

TESIS DOCTORAL

**TÉCNICAS INTELIGENTES BASADAS EN
PERCEPCIÓN VISUAL APLICADAS A LA
AGRICULTURA DE PRECISIÓN**

D. Alberto Tellaeché Iglesias

Ingeniero en Automática y Electrónica Industrial

**Departamento de Informática y Automática
Escuela Técnica Superior de Ingeniería Informática
UNIVERSIDAD NACIONAL DE EDUCACIÓN A
DISTANCIA**

2007

Departamento de Informática y Automática
Escuela Técnica Superior de Ingeniería Informática
UNIVERSIDAD NACIONAL DE EDUCACIÓN A
DISTANCIA

TÉCNICAS INTELIGENTES BASADAS EN
PERCEPCIÓN VISUAL APLICADAS A LA
AGRICULTURA DE PRECISIÓN

D. Alberto Tellaeché Iglesias
Ingeniero en Automática y Electrónica Industrial

Director de Tesis:
Dr. D. Gonzalo Pajares Martinsanz

Tutor:
Dr. D Joaquín Aranda Almansa

Agradecimientos

En primer lugar me gustaría agradecer a la Universidad Nacional de Educación a Distancia y a la Universidad Complutense de Madrid la excelente oportunidad que me han brindado en el programa de doctorado "Ingeniería de Sistemas y Automática". De no ser por este programa, y debido a mi situación personal, nunca hubiera podido realizar una tesis doctoral tan interesante y tan realizadora a nivel personal. Mis agradecimientos se hacen extensivos también al Instituto de Automática Industrial (IAI) del Consejo Superior de Investigaciones Científicas (CSIC), por permitirme basar, aunque sea de manera indirecta, mi trabajo de tesis en uno de sus proyectos y colaborar conmigo en su realización.

En el ámbito de los agradecimientos personales, me gustaría agradecer profundamente su ayuda y apoyo a mi director de tesis, el Dr. Gonzalo Pajares Martinsanz de la Universidad Complutense de Madrid. Pese al escollo de la distancia y a no habernos visto en muchas ocasiones, su apoyo, ayuda y dedicación han sido encomiables. Ahora que la tesis toca a su fin, le considero un buen amigo y espero poder seguir manteniendo el contacto con él en el futuro.

Me gustaría dar también las gracias a Ángela Ribeiro Seijas, investigadora del Instituto de Automática Industrial del Consejo Superior de Investigaciones Científicas, quién ha propiciado el trabajo en calidad de investigadora principal del subproyecto coordinado con referencia AGL2005-06180-C03-03 y título *"EXTRACCIÓN DE CONOCIMIENTO ESPACIO-TEMPORAL Y VISIÓN ARTIFICIAL PARA LA AUTOMATIZACIÓN DE TRATAMIENTOS AGRÍCOLAS LOCALIZADOS"* encuadrado dentro del Plan Nacional de I+D+i del Ministerio de Educación y Ciencia. A Xavier Paolo Burgos-Artizzu becario en el mismo centro de investigación del CSIC, bajo el mismo proyecto, por su inestimable ayuda y soporte. Ambos han colaborado en el desarrollo de los métodos que se presentan, proporcionando la mayoría de las imágenes utilizadas para la investigación. A César Fernández Quintanilla investigador del Centro de Ciencias

Medioambientales del Consejo Superior de Investigaciones Científicas por la iniciativa en temas relacionados con la Agricultura de Precisión como investigador principal del proyecto en el que se encuadra el anteriormente mencionado.

Me gustaría dar también las gracias al profesor Dr. D. Joaquín Aranda Almansa, del Departamento de Informática y Automática de la UNED por su labor como tutor de esta Tesis.

Por último, me gustaría dar mi más sincero agradecimiento a mi familia y a las personas que me han apoyado y querido de manera incondicional a lo largo de mi vida, que me han ayudado a ser quien soy y que me han enseñado que con esfuerzo todo es posible en la vida. Mención especial merece mi abuelo Antonio, que aunque ya hace muchos años que no está con nosotros, yo lo sigo teniendo muy presente en mi vida.

Resumen

Durante estos últimos años, y más concretamente, a partir de la década de los años 90, se han producido importantes avances en el uso de técnicas de automatización y control en agricultura. Estos avances han creado el concepto nuevo de "Agricultura de precisión". Uno de los principales objetivos de la agricultura de precisión es minimizar el volumen de uso de herbicidas, obteniendo numerosos beneficios en calidad de los productos obtenidos y minimizando los daños al medio ambiente causados por este tipo de productos químicos.

En este marco de actuación se han generado numerosos trabajos para la identificación de las malas hierbas en campos de cultivo. La presente tesis trata de dar solución a un problema de este tipo en situaciones en las que las malas hierbas son indistinguibles de los cultivos, ya que su color, tamaño y textura son prácticamente idénticos a los de los cultivos que se pretende optimizar. Para dar solución a este problema se utilizan técnicas de procesamiento de imagen avanzado y diversos algoritmos de aprendizaje automático.

Palabras clave:

Agricultura de precisión, detección de malas hierbas, Visión por computador, Aprendizaje Automático, toma de decisión, clasificación, segmentación.

Abstract

In these latest years, there has been a clear tendency of applying control and automation techniques in agriculture. These works have developed a new technical concept known as "Precision Agriculture". One of the main objectives of the precision agriculture is to minimize the volume of herbicides used, obtaining numerous advantages in the quality of the products obtained and minimizing the harms caused to the environment due to the use of these chemical products.

Within this framework there have been numerous approaches for the identification of weeds in crop fields. The present thesis, tries to find a solution to a problem of this kind in situations where the weeds are indistinguishable from the crops, because its colour, size, shape and texture are practically identical to the ones of the crops that are bound to be optimized. To find a solution to this problem, techniques of advanced image processing and several machine learning algorithms have been used.

Keywords:

Precision Agriculture, Weed detection, Machine Vision, Machine Learning, decision making, classification, segmentation.

Índice General

1. INTRODUCCIÓN.....	1
1.1. ANTECEDENTES	1
1.1.1. Agricultura de precisión.....	1
1.1.2. Ecología espacio-temporal.....	6
1.1.3. Detección de malas hierbas.....	8
1.1.4. Actuación.....	13
1.2. RESUMEN DE LOS MÉTODOS INVESTIGADOS	15
1.3. PROBLEMÁTICA.....	15
1.4. MOTIVACIÓN Y OBJETIVOS DE INVESTIGACIÓN	20
1.4.1. Objetivos Generales	20
1.4.2. Objetivos específicos	21
1.4.2.1 Localización y distribución espacial de las malas hierbas	21
1.4.2.2 Detección y decisión.....	22
1.5. APORTACIONES REALIZADAS EN LA INVESTIGACIÓN.....	22
1.5.1. Segmentación.....	22
1.5.2. Decisión.....	23
1.6. INVESTIGACIÓN PREVIA.....	24
1.7. CONTENIDO DE LA MEMORIA.....	26
2. SEGMENTACIÓN DE LA IMAGEN Y EXTRACCIÓN DE ATRIBUTOS..	27
2.1. INTRODUCCIÓN	27
2.2. ESTRUCTURA GENERAL DEL SISTEMA.....	28
2.3. SEGMENTACIÓN: ADQUISICIÓN DE IMÁGENES	30
2.4. SEGMENTACIÓN: BINARIZACIÓN, DETECCIÓN DE SURCOS Y EXTRACCIÓN DE CELIDAS	33
2.4.1. Binarización	33
2.4.2. Detección de las líneas de cultivo y obtención de celdas de procesamiento...	35

