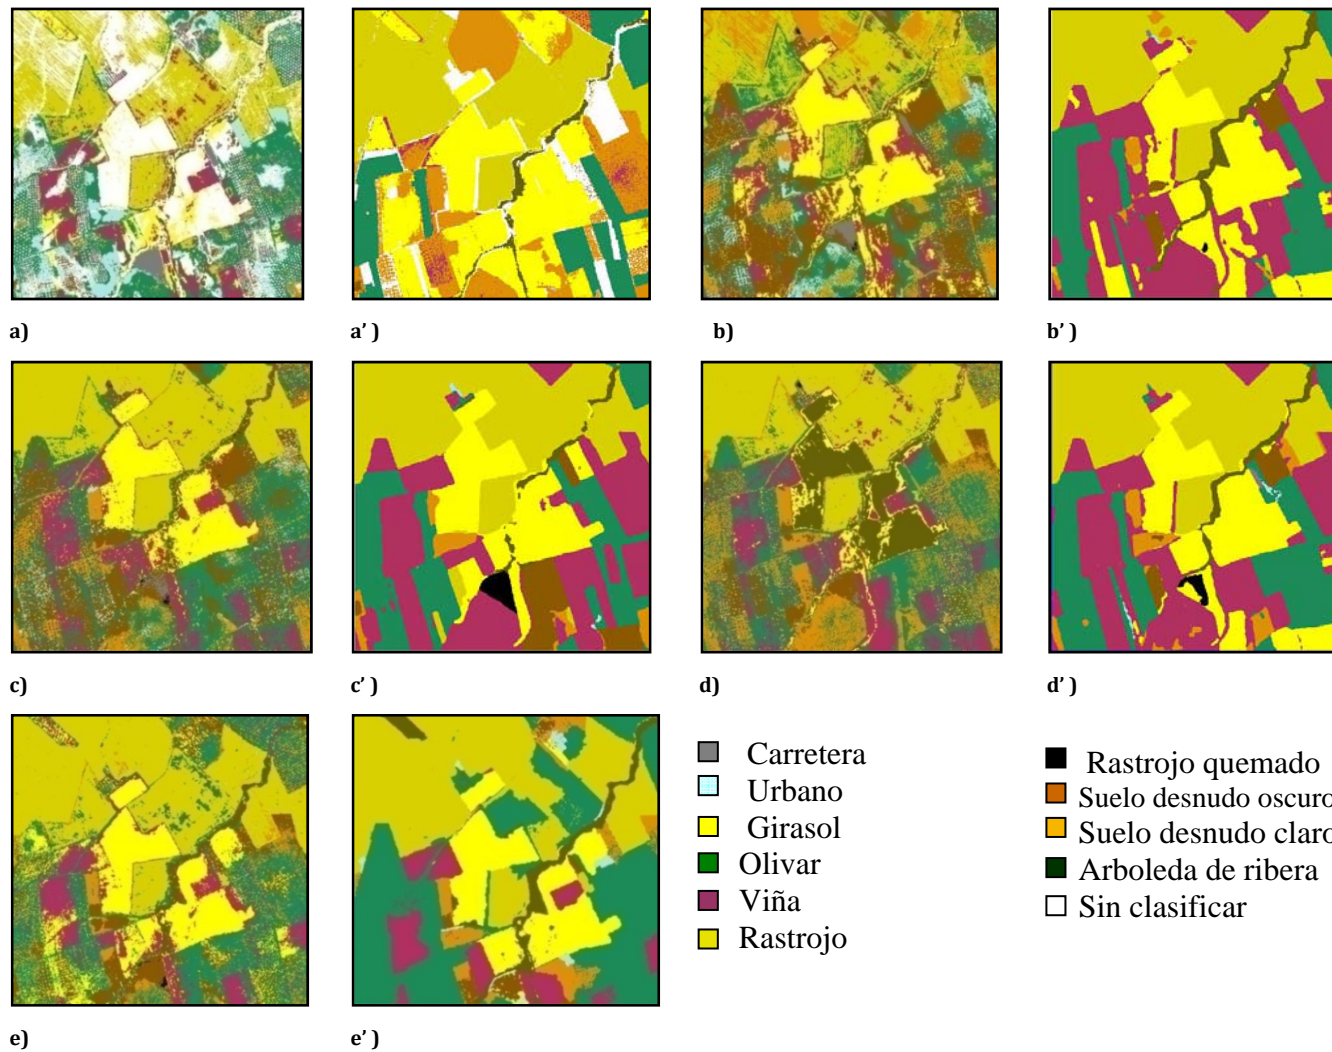


Figura 2.12. Resultados de las clasificaciones peores (a, b, c, d, e) y mejores (a', b', c', d', e'); a) P\*, b) MD\*, c) DMA\*, d) SAM\*, e) MP\* para la imagen fusionada y píxel como MIU; a') P, b') MD, c') DMA, d') SAM para la imagen multispectral y píxel+object como UMI; e') MP para la imagen fusionada y píxel+object como UMI. P\*: Paralelepípedos; MD\*: Mínima Distancia; MC\*: Distancia de Mahalanobis; SAM\*: Spectral Angle Mapper; ML\*: Máxima Probabilidad.

La clasificación de la imagen multiespectral de píxeles+objeto como UMI mostró precisiones muy altas en los clasificadores MD, SAM, DMA y MP con valores de FG del 89.71%, 89.52%, 91.55 y 91.71%, respectivamente. En estas clasificaciones, el valor de K fue siempre superior a 0.88. Al igual que en el caso de los objetos, los valores de clasificación fueron más bajos con la imagen fusionada respecto a las clasificaciones con la imagen multiespectral, excepto en la clasificación ML donde se obtuvieron los valores más altos de todas las clasificaciones realizadas con una FG de 94.51% y un K de 0.94 (Fig. 2.12e').

La Tabla 2.6 resume la Fiabilidad del Productor (FP) obtenida para cada uso del suelo en las distintas clasificaciones realizadas al evaluar los diferentes algoritmos de clasificación y las diferentes UMI. Los valores de FP varían considerablemente en función de la categoría clasificada. Un análisis general de los resultados de las clasificaciones teniendo en cuenta los usos de suelo individualmente muestra que las categorías mixtas (ej, *olivar*, *viña*, *suelo urbano o suelos desnudos claros y oscuros*) presentaron una alta variabilidad espectral en la misma clase y un valor muy bajo de FP (especialmente en las clasificaciones basadas en píxeles con imágenes fusionadas), en comparación con las categorías homogéneas que mostraron valores más altos de FP en cualquiera de las clasificaciones y UMI consideradas. Una de las mayores diferencias en FP se observó en el uso del suelo del *olivar*. La categoría *olivar* mostró valores de FP mayores del 92% en todas las clasificaciones basadas tanto en píxeles como en objetos de la imagen multiespectral. Sin embargo, los valores más altos de FP en *olivar* (superiores al 99.45%) se obtuvieron para los clasificadores DMA y MP aplicados en la imagen fusionada.

Como contraste, las categorías *arbolado de ribera* y *carreteras*, las cuales suelen presentar una variabilidad espectral menor, mostraron valores de FP mayores para todas las clasificaciones basadas en píxeles de la imagen multiespectral, excepto la categoría *arbolado de ribera* clasificada con el método MP, la cual obtuvo su mayor FP en las clasificaciones basadas en objetos. La discriminación de la clase *rastrojo quemado* tuvo mucho éxito en la clasificación de la imagen multiespectral con el método DMA teniendo en cuenta cualquier UMI, obteniéndose valores de FP de 99.96%, 98.38% y 98.49% en las clasificaciones basadas en píxeles, en objetos y píxeles+objetos respectivamente. Del mismo modo, la discriminación del *rastrojo* de cereal de invierno fue muy exacta con valores de FP superiores al 99.29% que llegaron incluso al 100% al clasificar la imagen multiespectral con los algoritmos MP o DMA en cualquiera de las UMI consideradas. Al comparar los resultados de los análisis basados en píxeles y los basados en objetos, no se observó una tendencia clara. Por ejemplo, la clasificación basada en objetos con el método MP de la imagen multiespectral mostró mejor FP en la categoría *viña* que la misma clasificación basada en píxeles (83.87% y 69.64%, respectivamente). Por el contrario, en la categoría de *suelo desnudo claro*, la FP mostró valores alrededor del 89% con ambas UMI y, en la categoría *carretera*, los valores de FP fueron mayores en la clasificación basada en píxeles que en la basada en objetos (78.01% y 45.31%, respectivamente).

Tabla 2.6- Fiabilidad del Productor (%) de los cinco métodos de clasificación.

Método <sup>(1)</sup>	Imagen + UMI <sup>(2)</sup>	Usos del suelo									
		Árboles Ribera	Carretera	Rastrojo	Viña	Olivar	Suelo urbano	Girasol	Rastrojo Quemado	Suelo des. oscuro	Suelo des. claro
P	M+P	81.44	92.28	95.56	71.59	25.68	49.54	28.92	78.43	0.00	0.00
	F+P	32.42	84.61	70.37	56.87	28.64	48.72	26.80	40.63	4.58	6.17
	M+O	73.22	82.31	86.26	2.70	94.45	30.35	97.91	85.91	14.79	87.55
	F+O	46.77	75.64	79.92	62.96	62.11	52.17	73.54	56.36	87.45	61.42
	M+PO	75.93	60.87	88.93	14.18	94.22	81.16	95.71	85.73	20.21	77.57
	F+PO	43.10	85.37	85.44	66.84	58.77	52.06	71.04	53.77	84.35	66.47
MD	M+P	86.03	86.11	73.46	49.64	28.20	45.20	70.21	90.66	58.41	93.38
	F+P	78.10	50.85	64.81	48.63	16.99	37.31	68.95	89.21	83.10	59.61
	M+O	72.28	71.13	95.53	87.44	92.76	88.77	84.37	97.10	79.84	69.28
	F+O	71.56	80.32	83.51	63.46	85.25	38.35	75.85	62.60	96.28	91.16
	M+PO	75.61	83.19	95.63	87.02	93.33	87.92	83.01	96.98	99.89	79.87
	F+PO	73.51	82.41	83.80	66.70	84.54	40.28	77.96	63.49	96.30	92.67
SAM	M+P	89.42	89.70	99.87	66.14	44.46	25.45	22.93	68.35	71.06	57.79
	F+P	81.70	55.18	98.77	64.51	40.25	19.17	24.10	67.05	56.65	70.07
	M+O	68.81	76.01	96.98	91.89	92.49	75.65	84.29	98.23	89.15	83.78
	F+O	73.96	70.47	87.32	79.32	84.65	52.81	82.78	84.37	65.27	68.07
	M+PO	77.58	80.81	95.78	88.21	96.85	83.03	84.38	94.83	87.00	79.77
	F+PO	75.36	77.61	86.94	78.43	84.33	50.15	85.46	80.79	84.31	93.43
DMa	M+P	83.49	90.07	100	80.33	35.68	59.28	82.63	99.69	63.97	94.97
	F+P	77.04	47.81	99.18	68.47	26.19	52.61	78.96	91.51	86.59	64.91
	M+O	73.42	74.68	100	93.30	93.44	92.30	90.35	98.38	93.22	67.83
	F+O	74.40	84.02	99.49	92.50	93.78	84.29	86.70	59.49	93.36	78.59
	M+PO	76.70	75.34	100	93.34	96.20	92.35	90.31	98.49	99.94	69.76
	F+PO	68.69	62.87	97.89	96.05	91.46	86.37	88.81	64.87	96.31	78.96
MP	M+P	87.58	93.32	99.29	80.02	84.38	84.12	89.70	96.77	93.70	93.09
	F+P	82.66	73.94	97.53	77.09	68.60	68.72	89.87	92.26	91.73	90.81
	M+O	97.00	45.31	99.84	83.87	99.64	61.57	95.38	79.36	90.29	89.92
	F+O	97.75	84.93	99.75	84.83	98.40	93.54	88.17	92.97	90.32	90.70
	M+PO	96.48	78.01	99.77	69.64	98.34	98.21	94.78	86.06	89.82	89.10
	F+PO	98.28	84.41	99.75	86.89	99.45	94.73	88.32	94.22	90.90	91.24

<sup>(1)</sup> Métodos de clasificación: P: Paralelepípedos, MD: Mínima Distancia, DMa: Distancia de Mahalanobis, SAM: Spectral Angle Mapper, MP: Máxima Probabilidad.

<sup>(2)</sup> Imágenes: M: imagen Multiespectral; F: imagen Fusionada; UMI: Unidad Mínima de Información: P: Píxel; O: Objetos; PO: Píxel+Objetos.



La Tabla 2.7 muestra la Fiabilidad del Usuario (FU) obtenida para cada uso del suelo en las distintas clasificaciones realizadas al evaluar los diferentes algoritmos de clasificación y las diferentes UMI. Como se indicó anteriormente para la FP, dos de los usos de suelo clasificados con más precisión fueron el *rastrojo quemado* y los *rastrojos* de cereal de invierno. Por ejemplo, el valor de FU en la categoría *rastrojo quemado* fue superior al 95% en la mayoría de las clasificaciones, con un 100% de acierto en muchas de ellas. La categoría *rastrojo* de cereal también presentó una alta precisión, con valores de FU que oscilaron entre el 97% y 100% en todas las clasificaciones basadas en objetos y píxeles+objetos de la imagen multiespectral.

Las diferencias entre clasificaciones realizadas sobre imágenes multiespectrales y fusionadas tampoco siguió un patrón claro. Normalmente, se obtuvieron valores de FP y FU mayores en la imagen multiespectral que en la imagen fusionada, aunque hay excepciones notables de esto. Por ejemplo, las FU de la categoría *carretera* en las clasificaciones basadas en píxeles+objetos con el método DMA fueron del 93.24% y 32.6% para la imagen multiespectral y fusionada, respectivamente. Sin embargo, en las clasificaciones basadas en objetos con el método P se obtuvieron, respectivamente, valores de FU para *girasol* del 39.59% y 89.93% con la imagen multiespectral y fusionada.

Tabla 2.7: Fiabilidad del Usuario (%) de los cinco métodos de clasificación.

Método <sup>(1)</sup>	Imagen + UMI <sup>(2)</sup>	Usos del suelo									
		Árboles de ribera	Carretera	Rastrojo	Víña	Olivar	Suelo urbano	Girasol	Rastrojo Quemado	Suelo des. oscuro	Suelo des. claro
P	M+P	81.44	92.28	95.56	71.59	25.68	49.54	28.92	78.43	0.00	0.00
	F+P	32.42	84.61	70.37	56.87	28.64	48.72	26.80	40.63	4.58	6.17
	M+O	73.22	82.31	86.26	2.70	94.45	30.35	97.91	85.91	14.79	87.55
	F+O	46.77	75.64	79.92	62.96	62.11	52.17	73.54	56.36	87.45	61.42
	M+PO	75.93	60.87	88.93	14.18	94.22	81.16	95.71	85.73	20.21	77.57
	F+PO	43.10	85.37	85.44	66.84	58.77	52.06	71.04	53.77	84.35	66.47
MD	M+P	86.03	86.11	73.46	49.64	28.20	45.20	70.21	90.66	58.41	93.38
	F+P	78.10	50.85	64.81	48.63	16.99	37.31	68.95	89.21	83.10	59.61
	M+O	72.28	71.13	95.53	87.44	92.76	88.77	84.37	97.10	79.84	69.28
	F+O	71.56	80.32	83.51	63.46	85.25	38.35	75.85	62.60	96.28	91.16
	M+PO	75.61	83.19	95.63	87.02	93.33	87.92	83.01	96.98	99.89	79.87
	F+PO	73.51	82.41	83.80	66.70	84.54	40.28	77.96	63.49	96.30	92.67
SAM	M+P	89.42	89.70	99.87	66.14	44.46	25.45	22.93	68.35	71.06	57.79
	F+P	81.70	55.18	98.77	64.51	40.25	19.17	24.10	67.05	56.65	70.07
	M+O	68.81	76.01	96.98	91.89	92.49	75.65	84.29	98.23	89.15	83.78
	F+O	73.96	70.47	87.32	79.32	84.65	52.81	82.78	84.37	65.27	68.07
	M+PO	77.58	80.81	95.78	88.21	96.85	83.03	84.38	94.83	87.00	79.77
	F+PO	75.36	77.61	86.94	78.43	84.33	50.15	85.46	80.79	84.31	93.43
DMa	M+P	83.49	90.07	100	80.33	35.68	59.28	82.63	99.69	63.97	94.97
	F+P	77.04	47.81	99.18	68.47	26.19	52.61	78.96	91.51	86.59	64.91
	M+O	73.42	74.68	100	93.30	93.44	92.30	90.35	98.38	93.22	67.83
	F+O	74.40	84.02	99.49	92.50	93.78	84.29	86.70	59.49	93.36	78.59
	M+PO	76.70	75.34	100	93.34	96.20	92.35	90.31	98.49	99.94	69.76
	F+PO	68.69	62.87	97.89	96.05	91.46	86.37	88.81	64.87	96.31	78.96
MP	M+P	87.58	93.32	99.29	80.02	84.38	84.12	89.70	96.77	93.70	93.09
	F+P	82.66	73.94	97.53	77.09	68.60	68.72	89.87	92.26	91.73	90.81
	M+O	97.00	45.31	99.84	83.87	99.64	61.57	95.38	79.36	90.29	89.92
	F+O	97.75	84.93	99.75	84.83	98.40	93.54	88.17	92.97	90.32	90.70
	M+PO	96.48	78.01	99.77	69.64	98.34	98.21	94.78	86.06	89.82	89.10
	F+PO	98.28	84.41	99.75	86.89	99.45	94.73	88.32	94.22	90.90	91.24

<sup>(1)</sup> Métodos de clasificación: P: Paralelepípedos, MD: Mínima Distancia, DMa: Distancia de Mahalanobis, SAM: Spectral Angle Mapper, MP: Máxima Probabilidad.

<sup>(2)</sup> Imágenes: M: imagen Multiespectral; F: imagen Fusionada; UMI: Unidad Mínima de Información: P: Píxel; O: Objetos; PO: Píxel+Objetos.

## 5. Discusión

Un repaso general de los cinco métodos de clasificación aplicados sobre la imagen multiespectral y fusionada para la discriminación de cultivos y sus medidas agroambientales muestra dos aspectos importantes. Por una parte, las clasificaciones basadas en objetos y las basadas en píxeles+objetos claramente mejoran a las clasificaciones basadas en píxeles con valores de fiabilidad global que superan el 85% en la mayoría de los análisis, siendo el clasificador MP el más preciso. Por otra parte, se observa un aumento del 4% en fiabilidad global en la clasificación de la imagen fusionada con el método de MP en comparación con la misma clasificación realizada en la imagen multiespectral.

Tras evaluar los resultados de la clasificación de todos los usos del suelo, lo primero que se observa es que el mejor y el peor clasificador, tanto en la imagen multiespectral como en la fusionada, es MP y P, respectivamente. Más concretamente, la peor alternativa fue la clasificación basada en píxeles con el clasificador P y la mejor fue la clasificación basada en píxeles+objetos con el clasificador MP, ambas realizadas sobre la imagen fusionada. Los clasificadores MD, DMA y SAM aplicados sobre la imagen multiespectral también funcionaron bien, satisfaciendo todos el requerimiento comúnmente aceptado de obtención de al menos un 85% de fiabilidad global en la clasificación (Foody, 2002) y un valor del coeficiente Kappa superior al 0.75 (Montserud y Leamans, 1992) o 0.80 (Landis y Koch, 1977). Al analizar los usos de suelo individualmente, se observó una precisión muy alta en la discriminación de *rastrojo* de cereal y *rastrojo quemado* en la clasificación de la imagen multiespectral con los clasificadores MP y DMA y cualquier UMI, obteniéndose errores de omisión muy bajos, es decir, valores muy altos de Fiabilidad del Productor (incluso del 100%).

Un gran número de clasificaciones fueron eficientes independientemente del clasificador, mostrando algunas de ellas valores de Fiabilidad del Productor superiores al 70%. Estos resultados apoyan las conclusiones de Thomlinson *et al.* (1999), que indicó que el criterio para una discriminación correcta de usos de suelo no era sólo la obtención de un valor mínimo de fiabilidad global del 85%, sino también no presentar ninguna clase con menos del 70% de precisión. De acuerdo con Yu *et al.* (2006), una fiabilidad global superior al 60% se puede considerar satisfactoria en casos de mapas complejos de vegetación. De este modo, aunque no existe un estándar en los límites de precisión, hay un consenso general de que son necesarias precisiones altas, especialmente si el mapa temático resultante puede ser utilizado como ayuda en políticas medioambientales y en la toma de decisiones para hacer frente a prácticas agrícolas sostenibles. Del mismo modo, un logro importante en este estudio fueron los excelentes valores de Fiabilidad del Productor obtenidos para la mayoría de las clases estudiadas. Entre los valores de Fiabilidad del Productor hay que remarcar los obtenidos con el *rastrojo* de cereal de invierno y la *rastrojo quemado*, los cuales son dos de las principales medidas agroambientales para la reducción de la erosión en la U.E., al ser estos usos de suelo los que mejores precisiones obtuvieron. Todo esto, junto con la metodología de

discriminación de cubiertas en olivar mostrada por Peña-Barragán *et al.* (2004), permite el control de las tres medidas agroambientales fundamentales aprobadas para los cereales de invierno y olivar, dos de los principales cultivos mediterráneos de secano.

En *olivar*, uno de los usos de suelo con mayor variabilidad espectral intraclase, se obtuvieron aumentos importantes de Fiabilidad del Productor y Fiabilidad del Usuario, es decir, disminuciones en los errores de omisión y comisión, al comparar los análisis basados en píxeles con los basados en objetos. Por tanto, se propone la utilización de la segmentación de las imágenes para análisis basados en objetos con la finalidad de reducir la separabilidad estadística entre usos de suelo causada por el incremento de la variabilidad espectral intraclase, en las propuestas de clasificación tradicionales basadas en píxeles (Yu *et al.*, 2006). Por el contrario, en el caso del *rastrojo quemado y rastrojos* de cereal de invierno, los aumentos en los valores de Fiabilidad del Productor en los análisis basados en objetos comparados con los basados en píxeles no son tan marcados ni para la imagen multiespectral ni para la fusionada, probablemente debido a que esos usos de suelo presentan coberturas más homogéneas con una menor variabilidad espectral intraclase.

Con respecto a recomendar el uso de una imagen multiespectral o fusionada, se debe tener en cuenta dos consideraciones: el aumento de precisión que se puede obtener con la imagen fusionada y los requerimientos que conlleva el proceso de fusión tanto a nivel computacional como de experiencia del usuario. Considerando la clasificación de todos los usos de suelo y que MP es el mejor clasificador (Tabla 2.5), se observa un aumento del índice Kappa de un 4% en la clasificación basada en objetos de la imagen fusionada (valor de K de 0.9) respecto a la misma clasificación de la imagen multiespectral (valor de K de 0.94). Curiosamente, esta misma mejora se logró en el análisis basado en píxeles+objetos (valores de K de 0.9 y 0.94 para la imagen multiespectral y fusionada, respectivamente). Analizando los usos de suelo individualmente (Tablas 2.6 y 2.7), se observa que en la mayoría de los casos, las precisiones de las clasificaciones obtenidas con la imagen fusionada fueron menores que las obtenidas con la imagen multiespectral. Esto indica que las mejoras de precisión en la clasificación general debidas al uso de la imagen fusionada no llegan a ser realmente notables.

A lo largo de los años, muchos autores han aplicado técnicas de fusión para aumentar la fiabilidad de las clasificaciones. Por ejemplo, estudios llevados a cabo sobre imágenes de alta resolución espacial han mostrado un aumento medio de sólo el 1.5% de la fiabilidad global en clasificaciones de coberturas forestales analizadas sobre la fusión de imágenes QuickBird pancromáticas y multiespectrales junto con información textural (Kosaka *et al.*, 2005). Por otra parte, Davis y Wang (2002) evaluaron el efecto de la clasificación sobre la fusión de imágenes IKONOS pancromáticas y multiespectrales con diferentes resoluciones radiométricas, no observando mejoras en las clasificaciones de coberturas urbanas al evaluar la fusión de 8-bit, aunque sí se registraron aumentos de hasta el 7% en el caso de la imagen de 11-bit. Como puede observarse, los estudios llevados a cabo con fusiones de la imagen pancromática y multiespectral no ofrecen un rango de mejoras tan amplio como otros estudios que utilizan otro tipo de fusiones de

datos. Probablemente debido a estas circunstancias, las mejoras de precisión que se obtuvieron en este trabajo fueron poco destacadas. Sin embargo, la decisión final de si llevar a cabo o no la fusión de la imagen depende de la importancia que tenga en los objetivos el obtener la máxima precisión en comparación con la relación coste/eficiencia que suponga para el estudio. Así, si el objetivo es obtener un inventario de cultivos, entonces la mejor opción será utilizar la imagen multiespectral usando cualquiera de los clasificadores, (excepto el clasificador P), en el análisis basado en píxeles+objetos como UMI, al permitir una clasificación de vegetación detallada. Sin embargo, si lo que se desea es la obtención de una cartografía que se pueda utilizar para tomas de decisión por las administraciones, se recomienda activamente el uso de la imagen fusionada (usando la clasificación basada en píxeles+objetos con el algoritmo MP). Estos mapas pueden ser utilizados como una herramienta de precisión para el control de la aplicación de medidas agroambientales, el inventario de cultivos y el control de superficie cultivada llevado a cabo por las administraciones locales y europeas. Un ejemplo de este control se observa en la quema de rastrojos. Las condiciones climáticas existentes en la zona Mediterránea conllevan un riesgo de incendio tremendamente alto durante la estación seca (verano), por lo que se prohíbe a los agricultores la quema de rastrojos del cereal de invierno. Sin embargo, cada año se observa un gran número de incendios debidos en parte a que los agricultores no cumplen esta importante medida agroambiental. Ello lleva a la administración a tener que controlar esta práctica, sancionando fuertemente a muchos agricultores por incumplimiento.

Los resultados muestran que la fecha elegida para la toma de la imagen de satélite fue muy acertada para la discriminación de medidas agroambientales ya que en una imagen tomada antes, por ejemplo en mayo o junio, el *rastrojo* del cereal de invierno y el *rastrojo quemado* no se clasificarían correctamente al estar todavía presente en el suelo el cultivo de cereal de invierno. En esas fechas también se dificultaría la detección del cultivo de la vid ya que, debido a la fenología del cultivo, éste se confundiría con el suelo desnudo. Peña-Barragán *et al.* (2004) estudiaron diferentes fechas y también concluyeron que a principios de julio era el mejor momento para la discriminación de cubiertas vegetales en olivar.

A modo de resumen, indicar que los resultados obtenidos en este estudio muestran que la elección de diferentes tipos de imágenes, clasificadores y UMI en la clasificación repercute originando grandes variaciones sobre los resultados obtenidos para la discriminación de cultivos y sus medidas agroambientales asociadas.

## 6. Referencias

Arora, K., Mickelson, S. K., Baker, J. L., Tierney, D. P., y Peters, C. J. 1996. Herbicide retention by vegetative buffer strips from runoff under natural rainfall. *Transaction of the ASAE* 39, 2155-2162.

Baatz, M., Schäpe, A. 2000. Multiresolution segmentation: an optimization approach for high quality muti-scale image segmentation. In: *Proceedings of the 12<sup>th</sup> Symposium for Applied Geographic Information Processing (Angewandte Geographische Informationsverarbeitung XII. AGIT 2000)*, Salzburg, Austria, pp. 12-23.

Benz, U., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M. 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing* 58, 239-258.

BOJA. 2007. Orden de 5 de Junio de 2007. Desarrollo de los requisitos de aplicación de la condicionalidad en relación con las ayudas directas en el marco de la Política Agraria Común. *Andalusian Official Bulletin (BOJA)* 119, 7-37.

Bricklemeyer, R.S., Lawrence, R.L., Miller, P.R., Battogtokn, N. 2006. Predicting tillage practices and agricultural soil disturbance in north central Montana with Landsat imagery. *Agriculture, Ecosystem and Environment* 114, 210-216.

Bunting, P. y Lucas, R. 2006. The delineation of tree crowns in Australian mixed species forest using hyperspectral compact airborne spectrographic imager (CASI) data. *Remote Sensing of Environment* 101, 230-248.

Burnett, C. y Blaschke, T. 2003. A multi-scale segmentation/object relationship modelling methodology for landscape analysis. *Ecological Modelling* 168, 233-249.

Castillejo González, I.L., Sánchez de la Orden, M., García-Ferrer Porras, A., García Torres, L. y López Granados, F. 2004. Agrology in olive grove soils in the P.D.O. Baena (Spain). *Management Information Systems 2004: Incorporating GIS and Remote Sensing* (pp. 135-144). Southampton, UK: Wit Press.

Chavez, P. S., Sides, S. C. y Anderson, J. A. 1991. Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT Panchromatic. *Photogrammetric Engineering y Remote Sensing* 72, 295-303.

Choi, M., Kim, R.Y., Nam, M-R., Kim, H.O. 2005. Fusion of multispectral and panchromatic satellite images using the curvelet transform. *IEEE Geoscience and Remote Sensing* 2, 136-140.

Chubey, M.S., Franklin, S.E., Wulder, M.A. 2006. Object-based analysis of Ikonos-2 imagery for extraction of forest inventory parameters. *Photogrammetric Engineering and Remote Sensing* 72, 383-394.

Congalton, R.G. 1991. A review of assessing the accuracy of classification of remotely sensed data. *Remote Sensing of Environment* 37, 35-46.

Davis, C. H., Wang, X. 2002. Urban land cover classification from high resolution multi-spectral IKONOS imagery. In: Proceedings of 2002 IEEE International Geoscience and Remote Sensing Symposium, Seoul, Korea, pp. 2980-2983.

Definiens. 2007. Definiens Developer 7-Reference Book, Definiens AG., München.

Duggin, M.J. and Robinove, C.J. 1990. Assumptions implicit in remote sensing data acquisition and analysis. *International Journal of Remote Sensing* 11, 1669-1694.

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

Garatuza-Payan, J. y Watts, C. 2005. The use of remote sensing for estimating ET of irrigated wheat and cotton in Northwest Mexico. *Irrigation and Drainage Systems* 19, 301-320.

Gómez, J.A., Battany, M., Renschler, C.S., Fereres, E. 2003. Evaluating the impact soil management on soil loss in olive orchards. *Soil Use Manage* 19, 127-134.

González-Audicana, M., Saleta, J.L., García-Catalán, R., García, R. 2004. Fusion of multispectral and panchromatic images using improved IHS and PCA mergers based on wavelet decomposition. *IEEE Transactions on Geoscience and Remote Sensing* 42, 1291-1299.

Harvey, K.R., Hill G.J.E. 2001. Vegetation mapping of a tropical freshwater swamp in the Northern Territory, Australia: A comparison of aerial photography, Landsat TM and SPOT satellite imagery. *International Journal of Remote Sensing* 22, 2911-2925.

Harken, J. y Sugumaran, R. 2005. Classification of Iowa wetlands using an airborne hyperspectral image: a comparison of the spectral angle mapper classifier and an object-oriented approach. *Canadian Journal of Remote Sensing*, 31, 167-174.

Hay, G.J., Blaschke, T., Marceau, D.J., Bouchard, A. 2003. A comparison of three image-object methods for the multiscale analysis of landscape structure. *Photogrammetric Engineering of Remote Sensing* 57, 327-345.

Henry, W. B., Shaw, D. R., Reddy, K. R., Bruce, L. M. y Tamhankar, H. D. 2004. Remote sensing to distinguish soybean from weeds after herbicide application. *Weed Technology* 18, 594-604.

Hill, J., Megier, J., Mehl, W. 1995. Land degradation, soil erosion, and desertification monitoring in Mediterranean ecosystems. *International Journal of Remote Sensing* 12, 107-130.

Holschneider, M., Tchamitchian, P. 1990. Les ondelettes en 1989. Ed. PG. Lemarié, Springer-Verlag, Paris.

Hunt, E. R., McMurtrey, J. E., Parker-Williams, A. E. y Corp, L. A. 2004. Spectral characteristic of leafy purge (*Euphorbia esula*) leaves and flower bracts. *Weed Science* 51, 492-497.

Kettig, R.L., Landgrebe, D.A. 1976. Classification of multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on Geoscience and Remote Sensing* 14, 19-26.

Koger, C. H., Shaw, D. R., Reddy, K. N. y Bruce, L. M. 2004. Detection of pitted morningglory (*Ipomoea lacunose*) by hyperspectral remote sensing. I. Effects of tillage and cover crop residue. *Weed Science* 52, 222-229.

Koger, C. H., Shaw, D. R. y Watson, C. E. 2003. Detecting late-season weed infestations in soybean (*Glycine max*). *Weed Technology* 17, 696-704.

Kosaka, N., Akiyama, T., Tsai, B., Kojima, T. 2005. Forest type classification using data fusion of multispectral and panchromatic high-resolution satellite imageries. In: *Proceedings of 2005 IEEE International Geoscience and Remote Sensing Symposium*, Toronto, Canada, pp. 1204-1206.

Laliberte, A.S., Rango, A. Havstad, K. , Paris, J. F., Beck, R.F., McNeely, R., González, A.L. 2004. Object-oriented image analysis for mapping shrub encroachment from 1937 to 2003 in southern New Mexico. *Remote Sensing of Environment* 93, 198-210.

González, A. L. 2004. Object-oriented image analysis for mapping shrub encroachment from 1937 to 2003 in southern New Mexico. *Remote Sensing of Environment* 93, 198-210.

Landis, J.R., Kock, G.G. 1977. The measurement of observer agreement for categorical data. *Biometrics* 33, 159-174.

Lathrop, R. G., Montesano, P., Haag, S. 2006. A multi-scale segmentation approach to mapping seagrass habitats using airborne digital camera imagery. *Photogrammetric Engineering and Remote Sensing* 72, 665-675.

Lobo, A. 1997. Image Segmentation and discriminat Analysis for the identification of land cover units in ecology. *IEEE Transactions on Geoscience and Remote Sensing* 35, 1136-1145.

López-Granados, F., Jurado-Expósito, M., Peña-Barragán, J. M. 2006. Using remote sensing for identification of late-season grass weed patches in wheat. *Weed Science* 54, 346-353.

Mallinis, G., Koutsias, N., Tsakiri-Strati, M., Karteris, M. 2008. Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing* 63, 237-250.

Martín de Santa Olalla, F., Calera, A., Domínguez, A. 2003. Monitoring water use by combining irrigation advisory service and remotely sensed data with geographic information system. *Agricultural Water Management* 61, 111-124.



Mickelson, S.K., Baker, J.L., Ahmed, S.I. 2003. Vegetative filter strips for reducing atrazine and sediment runoff transport. *Journal of Soil and Water Conservation* 58, 359-367.

Montserud, R.A., Leamans, R. 1992. Comparing global vegetation maps with the kappa statistic. *Ecological Modelling* 62, 275-293.

Núñez, J., Otazu, X., Fors, O., Prades, A., Palà, V., Arbiol, R. 1999. Multiresolution-based image fusion with additive wavelet decomposition. *IEEE Transactions on Geoscience and Remote Sensing* 37, 1204-1211.

Oetter, D. R., Cohen, W. B., Berterretche, M., Maiersperger, T. K., Kennedy, R. E. 2001. Land Cover mapping in an agricultural setting using multiseasonal Thematic Mapper data. *Remote Sensing of Environment* 76, 139-155.

Otazu, X., González-Audicana, M., Fors, O., Núñez, J. 2005. Introduction of sensor spectral response into image fusion methods. Application to Wavelet-based methods. *IEEE Transactions on Geoscience and Remote Sensing* 43, 2376-2385.

Peña-Barragán, J.M., Jurado-Expósito, M., López-Granados, F., Atenciano, S., Sánchez de la Orden, M., García-Ferrer, A., García-Torres, L. 2004. Assessment of soil uses in olive groves from aerial photographs. *Agriculture, Ecosystem and Environment* 103, 117-122.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2006. Spectral discrimination of *Ridolfia segetum* and sunflower crop as affected by phenological stages. *Weed Research* 46, 1-11.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2007. Mapping *Ridolfia segetum* Moris patches in sunflower (*Helianthus annuus* L.) crop using remote sensing. *Weed Research* 47, 167-172.

Peña-Barragán, J.M., López-Granados F., García-Torres L., Jurado-Expósito M., Sánchez de la Orden M., García-Ferrer A. 2008. Discriminating cropping systems and agri-environmental measures by remote sensing. *Agronomy for Sustainable Development* 28, 355-362.

Robinove, C. 1981. The logic of multispectral classification and mapping the land. *Remote sensing of Environment* 11, 231-24.

Robinson, G. D., Gross, H. N., Schott, J. R. 2000. Evaluating of two applications of spectral mixing models to image fusion. *Remote Sensing of Environment* 71, 272-281.

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

Schmidt, K. S., Skidmore, A. K. 2003. Spectral discrimination of vegetation types in a coastal wetland. *Remote Sensing of Environment* 85, 92-108.

Sohn, Y., Rebello, S. 2002. Supervised and unsupervised spectral angle classifiers. *Photogrammetric Engineering and Remote Sensing* 68, 799-811.

Song, C., Woodcock, C.E., Seto, K.C., Lenney, M.P., Macomber, S.A. 2011. Classification and Change Detection Using Landsat TM Data: When and How to Correct Atmospheric Effects? *Remote Sensing of Environment* 75, 230-244.

South, S., Qi, J., Lusch, D.P. 2004. Optimal classification methods for mapping agricultural tillage practises. *Remote Sensing of Environment* 91, 90-97.

Thomlinson, J.R., Bolstad, P.V., Cohen, W.B. 1999. Coordinating methodologies for scaling landcover classifications from site-specific to global: step toward validating global map products. *Remote Sensing of Environment* 70, 16-28.

Tran, T. N., Wehrens, R., Buydens L. M. C. 2003. SpaRef: a clustering algorithm for multispectral images. *Analytica Chimica Acta* 490, 303-312.

van der Werff, H.M.A., van der Meer, F.D. 2008. Shape-based classification of spectrally identical objects. *ISPRS Journal of Photogrammetry and Remote Sensing* 63, 251-258.

Vijayaraj, V., O'Hara, C.G., Younan, N. H. 2004. Quality analysis of pansharpened images. In: *Proceedings of IGARSS 2004 symposium, Anchorage, EE.UU.*, pp. 88-91.

Vijayaraj, V., Younan, N. H., O'Hara, C.G. 2006. Concepts of image fusion in remote sensing applications. In: *Proceedings of 2006 IEEE International Geoscience and Remote Sensing Symposium, Denver, EE.U.*, pp. 3798-3801.

Wald, L. 2002. *Data Fusion. Definition and Architectures- Fusion of Images of Different Spatial Resolutions.* Presses de l'Ecole, Ecole des Mines de Paris, Paris.

Yang C., Everitt J.H., Bradford J.M. 2006. Comparison of QuickBird satellite imagery and airborne imagery for mapping grain sorghum yield patterns. *Precision Agriculture* 7, 33-44.

Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M., Schirokauer, D. 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering and Remote Sensing* 72, 799-811.

Zambon, M., Lawrence, R., Bunn, A., Powell, S. 2006. Effect of alternative splitting rules on image processing using classification tree analysis. *Photogrammetric Engineering and Remote Sensing* 72, 25-30.

Graps, A. 1995. Introduction to wavelets. *IEEE computational science and engineering* 2, 50-61

Mallat, S.G. 1989. Theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 11, 674-693.

Starck, J.L., Murtagh, F.D., Bijaoui, A. 1994. Image restoration with noise suppression using a wavelet transform and a multiresolution support constraint. Proceedings of SPIE - The International Society for Optical Engineering 2302, 132-143.

**Discriminación espectral multitemporal  
de avena loca (*Avena sterilis* L.) y alpiste  
(*Phalaris* spp.) en campos de trigo  
(*Triticum durum* L.) en estados  
fenológicos tardíos**

---

---

## CAPÍTULO III



# Discriminación espectral multitemporal de avena loca (*Avena sterilis* L.) y alpiste (*Phalaris* spp.) en campos de trigo (*Triticum durum* L.) en estados fenológicos tardíos

## Resumen

El trigo, *Triticum durum* L., es el cultivo de cereal más importante en España con una superficie cultivada mayor de cinco millones de hectáreas anuales. La avena loca, *Avena sterilis* L., y el alpiste, *Phalaris* spp., son malas hierbas asociadas al cultivo del trigo que se localizan en rodales, aunque la aplicación de herbicidas para su eliminación se realiza en toda la parcela de trigo, lo que conlleva una aplicación excesiva de producto unida a una contaminación innecesaria. Para reducir la aplicación de herbicida, se han desarrollado técnicas de manejo localizado de rodales infestados con herbicidas basadas en mapas de infestaciones de malas hierbas. Obtener esta información a partir de exploraciones intensivas en campo es un proceso que consume mucho tiempo y dinero. Además obtiene como resultado un mapa en el que se han estimado los valores de infestación de los puntos no muestreados. La determinación de malas hierbas mediante teledetección ha demostrado ser una alternativa más eficiente. El principio para aplicar la teledetección en la determinación de malas hierbas se basa en la diferencia espectral existente entre malas hierbas y cultivos. Para probar este principio, se estudiaron respuestas espectrales (hiper- y multiespectrales) tomadas en campo de las regiones del visible e infrarrojo cercano para discriminar trigo, avena loca y alpiste en sus últimos estado fenológicos.

En el caso de las malas hierbas, los estados fenológicos analizados comprenden desde el inicio de la maduración de la semilla hasta su estado de maduración avanzado, mientras que en el trigo comprenden desde el inicio de la senescencia hasta su final. Las firmas espectrales se tomaron con un espectrorradiómetro de campo portátil en 8 fechas diferentes repartidas entre el 28 de abril y el 26 de mayo. Para analizar las diferencias de reflectancias entre especies y determinar la precisión en la clasificación de éstas en base a su estado fenológico se realizó un análisis discriminante por el método *stepwise*. Para ello se consideraron 4 escenarios o grupos de clasificaciones: 1) trigo-avena loca-alpiste, con cada especie representada por un grupo de espectros diferentes; 2) trigo-malas hierbas gramíneas, combinando las dos especies de malas hierbas es un único grupo espectral; 3) trigo-avena loca, y 4) trigo-alpiste, donde cada especie de mala hierba se clasifica de forma individual.

Los análisis alcanzaron el 100% de fiabilidad de la clasificación en los estados fenológicos de inicio de la maduración de la semilla de mala hierba y trigo verde (inicio senescencia) y estado avanzado de maduración de la semilla de mala hierba y trigo parcialmente verde (senescencia avanzada) tomados en las fechas comprendidas entre el 28 de abril y 6 de mayo. El análisis discriminante de los datos hiperespectrales dio como

resultado que de las 50 longitudes de onda analizadas, sólo 13 eran utilizadas para discriminar las especies en los distintos escenarios considerados. Por otra parte, el análisis multiespectral mostró que las bandas espectrales más anchas equivalentes a las de las imágenes del satélite QuickBird discriminaban la avena loca, el alpiste y el trigo con elevada precisión y en las mismas fechas que las obtenidas en el análisis hiperespectral. Estos resultados son muy útiles para determinar el periodo de tiempo idóneo para tomar imágenes con satélites multiespectrales como QuickBird y las longitudes de onda concretas que deberían usarse en el caso de tomar imágenes hiperespectrales con sensores aeroportados. Una cartografía precisa y a tiempo de la distribución espacial de malas hierbas es el elemento clave para realizar aplicaciones herbicidas localizadas con objeto de reducir el uso de herbicida aplicado y los costes de los tratamientos.

## 1. Introducción

### 1.1. Generalidades

El trigo es el cereal más importante en España con una superficie cultivada superior a los 5 millones de hectáreas anuales. La avena loca (*Avena sterilis* L.), el alpiste (*Phalaris* spp.) y el vallico (*Lolium rigidum* L.) son las malas hierbas gramíneas más comunes en cultivos de cereal, siendo estimadas, respectivamente, en un 65%, 34% y 32% de los campos cultivados del sur de España (Saavedra *et al.*, 1989). Aunque ya se conoce la distribución en rodales de la avena loca y el vallico en cereales de invierno (Barroso *et al.*, 2004b; Blanco-Moreno *et al.*, 2006), los graminicidas normalmente se aplican en toda la parcela, con el consiguiente riesgo de aplicaciones excesivas de producto. Para solventar esta situación, se ha demostrado que el Control Localizado de Malas Hierbas (CLMH) consistente en la pulverización directa sobre rodales de malas hierbas gramíneas en cereales de invierno es viable para el control de estas malas hierbas presentes en la mayoría de las latitudes (Timmermann *et al.*, 2003; Barroso *et al.*, 2004a; Ruiz *et al.*, 2006). Un aspecto clave del CLMH es la necesidad de obtener mapas de infestaciones de malas hierbas adecuados, precisos y en las fechas de aplicación con objeto de aprovechar al máximo las aplicaciones localizadas de herbicidas.

Algunos estudios han realizado trabajos de campo intensivos mediante tomas de datos basada en muestreos discretos sobre mallas de diferentes tamaños para el estudio de la distribución espacial de las malas hierbas y la estimación de su densidad en puntos no muestreados (Jurado-Expósito *et al.*, 2003, 2005). Rew y Cousens (2000) concluyeron que la obtención de mapas de rodales de malas hierbas a gran escala basados en inspecciones del terreno (muestreo discreto) es un trabajo que consume mucho tiempo y dinero. También sostuvieron que métodos de obtención de datos continuos tales como la teledetección son más apropiados y efectivos para el CLMH. La aplicación de técnicas de teledetección para el estudio de la cobertura de malas hierbas podría ser más eficiente que las costosas tomas de datos en campo, lo que puede ser constatado por el aumento del uso de esta tecnología para la obtención de mapas de distribución de malas hierbas en los últimos años. La importancia de la teledetección en el control localizado de malas hierbas ha sido revisado minuciosamente por Felton *et al.* (2002), Radhakrishnan *et al.* (2002), Thorp y Tian (2004), y Brown y Noble (2005), López-Granados (2011). En estos trabajos se muestra que la mayoría de los estudios de discriminación de malas hierbas en sistemas de cultivo se han basado en bandas anchas y discretas tomadas con sensores multiespectrales.

### 1.2. Caracterización espectral del cultivo y las malas hierbas

La respuesta espectral de una especie vegetal en el dosel o a nivel de hoja es única, y esa respuesta se conoce como signatura o firma espectral. Para detectar y mapear las malas hierbas es necesario que existan diferencias entre la reflectividad espectral del



cultivo y la de la mala hierba. Una característica definitoria de la firma espectral es que ésta varía en función del estado fenológico de la planta. El principio básico del uso de firmas espectrales adquiridas en campo para teledetección es que si se pueden medir o reconocer diferencias en la reflectividad en determinadas longitudes de onda debidas a los distintos estados fenológicos de las plantas, existe potencia para la detección remota de malas hierbas siempre que los sensores tengan esas longitudes de onda. Varias especies de malas hierbas se han identificado en cultivos aprovechando la diferencia en sus estados fenológicos (Lass y Callighan, 1997; Kavdir, 2004; Brown y Noble, 2005; Girma *et al.*, 2005; Peña-Barragán *et al.*, 2006). Las diferencias existentes en el ciclo de la vida de los cultivos y las malas hierbas en estados fenológicos avanzados, antes de que los cultivos y las malas hierbas estén senescentes y ambos se pongan amarillos, puede permitir la detección de diferencias espectrales. Por lo tanto, la detección de infestaciones de malas hierbas gramíneas tardías puede ser particularmente útil cuando las diferencias espectrales entre los cultivos de cereales y las malas hierbas son máximas debido a que éstas alcanzan su senescencia en un momento diferente al de los cultivos (Thompson *et al.*, 1991; Rew *et al.*, 1996; Koger *et al.*, 2003). Además, considerando que las infestaciones de malas hierbas presentan bastante estabilidad espacial de un año para otro (Barroso *et al.*, 2004b; Jurado-Expósito *et al.*, 2004, 2005). La obtención de mapas de malas hierbas tardías podría ser utilizado para diseñar métodos de control localizado en los años posteriores, o para aplicaciones de herbicidas de post-emergencia en temporada si no se ha realizado un adecuado tratamiento de control pre-emergencia. Por ejemplo, puede ser útil realizar aplicaciones localizadas post-emergencia para el control de rodales de malas hierbas gramíneas (ej. *Avena* spp.) en cereales con herbicidas muy específicos y caros. Se ha demostrado que localizando los rodales de malas hierbas en la época espectralmente más adecuada, se puede diseñar un programa de tratamiento herbicida localizado para la siguiente estación en cultivos de maíz y girasol (Goel *et al.*, 2003; Peña-Barragán *et al.*, 2007).

### 1.3. Sensores hiperespectrales vs multiespectrales

Los avances tecnológicos han dado lugar a innovadores sensores hiperespectrales portátiles que ofrecen una mejora considerable respecto a los sensores multiespectrales. Los sensores hiperespectrales presentan cientos de longitudes de onda continuas y muy estrechas, normalmente inferiores a 10nm de anchura, mientras que los sensores multiespectrales toman datos a lo largo de 3 a 7 bandas más anchas. Por tanto, debido que las bandas son más estrechas en los sistemas de escaneo hiperespectrales, se pueden detectar variaciones pequeñas o locales de las características de absorción que de otro modo podrían ser enmascaradas dentro de una banda más ancha de un sistema multiespectral (Schmidt y Skidmore, 2003; Koger *et al.*, 2004). La información multiespectral se ha utilizado satisfactoriamente en diversos estudios como la discriminación espectral de 27 tipos de vegetación de marisma en humedales costeros (Schmidt y Skidmore, 2003), la detección de la campanilla (*Ipomea lacunosa* L.) en campos de soja (Koger *et al.*, 2004), y la evaluación de la capacidad de separar cinco especies de malas hierbas y dos cultivos (Smith y Blackshaw, 2003; Peña-Barragán *et al.*, 2006).