2.5.	SEGMENTACIÓN: EXTRACCIÓN DE ATRIBUTOS.....	40
2.5.1.	<i>Razones para la elección de los atributos</i>	41
2.5.2.	<i>Relaciones cuantitativas</i>	44
2.5.3.	<i>Relaciones estructurales</i>	50
2.5.4.	<i>Base de conocimiento de celdas modelo</i>	54
2.5.5.	<i>Datos utilizados en los algoritmos de decisión</i>	55
3.	ALGORITMOS DE DECISIÓN	57
3.1.	INTRODUCCIÓN.....	57
3.2.	CLASIFICACIÓN MEDIANTE MÁQUINAS DE VECTORES SOPORTE.....	59
3.2.1.	<i>Teoría de las Support Vector Machines (SVM)</i>	59
3.2.1.1	Proceso de entrenamiento.....	59
3.2.1.2	Proceso de decisión.....	63
3.2.2.	<i>Utilización de las SVM en el problema de clasificación de celdas de cultivo</i>	64
3.3.	CLASIFICADORES ESTADÍSTICOS: BAYES Y VENTANA DE PARZEN.....	65
3.3.1.	<i>Teoría del clasificador Paramétrico Bayesiano</i>	66
3.3.1.1	Caso Normal multivariable con media desconocida.....	66
3.3.1.2	Caso Normal Multivariable con media y matriz de covarianza desconocidas.....	68
3.3.1.3	Teoría de la decisión de Bayes, el clasificador Bayesiano	69
3.3.2.	<i>Teoría del clasificador no paramétrico. Ventana de Parzen</i>	73
3.3.3.	<i>Utilización de los clasificadores estadísticos para la clasificación de las celdas de cultivo</i>	77
3.3.3.1	Clasificador no paramétrico de la ventana de Parzen	78
3.4.	CLASIFICACIÓN MEDIANTE AGRUPAMIENTO BORROSO O FUZZY CLUSTERING .	84
3.4.1.	<i>Teoría del agrupamiento borroso</i>	84
3.4.2.	<i>Utilización del método de agrupamiento borroso para la clasificación de celdas de cultivo</i>	88
3.5.	EL CLASIFICADOR HEBBIANO	89
3.5.1.	<i>Teoría del clasificador Hebbiano</i>	90
3.5.2.	<i>Utilización del clasificador Hebbiano para la clasificación de celdas de cultivo</i>	93

3.5.2.1	Etapa <i>off-line</i> : entrenamiento	93
3.5.2.2	Etapa <i>on-line</i> : decisión.....	95
3.6.	COMBINACIÓN DE CLASIFICADORES.....	95
3.6.1.	<i>Clasificador híbrido: Bayes y agrupamiento borroso</i>	97
3.6.1.1	Etapa <i>off-line</i> : entrenamiento.....	98
3.6.1.2	Etapa <i>on-line</i> : decisión.....	98
3.6.2.	<i>Clasificador híbrido: máquinas de vectores soporte y agrupamiento borroso</i>	99
3.6.2.1	Etapa <i>off-line</i> : entrenamiento.....	99
3.6.2.2	Etapa <i>on-line</i> : decisión.....	99
3.6.3.	<i>Clasificador híbrido: Bayes y Máquinas de Vectores Soporte</i>	100
3.7.	CLASIFICACIÓN MEDIANTE EL ALGORITMO MCDM BASADO EN LÓGICA BORROSA	101
3.7.1.	<i>Teoría del MCDM basado en lógica borrosa</i>	102
3.7.2.	<i>Cálculo de los pesos del algoritmo MCDM: algoritmo ID3</i>	107
3.7.3.	<i>Utilización del algoritmo MCDM basado en lógica borrosa para la clasificación de celdas de cultivo</i>	112
4.	RESULTADOS: ESTRATEGIAS DE TEST Y ANÁLISIS	117
4.1.	INTRODUCCIÓN	117
4.2.	VALORES Y MEDIDAS DE RENDIMIENTO	122
4.3.	CRITERIO EXPERTO.....	123
4.3.1.	<i>Densidad y dispersión de malas hierbas</i>	124
4.3.2.	<i>Factores adicionales</i>	125
4.3.3.	<i>Observación visual</i>	125
4.4.	DESCRIPCIÓN DEL CONJUNTO DE IMÁGENES DE PRUEBA Y SU PROCESAMIENTO SECUENCIAL.....	127
4.4.1.	<i>Imágenes de los campos de cereal</i>	127
4.4.2.	<i>Imágenes de los campos de maíz</i>	131
4.5.	ESTRATEGIA DE TEST PARA LOS MÉTODOS DE CLASIFICACIÓN SIMPLES E HÍBRIDOS EN LOS CAMPOS DE CEREAL.	133

4.6.	RESULTADOS DE LOS MÉTODOS DE CLASIFICACIÓN SIMPLES EN CULTIVOS DE CEREAL	137
4.6.1.	<i>Máquinas de vectores soporte: SVM</i>	137
4.6.2.	<i>Clasificador de Bayes paramétrico: BAYP</i>	140
4.6.2.1	Propiedades estadísticas de las clases.....	140
4.6.2.2	Resultados obtenidos.....	143
4.6.3.	<i>Clasificador de Bayes no paramétrico: BAYN</i>	144
4.6.4.	<i>Fuzzy Clustering: FUCL</i>	145
4.6.5.	<i>Clasificador Hebbiano: HEBB</i>	147
4.6.6.	<i>Comparativa de resultados para los clasificadores simples</i>	148
4.7.	RESULTADOS DE LOS MÉTODOS DE CLASIFICACIÓN HÍBRIDOS EN CULTIVOS DE CEREAL	149
4.7.1.	<i>Hibridación de Bayes paramétrico y Fuzzy Clustering: BAFU</i>	149
4.7.2.	<i>Hibridación de Fuzzy clustering y Máquinas de Vectores Soporte: FUSV</i>	150
4.7.3.	<i>Hibridación de Bayes no paramétrico y Máquinas de Vectores Soporte: BASV</i>	151
4.7.4.	<i>Comparativa de resultados para los clasificadores simples e híbridos</i>	152
4.8.	MÉTODO DE DECISIÓN MULTICRITERIO MCDM EN CAMPOS DE CEREAL	154
4.8.1.	<i>Diseño de la estrategia de test</i>	154
4.8.2.	<i>Toma de decisiones</i>	157
4.8.3.	<i>Análisis de resultados</i>	157
4.9.	ANÁLISIS COMPARATIVO DE RESULTADOS PARA LOS DIFERENTES MÉTODOS EN CULTIVOS DE CEREAL.....	164
4.10.	ESTRATEGIA DE TEST Y RESULTADOS PARA EL ESTIMADOR DE PARZEN EN CULTIVOS DE MAÍZ	166
4.10.1.	<i>Diseño de la estrategia de test</i>	166
4.10.2.	<i>Análisis de resultados</i>	168
5.	CONCLUSIONES Y TRABAJO FUTURO.....	173
5.1.	CONCLUSIONES	173

5.2.	TRABAJO DE INVESTIGACIÓN FUTURA	175
6.	REFERENCIAS	177

Lista de Símbolos, Abreviaturas y Siglas

AP	Agricultura de precisión
ANN	Red Neuronal Artificial (Artificial Neural Network)
BAFU	Clasificador híbrido basado en Bayes y Fuzzy Clustering
BASV	Clasificador híbrido basado en Bayes y Support Vector Machines
BAYN	Estimador no paramétrico de la ventana de Parzen
BAYP	Estimador de Bayes paramétrico
BC	Base de Conocimiento
CCP	Porcentaje de clasificación correcta (Correct Classification Percentage)
CSIC	Consejo Superior de Investigaciones Científicas
FkM	Fuzzy Clustering
FUCL	Estimador Basado en Fuzzy Clustering
FUSV	Clasificador híbrido basado en Fuzzy Clustering y Support Vector Machines
GPS	Sistema de posicionamiento global por satélite.
HEBB	Estimador o clasificador Hebbiano
IAI	Instituto de Automática Industrial
KB	Knowledge Base (Base de Conocimiento, BC)
RGB	Red, Green, Blue (imagen en color Rojo, Verde, Azul)
SIG	Sistemas de información geográfica
SVM, SVMA	Máquina de vectores soporte (Support Vector Machine)
UCM	Universidad Complutense de Madrid
UNED	Universidad Nacional de Educación a Distancia

Lista de Figuras

FIGURA 1-1: IMÁGENES DE CAMPOS DE CULTIVO: (A) CEREAL DE INVIERNO (CEBADA) Y (B) MAÍZ ...	3
FIGURA 1-2: PULVERIZACIÓN DE HERBICIDA DE FORMA GENERALIZADA.....	4
FIGURA 1-3: SISTEMA EXPERIMENTAL DE CÁMARAS CON PROYECCIÓN DE PERSPECTIVA.	13
FIGURA 1-4: VISTA DE DOS IMÁGENES CON PROYECCIÓN DE PERSPECTIVA; (A) EJE ÓPTICO PERPENDICULAR AL SUELO (B) EJE ÓPTICO FORMANDO UN ÁNGULO DE UNOS 40° CON RESPECTO AL SUELO.	19
FIGURA 2-1: ESQUEMA GENERAL DEL SISTEMA DESARROLLADO.....	30
FIGURA 2-2: PROYECCIÓN DE PERSPECTIVA.....	32
FIGURA 2-3: ESPACIO DE PARÁMETROS Y CELDAS DE ACUMULACIÓN.....	38
FIGURA 2-4: RESULTADO DE LA TRANSFORMADA DE HOUGH.....	39
FIGURA 2-5: CREACIÓN DE LA MALLA HORIZONTAL Y ESTABLECIMIENTO DE CELDAS.....	40
FIGURA 2-6: COMPORTAMIENTO DE LA PRESIÓN DE MALAS HIERBAS. (A) PRESENCIA DE MALAS HIERBAS CONSTANTE, (B) PRESENCIA DE CULTIVO CONSTANTE	49
FIGURA 3-1: ENTRENAMIENTO DE UNA MÁQUINA DE VECTORES SOPORTE PARA ENCONTRAR EL HIPERPLANO ÓPTIMO.	61
FIGURA 3-2: APROXIMACIÓN DE LA FUNCIÓN DE DENSIDAD DE PROBABILIDAD POR EL MÉTODO DEL HISTOGRAMA CON (A) INTERVALOS DE LONGITUD GRANDE Y (B) PEQUEÑA.	74
FIGURA 3-3: DIAGRAMA DE FLUJO MOSTRANDO LA CONEXIÓN ENTRE DOS NODOS DE UNA RED.	90
FIGURA 3-4: REGLA DE HEBB Y SU MODIFICACIÓN DE ACUERDO A LA ECUACIÓN ANTERIOR.....	91
FIGURA 3-5: ESQUEMA GENERAL DE UN CLASIFICADOR COMBINADO.	96
FIGURA 3-6: ÁRBOL DE DECISIÓN CREADO A PARTIR DEL EJEMPLO.....	111
FIGURA 4-1: IMÁGENES REPRESENTATIVAS DE LOS TRES SUBCONJUNTOS (B1, B2 Y B3) DE IMÁGENES DE CEREAL. EN LA PARTE IZQUIERDA SE REPRESENTA LA IMAGEN ORIGINAL Y EN LA DERECHA LAS CORRESPONDIENTES IMÁGENES SEGMENTADAS.	129
FIGURA 4-2: DIFERENTES PERSPECTIVAS SEGÚN EL AVANCE DEL TRACTOR DE UN CAMPO DE MAÍZ Y SUS RESPECTIVAS IMÁGENES SEGMENTADAS.	133
FIGURA 4-3: SVMA: VALORES DEL COEFICIENTE DE CCP PARA LOS TRES TESTS	139
FIGURA 4-4: BAYP: VALORES DEL COEFICIENTE DE CCP PARA LOS TRES TESTS.....	144

FIGURA 4-5: BAYN: VALORES DEL COEFICIENTE DE CCP PARA LOS TRES TESTS	145
FIGURA 4-6: FUCL: VALORES DEL COEFICIENTE DE CCP PARA LOS TRES TESTS.....	146
FIGURA 4-7: HEBB: VALORES DEL COEFICIENTE DE CCP PARA LOS TRES TESTS	148
FIGURA 4-8: COMPARATIVA DEL RENDIMIENTO PARA LOS CLASIFICADORES SIMPLES	149
FIGURA 4-9: BAFU: VALORES DEL COEFICIENTE DE CCP PARA LOS TRES TESTS	150
FIGURA 4-10: FUSV: VALORES DEL COEFICIENTE DE CCP PARA LOS TRES TESTS.....	151
FIGURA 4-11: BASV: VALORES DEL COEFICIENTE DE CCP PARA LOS TRES TESTS	152
FIGURA 4-12: RESULTADOS DEL COEFICIENTE CCP PARA LOS MÉTODOS SIMPLES E HÍBRIDOS PARA EL TEST 1 EN EL PASO 3	153
FIGURA 4-13: RESULTADOS DEL COEFICIENTE CCP PARA EL MÉTODO MCDM CON LOS PESOS OBTENIDOS MEDIANTE EL PROCEDIMIENTO DE VALIDACIÓN CRUZADA (VCR) Y MEDIANTE EL ALGORITMO ID3	158
FIGURA 4-14: RESULTADOS DEL COEFICIENTE CCP PARA LOS MÉTODOS SIMPLES, HÍBRIDOS Y MCDM EN SU MEJOR RENDIMIENTO	164
FIGURA 4-15: PORCENTAJE DE CELDAS A PULVERIZAR SEGÚN LOS DIFERENTES MÉTODOS	165
FIGURA 4-16: PORCENTAJE DE ERROR MEDIO PARA DIFERENTES VALORES DE K	168
FIGURA 4-17: RESULTADOS DEL COEFICIENTE CCP PARA EL MÉTODO DE BAYES EN CULTIVOS DE MAÍZ.....	170
FIGURA 4-18: PORCENTAJE DE CELDAS A PULVERIZAR SEGÚN LOS DIFERENTES MÉTODOS	170

Lista de Tablas

TABLA 3-1: CONTENIDO DE INFORMACIÓN PARA CADA UNO DE LOS CASOS	110
TABLA 3-2: TABLA DE DECISIÓN DE ACUERDO A LOS CRITERIOS Y LOS PESOS	114
TABLA 3-3: TABLA DE <i>PERFORMANCE</i> NORMALIZADA ACORDE CON LOS CRITERIOS Y LOS PESOS..	115
TABLA 4-1: RELACIÓN DE MÉTODOS Y SU NATURALEZA FRENTE A LOS ATRIBUTOS UTILIZADOS Y EL TIPO DE CULTIVO DONDE SE APLICAN	121
TABLA 4-2: CELDAS TIPO A PULVERIZAR Y A NO PULVERIZAR	131
TABLA 4-3: NÚMERO DE CELDAS PROCESADAS EN CADA PASO	134
TABLA 4-4: MÉTODOS SIMPLES: RESUMEN DE PARÁMETROS OBTENIDOS MEDIANTE EL PROCESO DE ENTRENAMIENTO (OFF-LINE) Y DECISIÓN EN EL PROCESO DE CLASIFICACIÓN (ON-LINE).....	135
TABLA 4-5: MÉTODOS HÍBRIDOS: RESUMEN DE PARÁMETROS OBTENIDOS MEDIANTE EL PROCESO DE ENTRENAMIENTO (OFF-LINE) Y DECISIÓN EN EL PROCESO DE CLASIFICACIÓN (ON-LINE).....	136
TABLA 4-6: NÚMERO DE IMÁGENES Y VALORES DE MARGEN PARA LAS FUNCIONES GAUSSIANAS DE BASE RADIAL (RBF), POLINOMIALES (POL) Y SIGMOIDES (SIG)	137
TABLA 4-7: NÚMERO DE IMÁGENES, NÚMERO DE CELDAS A PULVERIZAR (CP) Y A NO PULVERIZAR (CN); VECTORES SOPORTE PARA CADA TEST.....	138
TABLA 4-8: VALORES DE CCP Y PORCENTAJE DE CELDAS A PULVERIZAR PARA LOS TRES TESTS Y LOS PASOS REALIZADOS	139
TABLA 4-9: VALORES DE LOS CENTROS OBTENIDOS DURANTE LOS CUATRO PASOS PARA LOS TRES TESTS Y LOS DOS GRUPOS DE CELDAS	140
TABLA 4-10: VALOR DE CCP Y PORCENTAJE DE CELDAS A PULVERIZAR PARA EL CLASIFICADOR BAYESIANO PARAMÉTRICO	144
TABLA 4-11: VALOR DE CCP Y PORCENTAJE DE CELDAS A PULVERIZAR PARA EL CLASIFICADOR BAYESIANO NO PARAMÉTRICO.....	145
TABLA 4-12: VALORES DE LOS CENTROS OBTENIDOS DURANTE LOS CUATRO PASOS PARA LOS TRES TESTS Y LOS DOS GRUPOS DE CELDAS	146
TABLA 4-13: VALOR DE CCP Y PORCENTAJE DE CELDAS A PULVERIZAR PARA EL CLASIFICADOR BASADO EN FUZZY CLUSTERING	146

TABLA 4-14: VALORES DE LOS CENTROS OBTENIDOS DURANTE LOS CUATRO PASOS PARA LOS TRES TESTS Y LOS DOS GRUPOS DE CELDAS.....	147
TABLA 4-15: VALOR DE CCP Y PORCENTAJE DE CELDAS A PULVERIZAR PARA EL CLASIFICADOR HEBBIANO.....	148
TABLA 4-16: VALORES DE CCP PARA LAS DIFERENTES ESTRATEGIAS EN LOS TRES TEST Y PASOS	150
TABLA 4-17: VALOR CCP Y PORCENTAJE DE CELDAS A PULVERIZAR PARA LOS DIFERENTES PASOS Y TESTS.....	151
TABLA 4-18: VALOR CCP Y PORCENTAJE DE CELDAS A PULVERIZAR PARA LOS DIFERENTES PASOS Y TESTS.....	152
TABLA 4-19: VALORES DE CCP Y PORCENTAJE DE LAS CELDAS A PULVERIZAR PARA LOS TESTS...	158
TABLA 4-20: CLASIFICACIÓN DE LAS CELDAS EN CELDAS A PULVERIZAR Y A NO PULVERIZAR, CON SUS PARÁMETROS ESTRUCTURALES Y CUANTITATIVOS	161
TABLA 4-21: COMBINACIÓN DE ATRIBUTOS Y PORCENTAJES DE CELDAS CLASIFICADAS COMO A PULVERIZAR Y NO PULVERIZAR	162
TABLA 4-22: NÚMERO DE IMÁGENES Y NÚMERO DE CELDAS A PULVERIZAR Y NO PULVERIZAR DE ACUERDO AL CLASIFICADOR UTILIZADO.....	169
TABLA 4-23: VALORES DE CCP Y PORCENTAJE DE CELDAS A PULVERIZAR PARA LOS TESTS Y LOS PASOS REALIZADOS.	170

1. Introducción

1.1. Antecedentes

1.1.1. Agricultura de precisión

En estas últimas dos décadas, y gracias a la disponibilidad de nuevas tecnologías geoespaciales y de la información (sistemas de posicionamiento global por satélite-GPS, sistemas de información geográfica-SIG, sensores y controladores de maquinaria agrícola, sistemas de teledetección de alta resolución espacial y espectral) ha podido hacerse realidad el manejo de precisión de las explotaciones agrarias, optimizando el uso de los diversos insumos (fertilizantes, fitosanitarios, semillas)(Pierce, Nowak, 1999).