Como ya se ha mencionado, el uso de sistemas de escaneo hiperespectrales implica analizar cientos de longitudes de onda. Con objeto de reducir la cantidad de datos hiperespectrales necesarios para determinar un subconjunto de longitudes de onda estrechas sin perder información importante, se han utilizado varios métodos estadísticos. Por ejemplo, se han utilizado redes neuronales en cultivos de maíz (Yang *et al.*, 1999; Goel *et al.*, 2003) y trigo (Wang *et al.*, 1999; López-Granados *et al.*, 2008); se han aplicado técnicas basadas en árboles de decisión en estudios de maíz (Goel *et al.*, 2003) y otros usos de suelo (Friedl y Brodley, 1997; Friedl *et al.*, 1999); y se han realizado análisis de datos multivariantes tales como componentes principales y análisis discriminantes en cultivos de tomate y maíz (Slaughter *et al.*, 2004; Karimi, *et al.*, 2005a, b). Girma *et al.* (2005) estudió las firmas espectrales en la región del óptico para detectar bromo (*Bromus secalinus* L.) y vallico en trigo de invierno cultivado en invernadero. Los autores concluyeron que las medidas espectrales fueron diferentes en función del estado de crecimiento de las plantas, pero sugirieron que sería necesario evaluar si la diferenciación espectral sigue siendo fuerte en condiciones reales de campo. Los autores concluyeron que las medidas espectrales difirieron en función del estado de crecimiento de la planta, sugiriendo que sería necesario determinar si la identificación espectral es robusta en condiciones de campo.

La teledetección hiperespectral se ha presentado como una tecnología muy adecuada para estudios agrícolas, debido a que en ella se evita el solape espectral que se puede observar en las bandas más anchas de los sensores multispectrales. Algunos autores han intentado discriminar entre especies de malas hierbas y cultivos aplicando análisis discriminantes a datos hiperespectrales en lugar de multispectrales para evaluar si son realmente necesarios detalles espectrales tan sutiles (Smith y Blackshaw, 2003; Brown y Noble, 2005). Esta información es esencial debido a que la discriminación con firmas hiperespectrales necesita el uso de sensores aerotransportados hiperespectrales (ej. Compact Airborne Spectrographic Imager, CASI), mientras que la discriminación con firmas multispectrales puede realizarse con imágenes satélite de alta resolución espacial (ej. QuickBird).

### 1.4. Utilización de índices de vegetación

Las diferencias de reflectancia espectral pueden ser resaltadas mediante la utilización de índices de vegetación, los cuales son combinaciones matemáticas (ratios y lineales) de longitudes de onda o bandas seleccionadas en sensores hiperespectrales y multispectrales. Normalmente se combina la información de dos o más bandas para crear índices de vegetación que son de gran utilidad para la caracterización del crecimiento y desarrollo de la vegetación debido a que se aprovechan del contraste de reflectancia de la vegetación en diferentes bandas del espectro (Jackson y Huete, 1991; Hatfield y Pinter, 1993). Los índices más comúnmente utilizados en teledetección multispectral son el índice de vegetación de diferencia normalizada (*NDVI*, *Normalized Difference Vegetation Index*) =  $(IRc - R) / (IRc + R)$ , donde IRc representa la banda del infrarrojo cercano y R la banda del rojo (Rose *et al.*, 1973), y el índice de vegetación de proporción simple (*RVI*, *Ratio Vegetation Index*) =  $(IRc / R)$  (Jordan, 1969). Los índices *NDVI* y *RVI* son muy utilizados para

la diferenciación entre tipos de vegetación debido a que ésta normalmente muestra altos valores de reflectancia en la banda IRc y valores muy bajos en la región del rojo, centrándose ambos índices en realzar esas diferencias (Elmore *et al.*, 2000; Hansen y Schjoerring, 2003; Koger *et al.*, 2003). El índice *NDVI* ya ha sido utilizado en algunos trabajos en discriminaciones entre malas hierbas y cultivos (Lass y Callihan, 1997; Lamb *et al.*, 1999; López-Granados *et al.*, 2006; Peña-Barragán *et al.*, 2006), y entre áreas infestadas y libres de malas hierbas en cultivos de soja (Chan *et al.*, 2004) y girasol (Kavdir, 2004).

### 1.5. Objetivos

Como una parte de una investigación más amplia para estudiar las posibilidades y limitaciones que ofrecen las imágenes de teledetección para el mapeado de malas hierbas gramíneas en trigo, es esencial analizar las variaciones en sus firmas hiper- y multiespectrales en distintos estados fenológicos de maduración en condiciones de campo. Este enfoque permitirá identificar longitudes de onda o bandas espectrales adecuadas para la discriminación y clasificación de especies. Además, asumiendo que las fechas de muestreo deben elegirse en el momento en el que las diferencias fenológicas sean máximas, es necesario obtener series temporales de datos fenológicos tardíos con objeto de determinar el mejor momento para identificar los cultivos y las malas hierbas. Por ello, los objetivos de este estudio fueron (1) evaluar la potencialidad que supone el uso de series temporales de datos espectrorradiométricos tomados en campo en las regiones del espectro del visible e infrarrojo cercano para discriminar entre trigo, avena loca y alpiste en base a sus características hiperespectrales y multiespectrales, y (2) comparar la precisión de las discriminaciones realizadas con cada fecha de muestreo. Los resultados obtenidos facilitarán la determinación del periodo óptimo y de las mejores longitudes de onda para los sensores hiperespectrales o bandas espectrales en caso de utilizar las imágenes satélite multiespectrales que permitan mapear estas malas hierbas en cultivos de trigo.

## 2. Materiales

### 2.1. Zona de estudio

El trabajo se ha llevado a cabo en un campo de 25.6 ha situadas en la localidad de Santa Cruz, provincia de Córdoba (Fig. 3.1). Esta zona se caracteriza por presentar un relieve relativamente plano junto con un clima Mediterráneo continental caracterizado por veranos largos y secos e inviernos suaves. El trigo de invierno se sembró a mediados de noviembre y se cosechó a mediados de junio.

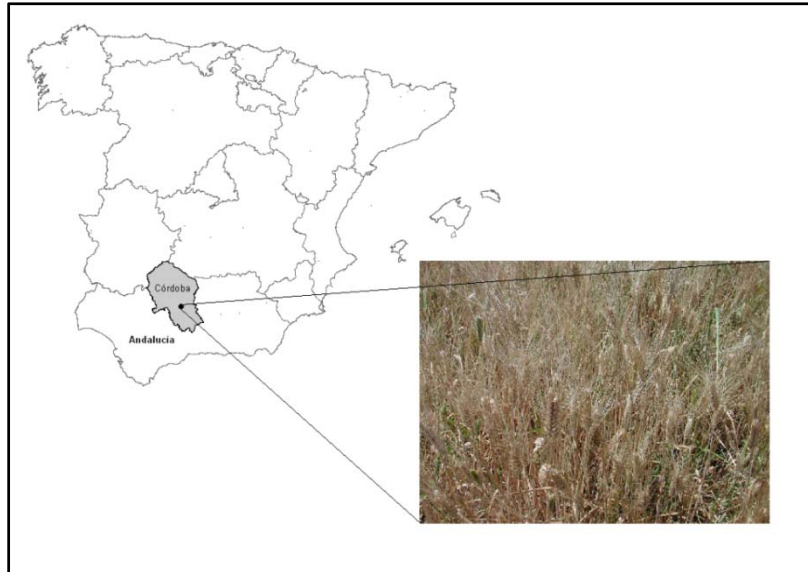


Figura 3.1. Localización del área de estudio en Andalucía.

Durante el estudio se observaron infestaciones importantes de malas hierbas constituidas principalmente por avena loca y alpiste. Las zonas elegidas de muestreo fueron visitadas regularmente cada semana desde finales de abril hacia adelante para tomar datos del estado fenológico de los cultivos y las malas hierbas y de sus firmas espectrales. Se consideraron cuatro estados fenológicos de malas hierbas y trigo (adaptados de Lancashire *et al.*, 1991) correspondientes a tres periodos tomados de las 8 fechas de muestreo (Tabla 2.1). Estos engloban desde finales de abril, donde el trigo se encuentra en un estado de maduración avanzando y parcialmente verde mientras que las malas hierbas están en un estado inicial de maduración con la planta verde; hasta finales de mayo, cuando el trigo se encuentra senescente y totalmente amarillo y las malas hierbas se encuentran en el comienzo del periodo de senescencia y empiezan a amarillear (Fig. 3.2).

Tabla 3.1: Etapas fenológicas del trigo, avena loca y alpiste desde el 28 de abril al 26 de mayo.

Etapas fenológicas		Fechas muestreo
Avena loca y alpiste	Trigo	
Inicio de la maduración de la semilla y planta verde, IM	Maduración avanzada y planta parcialmente verde, AM	Del 28 de abril al 6 de mayo
Maduración avanzada de la semilla y planta parcialmente verde, AM	Comienzo de la senescencia y planta amarilleando, IS	Del 14 al 22 de mayo
Comienzo de la senescencia y planta amarilleando, IS	Senescencia y planta amarilla, S	Hasta el 26 de mayo



Figura 3.2. Situación del trigo en la etapa fenológica S y las malas hierbas en la IS.

## 2.2. Lecturas espectrales

Se tomaron firmas espectrales en zonas de trigo libre de malas hierbas y de las dos especies de malas hierbas gramíneas cada cuatro días en el periodo comprendido desde el 28 de abril hasta el 26 de mayo. Esto equivalió a 8 días de muestreo. Cada especie de mala hierba que se muestreó ofrecía un rodal de aproximadamente 20-25 espigas/panículas por  $m^2$ . Para cada especie se tomaron veinte medidas verticales elegidas aleatoriamente con un espectrorradiómetro de campo ASD Handheld FieldSpec situado a una altura de 60-80 cm sobre el dosel de cada planta. Los datos espectrales medidos con el espectrorradiómetro se transformaron en valores de reflectividad, que representa la proporción de energía reflejada en un punto respecto a su energía incidente. Cada firma espectral fue calibrada justo antes y después de cada medida usando como referencia un panel de reflectancia fabricado con sulfato de bario (Spectralon). Las medidas con el espectrorradiómetro fueron tomadas entre las 12:00 h y las 14:00 h en días totalmente despejados de nubes (Salisbury, 1999) con un campo de visión óptico de  $25^\circ$  y sobre una superficie de 0.15 a  $0.20m^2$  (Fig. 3.3). Las medidas hiperespectrales se tomaron en la región del espectro que va desde los 325 a los 1075nm con una anchura de banda de 1.5nm. Debido a que la reflectancia espectral presentó mucho ruido en los valores límites (inicio y final de la medición) sólo se tomaron los valores de 400 a 900nm para el análisis.




Figura 3.3. Toma de datos en campo con espectrorradiómetro.

### 3. Metodología

Estudios previos (Thenkabail *et al.*, 2004; Peña-Barragán *et al.*, 2006) muestran que longitudes de onda adyacentes frecuentemente suelen suministrar información similar. Por este motivo, los datos hiperespectrales tomados fueron promediados obteniéndose 50 medidas en el rango de 400 a 900 nm de 10 nm de anchura cada una para poder ser analizados estadísticamente. Por otro lado, se volvieron a promediar los datos hiperespectrales originales en cuatro bandas espectrales más anchas, azul (A: 450-520nm), verde (V: 521-600nm), rojo (R: 630-690nm) e infrarrojo cercano (IRc: 760-900nm) equivalentes a las que ofrece el satélite comercial QuickBird. A partir de estas últimas bandas se calcularon los índices de vegetación  $NDVI = (IRc-R)/(IRc+R)$ ,  $RVI = (IRc/R)$ ,  $R/A$  (Everitt y Villareal, 1987),  $IRc-R$  y  $(R-V)/(R+V)$ .

#### 3.1. Análisis discriminante

Para determinar la capacidad de discriminación entra avena loca, alpiste y trigo con información tanto hiperespectral como multiespectral, se realizaron análisis discriminantes de cada conjunto de datos. El análisis discriminante es una técnica estadística que muestra qué conjunto de variables (variables independientes) son capaces de diferenciar distintos tipos de elementos o grupos de clasificación (variable dependiente) y cuántas de estas variables independientes son necesarias para alcanzar la mejor clasificación posible. Su objetivo último es encontrar la combinación lineal de las variables independientes que mejor permita diferenciar o discriminar los distintos grupos de clasificación. Los análisis realizados permitieron establecer modelos predictivos para clasificar el grupo de elementos correspondiente a las distintas especies vegetales basado en las características observadas en cada caso (longitudes de onda en el análisis

hiperespectral y bandas multiespectrales e índices de vegetación en el análisis multiespectral). Este procedimiento generó una función discriminante o un grupo de funciones cuando hubo más de dos grupos de clasificación, debido a que el número de funciones generado correspondió al número de grupos de clasificación menos uno, en base a las combinaciones lineales de las variables previstas que muestran las mejores discriminaciones entre grupos (Karimi, *et al.*, 2005b) (Eq. (1)). Este análisis también realizó una medición sobre el grado de diferenciación entre grupos.

$$\begin{aligned}
 y_1 &= a_{11}x_1 + \dots + a_{1p}x_p + a_{10} \\
 &\dots\dots\dots \\
 y_m &= a_{m1}x_1 + \dots + a_{mp}x_p + a_{m0}
 \end{aligned}
 \tag{1}$$

donde  $y$  son las funciones discriminantes,  $x$  el conjunto de variables independientes,  $p$  el número de variables independientes,  $n$  el número de grupos de clasificación (variables dependientes) y  $m = (n-1)$ .

La discriminación entre trigo y malas hierbas se realizó mediante un análisis discriminante *stepwise*, el cual seleccionó el conjunto más adecuado de longitudes de onda hiperespectrales o de bandas multiespectrales e índices para cada uno de los análisis hiperespectrales o multiespectrales, respectivamente. Con este sistema de análisis discriminante, las variables independientes se fueron incorporando a la función discriminante una a una, posibilitando construir una función en la que se utilizaron únicamente aquellas variables realmente útiles para la clasificación y evaluando la contribución individual de cada variable al modelo discriminante. El proceso se basó en análisis para la selección e inclusión de variables nuevas en el proceso junto con análisis para la eliminación de variables ya introducidas si tras esa nueva combinación de variables dejaban de tener significancia en el modelo (Karimi *et al.*, 2005a). Por tanto, se establecieron unos criterios de entrada/salida de variables. Así, una variable sólo se seleccionaba para el modelo si cumplía con un determinado criterio de entrada. En cada paso del análisis se incorporó una nueva variable al modelo, lo que hizo que se volvieran a evaluar nuevamente todas las variables ya incluidas para determinar si cumplían o no el criterio de salida. En el caso de que alguna lo cumpliera, ésta era expulsada del modelo. Para determinar los criterios de entrada y salida se usó el valor del estadístico F. El valor mínimo de F establecido como criterio de entrada fue 3.84, mientras que para el criterio de salida se consideró un valor de F de 2.71 (Visauta y Martori, 2003).

En este estudio, la calidad de cada uno de las funciones discriminantes obtenidas se determinó a partir del estadístico lambda de Wilks (Eq. (2)). Los valores de este estadístico fueron indicativos de la capacidad de separación o discriminación de las longitudes de ondas espectrales introducidas en los análisis. Cuanto más bajo es el valor de lambda de Wilks, mayor es la capacidad de diferenciación espectral entre grupos de clasificación (Thenkabail *et al.*, 2004). Estos valores oscilarán entre 1, donde los distintos

grupos son idénticos, hasta 0, donde existe la máxima diferencia entre ellos. En cada fase del proceso se introdujo la variable que minimizó el valor de lambda de Wilks global.

$$\Lambda = \frac{|S|}{|T|} \quad (2)$$

donde  $\Lambda$  es la lambda de Wilks,  $|S|$  es la matriz de varianza-covarianza combinada, calculada a partir de las matrices de varianza-covarianza de cada grupo y  $|T|$  es la matriz de varianza-covarianza total.

### 3.2. Escenarios agronómicos considerados

Para los análisis se consideraron 4 escenarios de clasificación según las posibilidades reales que suelen ocurrir en condiciones de campo. El análisis discriminante *stepwise* se calculó considerando como escenario 1, cuando el trigo, la avena loca y el alpiste representaron tres grupos diferentes de clasificación; escenario 2, cuando el trigo fue un grupo de clasificación y la avena loca y el alpiste se agruparon en otro grupo; escenario 3, cuando sólo se discriminó entre trigo y avena loca; y escenario 4, cuando la discriminación se centró en el trigo y el alpiste. Las funciones se generaron a partir de muestras de longitudes de onda para análisis hiperespectrales, o bien de bandas multiespectrales e índices de vegetación para análisis multiespectrales que caracterizaron cada grupo de clasificación (trigo, avena loca y alpiste) obtenidos a partir de los datos medidos en campo. Una vez obtenidas las funciones, éstas fueron utilizadas para verificar los mismos datos que sirvieron para crearlas, lo que permitió comprobar el grado de eficacia de la función desde el punto de vista de la clasificación. Esta comprobación se vio reforzada mediante la aplicación de un segundo método de verificación. Los resultados obtenidos en las clasificaciones de las funciones fueron comparados con los obtenidos con el método de validación cruzada. Dentro de este método se tomó la opción clasificación dejando uno fuera, la cual generó tantas funciones discriminantes como casos (mediciones) válidos tuvo el análisis a partir de todos los casos introducidos menos uno. Tras este proceso, cada caso fue clasificado utilizando la función discriminante en la que no hubo intervenido. Si tras la evaluación de estos dos procesos de validación los resultados fueron satisfactorios, la función discriminante podría utilizarse para clasificar futuros casos en los que se tengan medidas pero se desconozcan a qué grupo pertenecen.

Toda la metodología comentada anteriormente fue aplicada tanto a las longitudes de onda de los análisis hiperespectrales como al conjunto de bandas e índices de vegetación de los análisis multiespectrales para crear reglas de clasificación que permitieran discriminar entre el trigo y las malas hierbas avena loca y alpiste. Tanto los análisis discriminantes de ambos estudios como el cálculo de los índices de vegetación se realizó con el software SPSS 13.0 (SPSS Inc, 2004).



## 4. Resultados

### 4.1. Análisis hiperespectral y multitemporal

La Figura 3.4 representa las curvas promedio de la reflectancia hiperespectral medidas en campo del trigo, la avena loca y el alpiste. Las forma general de las firmas espectrales del trigo y de las malas hierbas fueron muy parecidas entre sí en las primeras fechas de muestreo (del 28 de abril al 18 de mayo) y en las últimas (del 22 al 26 de mayo) (Fig. 3.5). Las firmas espectrales medidas entre el 28 de abril y el 18 de mayo del trigo, avena loca y alpiste exhibieron el comportamiento característico de las plantas verdes, con un aumento de reflectividad en la región del verde del espectro electromagnético (550nm), conocido como “pico del verde”, y con los valores de reflectancia más altos en la región del infrarrojo cercano (760 a 900nm). Por ejemplo, en la medición del 2 de mayo, cuando el estado fenológico de las malas hierbas fue el inicio de la maduración de las semillas (IM) con la planta verde, y el trigo se encontraba en un estado fenológico de maduración avanzada de la semilla y planta parcialmente verde (AM), los valores de reflectividad para el trigo, la avena loca y el alpiste fueron respectivamente del 10%, 12% y 17% en la región del verde, y de 63%, 78% y 90% en la región del infrarrojo cercano. Estos valores mostraron que tanto el trigo como las dos malas hierbas se encontraban todavía en la fase de vida activa. Sin embargo, en la medición del 26 de mayo se observó que las malas hierbas presentaban un estado fenológico de inicio de senescencia (IS) con la planta amarilleando, mientras que el trigo ya estaba en un estado de total senescencia (S) y con la planta amarilla, mostrando unos valores de reflectividad para el trigo, la avena loca y el alpiste del 18%, 22% y 20% en la región del verde, y de 46%, 50% y 49% en la región del infrarrojo cercano, respectivamente. En esta última fecha, los valores de las firmas espectrales de las tres especies mostraron un incremento constante de reflectividad a medida que aumentaba la longitud de onda, sin observarse ningún comportamiento peculiar (pico o incremento) en la región del verde o del infrarrojo cercano como es típico de la vegetación senescente.

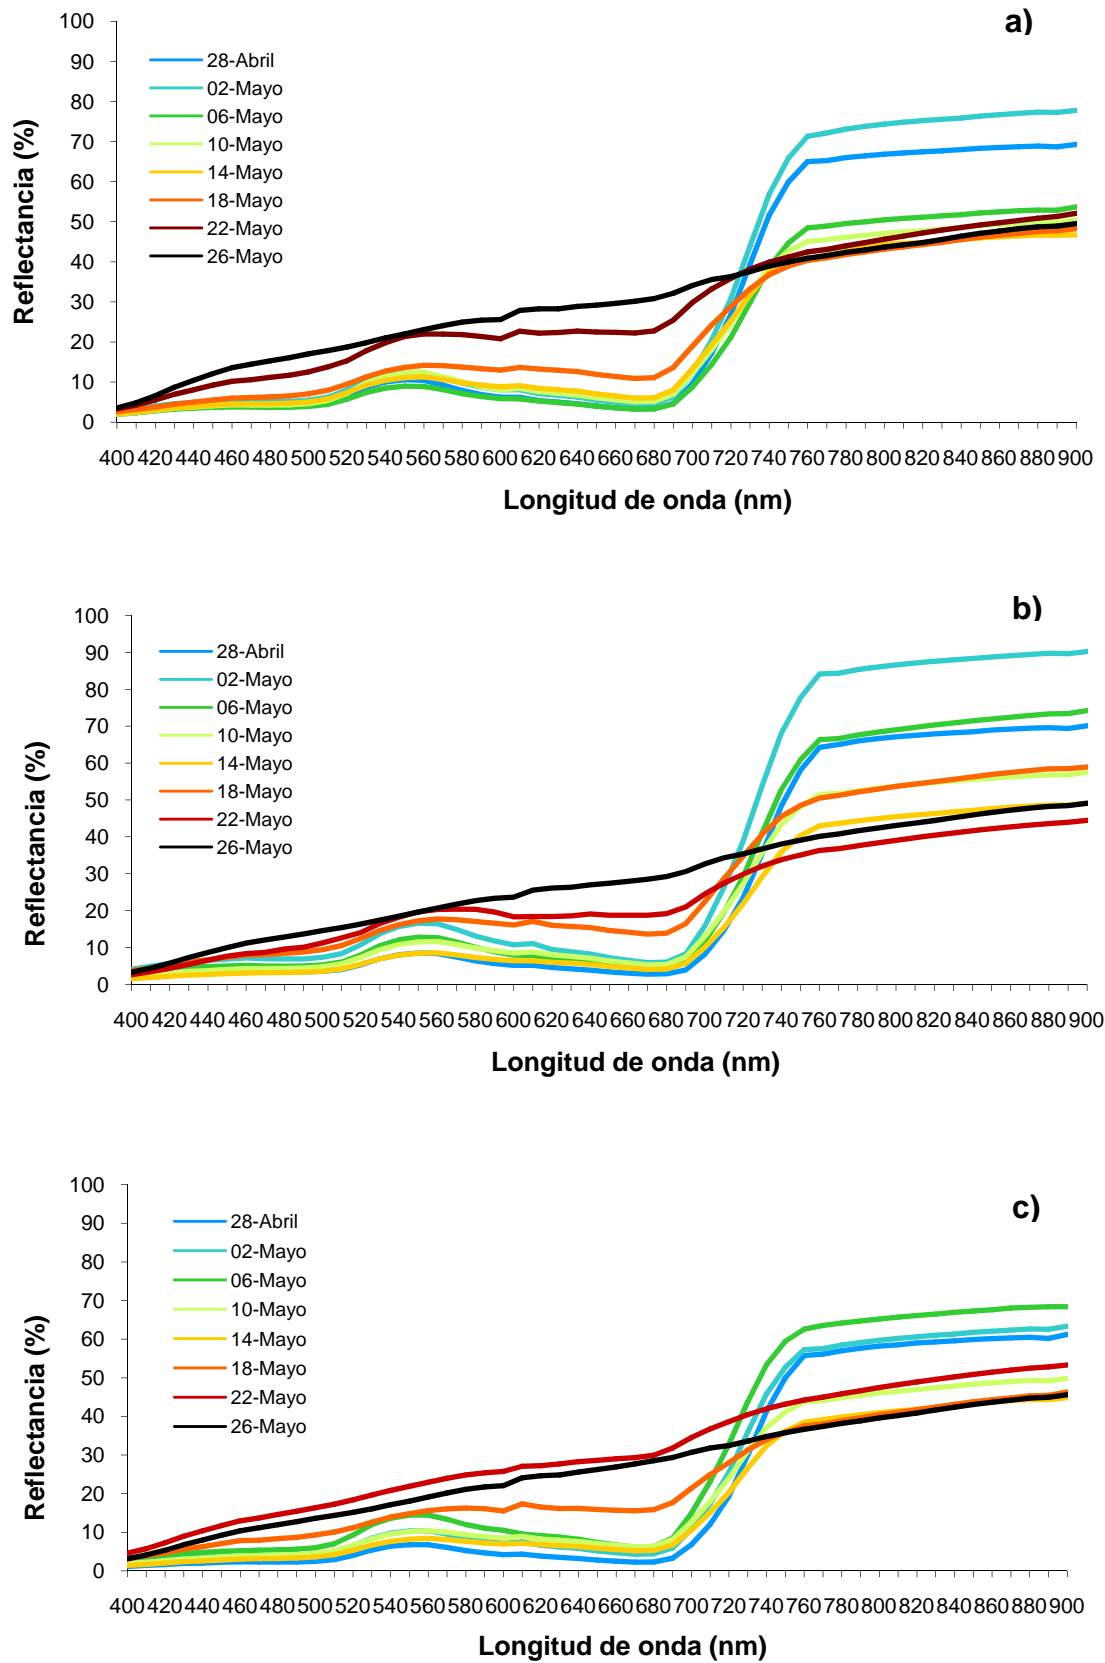


Figura 3.4: Curvas de reflectancia media de (a) Avena loca, (b) Alpiste y (c) Trigo en las diferentes fechas de muestreo.

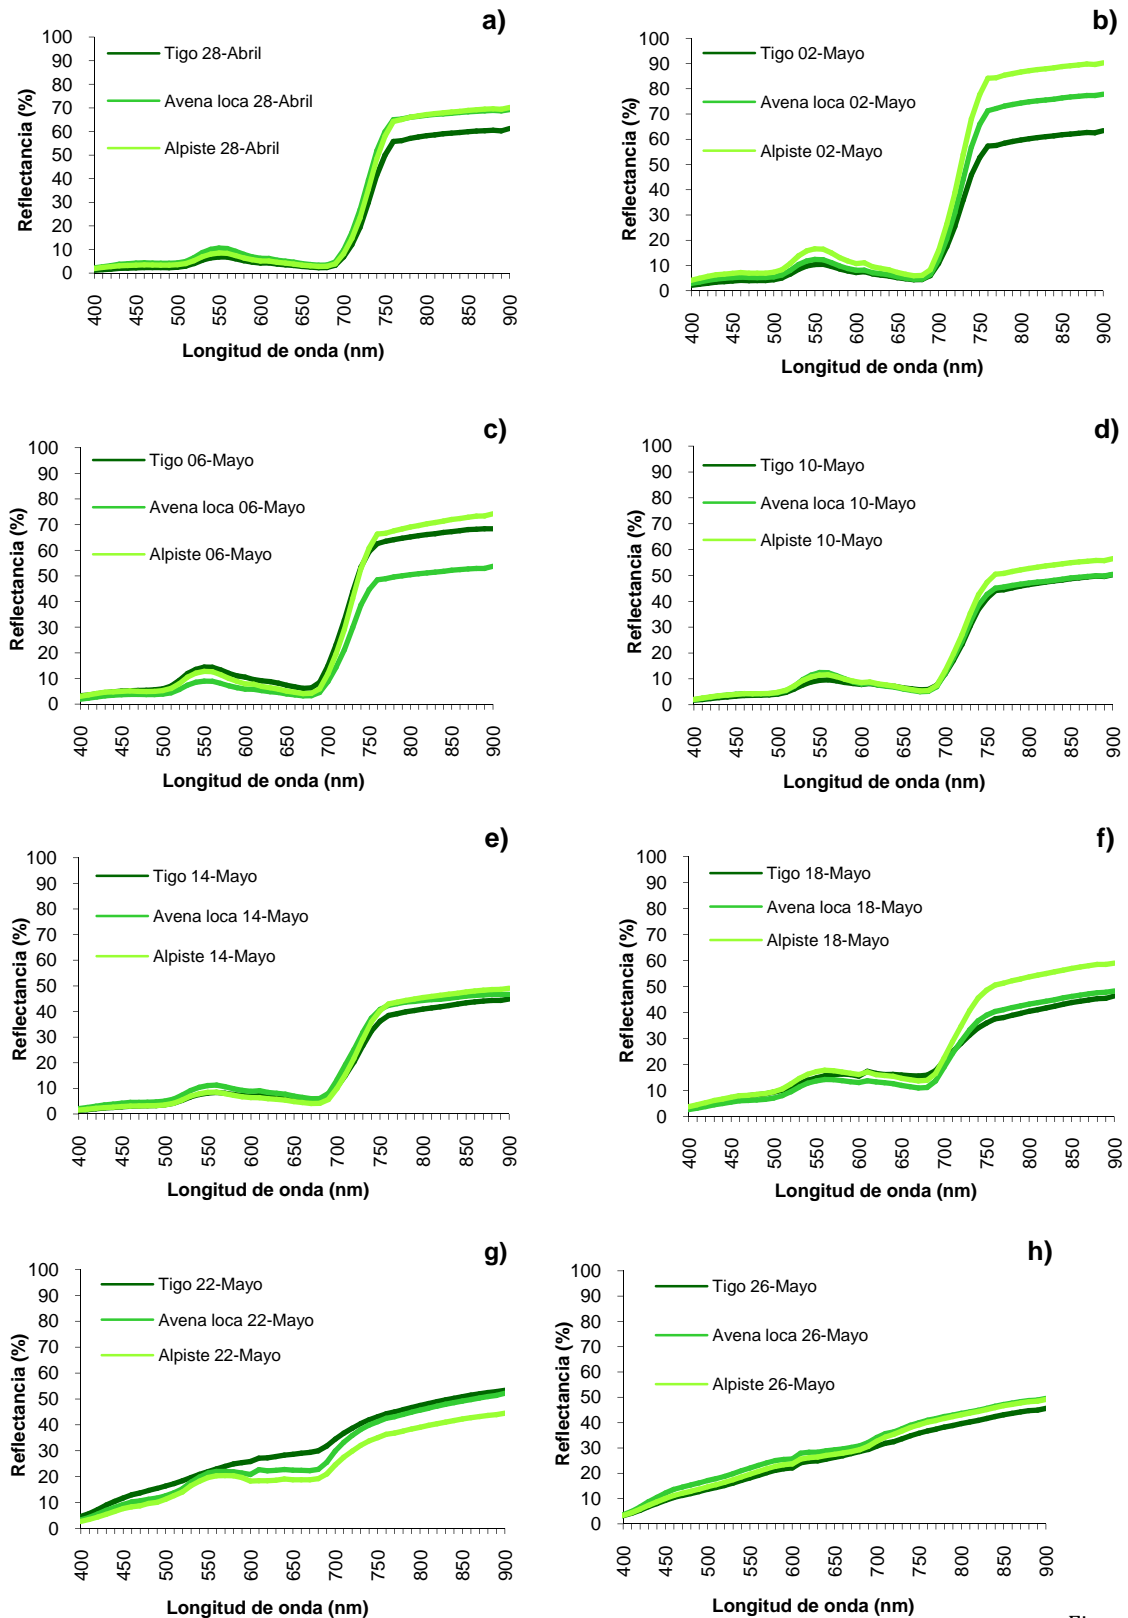


Figura 3.5: Curvas de reflectancia media de avena loca, alpiste y trigo en función de las fechas de muestreo: a) 28-Abril, b) 2-Mayo, c) 6-Mayo, d) 10-Mayo, e) 14-Mayo, f) 18-Mayo, g) 22-Mayo, y h) 26-Mayo.

En la Tabla 3.2 se muestran los resultados de las clasificaciones de cultivo y malas hierbas obtenidas a partir del modelo de análisis discriminante para un conjunto de distintas longitudes de onda que fueron elegidas en base al orden de entrada en el procedimiento de selección discriminante *stepwise*. Para desarrollar cada una de las funciones discriminantes que permitieran separar los espectros en los diferentes escenarios considerados, se seleccionaron un número de longitudes de onda que oscilaron entre 2 y 11. En el escenario 1, donde se clasificó el trigo, la avena loca y el alpiste, se llegó a obtener un porcentaje de precisión en la discriminación de estas especies del 100% en el intervalo comprendido entre el 28 de abril y el 6 de mayo. En esas fechas, la longitud de onda que más frecuentemente se seleccionó fue 420nm. Las longitudes de onda incluidas en el intervalo azul y en el intervalo infrarrojo cercano se seleccionaron nueve y siete veces respectivamente, y la región comprendida entre 800-900nm no llegó a ser elegida en ninguno de los modelos discriminantes para esas fechas. Los datos tomados en el intervalo de muestreo del 10 al 18 de mayo ofrecieron resultados algo inferiores, aunque todavía mostraron precisiones altas con más del 98% de fiabilidad global. El modelo discriminante correspondiente a 26 de mayo fue el que resultados menos satisfactorios obtuvo, equivocando en un 13.3% la discriminación de los espectros y, por consiguiente, consiguiendo un 86.7% de precisión en la discriminación espectral.

Cuando en el análisis del escenario 2 se redujo la complejidad al considerar sólo trigo y malas hierbas (valores espectrales conjuntos de avena loca y alpiste), también se alcanzó una tasa de discriminación del 100% en el intervalo de tiempo comprendido entre el 28 de abril y el 6 de mayo, junto con los datos muestreados el 22 de mayo, siendo las longitudes de onda 420 y 720nm las seleccionadas más a menudo. De las 50 longitudes de onda analizadas, se eligieron un total de 12 para los análisis, volviéndose a observar que ninguna de las longitudes presentes en el rango de los 800-900nm fue elegida en alguno de los modelos. El modelo discriminante correspondiente al 14 de mayo obtuvo los peores resultados, discriminando correctamente sólo el 88.3% de los espectros y fallando un 11.7% de las discriminaciones.

En el análisis en el que sólo se pretende discriminar el trigo y la avena loca, escenario 3, se obtuvo una capacidad de discriminación máxima en seis de las ocho fechas analizadas, con un 100% de fiabilidad global. Esta precisión se alcanzó con los datos del 28 de abril y 6, 10, 14, 18 y 26 de mayo. Debido a este número tan importante de fechas de muestreo favorables, el número de longitudes de onda elegidas fue también mayor, siendo 400, 420, 450, 490, 500, 510 690, 700 y 730 nm las más elegidas. En este caso, de las 50 longitudes de onda analizadas, se eligieron 28, llegando a analizar cinco longitudes en el rango de 800-900nm.

Finalmente, en el escenario 4 donde se analizó la discriminación entre trigo y alpiste, la capacidad de discriminación entre ambas especies también fue máxima (100%) en el periodo comprendido entre el 28 de abril hasta el 6 de mayo. En estas fechas de muestreo, las longitudes de onda que fueron seleccionadas con más frecuencia pertenecían al rango de azul, de 400 a 460nm, y al rango del rojo, de 600 a 680nm. En total se tomaron para estos análisis 11 de las 50 muestras analizadas.

En todos los escenarios estudiados, el valor mínimo (el más cercano a 0) de lambda de Wilks se obtuvo cuando existía una mayor separabilidad espectral entre espectros, mostrando el poder de discriminación de cada conjunto de longitudes de onda seleccionadas. En general, estos últimos se encontraron dentro de los rangos espectrales de visible e infrarrojo cercano, aunque se seleccionaron más frecuentemente los de la región del visible que los de la región del infrarrojo cercano. Teniendo en cuenta los cuatro escenarios de clasificación, las tres fechas más apropiadas (ordenadas en orden decreciente) fueron el 28 de abril = 6 de mayo > 2 de mayo, momento en el que el estado fenológico de las malas hierbas mostraba el inicio de la maduración de las semillas y el del trigo un estado de maduración de las semillas avanzando. En esas fechas de muestreo, algunos rangos de longitudes de onda fueron cruciales para la correcta discriminación del trigo, la avena loca y el alpiste. Entre las longitudes de onda que más frecuentemente se eligieron para la discriminación de las tres especies se destaca el rango desde 420 a 460 nm en la región del azul, del rango desde 560 a 580 nm en la región del verde, el rango desde 620 a 650 en la región del rojo y el rango desde 700 a 740 nm en la región del infrarrojo cercano. En general no se observaron grandes diferencias entre los resultados globales de la clasificación obtenidos mediante el análisis discriminante *stepwise* y los obtenidos por validación cruzada, lo que indicó que los modelos de clasificación fueron validados.

Tabla 3.2: Resultados del análisis discriminante sobre los datos hiperespectrales para avena loca, alpiste y trigo de acuerdo a diferentes escenarios de clasificación.

Escenarios de clasificación	Fechas de muestreo		Longitudes de onda (nm)	Lambda de Wilk	F-Exacta	Fiabilidad Global (%)	Validación cruzada (%)	
Trigo-Avena loca-Alpiste	Abril	28	450, 420, 620, 400, 700, 580	0.003	72.7	100	100	
		Mayo	2	730, 740, 760, 770, 610, 620, 700, 420, 560, 450, 430	0.007	77.1	100	100
			6	460, 470, 740, 420, 580, 650	0.019	54.8	100	100
			10	550, 570, 690, 530, 480, 470, 730, 420	0.044	23.6	98.3	96.7
			14	460, 680, 900, 490, 780, 520, 420, 720	0.027	31.8	98.3	95
			18	790, 550, 530, 750, 470, 630, 420	0.123	25	98.3	88.3
			22	690, 650, 680, 900	0.086	33	91.8	90.2
			26	450, 500, 420, 520	0.142	22.4	86.7	83.3
Trigo-Malas hierbas	Abril	28	420, 660, 690	0.175	42.5	100	96.8	
		Mayo	2	770, 760, 620, 700, 470, 420	0.100	79.7	100	100
			6	680, 460, 760, 420	0.122	98.1	100	100
			10	680, 460, 740, 450, 730	0.266	29.8	93.3	91.7
			14	410, 680, 690, 740	0.429	18.3	88.3	85
			18	460, 540, 400, 410	0.230	46	96.7	93.3
			22	680, 640, 760, 600	0.208	53.2	100	98.4
			26	680, 650, 610	0.399	28.1	91.7	86.7
Trigo - Avena loca	Abril	28	450, 420, 620, 510, 700, 400	0.007	336.5	100.	100	
		Mayo	2	770, 800	0.243	57.6	90	90
			6	690, 470, 890, 420, 610	0.065	97.3	100	100
			10	550, 690, 730, 510, 760, 480, 490, 870, 400	0.065	47.6	100	100
			14	500, 430, 490, 460, 900, 730, 410	0.064	67.2	100	100
			18	700, 710	0.161	96.2	100	100
			22	680, 650, 810	0.269	32.6	95	90
			26	450, 500, 530, 420	0.159	46.2	100	95
Trigo - Alpiste	Abril	28	400, 670, 680, 410, 500, 660	0.035	64.9	100	100	
		Mayo	2	420, 890, 850	0.078	140.9	100	100
			6	680, 460, 780, 420	0.115	67.1	100	100
			10	420, 680, 400, 870, 760	0.258	19.5	97.5	92.5
			14	680, 510, 440, 560	0.202	34.5	97.5	95
			18	460, 540, 450	0.222	42	97.5	97.5
			22	710, 580	0.333	38	97.6	95.1
			26	760, 800, 610, 720	0.477	9.6	87.5	82.5

### 4.2. Análisis multiespectral y multitemporal con índices de vegetación

La Figura 3.6 muestra las curvas de reflectancia media de avena loca, alpiste y trigo obtenidas en distintas fechas de muestreo en cuatro bandas espectrales equivalentes a las bandas multiespectrales presentes en el satélite QuickBird. Aparentemente tanto el trigo como la avena loca o el alpiste presentan diferencias apreciables en los valores de reflectancia mostrados en las cuatro bandas multiespectrales en las diferentes fechas muestreadas, lo que muestra el potencial que existe para separar estas tres especies gramíneas. Por tanto, la información espectral procedente de ciertas bandas del visible o del infrarrojo cercano podrían ser útiles en la discriminación de trigo, avena y alpiste en determinados estados fenológicos y fechas de muestreo. Sin embargo, puesto que las diferencias espectrales pueden llegar a ser muy pequeñas en algunos casos, sería aconsejable el uso de índices de vegetación para realzar dichas diferencias cuando fueran poco marcadas.

Al igual que se hizo con el análisis de los datos hiperespectrales, con los datos multiespectrales se utilizó el análisis discriminante *stepwise* para identificar las bandas multiespectrales o los índices de vegetación que mejor permitieran identificar las variaciones de las firmas espectrales para cada especie gramínea. La Tabla 3.3 muestra las bandas espectrales y los índices de vegetación seleccionados para cada uno de los cuatro escenarios de clasificación considerados. En el estudio, para desarrollar cada una de las funciones discriminantes que permitieran separar los espectros en los diferentes escenarios considerados, se seleccionaron un número de bandas o índices que oscilaron entre 1 y 7. En los análisis del escenario 1, donde se consideraron cada una de las tres especies de forma independiente, se obtuvieron precisiones en las clasificaciones del 100% para las fechas 28 de abril y 6 de mayo. En esas dos fechas el trigo se encontraba en estado fenológico de avanzada maduración con planta parcialmente verde y las malas hierbas en estado inicial de maduración con planta verde. Las bandas seleccionadas como mejores para estos análisis fueron las 4 bandas multiespectrales (A, V, R e IRc) y el índice de vegetación IRc-R. Los datos muestreados el resto de los días obtuvieron peores resultados, presentando los valores más bajos el día 10 de mayo con una precisión en la clasificación del 70% y el 18 de mayo con una precisión del 83.3%. Aún así, y al igual que ocurrió con el análisis hiperespectral, esta evaluación fue muy interesante ya que permitió la discriminación de las tres especies vegetales con una precisión entre el 95% y el 100% en la mayoría de las fechas estudiadas, (excepto el 10 y 18 de mayo).

## Discriminación espectral multitemporal de avena loca y alpiste en campos de trigo en fase tardía

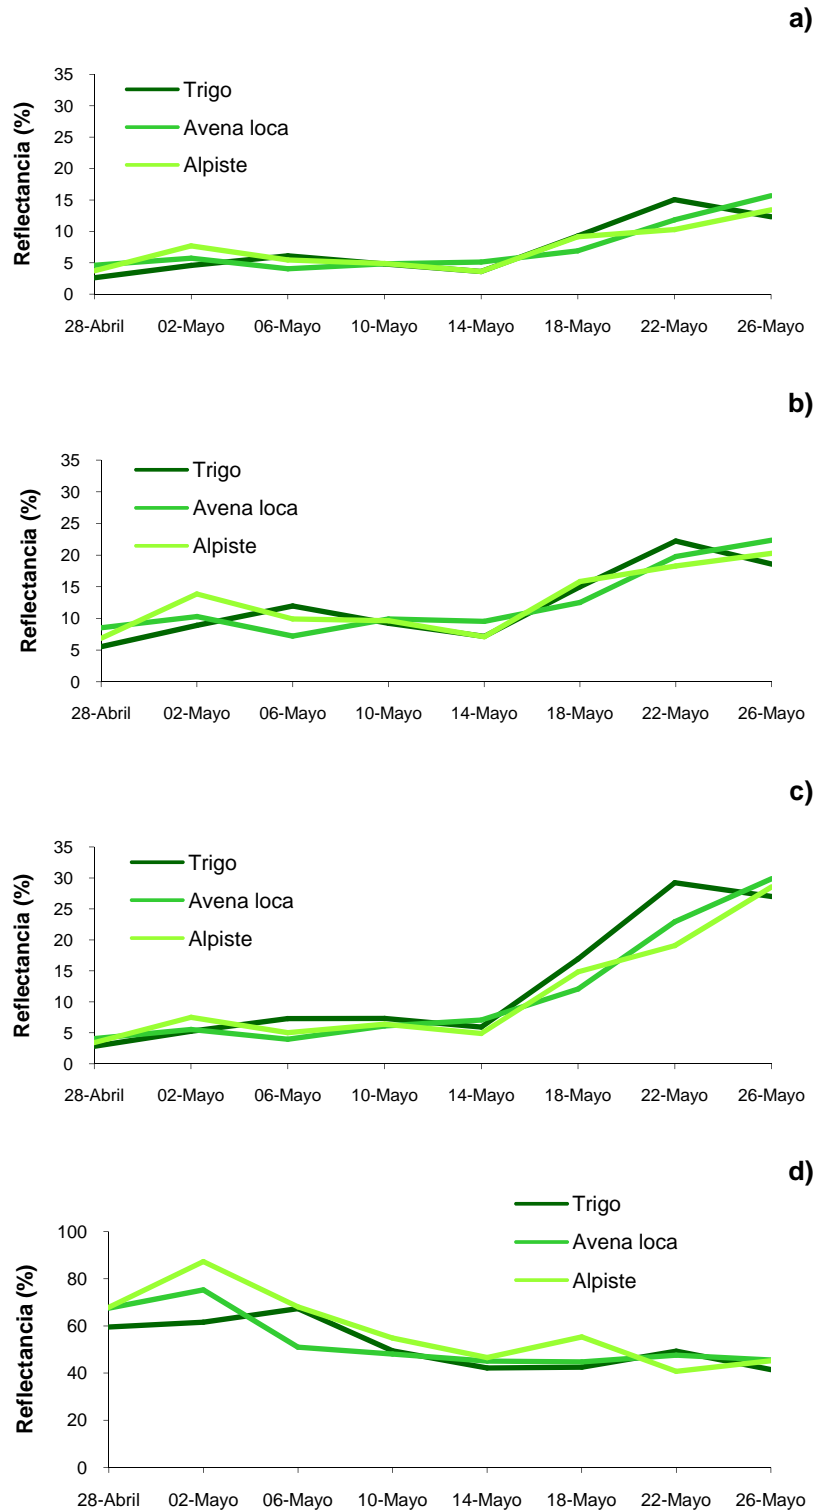


Figura 3.6: Curvas de reflectancia media de avena loca, alpiste y trigo en función de las fechas de muestreo para las bandas espectrales: a) Azul, b) Verde, c) Rojo y d) Infrarrojo cercano.



En el análisis realizado considerando el escenario 2, el cual se compone de los grupos trigo y malas hierbas, se obtuvieron porcentajes de discriminación superiores al 98% en todas las fechas de muestreo. Los mejores resultados de clasificación, que alcanzaron una precisión del 100%, se obtuvieron con los datos tomados entre los días 28 de abril y 6 de mayo y entre los días 10 y 18 de mayo. En el periodo del 28 de abril al 6 de mayo se seleccionaron como mejores bandas para la discriminación las cuatro bandas espectrales (A, V, R e IRc) así como 4 de los 5 índices espectrales introducidos en el análisis ( $R/B$ ,  $NDVI = (IRc-R/IRc+R)$ ,  $RVI = (IRc/R)$  y  $IRc-R$ ). Sin embargo, entre el 10 y 18 de mayo sólo se seleccionaron 3 de las 4 bandas multiespectrales (A, V e IRc) y 3 de los cinco índices de vegetación ( $NDVI$ ,  $R/B$  y  $(R-G/R+G)$ ).

En las clasificaciones donde sólo se clasificaron el trigo y la avena loca, escenario 3, se obtuvieron precisiones del 100% en cuatro fechas de muestreo: 28 de abril y 6, 22 y 26 de mayo. En estos casos se necesitaron menos bandas para obtener el máximo de precisión en la discriminación entre trigo y avena loca. Así, para los datos del 28 de abril fueron necesarias sólo 2 bandas multiespectrales (A y R), mientras que para los datos del 6 de mayo se necesitó una sola banda multiespectral (R) y un índice de vegetación ( $IRc-R$ ). Este mismo índice de vegetación ( $IRc-R$ ) fue la única banda seleccionada para el análisis del día 22 de mayo mientras que el índice ( $R/A$ ) fue el único seleccionado para el día 26 de mayo. El resto de fechas de muestreo obtuvieron unos valores de clasificación superiores al 92% excepto el 10 de mayo, donde se observó un grado de error del 42.5% y, por tanto, una precisión en la clasificación de sólo el 57.5%.

Finalmente, en el escenario 4 donde se analizó la capacidad de discriminación del trigo y el alpiste, las mejores clasificaciones con precisiones del 100% se obtuvieron en los muestreos del 28 de abril al 6 de mayo. Estos análisis mostraron que las bandas más adecuadas para el estudio eran las 4 bandas multiespectrales (A, V, R e IRc) y el índice de vegetación RVI. En este periodo de tiempo, el estado fenológico del trigo era de avanzada maduración con planta parcialmente verde y el alpiste se encontraba en estado inicial de maduración con planta verde. El resto de fechas obtuvieron precisiones en la discriminación bastante aceptables (con fiabilidades superiores al 97%), excepto en los días 10 y 18 de mayo donde se obtuvieron precisiones del 75% y del 87.5%, respectivamente.

En todos los escenarios estudiados se alcanzaron valores de lambda de Wilks muy bajos (cerca de 0) cuando se observó una separabilidad espectral muy alta entre especies, lo que indicó la capacidad de discriminación de cada grupo de bandas multiespectrales o índices de vegetación elegidos. En general, considerando los 4 escenarios de clasificación, en casi todos los casos se seleccionaron las cuatro bandas multiespectrales para los análisis, aunque las bandas pertenecientes al visible (A, V y R) fueron elegidas más frecuentemente que la banda del infrarrojo cercano (IRc). En cuanto a los índices, éstos fueron incorporados a los análisis en la mayoría de las ocasiones, siendo todos los índices muy utilizados excepto el índice ( $R-V/R+V$ ) que sólo se seleccionó en 3 ocasiones. Por otra parte, al igual que ocurrió con el análisis hiperespectral, las tres fechas más apropiadas para la discriminación de estas gramíneas fueron, en orden decreciente, el

28 de abril = 6 de mayo > 2 de mayo. En todo este periodo, el trigo se encuentra en un estado avanzado de maduración con la planta parcialmente verde mientras que las dos especies de malas hierbas se encuentran en un estado inicial de maduración con la planta verde. Sin embargo, los últimos estados fenológicos analizados mostraron una disminución general en la capacidad de discriminación. Finalmente, no se observaron grandes diferencias entre las precisiones de las clasificaciones obtenidas mediante el análisis discriminante *stepwise* y las obtenidas mediante validación cruzada, lo que muestra el alto grado de precisión de los modelos de clasificación.

Tabla 3.3: Resultados del análisis discriminante sobre bandas multispectrales e índices de vegetación con diferentes escenarios de clasificación.

Escenarios de clasificación	Fechas de muestreo		Bandas multispectrales e índices de vegetación	Lambda de Wilks'	F-Exacta	Fiabilidad Global (%)	Validación cruzada (%)
Trigo-Avena loca-Alpiste	Abril	28	B, G, NIR, R	0.002	16.4	100	86.7
		2	NDVI, G, NIR, RVI, B	0.047	48.7	98.3	98.3
	Mayo	6	NIR-R, R, B, NIR, G	0.003	196	100	100
		10	R, G, NIR	0.351	12.625	70	70
		14	R/B, R	0.030	133.5	95	96.7
		18	NDVI, NIR, RVI	0.195	23.2	83.3	81.7
		22	NIR-R, R, B, NIR	0.002	274.2	98.3	98.3
		26	R/B	0.003	8421.7	98.3	98.3
Trigo-Malas hierbas	Abril	28	R/B, G, NIR, R	0.000	14578	100	100
		2	R/B, NDVI, NIR, RVI	0.003	5294.1	100	100
	Mayo	6	R/B, NIR-R, B, R, NIR, G, RVI	0.096	70.1	100	100
		14	(R-G)/(R+G), NIR-R	0.071	370.5	98.3	100
		10	R/B, NIR	0.036	758.026	100	100
		18	(R-G)/(R+G), B, G, NIR, NDVI	0.023	22.8	100	100
		22	R/B, NDVI, R	0.060	295	98.3	100
		26	NIR-R, R/B	0.071	370.5	98.3	100
Trigo-Avena loca	Abril	28	B, R	0.123	60.5	100	95
		2	NDVI	0.297	89.1	92.5	92.5
	Mayo	6	NIR-R, R	0.027	677.6	100	100
		10	RVI	0.882	5	57.5	57.5
		14	R/B	0.070	507.5	97.5	100
		18	RVI, B, G, NIR, NDVI	0.143	40.9	97.5	95
		22	NIR-R	0.007	5179.6	100	100
		26	R/B	0.004	9956.6	100	100
Trigo-Alpiste	Abril	28	B, R	0.124	60.2	100	100
		2	B, RVI	0.089	188.3	100	100
	Mayo	6	B, R, NIR, G, RVI	0.112	54.2	100	97.5
		10	NDVI	0.774	11.121	75.0	75.0
		14	R/B	0.095	361	97.5	100
		18	NDVI	0.478	41.4	87.5	85
		22	R/B, R	0.078	219.6	97.5	100
		26	(R-G)/(R+G)	0.095	361	97,5	100

## 5. Discusión

Las curvas de reflectancia hiperespectral del trigo, la avena loca y el alpiste se han visto afectadas por el estado fenológico de las plantas. Pese a que la forma general de las firmas espectrales era similar, las curvas presentaron diferencias significativas de magnitud que permitieron su diferenciación (Fig. 3.1). Las diferencias en las respuestas hiperespectrales entre trigo, avena loca y alpiste se pueden atribuir a las variaciones en las cantidades relativas del contenido de clorofila, agua y la proporción de aire presente en las células, variables que afectan directamente en las propiedades espectrales de la vegetación (Price, 1994; Zwigelaar, 1998; Smith y Blackshaw, 2003). Schmidt y Skidmore (2003) demostraron que las diferencias de reflectividad existentes de la región del espectro del verde (pico verde) son importantes para la discriminación de distintos tipos de vegetación que se caracteriza por variaciones en su contenido de clorofila, mientras que las diferencias de reflectividad existentes en la región del infrarrojo cercano sirven para discriminar entre tipos de vegetación que presentarán diferencias en la estructura de la copa o geometría de la planta. Por tanto, la presencia o ausencia del pico del verde así como la obtención de valores altos o bajos en la región del infrarrojo cercano podría proporcionar un medio de discriminación mediante técnicas de teledetección, permitiendo el mapeo de estas especies en diferentes estados fenológicos (Peña-Barragán *et al.*, 2006).

Las variaciones en el comportamiento reflectivo de las tres especies gramíneas a lo largo del tiempo de estudio puede atribuirse a diferencias estructurales de las plantas debidas a las diferencias en el tiempo y duración de cada uno de sus estados fenológicos, los cuales presentan un estado según en el orden: trigo > avena loca = alpiste. Por ejemplo, cuando se analizaron las fechas del 22 al 26 de mayo se observó que tanto el trigo como las malas hierbas se encontraban en un cierto grado de senescencia, lo que se pudo constatar porque los valores de reflectancia crecían de forma constante, no exhibiendo ningún pico o incremento de reflectancia en la región del verde o del infrarrojo cercano. Estos resultados coinciden con los datos obtenidos previamente por otros investigadores (Rew *et al.*, 1996; Koger *et al.*, 2003;), los cuales discriminaron infestaciones de malas hierbas tardías cuando la diferencia espectral entre los cultivos y las malas hierbas prevaleció como por ejemplo, cuando se observaron malas hierbas verdes presentes en cultivos de cereal senescente o antes de que los cultivos y las malas hierbas estuvieran simultáneamente senescentes y tornando a amarillos.

El análisis estadístico realizado mediante el análisis discriminante *stepwise* obtuvo distintas combinaciones de longitudes de onda en función de los escenarios de clasificación considerados. El primer escenario de clasificación, en el que las firmas espectrales del trigo, avena loca y alpiste se consideraron como clases independientes, mostró los porcentajes de clasificación más altos entre el 28 de abril y el 6 de mayo en la región del espectro del visible e infrarrojo cercano, siendo las regiones del azul y la del infrarrojo las más frecuentes. Esta primera clasificación fue la más compleja y resulta de interés en los casos en los que avena y alpiste están presentes en el cultivo y es necesario un reconocimiento preciso de ambas especies (Cussans, 1995). Este escenario ocurre

cuando es necesario aplicar un herbicida avenicida, unos de los productos fitosanitarios más caros del mercado.

En el análisis del segundo escenario de clasificación, donde la dos especies de malas hierbas se agruparon en una única categoría, las mejores precisiones en las clasificaciones se obtuvieron en el mismo periodo que en el escenario 1 (del 28 de abril al 6 de mayo) y en la fecha del 26 de mayo. Aquí también se eligieron principalmente las regiones del espectro del azul y del infrarrojo cercano. La discriminación entre trigo y malas hierbas fue efectiva teniendo en cuenta que existe una mezcla de poblaciones de malas hierbas y que pueden ser controlada con un determinado tipo de herbicida (Borregaard *et al.*, 2000).

Sin tener en cuenta las firmas espectrales de entrada, en general el intervalo de longitudes de onda que oscila entre los 690-760nm ha sido mostrado por algunos autores como el decisivo para la discriminación de vegetación (Cochrane, 2000; Smith y Blackshaw, 2003). Este intervalo entra dentro de la región del espectro conocida como borde del rojo (*red edge*), situada en el límite entre la región del rojo donde se produce absorción debido a los pigmentos de clorofila y la región del infrarrojo cercano donde se observa un aumento destacado de reflexión debido a la estructura de la hoja. El punto exacto donde se encuentra en la región del rojo depende de la concentración de clorofila de cada planta (Munden *et al.*, 1994). Distintos investigadores han mostrado resultados similares en discriminaciones de diferentes especies de malas hierbas en cultivos (Borregaard *et al.*, 2000; Vrindts *et al.*, 2000; Goel *et al.*, 2003; Girma *et al.*, 2005; López-Granados *et al.*, 2006; Peña-Barragán *et al.*, 2006). El número de longitudes de onda significativas para el estudio varió en función de la fecha (Karimi *et al.*, 2005a), lo cual viene corroborado con la idea de que la longitud de onda correcta (borde del rojo) depende de la concentración de clorofila en cada momento (Munden *et al.*, 1994), que variará en función del estado fenológico de la planta (Girma *et al.*, 2005; Peña-Barragán *et al.*, 2006).

Para concluir, los resultados de este estudio han mostrado que pueden ser utilizados como una guía para crear una librería espectral de datos tomados en campo del cultivo del trigo y de las malas hierbas más importantes asociadas a él en estados fenológicos tardíos, desde la maduración hasta la senescencia. Los resultados muestran que existen diferencias espectrales significativas entre avena loca, alpiste y trigo en los periodos fenológicos tardíos, lo que puede ser utilizado para estudios con toma de imágenes. El estudio hiperespectral puede dar lugar a oportunidades para el uso de sensores hiperespectrales aeroportados. Así, mediante el análisis de los resultados obtenidos se pueden determinar las longitudes de onda y el momento fenológico de las especies más propicio para la adquisición de las imágenes, que facilite una correcta clasificación entre trigo y las malas hierbas. Actualmente, los sensores hiperespectrales aeroportados como el Compact Airborne Spectral Imager (CASI) son capaces de adquirir datos de 288 longitudes de onda en un rango espectral entre 400 a 1000nm, a partir de la configuración de toma de los datos programada por el propio usuario. Por lo tanto, una vez que se ha mostrado que los análisis discriminantes de datos tomados en campo son

prometedores para la clasificación de las firmas espectrales de avena loca, alpiste y trigo, investigaciones futuras podrían centrarse en analizar el potencial de análisis de las imágenes CASI tomadas en el momento fenológico más adecuado para su discriminación. Para este objetivo, el sensor CASI debería ser programado con 13 longitudes de onda para cada una de las regiones del azul (420-460nm), verde (560-580nm), rojo (620-650nm) e infrarrojo cercano (700-740nm), en lugar de las 288 longitudes de onda posibles. Sin embargo, este tipo de imágenes siguen siendo excesivamente caras debido a los costos de operación. La falta de compañías aéreas que ofrezcan productos económicos hace que estos análisis sean demasiado caros para agricultores o consultores que requiera información de parcelas individuales.

Actualmente, el uso de imágenes multispectrales de alta resolución espacial obtenidas mediante satélites comerciales presentan una alternativa mucho más barata y factible para el estudio y mapeo a gran escala de infestaciones de malas hierbas en cultivos. Por ejemplo, para el mapeo de avena loca en trigo se admitiría potencialmente el uso de imágenes multispectrales del satélite QuickBird, las cuales presentan una resolución espacial de 2.8m, debido a que el tamaño mínimo de los rodales de esta mala hierba ronda los 50m (Barroso *et al.*, 2004a). Partiendo de los datos obtenidos con el análisis multitemporal de los datos, basado en la agrupación de longitudes de onda hiperespectrales equivalentes a las longitudes de onda presentes en las bandas del satélite comercial QuickBird, se observó que la discriminación en estados fenológicos tardíos entre trigo, avena loca y alpiste también era factible debido a las diferencias de los ciclos de vida de las distintas especies que provocan variaciones en su comportamiento (Curran, 1985; Thompson *et al.*, 1991). Como se observó en el estudio hiperespectral, las diferencias en los porcentajes de clasificación de los datos obtenidos en diferentes fechas de muestreo se debió a cambios en la estructura de las plantas debido a las diferencias fenológicas. Los cambios de las características texturales de las plantas debidos a los diferentes grados de maduración que presenten provoca cambios significativos en los patrones de reflectividad de las malas hierbas (Burks *et al.*, 2002; Noble *et al.*, 2002). Así, Peña-Barragán *et al.* (2007) mostró que la discriminación eficiente de *Ridolfia segetum* en cultivo de girasol estaba influenciada directamente por su momento fenológico con el siguiente orden: floración > senescencia > estado vegetativo.

Junto a las cuatro bandas analizadas, equivalentes a las bandas multispectrales presentes en el satélite QuickBird, en el análisis se introdujeron cinco índices de vegetación. Estos mostraron su capacidad de realzar las diferencias espectrales entre las distintas especies vegetales, centrando su esfuerzo en aquellas regiones del espectro donde existió más contraste debido a la actividad de la vegetación. El análisis discriminante *stepwise* realizado sobre las cuatro bandas espectrales así como sobre los cinco índices de vegetación obtuvo distintas combinaciones de bandas/índices en función de los escenarios de clasificación considerados. El escenario de clasificación donde las firmas espectrales de trigo, avena loca y alpiste se consideraron como clases independientes (escenario 1) mostró los porcentajes de clasificación más altos el 28 de abril y el 6 de mayo, eligiendo como combinaciones más adecuadas las cuatro bandas del espectro. Resultados parecidos se obtuvieron en la discriminación de avena loca, alpiste y

vallico en cultivo de trigo mediante la aplicación de redes neuronales a información multiespectral obtenida en una única fecha de muestreo (López-Granados *et al.*, 2008).

En el análisis del segundo escenario de clasificación, donde las dos especies de malas hierbas se agruparon en una única categoría, se observó un aumento significativo de la precisión en las clasificaciones respecto a las clasificaciones de las tres especies por separado. Esta agrupación permitió obtener un valor mínimo de precisión del 98.3% los días 14, 22 y 26 de mayo, obteniendo en el resto de los análisis un 100% de fiabilidad. De acuerdo con Yang *et al.* (2002) y López-Granados *et al.* (2008) este pequeño aumento general en la precisión al considerar en la clasificación sólo las categorías malas hierbas y trigo se puede deber al hecho de que al agrupar las dos especies de malas hierbas es una única clase, se aumenta el número de firmas espectrales que representan a esa categoría en el proceso de discriminación respecto a la clase trigo.

Finalmente, en los análisis de los escenarios 3 y 4, donde se analizó la capacidad de discriminación entre trigo y avena loca o alpiste por separado, se necesitaron menos bandas e índices de vegetación para conseguir discriminaciones precisas entre especies. Esto es debido a que las diferencias fenológicas entre cada una de las malas hierbas y el trigo son más evidentes que cuando se agrupan las dos especies de malas hierbas en una única categoría (escenario 2).

Sin tener en cuenta las firmas espectrales de entrada, en general las cuatro bandas del espectro, así como todos los índices de vegetación excepto el  $(R-V/R+V)$  fueron muy útiles para la discriminación de malas hierbas en trigo con información multiespectral. Pese a que los tres índices de vegetación más usados en el análisis, (NDVI, RVI e  $(IRc-R)$ ), se centraron en el análisis de las diferencias espectrales generales propias de la vegetación (diferencias entre la banda roja y la infrarroja cercana), el índice que más veces se utilizó fue el  $(R/A)$ .

Como conclusión del análisis multiespectral se puede indicar que determinados índices de vegetación así como información multiespectral equivalente a las bandas presentes en el satélite QuickBird permitieron la discriminación de avena loca y alpiste en campos de trigo en periodos fenológicos tardíos de igual forma que con el análisis hiperespectral. Debido al alto coste en la obtención de imágenes hiperespectrales, sería más recomendable realizar este tipo de estudios con imágenes multiespectrales adquiridas mediante sensores comerciales de alta resolución espacial con información espectral equivalente al satélite QuickBird, lo que se ha planteado como objetivo para el **capítulo 4** de esta Tesis Doctoral. En este sentido, las imágenes QuickBird ya han sido utilizadas con éxito en la detección de especies de plantas invasoras, tales como *Leucaena leucocephala* Lam. De Wit. (Tsai y Chou, 2006). Debido a que los satélites comerciales tienen fijada una determinada resolución temporal, para una correcta discriminación de dichas especies hay que controlar muy bien la fecha de la toma de datos. En este caso y tras observar que en todos los escenarios analizados la mejor fecha de discriminación se correspondió con el intervalo del 28 de abril al 6 de mayo, fechas bajo las condiciones

agrícolas de esa zona y ese año, se recomienda que dichas fechas podrían ser aproximadas para discriminaciones de dichas especies en condiciones de cultivos mediterráneos. De forma más general y teniendo en cuenta la producción de trigo en otras regiones, a partir de este trabajo se puede definir el momento fenológico más adecuado para el análisis. Este momento fenológico sería cuando la avena loca o el alpiste presentan un estado inicial de maduración y la planta se encuentra totalmente verde, y el trigo ya ha entrado en un estado avanzado de maduración y la planta está parcialmente amarilla.

Como conclusión general, se puede decir que este estudio ha mostrado que existen diferencias espectrales significativas para una detección precisa de avena loca, alpiste y trigo en épocas fenológicas tardías. Estas diferencias pueden ser analizadas teniendo en cuenta las regiones del espectro correspondientes al visible e infrarrojo cercano con análisis tanto hiperespectrales como multiespectrales. En el caso del análisis multiespectral, debido a que las bandas analizadas recogen de forma más grosera la información espectral, es recomendable la aplicación de índices de vegetación para realzar las diferencias en el comportamiento espectral de cada especie. En ambos estudios también se ha mostrado que el mejor momento fenológico para la discriminación de dichas especies se observó cuando las malas hierbas se encontraban en un estado inicial de maduración y la planta totalmente verde, y el trigo ya ha entrado en un estado avanzado de maduración y la planta está parcialmente amarilla.

## 6. Referencias

Barroso, J., Fernández-Quintanilla, C., Maxwell, B.D., Rew, L. 2004a. Simulating the effects of spatial weed pattern and resolution of mapping and spraying on economics of site-specific management. *Weed Research* 44, 460-468.

Barroso, J, Fernández-Quintanilla, C., Ruiz, D., Hernaiz, P., Rew, L. 2004b. Spatial stability of *Avena sterilis* ssp. *ludoviciana* under annual applications of low rates of imazamethabenz. *Weed Research* 44, 178-186.

Blanco-Moreno, JM, Chamorro, L., Sans, X. 2006. Spatial and temporal patterns of *Lolium rigidum*-*Avena sterilis* mixed populations in a cereal field. *Weed Research* 46, 207-218.

Borregaard, T., Nielsen, H., Norgaard, L., Have, H. 2000. Crop-weed discrimination by line imaging spectroscopy. *Journal of Agricultural Engineering Research* 75, 389-400.

Brown, R.B., Noble, S.D. 2005. Site-specific weed management: sensing requirements-what do we need to see?. *Weed Science* 53, 252-258.

Burks, T.F., Shearer, S.A., Green, J.D., Heath, J.R. 2002. Influence of weed maturity levels on species classification using machine vision. *Weed Science* 50, 802-811.



Chang, J., Clay, S.A., Clay, D.E., Dalsted, K. 2004. Detecting weed-free and weed-infested areas of a soybean field using near-infrared spectral data. *Weed Science* 52, 642-646.

Cochrane, M.A. 2000. Using vegetation reflectance variability for species level classification of hyperspectral data. *International Journal of Remote Sensing* 21, 2075-2087.

Curran, P.J. 1985. Aerial photography for the assessment of crop condition: a review. *Applied Geography*. 5, 347-360.

Cussans, G. 1995. Machine vision for weed identification. Informal Weed Detection Workshop, Silsoe Research Institute, Bedford, UK.

Elmore, A.J., Mustard, J.F., Manning, S.J., Lobell, D.B. 2000. Quantifying vegetation change in semiarid environments: precision and accuracy of spectral mixture analysis and the normalized difference vegetation index. *Remote Sensing of Environment* 73, 87-102.

Everitt, J.H., Villarreal, R. 1987. Detecting huisache (*Acacia farnesiana*) and Mexican palo-verde (*Parkinsonia aculeata*) by aerial photography. *Weed Science* 35, 427-432.

Felton, W.L., Alston, C.L., Haigh, C.B.M., Nash, P.G., Wicks, G.A., Hanson, G.E. 2002. Using reflectance sensors in agronomy and weed science. *Weed Technology* 16, 520-527.

Friedl, M.A., Brodley, C.E. 1997. Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment* 61, 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. *IEEE Transactions on Geoscience and Remote Sensing*. 37, 969-977.

Girma, K.J., Mosali, J., Raun, W.R., Freeman, K.W., Martin, K.L., Solie, J.B., Stone, M.L. 2005. Identification of optical spectral signatures for detecting cheat and ryegrass in winter wheat. *Crop Science* 45, 477-485.

Goel, P.K., Prasher, S.O., Patel, R.M., Landry, J.A., Bonnel, R.B., Viau, A.A. 2003. Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. *Computers and Electronics in Agriculture* 39, 67-93.

Hansen, P.M., Schjoerring, J.K. 2003. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sensing of Environment* 86, 325-337.

Hatfield, J.L., Pinter, J.R. 1993. Remote sensing for crop protection. *Crop Protection* 12, 403-413.

Jackson, R.D., Huete, A.R. 1991. Interpreting vegetation indices. *Preventive Veterinary Medicine* 11, 185-200.

Jordan, C.F. 1969. Derivation of leaf area index from quality of light on the forest floor. *Ecology* 50, 663-666.

Jurado-Expósito, M., López-Grabados, F., Atenciano, S., García-Torres, L. González-Andújar, J.L., 2003. Discrimination of weed seedlings, wheat (*Triticum aestivum*) stubble and sunflower (*Helianthus annuus*) by near-infrared reflectance spectroscopy (NIRS). *Crop Protection* 22, 1177-1180.

Jurado-Expósito, M., López-Granados, F., González-Andújar, J.L., García-Torres, L. 2004. Spatial and temporal analysis of *Convolvulus arvensis* L. populations over four growing seasons. *European Journal of Agronomy* 21, 287-296.

Jurado-Expósito, M., López-Granados, F., González-Andújar, J.L. and García-Torres, L. 2005. Characterizing population growth rate of *Convolvulus arvensis* L. in wheat-sunflower no-tillage systems. *Crop Science* 45, 2106-2112.

Karimi, Y, Prasher, S.O., McNaim, H., Bonnell, R.B., Dutilleul, P., Goel, P.K. 2005a. Discriminant analysis of hyperspectral data for assessing water and nitrogen stresses in corn. *Transactions of the American Society of Agricultural Engineers* 48, 805-813.

Karimi, Y, Prasher, S.O., McNaim, H., Bonnell, R.B., Dutilleul, P., Goel, P.K. 2005b. Classification accuracy of discriminant analysis, neural networks and decision trees for weed and nitrogen stress detection in corn. *Transactions of the American Society of Agricultural Engineers* 48, 1261-1268.

Kavdir, I. 2004. Discrimination of sunflower, weed and soil by artificial neural network. *Computers and Electronic in Agriculture* 44, 153-160.

Koger, H.K., Shaw, D.R., Watson, C.E., Reddy K.N. 2003. Detecting late-season weed infestations in soybean (*Glycine max*). *Weed Technology* 17, 696-704.

Koger, H.K., Shaw, D.R., Reddy K.N., Bruce, L.M. 2004. Detection of pitted morningglory (*Ipomea lacunosa*) with hyperspectral remote sensing. II. Effects of vegetation ground cover and reflectance properties. *Weed Science* 52, 230-235.

Lamb, D.W., Weedon, M.M., Rew, L.J. 1999. Evaluating the accuracy of mapping weeds in seedling crops using airborne digital imaging: *Avena* spp. in seedling triticale. *Weed Research* 39, 481-492.

Lancashire, P.D., Bleiholder, H., Van Den Doom T., Langelüddeke, P., Srauss, R., Weber, E., Witzemberger, A. 1991. A uniform decimal code for growth stages of crops and weeds. *Annals of Applied Biology* 119, 561-601.

Lass, L.W., Callihan R.H. 1997. The effect of phenological stage on detectability of yellow hawkweed (*Hieracium pratense*) and oxeye daisy (*Chrysanthemum leucanthemum*) with remote multispectral digital imagery. *Weed Technology* 11, 248-256.

López-Granados, F., Peña-Barragán, J.M., Jurado-Expósito, M., García-Torres, L. 2006. Using remote sensing for identification of late-season grassy weeds patches in wheat (*Triticum durum*) for precision agriculture. *Weed Science* 54, 346-353.

López-Granados, F., Peña-Barragán, J.M., Jurado-Expósito, M., Francisco-Fernández, M., Cao, R., Alonso-Betanzos, A., Fontenla-Romero, O. 2008. Multispectral classification of grass weeds and wheat (*Triticum durum*) crop using linear and nonparametric functional discriminant analysis, and neural networks. *Weed Research* 48, 28-37.

Munden, R., Curran, P.J. and Catt, A. 1994. The relationship between red edge and chlorophyll concentration in the Broadbalk winter wheat experiment at Rothamsted. *International Journal of Remote Sensing* 15, 705-709.

Noble, S.D., Brown, R.B., Grove, T.G. 2002. The use of spectral properties for weed detection and identification – a review. In: AIC Meeting, Saskatoon, SK., Canada. CSAE Paper No. 02-208. CSAE/SCGR, Mansonville, QC., Canada.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2006. Spectral discrimination of *Ridolfia segetum* and sunflower as affected by phenological stage. *Weed Research* 46, 10-21.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2007. Mapping *Ridolfia segetum* patches in sunflower crop using remote sensing. *Weed Research* 47, 164-172.

Price, J.C. 1994. How unique are spectral signatures? *Remote Sensing of Environment* 49, 181-186.

Radhakrishnan, J., Liang, S., Teasdale, J.R., Shuey C.J. 2002. Remote sensing of weed canopies. In: Ranjan S. Mittriah, ed. *From laboratory Spectroscopy to Remotely Sensed Spectra of Terrestrial Ecosystem*. Dordrecht: Kluwer, pp. 175-202.

Rew, L.J., Cussans, G.W., Muggleston A.M., Miller P.C.H. 1996. A technique for mapping the spatial distribution of *Elymus repens*, with estimates of the potential reduction in herbicide usage from patch spraying. *Weed Research* 4, 283-292.

Rew, L.J., Cousens, R.D. 2000. Spatial distribution of weeds in arable crops: are current samplings and analytical methods appropriate?. *Weed Research* 41, 1-18.

Rose, J.W., Haas, R.H., Schell, J.A., Deering, D.W. 1973. Monitoring vegetation systems in the Great Plains with ERTS. In: *Proceedings of the Earth Resources Technology Satellite Symposium NASA SP-351*, Washington DC, EE.UU., pp. 309-317.

Ruiz D, Escribano, C., Fernández-Quintanilla, C. 2006. Assessing the opportunity for site-specific management of *Avena sterilis* in winter barley fields in Spain. *Weed Research*. 46, 379-387.

Saavedra, M., Cuevas, J., Mesa-García, J., García-Torres, L. 1989. Grassy weeds in winter cereals in southern Spain. *Crop Protection* 8, 181-187.

Salisbury, J.W. 1999. *Spectral measurements field guide*. Report No. ADA362372. Washington, D.C.: Defense Technology Information Center.

Schmidt, K.S., Skidmore, A.K. 2003. Spectral discrimination of vegetation types in a coastal wetland. *Remote Sensing of Environment* 85, 92-108.

Slaughter, D.C., Lanini, W.T., Giles, D.K. 2004. Discriminating weeds from processing tomato plants using visible and near-infrared reflectance. *Transactions of the American Society of Agricultural Engineers* 47, 1907-1911.

Smith, A.M., Blackshaw, R.E. 2003. Weed-crop discrimination using remote sensing: a detached leaf experiment. *Weed Technology* 17, 811-820.

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

Thompson, J.F., Stafford, J.V., Miller, P.C.H. 1991. Potential for automatic weed detection and selective application. *Crop Protection* 10, 254-259.

Thorp, K.R., Tian, L.F. 2004. A review of remote sensing of weeds in agriculture. *Precision Agriculture* 5, 477-508.

Timmermann, C., Gerhards, R., Kuehbauch, W. 2003. The economic impact of the site specific weed control. *Precision Agriculture* 4, 241-252.

Tsai, F., Chou, M.J. 2006. Texture augmented analysis of high resolution satellite imagery in detecting invasive plant species. *Journal of the Chinese Institute of Engineers* 29, 581-592.

Visauta, B, Martori, J.C. 2003. Análisis estadístico con SPSS para Windows. Volumen II: Estadística multivariante. 2ª Edición. McGraw-Hill Interamericana de España, España.

Vrindts, E., De Baerdemaeker, J., Ramon, H. 2000. Using spectral information for weed detection in field circumstances. In: *Proceedings of the Third Millennium AgEng2000*. Paper 00-PA-010. European Society Agricultural Engineers, Warwick, UK, sp.

Wang, N., Dowel, F.E., Lacey, R.E. 1999. Single wheat kernel colour classification using neural networks. *Transactions of the American Society of Agricultural Engineers* 42, 233-240.

Wilson, B.J., Brain, P. 1991. Long-term stability of distribution of *Alopecurus myosuroides* Huds. within cereal fields. *Weed Research* 31, 367-373.

Yang, C.-C., Prasher, S.O., Landry, J.A. 1999. Use of artificial neural networks to recognize weeds in a corn field. *Journée d'information Scientifique et Technique en génie agroalimentaire*, (pp. 60-65). Saint-Hyacinthe, Québec, Canada.

Yang, C.C., Prasher, S.O., Landry, J., Ramaswamy, H.S. 2002. Development of Neural Network for weed recognition in corn fields. *Transactions of the American Society of Agricultural Engineers* 42, 147-152.

Zwiggelaar R. 1998. A review of spectral properties of plants and their potential use for crop/weed discrimination in row-crops. *Crop Protection* 17, 189-205.



**Clasificación de infestaciones de Avena (*Avena sterilis* L.) en trigo (*Triticum durum* L.) mediante técnicas basadas en píxeles y objetos con imágenes QuickBird**

---

## **CAPÍTULO IV**



# Clasificación de infestaciones de avena (*Avena sterilis* L.) en trigo (*Triticum durum* L.) mediante técnicas basadas en píxeles y objetos con imágenes QuickBird

## Resumen

Actualmente, la agricultura intensiva tiene como principal objetivo obtener el máximo de producción agrícola gracias a una alta tecnificación. En el caso del control de malas hierbas, este tipo de agricultura se caracteriza por considerar cada parcela como una unidad homogénea en la que las infestaciones son uniformes, lo que en la realidad no ocurre ya que las malas hierbas se distribuyen en agregados. Puesto que todos los tratamientos se aplican de manera uniforme, parte de la superficie agrícola puede recibir un tratamiento innecesario, mientras que otra parte puede presentar un déficit muy acusado. Para corregir este tipo de actuación aparece la agricultura de precisión, y en concreto el **Control Localizado de Malas Hierbas** (CLMH o SSWM, del inglés *Site-Specific Weed Management*), conjunto de técnicas agrícolas que tienen como principal objetivo la aplicación selectiva o dirigida de tratamientos con el fin de optimizar el proceso productivo.

En el presente trabajo se ha realizado un análisis comparativo de fiabilidad con técnicas basadas en píxeles y basadas en objetos para analizar si dichas herramientas presentan la capacidad de clasificar de forma eficiente rodales de la mala hierba *Avena sterilis* L. en parcelas de trigo para un posterior manejo localizado con herbicidas. Así, sobre 26 parcelas individuales presentes en dos imágenes multiespectrales QuickBird tomadas en 2006 y 2008 se aplicaron seis métodos de clasificación: Paralelepípedos, Distancia de Mahalanobis, Máxima Probabilidad, *Spectral Angle Mapper*, *Support Vector Machine* y Árbol de Decisión. Posteriormente, esas mismas imágenes fueron sometidas a un proceso de segmentación para agrupar píxeles que presentaran un comportamiento homogéneo. Estas bandas segmentadas fueron también sometidas a los mismos métodos de clasificación, evaluando posteriormente los resultados obtenidos con las imágenes con y sin segmentar.

Finalmente, y para comparar los resultados con un trabajo anterior realizado con imágenes aéreas (López-Granados, 2006), se calculó el índice de vegetación *NDVI* sobre las imágenes originales y las segmentadas y sobre ellas se realizó una clasificación basada en un Árbol de Decisión. Los resultados obtenidos mostraron claramente que los análisis basados en píxeles y los basados en objetos presentaban un resultado muy similar en la mayoría de las clasificaciones desarrolladas, no observándose una clara distinción entre ninguno de ellos. En ambos análisis, las fiabilidades globales obtenidas en la mayoría de las parcelas superaron el 80%, siendo muchas de ellas cercanas al 99%. En general, todos los clasificadores presentaron precisiones muy parecidas y superiores al 90% excepto el clasificador Paralelepípedos, que presentó precisiones inferiores al 60% de fiabilidad



global en algunos casos. En las parcelas clasificadas de la imagen 2006 se observó que el algoritmo Distancia de Mahalanobis fue el que ofreció mejores resultados en un número mayor de parcelas, mientras que en la imagen de 2008 el clasificador *Support Vector Machine* fue el que mejores resultados mostró. En ambos casos, las fiabilidades globales rondaron entre el 98% y el 100%, con valores del coeficiente Kappa superiores al 0.96. Al analizar los resultados obtenidos al clasificar el índice *NDVI* con un Árbol de Decisión se observó que pese a que no se aumentaba la precisión respecto a los clasificadores anteriormente comentados, en muchos casos se mejoraron los resultados ofrecidos con la clasificación Árbol de Decisión sobre las bandas multiespectrales.

Posteriormente, y tras concluir que el aumento del coste computacional debido a técnicas como la segmentación no ofrecía mejoras sustanciales en la precisión de las clasificaciones, se realizó un análisis para discriminar y cartografiar infestaciones de avena en cultivo de trigo analizando toda la imagen conjuntamente. Esta parte se basó en un análisis jerárquico. En primer lugar se segmentó la imagen en objetos pequeños que permitieran clasificar con precisión los distintos usos de suelo. A continuación, y mediante una segunda segmentación en la que se obtuvieron objetos similares a las parcelas agrícolas, se determinó aquéllas que estaban cultivadas de trigo del resto de usos de suelo mediante relaciones ente niveles de segmentación. Tras enmascarar dichas parcelas, éstas se sometieron a una clasificación únicamente basada en píxeles y con los algoritmos de clasificación que mejor resultados ofrecieron en el análisis previo: Distancia de Mahalanobis, Máxima Probabilidad y *Support Vector Machine*. Las precisiones obtenidas en estas clasificaciones fueron superiores al 90% de fiabilidad global en todos los casos. La imagen de 2006 mostró mejores fiabilidades con valores superiores al 98% en los tres clasificadores, mientras que la imagen de 2008 presentó valores entre el 91% y el 93% de fiabilidad global.

## 1. Introducción

### 1.1. Conceptos generales

La agricultura de precisión surge como un nuevo tipo de técnicas agrarias que permiten mantener una producción agrícola de calidad a la vez que se minimiza el impacto medioambiental que genera este sector. Estas mejoras se basan en aplicaciones localizadas de insumos (fertilizantes, herbicidas, pesticidas, etc.) en base a las necesidades que presenta el terreno en cada momento, minimizando así la actual contaminación que ciertos *inputs* agrarios producen en la agricultura intensiva actual así como el coste de producción. Por tanto, la generación de unos mapas precisos y de calidad del estado del terreno son unos de los componentes esenciales para implementar estas técnicas de forma exitosa, permitiendo una reducción general de los insumos aplicados (Karimi *et al.*, 2005). Existen diversos métodos para obtener información de la situación actual de las parcelas y generar dichos mapas. Muchos de ellos se basan en muestreos discretos e intensivos en base a divisiones sistemáticas del terreno con diferente tamaño de cuadrícula y una posterior interpolación espacial de los datos para obtener la distribución de toda la superficie (Jurado-Expósito *et al.*, 2003, 2004, 2005). Por su parte, otro tipo de técnicas como la teledetección se basa en la obtención continua de datos, lo que ofrece valores reales del terreno en toda la superficie estudiada. Rew y Cousens (2001) revisaron distintas técnicas de obtención de datos del terreno de forma sistemática y continua, y concluyeron que la generación de mapas a gran escala de infestaciones de malas hierbas a partir de medidas en campo (muestreos discretos) era un procedimiento que consumía mucho tiempo y dinero, mientras que métodos de toma de datos continuos, como la teledetección, eran más apropiados y rentables para el control localizado de las malas hierbas. Esta misma conclusión ya la había expuesto anteriormente Moran *et al.* (1997), en cuyo trabajo se revisaron las ventajas y limitaciones que presentaba la teledetección basada en imágenes para la agricultura de precisión, concluyendo que estas técnicas presentan la gran ventaja de permitir el seguimiento estacional del cultivo y de las condiciones del mismo, facilitando su manejo con gran control temporal, con información casi en tiempo real para aquellos cultivos que necesitan un manejo crítico en determinadas fechas. Sin embargo, las limitaciones se centraron en el aspecto tecnológico, indicando que para una mejora de estas técnicas era aconsejable diseñar sensores con resoluciones espaciales, espectrales y temporales que se adecuaran más a las características de la vegetación. Trece años después se ha observado un avance muy significativo en la tecnología de los sensores remotos y de los vehículos que los portan, existiendo actualmente una gama muy diversa de sensores de alta resolución, multiespectrales e hiperespectrales, montados sobre satélites o vehículos aéreos que permiten adecuarse perfectamente a las características de las distintas aplicaciones de la agricultura de precisión.

### 1.2. Control Localizado de Malas Hierbas (CLMH)

En España, el trigo (*Triticum durum* L. y *Triticum aestivum* L.) es uno de los cereales más importante con una superficie que supera los 5 millones de hectáreas anualmente. Esta superficie puede verse disminuida por múltiples factores como una baja fertilidad en los suelos, escasez de agua, aparición de plagas y enfermedades y por la competición por los recursos que ejercen la aparición de malas hierbas asociadas al cultivo. En este sentido, la avena loca (*Avena sterilis* L.) es una de las malas hierbas más frecuente en este cultivo, observándose su presencia en el 65% de los campos de trigo andaluces (Saavedra *et al.*, 1989). Al igual que ocurre con otras malas hierbas, la avena loca se distribuye en rodales localizados a lo largo del campo de cultivo (Barroso *et al.*, 2004b; Blanco-Moreno *et al.*, 2006). Sin embargo, la aplicación de herbicidas para su eliminación suele realizarse en toda la parcela de trigo, lo que conlleva una aplicación innecesaria de producto que aumenta los costes de producción unida a una potencial contaminación medioambiental. Para reducir la aplicación de herbicida, en la agricultura de precisión se han desarrollado técnicas de **Control Localizado de Malas Hierbas** (CLMH o SSWM, del inglés *Site-Specific Weed Management*) basadas en mapas de infestaciones de malas hierbas. Estas técnicas aplican el tratamiento únicamente en los rodales infestados, a la vez que ajustan las aplicaciones de herbicida en base a la densidad de las malas hierbas o a sus características, como el tipo de mala hierba (gramínea o de hoja ancha) o al grado de resistencia a los herbicidas. Este tipo de técnicas son muy apropiadas para los objetivos actuales de Europa, donde se apuesta por técnicas que minimicen el uso de herbicidas y permitan el control de proceso de producción agrícola mediante la trazabilidad de los productos (FP7-NMP, 2009).

### 1.3. Teledetección: discriminación temprana vs tardía de malas hierbas

En la mayoría de los análisis de control de malas hierbas en cultivos se suele realizar el tratamiento en una etapa temprana del crecimiento del cultivo. Sin embargo, la discriminación mediante teledetección de algunas combinaciones cultivo-malas hierbas, ej. malas hierbas gramíneas en cultivos de cereal, presentan muchas dificultades para la clasificación de ambas especies en fases tan tempranas en comparación a la realización de su mapeo en la fase tardía del cultivo. Estas complicaciones se deben, principalmente, a que ambos tipos de plantas presentan un comportamiento espectral muy parecido en la fase inicial del cultivo, a que en ese momento los rodales de la mala hierba son muy pequeños y a que la falta de densidad del cultivo en estados tan avanzados de crecimiento hacen que el suelo también interfiera en la discriminación (Thorp y Tian, 2004). Una alternativa a la discriminación en fases tempranas es la detección en fases tardías de cultivo, debido a que las diferencias fenológicas cultivo-mala hierba pueden ser suficientemente acusadas para permitir un incremento en la respuesta espectral de cada especie. En este caso, la detección de malas hierbas en estados fenológicos tardíos del cultivo presenta un gran potencial si la superficie de cultivo se encuentra totalmente cubierta, las malas hierbas superan la altura del cultivo y las diferencias espectrales entre el cultivo y las mala hierbas están presentes y son cuantificables (López-Granados, 2011).

Debido a que las infestaciones de malas hierbas son relativamente estables en el tiempo desde el punto de vista espacial (Barroso *et al.*, 2004a; Jurado-Expósito *et al.*, 2004, 2005; Heijting *et al.*, 2007a), la discriminación y mapeo de malas hierbas en épocas tardías de cultivo está dirigida a utilizar dichos mapas en aplicaciones en post-emergencia en esa misma temporada si no se ha alcanzado un control adecuado, por ejemplo para controlar malas hierbas crucíferas en cereal de invierno (de Castro *et al.*, 2010); o bien para tratamientos en pre-emergencia en años sucesivos. Asimismo, estos mapas también permiten conocer dónde se localiza el banco de semillas de las malas hierbas estudiadas en el campo de cultivo (Koger *et al.*, 2003).

El **capítulo 3** de esta Tesis Doctoral tuvo como objetivo evaluar la capacidad de discriminación espectral que presentaba el trigo respecto a dos de sus malas hierbas más comunes, la avena loca (*Avena sterilis* L.) y el alpiste (*Phalaris* spp.) en fases tardías del cultivo. Tras tomar muestras de campo de la firma espectral de las tres especies en distintos momentos fenológicos y un posterior análisis discriminante de los datos, los resultados mostraron que existían diferencias espectrales significativas para discriminar las tres especies con precisión, tanto realizando un análisis con información hiperespectral en el rango del espectro entre el azul y el infrarrojo cercano como multiespectral con las 4 bandas azul, verde, rojo e infrarrojo cercano. El estado fenológico más propicio para la clasificación fue cuando las malas hierbas presentaban un estado inicial de maduración y las plantas se encontraban totalmente verdes, mientras que el trigo ya había entrado en un estado avanzado de maduración y la planta estaba parcialmente amarilla.

Algunos autores han estudiado la distribución de malas hierbas en cultivo de trigo mediante tratamiento de imágenes digitales de muy alta resolución espacial tomadas con sensores en vehículos aeroportados (López-Granados *et al.*, 2006; Eddy *et al.*, 2008; Hamouz *et al.*, 2008). Mediante muestreo en campo y técnicas geoestadísticas Barroso *et al.* (2004b) mostraron que el rango del semivariograma, es decir, la extensión de los rodales de avena en trigo, rondaban los 50 m. Teniendo en cuenta este tamaño medio de los rodales y que es posible la discriminación de ambas especies con 4 bandas de espectro pertenecientes a cada una de las regiones comprendidas entre el azul y el infrarrojo cercano, López-Granados *et al.* (2006) indicaron la posibilidad de poder discriminar con precisión infestaciones de avena loca en trigo con imágenes multiespectrales del satélite QuickBird.

### 1.4. Clasificación digital

La mayoría de los métodos de clasificación utilizados en estudios de discriminación de usos de suelo se realizaron utilizando clasificaciones supervisadas (Oetter *et al.*, 2001; South *et al.*, 2004; Zambon *et al.*, 2006; Hester *et al.*, 2008; Yang y Everitt, 2010). Estas clasificaciones se basan en la caracterización estadística de las distintas categorías de clasificación según zonas definidas por el usuario como zonas de entrenamiento, lo que implica un conocimiento previo del territorio. A partir de este análisis estadístico, distintos algoritmos de asignación extrapolan esas características

espectrales al resto de los píxeles de la imagen asignándolos a la categoría más cercana. Estos algoritmos de asignación generan reglas de decisión en base a distintas medidas de diferenciación espectral como centralidad y dispersión (clasificador Paralelepípedos), distancias espectrales (ej. clasificador de Distancia de Mahalanobis), de ángulos (ej. clasificador *Spectral Angle Mapper* (SAM)), de probabilidad (ej. clasificador de Máxima Probabilidad), de minería de datos o autoaprendizaje (ej. clasificador *Support Vector Machine*, clasificadores de Árboles de Decisión (algoritmo C4.5)), entre otros.

Los clasificadores basados en distancias dependen principalmente de los valores espectrales medios de cada una de las distintas categorías, ignorando la varianza que existe en cada clase. Los clasificadores basados en ángulos también crean la regla de decisión a partir de un valor espectral de referencia para cada clase, pero midiendo el ángulo espectral formados entre éste y el píxel a clasificar, en vez de medir la distancia. Su gran ventaja es que es relativamente insensible a los efectos de iluminación y albedo porque la variación de iluminación no cambia la dirección del vector, sólo cambia su magnitud. Por su parte, las rutinas de clasificación basadas en probabilidades incorpora en las reglas de decisión tanto la media de cada una de las categorías de clasificación como la varianza para caracterizar mejor cada categoría. Finalmente, los clasificadores basados en minerías de datos presentan múltiples formas de crear reglas de decisión en función de la naturaleza de éstos, basándose siempre en avanzados análisis estadísticos de los datos entrenados y en técnicas de inteligencia artificial.

En general, cuanto más complejo sea el método de asignación y mayor sea el número de variables estadísticas que maneje el algoritmo, mejor resultado suele presentar la clasificación. Sin embargo, no se puede afirmar que exista una rutina de clasificación ideal ya que el mejor clasificador dependerá de las características de la información de partida, las necesidades y requerimientos del estudio así como las limitaciones en el coste computacional de trabajo.

### 1.5. Segmentación

La mayor parte de estudios de clasificación de usos de suelo se han basado en los valores de los píxeles como unidades básicas e independientes. Sin embargo, y debido a que el terreno es continuo, mucha información está contenida en la relación entre píxeles adyacentes, lo que permite la identificación de objetos formados por píxeles con características comunes, es decir, **objetos** homogéneos desde un punto de vista tanto espectral como espacial. Estos objetos son creados mediante procesos de **segmentación** basados en algoritmos que toman píxeles semillas y determinan el crecimiento alrededor de ellos en base a ciertos criterios de homogeneidad (Yu *et al.*, 2006). Los objetos así creados no están caracterizados sólo por sus información espectral, sino también por características de forma, que han limitado la forma de agruparse entre ellos. En este caso, la clasificación no está basada en los píxeles sino en los objetos como mínima unidad de información. Esta clasificación basada en objetos tiene la ventaja de trabajar con más información que la disponible únicamente con píxeles ya que, mientras que un análisis

basado en píxeles utiliza como información únicamente la respuesta espectral de todos los píxeles en cada banda, el análisis basado en objetos maneja, además de información espectral que caracteriza a cada objeto, otro tipo de información adicional derivada de los objetos de la imagen. En el **capítulo 2** de esta Tesis Doctoral se ha desarrollado con más detalle las ventajas de segmentar las imágenes y del análisis basado en objetos,

La información adicional derivada de la segmentación se obtiene en base a cálculos estadísticos centrados en su tamaño, forma y contexto, pudiendo ser calculada como información relativa de un objeto, subobjeto o super-objeto en el caso de que se haya creado un jerarquía multinivel de imágenes segmentadas (Chubey *et al.*, 2006). La jerarquía multinivel o multirresolución se basa en un estudio de la información desde distintos niveles de escala, lo que permite observar cómo algunos objetos presentan diferente comportamiento en función de la escala de análisis. Diversos autores han segmentado las imágenes digitales teniendo en cuenta diferentes parámetros de escala y mediante un estudio de la red jerárquica multirresolución creada han conseguido clasificar con precisión áreas urbanas (Bruzzone y Carlin, 2006; Chen *et al.*, 2009), ecosistemas forestales (Hájek, 2008; Zhou y Troy, 2009a), marinos (Urbański *et al.*, 2009), orografía del terreno (Barlow *et al.*, 2003; Möller *et al.*, 2008), etc. Sin embargo, el uso de redes jerárquicas multirresolución no se ha utilizado significativamente en estudios de caracterización del uso del suelo agrario.

Pese a que la mayor parte de los estudios de clasificación mediante teledetección se centran en clasificaciones basadas en píxeles, en los últimos años se ha visto un aumento considerable de los análisis basados en objetos. Diversos autores han demostrado que clasificaciones realizadas con imágenes previamente segmentadas en función de características homogéneas mejoran la discriminación de usos de suelo en ecosistemas forestales (Bunting *et al.*, 2006; Chubey *et al.*, 2006; Yu *et al.*, 2006), en agricultura (Peña-Barragán *et al.*, 2011) en paisajes (Burnett y Blaschke, 2003; Hay *et al.*, 2003), en humedales y masas de agua (Harken *et al.*, 2005; van der Werff y van der Meer, 2008), en zonas costeras (Lathrop *et al.*, 2006) y en áreas urbanas (Zhou *et al.*, 2009b; Bhaskaran *et al.*, 2010). Hasta ahora, los análisis basados en objetos se han centrado en unidades homogéneas de terreno relativamente amplias y donde las diferencias entre usos de suelo son visibles. Sin embargo, se carece de estudios basados en objetos orientados a clasificar malas hierbas en cultivos. Las malas hierbas suelen presentar una escasa representación en el terreno y en la mayoría de los análisis suelen englobarse en otra categoría debido a su semejanza espectral con los cultivos.