De esta forma ha surgido el concepto de “Agricultura de Precisión (AP)”, definido como el conjunto de técnicas de cultivo que utilizan tecnologías de la información para ajustar el uso de semillas y de agroquímicos considerando la diversidad del medio físico y del medio biológico (NRC, 1997). Las tecnologías y prácticas englobadas dentro de la AP ofrecen el potencial de alterar fundamentalmente los sistemas de producción agraria, aumentando su rentabilidad económica y disminuyendo el impacto ambiental. En este sentido, la AP tiene un atractivo indudable. Pocos se opondrían a una filosofía de manejo que trata de engarzar los insumos aportados con las necesidades exactas. Además, esta filosofía se ajusta perfectamente a los principios científicos de la agricultura sostenible y de la gestión integrada de suelos, cultivos y plagas.

La práctica comercial de la AP está todavía en sus inicios. La liberalización de la señal de los GPS en los Estados Unidos en la década de los 80 permitió a muchos agricultores de este país poner en práctica este nuevo concepto de agricultura. Hoy en día, el uso de monitores de rendimiento en las cosechadoras es de un 30% en maíz, un 25% en soja y un 10% en trigo. El uso de mapas de suelos georeferenciados está entre un 11% y un 22% mientras que el uso de mapas obtenidos por teledetección está entre

un 3 y un 6% (Daberkow y col., 2002). En otros países, como Canadá, Australia, Argentina y Brasil, su uso está también relativamente extendido. En Europa la tasa de utilización de estas tecnologías es bastante menor, destacando Alemania, Dinamarca y el Reino Unido. En Alemania, encuestas recientes indican que el usuario habitual de la AP gestiona explotaciones grandes, con un tamaño medio de algo más de 1.000 ha. Sin embargo, el usuario potencial tiene un tamaño medio de explotación de 350 ha (Gumpertsberger y Jurgens, 2003).

Diversos estudios ponen de manifiesto que, si bien estas técnicas son aún caras, las ventajas que supone su utilización son muchas destacando principalmente la optimización de insumos (semillas, fertilizantes, herbicidas) (Godwin y col., 2001). Esto redundaría en un incremento en la rentabilidad de las explotaciones y en una minimización de la contaminación de suelos y aguas por productos agroquímicos (Pierce y Nowak, 1999). Estudios realizados dentro de nuestro país con cultivos de cereales muestran cómo es posible mejorar la rentabilidad de la producción y, a la vez, reducir substancialmente el uso de plaguicidas mediante el empleo de sistemas de tratamientos localizados con herbicidas (Barroso y col., 2004b). Por otro lado, la utilización de estas técnicas permitiría obtener información exacta y en tiempo real a agricultores, cooperativas, mercados y administración sobre las superficies sembradas con cada cultivo, la cantidad de productos aplicados, las producciones obtenidas, etc., convirtiéndolas en una herramienta de gestión rápida, eficaz y de gran utilidad.

Dentro de la agricultura de precisión destaca por su importancia el tratamiento de las malas hierbas en campos de cultivo (BurgosArtizzu, 2007). Las malas hierbas se caracterizan porque originan importantes pérdidas en las producciones agrícolas. Por mencionar un ejemplo, existen estudios concretos realizados por Barroso y col. (2005) que han cuantificado las pérdidas en cultivos de cereal por la existencia de una especie de mala hierba conocida como *Avena sterilis*, vulgarmente *Avena loca*. Estas pérdidas llegan a ser del 15% un determinado año, así como en los dos o tres sucesivos. Si no

son convenientemente tratadas con el fin de ser eliminadas dado su carácter agresivo y prolífico, las mismas se extenderán por todo el campo produciendo una alta invasión.

Una característica importante que manifiesta este y otro tipo de malas hierbas es su localización espacial en forma de rodales, que de no ser tratados se extenderán indiscriminadamente por el campo de cultivo. En la figura 1-1 se muestran dos ejemplos de rodales. En (a) un rodal en un campo de cereal y en (b) en un campo de maíz. En esta segunda imagen se aprecia mejor la presencia del rodal en una zona perfectamente localizada y su ausencia en el resto del campo.



(a)



(b)

Figura 1-1: Imágenes de campos de cultivo: (a) cereal de invierno (cebada) y (b) maíz.

Tradicionalmente, la forma más habitual de pulverización mediante herbicida de los campos de cultivo consiste en aplicar herbicida como si la distribución de las malas hierbas fuera homogénea, es decir no selectiva, en el sentido de que el herbicida se aplica sobre el campo completo sin tener en cuenta la existencia de los mencionados rodales y además con dosis constantes independientemente de que haya o no malas hierbas (Baron, 2005). En la figura 1-2 se muestra una imagen de esta operación de pulverización no controlada sobre un campo de maíz.



Figura 1-2: Pulverización de herbicida de forma generalizada.

Como puede apreciarse el herbicida se aplica sobre toda la superficie aunque realmente sólo afectará a aquellas especies de malas hierbas sobre las que caiga directamente. Inmediatamente se puede deducir, por lo expuesto hasta el momento, que si se aplicara de forma selectiva exactamente sobre las zonas donde realmente existan malas hierbas se obtendrían dos beneficios nada despreciables:

1. Evitar la contaminación excesiva de las tierras tratadas y por consiguiente disminuir el riesgo de contaminación medioambiental directa o por filtración hacia las capas freáticas de aguas subterráneas.
2. Ahorrar costes en el tratamiento de los cultivos.

Estos son dos aspectos importantes que motivan el desarrollo de tecnologías en el ámbito de la agricultura de precisión para este tipo de tratamientos localizados. Bien es cierto que la aplicación selectiva podría llevarse a cabo mediante técnicas de exploración manual de los campos de cultivo para localizar y determinar por simple inspección visual si una determinada zona debe o no pulverizarse. Sin embargo debido a la naturaleza de las malas hierbas en el sentido de que muchas veces llegan a confundirse y enmascararse con el cultivo, unido al hecho de que normalmente la extensión de los campos ocupa varias hectáreas, esta técnica manual puede conducir a la fatiga de la persona o personas encargadas de llevar a cabo esta tarea. Por tanto, las posibilidades de desarrollo de un sistema automático de detección para evitar estos

problemas, junto con los dos beneficios anteriormente expuestos motivan suficientemente el planteamiento de la investigación llevada a cabo.

Aunque el sector privado ha sido el principal motor en el lanzamiento de estas nuevas tecnologías, es necesario el apoyo de la investigación pública para poder superar los escollos todavía presentes en su desarrollo. En este sentido es de destacar que los conocimientos básicos sobre la ecología espacial y temporal de las poblaciones de malas hierbas (imprescindibles para la toma de decisiones por parte del agricultor) son todavía muy escasos. Asimismo, se requieren mejores técnicas de detección de rodales de malas hierbas, tanto para las especies individuales como para el conjunto de las malas hierbas. Y, finalmente, se requieren unos procedimientos de actuación y unas tecnologías que permitan aplicar el producto adecuado en el lugar y el momento precisos.