### 1.6. Objetivos

El principal objetivo de este estudio fue determinar qué metodología permitía la discriminación y el mapeo de la mala hierba avena loca en trigo en fases tardías utilizando imágenes de satélite QuickBird de 2 años. Para ello se llevaron a cabo análisis basados en píxeles y basados en objetos con 6 clasificadores y el índice de vegetación *NDVI* sobre las dos imágenes QuickBird, analizando de forma individual un conjunto de parcelas de trigo a

“escala parcela”. Un segundo objetivo que se planteó fue evaluar la precisión de la discriminación de la avena loca en trigo a “escala imagen”, aislando previamente todas las parcelas de trigo de la imagen del resto de usos de suelo mediante una red jerárquica multirresolución.

## 2. Materiales

### 2.1. Zona de estudio

El estudio de infestaciones en avenas se ha llevado a cabo tomando datos durante los años 2006 y 2008 en una zona agrícola del municipio de La Lantejuela, en la provincia de Sevilla (Fig. 4.1). Esta zona se caracteriza por presentar un relieve relativamente plano junto con un clima Mediterráneo continental caracterizado por veranos largos y secos e inviernos suaves. La imagen tomada en el año 2008 tuvo que ser desplazada geográficamente respecto a la tomada en 2006 debido a que en esa zona se produjo una variación importante de los usos de suelo que interesaban para este estudio, fundamentalmente debido a la conversión de parcelas de herbáceos a olivar, por lo que no se pudo estudiar las misma superficie en ambos años. Debido a esta variación en los usos de suelo, la superficie adquirida en el año 2008 fue algo mayor que la muestreada en 2006 en previsión de que se produjeran más cambios que dificultaran estudios multitemporales posteriores. A la hora de elegir la zona de trabajo, se tomó la zona muestreada del año 2008 como base del estudio y, a partir de ella, se estudió toda la superficie que coincidiera de la imagen 2006. De esta forma, en la imagen de 2006 se han estudiado 4701.9 ha, y 7543.8 ha en la imagen de 2008 (Fig. 4.2).




Figura 4.1. Localización del área de estudio en Andalucía.




Figura 4.2. Zona estudiada (recuadro amarillo) sobre imagen QuickBird (a) de 2006 y (b) de 2008.

Tras el análisis realizado en el **capítulo 3** de esta Tesis Doctoral centrado en la determinación del momento fenológico más apropiado para la discriminación de malas hierbas gramíneas en trigo, éste determinó que para las condiciones agroclimáticas de esta zona de estudio, la mejor diferenciación se realizaría cuando las plantas de trigo se encuentran en un estado de senescencia avanzado y con una coloración amarillenta, mientras que las avenas se encuentran en un estado de maduración avanzado pero todavía verdes (Fig. 4.3). Puesto que es necesario controlar perfectamente el estado fenológico en ambas plantas, durante el mes anterior a la toma de las imágenes se realizaron numerosas visitas a campo con el objetivo de ver la evolución de los estados fenológicos en función de la climatología específica de dichos años y determinar la horquilla más adecuada para la adquisición de la imagen.



Figura 4.3. Estado del trigo y la avena loca en la fecha de estudio.



En ambos años se realizó una campaña de campo intensiva para posicionar los rodales de avena en parcelas de trigo. Esta campaña de campo tuvo lugar en los dos días anteriores y posteriores a la toma de la imagen. En total se muestrearon 11 parcelas en 2006 y 15 parcelas en 2008. De las 11 parcelas de 2006, sólo 4 presentaban trigo en 2008, por lo que junto a éstas se muestrearon 11 parcelas de trigo más en 2008. En cada uno de estos campos se tomaron datos tanto de los rodales de avena como del trigo limpio para poder utilizarlos en las fases de entrenamiento y verificación de las clasificaciones. En total se muestrearon 5.32 ha repartidas por 11 parcelas en 2006 y 7.26 ha repartidas en 15 parcelas en 2008 mediante la georreferenciación de puntos con un GPS TRIMBLE PRO-XRS submétrico diferencial.

El muestreo se hizo teniendo en cuenta las características propias de cada parcela respecto a la distribución de las avenas. De la superficie muestreada cada año, entre un 15% y un 20% del muestreo se utilizó para el entrenamiento de las clasificaciones mientras que el resto se utilizó para su verificación. Además de esta monitorización de las emergencias de avena tanto en el año 2006 como en el 2008, se recorrió el área que abarcaba toda la imagen con objeto de tener definidas en las imágenes las parcelas de trigo presentes en esas fechas para el análisis que denominamos a “escala imagen”. Además, también se marcaron sobre la imagen distintos ejemplos de los cultivos presentes en esa zona para poder realizar un análisis visual posterior.

### *2.2. Imágenes satélite y pre-procesado*

Las imágenes utilizadas fueron adquiridas por el satélite QuickBird el 15 de Mayo de 2006 y el 22 de Mayo de 2008. En ambos casos se adquirió una banda pancromática de 0.6 m de resolución espacial y 4 bandas multispectrales de 2.4 m de resolución espacial en las bandas azul (A: 450 a 520nm), verde (V: 520 a 600nm), rojo (R: 630 a 690nm) e infrarrojo cercano (IRc: 760 a 900nm). La resolución radiométrica de las imágenes fue de 11 bit. Puesto que este trabajo tuvo como objetivo caracterizar de forma relativa unos usos de suelo respecto a otros en una misma imagen, no fue necesario realizar más correcciones que las que ya se habían realizado al adquirir dicha imagen (Robinove, 1981; Duggin and Robinove, 1990; Song *et al.*, 2001).

### 3. Metodología

#### 3.1. Clasificación a “escala parcela”

El análisis llevado a cabo a escala parcelase centró en evaluar la metodología más eficiente para la discriminación de infestaciones de avenas en cada una de las parcelas de trigo de forma individualizada. Esta evaluación se centró en dos objetivos de partida: 1) Evaluar la conveniencia o no de segmentar la imagen para la discriminación de los rodales de avena en trigo; 2) Comparar distintos métodos de clasificación para evaluar el clasificador más apropiado para este estudio.

##### 3.1.1. Análisis de separabilidad espectral

Pese a que según los datos obtenidos en el **capítulo 3** de esta Tesis Doctoral se tomaron las imágenes en el momento fenológico óptimo para la discriminación entre avenas y trigo, antes de comenzar el estudio se analizó la separabilidad espectral de ambas cubiertas en cada una de las parcelas muestreadas durante los años 2006 y 2008 para determinar si eran suficientemente diferentes espectralmente para ser discriminados con precisión. Este análisis se realizó con el método de la medida de distancia espectral *Jeffries-Matusita* (JM), el cual ofrece resultados adecuados cuando los datos se encuentran repartidos según una distribución normal. El algoritmo de distancia JM calcula la separabilidad espectral entre las firmas de dos clases, obteniendo como resultado un valor entre 0 y 2 (Richards, 1993). Los valores cercanos a 2 indican un alto grado de separabilidad, mientras que los valores cercanos a 0 indican una escasa separabilidad (Thomas *et al.*, 2002). Un criterio genérico utilizado en teledetección refiere que los valores superiores a 1.9 muestran una separabilidad espectral muy buena, mientras que valores inferiores indican posibles problemas de discriminación. Cuando el valor es menor que 1 indica que la separabilidad es muy reducida y sería recomendable combinar esas dos cubiertas en una sola (ITT, 2008). Esta medida de distancia espectral puede ser utilizada para determinar el número de clases en función de su separabilidad espectral, aunque hay que destacar que la relación entre separabilidad espectral y precisión en la discriminación de cubiertas es no lineal (Thomas *et al.*, 2002). El análisis de separabilidad espectral se realizó con el software de procesamiento de imagen ENVI 4.5 (ITT *Visual Information Solutions*, 2008).

##### 3.1.2. Segmentación

Con el fin de crear agrupamiento de píxeles con características similares que pudieran mejorar la discriminación entre cubiertas se procedió a segmentar cada una de las 26 parcelas de estudio (11 parcelas de 2006 y 15 parcelas de 2008). El proceso de segmentación de las imágenes se realizó con una segmentación multirresolución (*Multiresolution Segmentation*) basada en el algoritmo de segmentación *Fractal Net Evolution Approach* (FNEA) implementado en el software *Definiens Developer 7* (*Definiens*

AG 2007). Estos agrupamientos de píxeles, denominados objetos o regiones, se obtienen en base a unos requisitos impuestos por el usuario. Estos requisitos se centran en el peso de los datos de entrada, así como en la determinación de una serie de parámetros de segmentación. Los parámetros que definen una segmentación son: 1) factor de escala, que controla el tamaño medio de los objetos al mostrar el valor máximo de heterogeneidad permitido en la formación de objetos, 2) color, que muestra el grado de influencia de la información espectral en la segmentación, 3) forma, que muestra el grado de influencia de la forma de los objetos (compacidad y suavidad) en la segmentación.

Cada una de las parcelas fue segmentada con unos parámetros de segmentación diferentes en función de las características de éstas. La determinación de dichos parámetros se hizo mediante el ensayo de diferentes escenarios con distintas variables de entrada. A la hora de definirlos, se consideró que el parámetro forma no tenía relevancia en este análisis ya que la distribución de avenas en trigo no sigue ningún tipo de patrón morfológico concreto. En este caso, la discriminación entre ambas cubiertas se centró fundamentalmente en la diferencia espectral de éstas, por lo que se consideró que la segmentación se basaría en criterios espectrales asignando un valor máximo al parámetro color (valor 1) y un valor mínimo al parámetro de forma (valor 0). Por tanto, fijados estos dos parámetros, los distintos escenarios evaluados se centraron en determinar el factor de escala más adecuado para la cada parcela en cada uno de los años estudiados. El análisis de estos escenarios se realizó mediante la clasificación y verificación de cada uno de ellos en base a su capacidad de discriminar las clases avena y trigo. En general, debido a las características propias de estos escenarios en los que existe poca superficie de análisis en cada parcela analizada y una gran homogeneidad espectral, se obtuvieron parámetros de escala bastante bajos, predominando los valores iguales o inferiores a 10 en la mayoría de las parcelas de los años 2006 y 2008 (Tablas 4.1 y 4.2).

Tabla 4.1-Parámetros de segmentación de las 11 parcelas clasificadas en 2006.

	Parcelas 2006										
	1	2	3	4	5	6	7	8	9	10	11
Factor Escala	10	6	4	5	5	5	5	4	6	5	4
Color <sup>(1)</sup>	1	1	1	1	1	1	1	1	1	1	1
Forma*	0	0	0	0	0	0	0	0	0	0	0

<sup>(1)</sup> Color + Forma = 1

Tabla 4.2-Parámetros de segmentación de las 15 parcelas clasificadas en 2008.

	Parcelas 2006										
	1	2	3	4	5	6	7	8	9	10	11
Factor Escala	10	6	4	5	5	5	5	4	6	5	4
Color <sup>(1)</sup>	1	1	1	1	1	1	1	1	1	1	1
Forma	0	0	0	0	0	0	0	0	0	0	0

<sup>(1)</sup> Color + Forma = 1

Aunque a partir de la segmentación se obtienen una gran cantidad de información referida a las características de los objetos y sus relaciones, para poder realizar una comparación objetiva con las parcelas sin segmentar, se tomó como variable de estudio el valor espectral medio de cada objeto en cada banda (Media). Este valor se obtiene a partir del cálculo de la media de los valores espectrales de cada píxel que compone el objeto en cada una de las bandas (Eq. 1).

$$M = \frac{1}{\#P_v} \sum_{(x,y) \in P_v} c_k(x,y) \quad (1)$$

donde M es la media espectral de cada objeto en cada banda (Media), #P<sub>v</sub> el número total de píxeles contenidos en un objeto de la imagen v, y c<sub>k</sub>(x,y) el valor de la imagen en el píxel (x,y) en la banda k.

### 3.1.3. Clasificación y verificación

Para la evaluación del método de clasificación que mejor se ajustara a este estudio se analizaron 5 algoritmos de clasificación supervisada implementados en el software ENVI 4.5 (ITT *Visual Information Solutions*, 2008): **Paralelepípedos (P)**, **Distancia de Mahalanobis (DMa)**, **Máxima Probabilidad (MP)**, **Spectral Angle Mapper (SAM)**, **Support Vector Machine (SVM)** y **Árbol de Decisión (AD)**. Estos métodos se eligieron por su marcada diferencia conceptual/ matemática respecto a los criterios que siguen para la asignación de píxeles a cada categoría. El método P se caracteriza por crear un área de dominio para cada categoría en base a los valores de centralidad y dispersión del entrenamiento. Por su parte, el método DMa determina la asignación de cada píxel a una categoría en base a una medida de similitud espectral basada en el cálculo de la distancia espectral teniendo en cuenta la correlación entre variables aleatorias. Por otro lado se encuentra el método MP, el cual es un clasificador basados en probabilidades que define una función de probabilidad para cada categoría en función de la media y la matriz de varianza-covarianza, asignando cada píxel a la categoría cuya probabilidad sea mayor. Entre los clasificadores basados en ángulos espectrales se evaluó el clasificador SAM, el cual basa la asignación de cada píxel a una determinada categoría en función de la similaridad espectral, es decir, del ángulo formado entre el píxel a clasificar y un píxel de referencia, para cada una de las bandas que intervienen en la clasificación.

En el estudio también se consideraron los algoritmos de aprendizaje automático basados en la minería de datos (*data mining*) con la aplicación del algoritmo SVM, que asigna cada píxel a una categoría a partir de la creación, para cada categoría, de un hiperplano N-dimensional de margen o separación máximo respecto a los otros hiperplanos. Este algoritmo de aprendizaje es muy versátil. Inicialmente, el SVM discrimina entre categorías en base a una función lineal, aunque está preparado para implementar igualmente funciones no lineales. Para este estudio se han testeado una función lineal (*linear*) y tres funciones no lineales: una polinómica (*polynomial*), otra sigmoideal (*sigmoid*) y una red neuronal (*Radial Basic Function*). El mejor resultado

obtenido de las cuatro clasificaciones ha sido el utilizado como representativo del algoritmo SVM en cada parcela.

Finalmente, otro método de asignación empleado fue el AD, el cual se basa en una discriminación secuencial de cada una de las categorías de acuerdo a la banda o bandas que permitan más claramente su separación del resto. La determinación de la secuencia de discriminación se realizó mediante el algoritmo C4.5 (Quinlan, 1993), implementado en el software Weka 3.6.1 (Universidad de Waikato, Nueva Zelanda, 2009). Este algoritmo genera un árbol de decisión y un conjunto de reglas que se utilizan para determinar la regla de secuenciación que se debe de emplear en cada momento. El árbol se construye mediante la estrategia *depth-first* (búsqueda en profundidad) que analiza todas las divisiones posibles (nodos del árbol) del conjunto de datos para, posteriormente, seleccionar la división con la mayor ganancia de información. Actualmente, el C4.5 es uno de los algoritmos más utilizados en el aprendizaje automático y minería de datos, siendo el estándar utilizado para comparar la precisión de los algoritmos nuevos (Drummond y Holte, 2003).

Para cada una de las parcelas analizadas en los años 2006 y 2008 se realizó una clasificación basada en píxeles y otra basada en objetos con cada uno de los métodos de clasificación anteriormente descritos. Para la clasificación basada en píxeles se analizaron directamente las cuatro bandas multiespectrales (A, V, R, IRc) mientras que en la basada en objetos se analizaron las cuatro bandas correspondientes a la media espectral de los píxeles que conforman cada objeto (Media\_A, Media\_V, Media\_R, Media\_IRc). López-Granados *et al.* (2006) estudiaron la capacidad de discriminación de malas hierbas gramíneas tardías en trigo a partir de diferentes índices espectrales con fotografías aéreas. El estudio sugiere que la detección de malas hierbas gramíneas en trigo es factible con imágenes satélite de alta resolución o fotografías aéreas, mostrando que el índice *NDVI* (*Normalized Difference Vegetation Index*) fue el que mejores resultados ofreció en todas las localizaciones estudiadas con valores de precisión superiores al 89%. Con objeto de valorar la mejora de la metodología propuesta en este trabajo respecto a la obtenida por López-Granados *et al.* (2006), se planteó aplicar la misma metodología seguida por estos autores en las distintas parcelas de estudio para comparar los resultados con los obtenidos mediante clasificación supervisada. Para ello se obtuvo el índice *NDVI* a partir de la imagen multiespectral de cada parcela para realizar un análisis basado en píxeles. Dado que un objetivo de este trabajo fue valorar la conveniencia o no de segmentar la imagen para la discriminación de avena en trigo, se decidió aplicar el mismo procedimiento en la imagen segmentada de cada parcela, por lo que se obtuvo el índice *NDVI* a partir de la media espectral de los píxeles que conforman cada objeto de las bandas rojo e infrarrojo cercano. La definición de cada categoría se realizó mediante la determinación, a partir de un Árbol de Decisión, del valor digital frontera que delimitó el intervalo de valores para dichas categorías.

El análisis de la precisión en los resultados se realizó mediante el cálculo de la matriz de confusión, de la cual se obtuvo la Fiabilidad Global (FG) de la clasificación. Por otro lado también se calculó el coeficiente Kappa (K), el cual indica si los resultados obtenidos en la matriz de confusión son significativamente mejores que los producidos en una clasificación a azar.

Todas las clasificaciones de cada una de las parcelas tuvieron el mismo entrenamiento y verificación. En el análisis basado en píxeles se utilizaron los valores estadísticos de los píxeles involucrados en el entrenamiento/verificación. Por su parte, debido a que los objetos creados en la segmentación se componen de píxeles que toman un mismo valor en función de atributo de la segmentación estudiado, en este caso los procesos de entrenamiento/verificación utilizaron los valores estadísticos de los píxeles de cada objeto incluidos en el muestreo.

### *3.2. Clasificación a “escala imagen”*

Por su parte, el análisis llevado a cabo a escala imagen se centró en evaluar la capacidad para obtener en una gran extensión agrícola un mapa preciso de la distribución de avenas en parcelas de trigo. Para la realización de este apartado se utilizaron aquellas técnicas de clasificación que mejores resultados obtuvieron en el apartado anterior. Los procedimientos para este estudio fueron: 1) aislar las parcelas de trigo del resto de usos de suelo de la imagen; 2) comparar distintos métodos de clasificación para evaluar el clasificador más apropiado para este estudio.

#### *3.2.1. Detección de parcelas de trigo*

La discriminación de parcelas de trigo en toda la imagen se realizó mediante una clasificación jerárquica basada en objetos. Pese a que en el **capítulo 2** de esta Tesis Doctoral se discriminaron usos de suelo en cultivos mediterráneos con una alta fiabilidad, en este trabajo se buscó una clasificación de las parcelas de trigo más exacta en la que se forzara la división de usos de suelo por los límites marcados por las parcelas catastrales. Debido a que una parcela catastral puede presentar una gran heterogeneidad de respuestas espectrales (aparición de zonas cultivadas junto con edificaciones, caminos o suelo desnudo), en muchos casos resulta muy difícil determinar correctamente el uso del suelo mayoritario debido a la gran mezcla espectral de la superficie estudiada. Para ello se planteó una metodología jerárquica basada en una segmentación de la imagen con objetos homogéneos espectralmente de tamaño medio que permitieran la clasificación de los distintos usos de suelo (Fig. 4.3a) para, posteriormente, relacionarlos con otros objetos obtenidos en una segmentación de un nivel superior en la que la forma de los objetos está forzada al límite de la parcela (Fig. 4.3b).

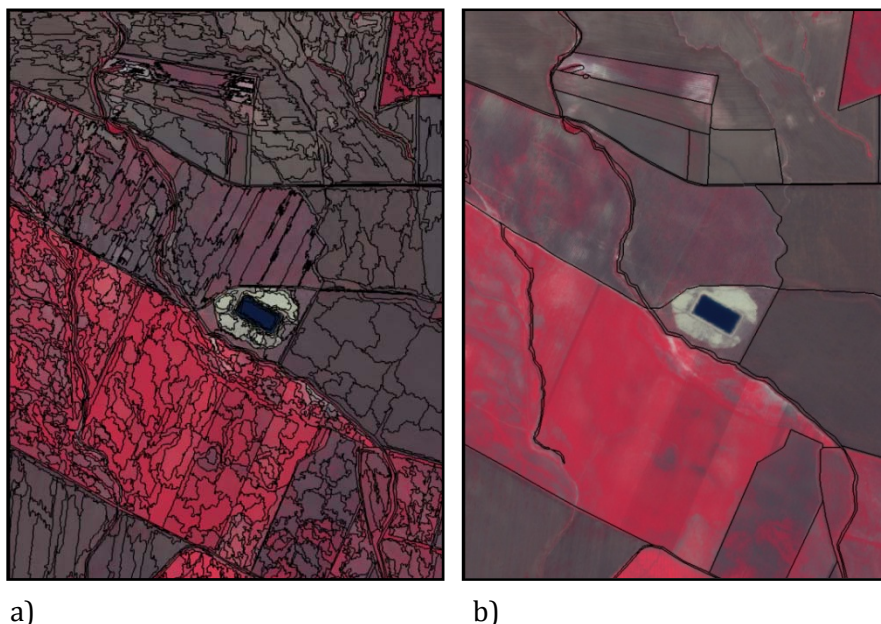


Figura 4.4. Segmentación jerárquica de la imagen: a) nivel inferior (sub-objetos); b) nivel superior (super-objetos).

### 3.2.1.1. Muestreo de los usos de suelo

A partir de los datos tomados en las campañas de campo de los años 2006 y 2008 se marcaron sobre la imagen las parcelas cultivadas con trigo y con la ayuda del parcelario, se definieron unas parcelas de entrenamiento y verificación para este estudio. Dichas regiones de entrenamiento/verificación se utilizaron igualmente tanto para la clasificación intermedia realizada en este apartado como para la clasificación final. La única diferencia en dichas clasificaciones se debió a que la clasificación intermedia requirió de un mayor grado de detalle en cuanto a la descripción de los usos de suelo de las distintas parcelas, mientras que en la clasificación final sólo se evaluó si la parcela era trigo o no trigo. Para obtener ese grado de detalle en los usos de suelo de las parcelas de estudio se realizó un análisis visual de la imagen en base a los datos tomados durante la campaña en campo de los distintos usos de suelo presentes en esa zona. A partir de ahí se definieron 6 usos de suelo principales en función de su semejanza espectral: trigo (*Triticum durum* L.), girasol (*Helianthus annuus* L.), olivar (*Olea europaea* L.), adormidera (*Papaver somniferum* L.), suelo desnudo, agua y edificaciones. Para la clasificación final todos los usos de suelo, excepto el trigo, se agruparon en una sola categoría “No Trigo”.

El proceso de entrenamiento de las clasificaciones se realizó con 1350ha en 2006 y con 1920ha en 2008, algo más del 25% de la superficie analizada. Por su parte, para la verificación de las clasificaciones se utilizó el 91.92% de la superficie total analizada en 2006 (4322.5ha) y el 97.42% en 2008 (7092.5ha). Entre las parcelas a verificar se incluyeron las parcelas que se habían utilizado para el entrenamiento. La superficie restante que no se tuvo en cuenta, el 8.08% en 2006 y el 2.58% en 2008, corresponde a parcelas de superficie inferior a 250m<sup>2</sup> que no reflejan ninguna unidad agrícola por sí mismas y que suelen deberse a errores en la digitalización del parcelario y otras divisiones

menores. En este grupo también se incluyeron los polígonos correspondientes a caminos agrícolas y arroyos, ya que suelen presentar distintos usos de suelo debido a errores en la digitalización, a la falta de actualización en el caso de los caminos y al distinto nivel de la lámina de agua en función del estado hídrico de ese año, en el caso de los arroyos.

### 3.2.1.2. Segmentación de objetos homogéneos: nivel inferior

El objetivo principal de este apartado fue segmentar la imagen en objetos homogéneos, principalmente desde el punto de vista espectral, pero que estuvieran influenciados por la forma de las parcelas catastrales. Para ello se realizó una segmentación multirresolución (*Multiresolution Segmentation*), basada en el algoritmo de segmentación *Fractal Net Evolution Approach* (FNEA) implementado en el software *Definiens Developer 7* (*Definiens AG 2007*). Puesto que previamente a este estudio se había realizado una segmentación de una imagen QuickBird con características similares y con la misma finalidad (**capítulo 2** de esta Tesis Doctoral), se optó por tomar directamente los parámetros de segmentación definidos en dicho estudio como los más apropiados para este caso. Los ajustes de los diferentes parámetros de segmentación se determinaron a partir de ensayar diferentes escenarios con distintos parámetros de entrada y evaluar, en base a sucesivas clasificaciones y validaciones, su capacidad para discriminar los elementos agrícolas significativos. En base a ese estudio, los valores utilizados para esta segmentación se muestran en la Tabla 4.3. Junto a estos parámetros también se consideró que todas las bandas presentes en la segmentación (A, V, R, IRc) tendrían el mismo peso en este proceso y se incorporó la capa parcelaria de Catastro para forzar la creación de objetos en base a los límites de las parcelas.

Tabla 4.3- Parámetros de segmentación para el 1<sup>er</sup> nivel de la red jerárquica.

Parámetros segmentación				
<i>Factor escala</i>	<i>Color</i> <sup>(1)</sup>	<i>Forma</i>	<i>Suavidad</i>	<i>Compacidad</i>
50	0.8	0.2	0.5	0.5

<sup>(1)</sup> Color + Forma = 1; Suavidad + Compacidad = 1

De toda la información que se obtuvo tras la segmentación, para este análisis se tomó como variable de estudio el valor espectral medio de cada objeto en cada una de las cuatro bandas espectrales segmentadas (Media).

### 3.2.1.3. Clasificación y verificación

En cada una de las imágenes obtenidas en los años 2006 y 2008 se realizó una clasificación basada en objetos con los tres algoritmos de clasificación supervisada que mejor resultados ofrecieron en el análisis a nivel parcela: DMA, MP y SVM. En dichas clasificaciones se analizaron las cuatro bandas correspondientes a la media espectral de los píxeles que conforman cada objeto (Media\_A, Media\_V, Media\_R, Media\_IRc). La



validación de las clasificaciones se realizó mediante el análisis de la matriz de confusión, de la Fiabilidad Global (FG) de la clasificación y del coeficiente Kappa (K). Todos estos análisis se realizaron con el software ENVI 4.5 (ITT *Visual Information Solutions*, 2008).

#### 3.2.1.4. Segmentación de objetos equivalentes a parcelas: nivel superior

Para discriminar las infestaciones de avena en toda la imagen (a “escala imagen”), a continuación se procedió a realizar otra segmentación multirresolución (*Multiresolution Segmentation*) con en el software *Definiens Developer 7* (*Definiens AG* 2007), en la que se forzó a que los objetos fueran equivalentes a las parcelas presentes en el parcelario de Catastro. Esta segmentación ya no se basó en las imágenes multiespectrales de los años 2006 y 2008, sino que se segmentaron las clasificaciones que mejor fiabilidad obtuvieron en el apartado anterior. Para poder realizar un análisis jerárquico, es decir, teniendo en cuenta distintos niveles de segmentación, se tuvieron que ejecutar dos segmentaciones consecutivas. Antes de comenzar a segmentar las clasificaciones elegidas en el apartado anterior, éstas fueron reclasificadas en dos grupos: Trigo-No Trigo, con el fin de analizar sólo el uso de suelo que interesaba. Esta clasificación binaria fue segmentada con los mismos parámetros de segmentación utilizados en el apartado 1.b (Tabla 4.3) con el objetivo de crear objetos semejantes a los obtenidos en la segmentación inicial (Fig. 4.4a). Los objetos creados fueron parecidos aunque no idénticos a los obtenidos en el apartado anterior. Esta pequeña variación no supuso ningún problema ya que lo que se buscó fue delimitar lo mejor posible las regiones clasificadas para que dos objetos contiguos clasificados con el mismo uso del suelo, pero perteneciente a parcelas distintas, no se agruparan. Puesto que los objetos recién creados no se encuentran asignados a ninguna categoría, estos volvieron a ser clasificados en los grupos Trigo-No Trigo (Fig. 4.4b).

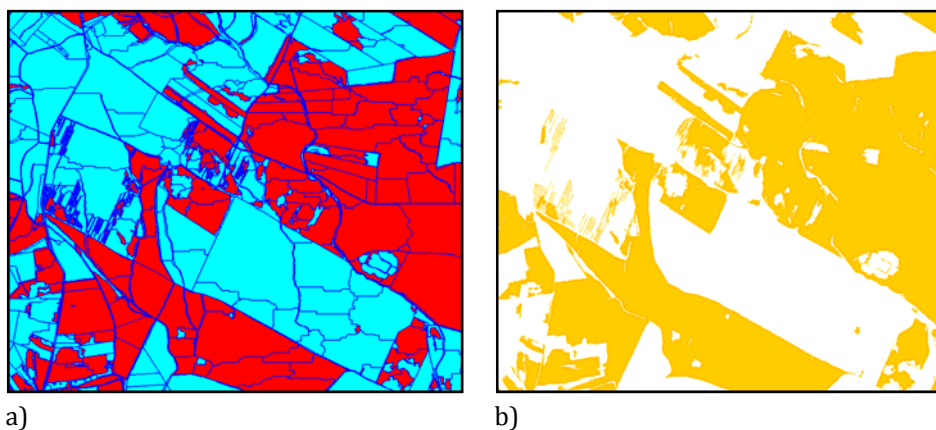


Figura 4.5. Primer nivel de la segmentación: a) Objetos creados en la segmentación y b) clasificación de objetos en las categorías “Trigo-No Trigo”.

Tomando como base los objetos obtenidos anteriormente, se procedió a realizar la segunda segmentación en un nivel superior en la que se formaron los objetos con la forma de las parcelas catastrales (Fig. 4.5). Para conseguir una segmentación tan específica fue necesario controlar adecuadamente los parámetros de segmentación. En este caso, se procedió a eliminar el efecto de la banda clasificada de la segmentación asignándole un peso nulo en el proceso. Por tanto, lo que se buscó es que todo el peso en la formación de los objetos cayera sobre la capa auxiliar de catastro. Respecto al resto de parámetros de segmentación, se procedió a asignar un factor de escala muy alto para que no se formaran objetos menores a la parcela y se procedió a dar el máximo valor a la componente forma para la formación de objetos en detrimento de la componente espectral (Tabla 4.4).

Tabla 4.4- Comparativa de los parámetros de segmentación del 1<sup>er</sup> nivel (sub-objetos) y 2<sup>o</sup> nivel (super-objetos) de la red jerárquica.

	Segmentaciones	
	1 <sup>er</sup> Nivel	2 <sup>o</sup> Nivel
Factor de escala	50	10000
Color <sup>(1)</sup>	0.8	0.1
Forma	0.2	0.9
Suavidad	0.5	0.5
Compacidad	0.5	0.5
Peso bandas	1	0
Información auxiliar	Sí	Sí

<sup>(1)</sup> Color + Forma = 1; Suavidad + Compacidad = 1




Figura 4.6. Objetos creados en el 2<sup>o</sup> nivel de segmentación.

### 3.2.1.5. Análisis jerárquico: comparación de niveles de segmentación

A partir de estos dos niveles de segmentación, con el software *Definiens Developer 7* (Definiens AG 2007) se realizó un análisis jerárquico en el que se relacionaron los objetos clasificados como trigo en la segmentación de nivel inferior (sub-objetos) con los objetos del nivel superior (super-objetos). La variable más satisfactoria que relacionó

ambos niveles de objetos fue obtenida mediante el cálculo de la Relación de Área de Trigo (RAT), dentro del grupo de variables de análisis jerárquico “Área relacionada con sub-objetos (*Rel. area to sub-objects*)”, la cual calculó para cada objeto de nivel superior, la proporción de superficie clasificada en una determinada categoría a nivel sub-objetos (Eq. 2). Los valores oscilan desde 0 a 1. El valor 0 indica que un determinado objeto de nivel superior no contiene ningún subobjeto que se encuentre clasificado con la categoría estudiada (en este caso trigo). Por su parte, el valor 1 indica que un determinado objeto de nivel superior está formado en su totalidad por distintos sub-objetos clasificados con dicha categoría (trigo).

$$Rel. area = \frac{\#P_v}{\#P_{Uv(d)}} \quad (2)$$

donde  $\#P_v$  es el área de los píxeles pertenecientes a una categoría  $v$  y  $\#P_{Uv(d)}$  es el área del super-objeto.

Las datos obtenidos para estas variables fueron exportados al software ENVI 4.5 (ITT *Visual Information Solutions*, 2008) para realizar un análisis teniendo en cuenta distintas proporciones de trigo (sub-objetos) en los objetos equivalentes a las parcelas (super-objetos) para las imágenes QuickBird de 2006 y 2008. Se analizaron varios escenarios que clasificaron los objetos de nivel superior en la categoría trigo en función de la proporción de superficie de trigo clasificada en sus sub-objetos. Para ello se evaluaron las proporciones que iban desde el 10% (RAT = 0.1) de superficie clasificada como trigo en sus sub-objetos hasta el 90% (RAT = 0.9). Esta clasificación se llevó a cabo mediante un análisis basado en píxeles en el que se comparó dos algoritmos de clasificación supervisada diferentes: DMA y MP. La elección dichos algoritmos de clasificación, así como de la clasificación basada en píxeles se debió a que fueron las opciones que mejores resultados proporcionaron a escala parcela respecto a su coste computacional. En este estudio no se consideró el clasificador SVM que, aunque ofreció muy buenos resultados en el estudio a escala parcela, presentó un coste operacional muy alto para este estudio a escala imagen. Cada una de estas clasificaciones fue verificada mediante el análisis de la fiabilidad global de la clasificación y de la fiabilidad del productor, la cual refleja la probabilidad de que un píxel clasificado represente esa categoría en la realidad, representen realmente dicha clase en el terreno (Congalton, 1991). Este análisis definió de forma más correcta las parcelas que realmente presentaban trigo (2<sup>o</sup> nivel de segmentación) (Fig. 4.6b), respecto a la clasificación realizada mediante la segmentación por características espectrales homogéneas (1<sup>er</sup> nivel de segmentación) (Fig. 4.6a).

A partir de este análisis se determinaron, para los años 2006 y 2008, las clasificaciones que definirían la superficie de trigo de las imágenes y, por tanto, las parcelas de trigo a analizar para determinar su infestación por avenas. En estas clasificaciones se comprobó que se habían clasificado correctamente como trigo todas las parcelas en las que se había muestreado avenas en los años estudiados.

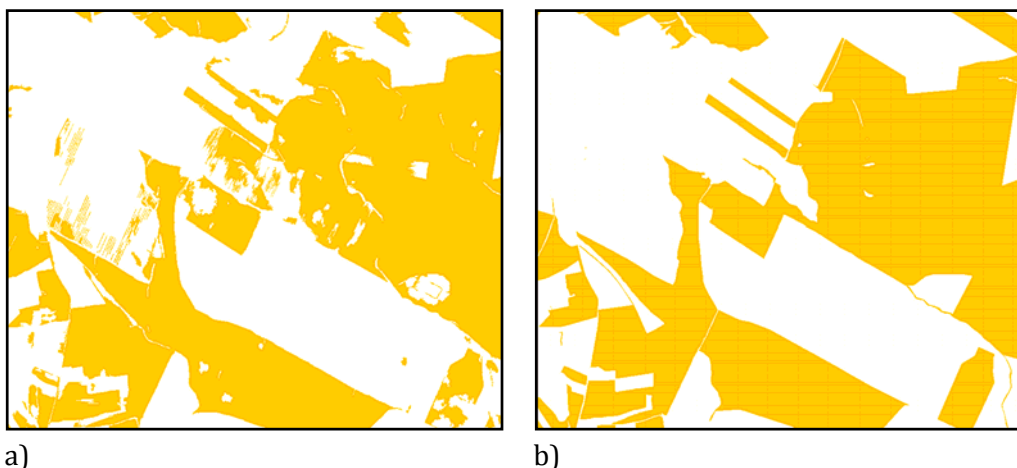


Figura 4.7. Comparativa de las clasificaciones “Trigo-No Trigo” obtenidas: a) 1º nivel de segmentación y b) 2º nivel de segmentación.

### 3.2.2. Discriminación de avenas en parcelas trigo

Las imágenes de los años 2006 y 2008 fueron enmascaradas en base a las parcelas de trigo obtenidas en el apartado anterior. A continuación, y utilizando las mismas regiones de entrenamiento y verificación que en el análisis a nivel parcela, se procedió a clasificar todas las parcelas de trigo en ambas imágenes. Esta clasificación se llevó a cabo mediante un análisis basado en píxeles en el que se compararon tres algoritmos de clasificación supervisada diferentes: DMA, MP y SVM. Al igual que se decidió en las clasificaciones anteriores, la elección de dichos algoritmos de clasificación, así como de la clasificación basada en píxeles se debió a que fueron las opciones que mejores resultados proporcionaron a escala parcela respecto a su coste computacional. La única diferencia en este caso es que se incluyó el clasificador *Support Vector Machine* (SVM) debido a que, aunque presenta un coste operacional muy alto para una superficie de estudio tan grande, gran parte de la superficie no se analiza al no corresponder a parcelas de trigo. En dichas clasificaciones se analizaron las cuatro bandas multiespectrales correspondientes. La validación de las clasificaciones se realizó mediante el análisis de la matriz de confusión, de la Fiabilidad Global (FG) de la clasificación y del coeficiente Kappa (K). Todos estos análisis se realizaron con el software ENVI 4.5 (ITT *Visual Information Solutions*, 2008).

## 4. Resultados

### 4.1. Clasificación a “escala parcela”

Como se ha indicado en la sección anterior, antes de comenzar la discriminación de los rodales de avena en las 26 parcelas de trigo analizadas en las imágenes de los años 2006 y 2008, se realizó un análisis de separabilidad espectral. Las Tablas 4.5 y 4.6 muestran los valores de separabilidad espectral obtenidos en las 11 parcelas de trigo analizadas en 2006 y en las 15 parcelas analizadas en 2008, mostrando valores que oscilan entre una separabilidad espectral mínima de 1.66 y una separabilidad máxima de 2.

Tabla 4.5- Separabilidad espectral medida con la distancia espectral *Jeffries-Matusita* entre los usos Trigo-Avena en las 11 parcelas analizadas en 2006.

	Jeffries-Matusita										
	Parcelas 2006										
	1	2	3	4	5	6	7	8	9	10	11
<i>Imagen</i>											
Píxel	1.98	1.97	1.91	2.00	1.90	1.98	1.94	1.93	1.96	1.85	2.00
Objeto	1.97	1.97	1.91	2.00	1.90	1.98	1.94	1.93	1.94	1.85	2.00

Tabla 4.6- Separabilidad espectral medida con la distancia espectral *Jeffries-Matusita* entre los usos Trigo-Avena en las 15 parcelas analizadas en 2008.

	Jeffries-Matusita														
	Parcelas 2008														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
<i>Imagen</i>															
Píxel	1.68	1.83	1.67	1.99	1.97	1.72	1.92	1.94	1.88	1.72	1.73	1.90	1.93	1.92	1.87
Objeto	1.67	1.83	1.66	1.99	1.96	1.72	1.91	1.94	1.85	1.72	1.74	1.89	1.92	1.92	1.87

La separabilidad espectral obtenida en las distintas parcelas analizadas en los años 2006 y 2008 fue satisfactoria, si bien en general se observó una disminución de separabilidad espectral en el año 2008 debido a que las avenas de ese año estaban en un estado fenológico más tardío y, por tanto, más cercano al senescente trigo. Aún así, la mayoría de las parcelas estudiadas en ambos años presentó una separabilidad superior a 1.8, lo que generó unas expectativas positivas para la discriminación entre las dos cubiertas. En este caso, todas las parcelas de 2006 presentaron una separabilidad excelente con valores iguales o superiores a 1.85 y llegando a una separabilidad máxima con valor 2 en las parcelas 4 y 11. Sin embargo, tres cuartas partes de las parcelas de 2008 (10/15 parcelas) mostraron una separabilidad muy buena con valores superiores a 1.80, quedando el resto con valores algo menores debido a la semejanza espectral. Respecto a los valores de separabilidad espectral obtenidos con la imagen multispectral (análisis basado en píxeles) y con la imagen segmentada (análisis basado en objetos), se observó

que no existía una diferencia significativa de los valores obtenidos en ninguno de los años estudiados. Se observó más estabilidad en los datos de 2006 que en los de 2008, aunque los valores en general fueron muy estables con una oscilación máxima de 0.3 observada en los valores analizados en la parcela 9 del año 2008.

Tras este análisis espectral previo se procedió a clasificar cada una de las parcelas con distintos algoritmos de asignación. Las tablas 4.7 y 4.8 muestran los valores de FG y K de los mejores resultados obtenidos en las distintas clasificaciones de cada una de las parcelas de los años 2006 y 2008. En ellas se puede observar cómo todos los clasificadores, excepto el clasificador P, consiguen precisiones muy altas con valores que superan el 91% de FG y el 0.8 de K, siendo la mayoría de ellas superiores a 98% en FG y a 0.9 de K. La Figura 4.7 muestra, a modo de ejemplo, las clasificaciones realizadas con cada uno de los algoritmos de asignación en los análisis basados en píxeles y objetos de la parcela número 14 de la imagen de 2008. En general, las precisiones obtenidas en cada parcela presentan unos valores muy parecidos para la mayoría de los clasificadores, observándose variaciones entre ellas en función de la variabilidad y de las características propias de cada parcela, es decir, del estado fenológico del trigo y de la avena en el momento de la toma de la imagen. La influencia de esta variabilidad del estado fenológico se ve reflejado en la medida de distancia espectral *Jeffries-Matusita*, donde se observó que, aunque la mayor parte de las parcelas presentaron una separabilidad espectral satisfactoria entre las dos cubiertas estudiadas, en el caso de las parcelas analizadas en la imagen de 2006 se observó una separabilidad espectral general aún mejor. Este patrón se repite en las clasificaciones. En general se observa que todas las parcelas presentan una precisión en la clasificación muy alta, aunque en las clasificaciones de las parcelas analizadas en 2008 es donde se observan peores FG con valores obtenidos en la clasificación de P tan bajos como de 37.40% de FG y 0.1 de K en la parcela número 1 o valores de FG entre el 50 y 60% y de K entre 0.2 y 0.4 en las parcelas número 5, 6 y 7.

Tabla 4.7- Resultados obtenidos en la clasificación de infestaciones de avena loca en parcelas de trigo de las 11 parcelas analizadas en 2006.

QuickBird 2006																												
Paralelepípedos				Distancia Mahalanobis				Máxima Probabilidad				Spectral Angle Mapper				Support Vector Machine				Árbol Decisión				Árbol decisión NDVI				
Píxel		Objetos		Píxel		Objetos		Píxel		Objetos		Píxel		Objetos		Píxel		Objetos		Píxel		Objetos		Píxel		Objetos		
NP <sup>(1)</sup>	FG <sup>(2)</sup>	K*	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K
1	98.0	0.7	96.4	0.9	99.5	1	99.2	1	99.5	1	99.8	1	98.8	1	97.9	1	98.6	1	97.4	1	97.1	0.9	95.8	0.9	99.9	1	99.9	1
2	91.3	0.8	91.1	0.8	99.3	1	99.2	1	99.8	1	99.8	1	99.0	1	98.9	1	100	1	99.4	1	99.1	1	99.1	1	99.1	1	99.3	1
3	76.1	0.6	77.0	0.6	98.2	1	98.3	1	95.5	0.9	95.8	0.9	98.7	1	98.7	1	96.8	0.9	97.4	1	95.6	0.9	95.5	0.9	94.8	0.9	94.6	0.9
4	90.2	0.8	91.3	0.8	99.4	1	99.5	1	99.9	1	99.9	1	96.9	0.9	97.7	1	99.3	1	99.3	1	94.3	0.9	94.3	0.9	99.9	1	100	1
5	68.6	0.5	67.5	0.4	98.1	1	98.0	1	95.4	0.9	95.5	0.9	96.7	0.9	95.6	0.9	97.5	1	97.3	1	96.1	0.9	95.5	0.9	94.6	0.9	94.6	0.9
6	91.2	0.8	90.9	0.8	100	1	100	1	100	1	100	1	100	1	100	1	100	1	100	1	95.2	0.9	92.6	0.9	99.8	1	99.9	1
7	89.0	0.8	90.0	0.8	100	1	100	1	100	1	100	1	100	1	100	1	100	1	100	1	99.7	1	99.9	1.00	100	1	100	1
8	82.4	0.7	85.3	0.7	98.9	1	98.9	1	98.8	1	98.8	1	98.5	1	98.1	1	97.5	0.9	97.9	1	94.4	0.9	94.3	0.9	98.4	1	98.4	1
9	83.6	0.7	81.7	0.7	98.7	1	97.6	1	97.4	1	98.2	1	99.3	1	98.2	1	95.7	0.9	97.2	0.9	95.6	0.9	94.7	0.9	99.0	1	98.9	1
10	80.0	0.6	79.0	0.6	99.8	1	99.8	1	99.8	1	99.8	1	99.1	1	99.0	1	99.9	1	99.5	1	99.1	1	99.3	1	99.2	1	99.3	1
11	87.9	0.7	87.6	0.8	99.9	1	99.9	1	98.0	1	98.3	1	99.8	1	99.9	1	99.9	1	99.9	1	98.8	1	98.8	1	94.2	0.9	95.0	0.9

(1) NP= Número de parcela;

(2) FG =Fiabilidad Global (%); K=Coficiente Kappa

Tabla 4.8- Resultados obtenidos en la clasificación de infestaciones de avena loca en parcelas de trigo de las 15 parcelas analizadas en 2008.


QuickBird 2008																												
Paralelepípedos					Distancia Mahalanobis				Máxima Probabilidad				Spectral Angle Mapper				Support Vector Machine				Árbol Decisión				Árbol decisión NDVI			
Píxel		Objetos			Píxel		Objetos		Píxel		Objetos		Píxel		Objetos		Píxel		Objetos		Píxel		Objetos		Píxel		Objetos	
NP <sup>(1)</sup>	FG <sup>(2)</sup>	K*	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K	FG	K
1	37.4	0.1	37.1	0.1	95.4	0.9	97.7	0.9	97.6	1	98.1	1	92.5	0.9	94.1	0.9	99.0	1	99.5	1	98.5	1	93.8	0.9	93.8	0.9	94.0	0.9
2	91.5	0.8	90.7	0.8	99.7	1	99.8	1	99.6	1	99.5	1	99.6	1	99.6	1	99.7	1	99.7	1	99.0	1	98.9	1	99.0	1	99.0	1
3	68.3	0.5	68.8	0.5	98.4	1	98.4	1	98.1	1	98.3	1	96.9	0.9	94.0	0.9	98.1	1	97.6	1	91.9	0.8	93.5	0.9	98.1	1	98.1	1
4	89.7	0.8	90.2	0.8	100	1	100	1	100	1	100	1	99.8	1	95.8	0.9	100	1	100	1	98.9	1	99.1	1	100	1	100	1
5	59.2	0.4	59.6	0.4	99.8	1	99.8	1	100	1	100	1	99.3	1	98.9	1	100	1	99.9	1	99.1	1	98.9	1	99.9	1	99.9	1
6	53.2	0.2	53.2	0.2	98.1	1	98.2	1	98.5	1	98.6	1	97.4	1	96.3	0.9	99.4	1	99.5	1	96.2	0.9	96.1	0.9	99.1	1	99.1	1
7	51.6	0.3	51.9	0.3	99.1	1	98.8	1	99.9	1	99.9	1	99.0	1	99.0	1	99.7	1	99.4	1	97.7	1	99.0	1	99.0	1	99.1	1
8	68.1	0.5	68.1	0.5	99.8	1	99.9	1	99.7	1	99.8	1	99.6	1	99.0	1	99.7	1	99.8	1	98.5	1	97.8	1	99.6	1	99.6	1
9	86.0	0.7	84.0	0.7	98.8	1	97.7	1	99.9	1	99.9	1	92.2	1	97.7	1	100	1	100	1	98.7	1	97.3	1	100	1	99.9	1
10	83.6	0.7	84.5	0.7	98.8	1	98.7	1	98.4	1	98.7	1	98.00	1	94.1	0.9	98.8	1	98.9	1	98.1	1	98.1	1	97.6	1	97.6	1
11	90.4	0.8	89.8	0.8	98.0	1	98.2	1	98.5	1	98.9	1	97.8	1	93.0	0.9	98.2	1	98.8	1	98.9	1	99.2	1	98.8	1	98.2	1
12	89.1	0.8	89.7	0.8	98.8	1	98.8	1	99.2	1	99.5	1	92.1	0.8	94.1	0.9	98.6	1	98.4	1	97.6	1	98.6	1	97.1	0.9	97.2	0.9
13	95.6	0.9	95.3	0.9	100	1	100	1	99.9	1	99.9	1	99.7	1	98.3	1	99.9	1	99.9	1	99.9	1	100	1	99.8	1	99.8	1
14	83.1	0.7	82.2	0.7	99.7	1	99.7	1	99.4	1	99.6	1	99.5	1	99.3	1	100	1	100	1	98.2	1	98.3	1	99.3	1	100	1
15	68.4	0.4	68.9	0.4	99.2	1	99.1	1	99.1	1	99.5	1	99.2	1	97.8	1	99.4	1	99.1	1	98.4	1	97.7	1	99.0	1	99.1	1

<sup>(1)</sup> NP= Número de parcela;


<sup>(2)</sup> FG =Fiabilidad Global (%); K=Coficiente Kappa



## CLASIFICACIÓN BASADA EN PÍXELES




Paralelepíedros



Distancia Mahalanobis




Máxima Probabilidad




Spectral Angle Mapper



Support Vector Machine




Árbol Decisión



Árbol Decisión NDVI

## CLASIFICACIÓN BASADA EN OBJETOS


- Avena
- Trigo
- Sin clasificar




Paralelepíedros




Distancia Mahalanobis




Máxima Probabilidad




Spectral Angle Mapper



Support Vector Machine



Árbol Decisión



Árbol Decisión NDVI

Figura 4.8. Ejemplo de las clasificaciones basadas en píxeles y objetos de la Parcela 14 de la imagen QuickBird 2008.