Uno de los retos que actualmente tiene planteados la AP se centra en el tratamiento de las malas hierbas donde se aúnan los esfuerzos provenientes de la ecología y la propia agricultura. Los técnicos agrícolas tratan de eliminar mediante el uso de productos agroquímicos (herbicidas) las malas hierbas en aras del incremento de la producción agrícola. Como es bien sabido, dichos productos resultan ser altamente contaminantes por lo que desde el punto de vista ecológico su uso es desaconsejable. Es más, determinadas políticas agrarias subvencionan las producciones ecológicas. Lo anterior unido al elevado coste económico del herbicida aplicado, hace que el interés por conseguir una reducción en la cantidad aplicada manteniendo a la vez la producción agrícola constituya uno de los objetivos de la agricultura de precisión en este tipo de tratamientos. Este interés se ha visto últimamente incrementado por el también creciente interés industrial en la producción de biocombustibles. Conviene destacar que si la utilización de los biocombustibles pretende como uno de sus objetivos la disminución del efecto contaminante medioambiental, la producción de la materia prima agrícola no debería generar otros tipos de contaminación con efectos altamente nocivos y adicionalmente encarecer el biocarburante.

El trabajo de investigación que se presenta se centra precisamente en determinar, mediante técnicas basadas en visión por computador, las localizaciones espaciales de malas hierbas en los campos de cultivo con el fin de aplicar un tratamiento selectivo. Con ello se pretende conseguir los objetivos ya mencionados, sintetizados como sigue:

1. Disminuir la contaminación medioambiental.
2. Disminuir costes de producción agrícola.
3. Mantener el rendimiento de las producciones agrícolas.

1.1.2. *Ecología espacio-temporal*

El estudio de las zonas de agregación de malas hierbas y de los procesos relevantes a nivel rodal es un área emergente dentro de la malherbología. La cuantificación de los numerosos factores que componen la heterogeneidad ambiental de una zona, el establecimiento de relaciones entre dichos factores y los niveles poblacionales y el estudio de la estabilidad temporal de los rodales presentan problemas experimentales importantes. El empleo de los métodos clásicos utilizados en ecología vegetal en combinación con el uso de sistemas GPS y SIG (Sistemas de Información Geográfica) ofrece una poderosa herramienta para comprender mejor la presencia y dinámica espacio-temporal de los rodales.

La comprensión de los factores que dan origen a la presencia de rodales podría facilitar el manejo de dichas zonas y de todo el campo en general. Trabajos realizados en cultivos de maíz y soja en la zona central de los EEUU muestran la elevada asociación entre el relieve del terreno y algunas propiedades del suelo (materia orgánica, fertilidad) con la presencia y abundancia de diversas malas hierbas (Dieleman y col., 2000). Basándose en los resultados obtenidos, Dieleman y sus colaboradores concluyen que dichas asociaciones son debidas a la interacción de las prácticas agronómicas (labores, tratamientos herbicidas) con las propiedades de cada zona, creando una

heterogeneidad de humedad y fertilidad de suelo y de concentración de herbicida que, en último término, condiciona el crecimiento, reproducción y capacidad competitiva tanto del cultivo como de la mala hierba. El estudio de estas interacciones es complejo y requiere una consideración específica de cada caso (suelo/cultivo/mala hierba).

Si bien los aspectos espaciales son los que han recibido una mayor atención, no podemos olvidarnos de su interacción con los aspectos temporales. Por un lado, es de una gran relevancia el estudio del desarrollo temporal de las infestaciones a diferentes escalas espaciales: parcela, explotación, comarca, región. Ello facilitaría la planificación de los tratamientos y su realización en el lugar y momento más adecuado. La construcción de mapas predictivos de las infestaciones a estas escalas es una nueva vía muy prometedora que ya ha dado sus primeros resultados (Main y col., 2004). Por otro lado, el estudio de la estabilidad temporal de los rodales de malas hierbas tiene un elevado interés de cara a determinar su evolución en el tiempo y las implicaciones de manejo a largo plazo. Diversos autores han estudiado la dinámica espacio-temporal de los rodales de distintas especies de malas hierbas. Las principales conclusiones obtenidas fueron que los rodales de determinadas especies de malas hierbas eran estables (Webster y col., 2000), mientras que otras especies, en concreto *Avena fatua*, no parecen presentar estabilidad en el tiempo (Perry y Lutman, 2000).

Durante los últimos años, diversos proyectos de investigación llevados a cabo por varios grupos de investigadores españoles han permitido avanzar considerablemente en los conocimientos ecológicos necesarios para poder manejar las malas hierbas dentro de sistemas de AP. Estudios realizados en Andalucía por el equipo del Instituto de Agricultura Sostenible dentro del Consejo Superior de Investigaciones Científicas (CSIC) han permitido modelizar espacialmente la nascencia de las principales malas hierbas en cultivos de girasol, establecer la estabilidad temporal de los rodales de esta especie y su tasa de crecimiento interanual y poner a punto la metodología para establecer mapas predictivos de malas hierbas incorporando diversas variables secundarias (López-Granados y col., 2005; Jurado-Expósito y col., 2003b; Jurado-Expósito y col. 2004). Los

estudios en colaboración llevados a cabo en Castilla por los equipos del Centro de Ciencias Medioambientales y del Instituto de Automática Industrial en el CSIC han permitido caracterizar la heterogeneidad espacial de las poblaciones de *Avena sterilis* en función de parámetros del suelo (Díaz y col., 2003; Díaz y col., 2005) y de documentar la estabilidad temporal en la posición de los rodales de esta especie (Barroso y col., 2004a). Asimismo, se ha establecido el desplazamiento de la posición de los rodales de esta especie causado por las labores del terreno y por el pase de las cosechadoras y se han podido establecer las relaciones existentes entre la posición de los principales rodales de *A. sterilis* y algunos parámetros del medio. En Cataluña, los trabajos llevados a cabo por la Universidad de Barcelona y la Universidad Politécnica de Cataluña han permitido caracterizar la distribución espacial de *Lolium rigidum* y su relación con el desplazamiento de las cosechadoras (Blanco-Moreno y col., 2004).

1.1.3. Detección de malas hierbas

La implementación práctica de la AP en el ámbito del manejo de malas hierbas depende totalmente de la disponibilidad de sistemas automáticos de detección de la abundancia de las malas hierbas infestantes. Existen diversas opciones para llevar a cabo dicha detección: evaluación visual asistida por GPS desde un vehículo en marcha (Van Wychen y col., 2002), detección terrestre utilizando análisis de imagen biespectral (Gerhards y Christensen, 2003), análisis de imágenes digitales para la construcción de mapas de infestación (Yang y col., 2003a,b), detección aérea utilizando imágenes multiespectrales (Chang y col., 2004; Gibson y col. 2004; Koger y col., 2004). Cada uno de estos métodos tiene sus ventajas e inconvenientes, siendo necesario determinar cuál es el que mejor se ajusta al problema en cuestión.

Se entiende como teledetección en su sentido más amplio el uso de sensores situados en plataformas terrestres, aéreas o satelitales para medir la reflexión o emisión de la radiación electromagnética a partir de un objeto de interés (Thorp y Tian, 2004). Aunque el uso de estas técnicas dentro de la agricultura se inició en la década de los 60 del pasado siglo, su utilización para la detección de malas hierbas no se llevó a cabo

hasta los años 80. Los primeros experimentos realizados con sensores aerotransportados en condiciones muy controladas mostraron la posibilidad del empleo de la teledetección para discriminar parcelas homogéneas sembradas con cultivos o con malas hierbas (Menges y col., 1985). Sin embargo, el empleo de la teledetección para la detección de malas hierbas, creciendo naturalmente entre los cultivos, ha demostrado ser una tarea bastante más complicada. La mayoría de los investigadores han usado diversos algoritmos de clasificación para delinear los rodales de malas hierbas basándose en la variabilidad en las respuestas espectrales del suelo, cultivo y combinaciones cultivo/mala hierba. Los algoritmos de clasificación funcionan bien para la detección de las malas hierbas en pre-emergencia del cultivo (antes de su nacimiento) ya que la respuesta espectral del suelo desnudo es generalmente separable de la respuesta de las malas hierbas (Lamb y Weedon, 1998). Sin embargo, una vez que ha nacido el cultivo, la capacidad de los algoritmos de clasificación para detectar las malas hierbas se reduce notablemente ya que ambos tipos de plantas muestran características espectrales similares (Lamb, Brown, 2001). Los efectos asociados a la presencia de suelo suponen un problema adicional en la detección de malas hierbas dado que la interacción entre la reflectividad procedente de la cubierta vegetal y el suelo de fondo altera la respuesta espectral captada por el sensor cuando el porcentaje de cobertura vegetal es bajo o intermedio (Huete y col., 1985). Desgraciadamente, este es precisamente el período en el cual la teledetección debe ser empleada para generar mapas de malas hierbas que puedan ser usados directamente para la realización de tratamientos herbicidas en post-emergencia. Una posible estrategia para evitar este problema es emplear la teledetección para cartografiar las malas hierbas al final del ciclo del cultivo, cuando el porcentaje de cobertura vegetal es muy alto y no existe interferencia de la señal procedente del suelo. Además, es en este momento cuando las malas hierbas en estado de floración/fructificación suelen presentar una respuesta espectral más diferenciada del cultivo. Los mapas de malas hierbas generados en esta fase de crecimiento de la plantación se podrán utilizar en tratamientos de años posteriores siempre que se confirme la estabilidad espacial de los rodales detectados y

se definan algoritmos de ajuste que permitan predecir la distribución espacial de los rodales en años sucesivos.