La Figura 4.8 muestra el valor de FG medio de todas las parcelas obtenido para cada clasificador en cada una de las imágenes estudiadas y teniendo en cuenta la clasificación basada en píxeles y la basada en objetos. Como se puede observar en la figura, todos los algoritmos de asignación a excepción del algoritmo P, presentan una alta capacidad de discriminación bajo las circunstancias presentes en este estudio con valores de FG media superiores a 96% tanto en la imagen de 2006 como en la de 2008. Por su parte, los valores medios de FG obtenidos con el clasificador P son menores, obteniéndose una precisión mínima del 74% en con imagen de 2008.

Figura 4.9. Fiabilidad Global media de todas las parcelas analizadas en 2006 y 2008 según los métodos de clasificación.

Analizando los 6 clasificadores que presentan mejores resultados (DMa, MP, SAM, SVM, AD y AD con *NDVI*) en las Tablas 4.7 y 4.8, se observa que todos ellos obtienen unos resultados muy precisos. En las parcelas clasificadas de la imagen 2006, las mejores precisiones se obtuvieron principalmente con los clasificadores DMa, MP, SAM y SVM, siendo el clasificador DMa el que ofreció mejores resultados un número mayor de veces. Por su parte, en la imagen de 2008 los clasificadores que presentaron mayores FG fueron DMa, MP y SVM, siendo éste último el que mejores resultados ofreció. Analizando la FG media de todas las parcelas analizadas cada año (Figura 4.8), se observa como el clasificador DMa presentó el mejor valor medio de precisión en 2006 tanto en las clasificaciones basadas en píxeles como en las basadas en objetos, con valores superiores a 99% de FG y siempre con un K de 1. Sin embargo, en el año 2008 los clasificadores SVM y MP fueron los que ofrecieron las precisiones medias más altas en los análisis basados en píxeles y en objetos. Mientras que los algoritmos DMa, MP y SVM presentaron un comportamiento excelente en todas las parcelas analizadas, el algoritmo SAM fue el que obtuvo resultados más erráticos siendo uno de los que mejores resultados mostró en las parcelas de 2006 y el que peor resultado medio ofreció en las parcelas de 2008. Aún así, la capacidad de discriminación de los 6 clasificadores es muy parecida, observándose una

diferencia máxima entre el mejor y peor resultado de FG media de un 2.8%, (entre el 99.3% obtenido con DMA y el 96.3% obtenido con AD), en el análisis basado en objetos de la imagen 2006, y de un 2.6% de FG media, (entre el 99.3% obtenido tanto con SVM como con MP y el 96.7% obtenido con SAM) en el análisis basado en objetos de la imagen 2008.

Analizando más detalladamente el efecto de la segmentación de la imagen en la clasificación, también se comprobó un comportamiento similar entre ambos tipos de análisis al ofrecer valores de FG muy parecidos entre las clasificaciones basadas en píxeles y basadas en objetos. Las Tablas 4.9 y 4.10 muestran el incremento relativo de FG que suponen las clasificaciones basadas en objeto respecto a las basadas en píxeles ( $(FG_{objeto} - FG_{píxel}) * 100 / FG_{píxel}$ ). Como se puede observar en los valores de las imágenes de 2006 y de 2008, las variaciones de FG entre un tipo de análisis y el otro es mínimo en la mayoría de las parcelas estudiadas, pudiendo ofrecer pequeñas mejoras en la precisión en unos casos (valores positivos) y pequeñas reducciones en otros (valores negativos). Si se analizan en su conjunto todas las parcelas clasificadas en el año 2006, el incremento medio del análisis basado en objetos respecto al basado en píxeles tiende a ser negativo en la mayor parte de los clasificadores, llegando a bajar la FG media hasta en un 0.5% en el caso del clasificador AD y mejorando hasta un 0.2% con el clasificador MP. En las parcelas analizadas en el año 2008 ocurrió algo parecido, observándose un decremento máximo de FG media de hasta un 0.7% con el clasificador SAM y un aumento de FG de hasta un 0.2% con el MP.

Sin embargo, aunque la media del incremento de la FG no varió mucho entre clasificadores, si se analiza el incremento de FG de forma independiente para cada parcela, se observan valores muy dispares entre los distintos clasificadores y en los distintos años estudiados. En las parcelas analizadas de la imagen 2006 se obtuvo un comportamiento bastante similar entre ambos tipos de análisis (píxel/objeto) en la mayoría de los clasificadores, siendo P el clasificador que más fluctuaciones produjo con una desviación estándar de 1.7 de los datos medidos en las 11 parcelas. Con este clasificador se observaron comportamientos muy dispares, entre los que destaca un incremento de la FG de un 3.6% con la segmentación de la parcela 8 junto con una disminución de FG de hasta un 2.3% en la parcela 9 con el mismo tipo de análisis. Por su parte, los clasificadores DMA, MP y AD con *NDVI* presentaron poca oscilación de valores con desviaciones estándar de 0.3 en todos los casos. En el caso de las parcelas clasificadas con la imagen de 2008, las variaciones de FG producidas entre análisis basados en píxeles y en objetos fueron mucho mayores. En estas parcelas, el clasificador que mayor fluctuación de valores presentó fue SAM, con una desviación estándar de 2.8, mostrando valores tan dispares como un incremento de FG de hasta un 6% en la clasificación basada en objetos respecto a la basada en píxeles para la parcela 9, así como una disminución de FG de hasta un 4.9% en el mismo análisis de la parcela 11. El clasificador AD también presentó una desviación estándar de 1.5, valor muy alto respecto a los obtenidos por el resto de métodos. En este clasificador, el mayor incremento de precisión obtenido con su clasificación basada en objetos respecto a la basada en píxeles se observó en la parcela 3, con un incremento de FG de 1.7%. Sin embargo, la segmentación tuvo un efecto contrario en la parcela 1, al reducir la FG en un 4.8% de la clasificación basada en objetos respecto a la basada en píxeles.

Tabla 4.9- Comparativa de las precisiones obtenidas con las clasificaciones basadas en objetos respecto a las basadas en píxeles para las 11 parcelas analizadas en 2006.

QuickBird 2006																					
Nº P	Paralelepípedos			Distancia de Mahalanobis			Máxima Probabilidad			Spectral Angle Mapper			Support Vector Machine			Árbol Decisión			Árbol Decisión NDVI		
	P <sup>(1)</sup>		O	P		O	P		O	P		O	P		O	P		O	P		O
	FG <sup>(2)</sup>	FG	Δ	FG	FG	Δ	FG	FG	Δ	FG	FG	Δ	FG	FG	Δ	FG	FG	Δ	FG	FG	Δ
1	98.0	96.4	-1.6	99.5	99.2	-0.3	99.5	99.8	0.4	98.8	97.9	-0.9	98.6	97.4	-1.2	97.1	95.8	-1.3	99.9	99.9	0.1
2	91.3	91.1	-0.2	99.3	99.2	-0.2	99.8	99.8	0.0	99.0	98.9	-0.1	100.0	99.4	-0.6	99.1	99.1	0.0	99.1	99.3	0.3
3	76.1	77.0	1.2	98.2	98.3	0.2	95.5	95.8	0.3	98.7	98.7	0.1	96.8	97.4	0.6	95.6	95.5	-0.1	94.8	94.6	-0.2
4	90.2	91.3	1.2	99.4	99.5	0.1	99.9	99.9	0.0	96.9	97.7	0.8	99.3	99.3	-0.1	94.3	94.3	0.0	99.9	100	0.1
5	68.6	67.5	-1.6	98.1	98.0	-0.2	95.4	95.5	0.1	96.7	95.6	-1.2	97.5	97.3	-0.2	96.1	95.5	-0.7	94.6	94.6	0.0
6	91.2	90.9	-0.3	100	100	0.0	100	100	0.0	100	100	0.0	100	100	0.0	95.2	92.6	-2.7	99.8	99.9	0.1
7	89.0	90.0	1.1	100	100	0.0	100	100	0.0	100	100	0.0	100	100	0.0	99.7	99.9	0.3	100.0	100.0	0.0
8	82.4	85.3	3.6	98.9	98.9	0.0	98.8	98.8	0.0	98.5	98.1	-0.5	97.5	97.9	0.4	94.4	94.3	-0.1	98.4	98.4	0.0
9	83.6	81.7	-2.3	98.7	97.6	-1.1	97.4	98.2	0.9	99.3	98.2	-1.2	95.7	97.2	1.6	95.6	94.7	-1.0	99.0	98.9	-0.2
10	80.0	79.0	-1.3	99.8	99.8	0.0	99.8	99.8	0.0	99.1	99.0	-0.1	99.9	99.5	-0.4	99.1	99.3	0.2	99.2	99.3	0.1
11	87.9	87.6	-0.3	99.9	99.9	0.0	98.0	98.3	0.3	99.8	99.9	0.2	99.9	99.9	0.1	98.8	98.8	0.0	94.2	95.0	0.8
$\bar{X}(\Delta)$			-0.1			-0.1			0.2			-0.3			0.0			-0.5			0.1
$\sigma(\Delta)$			1.7			0.3			0.3			0.6			0.7			0.9			0.3

<sup>(1)</sup> Tipos de análisis: P: análisis basado en Píxeles; O: análisis basado en Objetos

<sup>(2)</sup> Valores de Fiabilidad: FG: Fiabilidad Global (%), Δ= incremento de la FG objeto respecto a la FG píxel;  $\bar{X}$  = media del incremento;  $\sigma(\Delta)$ = desviación estándar del incremento.

Tabla 4.10- Comparativa de las precisiones obtenidas con las clasificaciones basadas en objetos respecto a las basadas en píxeles para las 15 parcelas analizadas en 2008.

QuickBird 2008																					
Paralelepípedos			Distancia de Mahalanobis			Máxima Probabilidad			Spectral Angle Mapper			Support Vector Machine			Árbol Decisión			Árbol Decisión NDVI			
Nº P	P <sup>(1)</sup>		Δ	P		Δ	P		Δ	P		Δ	P		Δ	P		Δ	P		Δ
	FG <sup>(2)</sup>	FG		FG	FG		FG	FG		FG	FG		FG	FG		FG	FG		FG	FG	
1	37.4	37.1	-0.9	95.4	97.7	2.5	97.6	98.1	0.5	92.5	94.1	1.8	99.0	99.5	0.5	98.5	93.8	-4.8	93.8	94.0	0.2
2	91.5	90.7	-0.8	99.7	99.8	0.1	99.6	99.5	-0.1	99.6	99.6	0.0	99.7	99.7	0.0	99.0	98.9	-0.1	99.0	99.0	0.1
3	68.3	68.8	0.7	98.4	98.4	-0.1	98.1	98.3	0.2	96.9	94.0	-3.0	98.1	97.6	-0.5	91.9	93.5	1.7	98.1	98.1	0.0
4	89.7	90.2	0.6	100	100	0.0	100	100	0.0	99.8	95.8	-4.1	100	100	0.0	98.9	99.1	0.2	100	100	0.1
5	59.2	59.6	0.7	99.8	99.8	0.1	100	100	0.0	99.3	98.9	-0.5	100	99.9	-0.1	99.1	98.9	-0.3	99.9	99.9	0.0
6	53.2	53.2	0.0	98.1	98.2	0.2	98.5	98.6	0.2	97.4	96.3	-1.1	99.4	99.5	0.1	96.2	96.1	-0.1	99.1	99.1	0.0
7	51.6	51.9	0.6	99.1	98.8	-0.3	99.9	99.9	0.0	99.0	99.0	0.1	99.7	99.4	-0.3	97.7	99.0	1.3	99.0	99.1	0.1
8	68.1	68.1	0.0	99.8	99.9	0.0	99.7	99.8	0.1	99.6	99.0	-0.7	99.7	99.8	0.2	98.5	97.8	-0.8	99.6	99.6	0.0
9	86.0	84.0	-2.3	98.8	97.7	-1.1	99.9	99.9	0.1	92.2	97.7	6.0	100	100	0.0	98.7	97.3	-1.4	100	99.9	-0.1
10	83.6	84.5	1.0	98.8	98.7	-0.1	98.4	98.7	0.3	98.0	94.1	-4.0	98.8	98.9	0.1	98.1	98.1	0.0	97.6	97.6	0.0
11	90.4	89.8	-0.7	98.0	98.2	0.3	98.5	98.9	0.4	97.8	93.0	-4.9	98.2	98.8	0.6	98.9	99.2	0.3	98.8	98.2	-0.7
12	89.1	89.7	0.6	98.8	98.8	0.1	99.2	99.5	0.4	92.1	94.1	2.2	98.6	98.4	-0.2	97.6	98.6	1.0	97.1	97.2	0.1
13	95.6	95.3	-0.3	100	100.0	0.0	99.9	99.9	0.0	99.7	98.3	-1.4	99.9	99.9	0.0	99.9	100	0.2	99.8	99.8	0.0
14	83.1	82.2	-1.1	99.7	99.7	0.0	99.4	99.6	0.3	99.5	99.3	-0.3	100	100	0.0	98.2	98.3	0.1	99.3	100	0.8
15	68.4	68.9	0.7	99.2	99.1	-0.1	99.1	99.5	0.4	99.2	97.8	-1.4	99.4	99.1	-0.3	98.4	97.7	-0.7	99.0	99.1	0.1
$\bar{X}$			-0.1			0.1			0.2			-0.7			0.0			-0.2			0.0
$\sigma$			0.9			0.7			0.2			2.8			0.3			1.5			0.3

<sup>(1)</sup> Tipos de análisis: P: análisis basado en Píxeles; O: análisis basado en Objetos

<sup>(2)</sup> Valores de Fiabilidad: FG: Fiabilidad Global (%), Δ= incremento de la FG objeto respecto a la FG píxel;  $\bar{X}$  = media del incremento;  $\sigma(\Delta)$ = desviación estándar del incremento.

## 4.2. Clasificación a “escala imagen”

### 4.2.1. Discriminación de parcelas de trigo

La clasificación de las parcelas de trigo de las imágenes de 2006 y 2008 y su posterior enmascaramiento del resto de usos de suelo se realizó mediante una metodología de segmentación jerárquica. Tras la primera segmentación de nivel inferior de toda la imagen se procedió a clasificar cada una de las parcelas con los algoritmos de asignación DMA y MP. La Tabla 4.11 muestra los valores de Fiabilidad Global (FG) y coeficiente Kappa (K) de los mejores resultados obtenidos en las distintas clasificaciones para cada una de las dos imágenes. En ella se puede observar que la capacidad de discriminación de usos de suelo entre ambas imágenes fue similar con los dos clasificadores utilizados, siendo las diferencias entre ellos no superior al 0.6%. El clasificador que mejores resultados ofreció fue MP con una FG cercana al 89% y un K de 0.8 en ambos años. Por su parte, el clasificador DMA mostró un resultado algo menor al clasificar las dos imágenes con una precisión media más cercana al 86% y un K de 0.7.

Tabla 4.11- Resultados obtenidos en la clasificación de parcelas de trigo con las imágenes de 2006 y 2008.

	Distancia Mahalanobis		Máxima Probabilidad	
	FG <sup>(1)</sup>	K	FG	K
<i>Imagen</i>				
2006	86.26	0.73	88.79	0.77
2008	85.68	0.71	89.22	0.76

<sup>(1)</sup> FG =Fiabilidad Global (%); K=Coeficiente Kappa

En vista de los resultados obtenidos, tanto en el estudio de la imagen de 2006 como en la de 2008 se tomó la clasificación de MP para la realización de la segmentación de nivel superior. A partir de estos dos niveles de segmentación se llevó a cabo un análisis jerárquico en el que se relacionó los objetos clasificados como trigo en la segmentación de nivel inferior (sub-objetos) con los objetos del nivel superior (super-objetos) mediante el cálculo de la *Relación de Área de Trigo (RAT)*. La Tabla 4.12 muestra un análisis de precisiones en las clasificaciones de parcelas de trigo teniendo en cuenta distintas proporciones de trigo (RAT) en los objetos equivalentes a las parcelas (super-objetos) para las imágenes QuickBird de 2006 y 2008. El comportamiento de esta variable fue ligeramente diferente en ambas imágenes. En general, los valores de FG de la imagen 2006 fueron levemente superiores a los obtenidos en 2008, con valores que oscilaron entre el 81.66% de FG mínima y el 95.23% de FG máxima en la imagen 2006 con RAT de 0.90 y 0.35, respectivamente, mientras que en la imagen 2008 los valores oscilaron entre el 79.90% y el 91.04% de FG obtenidos con RAT de 0.10 y 0.60 respectivamente.

Junto con estos valores también se analizó la Fiabilidad del Productor del trigo (FPt) para analizar la precisión de los píxeles clasificados como trigo. Para la determinación de la mejor clasificación que definiera las parcelas de trigo, se analizaron conjuntamente ambas fiabilidades (FG y FPt) observándose que la FG más alta no iba acompañada de la mejor FPt. Así, en la imagen de 2008 la FPt mayor (99.26%) se obtuvo en la clasificación para una RAT de 0.10, la cual ofreció el peor dato de FG de todo el análisis con un valor de 79.90%. En la imagen de 2006 no llegó a ser tan marcada esa diferencia, aunque los valores de FG y FPt no eran parejos. De este modo, para cada imagen se tomó la combinación que alcanzó el mejor resultado medio entre FG y FPt. Para la imagen de 2006 se eligió la clasificación con un RAT de 0.30 cuyos valores de precisión fueron de 93.25% de FG y 95.33% de FPt. Por su parte, en la imagen de 2008 se tomó la clasificación con un RAT de 0.55 cuyas precisiones fueron 90.98% de FG y 93.20% de FPt.

Tabla 4.12- Resultados de Fiabilidad Global (%) y Fiabilidad del Productor (%) en parcelas de trigo, obtenidos a partir del análisis jerárquico con distintas proporciones de trigo (RAT).

RAT <sup>(1)</sup>	<i>Imagen</i>				
	2006		2008		
	FG <sup>(2)</sup>	FPt	FG	FPt	
0.10	91.10	96.03	79.90	99.26	
0.15	92.12	95.61	83.66	98.64	
0.20	92.85	90.37	84.77	98.60	
0.25	93.12	95.37	86.61	98.26	
0.30	93.25	95.33	87.22	97.72	
0.35	95.23	92.95	88.21	96.15	
0.40	91.98	92.24	88.90	95.06	
0.45	91.77	91.68	89.63	94.25	
0.50	91.58	91.20	90.25	93.69	
0.55	91.51	90.34	90.98	93.20	
0.60	91.69	89.12	91.04	91.85	
0.65	90.39	86.22	89.89	88.29	
0.70	90.26	85.66	89.65	86.81	
0.75	88.70	82.09	88.76	84.08	
0.80	88.11	80.49	86.82	78.30	
0.85	85.00	73.51	85.03	70.72	
0.90	81.66	66.47	82.34	62.63	

<sup>(1)</sup> RAT: Relación de Área de Trigo

<sup>(2)</sup>FG= Fiabilidad Global (%); FPt= Fiabilidad del Productor de la clase trigo (%)

4.2.2. Detección de avena en trigo

Tras aislar las parcelas de trigo del resto de los cultivos en las imágenes de 2006 y 2008, se procedió a clasificar el conjunto de estas parcelas con tres algoritmos de asignación. La Tabla 4.13 muestra los valores de FG y K obtenidos en las clasificaciones de todas las parcelas de trigo para los años 2006 y 2008. Pese a que todos los clasificadores consiguieron precisiones muy elevadas, la imagen de 2006 obtuvo clasificaciones más precisas con valores de FG superiores al 98% mientras que en la imagen de 2008 los valores oscilaron entre el 91% y el 93%. Claramente, de los tres clasificadores evaluados, MP y SVM fueron los que mejores resultados ofrecieron con pequeñas diferencias en sus resultados, 0.16% de FG en la imagen de 2006 y 0.59% en 2008. La figura 4.9 muestra la clasificación más precisa obtenida en cada uno de los años estudiados. En el caso de la imagen de 2006, la mejor clasificación logró un 98.29% de FG y un 0.97 de K con el clasificador MP (Fig. 4.9a), mientras que en la imagen de 2008 se alcanzó una FG máxima de 93.63% y un K de 0.87 con el clasificador SVM (Fig. 4.9b).

Tabla 4.13- Resultados obtenidos de la clasificación de infestaciones de avena loca en parcelas de trigo con las imágenes de 2006 y 2008.

	Distancia Mahalanobis		Máxima Probabilidad		Support Vector Machine	
	FG <sup>(1)</sup>	K	FG	K	FG	K
<i>Imagen</i>						
2006	98.00	0.96	98.29	0.97	98.13	0.96
2008	91.11	0.82	93.04	0.86	93.63	0.87

<sup>(1)</sup> FG =Fiabilidad Global (%); K=Coficiente Kappa






Figura. 4.10: Clasificación más precisa de infestaciones de avena loca en parcelas de trigo para el año: a) 2006 y b) 2008.

## 5. Discusión

Un primer análisis de los resultados obtenidos en este estudio, tanto en las clasificaciones de las parcelas individualmente como en toda la imagen, muestra que las imágenes multiespectrales QuickBird permiten la detección de la mala hierba avena loca en cultivos de trigo con altas tasas de precisión en el momento fenológico en el que se adquirieron las imágenes. Las diferencias en las respuestas espectrales entre el trigo y la avena loca se pueden atribuir a las variaciones en las cantidades relativas del contenido de clorofila, agua y la proporción de aire presente en las células debidas a la diferencia de su ciclo fenológico, variables que afectan directamente en las propiedades espectrales de la vegetación (Price, 1994; Zwiggelaar, 1998; Smith y Blackshaw, 2003). Actualmente existen algunos trabajos cuyo objetivo principal es determinar la superficie infestada de malas hierbas en cultivos en estados fenológicos tardíos mediante técnicas de tratamiento de imágenes multiespectrales. Gibson *et al.* (2004) analizaron imágenes aéreas multiespectrales de 1.3m de resolución espacial para la discriminación de malas hierbas en cultivo de soja, obteniendo un error del 11% en la terminación de presencia-no presencia de mala hierba y un error entre el 17% y el 39% en la clasificación ente especies. También con imágenes aéreas multiespectrales, pero de 0.4m de tamaño de píxel, Peña-Barragán *et al.* (2007) discriminaron *Ridolfia segetum* Moris en cultivos de girasol, alcanzando precisiones superiores al 85%. López-Granados *et al.* (2006) basaron su trabajo en discriminar malas hierbas gramíneas en trigo con imágenes aéreas de 0.3m de píxel, logrando precisiones entre el 85% y el 90% en la discriminación de malas hierbas gramíneas. Pese a las altas precisiones obtenidas en estos estudios, un problema que presentan estos análisis es la rentabilidad de las imágenes a gran escala. Por ello, nos planteamos la utilización de imágenes satélite de alta resolución espacial (ej. QuickBird) para trabajos de discriminación de malas hierbas. Estas imágenes, además de presentar un coste más reducido que las imágenes aéreas, tienen la ventaja de poder tomarse en cualquier parte del mundo. Debido a que muchas especies de malas hierbas, entre las que se destaca la *Avena sterilis*, están presentes en la mayor parte de las latitudes, la metodología propuesta y los resultados obtenidos en este capítulo pueden ser extrapolados sin grandes modificaciones.

Tras evaluar los resultados obtenidos en las clasificaciones de las parcelas de trigo de forma independiente (a "escala parcela"), se observa que todos los clasificadores presentaron precisiones muy parecidas entre sí y superiores al 90%, excepto el clasificador P, que presentó precisiones inferiores en todas las situaciones analizadas. Por su parte, los algoritmos DMA, MP y SVM son los que mostraron mejores precisiones, aunque la capacidad de discriminación de todos los clasificadores excepto P fue muy parecida, observándose una diferencia máxima de fiabilidad global entre el mejor y peor resultado de un 2.7%. De forma general, todas las clasificaciones excepto algunas realizadas con el clasificador P satisficieron el requerimiento comúnmente aceptado para considerar que una clasificación es precisa si presenta al menos un 85% de FG en la clasificación (Foody, 2002) y un valor de K superior al 0.75 (Montserud y Leamans, 1992) o 0.80 (Landis y Koch, 1977), observándose en este estudio valores superiores al 98% de FG y al 0.97 de K en muchísimos de los casos. De este modo, se cumplió el objetivo

principal de este trabajo de obtener precisiones muy altas, especialmente si el mapa temático resultante va a ser utilizado como ayuda al diseño de programas de CLMH con técnicas de agricultura de precisión.

Por otra parte, considerando los resultados obtenidos en cada parcela, las clasificaciones basadas en píxeles ofrecieron unos resultados muy similares a las clasificaciones basadas en objetos. Si se analiza la fiabilidad media de todas las parcelas en cada uno de los años estudiados y comparando la diferencias de las precisiones obtenidas con las clasificaciones basada en objetos y a las basadas en píxeles con cada unos de los clasificadores, se obtuvo que las diferencias de fiabilidad de ambos tipos de tratamientos eran casi despreciables, con valores que oscilaron desde el -0.5% al 0.2% de variación de fiabilidad en el año 2006 y con diferencias entre el -0.7% al 0.2% en el año 2008. En este sentido, los clasificadores que más diferencias mostraron entre sus análisis basados en píxeles y objetos fueron SAM, AD y MP. Los dos primeros presentaron una FG media de todas las parcelas superior en las clasificaciones basadas en píxeles que las obtenidas con objetos, mientras que el clasificador MP se comportó algo mejor con las clasificaciones basadas en objetos. Estos resultados no han podido ser comparados con otros similares ya que actualmente no existen estudios de discriminación de malas hierbas en cultivos herbáceos basados en objetos. Pese a que se podría pensar que la distribución de malas hierbas en rodales podría favorecer mejores precisiones en clasificaciones basadas en objetos respecto a las basadas en píxeles (López-Granados, 2011), en este caso los resultados obtenidos son satisfactorios. No obstante, la escasa diferenciación espectral del cultivo y la mala hierba genera objetos muy pequeños formados por muy pocos píxeles, lo que unido al excelente comportamiento de los clasificadores a nivel píxel, no permite mucho grado de mejora en las precisiones obtenidas.

Por tanto, pese a que la mayoría de los análisis supusieron muy buenos resultados, no todos son tan aconsejables debido a la complejidad del tratamiento así como a su carga computacional. Por ejemplo, comparando las clasificaciones basadas en píxeles con las basadas en objetos, éstas últimas requieren de un procesado inicial de segmentación de la imagen, procedimiento que necesita unos niveles de conocimiento avanzados junto con un programa informático de tratamiento específico que no requiere la tradicional clasificación basada en píxeles. Por tanto, ante igualdad de resultados, en este trabajo se puede concluir que para este tipo de clasificación no es necesario realizar una clasificación basadas en objetos. Lo mismo ocurre con los distintos algoritmos de clasificación. Pese a que todos requieren la misma información de partida para su ejecución, algunos presentan un coste computacional mucho más elevado que otros. Este sería el caso de los algoritmos SVM o los realizados con AD, que requieren un aprendizaje más profundo de los datos iniciales que otros algoritmos, lo que conlleva un aumento del tiempo de procesado de los datos. Por su parte, los algoritmos DMa y MP ofrecieron resultados excelentes en la mayoría de los análisis basados en píxeles y su operatividad es sencilla, rápida y está implementada en la mayoría de los programas informáticos de tratamiento digital de imágenes. En base a esta conclusión, la discriminación de avena loca en parcelas de trigo se debe realizar con los tratamientos que optimicen el proceso, es decir, que aumenten la fiabilidad de la clasificación reduciendo el coste del tratamiento (coste computacional y/o

complejidad del tratamiento) como sería la clasificación basada en píxeles con los algoritmos DMA o MP. No obstante, los procedimientos desarrollados podrían ser de utilidad para posteriores investigaciones en las que los usos del suelo presenten una mayor similitud fenológica y espectral. Este sería el caso de la clasificación de malas hierbas en estado de plántula para tratamientos en pre-emergencia en temporada.

Para la discriminación de la infestación de avena loca en parcelas de trigo a “escala imagen” fue necesario clasificar las parcelas de trigo de la imagen para, posteriormente, aislarlas del resto de usos de suelo mediante una máscara. Para este proceso se realizó un análisis basado en objetos ya que el estudio anterior expuesto en el **capítulo 2** de esta Tesis Doctoral mostró como la clasificación de usos de suelo con características muy similares a las de este trabajo fue más precisa al analizar los objetos como unidad mínima de información y no los píxeles como elementos independientes. Para este estudio se realizó una clasificación jerárquica con distintos niveles de segmentación. Así, una primera segmentación con objetos más pequeños (1º nivel de segmentación) permitió la clasificación de los distintos usos de suelo, mientras que una segunda segmentación con objetos equivalentes a las parcelas catastrales (2º nivel de segmentación) se usó para delimitar los límites exactos de las parcelas, permitiendo clasificar con más exactitud las parcelas de trigo. En este caso, los dos clasificadores utilizados, DMA y MP, ofrecieron resultados muy similares y superiores al 85% de fiabilidad en los dos años estudiados. Hasta ahora pocos son los autores que han utilizado el análisis jerárquico para la discriminación de usos de suelo agrarios. Laliberte *et al.* (2007, 2010) centraron sus trabajos en la discriminación de pastizales mediante la segmentación de las imágenes y su posterior análisis jerárquico, obteniendo fiabilidades globales entre el 70% y el 80% con imágenes QuickBird (Laliberte *et al.*, 2007) y entre 83% y 88% con imágenes tomadas con UAV (Laliberte *et al.*, 2010). Un análisis más complejo lo realizó Peña-Barragán *et al.* (2011) que llegaron a discriminar hasta 13 cultivos diferentes a partir de variables espectrales y texturales analizadas mediante un análisis jerárquico de 3 imágenes ASTER segmentadas previamente, obteniendo una precisión del 79% en toda la imagen y hasta un 90% en la clasificación de algunos cultivos.

Tras la detección de las parcelas de trigo presentes en la imagen, la discriminación de avena loca en todas las parcelas de trigo conjuntamente (“escala parcela”) también produjo unos resultados muy satisfactorios. Los tres algoritmos que mejor resultado presentaron en el análisis a “escala parcela” (DMA, MP y SVM) son los utilizados en el análisis a “escala imagen”, ofreciendo unos resultados similares, con una variación máxima del 2.5% de FG en cada año estudiado. Todos los análisis superaron el 91% de FG, observándose valores superiores al 98% para el año 2006 y superiores al 93% para el 2008. Por ello, a “escala parcela” también se cumplió el objetivo principal de este estudio de obtener un mapa temático preciso para utilizarlo como base para el diseño de sistemas de CLMH.

A modo de conclusión se puede indicar que existen diferencias espectrales significativas para la detección precisa de avena loca y trigo en imágenes multiespectrales QuickBird registradas en épocas fenológicas tardías. Los resultados obtenidos en este estudio muestran que el empleo de técnicas de clasificación más avanzadas como la segmentación o los algoritmos de clasificación basados en *Data Mining* no mejoran sustancialmente las precisiones de las clasificaciones avena-trigo. Sin embargo, la técnica de segmentación y su posterior análisis jerárquico han contribuido muy satisfactoriamente a la discriminación precisa de las parcelas de trigo del resto de usos de suelo. La finalidad de este estudio y la necesidad de altas precisiones en las clasificaciones se centra en contribuir de manera más eficiente y sostenible en el control de las malas hierbas en cultivos mediante la aplicación localizada de herbicidas y especialmente en el caso de malas hierbas gramíneas en trigo (ej. *Avena sterilis*), las cuales precisan para su control herbicidas muy específicos y caros. En este sentido, y debido a la estabilidad espacial que presentan de un año para otro (Barroso *et al.*, 2004b, Jurado-Expósito *et al.*, 2004, 2005) un mapa preciso de infestación de malas hierbas podría ser utilizado para el diseño de sistemas de CLMH pre-emergencia en años posteriores, o para aplicaciones de herbicida post-emergencia en temporada si no se ha realizado un adecuado tratamiento de control pre-emergencia. Para investigaciones futuras habría que comprobar si la metodología desarrollada es útil para discriminar esta mala hierba en estado fenológico temprano (plántula) en el cultivo de trigo.

## 6. Referencias

Barlow, J., Martin, Y., Franklin, S.E. 2003. Detecting translational landslide scars using segmentation of Landsat ETM+ and DEM data in the northern Cascade Mountains, British Columbia. *Canadian Journal of Remote Sensing* 29, 510-517.

Barroso, J., Fernández-Quintanilla, C., Maxwell, B.D., Rew, L. 2004a. Simulating the effects of spatial weed pattern and resolution of mapping and spraying on economics of site-specific management. *Weed Research*. 44, 460-468.

Barroso, J., Fernández-Quintanilla, C., Ruiz, D., Hernaiz, P., Rew, L. 2004b. Spatial stability of *Avena sterilis* ssp. *ludoviciana* under annual applications of low rates of imazamethabenz. *Weed Research* 44, 178-186.

Bhaskaran, S. Paramananda, S., Ramnarayan, M. 2010. Per-pixel and object-oriented classification methods for mapping urban features using Ikonos satellite data. *Applied Geography* 30, 650-665.

Blanco-Moreno, J.M., Chamorro, L., Sans, X. 2006. Spatial and temporal patterns of *Lolium rigidum*-*Avena sterilis* mixed populations in a cereal field. *Weed Research* 46, 207-218.

Bruzzzone, L., Carling, L. 2006. A multilevel context-based system for classification of very high spatial resolution images. *IEEE Transactions on Geoscience and Remote Sensing* 44, 2587-2600.

Bunting, P., Lucas, R. 2006. The delineation of tree crowns in Australian mixed species forest using hyperspectral compact airborne spectrographic imager (CASI) data. *Remote Sensing of Environment* 101, 230-248.

Burnett, C., Blaschke, T. 2003. A multi-scale segmentation/object relationship modelling methodology for landscape analysis. *Ecological Modelling* 168, 233-249.

Chen, Y., Su, W., Li, J., Sun, Z. 2009. Hierarchical object oriented classification using very high resolution imagery and LIDAR data over urban areas. *Advances in Space Research* 43, 1101-1110.

Chubey, M.S., Franklin, S.E., Wulder, M.A. 2006. Object-based analysis of Ikonos-2 imagery for extraction of forest inventory parameters. *Photogrammetric Engineering and Remote Sensing* 72, 383-394.

De Castro, I.A., Jurado-Expósito, M., Gómez-Casero, M.T., Gómez-Candón, D., Caballero-Novella, J.J., López-Granados, F. 2010. Discrimination of cruciferous weeds in wheat crops using QuickBird satellite imagery. In: *Proceedings of IV Symposium on Recent Advances on Quantitative Remote Sensing*, Valencia, España, pp 133-137.

Duggin, M.J., Robinove, C.J. 1990. Assumptions implicit in remote sensing data acquisition and analysis. *International Journal of Remote Sensing* 11, 1669-1694.

Eddy, P.R., Smith, A.M., Hill, B.D., Peddle, D.R., Coburn, C.A., Blackshaw, R.E. 2008. Hybrid segmentation-Artificial neural network classification of high resolution hyperspectral imagery for site-specific herbicide management in agriculture. *Photogrammetric Engineering and Remote Sensing* 74, 1249-1257.

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

FP7-NMP. 2009. Framework Programme 7 - NMP: Nanosciences, Nanotechnologies, Materials and New Production Technologies. RHEA Project (2010-2014): Robot Fleets for Highly Effective Agriculture and Forestry Management. Available at: <http://www.rhea-project.eu/>.

Gibson, K.D., Dirks, R., Medlin, C.R., Jonston, L. 2004. Detection of weed species in soybean using multispectral digital images. *Weed Technology* 18, 742-749.

Hájek, F. 2008. Process-based approach to automated classification on forest structures using medium format digital aerial photos and ancillary GIS information. *European Journal of Forest Research* 127, 115-124.

Hamouz, P., Nováková, K., Soukup, J., Holec, J. 2008. Detection of *Cirsium arvense* L. In winter wheat using a multispectral imaging system. *Journal of Plant Diseases and Protection* 21, 167-170.

Harken, J., Sugumaran, R. 2005. Classification of Iowa wetlands using an airborne hyperspectral image: a comparison of the spectral angle mapper classifier and an object-oriented approach. *Canadian Journal of Remote Sensing* 31, 167-174.

Hay, G.J., Blaschke, T., Marceau, D.J., Bouchard, A. 2003. A comparison of three image-object methods for the multiscale analysis of landscape structure. *Photogrammetric Engineering and Remote Sensing* 57, 327-345.

Heijting, S., Werf, W.V., Stein, A., Kropff, M.J. 2007. Are weed patches stable in location? Application of an explicitly two-dimensional methodology. *Weed Research* 47, 381-395.

Hester, D.B., Cakir, H.I., Nelson, S.A.C., Khorram, S. 2008. Per-pixel classification of high spatial resolution satellite imagery for urban land-cover mapping. *Photogrammetric Engineering and Remote Sensing* 74, 463-471.

Jurado-Expósito, M., López-Granados, F., González-Andújar, J.L., García-Torres, L. 2004. Spatial and temporal analysis of *Convolvulus arvensis* L. populations over four growing seasons. *European Journal of Agronomy* 21, 287-296.

Jurado-Expósito, M., López-Granados, F., González-Andújar, J.L., García-Torres, L. 2005. Characterizing population growth rate of *Convolvulus arvensis* L. in wheat-sunflower no-tillage systems. *Crop Science* 45, 2106-2112.

Karimi, Y., Prasher, S.O., McNairn, H., Bonnell, R.B., Dutilleul, P., Goel, P.K. 2005. Classification accuracy of discriminant analysis, artificial neural networks and decision trees for weed and nitrogen stress detection in corn. *Transactions of the American Society of Agricultural Engineers* 48, 1261-1268.

Koger, H.K., Shaw, D.R., Watson, C.E., Reddy K.N. 2003. Detecting late-season weed infestations in soybean (*Glycine max*). *Weed Technology* 17, 696-704.

Laliberte, A.S., Fredrickson, E.L., Rango, A. 2007. Combining decision trees with hierarchical object-oriented image analysis for mapping arid rangelands. *Photogrammetric Engineering and Remote Sensing* 73, 197-207.

Laliberte, A.S., Herrick, J.E., Rango, A., Winters, C. 2010. Acquisition, orthorectification, and object-based classification of unmanned aerial vehicle (UAV) imagery for rangeland monitoring. *Photogrammetric Engineering and Remote Sensing* 76, 661-672.

Landis, J.R., Kock, G.G. 1977. The measurement of observer agreement for categorical data. *Biometrics* 33, 159-174.

Lathrop, R.G., Montesano, P., Haag, S. 2006. A multi-scale segmentation approach to mapping seagrass habitats using airborne digital camera imagery. *Photogrammetric Engineering and Remote Sensing* 72, 665-675.

López-Granados, F., Peña-Barragán, J.M., Jurado-Expósito, M., García-Torres, L. 2006. Using remote sensing for identification of late-season grassy weeds patches in wheat (*Triticum durum*) for precision agriculture. *Weed Science* 54, 346-353.

López-Granados, F. 2011. Weed detection for site-specific weed management: mapping and real-time approaches. *Weed Research* 51, 1-11.

Möller, M., Volk, M., Firedrich, K., Lymburner, L. 2008. Placing soil-genesis and transport processes into a landscape context: A multiscale terrain-analysis approach. *Journal of Plant Nutrition and Soil Science* 171, 419-430.

Montserud, R.A., Leamans, R. 1992. Comparing global vegetation maps with the kappa statistic. *Ecological Modelling* 62, 275-293.

Moran, M.S., Inoue, Y., Barnes, E.M. 1997. Opportunities and limitations for image-based remote sensing in precision crop management. *Remote sensing of Environment* 61, 319-346.

Oetter, D.R., Cohen, W.B., Berterretche, M., Maersperger, T.K., Kennedy, R.E. 2001. Land Cover mapping in an agricultural setting using multiseasonal Thematic Mapper data. *Remote Sensing of Environment* 76, 139-155.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2007. Mapping *Ridolfia segetum* patches in sunflower crop using remote sensing. *Weed Research* 47, 164-172.

Peña-Barragán, J.M., Ngugi, M.K., Plant, R.E., Six, J. 2011. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment* 15, 1301-1316.

Price, J.C. 1994. How unique are spectral signatures? *Remote Sensing of Environment* 49, 181-186.

Rew, L.J. y Cousens, R.D. 2001. Spatial distribution of weeds in arable crops: Are current sampling and analytical methods appropriate? *Weed Research* 41, 1-18.

Robinove, C. 1981. The logic of multispectral classification and mapping the land. *Remote sensing of Environment* 11, 231-24.

Saavedra, M., Cuevas, J., Mesa-García, J., García-Torres, L. 1989. Grassy weeds in winter cereals in southern Spain. *Crop Protection* 8, 181-187.

Smith, A.M., Blackshaw, R.E. 2003. Weed-crop discrimination using remote sensing: a detached leaf experiment. *Weed Technology* 17, 811-820.

Song, C., Woodcock, C.E., Seto, K.C., Lenney, M.P., Macomber, S.A. 2011. Classification and Change Detection Using Landsat TM Data: When and How to Correct Atmospheric Effects? *Remote Sensing of Environment* 75, 230-244.

South, S., Qi, J., Lusch, D.P. 2004. Optimal classification methods for mapping agricultural tillage practises. *Remote Sensing of Environment* 91, 90-97.

Thorp, K.R., Tian, L.F. 2004. A review of remote sensing of weeds in agriculture. *Precision Agriculture* 5, 477-508.

Tsai, F., Chou, M.J. 2006. Texture augmented analysis of high resolution satellite imagery in detecting invasive plant species. *Journal of Chinese Institute of Engineers* 29, 581-592.



Urbański, J.A., Mazur, A., Janas, U. 2009. Object-oriented classification of QuickBird data for mapping seagrass spatial structure. *Oceanological and Hydrobiological Studies* 38, 27-43.

van der Werff, H.M.A., van der Meer, F.D. 2008. Shape-based classification of spectrally identical objects. *ISPRS Journal of Photogrammetry and Remote Sensing* 63, 251-258.

Yang, C., Everitt, J.H. 2010. Mapping three invasive weeds using airborne hyperspectral imagery. *Ecological Informatics* 5, 429-439.

Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M., Schirokauer, D. 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering and Remote Sensing* 72, 799-811.

Zhou, W., Troy, A. 2009a. Development of an object-based framework for classifying and inventorying human-dominanted forest ecosystems. *International Journal of Remote Sensing* 30, 6343-6360.

Zhou, W., Huang, G., Troy, A., Cadenasso, M.L. 2009b. Object-based land cover classification of shaded areas in high spatial resolution imagery of urban areas: A comparison study. *Remote Sensing of Environment* 113, 1769-1777.

Zwiggelaar, R. 1998. A review of spectral properties of plants and their potential use for crop/weed discrimination in row-crops. *Crop Protection* 17, 189-205.

**Estabilidad de los rodales de *Avena sterilis* en trigo: análisis espacial de la persistencia**

---

**CAPÍTULO V**



## Estabilidad de los rodales de *Avena sterilis* en trigo: análisis espacial de la persistencia

### Resumen

Las técnicas de manejo en agricultura tradicional consideran cada parcela como una unidad homogénea en la que las infestaciones de malas hierbas se distribuyen espacialmente de manera uniforme. Sin embargo, la realidad es muy diferente, existiendo una gran heterogeneidad a lo largo de la superficie de cultivo debido a que las malas hierbas se suelen distribuir en agregados, presentando un determinado patrón de crecimiento en función de sus características fisiológicas y de las técnicas de cultivo. En el caso de aplicar tratamientos de manera uniforme, parte de la superficie agrícola puede recibir un tratamiento innecesario, mientras que otra parte puede presentar déficit. En el presente trabajo se ha realizado un análisis espacial de la persistencia de infestaciones de avena loca (*Avena sterilis*) en cultivos de trigo (*Triticum durum*) con objeto de caracterizar su distribución espacial (estadísticas de cambio, nivel de agrupación y grado de dispersión de semillas) y diseñar mapas de tratamientos para el Control Localizado de Malas Hierbas (CLMH).

El análisis se ha realizado sobre 4 parcelas de trigo (**A, B, C, D**) infestadas de avena loca que fueron muestreadas y clasificadas en los años 2006 y 2008. La clasificación se realizó con infestaciones en fase tardía y en todo ese periodo no se realizó ningún tratamiento de control de malas hierbas. Partiendo de esa información y viendo como varió la infestación entre el año 2006 y 2008, se realizó un estudio espacial para **analizar la persistencia** de la distribución de la infestación. En primer lugar se calcularon unas estadísticas de cambio de usos del suelo (trigo-avena) para determinar la variación de superficie infestada entre ambas cosechas. A continuación se aplicó el Índice de Moran a las cuatro parcelas en cada uno de los años estudiados para determinar si existió agregación en la infestación, es decir, si la infestación se distribuyó en rodales, o si ésta se localiza de forma dispersa por la parcela. Finalmente, se estudió el grado de dispersión de las infestaciones a partir del cálculo de distancias entre las avenas de 2006 y las nuevas avenas de 2008.

En general, estos análisis mostraron que en las Parcelas A, B y D se había observado un incremento generalizado de la superficie infestada de un 7.80%, 30.94% y 6.47%, respectivamente. Sin embargo, la parcela C presentó un comportamiento opuesto al disminuir la superficie de avena en un 5.84%. Del total de superficie clasificada como avena en el año 2006, la proporción de superficie que siguió siendo avena en el año 2008 fue muy variable entre parcelas, con valores que oscilaron entre un 92.82% de superficie que presentó la misma localización de avena en la parcela B hasta sólo un 44.43% de superficie coincidente en la parcela C. Por su parte, el análisis de distribución de la infestación mediante el Índice de Moran mostró que todas las parcelas presentaban una

alta autocorrelación espacial positiva (valores del índice entre 0.60 y 0.84), lo que indicó que la distribución de las malas hierbas fue en rodales y, por tanto, el diseño de futuros tratamientos localizados de herbicida podría ser factible. Finalmente, el análisis del grado de dispersión de la infestación mostró que la mayor parte de las nuevas avenas se localizaron cerca de avenas anteriores (avenas fuente). Como dato medio de las cuatro parcelas analizadas se observó que el 25%, 50%, 75% y 95% de las nuevas avenas de 2008 se encontraron a aproximadamente 1m, 4m, 9m y 25m de las avenas anteriores (avenas 2006), respectivamente.

A partir de estos datos se diseñaron 5 programas de CLMH en función del nivel de infestación que se decidió controlar. Estos sistemas partieron de los datos de infestaciones de 2006 como base de estudio para proponer un sistema de control de malas hierbas para el siguiente cultivo de trigo (año 2008). A partir de dicha información, y en función de la proporción de avenas a controlar, se ampliaron las zonas de tratamiento (buffers). Estos tratamientos se basaron en unidades de manejo de 15x15m, y sobre cada una de estas unidades se determinó la superficie infestada. Como umbral de manejo se consideró que todas aquellas zonas con infestaciones superiores al 25% debían ser tratadas. Al aplicar producto en toda la unidad de manejo, la superficie tratada aumentó considerablemente respecto a la superficie considerada como posiblemente infestada. La Parcela A fue la que más acusó este efecto, tratando hasta un 25% más de superficie de la parcela que la realmente infestada. Sin embargo, los tratamientos de las Parcelas B, C y D no llegaron a tratar en exceso tanta superficie, siendo entre un 1% y un 14.9% la diferencia entre superficie tratada y superficie considerada como infestada. Tras el diseño de los 5 tratamientos en cada una de las parcelas, se realizó un análisis económico mediante una curva de equilibrio donde se comparó el coste que supondría tratar cada una de las parcelas con técnicas de precisión y las pérdidas debidas a la existencia de malas hierbas en el cultivo en aquellas zonas no controladas. Este análisis mostró que el umbral económico de tratamiento de las parcelas A, C y D se encontraba entre 1m y 4m alrededor de las avenas infestadas en el año 2006. Sin embargo, la Parcela B mostró que su umbral se encontraba tratando una distancia entre 9m y 25m alrededor de las avenas de 2006. Ello pudo ser debido a que dicha parcela presentó un mayor nivel de infestación y éstas estaban muy agrupadas, por lo que un aumento de la superficie a controlar pudo optimizar el proceso.

## 1. Introducción

A diferencia de la agricultura tradicional basada en la aplicación de insumos (fertilizantes, herbicidas y pesticidas) de forma uniforme en toda la parcela de cultivo, la agricultura de precisión muestra un conjunto de técnicas agrarias basadas en la aplicación localizada de productos en base a las necesidades que presenta el cultivo en cada momento, permitiendo mantener una producción agrícola de calidad tanto cuantitativa como cualitativa. Para poder diseñar correctamente estos sistemas de manejo localizado es necesario conocer a fondo el comportamiento de cada uno de los aspectos químicos (grado de fertilidad del suelo o contenido de humedad) o biológicos (crecimiento de malas hierbas, aparición de plagas o estado fitosanitario del cultivo) que demandarán la aplicación de insumos.

### 1.1. Control Localizado de Malas Hierbas (CLMH)

El manejo y control de malas hierbas en cultivo es un campo de aplicación donde la agricultura de precisión cobra una gran importancia. A pesar de que usualmente las aplicaciones de herbicida se realizan de forma uniforme en toda la parcela, la población de malas hierbas tiende a distribuirse a lo largo de la dirección del cultivo (Gerhards and Christensen, 2006) y puede aparecer agregada formando rodales (Jurado-Expósito *et al.*, 2003; 2004; 2009). Esta distribución de las malas hierbas favorece las técnicas de Control Localizado de Malas Hierbas (CLMH). Estos tratamientos permiten diseñar un sistema de aplicación de herbicida en aquellas zonas donde esté presente la mala hierba, ajustando el volumen de producto a aplicar en función de la densidad de mala hierba, del umbral económico de la aplicación, de las propias características de las distintas especies de malas hierbas presentes en cada rodal, o incluso del grado de resistencia a los herbicidas (Timmermann *et al.* 2003; Maxwell and Luschei, 2005; Wiles, 2009). Los beneficios económicos y medioambientales que suponen los CLMH incluyen la reducción del volumen de herbicida, del tiempo de aplicación y el aumento del control de las malas hierbas (Felton *et al.*, 1991; Thompson *et al.*, 1991; Medlin *et al.*, 2000). Este tipo de técnicas son muy apropiadas para los objetivos actuales de la Unión Europea, donde se apuesta por técnicas que minimicen el uso de herbicidas y permitan el control de proceso de producción agrícola mediante la trazabilidad de los productos (FP7-NMP, 2009). En la actualidad, para realizar la discriminación y mapeo de rodales de malezas se está utilizando teledetección con imágenes de alta resolución espacial, a la vez que se están probando nuevas técnicas de análisis de imagen.

### 1.2. Estabilidad de los rodales de malas hierbas

Debido al coste que supone la generación de mapas de infestación de malas hierbas, es importante minimizar la frecuencia de mapeo. En este sentido, la estabilidad y el comportamiento de cada mala hierba son críticos. Malas hierbas que presenten una distribución espacial estable permitirán generar mapas de infestaciones espaciado en el

tiempo, posiblemente cada 3 ó 4 años. Por el contrario, especies invasoras que sufran cambios rápidos en su distribución espacial requerirán crear mapas de infestaciones cada poco tiempo. La tasa de dispersión de semillas de malas hierbas anuales es dependiente del sistema natural de dispersión de cada planta (dispersión primaria), y de las operaciones agrarias realizadas sobre ellas (dispersión secundaria). En general, aquellas especies cuya dispersión no depende del viento suelen diseminar sus semillas en distancias cortas, menor de 0.5m en muchos casos (Blattner y Kadereit, 1991; Howard *et al.*, 1991; Nadeau y King, 1991). Sin embargo, las malas hierbas altas, y especialmente aquéllas que retienen las semillas hasta la recolección, presentan movimientos de sus semillas por la maquinaria agrícola en su misma parcela e, incluso, hacia otras parcelas. Por ello, la tasa de dispersión aumenta considerablemente, aunque la mayor parte de las semillas se localizan en los primeros metros (Ballaré *et al.*, 1987; Howard *et al.*, 1991).

### 1.3. El caso de la Avena loca

La avena loca (*Avena sterilis*) es una de las principales malas hierbas asociadas a los cereales de invierno, causando importantes reducciones en los rendimientos de los cultivos tanto en Europa como en Norte y Sur América, Australia e India (Wille *et al.*, 1998; Walker *et al.*, 2002). Esta mala hierba altamente competitiva, que se caracteriza por producir un gran número de semillas, está ampliamente implantada en cultivos cerealísticos cultivados en bajo condiciones de clima Mediterráneo. Distintos estudios han demostrado que la avena se distribuye en agregados espaciales con densidad variable, los cuales suelen persistir a lo largo de los años (Barroso *et al.*, 2004b; Blanco-Moreno *et al.*, 2006). Este hecho no se tiene en cuenta en la agricultura convencional, en la que un campo de cultivo es considerado como un espacio uniforme sobre el que se aplica el mismo tratamiento fitosanitario herbicida sobre toda su superficie. Sin embargo, la disponibilidad de herbicidas selectivos, su coste relativamente alto en producciones de secano y la presión social y política para reducir su uso, está propiciando el diseño de CLMH, tratamientos en los que la necesidad de que las malas hierbas se encuentren agregadas en rodales es una de sus condiciones. Siguiendo esta línea, se ha comprobado que la utilización de bajas dosis de herbicidas avenicidas sobre los rodales consiguen una disminución en la producción de semillas, lo que se traduce en una reducción exponencial del número de plantas en el transcurso de los años (Barroso *et al.*, 2004b). Sin embargo, este control debe estar ajustado a la densidad que presente dicha mala hierba. Barroso *et al.* (2009) compararon el efecto de tres tratamientos del herbicida imazamethabenz aplicado con dosis distintas en función de la densidad de avenas durante tres campañas sucesivas. El tratamiento que aplicó con la dosis completa (dosis recomendada por el fabricante) consiguió controlar satisfactoriamente la emergencia de malas hierbas en esos tres años, mientras que los que redujeron su dosis presentaron problemas de nuevas emergencias, sobre todo en aquellas zonas iniciales de baja densidad de mala hierba que fue tratada con dosis herbicida excesivamente baja.

A la hora de decidir las zonas tratadas, se suele controlar la densidad de la infestación de mala hierba teniendo en cuenta el número de plantas emergidas por metro cuadrado de cultivo. Para el caso de infestaciones de avena loca, Cussans (1980) propuso unos rangos de densidad de infestación en función del efecto que ejercían las malas hierbas sobre la producción del cultivo. Según esta clasificación de densidades, aquellas zonas con menos de 0.1 panícula por m<sup>2</sup> se consideran libres de malas hierbas y, por tanto, sin efecto sobre la producción de trigo en la siguiente cosecha. Cuando la densidad presenta entre 0.1 y 1 panículas por m<sup>2</sup> existe una infestación reducida de malas hierbas que no causará una competición con el cultivo muy acusada en la siguiente cosecha. Infestaciones de 1 a 10 panículas por m<sup>2</sup> muestran un grado de infestación medio que probablemente repercutirá en la producción de trigo del año próximo. Finalmente, si la densidad de avenas es superior a 10 panículas m<sup>2</sup>, el grado de infestación se considera muy elevado y acarreará grandes pérdidas de producción en cosechas sucesivas.

Se ha demostrado el ahorro económico que supone la utilización de agricultura de precisión en el control de malas hierbas (Timmermann, *et al.*, 2003). El beneficio económico de los tratamientos localizados de herbicida dependen de diversos factores tales como la proporción de la parcela que está infestada, el número de rodales en los que se encuentra la mala hierba y la resolución espacial posible en la tecnología de obtención de mapas y de pulverización (Barroso *et al.*, 2004a). Diversos estudios han intentado cuantificar estos beneficios. Por ejemplo, Luschei *et al.* (2001) determinaron el porcentaje máximo de superficie infestada que debía ser tratado para que fuera rentable el sistema de CLMH. Por su parte, Barroso *et al.* (2004a) analizaron la rentabilidad de los sistemas de CLMH teniendo en cuenta tanto el porcentaje de superficie infestada como las condiciones de agregación (tamaños de rodal). Finalmente, Fernández-Quintanilla *et al.* (2006) centraron su estudio de rentabilidad en el análisis de distintas dosis de tratamiento en función de la densidad de infestación.

La aplicación de cualquier tipo de tratamiento para el control de infestaciones de malas hierbas produce una reducción exponencial del número de plantas invasoras en el transcurso de los años (Barroso *et al.*, 2004b). En muchos casos, y sobre todo en momentos donde el precio del trigo es bajo, es frecuente que se prescindiera de este tratamiento debido a que las pérdidas de producción producidas por la competencia de la avena loca con el trigo es inferior al coste del tratamiento herbicida Fernández-Quintanilla *et al.* (2006). Este hecho da lugar a campos de trigo infestados de avena loca con densidades muy variables en las diferentes zonas de una parcela que van extendiéndose por toda la superficie a lo largo del tiempo. Sin embargo, gran parte del beneficio económico de los agricultores de cereales, y especialmente en los cultivos de trigo duro, viene dado por las ayudas de la PAC, ayudas que se basan en la superficie cultivada. Esta subvención viene determinada por las condiciones del cultivo, estableciéndose para los herbáceos que deben ser sembrados con arreglo a las normas locales reconocidas y conservados al menos hasta el comienzo de la fase de floración, en condiciones normales de crecimiento, de acuerdo con el sistema de explotación (FEGA, 2007). Dentro de los criterios de conservación de los cultivos se encuentra el control de la emergencia de malas hierbas, emergencia que se considera debida a un cuidado deficiente del cultivo. En el caso



de que un cultivo presente un elevado grado de infestación de malas hierbas, se produce una penalización basada en una disminución de la superficie equivalente a la infestación en el cobro de la ayuda de la PAC.

### *1.4. Objetivos*

En varios trabajos de teledetección de malas hierbas en fase tardía se afirma que los mapas de malas hierbas obtenidos tienen vigencia los años próximos a su clasificación dado que los rodales son estables (López-Granados *et al.*, 2006; Peña-Barragán *et al.*, 2007; García-Torres *et al.*, 2008) aunque se han llevado a cabo muy pocos experimentos de campo que lo corroboren (López-Granados y García-Torres 1993, 1998). Por tanto, el principal objetivo de este estudio fue plantear el diseño de un sistema de CLMH para el manejo de infestaciones de avena loca en cultivo de trigo en años consecutivos, previa clasificación de infestaciones tardías con imágenes QuickBird en años anteriores. Para obtener dicho objetivo se realizó un análisis de persistencia espacial de las infestaciones de malas hierbas en cuatro parcelas analizadas en los años 2006 y 2008, lo que permitió caracterizar el comportamiento de la infestación (estadísticas de cambio, nivel de agrupación y grado de dispersión de sus semillas). Con esta información se plantearon distintos sistemas de manejo localizado de malas hierbas basados en agricultura de precisión que fueron evaluados económicamente para determinar el umbral óptimo de tratamiento.

## **2. Materiales**

### *2.1. Zona de estudio*

El análisis de estabilidad de rodales de avena en cultivo de trigo se realizó en 4 parcelas de control situadas en el municipio de La Lantejuela, en la provincia de Sevilla (Fig. 5.1). Esta zona se caracteriza por presentar un relieve relativamente plano junto con un clima Mediterráneo continental caracterizado por veranos largos y secos e inviernos suaves. Para el estudio se realizaron 2 campañas de campo, una en 2006 y otra en 2008, dado que la rotación de cultivos prácticamente impidió que alguna parcela de trigo de 2007 coincidiera con parcelas de trigo de 2006. Pese a que en 2006 se muestrearon 11 parcelas y 15 en 2008, sólo 4 de ellas presentaron cultivo de trigo en ambos años. Esta limitada coincidencia en los tipos de cultivos en el periodo estudiado se debió a que en esa zona se produjo una variación importante de los usos de suelo agrario, fundamentalmente debido a la conversión de parcelas de herbáceos a olivar.

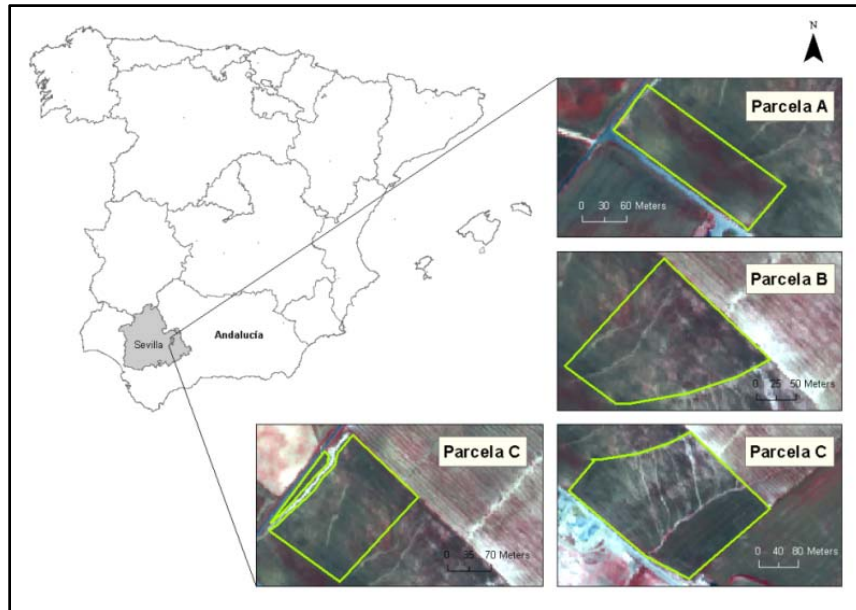


Figura 5.1. Localización del área de estudio en Andalucía.

Tras como se determinó en el **capítulo 3** de esta Tesis Doctoral, para la discriminación de la mala hierba avena loca (*Avena sterilis*) en trigo (*Triticum durum*) se tomaron las imágenes en el momento fenológico donde las plantas de trigo se encontraban en un estado de senescencia avanzado y con una coloración amarillenta, mientras que las avenas presentaban un estado de maduración avanzado pero todavía verdes, al ser éstos los estados fenológicos más apropiados para su discriminación. En función de las condiciones climáticas de cada año, la toma de imágenes se llevó a cabo en mayo de 2006 y 2008 con pocos días de diferencia. En ambos años se realizó una campaña de campo intensiva para definir la posición de los distintos rodales de avena en las cuatro parcelas de trigo. Junto a estas cuatro parcelas, en dicha campaña de campo también se muestrearon otras parcelas de trigo que han sido analizadas en estudios anteriores. Todas las características de muestreo se encuentran explicadas en el **capítulo 4** de esta Tesis Doctoral.

## 2.2. Imágenes de satélite y pre-procesado

Como se ha indicado anteriormente, las imágenes utilizadas fueron adquiridas por el satélite QuickBird el 15 de Mayo de 2006 y el 22 de Mayo de 2008. Las características de las imágenes así como el procesado realizado se encuentran explicados en el **capítulo 4** de esta Tesis Doctoral.

## 3. Metodología

El análisis llevado a cabo se centró en evaluar la persistencia de los rodales de malas hierbas en parcelas de trigo no tratadas, junto con la propuesta de un sistema de manejo localizado para la optimización del tratamiento de herbicidas.

### 3.1. Análisis de persistencia de avena en trigo

#### 3.1.1. Detección de cambios

Se realizó un análisis de persistencia de avena en trigo a partir del estudio de los datos obtenidos a nivel parcela de las cuatro parcelas estudiadas (Parcelas A, B, C y D) en los años 2006 y 2008 (Fig. 5.2). Las clasificaciones trigo-avena utilizadas para este estudio multitemporal se obtuvieron del análisis realizado en el **capítulo 4** de esta Tesis Doctoral. De este modo, se tomaron como clasificación de referencia para cada parcela y cada año estudiado, la mejor clasificación obtenida en el análisis de dicho capítulo de la Tesis, independientemente de si estas clasificaciones se alcanzaron mediante técnicas basadas en píxeles o en objetos y a partir de la clasificación de las bandas multiespectrales o del índice *NDVI*.

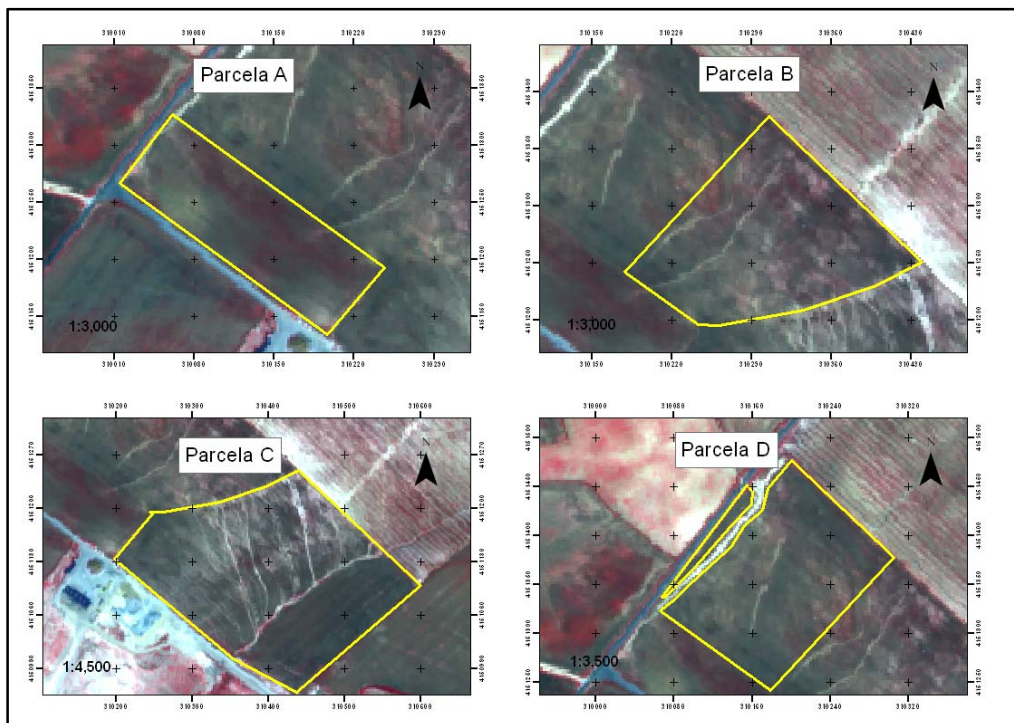


Figura 5.2. Parcelas analizadas en los años 2006 y 2008.

Una primera parte del análisis se basó en un estudio de **detección de cambios** espaciales entre las dos fechas (2006-2008) realizado con el software ENVI 4.5 (*ITT Visual Information Solutions, 2008*). Este análisis partió de una cuantificación superficial de la distribución avena y trigo en cada parcela en ambos años estudiados. A continuación se realizó un análisis de estadísticas de cambio que tomó como referencia el estado inicial del estudio (año 2006). En este análisis se determinó, para cada uso de suelo considerado en el año 2006, el cambio sufrido por esos píxeles en la imagen del estado final (2008). Junto con este análisis también se realizó un mapa de diferencias que mostró gráficamente las diferencias en los usos de suelo entre el estado inicial (año 2006) y final (año 2008) de las parcelas estudiadas. Este mapa se obtuvo restando la clasificación de 2008 a la de 2006 (estado final - estado inicial) y determinando los valores de cambio de usos del suelo (Tabla 5.1).

Tabla 5.1- Características del análisis de cambio.

Posibilidad	Regla numérica <sup>(1)</sup>	Valor	Cambio
Avena 08-Avena 06	1-1	0	No Cambio
Trigo 08-Trigo 06	2-2	0	No Cambio
Trigo 08-Avena 06	2-1	1	Aumento de trigo
Avena 08-Trigo 06	1-2	-1	Aumento de avena

<sup>(1)</sup> Avena=1; Trigo=2

### 3.1.2. Autocorrelación espacial

Tras conocer el porcentaje de cambio de cada uso del suelo (trigo/avena) en cada parcela en los dos años estudiados, también fue interesante conocer si existió agregación en la localización de las malas hierbas o si éstas se encontraron dispersas por toda la imagen. Una agregación en los datos nos indica que la infestación de avenas se distribuye en rodales, lo que facilita el diseño de mapas de tratamiento localizado de herbicida tanto para el año de estudio como para años sucesivos. Para el análisis del grado de agregación se calculó el Índice de Moran. Este análisis se realizó con el software ArcGIS 9.3 (ESRI INC, 2008).

El Índice de Moran (Moran, 1950) muestra el grado **de correlación espacial** que presenta cada una de las variables estudiadas (trigo/avena). La autocorrelación espacial se basa en que todas las variables están relacionadas entre sí, pero las variables más próximas en el espacio tienen una relación mayor que las distantes (Tobler, 1970). El índice de Moran puede ser entendido como un coeficiente de correlación entre valores del mismo factor medido en localizaciones vecinos, y se calcula siguiendo la siguiente expresión (1):

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n \sum_{j=1}^n w_{ij} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (1)$$

donde  $x_i$  y  $x_j$  son los valores que toma la variable de estudio en los puntos  $i$  y  $j$ ,  $\bar{x}$  su promedio,  $n$  el número de puntos analizados y  $w_{ij}$  la matriz de distancias que define si los puntos geográficos  $i$  y  $j$  son o no vecinos.

Para definir si una **autocorrelación espacial** es significativa se realiza un test de hipótesis nula, comprobando si la configuración espacial de la variable se produce aleatoriamente, es decir, si se cumplen o no los supuestos del modelo a partir de estimar si un estadístico muestral difiere significativamente de lo esperado aleatoriamente. Esta prueba se efectúa al ubicar el coeficiente de Moran dentro de una curva normal de probabilidades. Para ello se realiza un proceso de aleatorización donde los datos de las unidades espaciales se intercambian (permutan) al azar, obteniéndose diferentes valores de autocorrelación que se comparan con el producido en la distribución real. Luego se especifica el nivel de significancia, que indica la probabilidad de rechazar la hipótesis nula siendo ésta verdadera. Asimismo, el  $p$ -valor es el resultado que nos brinda el test de

hipótesis. Si el nivel de significancia es superior al  $p$ -valor, se rechaza la hipótesis nula y se acepta la alternativa. En caso contrario se comprueba la hipótesis nula, es decir, que la configuración espacial se produce de forma aleatoria.

Este índice toma valores en el rango entre -1 y 1, aunque puede superar ambos límites (Cliff y Ord, 1981; Upton y Fingleton, 1985). Cuando no existe autocorrelación espacial, su valor tiende a 0, mostrando que las unidades espaciales vecinas presentan valores producidos en forma aleatoria. La autocorrelación espacial positiva se observa con valores mayores de 0 (positivos) e indica que las unidades espaciales vecinas presentan valores próximos y, por tanto, hay una tendencia al agrupamiento o concentración de las unidades espaciales. Finalmente, la autocorrelación espacial negativa se obtiene con valores del índice de Moran menores de 0 (negativos) e indica que las unidades espaciales vecinas presentan valores muy disímiles y que existe una tendencia a la dispersión de las unidades espaciales. El análisis de autocorrelación espacial se realizó para las cuatro parcelas estudiadas (parcelas A, B, C y D). Además, el índice se calculó en los dos años estudiados 2006 y 2008, para corroborar que el patrón espacial se mantenía a lo largo del tiempo.

### *3.1.3. Análisis de la distancia de propagación*

Una vez que se comprobó si existía o no cierto grado de agregación en la situación espacial de la avenas, tanto en el año 2006 como en 2008, fue necesario comprobar si la aparición de nuevas avenas estaba influenciada o no por la situación espacial de las avenas anteriores. Con este análisis se pretendió determinar si la dispersión de la semilla se realizó a distancias cortas de la fuente (avenas 2006) o si por el contrario estuvo muy influenciada por factores externos como el viento o la maquinaria agrícola, que alejan su germinación de la fuente. En general, distancias de dispersión cortas pueden implicar un patrón espacial agregado de plántulas, lo que facilitaría conocer el comportamiento de la mala hierba con vistas a proponer mapas de CLMH más ajustados para años sucesivos.

El **análisis de la distancia de propagación** se realizó mediante el cálculo de la mínima distancia existente ente cada píxel clasificado como avena en la imagen de 2008 y el píxel de avena 2006 más cercano, considerando que éste podría ser la fuente de la semilla. El cálculo de esta distancia se realizó con el software *ArcGIS* 9.3 (ESRI INC, 2008). Una vez obtenida esta información, la distribución de distancias se representó como un histograma de frecuencias en el que se pudo determinar si existía una mayor distribución de avenas en zonas cercanas al origen (gran dependencia espacial de las avenas 2008 de la avenas 2006), o si bien existía un comportamiento más aleatorio en el que no se observaba ningún tipo de tendencia (independencia espacial de las avenas de ambos años).

### 3.2. Mapas de Control Localizado de Malas Hierbas (CLMH)

La información sobre el grado de infestación de la mala hierba avena loca en las cuatro parcelas analizadas en los años 2006 y 2008 se obtuvo tomando como clasificación de referencia la mejor clasificación obtenida en el análisis “a escala parcela” del **capítulo 4** de esta Tesis Doctoral para cada parcela y cada año estudiado. Estos mapas sirvieron de base para determinar tanto la superficie infestada de plantas de avenas como la ocupada por el cultivo, y así poder diseñar un programa de CLMH. En el análisis no se tuvo en cuenta la densidad de la infestación. Sin embargo, y debido a que el tratamiento se realizará en el siguiente cultivo de trigo, se deberían tratar todas aquellas infestaciones cuya densidad de mala hierba fuera moderada o superior (más de 10 panículas por m<sup>2</sup>). Según estas densidades, y teniendo en cuenta que el tamaño del píxel utilizado para este análisis fue de 2.4m, (5.76m<sup>2</sup>/píxel), infestaciones bajas de avena serían prácticamente indetectables para este tipo de imagen. Por ello, todas los píxeles clasificados de avena presentarán un nivel de infestación suficientemente elevado como para ser tratado.

Sobre estos mapas se diseñó una **malla homogénea** que cubrió toda la zona cultivada. El diseño de esta malla se realizó en base a una serie de limitaciones que tiene el sistema de pulverización. En primer lugar, es importante tener en cuenta el ancho de barra del pulverizador. Pese a que existen diversos anchos de barra, para este estudio se consideró un ancho de 15m y se previó la situación más desfavorable en la que no se puede controlar las secciones de la barra de forma independiente. Por otra parte, existe un tiempo necesario para alcanzar la estabilidad adecuada del pulverizador (presión, caudal y tamaño de la gota) al abrir y cerrar las boquillas, lo que debe ser controlado con la longitud del tratamiento. Puesto que tampoco se sabe cuál será la dirección del tractor a la hora de hacer la operación de aplicación de herbicidas, en el estudio se propuso una malla regular de 15 x 15m que recorra toda la superficie a tratar.

La determinación de las **zonas de manejo** se obtuvieron con el software SARI (*Sectioning and Assessment of Remote Images*) (García-Torres *et al.*, 2008). SARI es un software diseñado para manejar imágenes para aplicaciones agrícolas localizadas (García-Torres *et al.*, 2009), pudiendo ser utilizado para diseñar tratamientos localizados de malas hierbas. El software dividió la parcela con una malla de 15x15m formando unidades de tratamiento y en cada unidad agrupó y clasificó zonas con infestación de avena, creando *clusters*. En función de la superficie de avena presente en cada unidad, ésta fue clasificada como infestada o no. Para el estudio se consideró que todas las unidades de manejo que presentaran más del 25% de malas hierbas fueran tratadas Barroso *et al.* (2004a). Se tuvieron en cuenta 4 clases de infestaciones según la superficie infestada que definieron las zonas a tratar o no tratar (Tabla 5.2).

Tabla 5.2- Grados de infestación considerados para el CLMH.

Superficie infestada (%)	Grado de infestación	Tratamiento localizado
0-25%	Bajo	No
25-50%	Medio	Sí
50-75%	Alto	Sí
75-100%	Muy alto	Sí

El diseño del sistema de manejo se realizó sobre la clasificación realizada en el año 2006, con vista a predecir el tratamiento necesario para el siguiente cultivo de trigo (año 2008). Con la información obtenida en el estudio del grado de dispersión de la infestación (avena 2008) respecto a la fuente (avena 2006), se planificaron 5 tratamientos diferentes. Un tratamiento T1 no tuvo en cuenta los datos obtenidos en 2008, planificando el tratamiento a partir de la dispersión de malas hierbas detectadas en 2006. El resto de tratamientos tuvieron en cuenta que tras el cultivo de 2006 se produjo un cierto grado de dispersión de infestación, por lo que se incrementaron las zonas de manejo alrededor de las zonas infestadas en 2006 en función del comportamiento medio de las cuatro parcelas estudiadas. De esta forma, se definieron los tratamientos T2, T3, T4 y T5 con un incremento de distancia que recogiera un 25%, 50%, 75% y 95% de las nuevas plantas de avena surgidas en 2008.

### 3.3. Estudio económico

Finalmente, a los distintos tratamientos (T1, T2, T3 y T4) se les realizó un análisis para evaluar la viabilidad económica de las distintas estrategias. Este análisis se basó en comparar el coste económico (€) que supone realizar la aplicación localizada de herbicida para cada uno de los tratamientos en cada una de las parcelas con la pérdida económica (€) asociada a la bajada de producción que producen las malas hierbas que no se han conseguido eliminar tras el tratamiento. Puesto que el tratamiento se realizó sobre la infestación realizada en 2006 y se conoce cómo evolucionó la infestación en 2008, se pudo ver el efecto que tendrían cada uno de los tratamientos ya que se calculó la superficie donde se produjo la eliminación de las malas hierbas (superficie tratada) y la superficie de malas hierbas que permanecieron tras el tratamiento.

El cálculo del coste total que supondría la aplicación de herbicida (C) se realizó teniendo en cuenta los gastos fijos y variables del proceso mediante la expresión (2):

$$C = C_{\text{mapa}} + C_{\text{pulverización}} \quad (2)$$

donde  $C_{\text{mapa}}$  representa los costes asociados a la obtención del mapa de malas hierbas y  $C_{\text{pulverización}}$  todos los costes asociados a la pulverización de producto en las zonas definidas en el mapa de CLMH. De forma más precisa, el coste total que supondría la aplicación de herbicida (C) se puede expresar con la siguiente expresión (3):

$$C = [(C_i + C_p) \times S] + [(D_h \times C_h) + C_{mp}] \times S_t \quad (3)$$

donde  $C_i$  es el coste de la imagen,  $C_p$  es el coste de la generación del mapa de infestaciones,  $S$  es la superficie total de la parcela,  $D_h$  es la dosis de herbicida recomendada,  $C_h$  es el coste del herbicida,  $C_{mp}$  es el coste de la maquinaria de pulverización con sistema de aplicación localizada y  $S_t$  es la superficie tratada.

Los parámetros económicos utilizados para el cálculo del **coste de aplicación de herbicida** fueron: coste de la imagen 0.185€/ha para la adquisición de una imagen QuickBird multiespectral (Eurimage, 2010); coste del procesado de datos y obtención del mapa de infestaciones 0.2€/ha; dosis recomendada de herbicida 0.2 l/ha; coste del herbicida (Clodinafop propargil 24% + Cloquintocet mexil 6%) 215€/l y coste de la maquinaria de pulverización 20.1€/ha (Ruiz *et al.*, 2006). En el caso de la compra de la imagen, no se tuvo en cuenta la limitación de superficie mínima impuesta por la compañía distribuidora al considerar que esta técnica se impone en una determinada región y que una misma escena sirve para diversos agricultores. Por otra parte, en el cálculo del coste asociado al procesado se considera que el método de clasificación está puesto a punto y que se hace conjuntamente al grupo de agricultores que han solicitado este tratamiento.

Por otro lado, para el cálculo de la **pérdida económica** (4) asociada a la bajada de producción (P) que producen las malas hierbas se tuvo en cuenta los siguientes factores :

$$P = P_{producción} + P_{ayudas} \quad (4)$$

donde  $P_{producción}$  tienen en cuenta las pérdidas económicas debidas a la disminución de la producción de trigo por infestación de avena loca y  $P_{ayudas}$  muestra las pérdidas debidas a la penalización de superficie en las ayudas agrarias. De forma más precisa, la pérdida económica asociada a la bajada de producción (P) se puede expresar con la siguiente expresión (5):

$$P = (D_p \times P_t) + (A \times S_i) \quad (5)$$

donde  $D_p$  muestra la disminución de producción debida a la infestación de malas hierbas,  $P_t$  el precio del mercado del trigo, A las ayudas agrarias asociadas al cultivo de trigo duro y  $S_i$  superficie infestada de avena loca tras el tratamiento localizado, considerando que toda la superficie tratada ha quedado libre de malas hierbas.

Los parámetros económicos utilizados para el cálculo de la pérdida económica asociada a la bajada de producción fueron: pérdidas de producción 250kg/ha, valor medio obtenido a partir del intervalo de pérdida de producción (100-400kg/ha) de trigo debido a infestaciones de avena (Fernández-Quintanilla *et al.*, 2006); precio del trigo 0.18€/kg, precio medio calculado en base a los datos mostrados por la Asociación de Comercio de Cereales y Oleaginosas de España y ayudas agrarias al cultivo del trigo duro 545.6€ (63€/t por el rendimiento medio de los cereales determinado en el Plan de Regionalización (3.2 t/ha para la zona de estudio) + 344€/ha de suplemento de trigo duro) (MAMR, 2011). La superficie infestada de avena tras el tratamiento herbicida se calcula eliminado de la infestación real de 2008 las zonas que han sido tratadas.



## 4. Resultados

### 4.1. Análisis de persistencia de avena en trigo

#### 4.1.1. Detección de cambios

El análisis de persistencia se realizó sobre 4 parcelas de trigo que fueron muestreadas en los años 2006 y 2008. Este estudio multitemporal se realizó tomando como clasificación de referencia, para cada una de las parcelas y en cada uno de los dos años estudiados, la mejor clasificación obtenida independientemente del clasificador, del tipo de análisis (basado en píxeles o en objetos) y del tipo de imagen analizada (bandas multiespectrales o índice *NDVI*) (Fig. 5.3).

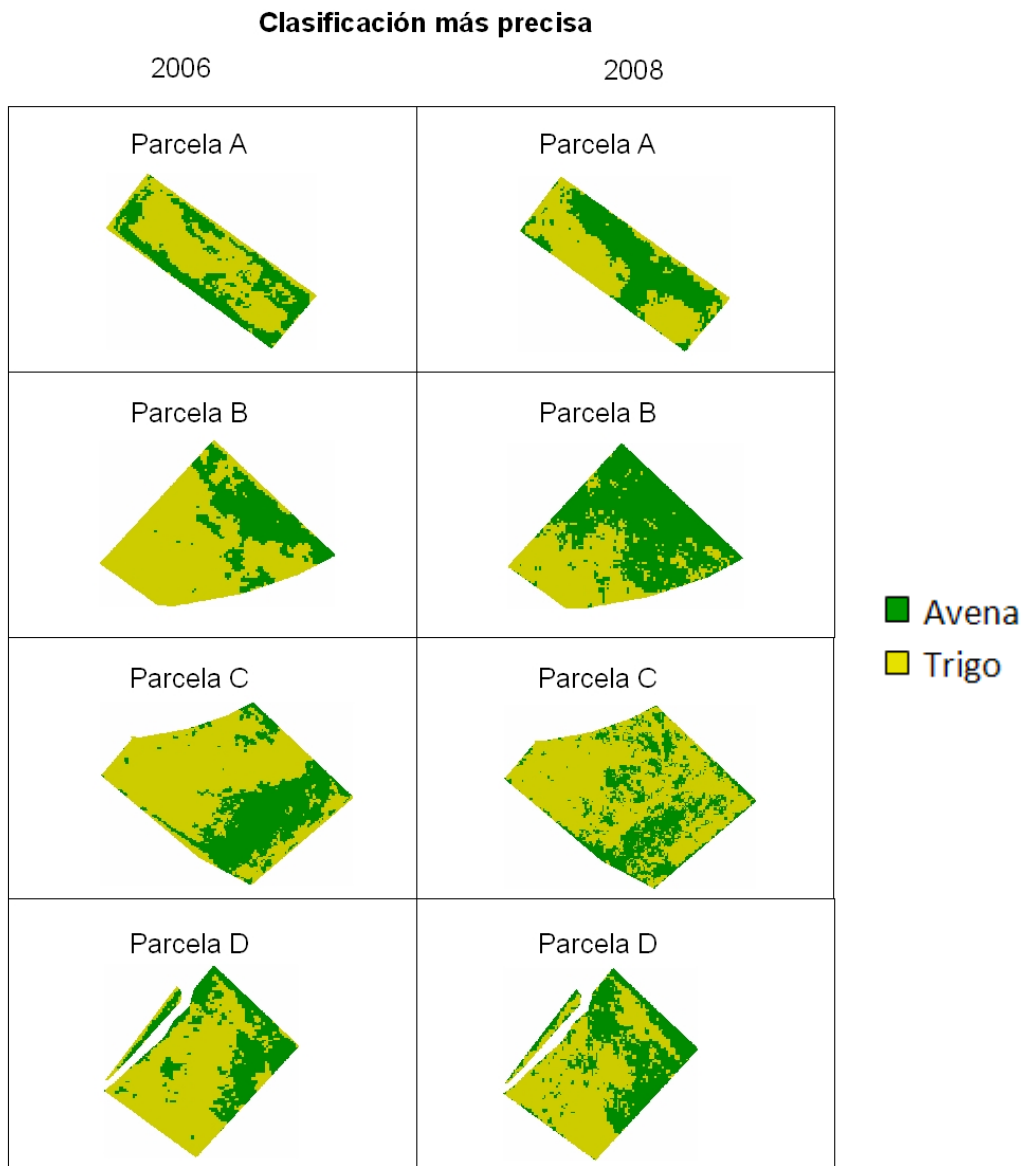


Figura 5.3. Clasificaciones consideradas para el estudio en cada una de las parcelas y para cada año.

La Tabla 5.3 muestra una cuantificación superficial de la distribución avena y trigo en cada parcela en los dos años estudiados. La tendencia temporal observada en la distribución de las avenas en las parcelas marca un incremento generalizado de la superficie de éstas. Este aumento se constató en las parcelas A, B y D, las cuales presentaron un aumento en la superficie de avena entre los años estudiados de un 7.8% (39.12% de avena en 2006 y 46.92% en 2008), un 30.95% (29.03% de avena en 2006 y 59.98% en 2008) y un 6.47% (33.28% de avena en 2006 y 39.75% de avena en 2008), respectivamente. Sin embargo, la parcela C mostró un comportamiento opuesto al disminuir su superficie de avena en un 5.84% (34.28% de avena en 2006 y 28.44% en 2008).

Tabla 5.3- Análisis de superficies clasificadas para cada parcela y cada año estudiado.

		Parcela A		Parcela B		Parcela C		Parcela D	
		Superficie	%	Superficie	%	Superficie	%	Superficie	%
2006	<i>Avena</i>	0.68	39.12	0.73	29.03	2.19	34.28	0.92	33.28
	<i>Trigo</i>	1.06	60.88	1.79	70.97	4.19	65.72	1.85	66.72
	<i>Total</i>	1.74	100	2.52	100	6.38	100	2.77	100
2008	<i>Avena</i>	0.82	46.92	1.51	59.98	1.82	28.44	1.10	39.75
	<i>Trigo</i>	0.92	53.08	1.01	40.02	4.56	71.56	1.67	60.25
	<i>Total</i>	1.74	100	2.52	100	6.38	100	2.77	100

Para completar el estudio de detección de cambios espaciales entre las dos fechas, la Tabla 5.4 muestra las estadísticas de cambio de usos del suelo para cada píxel entre el estado inicial (año 2006) y final (año 2008) de las parcelas estudiadas. Del total de superficie clasificada como avena en el año 2006, la proporción de superficie que siguió siendo avena en el año 2008 fue muy variable entre parcelas, con valores que oscilaron entre un 92.82% de superficie que presenta la misma localización de avena en la parcela B hasta sólo un 44.43% de superficie coincidente en la parcela C. Por lo tanto, sólo un 7.18% de superficie de avena de 2006 pasó a ser trigo en 2008 en la parcela B mientras que el cambio de uso avena-trigo en la parcela C fue de más de la mitad de su superficie clasificada como avena en 2006 (55.57%). Por su parte, la permanencia espacial de la superficie de trigo entre ambos años tampoco fue muy destacada, aunque entre parcelas si se observó un comportamiento algo más homogéneo. Por una parte, en las parcelas A y B se observó que el 57.56% y 53.44% de la superficie de trigo de 2006 permanecía como trigo en 2008 y una superficie muy similar de trigo (42.44% y 46.56%, respectivamente) pasó a ser avena en 2008. Sin embargo, tanto en la parcela C como en la D observó mayor persistencia en la superficie de trigo (79.90% y 73.90%) respectivamente y sólo el 20.10% y el 26.05% de la superficie pasó de trigo a avena en el año 2008 en dichas parcelas. Junto con este análisis también se realizó un mapa de diferencias que mostró gráficamente estos cambios en los usos del suelo entre el estado inicial (2006) y final (2008) del análisis (Fig. 5.4).

Diferencias de usos (2008 - 2006)

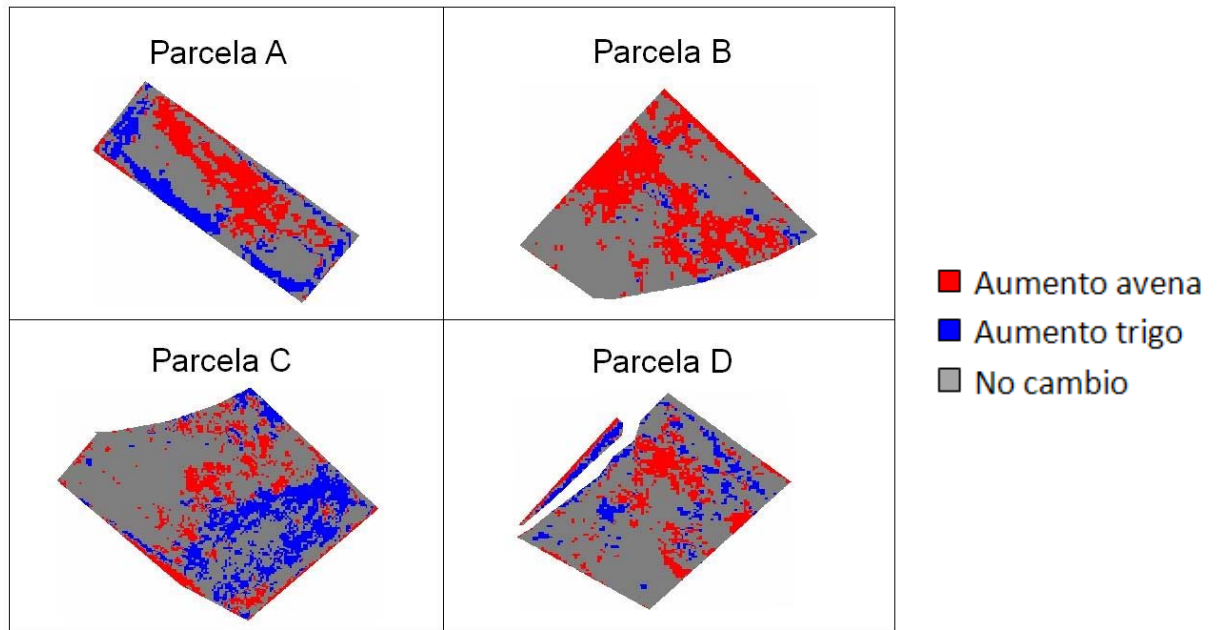


Figura 5.4. Análisis de cambios de usos de suelo en las cuatro parcelas estudiadas.

Tabla 5.4 – Resumen de las estadísticas de cambio para las cuatro parcelas estudiadas en los años 2006 y 2008.

	Parcela A					Parcela B				
	Avena(06)		Trigo(06)		Total (08)	Avena(06)		Trigo(06)		Total (08)
	Superficie	%	Superficie	%	Superficie	Superficie	%	Superficie	%	Superficie
Avena (08)	0.37	53.89	0.45	42.44	0.82	0.68	92.82	0.83	46.56	1.51
Trigo (08)	0.31	46.11	0.61	57.56	0.92	0.05	7.18	0.96	53.44	1.01
Total (06)	0.68	100	1.06	100	1.74	0.73	100	1.79	100	2.52
	Parcela C					Parcela D				
	Avena (06)		Trigo (06)		Total (08)	Avena (06)		Trigo (06)		Total (08)
	Superficie	%	Superficie	%	Superficie	Superficie	%	Superficie	%	Superficie
Avena (08)	0.98	44.43	0.84	20.10	1.82	0.62	67.21	0.48	26.05	1.10
Trigo (08)	1.21	55.57	3.35	79.90	4.56	0.30	32.78	1.37	73.90	1.67
Total (06)	2.19	100	4.19	100	6.38	0.92	100	1.85	100	2.77

## 4.1.2. Autocorrelación espacial

Junto con el análisis de cambio, para estudiar el patrón espacial de la distribución de las infestaciones de avenas locas en cultivos de trigo se calculó el Índice de Moran. Este índice analiza la autocorrelación espacial existente entre las zonas infestadas, mostrando si la distribución de la infestación es aleatoria (sin autocorrelación), agregada (autocorrelación positiva) o dispersa (autocorrelación negativa).

La Tabla 5.5 presenta los valores de autocorrelación espacial (índice de Moran) en la distribución de las infestaciones de avenas respecto al cultivo. Este índice se ha calculado para las cuatro parcelas (parcelas A, B, C y D) y en los dos años estudiados (2006 y 2008) con el objeto de definir si existe un cierto grado de agregación de las malas hierbas en las parcelas, lo que facilitaría el diseño de los mapas de CLMH. En todos los casos estudiados se observó una marcada autocorrelación espacial positiva, es decir, un claro agrupamiento de las infestaciones de avenas en las parcelas, con valores del Índice de Moran entre 0.60 y 0.84. La parcela que presentó una autocorrelación espacial positiva mayor fue la Parcela B, con valores del Índice de Moran de 0.76 y 0.83 para los años 2006 y 2008, respectivamente. Por su parte, los valores del índice menores se alcanzaron en la parcela D, con valores de 0.76 para el año 2006 y 0.70 para el 2008. La parcela C obtuvo los valores más extremos de autocorrelación espacial entre los dos años medidos. Así, mientras que en el año 2006 se observó un valor de agrupamiento muy alto (0.84), en el año 2008 la autocorrelación disminuyó significativamente a valores del índice de 0.60. Todos estos resultados se lograron con un nivel de confianza del 99% (nivel de significación del 1%) y con significancia estadística ( $p = 0.00000$ ).

Tabla 5.5 – Análisis de la autocorrelación espacial de las cuatro parcelas estudiadas en los años 2006 y 2008.

		I. Moran calculado	I. Moran Esperado	Desviación estándar	Valor Z	Significación (p)
Parcela A	2006	0.66895	-0.00033	0.00017	51.29638	0.000
	2008	0.81533	-0.00033	0.00017	62.51356	0.000
Parcela B	2006	0.75495	-0.00023	0.00012	70.01710	0.000
	2008	0.83472	-0.00023	0.00012	77.36441	0.000
Parcela C	2006	0.84149	-0.00009	0.00005	124.46149	0.000
	2008	0.60262	-0.00009	0.00005	89.14187	0.000
Parcela D	2006	0.76212	-0.00021	0.00011	73.06182	0.000
	2008	0.69945	-0.00021	0.00011	67.54269	0.000

#### 4.1.3. Análisis de la distancia de propagación

Por otra parte, los análisis de distancia de propagación de infestaciones de avena muestran que las nuevas plantas de avena emergidas en 2008 estaban claramente influenciadas por las ya presentes en años anteriores (avenas 2006). Las figuras 5.5, 5.6, 5.7 y 5.8 muestran, para las parcelas A, B, C y D respectivamente, la distribución espacial de la avena clasificada para la imagen de 2006 y las nuevas plantas de avena emergidas en 2008, así como el histograma de frecuencias donde se observa el tipo de dispersión de las semillas. Pese a la distinta distribución de avena presente en las cuatro parcelas estudiadas, el histograma muestra una clara tendencia en el emplazamiento de las nuevas infestaciones avenas. Estos gráficos indican claramente que la mayor parte de las avenas nuevas emergidas en el año 2008 se encontraban muy próximas a las avenas detectadas en el año 2006, siendo los valores de frecuencia (eje Y) y de distancias (eje X) dependientes de la cantidad de avenas nuevas emergidas en 2008 y de las dimensiones de cada parcela, respectivamente. Por ejemplo, la parcela A mostró una distribución decreciente de distancias constante desde el origen hasta aproximadamente unos 17m de distancia. Sin embargo, las parcelas B, C y D presentaron una distancia máxima de dispersión mucho mayor, con valores aproximados de 65m, 42m y 36m, respectivamente. En estos tres casos, aunque se obtuvieron valores puntuales muy alejados de la fuente de origen de la semilla, la distribución fue constante hasta los 40m, 3 m y 20m para las parcelas B, C y D.

Junto al histograma de frecuencias también se muestra el acumulado de los datos, que ofrece información de la proporción de avenas de 2008 que se encuentran a una cierta distancia de avenas de 2006. Por ejemplo, en todas las parcelas se observa que el 25% de las nuevas avenas emergidas en 2008 se localizan en los dos metros alrededor de las avenas existentes en 2006, excepto en la parcela C, que se localizan entre los 2 y 3m de la fuente de semilla. Este comportamiento tan homogéneo se interrumpió a medida que aumenta la superficie de avena. Así, mientras que el 50% de las emergencias nuevas de avena de la parcela A se encontraban entre 2 y 3m del origen, la parcela D presenta la misma proporción de avena entre 3 y 4m, la parcela B a 5m y la parcela C entre 7 y 8m. Por su parte, el 75% de las plantas de avena nuevas se localizaron a 5m del origen en la parcela A, a 8m en la parcela D, a 12m en la parcela B y a 20m en la parcela C. Finalmente, la mayoría de las infestaciones nuevas de avena (95%) se localizan a 10m en la parcela A, a 18m en la parcela D, a 27m en la parcela B y a 33m en la parcela C. Pese a que la parcela C es la que presentó mayor distancia en la dispersión de la infestación, el valor máximo de dispersión se observó en la parcela B, con localización de avena a más de 65m desde el origen.