Las investigaciones llevadas a cabo en los últimos años en teledetección remota en malherbología han utilizado sensores a bordo de dirigibles, aeronaves a radio-control, aviones y satélites. Las recientes mejoras producidas en las tecnologías de los sensores (mayor resolución espacial y espectral) han aumentado el potencial para una delineación precisa de las zonas infestadas de malas hierbas. Inicialmente, la investigación enfocada a la detección de malas hierbas se llevaba a cabo con fotografía en color y equipos de video analógicos (Menges y col., 1985). Hoy en día la toma de datos se realiza habitualmente mediante tecnologías digitales (Lamb y Weedon, 1998; Thorp y Tian, 2004). Asimismo, con la introducción de sistemas de adquisición de imágenes hiperespectrales que proporcionan información en un espectro casi continuo, la discriminación espectral entre cultivos y malas hierbas se puede realizar de una forma mucho más precisa (Thorp y Tian, 2004), pues este tipo de imágenes ofrece una detallada identificación de cada cubierta lo que permite introducir tratamientos específicos que no serían abordables con las imágenes multiespectrales convencionales.

La detección de malas hierbas utilizando imágenes obtenidas desde plataformas aéreas o desde satélites presenta problemas debido a las complejas interacciones entre los espectros del cultivo, las malas hierbas y el suelo y al hecho de que dicha adquisición es difícilmente controlable por el usuario (habitualmente las imágenes de satélite deben contratarse con bastante antelación, siendo posible que en el momento en el que se tome la imagen no sea el más adecuado). Por esta razón, la línea de investigación de esta tesis se ha centrado en el uso de sensores colocados en plataformas terrestres.

Inicialmente, la discriminación entre suelo y vegetación se llevó a cabo utilizando fotodetectores que miden electrónicamente la radiación visible y la del infrarrojo cercano, calculando un índice para la estimación de la cobertura vegetal en un área determinada (Shearer y Jones, 1991). Estos sensores consiguieron detectar con éxito las zonas

infestadas con malas hierbas dentro de un cultivo de soja, permitiendo la realización de un tratamiento localizado con herbicida en dichas zonas. Debido a su gran simplicidad, los sensores fotoeléctricos se han incorporado ya a varios sistemas de aplicación diferencial o selectiva de herbicidas. Sin embargo, su uso está limitado a la detección de infestaciones bastante abundantes presentes en el medio de los surcos del cultivo, siendo incapaces de discriminar entre cultivos y malas hierbas. Por ello, la investigación en este ámbito se ha dirigido hacia el uso de tecnologías de visión artificial. En este caso, las imágenes son recogidas con sistemas de cámaras terrestres, utilizando posteriormente rutinas de procesamiento que permiten segmentar las imágenes diferenciando la vegetación del suelo y delinear las malas hierbas y el cultivo basándose en su color, forma, textura o posición en el terreno (Gerhards y Christensen, 2003; Tian, 2002; Yang y col. 2003a,b; García-Pérez y col., 2000; Ribeiro y col. 2005). Aunque el costo de estos sistemas es relativamente mayor que el de los fotodetectores, su potencial para la aplicación localizada de herbicidas en tiempo real ya ha sido mostrada por varios investigadores (Gerhards y Christensen, 2003; Tian 2002).

Las investigaciones previas llevadas a cabo en el ámbito de la teledetección han permitido caracterizar espectralmente diversos cultivos de cereales y malas hierbas gramíneas acompañantes (Martin y col., 2005), las malas hierbas dicotiledóneas dominantes del cultivo de girasol (Atenciano y col., 2001; Jurado-Expósito y col. 2003a, 2003b) y las cubiertas vegetales en olivar (Peña-Barragán y col., 2004).

En lo relativo a la evaluación desde plataformas terrestres, se ha desarrollado y puesto a punto, utilizando como base diferentes herramientas desarrolladas para la recogida de información georeferenciada (Ribeiro y col., 2001), un procedimiento para la construcción de mapas de infestación de *Avena sterilis* a partir de las estimaciones realizadas por un evaluador desde la cabina de la cosechadora (Barroso y col., 2005). Asimismo, se ha desarrollado un sistema automático de adquisición desde la cosechadora de videos georeferenciados de zonas del cultivo siguiendo un plan de muestreo previamente definido (Ribeiro y col., 2003). Las imágenes así obtenidas podrán

ser evaluadas posteriormente por el técnico o agricultor de un modo similar a la evaluación que éste realiza desde la cabina de la cosechadora, pero evitando el estrés visual que esta operación produce, la tendencia a la saturación en percepción que hace, por ejemplo, que situaciones que inicialmente se valoraron con un alto nivel de infestación se valoren posteriormente con nivel inferior si el campo está muy infestado. Conviene resaltar que el sistema, en contraposición con la evaluación desde cabina, no requiere en la cosechadora personal adicional al conductor. En otras investigaciones se ha desarrollado un sistema de visión artificial que ayuda al usuario a la determinación del índice de infestación para una imagen de entrada (Ribeiro y col. 2005). El sistema utiliza la combinación de planos de color y una propiedad estructural como medio para discriminar entre mala hierba, suelo y cultivo.

La revisión bibliográfica realizada muestra numerosos ejemplos de detección de malas hierbas con diferentes sensores y desde diversas plataformas. Cada tipo de sistema tiene sus propias ventajas y limitaciones, siendo necesaria más investigación para definir cuál será la dirección que tomará finalmente la detección de malas hierbas en el futuro (Moran y col., 1997; Radhakrishnan y col., 2002; Thorp y Tian, 2004).

En la figura 1-3 se muestra un sistema experimental de esta naturaleza donde se han instalado sendas cámaras en dos posiciones distintas del tractor con el fin de analizar la calidad de las imágenes obtenidas.



Figura 1-3: Sistema experimental de cámaras con proyección de perspectiva.

En ambos casos la proyección de captura de las imágenes es la de perspectiva donde el eje óptico de la cámara forma un ángulo de entre 30° a 45° con respecto a un eje horizontal imaginario. En esto se diferencia de otras aplicaciones que utilizan también proyección de perspectiva con el eje óptico perpendicular al suelo y la cámara situada a una altura de entre 1 y 2 metros como se muestra en la figura 1-4(a).

1.1.4. Actuación

Como se ha visto previamente, numerosas investigaciones se han centrado en el desarrollo de técnicas de detección de malas hierbas. En contraste, sólo un número muy reducido de trabajos se han ocupado de la utilización de esos datos en aplicaciones localizadas con herbicidas (Tian y col. 1999). Quizás, al tratar de llevar a un nivel superior las técnicas actuales de detección se consiga identificar los atributos más críticos de una estrategia de detección/actuación sobre las malas hierbas. O quizás se puedan obviar algunos de los problemas más difíciles de la detección. En la actualidad es posible generar mapas de infestación de malas hierbas sobre la base de datos espectrales, de densidad o de cobertura. Sin embargo, no existen métodos automáticos

contrastados para asignar dosis de herbicidas en función de los parámetros disponibles. En uno de los pocos casos en los que este paso ha sido dado, Yang y col. (2003a,b) desarrollaron un mapa de aplicación de herbicidas para un cultivo de maíz utilizando técnicas de redes neuronales artificiales (ANN) y de lógica difusa. Sin embargo, muchos de los parámetros utilizados en estas técnicas fueron definidos arbitrariamente. Se requieren estudios experimentales que permitan cuantificar dichos parámetros para un caso concreto. Asimismo, en el futuro será necesario realizar un mayor esfuerzo en investigación con objeto de determinar la dosis de herbicida óptima para diferentes coberturas de mala hierba.

La fusión bien ponderada de los conocimientos de ingeniería y economía agrícola, conocimientos ecológicos sobre el comportamiento de malas hierbas y la experiencia en la aplicación de agroquímicos será una cuestión de especial importancia si se quiere realmente lograr una aplicación localizada de herbicidas con ciertas garantías de éxito y con el mínimo impacto ambiental.

Uno de los objetivos principales de esta tesis es contribuir en el esfuerzo de reducción de los productos contaminantes del medio ambiente en el área agrícola.

Actualmente, existe una clara tendencia hacia la reducción de la utilización de agentes químicos en los cultivos agrícolas con el fin de reducir su efecto contaminante. Los principales objetivos de las técnicas desarrolladas con tal propósito deben garantizar la eficacia que de ellas se espera. Simultáneamente a la reducción del efecto contaminante se desea obtener productos agrícolas de mejor calidad con el consiguiente ahorro económico. Esta tendencia ha sido establecida entre varios países, creando un interés creciente (Cloutier y Ascard, 2004).

El desarrollo de las tecnologías de la información, tanto desde el punto de vista Hardware como Software, contribuye enormemente a la consecución de las metas anteriormente citadas.

1.2. Resumen de los métodos investigados

La revisión de los métodos expuestos sugiere lo siguiente:

1. La aplicación selectiva de herbicida para la pulverización y el tratamiento de malas hierbas es posible, permitiendo importantes reducciones de costos y disminución de la contaminación medioambiental.
2. Es deseable un método automático de detección de malas hierbas.
3. Un sistema de visión basado en la discriminación espectral permite distinguir las plantas, que manifiestan propiedades de reflectancia muy diferentes a otro tipo de materiales (suelo, piedras, residuos orgánicos, etc.).
4. Mediante proyección de perspectiva en la imagen es posible tener una idea global de la escena y la distribución de rodales o plantas aisladas de malas hierbas en ésta y por tanto en la imagen.
5. Es posible determinar la cantidad relativa de biomasa (plantas) en relación a la superficie de cultivo.
6. La presencia de zonas con propiedades reflectantes de biomasa (tonalidad espectral del verde) entre los surcos indican la posible presencia de malas hierbas ya que no podría ser cultivo debido a que éstos solamente nacen a lo largo de los surcos.
7. La utilización de mapas de distribución de malas hierbas a partir de datos previamente recopilados procedentes de años anteriores así como de las características del suelo (tipo de suelo, propiedades químicas, precipitaciones a lo largo del año, etc.) pueden ayudar a la evaluación del sistema automático por comparación de los criterios de los expertos frente a los sistemas automáticos.

1.3. Problemática

El desarrollo de las posibilidades de las técnicas basadas en visión artificial, permite actualmente la identificación rápida y fiable de las malas hierbas presentes en los campos de cultivo. Los sistemas automáticos desarrollados hasta ahora permiten

utilizar técnicas para procesar fácilmente los campos de cultivo y así obtener los datos necesarios para clasificar y distinguir las malas hierbas del cultivo.

El desarrollo de estos sistemas hasta ahora ha estado basado en la computación de las características geométricas de las malas hierbas porque éstas tienen formas (factor de forma, ratio de longitud, razón de aspecto, etc) que pueden ser identificadas (Pérez y col., 2000; Aitkenhead y col. 2003; Granitto y col., 2005; Onyango y Marchant, 2003). En otras aproximaciones las imágenes en color han sido utilizadas con éxito para establecer la calidad del cultivo y caracterizar daños o enfermedades en ellos (Sogaard y Olsen, 2003; Yang y col., 2003a) estimaron forma y cantidad de mala hierba en cultivos basándose en imágenes digitales, utilizando un algoritmo *fuzzy* para planificar una pulverización selectiva. Recientemente Gerhards y Oebel (2006) han usado imágenes diferenciales en tiempo real utilizando las bandas del infrarrojo cercano y visible (NIR-VIS) obtenidas a partir de 3 cámaras bi-espectrales. Otras aproximaciones han utilizado índices de color para distinguir la vegetación del fondo (Thorp y Tian, 2004; Tian y col. 1999; Ribeiro y col. 2005).

Bacher (2001) estimó la densidad de malas hierbas en un campo de cereal (cebada de invierno) mediante técnicas de binarización y morfológicas, identificando posteriormente los surcos del cultivo utilizando información de las distancias existentes entre los surcos para decidir sobre la aplicación del herbicida en función de las distancias encontradas.

Centrándonos específicamente en los campos de cultivo de cereal y maíz objeto de la presente investigación y las malas hierbas que sobre ellos aparecen para ser tratadas, es preciso añadir que las mismas se presentan sin formas geométricas definidas y por tanto carentes de propiedades que las definan en este sentido. En ambos tipos de cultivos, las malas hierbas en el estado de crecimiento en el que se encuentran en el momento de la aplicación del herbicida para su tratamiento presentan la siguiente problemática común:

1. Poseen una firma espectral similar a la de los propios cultivos, es decir, son indistinguibles del cultivo desde el punto de vista del color.
2. Nacen y crecen sin ningún tipo de control en el campo, mezclándose con los cultivos dentro de los surcos y también fuera de ellos.
3. Carecen de formas geométricas definidas.
4. Su distribución en el campo es totalmente irregular y anárquica, pudiendo aparecer plantas de malas hierbas aisladas o en agrupaciones diversas. Cuando se agrupan lo hacen también de forma irregular, así se presentan bajo pequeñas agrupaciones aisladas unas de otras con un número de plantas variable y relativamente pequeño o en grandes agrupaciones (rodales) donde la densidad de plantas es muy elevada.

En el caso concreto de los campos de cereal y particularmente en cultivos de cebada de invierno crece una variedad de mala hierba conocida científicamente como *Avena Sterilis*, L. (vulgarmente avena loca). A la problemática anteriormente expuesta concretada en los cuatro puntos anteriores, se añade el hecho de que en esta variedad también la textura en el momento del tratamiento se hace indistinguible de la textura que presenta el cereal. Sólo experimentados profesionales (agricultores y técnicos agrícolas) la distinguen visualmente sobre el campo donde se encuentra.

Debido a la problemática expuesta anteriormente, las técnicas automáticas de detección de malas hierbas estudiadas hasta el momento y para los campos de cultivo objeto de esta investigación no son aplicables. Se hace necesario el desarrollo de un método automático capaz de abordar la problemática mencionada con el fin de ofrecer una solución. Esto origina el trabajo de investigación que se presenta, cuyo origen se sitúa en el IAI del CSIC donde se inician los trabajos con imágenes del tipo mostrado en la figura 1-4(a) y con la misma finalidad bajo la cobertura del proyecto de investigación en el ámbito del I+D+i (Ribeiro, 2005). No obstante, como consecuencia de algunas ventajas proporcionadas por las imágenes del tipo mostrado en la figura 1-4(b), que después se

analizarán, las investigaciones de este trabajo se realizan con este último tipo de imágenes.

Los desarrollos realizados hasta el momento examinan una zona muy localizada del campo de cultivo (Ribeiro y col., 2005; BurgosArtizzu, 2007a,b), generalmente desde una perspectiva ortogonal, abarcando áreas pequeñas. No obstante, dado que el sistema de visión utilizado en estas experiencias se acopla sobre un tractor, figura 1-3, que en el futuro se pretende sea robotizado y automático, las imágenes se toman con proyección de perspectiva. En el momento de la elaboración de esta Tesis, se están realizando diversos experimentos para la localización de las cámaras en la parte delantera como se aprecia en la mencionada figura, así como desde la propia cabina del conductor. La mayoría de las imágenes utilizadas en los experimentos de esta Tesis han sido tomadas con la cámara inferior, por la sencilla razón de que la inestabilidad del sistema debido al movimiento del tractor es inferior que para el caso de la cámara situada en la parte superior. No obstante, en todos los casos la proyección es de perspectiva. Por tanto, muchas aplicaciones de extracción de malas hierbas referenciadas previamente tampoco son aplicables en imágenes con este tipo de proyección.

Algunas aplicaciones basadas en visión por computador (Ribeiro, 2005; BurgosArtizzu, 2007) obtienen las imágenes enfocando al objetivo con el eje óptico perpendicular al suelo, figura 1-4(a). Como se ha explicado previamente las malas hierbas crecen sin control en zonas relativamente extensas, este es el caso de la *Avena Sterilis*. Bajo esta consideración hemos creído conveniente que el área de zona de cultivo a procesar podría ser mucho más amplia que la proporcionada por la toma de imágenes con el eje óptico perpendicular. En definitiva, la idea se basa en la necesidad de procesar zonas amplias y establecer criterios globales de identificación de áreas de malas hierbas para ser pulverizadas. Por ello, se ha optado por obtener una imagen en perspectiva del campo de cultivo a analizar, donde a medida que las líneas de cultivo se alejan convergen en un punto imaginario conocido como punto de fuga. Este es el caso

de la imagen mostrada en la figura 1-4(b). Podríamos hacer una distinción entre ambos tipos de imágenes, en el sentido de que las primeras se fundamentan en la identificación local de las malas hierbas, mientras que las segundas tienen en cuenta una perspectiva menos localizada para llegar a ser global.