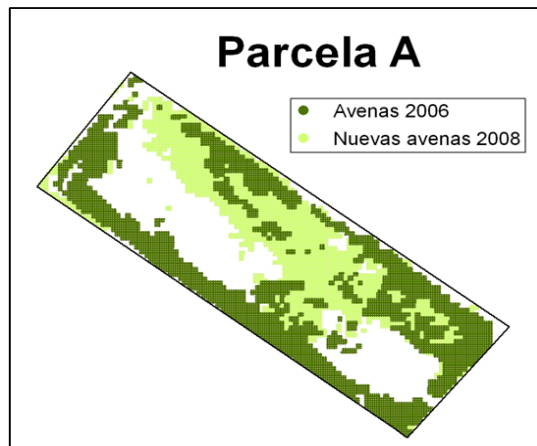


Figura 5.5: Histograma de frecuencias y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena 2006 para la Parcela A.





Figura 5.6: Histograma de frecuencias y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena 2006 para la Parcela B.





Figura 5.7: Histograma de frecuencias y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena 2006 para la Parcela C.

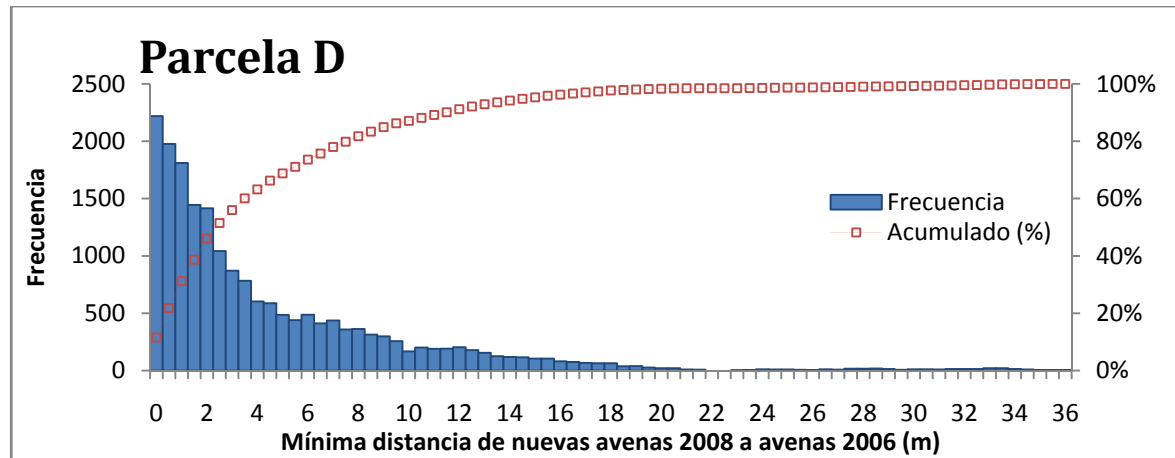



Figura 5.8: Histograma de frecuencias y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena 2006 para la Parcela D.



4.2. Mapas de Control Localizado de Malas Hierbas (CLMH)

Los mapas de tratamiento localizado de herbicida se diseñan para identificar las áreas que deben ser pulverizadas con el tratamiento. En este caso se diseñó un programa de CLMH para el cultivo de trigo del año 2008, partiendo de la infestación detectada a final del cultivo de trigo del año 2006. En este caso, y puesto que al final del ciclo del cultivo se produjo dispersión de la infestación alrededor de las emergencias iniciales (2006), se plantearon varios tratamientos que cubrieran distintos porcentajes de infestación de avenas en la cosecha de 2008.

Para determinar cada uno de estos tratamientos se analizaron los resultados obtenidos en el estudio de dispersión de avenas. Puesto que las cuatro parcelas presentaron características diferentes (forma, tamaño, orientación,...), se tomó como referencia la media de la distribución de las cuatro parcelas. Para ello se calculó el histograma de frecuencias y el acumulado de las cuatro parcelas conjuntamente para obtener un comportamiento medio de la zona estudiada (Fig. 5.9). Sobre el histograma acumulado (Fig. 5.10) se determinó la distancia de propagación de la semilla, observándose una distribución de tipo exponencial. Así, el 25% de las nuevas plantas de avenas emergidas en 2008 se encontraron aproximadamente a 1m de las avenas detectadas en 2006, el 50% de las nuevas avenas a unos 4m de las avenas de 2006 y el 75% de las nuevas avenas de 2008 a unos 9m de las avenas de 2006. A partir de ese punto se observa una disminución de la pendiente de la curva hasta formar una meseta prácticamente plana donde pequeños incrementos en la proporción de nuevas avenas se distribuyen a lo largo de grandes distancias. Por ejemplo, mientras que el 90% de las malas hierbas se distribuyen a 18m de la avena 2006, el 95% de las nuevas avenas 2008 se distribuyen a 25m y el 100% de las nuevas emergencias a más de 70m.

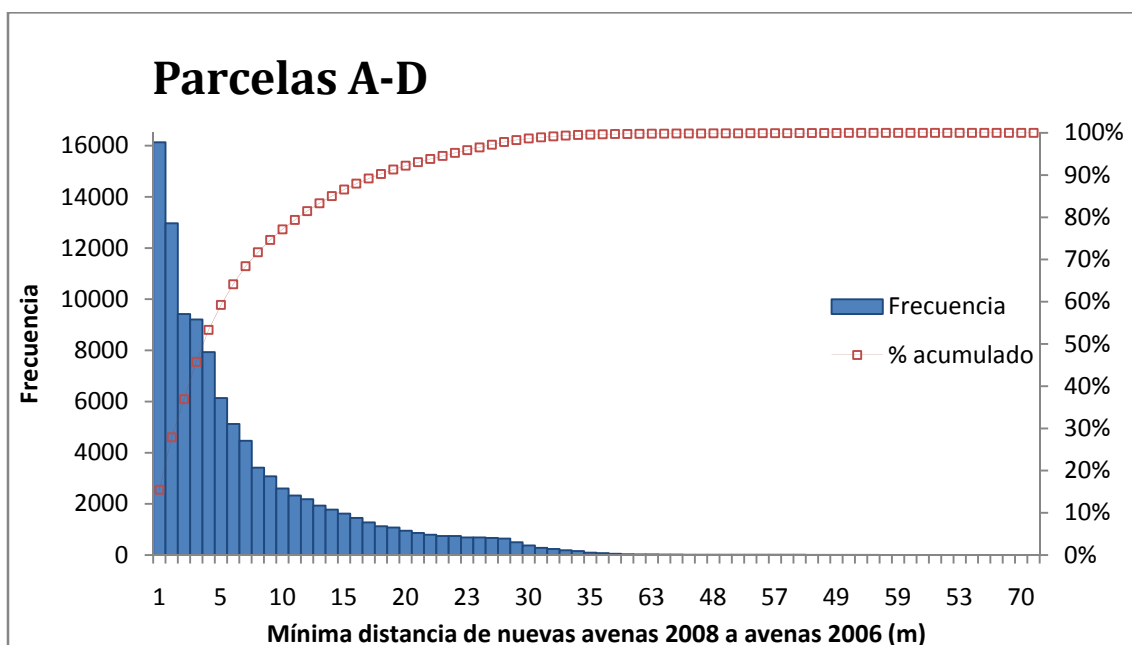


Figura 5.9: Histograma y acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena anterior (2006) para el conjunto de parcelas A-D.

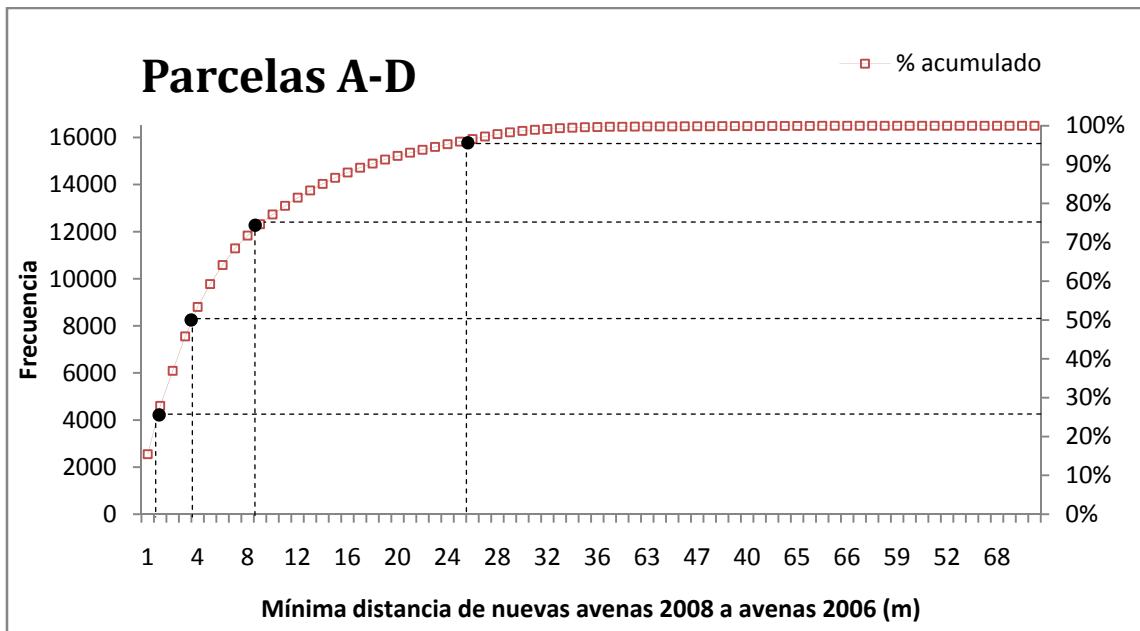


Figura 5.10: Acumulado de la mínima distancia de nuevas plantas de avenas (2008) a la infestación de avena anterior (2006) para el conjunto de parcelas A-D. Determinación de las distancias para el 25%, 50%, 75% y 95% de los puntos.

A partir del análisis de la dispersión de las infestaciones de avena loca en las cuatro parcelas estudiadas se determinaron 5 posibles tratamientos localizados de herbicida para evaluar su viabilidad económica. Las características de estos tratamientos se encuentran recogidas en la Tabla 5.6. Para el primer tratamiento (T1) se tuvo en cuenta sólo la infestación de malas hierbas observadas en el año 2006. Para los restantes tratamientos (T2, T3, T4 y T5) se consideró aumentar una determinada distancia (*buffer*) alrededor de las infestaciones de 2006 con objeto de controlar una proporción mayor de avenas del año 2008. Para controlar el 25%, 50%, 75% y 95% de las nuevas avenas de 2008 se han incrementaron 1m, 4m, 9m y 25m la superficie alrededor de la superficie infestada en 2006, respectivamente.

Tabla 5.6 – Características de los tratamientos para el CLMH.

Tratamiento	Nuevas avenas 2008 (%)	Distancia a avenas 2006 (m)
T1	0	0
T2	25	1
T3	50	4
T4	75	9
T5	95	25

Una vez determinadas las zonas con infestación de avena, se realizó el diseño del programa de tratamiento a partir de la generación de zonas de manejo de 15x15m, precisándose que las zonas con infestaciones inferiores al 25% de su superficie no se iban a tratar. En todas aquellas zonas en las que el porcentaje de infestación fue mayor del 25% se diseñó el tratamiento localizado de la totalidad de la zona de manejo de 15x15m. Como ejemplo, la Figura 5.11 muestra el grado de infestación de la parcela A considerando el tratamiento T1 y el diseño del tratamiento localizado de malas hierbas. El cálculo de los grados de infestación considerados para cada uno de los tratamientos (T1, T2, T3, T4 y T5) en las parcelas A, B, C y D se muestran en el Anexo I.

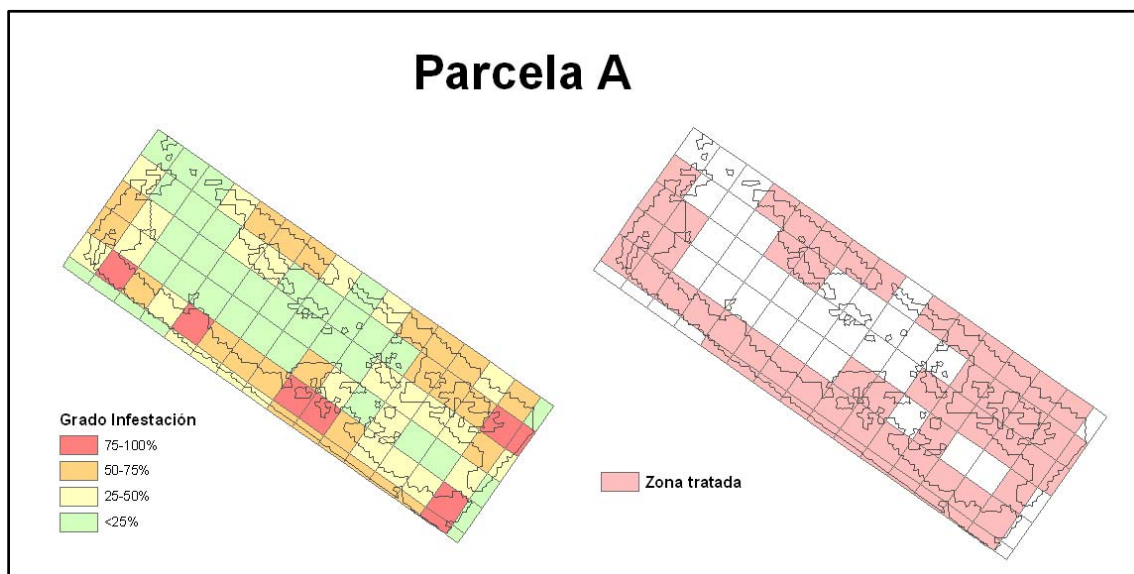


Figura 5.11: Grado de infestación y zona tratada para el tratamiento T1 en la parcela A.

La Tabla 5.7 muestra el porcentaje de superficie tratada ( $S_t$ ) de cada parcela en función de la superficie considerada como posiblemente infestada ( $S_i$ ) en cada tratamiento. La superficie tratada aumentó considerablemente a medida que se incrementó el porcentaje de nuevas avenas de 2008 que se debía controlar, llegando a tratar la mayor parte de la superficie (del 87% al 100% de la superficie de las parcelas) con el diseño del tratamiento T5 (control del 95% de las nuevas emergencias de avena 2008). Debido a la distribución que presentaron las avenas en la parcela A, ésta fue la parcela que más diferencias presentó entre la superficie tratada ( $S_t$ ) y la que realmente se quiso controlar ( $S_i$ ), tratando alrededor de un 25% más de superficie de la parcela que la realmente infestada para los tratamientos T1 y T2. Sin embargo, a medida que los tratamientos controlaron más superficie posiblemente infestada en 2008 ( $S_i$ ), las diferencias entre superficie tratada y superficie infestada disminuyeron, tratando en exceso alrededor de un 11% de la superficie de la parcela para el tratamiento T3, un 7.5% para el tratamiento T4 y no existiendo ninguna diferencia entre la superficie tratada y la infestada en el tratamiento T5. En este último caso, se previó un tratamiento del 100% de la parcela, equivalente a considerar que el 100% de la superficie de la parcela podría estar infestada en 2008. Este tipo de tratamiento es equivalente al tratamiento tradicional, por lo que realizarlo con tecnología de precisión encarece mucho el coste.

Tabla 5.7 – Resumen de la superficies consideradas como posiblemente infestadas ( $S_i$ ) y superficies tratadas ( $S_t$ ) por los distintos tratamientos en las cuatro parcelas.

		Parcela A	Parcela B	Parcela C	Parcela D
T1 <sup>(1)</sup>	$S_i$ <sup>(2)</sup>	35.8	27.8	32.8	30.1
	$S_t$	61.4	39.5	39.5	42.7
	$\Delta S$	25.6	11.7	6.7	12.6
T2	$S_i$	48.7	33.1	38.2	37.9
	$S_t$	72.7	44.9	46.2	52.8
	$\Delta S$	24.0	11.8	8.0	14.9
T3	$S_i$	73.8	45.6	49.9	56.6
	$S_t$	85.0	54.4	59.7	69.9
	$\Delta S$	11.2	8.8	9.8	13.3
T4	$S_i$	90.4	58.9	63.8	75.4
	$S_t$	97.9	64.6	70.2	82.5
	$\Delta S$	7.5	5.7	6.4	7.1
T5	$S_i$	100	85.2	90.7	98.4
	$S_t$	100	87.5	93.9	99.4
	$\Delta S$	0	2.3	3.2	1.0

<sup>(1)</sup> Tratamientos: T1, T2, T3, T4 y T5: tratamientos considerando las avenas de 2006 y considerando el 25%, 50%, 75% y 95% de las nuevas avenas de 2008, respectivamente.

<sup>(2)</sup> Superficies.  $S_i$ : superficie considerada como infestada según cada tratamiento (%),  $S_t$ : superficie tratada según las zonas de manejo de 15x15m (%) y  $\Delta S$ : Diferencia entre la superficie considerada como infestada ( $S_i$ ) y la tratada ( $S_t$ ) (%).

Las parcelas B, C y D mostraron unos valores ligeramente diferentes a los obtenidos en la parcela A. En las tres parcelas se constató que pese a que la superficie infestada en los tratamientos T1 y T2 era parecida a la de la Parcela A, la diferencia entre la superficie tratada y la superficie infestada fue menor que en dicha parcela con valores que oscilaron entre el 6.7% para la parcela C y el tratamiento T1 y el 14.9% para la parcela D y el tratamiento T2. A partir del tratamiento T3, los porcentajes de superficie infestada de las tres parcelas empezaron a ser claramente inferiores que los obtenidos en la parcela A, con disminuciones de hasta un 48.7% de la superficie infestada de la parcela B en el tratamiento T4 respecto a la parcela A del mismo tratamiento. En estas 3 parcelas también se observó que la superficie tratada se ajustó más a la superficie infestada, con diferencias que oscilaron entre el 1% para la parcela D y el tratamiento T5 y el 13.3% para la parcela D y el tratamiento T3.

### 4.3. Estudio económico

Tras el diseño de los 5 tratamientos en cada una de las parcelas, se realizó un análisis económico donde se comparó mediante una curva de equilibrio el coste que supondría tratar cada una de las parcelas con técnicas de precisión y las pérdidas debidas a la existencia de malas hierbas en el cultivo en aquellas zonas no tratadas. En este estudio se consideró una nueva situación (T0), en la que no se realizó ningún control de las malas hierbas en las parcelas.

Las Figuras 5.12, 5.13, 5.14 y 5.15 muestran que en todas las parcelas existió un incremento lineal de coste de la aplicación de herbicida a medida que aumentaba la superficie tratada. Ahora bien, debido a que no toda la superficie tratada tenía la misma proporción de infestación, la curva de pérdidas por infestación de malas hierbas disminuyó a medida que se trata más superficie con herbicida, pero dicha disminución no fue lineal. Aunque la diferencia entre el coste de aplicación de herbicida fue elevado con respecto a las pérdidas económicas debidas a la presencia de malas hierbas en el cultivo, la diferencia existente en las pendientes de las curvas (la curva de pérdidas por infestación fue mucho más pronunciada que la pendiente de la curva de coste de aplicación de herbicida), generó un punto de corte llamado **Punto de Equilibrio**. Dicho punto representa el nivel de tratamiento de herbicida óptimo para cada una de las parcelas, es decir, el **umbral económico de tratamiento**.

Todas las superficies tratadas menores a las recogidas en dicho punto para cada parcela (superficie a la izquierda del umbral económico de tratamiento), representan zonas donde el incremento del coste supuesto por la aplicación de herbicida disminuye el incremento de pérdidas producidas por la infestación, es decir, a medida que se aumenta la superficie tratada se controla una gran superficie infestada de malas hierbas y, por tanto, se disminuye rápidamente las pérdidas debidas a dichas infestaciones. El Punto de Equilibrio representa el punto en el que el coste de aplicación de herbicida es igual a las pérdidas debidas a la infestación, siendo este tratamiento el óptimo para obtener los mejores rendimientos económicos a los cultivos. Finalmente, toda la superficie tratada con herbicida mayor a la indicada por el Punto de Equilibrio (superficie a la derecha del umbral económico de tratamiento), representan zonas donde el costo de aplicación de herbicidas es superior a las pérdidas producidas por las infestaciones, por lo que tratar esa superficie supone controlar un número tan bajo de infestaciones de malas hierbas, que las pérdidas debidas a dichas infestaciones no compensan el gasto de herbicida utilizado para su control.




Figura 5.12: Curva de equilibrio *Coste aplicación herbicidas-Pérdidas por infestación* para la Parcela A.




Figura 5.13: Curva de equilibrio *Coste aplicación herbicidas-Pérdidas por infestación* para la Parcela B.




Figura 5.14: Curva de equilibrio *Coste aplicación herbicidas-Pérdidas por infestación* para la Parcela C.




Figura 5.15: Curva de equilibrio *Coste aplicación herbicidas-Pérdidas por infestación* para la Parcela D.

En las cuatro parcelas estudiadas se observó un comportamiento bastante homogéneo, mostrando todas ellas que era necesario tratar un cierto nivel de malas hierbas para conseguir el beneficio óptimo del cultivo. Respecto a la determinación de dicho punto óptimo, en las parcelas A, C y D se obtuvo el Punto de Equilibrio entre el tratamiento T2 y el tratamiento T3. Esto indica que en dichas parcelas fue interesante diseñar un programa de tratamiento localizado de herbicidas que tuviera en cuenta la superficie infestada por avena loca en el año 2006 más un incremento de la superficie alrededor de dicha zona (*buffer*) de entre 1m y 4m. Ello supondría controlar todas las infestaciones de avena loca detectadas en 2006 y entre un 25% y un 50% de las infestaciones previstas para el siguiente cultivo (2008). Sólo la parcela B presentó algo más desplazado el umbral económico de tratamiento, situándose éste entre el tratamiento T4 y el T5, es decir, considerando una región adicional de superficie alrededor de la infestación obtenida en 2006 de 9m a 25m. En este caso, para que el cultivo optimizara los beneficios se requirió controlar toda la avena presente en 2006 junto con la mayoría (entre el 75% y el 95%) prevista para el cultivo de 2008. Este incremento tan significativo de la superficie a controlar pudo deberse a que la parcela B fue la que presentó un mayor nivel de infestación de nuevas malas hierbas en 2008 y éstas estaban bastante agrupadas (próximas entre ellas y a las avenas presentes en 2006) (Fig. 5.4), por lo que el aumento de la superficie de tratamiento permitió controlar mejor las avenas de 2008 y optimizar el proceso.

## 5. Discusión

Los resultados obtenidos en este trabajo muestran que la distribución espacial de las infestaciones de avena loca en cultivos de trigo se distribuyeron en rodales altamente dependientes de infestaciones anteriores. El conocimiento de esta distribución espacial facilita predecir el comportamiento espacial futuro con la finalidad de proponer programas de CLMH. Las estadísticas de cambio mostraron que tres de las cuatro parcelas aumentaron su nivel de infestación en el siguiente cultivo de trigo debido a que no se realizó ningún tratamiento herbicida. Estos incrementos fueron moderados en las parcelas A y D con incrementos alrededor del 6% y 8%. Sin embargo, la parcela B presentó un incremento de avena muy destacado, aumentando su superficie infestada en casi un 31%. Estos incrementos corroboran resultados obtenidos en otros estudios como el de Barroso *et al.* (2009), que compararon tres estrategias de control localizado de herbicidas para el control de avena loca en trigo y determinaron que aquellas zonas que presentaron un nivel inicial de infestación insignificante y, por tanto, no fueron tratadas, aumentaron significativamente su población de malas hierbas en los dos años siguientes.

Las infestaciones observadas tanto en 2006 como en 2008 fueron analizadas para ver si presentaban algún patrón espacial concreto. Para conocer el grado de agregación/dispersión de la infestación se analizó el grado de autocorrelación espacial que presentaban las avenas mediante el Índice de Moran. Los resultados mostraron una alta autocorrelación espacial positiva en todos los casos estudiados con valores que oscilaron entre 0.60 y 0.84, lo que sugiere que la distribución de estas malas hierbas fue en



forma agregada, es decir, en forma de rodales. Aunque muchos autores parten de la premisa de que la mayoría de las malas hierbas se distribuyen en rodales y que persisten en el tiempo, son escasos los trabajos que analizan realmente la distribución espacial de estas infestaciones. Heijting *et al.* (2007) analizaron la estabilidad espacial de 17 especies de malas hierbas en cultivos de maíz y detectaron que aquellas malas hierbas que presentaban grandes densidades de infestación presentaron mayor autocorrelación espacial (estabilidad espacial), mientras que las que presentaron densidades más bajas también presentaron autocorrelaciones espaciales menores. De forma general, malas hierbas que presenten una distribución espacial estable permitirán generar mapas de infestaciones espaciado en el tiempo.

Por el contrario, especies invasoras que sufran cambios rápidos en su distribución espacial requerirán crear mapas de infestaciones cada poco tiempo (Goudy *et al.*, 2001), lo que aumenta considerablemente el coste de este tipo de tratamientos. De esta forma, para diseñar sistemas de CLMH para este tipo de malas hierbas con baja estabilidad sería necesario discriminar la infestación en fase temprana del cultivo. En el caso de malas hierbas gramíneas en cultivos de cereal, esta tarea en época temprana es muy compleja debido a que las plántulas del cultivo y de las malas hierbas son espectralmente muy parecidas y la reflectividad del suelo interfiere en el análisis. Por tanto, una alternativa sería utilizar mapas de discriminación de infestaciones obtenidos en época tardía en años anteriores, que es la estrategia presentada a lo largo de los **capítulos 3 y 4** de esta Tesis Doctoral.

El último aspecto considerado para la caracterización de las infestaciones se centró en el análisis de la dispersión de las infestaciones entre un año y otro. En este análisis se determinó el grado de dependencia de las nuevas plantas de avenas surgidas en 2008 respecto a las avenas anteriores (2006), considerando estas últimas como fuente de infestación de las nuevas avenas. Los resultados mostraron que para todas las parcelas existía una clara tendencia en la distribución de las nuevas avenas, siendo mayor la frecuencia de aparición de nuevas avenas en 2008 conforme más cerca se estaba de la posición ocupada por las avenas de 2006. Esta distancia varió considerablemente en función de las dimensiones de las parcelas estudiadas, aunque en todas las parcelas el 50% de las nuevas avenas se encontró en los 8m más cercanos a la infestación de 2006. Sin embargo, a medida que aumentó el porcentaje de nuevas infestaciones de avena analizadas, sus distancias a las avenas fuente se incrementaron exponencialmente con resultados muy diferentes al considerar distintas dimensiones. Así, mientras que en la parcela A, la de tamaño más reducido, se observó que el 100% de las nuevas avenas se distribuían aproximadamente a 17m alrededor de la infestación de 2006, el resto de parcelas más grandes presentaba sus nuevas avenas mucho más alejadas de las avenas fuente, con separaciones de hasta 65m. Estos resultados concuerdan con los obtenidos en otros estudios de dispersión de malas hierbas que indican que la tasa de dispersión aumenta hasta separarse 100m de la fuente de origen, aunque la mayor parte de las emergencias se localizan en los 20 primeros metros (Ballaré *et al.*, 1987, Howard *et al.*, 1991). Más concretamente, Barroso *et al.* (2006) analizaron la capacidad de dispersión de la avena loca en parcelas de trigo teniendo en cuenta distintos tratamientos agrícolas y concluyeron que dicha mala hierba puede llegar a dispersarse a largas distancias de las

avenas fuente debido, principalmente, al efecto del viento y al transporte de semilla por parte de la maquinaria agrícola. Según este trabajo, tras dos años de estudio se observó que prácticamente todas las avenas se encontraban en los 5m más cercanos a las avenas iniciales, aunque había un grupo reducido de individuos que llegaron a desplazarse hasta 30m de la fuente. En vista de estos resultados, y como sugirió Colbach *et al.* (2000), los rodales de malas hierbas anuales que dispersan su semilla antes de la recolección son más estables que los que mantienen la semilla durante la cosecha del cultivo.

Una vez que se hubo determinado que la tendencia de las avenas era a aumentar su superficie si no se trataba con herbicida previamente, que éstas tendían a distribuirse de forma agregada formando rodales y que la nuevas emergencias de avena prevista para años posteriores se solía encontrar muy cerca de infestaciones anteriores, se plantearon distintos diseños de CLMH. En total se diseñaron 5 programas de manejo localizado de herbicida en función del nivel de infestación que se optó por controlar. Aunque se parta de mapas muy detallados de infestaciones, un control preciso de las malas hierbas puede llegar a ser muy difícil si el área infestada es considerablemente menor que la mínima unidad de tratamiento disponible por el equipo pulverizador (Pierce y Nowak, 1999), por lo que es necesario ajustar las unidades de manejo a la tecnología disponible. Por tanto, teniendo en cuenta las características de los equipos de tratamiento, se dividieron las parcelas en unidades de manejo de 15x15m. Como umbral de control se consideró que todas aquellas unidades de manejo con infestaciones superiores al 25% fueran tratadas Barroso *et al.* (2004a). Aunque se fijó este umbral de infestación para determinar la necesidad de tratamiento, en el estudio se realizó un cálculo más pormenorizado de la superficie infestada con el fin a poder proponer en el futuro otros métodos de manejo como la aplicación de herbicidas con dosis ajustada en función de la superficie afectada por la infestación (de Castro *et al.*, 2010, García-Torres *et al.*, 2010).

Debido a que se trataron unidades de manejo completas con niveles de infestación entre el 25% y el 100% de su superficie, en muchos casos la superficie tratada aumentó considerablemente respecto a la superficie considerada como posiblemente infestada. Estas diferencias fueron variables en función de la parcela estudiada y del tipo del diseño del tratamiento a aplicar, llegándose a obtener niveles de ajuste excelentes con sólo un 1% de incremento de la superficie tratada respecto a considerada como posiblemente infestada en la parcela D. Sin embargo, en algunos casos esta diferencia fue muy acusada, con valores máximos de hasta un 25% más de la superficie tratada respecto a considerada como posiblemente infestada en la parcela A. Resultados muy parecidos, con incrementos de hasta un 30% de superficie tratada respecto a superficie infestada, se obtuvieron en un análisis sobre campos de maíz en el que se definieron las zonas de manejo teniendo en cuenta la superficie infestada junto con un incremento de seguridad de hasta 5m que permitiera compensar los tiempos de reacción del equipo de tratamiento desde que se da la orden de aplicar hasta que el herbicida llega a las boquillas (IDAE, 2010). Estos incrementos pueden variar considerablemente en función del tamaño de la unidad de manejo y del umbral de infestación considerado como límite para tratar una determinada zona. Gómez-Candón *et al.* (2009) analizaron mediante la evaluación de los índices OHS (*Overall Herbicide Saving*) y OHAE (*Overall Herbicide Application Efficiency*), la capacidad

de optimizar la eficiencia de un programa de CLMH en función de las variaciones del tamaño de la unidad de tratamiento y de la cantidad de infestaciones existentes en cada unidad tratada con el software SARI (*Sectioning and Assessment of Remote Images*) (García-Torres *et al.* 2008).

Nuestro análisis mostró que el punto óptimo de tratamiento de las parcelas A, C y D se encontraba entre 1m y 4m alrededor de las zonas infestadas en el año 2006. Estos datos concuerdan con los obtenidos en otros estudios. Rew *et al.* (1997) sugirieron que en el diseño de un mapa de tratamiento localizado, era recomendable añadir un incremento de superficie alrededor de la infestación clasificada (*buffer*) de unos 4m con objeto de abarcar los desplazamientos de las infestaciones, los errores de navegación de la maquinaria y el tiempo de respuesta de los pulverizadores. Resultados similares observaron Barroso *et al.* (2006), los cuales concluyeron que el efecto del viento y de la maquinaria agrícola producía una dispersión de la mayoría de las semillas en un rango de 3m alrededor de infestaciones anteriores, por lo que podría ser recomendable añadir un *buffer* de 4m alrededor de los rodales mapeados en un año concreto para diseñar los mapas de manejo localizado de avenas para los años siguientes. Un resultado muy diferente mostró la parcela B, cuyo umbral económico de tratamiento (Punto de Equilibrio) se encontró a una distancia entre 9m y 25m alrededor de las avenas de 2006. Ello pudo ser debido a que dicha parcela presentó un mayor nivel de infestación y éstas estaban muy agrupadas, por lo que un aumento de la superficie a controlar pudo optimizar el proceso. Este beneficio debido a la agrupación de malas hierbas en menos rodales pero de mayor superficie coincide con lo indicado por Barroso *et al.* (2004a), donde los beneficios de sus tratamientos aumentaban a medida que una misma superficie infestada se agrupaba en un número más pequeño de rodales pero de mayor superficie.

En general, la superficie óptima de tratamiento con CLMH se encontró por debajo del 75% en todas las parcelas. La parcela A fue la que mayor superficie de control necesitó con aproximadamente un 75%, mientras que las parcelas B, C y D requirieron alrededor de un 65%, 60% y 55%. Esto concuerda con lo expuesto por Luschei *et al.* (2001), que mostraron que el beneficio de los sistemas de CLMH aumentaba a medida que disminuía el porcentaje de superficie infestada, valorando que el sistema era rentable cuando las infestaciones eran menores del 72% de la superficie de la parcela en producciones de cereal de secano en EEUU. Una conclusión parecida alcanzaron Barroso *et al.* (2004a) los cuales analizaron los beneficios económicos de los tratamientos de CLMH con distintas condiciones de agregación de malas hierbas (distintos tamaños de rodal) y distintas proporciones de infestación, obteniendo como resultados que el tratamiento localizado de malas hierbas no era rentable en parcelas con superficies infestadas mayores del 64% si se comparaba con el tratamiento de toda la parcela con técnicas tradicionales. Además, determinaron que a medida que disminuía la superficie infestada se podía tratar rodales de infestación más pequeños con maquinaria de pulverización más especializada y cara sin perder el beneficio económico.

De forma general se puede concluir que el control de infestaciones de avena loca en cultivo de trigo es viable tanto a nivel técnico como económico mediante tratamientos de CLMH. Esto se debe a que la distribución de las avenas es en forma de rodales cuya dispersión se localiza en zonas muy cercanas a infestaciones anteriores. Este tipo de distribución permite que los mapas de las infestaciones obtenidos en 1 año puedan ser utilizados para diseñar tratamientos en años consecutivos. A partir del conocimiento del grado de dispersión de la semilla, estos tratamientos permitirán controlar no sólo las infestaciones clasificadas un determinado año, sino también un porcentaje importante (25-50%) de las previstas para el siguiente cultivo.

## 6. Referencias

Ballaré, C.L., Scopel, A.L., Ghera, C.M., Sánchez, R.A. 1987. The demography of *Datura ferox* (L.) in soybean crops. *Weed Research* 27, 91-102.

Barroso, J., Fernández-Quintanilla, C., Maxwell, B.D., Rew, L.J. 2004a. Simulating the effects of weed spatial pattern and resolution of mapping and spraying on economics of site-specific management. *Weed Research* 44, 460-468.

Barroso, J., Fernández-Quintanilla, C., Ruiz, D., Hernaiz, P., Rew, L. 2004b. Spatial stability of *Avena sterilis* ssp. *ludoviciana* under annual applications of low rates of imazamethabenz. *Weed Research* 44, 178-186.

Barroso, J., Navarrete, L., Sánchez Del Arco, M.J., Fernández-Quintanilla, C., Lutman, P.J.W., Perry, N.H., Hull, R.I. 2006. Dispersal of *Avena fatua* and *Avena sterilis* patches by natural dissemination, soil tillage and combine harvesters. *Weed Research* 46, 118-128.

Barroso, J., Ruiz, D., Escribano, C., Barrios, L., Fernández-Quintanilla, C. 2009. Comparison of three chemical control strategies for *Avena sterilis* ssp. *Ludoviciana*. *Crop Protection* 28, 393-400.

Blanco-Moreno, J.M., Chamorro, L., Sans, X. 2006. Spatial and temporal patterns of *Lolium rigidum*-*Avena sterilis* mixed populations in a cereal field. *Weed Research* 46, 207-218.

Blattner, F., Kadereit, J.W. 1991. Patterns of seed dispersal in two species of *Papaver* L. under near-natural conditions. *Flora* 185, 55-64.

Cliff, A.D., Ord, J.K. 1981. *Spatial Processes: Models and Applications*. Pion Ltd., London.

Colbach, N., Forcella, F., Johnson, G.A. 2000. Spatial and temporal stability of weed populations over five years. *Weed Science* 48, 366-377.

Cussans, G.W. 1980. Strategic planning for weed control – a researcher's view. In: *Proceedings Brighton Crop Protection Conference – Weeds*, Brighton, U.K., pp. 823-831.

De Castro, I.A., Jurado-Expósito, M., Gómez-Casero, M.T., Gómez-Candón, D., Caballero-Novella, J.J., López-Granados, F. 2010. Discrimination of cruciferous weeds in wheat crops using QuickBird satellite imagery. In: Proceedings of IV Symposium on Recent Advances on Quantitative Remote Sensing, Valencia, España, pp 133-137.

Eurimage. 2011. Price List (July 2010). [http://www.eurimage.com/products/docs/eurimage\\_price\\_list.pdf](http://www.eurimage.com/products/docs/eurimage_price_list.pdf).

FEGA (Fondo Español de Garantía de Calidad). 2007. Plan nacional de controles sobre el terreno, para verificar el cumplimiento de los criterios de admisibilidad, de las superficies de los regímenes de ayuda declarados en la solicitud única. N° de registro: 00004844.

Felton, W.L., Doss, A.F., Nash, P.G., McCloy, F. 1991. To selectively spot spray weed. American Society of Agricultural Engineers Symposium 11, 427-432.

Fernández-Quintanilla, C., Ruiz, D., Barroso, J., Escribano, C., Ribeiro, A. 2006. El manejo de la avena loca mediante técnicas de agricultura de precisión. Vida Rural 233, 36-38.

FP7-NMP. 2009. Framework Programme 7 - NMP: Nanosciences, Nanotechnologies, Materials and New Production Technologies. RHEA Project (2010-2014): Robot Fleets for Highly Effective Agriculture and Forestry Management. Available at: <http://www.rhea-project.eu/>.

García-Torres, L., Peña-Barragán, J.M., Caballero-Novella, J.J., López-Granados, F., Jurado-Expósito, M. 2008. SARI @ Software, Splitting and Assessment of Remote Images. Office for Registration of Intellectual Property, Seville, Spain, N° 200899900226820, pp.39 (in Spanish).

García-Torres, L., López-Granados, F., Peña-Barragán, J.M., Caballero-Novella, J.J., Jurado-Expósito, M. 2009. Automatic procedure to section remote images and to characterize agri-environmental indicators. Spanish Office for Patents and Trademarks, Madrid, Spain, PCTES2009/07247, pp.48 (in Spanish).

García-Torres, L., Gómez-Candón, D., Caballero-Novella, J.J., Gómez-Casero, M.T., Peña-Barragán, J.M., Jurado-Expósito, M., López-Granados, F., Castillejo-González, I.L., García-Ferrer, A., 2010. Sectioning and assessment remote images for precision agriculture: the case of *orobanche crenate* in pea crop. In: Proceedings of 10<sup>th</sup> congress of Precision Agriculture, Denver, EE.UU., sp.

Gerhards, R. y Christensen, S. 2006. Site-Specific Weed Management. In. Handbook of Precision Agriculture principles and Applications. A Srinivasan (Ed.), Food Products Press (pp. 185-206). The Haworth Press. New York.

Gómez-Candón, D., López-Granados, F., Caballero-Novella, J.J., García-Ferrer, A., Peña-Barragán, J.M., Jurado-Expósito, M., García-Torres, L. 2011. Efficiency and economy of control of *Avena sterilis* in wheat through remote sensing. Precision Agriculture (submitted).

Goudy, H.J., Bennett, K.A., Brown, R.B., Tardif, F.J. 2001. Evaluation of site-specific weed management using a direct-injection sprayer. *Weed science* 49, 359-366.

Heijting, S., Werf, W.V., Stein, A., Kropff, M.J. 2007. Are weed patches stable in location? Application of an explicitly two-dimensional methodology. *Weed Research* 47, 381-395.

Howard, C.L., Mortimer, A.M., Gould, P., Putwain, P.D. 1991. The dispersal of weeds: seed movement in arable agriculture. In: *Proceedings 1991 Brighton Crop Protection Conference – Weeds*, Brighton, UK, 821-828.

IDAE (Instituto para la Diversificación y Ahorro de la Energía). 2010. Ahorro y Eficiencia Energética en la Agricultura de Precisión. Fondo editorial del IDAE, en la serie "Ahorro y Eficiencia Energética en la Agricultura". Madrid.

Jurado-Expósito, M., López-Granados, F., García-Torres, L., García-Ferrer, A., Sánchez de la Orden, M., Atenciano, S. 2003. Multi-species weed spatial variability and site-specific management maps in cultivated sunflower. *Weed Science* 51, 319-328.

Jurado-Expósito, M., López-Granados, F., González-Andujar, J.L., García-Torres, L. 2005. Spatial and temporal analysis of *Convolvulus arvensis* L. populations over four growing seasons. *European Journal of Agronomy* 21, 287-296.

Jurado-Expósito, M., López-Granados, F., Peña-Barragán, J.M., García-Torres, L. 2009. A digital elevation model to aid geostatistical mapping of weeds in sunflower crops. *Agronomy for Sustainable development* 29, 391-400.

López-Granados, F., García-Torres, L. 1993. Population dynamics of crenate broomrape (*Orobancha crenata*) in faba bean (*Vicia faba*). *Weed Science* 41, 563-567.

López-Granados, F., García-Torres, L. 1998. Short and long term economic implications of controlling crenate broomrape (*Orobancha crenata*) in broad bean under various management strategies. *Weed Science* 17, 139-143.

López-Granados, F., Jurado-Expósito, M., Peña-Barragán, J.M., García-Torres, L. 2006. Using remote sensing for identification of late-season grass weed patches in wheat. *Weed Science* 54, 346-353.

Luschei, E.C., Van Wychen, L.R., Maxwell, B.D., Bussan, A.J., Buschena, D., Goodman, D. 2001. Implementing and conducting on-farm weed research with the use of GPS. *Weed Science* 49, 536-542.

Maxwell, B.D., Luschei, E.C. 2005. Justification for site-specific weed management based on oncology and economics. *Weed Science* 53, 221-227.

MAMR. 2011. Organización Común de Mercados. <http://www.mapa.es/>.

Medlin, C.R., Shaw D.R., Gerard, P.D., LaMastus, F.E. 2000. Using remote sensing to detect weed infestations in *Glycine max*. *Weed Science* 48, 393-398.

Moran, P.A.P. 1950. Notes on Continuous Stochastic Phenomena. *Biometrika* 37, 17-23.

Tobler, W.R. 1970. A computer model simulation of urban growth in the Detroit region. *Economic Geography* 46 (Supplement: Proceedings. International Geographical Union. Commission on Quantitative Methods), 234-240.

Nadeau, L.B., King, J.R. 1991. Seed dispersal and seedling establishment of *Linaria vulgaris* Mill. *Canadian Journal of Plant Science* 71, 771-782.

Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., García-Torres, L. 2007. Mapping *Ridolfia segetum* Moris patches in sunflower (*Helianthus annuus* L.) crop using remote sensing. *Weed Research* 47, 167-172.

Pierce, F.J., Nowak, P. 1999. Aspects of precision agriculture. In: *Advances in Agronomy* (ed. DL Sparks), vol. 67, 1-85. Academic Press, San Diego, CA, USA.

Rew, L.J., Miller, P.C.H., Paice, M.E.R. 1997. The importance of patch mapping resolution for sprayer control. *Aspect of Applied Biology* 48, 49-55.

Ruiz, D., Escribano, C., Fernández-Quintanilla, C. 2006. Assessing the opportunity for site-specific management of *Avena sterilis* in winter barley fields in Spain. *Weed research* 46, 379-387.

Thompson, J.F., Stafford, J.V., Miller, P.C.H. 1991. Potential for automatic weed detection selective herbicide application. *Crop Protection* 10, 254-259.

Timmermann, C., Gerhards, R., Kühbauch, W. 2003. The economic impact of weed control. *Precision Agriculture* 4, 249-260.

Upton, G.J.G., Fingleton, B. 1985. *Spatial Data Analysis by Example, Vol. 1. Point Pattern and Quantitative Data*. Wiley, Chichester.

Walker, S.R., Medd, R.W., Robinson, G.R., Cullis, B.R. 2002. Improved management of *Avena ludoviciana* and *Phalaris paradoxa* with more densely sown wheat and less herbicide. *Weed Research* 42, 257-270.

Wiles, L.J. 2009. Beyond patch spraying: site-specific weed management with several herbicides. *Precision Agriculture* 10, 277-290.

Wille, M.J., Thill, D.C., Price, W.J. 1998. Wild oat (*Avena fatua*) seed production in spring barley (*Hordeum vulgare*) is affected by the interaction of wild oat density and herbicide rate. *Weed Science* 46, 336-343.

## 7. Anexo1

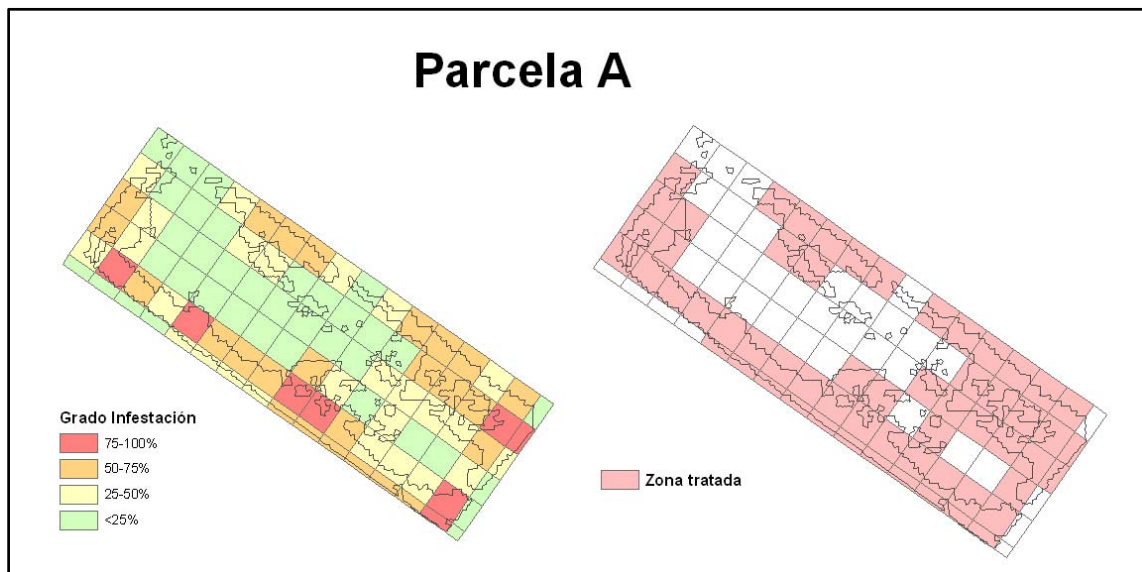


Figura 5.16: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 en la parcela A.

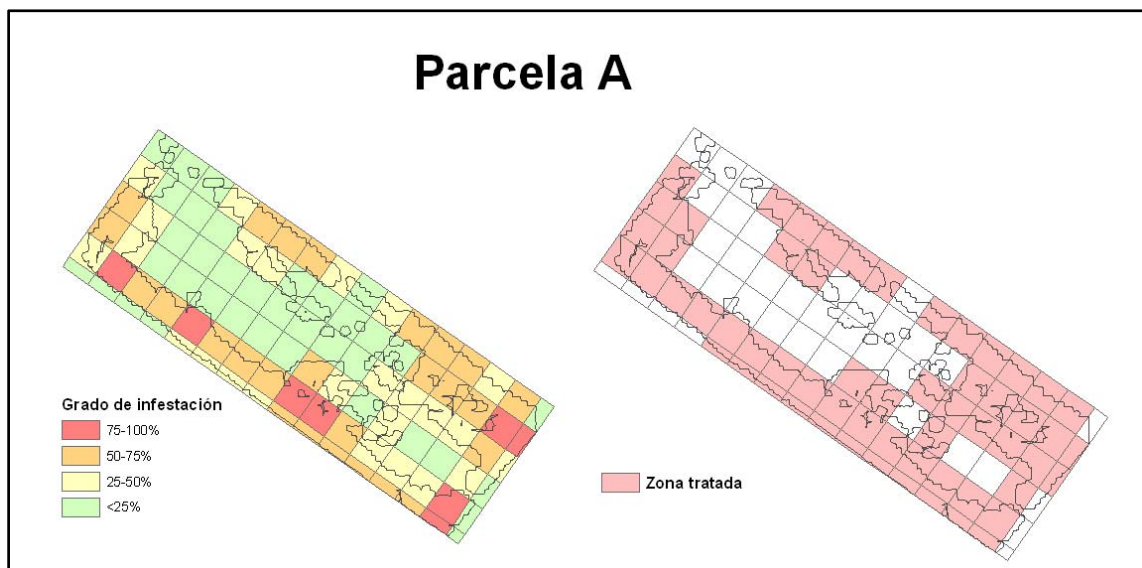


Figura 5.17: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 1 metro en la parcela A.



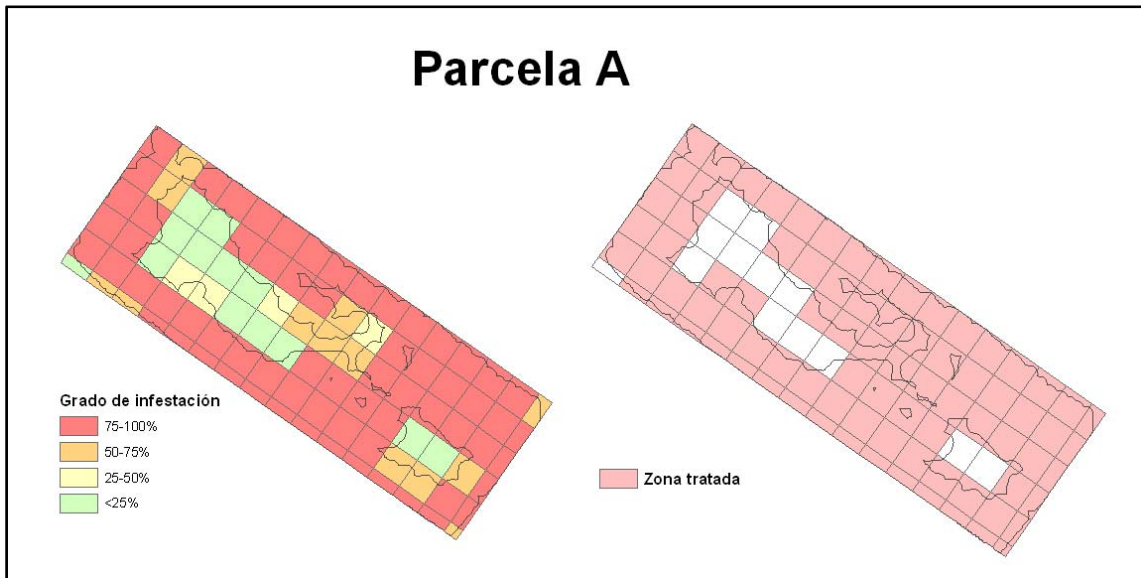


Figura 5.18: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 4 metros en la parcela A.




Figura 5.19: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 9 metros en la parcela A.




Figura 5.20: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 25 metros en la parcela A.

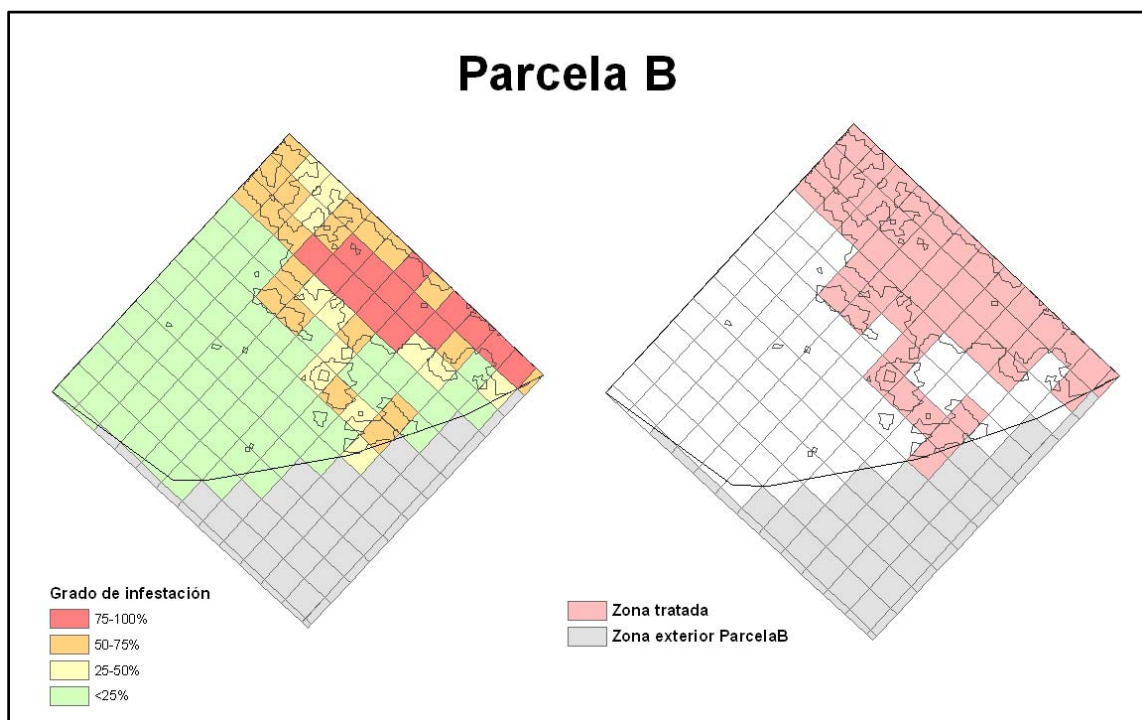


Figura 5.21: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 en la parcela B.

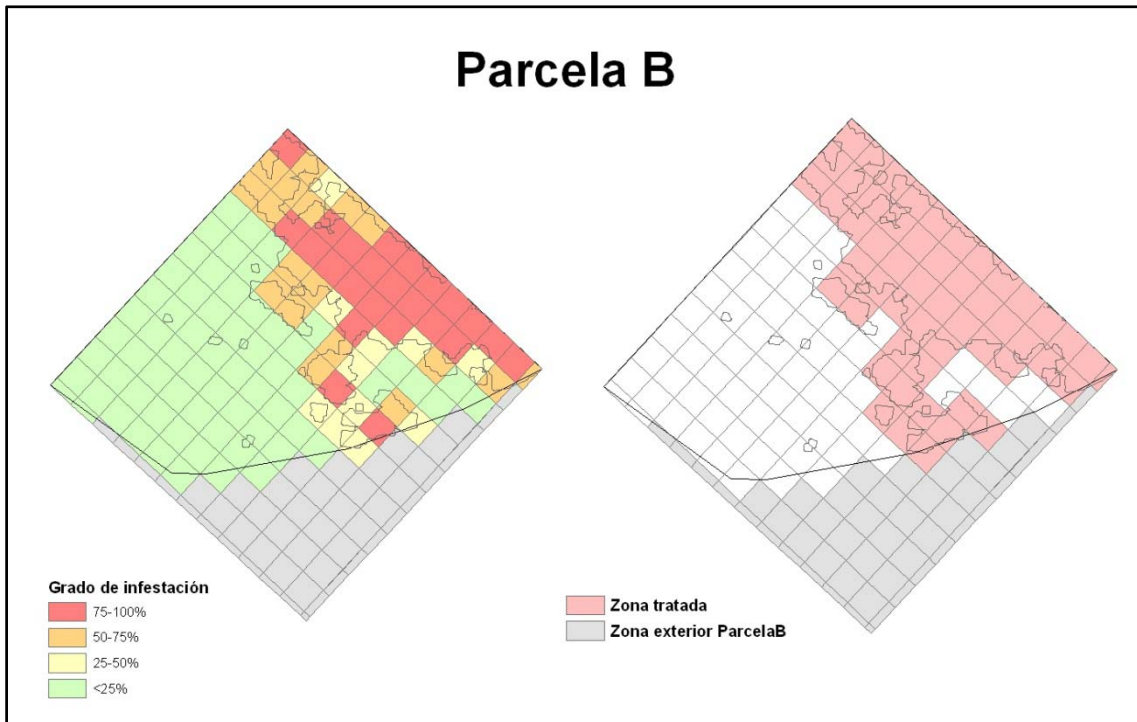


Figura 5.22: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 1 metro en la parcela B.

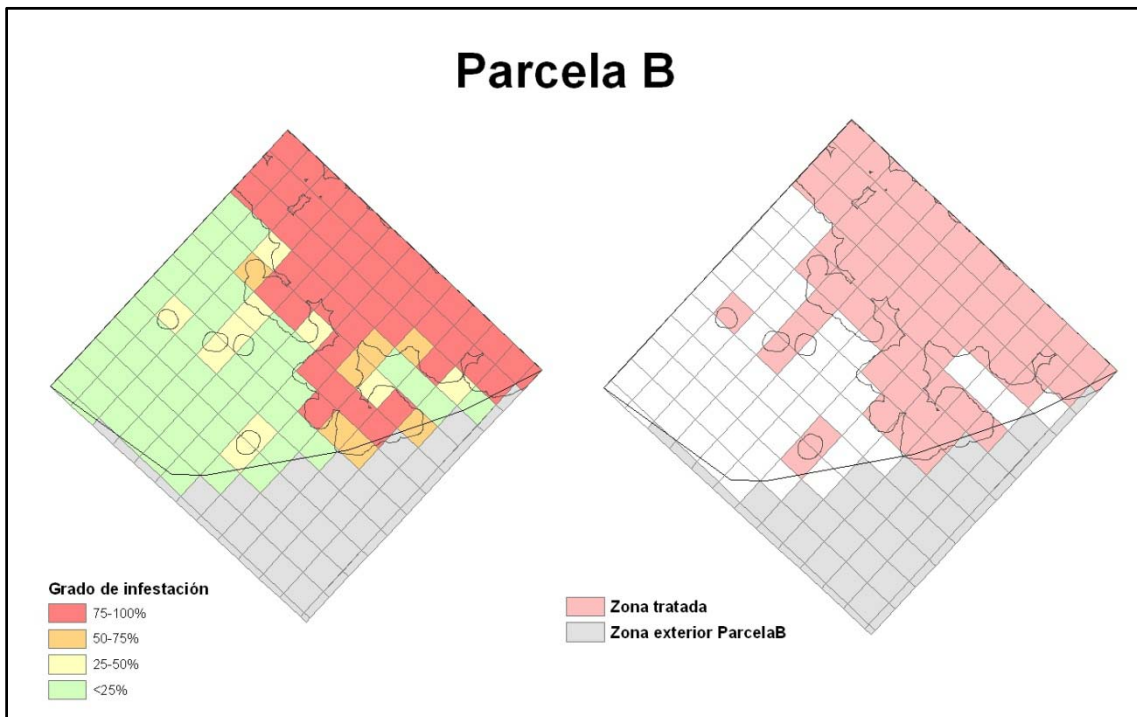


Figura 5.23: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 4 metros en la parcela B.

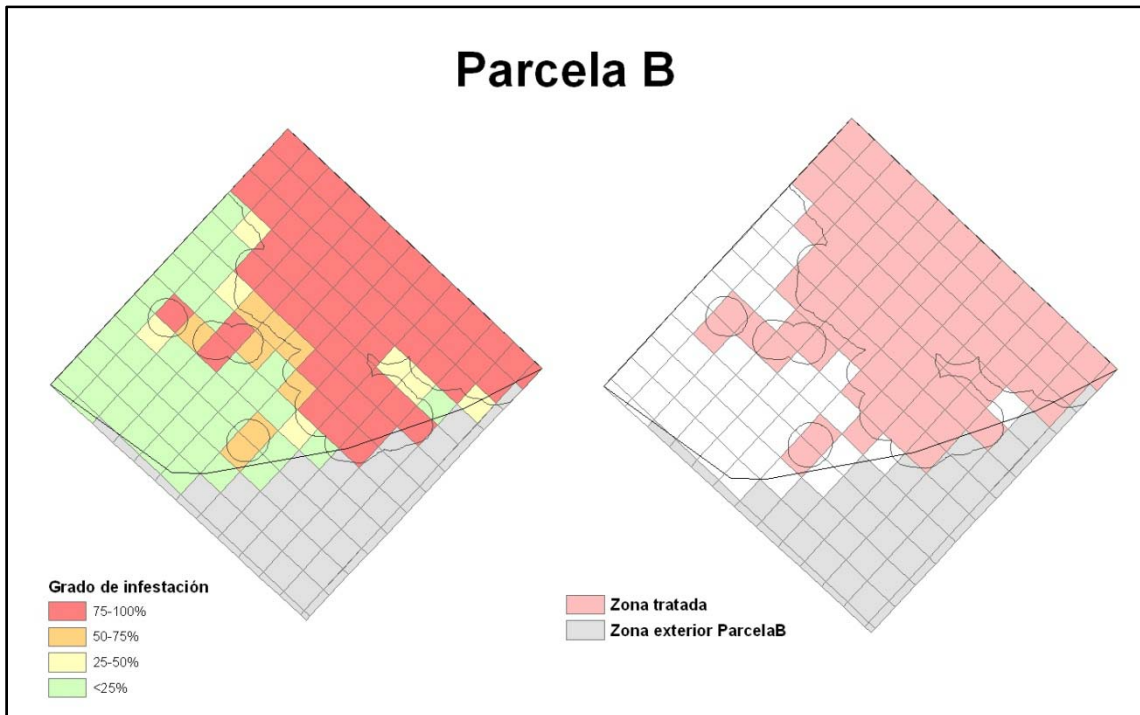


Figura 5.24: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 9 metros en la parcela B.

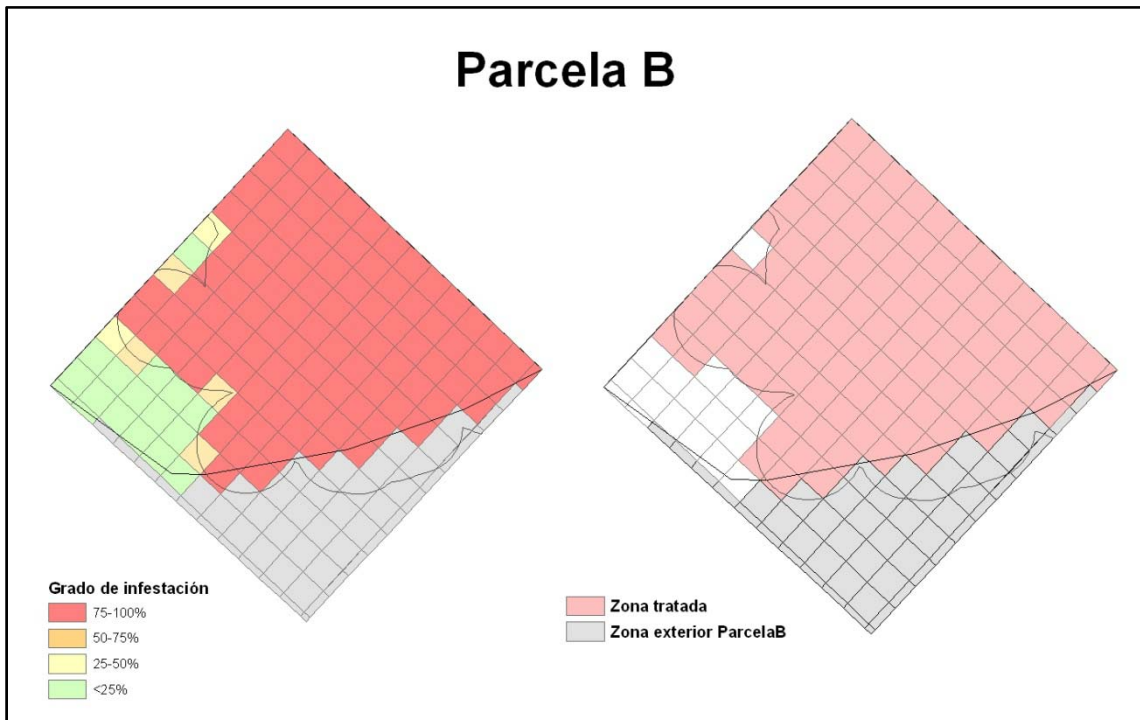


Figura 5.25: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 25 metros en la parcela B.

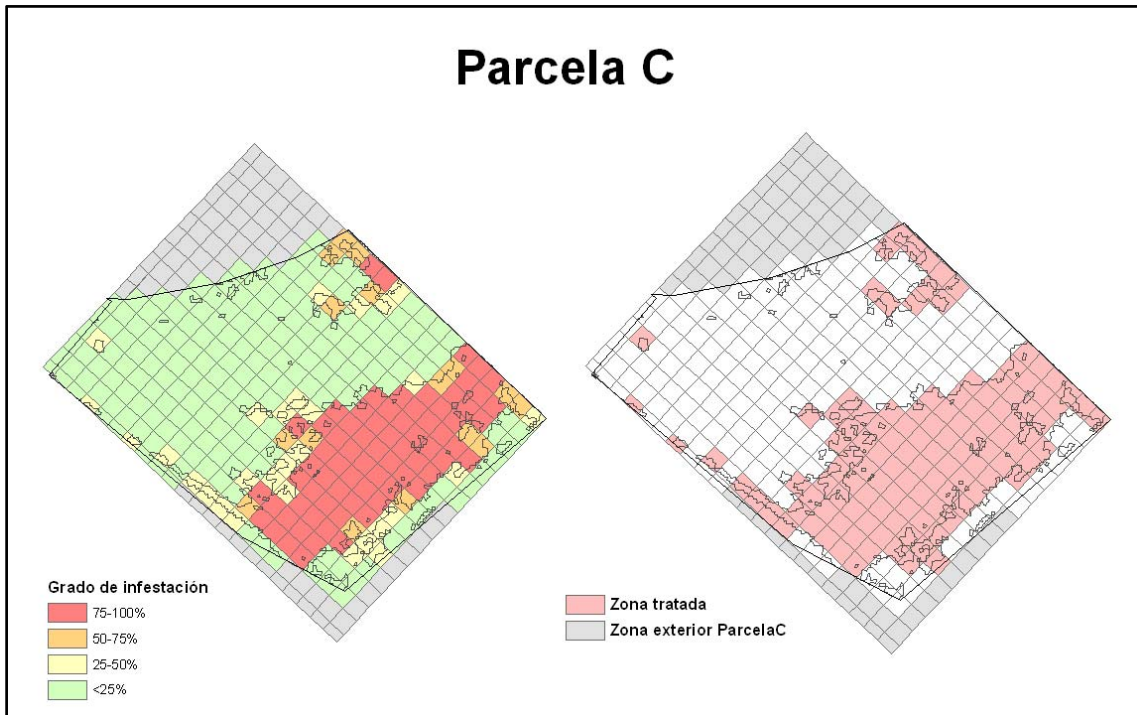


Figura 5.26: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 en la parcela C.

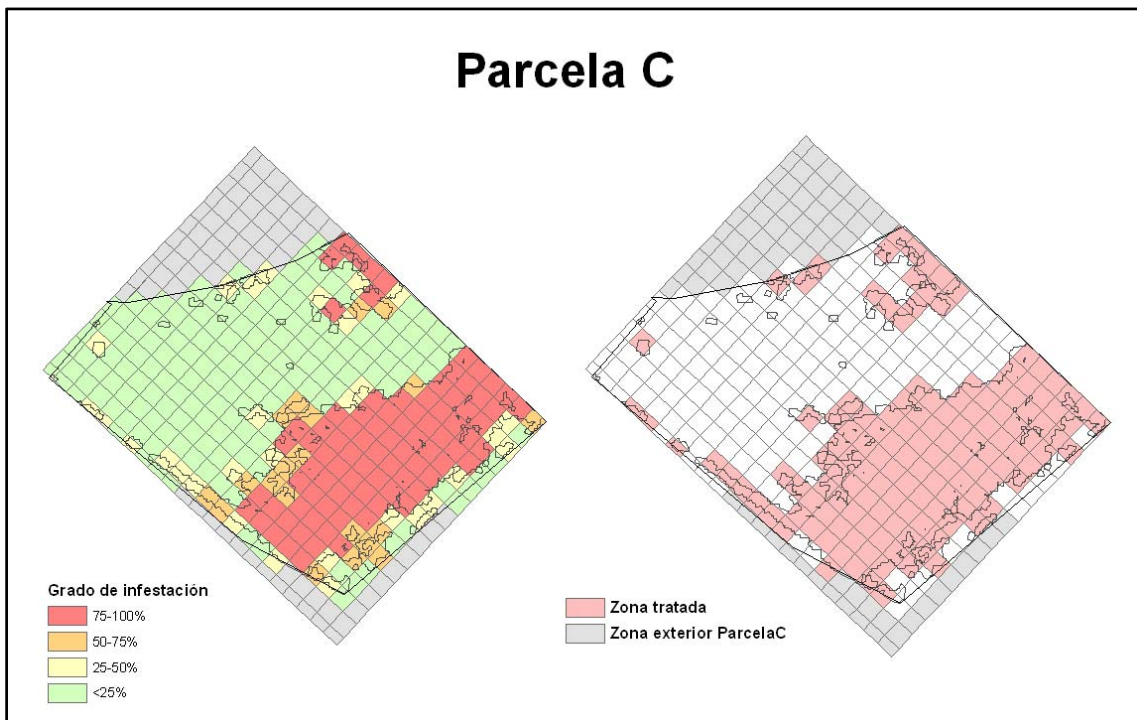


Figura 5.27: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 1 metro en la parcela C.

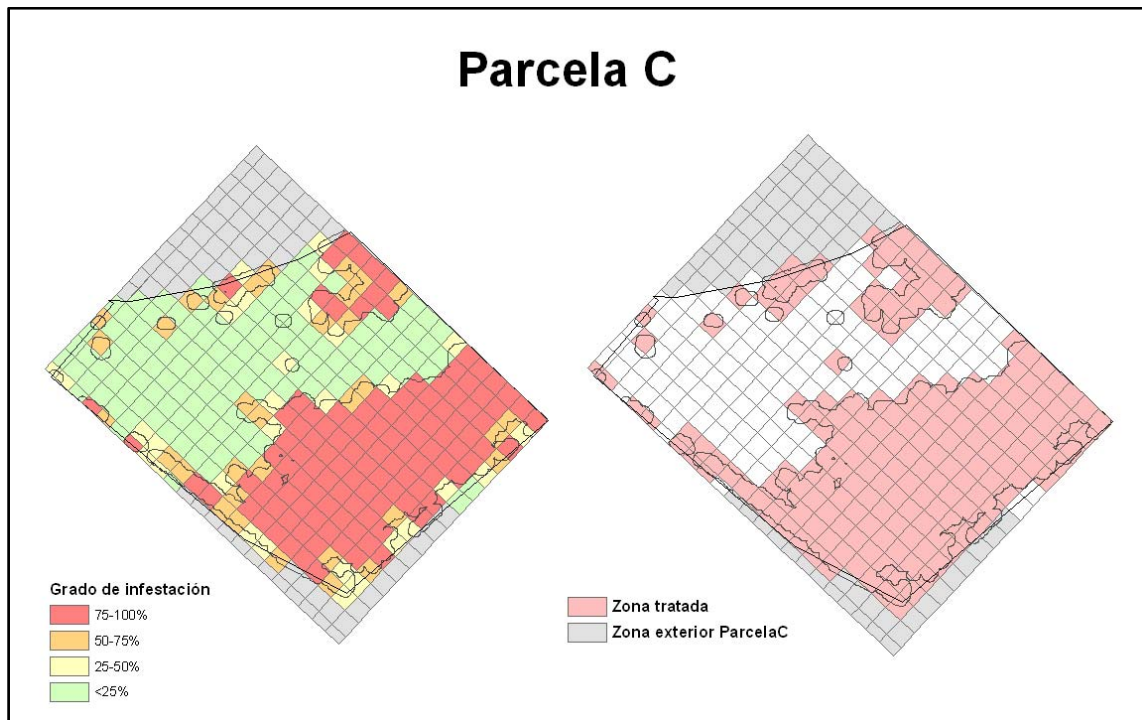


Figura 5.28: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 4 metros en la parcela C.

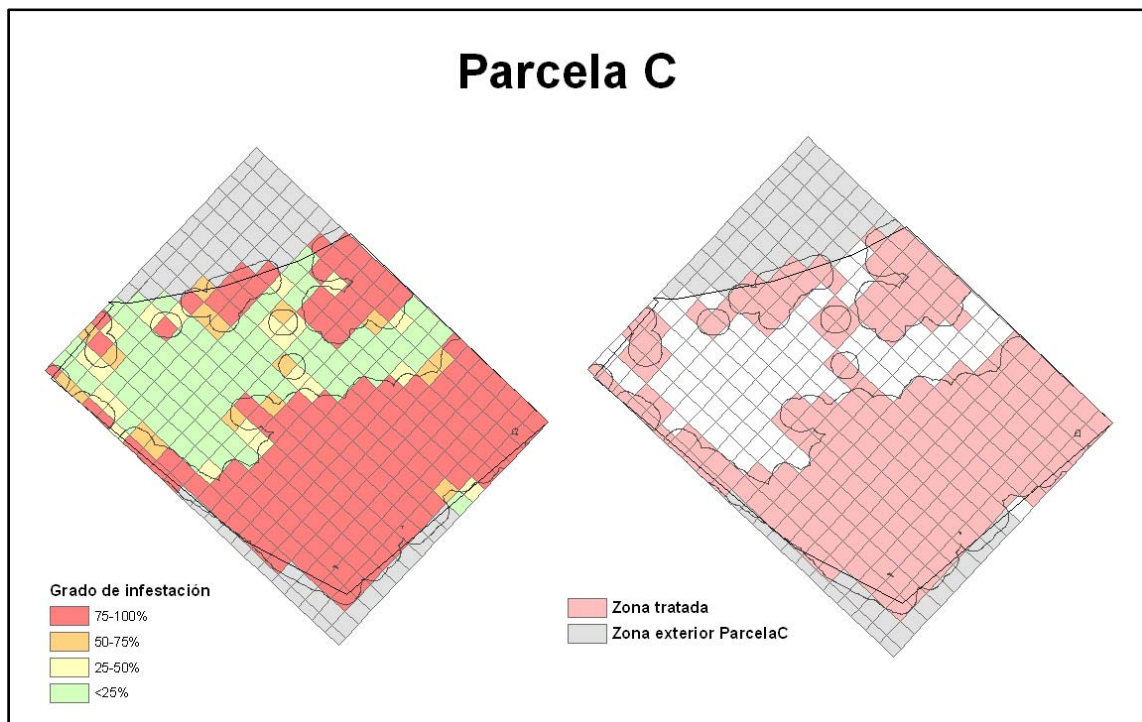


Figura 5.29: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 9 metros en la parcela C.

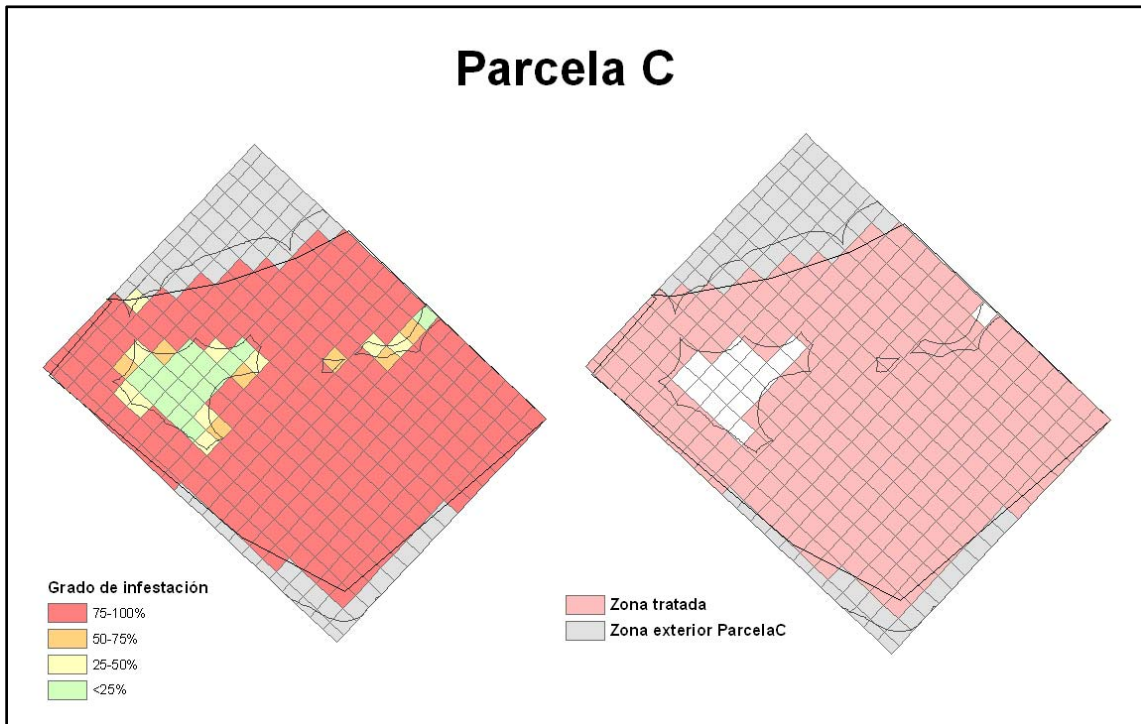


Figura 5.30: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 25 metros en la parcela C.

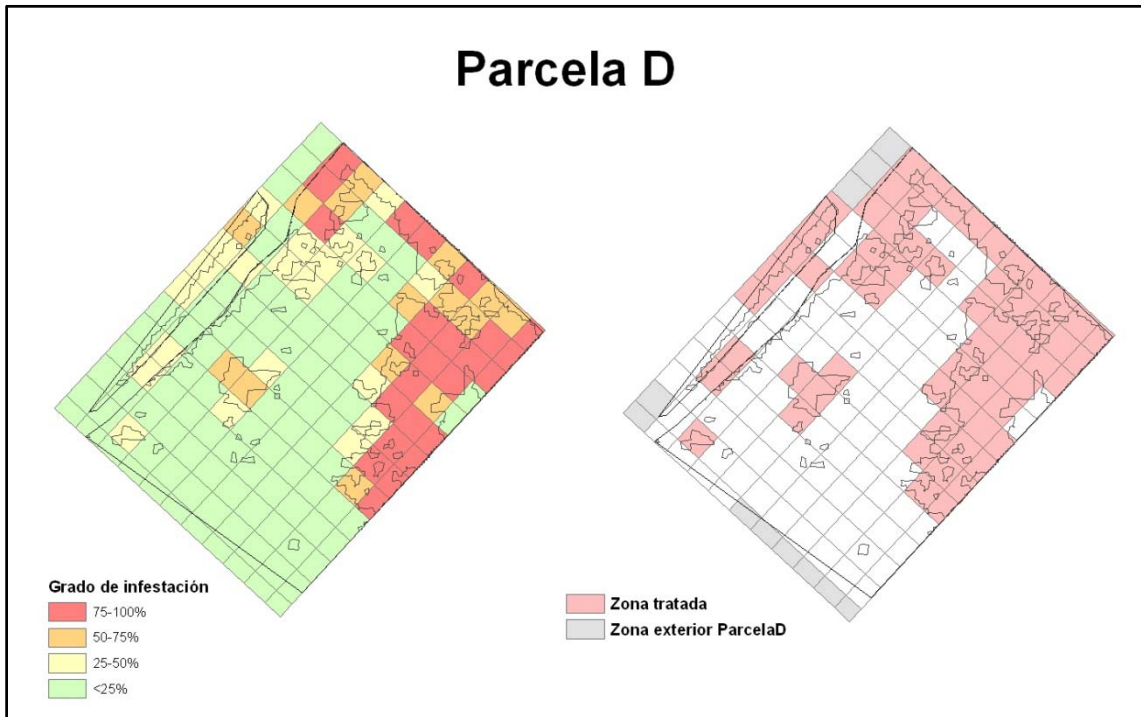


Figura 5.31: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 en la parcela D.

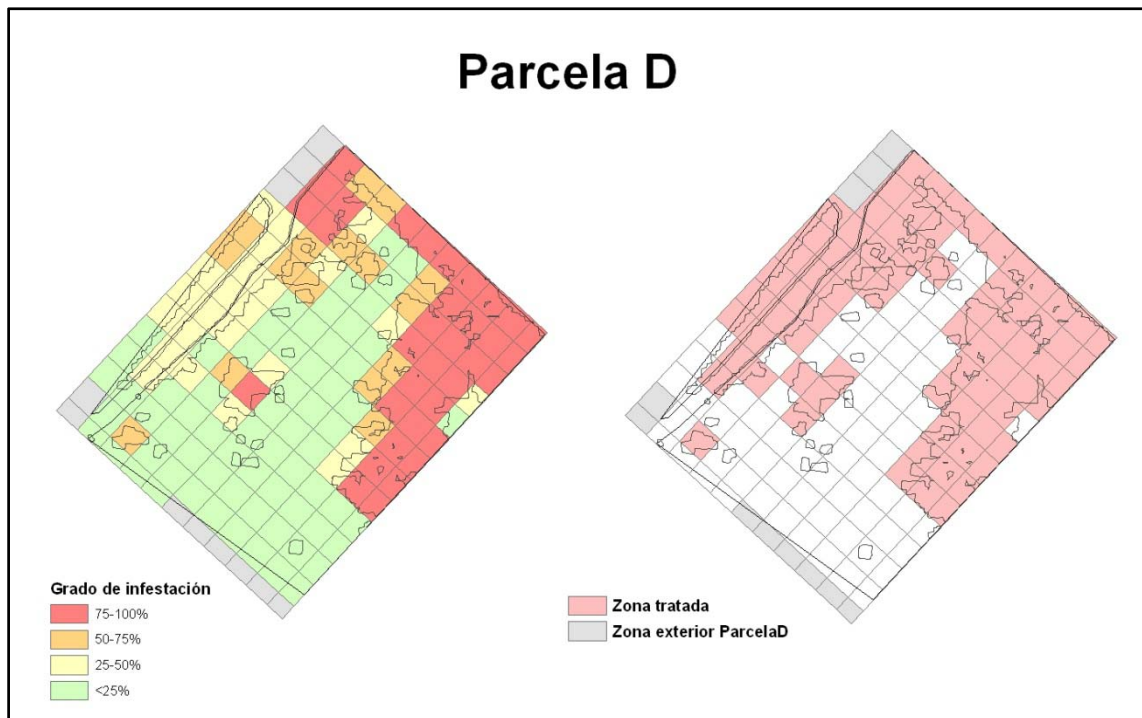


Figura 5.32: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 1 metro en la parcela D.

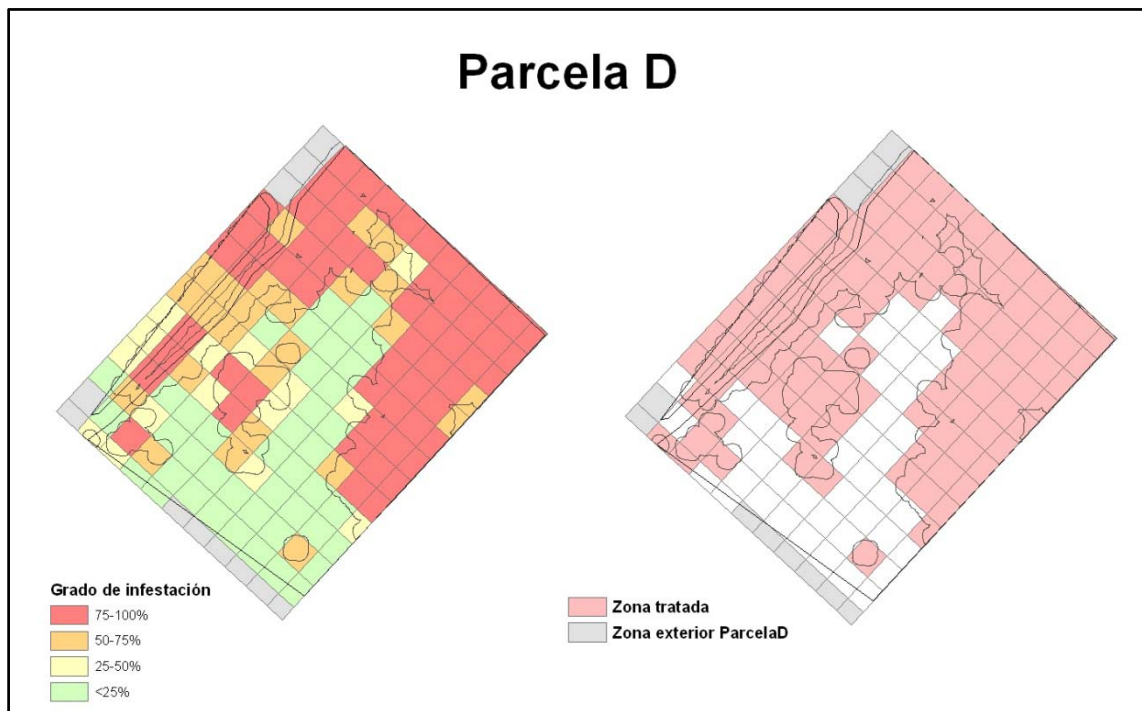


Figura 5.33: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 4 metros en la parcela D.



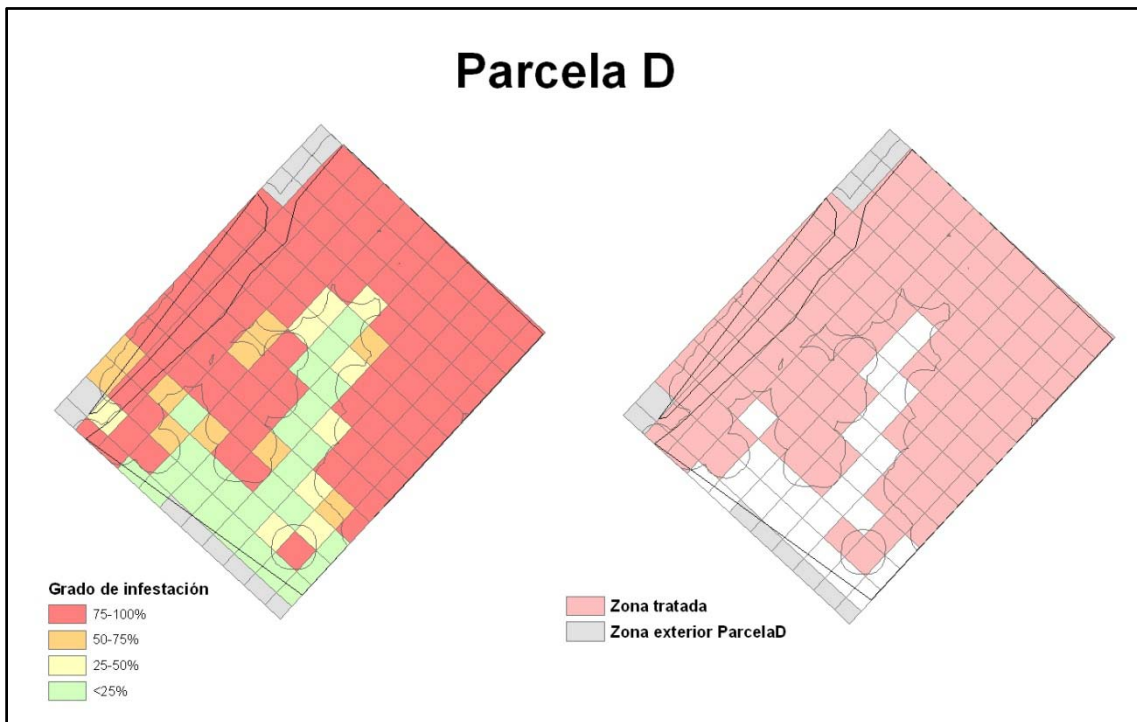


Figura 5.34: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 9 metros en la parcela D.

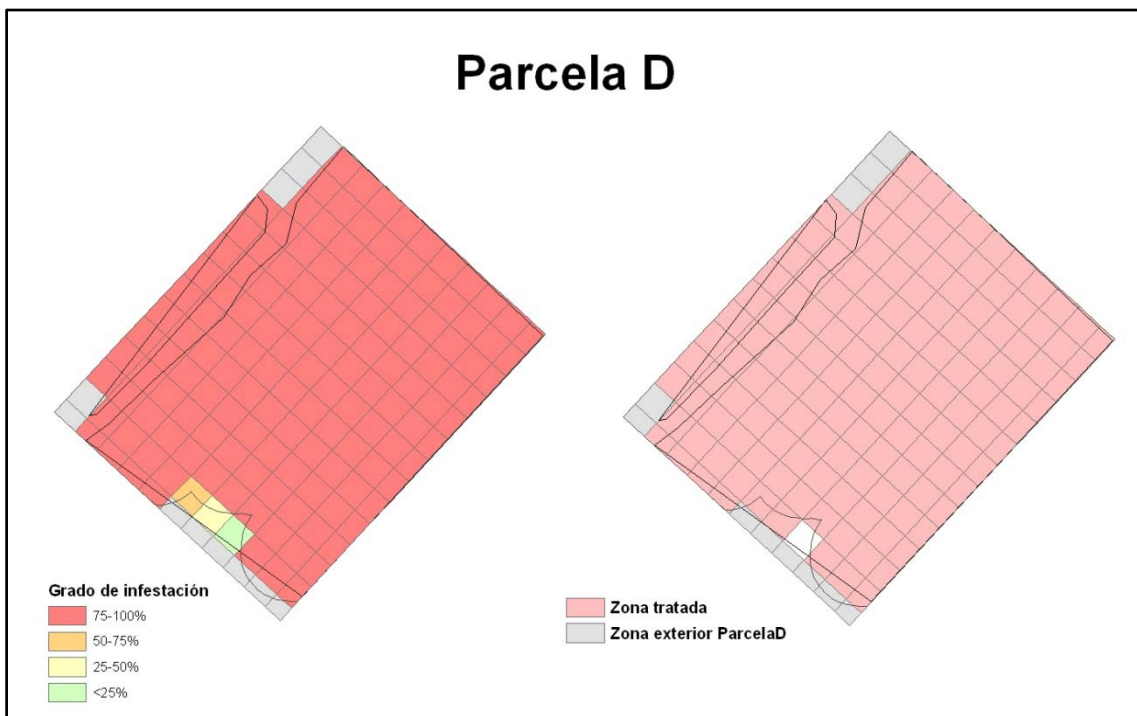


Figura 5.35: Grado de infestación de malas hierbas y zona tratada para infestación presente en 2006 + buffer de 25 metros en la parcela D.

# **Conclusiones generales**

---

## **CAPÍTULO VI**

## Conclusiones generales

En esta Tesis Doctoral se ha abordado el uso de imágenes del satélite QuickBird para la consecución de los siguientes objetivos agronómicos:

- a) Evaluación de técnicas basadas en píxeles y objetos para la detección de cultivos y sus medidas agroambientales (**Capítulo 2**).
- b) Discriminación espectral multitemporal de avena loca (*Avena sterilis* L.) y alpiste (*Phalaris spp.*) en campos de trigo (*Triticum durum* L.) en estados fenológicos tardíos (**Capítulo 3**).
- c) Clasificación de infestaciones de Avena (*Avena sterilis* L.) en trigo (*Triticum durum* L.) mediante técnicas basadas en píxeles y objetos (**Capítulo 4**).
- d) Estudio de la estabilidad de los rodales de *Avena sterilis* en trigo: análisis espacial de la persistencia (**Capítulo 5**).

De los estudios anteriores se han obtenido las siguientes conclusiones:

1. Las imágenes de satélite de alta resolución espacial, como las imágenes QuickBird, han demostrado ser útiles y precisas para aplicaciones en agricultura de conservación y agricultura de precisión. A partir de la combinación de distintas técnicas de procesamiento se han clasificado con exactitud los principales cultivos de secano mediterráneos junto con sus medidas agroambientales. Esta clasificación es fundamental para la creación de inventarios agrícolas para diversos usos agronómicos, entre los que destaca el control de ayudas agrarias. Por su parte, también se han obtenido excelentes precisiones en la clasificación de infestaciones de la mala hierba *Avena sterilis* en cultivos de trigo para el diseño posterior de medidas de control localizado dirigido únicamente a las zonas infestadas.

2. La segmentación de imágenes y formación de objetos para su uso en posteriores análisis ha tenido un comportamiento desigual en función de las características de las clasificaciones realizadas. En los estudios en los que se han clasificado usos de suelo diferentes espectralmente (ej. parcelas de cultivos) la utilización de imágenes segmentadas incrementa la precisión del análisis hasta un 30% respecto a la misma clasificación basada en píxeles. Sin embargo, cuando se analizan usos de suelo muy similares espectralmente (ej. infestación de *Avena sterilis* en trigo) se observan precisiones similares en ambos métodos.

3. En cualquier análisis de sistemas agrícolas mediante técnicas de teledetección se debe incorporar la variable época del año en la que se adquiere la imagen (componente temporal), debido a que la evolución del estado fenológico de las plantas estudiadas afecta significativamente a su respuesta espectral y, por tanto, a su capacidad de discriminación del resto de usos de suelo .

4. La época más apropiada para la discriminación de los principales cultivos mediterráneos de secano y sus medidas agroambientales es a principio del verano (mes de julio), cuando la viña ya presenta una actividad vegetal importante para ser detectada y los cereales de invierno ya han sido cosechados lo cual favorece la discriminación ente rastrojo y rastrojo quemado. Las técnicas de clasificación basadas en objetos sobre imágenes de alta resolución espacial (QuickBird) ofrecieron mejores resultados que las basadas en píxeles con todos los algoritmos de clasificación evaluados, aunque la combinación de objetos y píxeles fue la que mejor precisiones mostró con valores superiores al 85% en la mayoría de los casos. Por su parte, la utilización de imágenes fusionadas (pansharpen) en el estudio mejoró de forma limitada los resultados, si bien la clasificación más precisa del estudio se obtuvo con la clasificación combinada de píxeles y objetos de la imagen fusionada con el método máxima probabilidad, obteniéndose una precisión de 94.51%.

5. La medida de las firmas espectrales con espectroradiómetro de campo de las clases estudiadas es relevante para determinar la fecha más apropiada (análisis temporal), las longitudes de onda (análisis hiperespectral) y las bandas o los índices de vegetación (análisis multiespectral) que poseen un potencial mayor para su discriminación mediante teledetección.

6. La época adecuada para la discriminación de las malas hierbas *Avena sterilis* L. y *Phalaris* spp. en trigo utilizando espectroradiómetro de campo es 3-5 semanas antes de la cosecha dependiendo de la climatología de ese año, cuando las malas hierbas se encuentran en un estado inicial de maduración con la planta verde y el trigo se encuentra en un estado avanzado de maduración con la planta parcialmente amarilla o senescente. Para la discriminación entre cultivo y malas hierbas mediante datos hiperespectrales se observa que las longitudes de onda más utilizadas se encuentran en las regiones del infrarrojo cercano, azul y rojo. Por su parte, en el análisis multiespectral se ha obtenido que las cuatro bandas consideradas (Azul (A), Verde (V), Rojo (R) e Infrarrojo cercano (IRc)), así como todos los índices excepto el (R-V/R+V), fueron muy útiles para esta discriminación.

7. Respecto a los trabajos a “escala parcela” con imágenes del satélite QuickBird tomadas en 2 años permitieron la discriminación de *Avena sterilis* en cultivo de trigo cuando la mala hierba está en un estado inicial de maduración con la planta verde y el trigo se encuentra en un estado avanzado de maduración con la planta parcialmente amarilla o senescente. Las segmentaciones de las imágenes y la formación de los objetos ofrecieron precisiones similares en las precisiones respecto a las clasificaciones basadas

en píxeles. Todos los clasificadores evaluados presentan precisiones muy parecidas entre sí y superiores al 90%, excepto el clasificador Paralelepípedos. Varios clasificadores destacan por su precisión, siendo los clasificadores Distancia de Mahalanobis, Máxima Probabilidad y *Support Vector Machine* los que presentan mejor capacidad de discriminación con valores superiores al 98% en la mayoría de las parcelas de trigo analizadas individualmente.

8. Respecto a los estudio a “escala imagen”, el análisis jerárquico mediante técnicas de segmentación multiresolución permite clasificaciones muy precisas entre cultivos, con valores de fiabilidad de las parcelas de trigo superiores al 93%. Estas parcelas, una vez aisladas del resto de usos de suelo y analizadas conjuntamente, obtienen a su vez excelentes tasas de discriminación entre trigo y la mala hierba *Avena sterilis* en estado tardío, con precisiones del 98.29% con el clasificador Máxima Probabilidad en la imagen de 2006 y 93.63% con el clasificador *Support Vector Machine* en la imagen de 2008.

9. Tras un análisis espacial de persistencia de los rodales de *Avena sterilis* en campos de trigo se observa que éstos persisten en el espacio y en el tiempo a la vez que tienden a aumentar su población si no es controlada adecuadamente. Su crecimiento se hace en base a los rodales del año anterior (crecimiento agregado) y la mayor parte de la dispersión de las infestaciones se encuentra a escasos metros de infestaciones previas. Este tipo de patrón espacial de propagación de la infestación es muy útil para el diseño de un programa de control localizado para el siguiente año ya que el mapa de infestaciones y de tratamientos obtenido se puede utilizar al año siguiente.

10. Tras simular y analizar económicamente la viabilidad de este programa, se observa que en general son rentables aquellos tratamientos dirigidos a la superficie clasificada un determinado año más una zona extra de control (*buffer*) de 1m a 4m, lo que eliminaría aproximadamente toda la avena clasificada en el estudio de 2006 junto a una proporción de nuevas malas hierbas emergidas al año siguiente de entre un 25% y un 50%.

# **Abreviaturas**

---

---

## Abreviaturas

---

A: Azul

AD: Árbol de decisión

CLMH: Control Localizado de Malas Hierbas

D<sub>Ma</sub>: Distancia de Mahalanobis

FG: Fiabilidad Global

FP: fiabilidad del Productor

F<sub>Pt</sub>: Fiabilidad del Productor del trigo

FU: Fiabilidad del Usuario

I<sub>Rc</sub>: Infra Rojo cercano

JM: Jeffries-Matusita

K: coeficiente Kappa

MD: Mínima Distancia

MP: Máxima Probabilidad

NDVI: Normalized Difference Vegetation Index

P: Paralelepípedos

R: Rojo

RVI: Ratio Vegetation Index

RAT: Relación de Área de Trigo

SAM: Spectral Angle Mapper

SVM: Support Vector Machine

UMI: Unidad Mínima de Información

V: Verde