Conviene resaltar el hecho de que en la actualidad se están desarrollando sistemas de detección locales denominados “Weed seeker” basados en la detección de la reflectancia espectral de plantas con clorofila, de este modo sólo se aplicaría herbicida en aquellas zonas donde existen plantas, evitando la pulverización en zonas con ausencia de vegetación (Stone y col.. 2004). Algunas experiencias con estos sistemas se han llevado a cabo en el tratamiento de malas hierbas en plantaciones arbóreas donde sólo se requiere eliminar las malas hierbas del suelo sin necesidad de detectar la clorofila del material vegetal de los árboles. McCloskey y col. (2007) han experimentado con estos dispositivos para pulverización de las malas hierbas que crecen en el suelo en campos de cítricos de Arizona. En este caso, las malas hierbas no están mezcladas con los cultivos arbóreos y por tanto la problemática resulta muy diferente.



Figura 1-4: Vista de dos imágenes con proyección de perspectiva; (a) eje óptico perpendicular al suelo (b) eje óptico formando un ángulo de unos 40° con respecto al suelo.

1.4. Motivación y objetivos de investigación

El trabajo de investigación objeto de esta tesis se enmarca dentro de una colaboración de investigación con el IAI del CSIC, en el área agrícola para la pulverización selectiva de malas hierbas en campos de cultivo. Se trata de un proyecto coordinado por el Instituto de Ciencias Medioambientales del CSIC con la participación del IAI junto con varios centros universitarios. Dentro de estos últimos se encuentra la Universidad Complutense que participa mediante convenio marco de colaboración con el CSIC y donde se encuadra la investigación que se presenta dentro del programa de doctorado interuniversitario denominado Ingeniería de Sistemas y Automática entre la UNED y la UCM.

Dicha colaboración se ha materializado en el proyecto del Plan Nacional de I+D+i del Ministerio de Educación y Ciencia para el trienio 2005-2008 (Ribeiro, 2005)

1.4.1. Objetivos Generales

La Agricultura de Precisión ofrece un enorme potencial de cara a la optimización de los medios de producción. En el ámbito concreto del manejo de malas hierbas, el uso de estas técnicas puede permitir un menor uso de fitosanitarios, con los consiguientes beneficios económicos y ambientales. Aunque ya existe una base general de conocimientos y, sobre todo, un rico arsenal de tecnologías disponibles, para poder implantar estas técnicas en España se necesita, por un lado, superar algunos escollos aun existentes en esta materia (principalmente en lo referente a conocimientos de base y a técnicas de detección) y por otro lado, adaptar los sistemas desarrollados al caso concreto y las características particulares de los cultivos realizados. En base a estas necesidades, en la presente tesis se establecen los objetivos principales siguientes:

1. Automatizar la detección de malas hierbas en cultivos agrícolas de cereal y maíz mediante el empleo de técnicas de visión artificial.

2. Diseñar un sistema experto automático de decisión para determinar zonas de posible pulverización en función de la existencia de malas hierbas.
3. Proporcionar unos procedimientos generales para su aplicación a otros campos de cultivo con distribuciones de cultivo similares (surcos espaciados).

1.4.2. Objetivos específicos

En relación a los objetivos específicos se distinguen dos tipos. El primero hace referencia a la necesidad de identificar la forma en la que las malas hierbas se distribuyen espacialmente en los campos de cultivo junto con sus formas de aparición. El segundo se refiere a la detección de las malas hierbas en su localización espacial y a la toma de decisión sobre su pulverización en caso necesario.

1.4.2.1 Localización y distribución espacial de las malas hierbas

1. Establecer e identificar los patrones típicos de malas hierbas que pueden aparecer en los campos de cultivo objeto de estudio.
2. Determinar la distribución espacial de malas hierbas y su repercusión en los procesos de detección y decisión posteriores.
3. Extraer conocimiento espacio-temporal. Establecimiento de reglas sobre el comportamiento ecológico de las malas hierbas para poder predecir la distribución espacial y temporal de las malas hierbas en el momento de aplicación del herbicida cuando las características espectrales y de textura de las malas hierbas y los cultivos sean indistinguibles.

1.4.2.2 Detección y decisión

1. Desarrollar una metodología precisa para la detección de zonas de malas hierbas dentro de los campos de cultivo mediante técnicas de segmentación de imágenes.
2. Aplicar algoritmos de aprendizaje y clasificación, procedentes del área de reconocimiento de patrones, para tomar una decisión sobre si la zona analizada debe ser o no pulverizada con herbicida y en qué cantidad según su grado de infestación. Estos algoritmos se analizarán de forma individual y combinada. La combinación de clasificadores se conoce como hibridación.
3. Analizar técnicas propias de la denominada teoría de la decisión.

1.5. Aportaciones realizadas en la investigación

En cualquiera de los métodos existentes en la literatura basados en técnicas automáticas de visión por computador, referenciados previamente, el objetivo consiste en identificar las zonas infestadas de malas hierbas para proceder a su pulverización en caso necesario. Como ya se ha mencionado previamente, éste es también el objetivo de la presente investigación si bien desde la particularidad derivada de la problemática expuesta anteriormente. En este sentido, son dos los procesos que se distinguen: segmentación y decisión. Las aportaciones realizadas en cada uno de ellos se sintetizan a continuación.

1.5.1. Segmentación

La segmentación tiene como finalidad el aislamiento de las malas hierbas respecto de lo que representa la parte de cultivo y de suelo sin vegetación. El proceso de segmentación propuesto contempla los siguientes pasos:

1. Binarización de la imagen original para separar la parte vegetal (plantas de cultivo y malas hierbas) de la no vegetal (suelo).

2. Tratamiento de la imagen binarizada mediante técnicas morfológicas con el fin de eliminar mínimas agrupaciones de píxeles que representan vegetación y que desde el punto de vista de su posterior tratamiento son irrelevantes. También se incluyen en este proceso operaciones relativas al suavizado de bordes de las regiones binarizadas, así como el rellenado de pequeños huecos.
3. Partición de la imagen en unidades de tratamiento elementales (celdas) sobre las que se tomarán las decisiones propiamente dichas.

1.5.2. Decisión

La decisión consiste en determinar para cada celda, proporcionada por el proceso de segmentación, si debe o no ser pulverizada mediante el herbicida y en su caso la cantidad más conveniente a aplicar.

El proceso de decisión propuesto consta de los siguientes pasos:

1. Entrenamiento del sistema mediante celdas patrón, que constituyen sendos conjuntos de celdas de entrenamiento para ser pulverizadas o no.
2. Obtención de las propiedades o características que describen y caracterizan las celdas.
3. Selección y estudio de diferentes métodos de decisión.
4. Máquinas de vectores soporte o "Support Vector Machines".
5. Métodos de naturaleza estadística: estimación paramétrica de Bayes y estimación no paramétrica como la ventana de Parzen.
6. Agrupamiento borroso o "*Fuzzy Clustering*".
7. Clasificación aplicando técnicas basadas en el aprendizaje Hebbiano.
8. Toma de decisiones multicriterio o "Multicriteria Decision Making (MCDM)".
9. Aprendizaje de los parámetros involucrados en cada uno de los métodos de decisión anteriores.

10. Combinación de métodos para diseñar estrategias combinadas (híbridas).
11. Decisión propiamente dicha según las funciones estimadas, los parámetros aprendidos o los criterios establecidos.

1.6. Investigación previa

Esta tesis se basa en la investigación teórico-práctica llevada a cabo previamente y materializada en seis publicaciones internacionales, todas ellas sometidas al correspondiente proceso de revisión por pares. La tesis recoge los trabajos allí publicados, estableciendo un único criterio de evaluación de los métodos propuestos con el fin de comparar los resultados obtenidos por las diferentes estrategias publicadas. En este sentido, conviene resaltar el hecho de que algunos resultados publicados en los citados trabajos difieren ligeramente de los presentados en esta memoria por el hecho de que las imágenes utilizadas para prueba en ambos casos no han sido exactamente las mismas.

Por otro lado, las mencionadas publicaciones se han llevado a cabo tanto en cultivos de cereal como en campos de maíz, algo que en la presente tesis se ha recogido convenientemente bajo diferentes epígrafes.

Los citados trabajos poseen una parte común que es la relativa al proceso de segmentación que se verá con detalle y una parte diferencial en lo que a las estrategias de decisión se refiere.

Las referencias publicadas en revistas indexadas son:

1. Alberto Tellaeché, Xavier P. Burgos-Artizzu, Gonzalo Pajares, Ángela Ribeiro (2007). A vision-based method for weeds identification through the Bayesian decision theory. *"Pattern Recognition"*, Elsevier, vol. 41, pp 521-530. Discutido en profundidad en la sección 3.3.

2. Gonzalo Pajares, Alberto Tellaeché, Xavier P. Burgos-Artizzu, Ángela Ribeiro (2007). Design of a computer vision system for a differential spraying operation in precision agriculture using Hebbian learning. *"IET Computer Vision"*, Aceptado para publicación. Discutido en profundidad en la sección 3.5.
3. Alberto Tellaeché, Gonzalo Pajares, Ángela Ribeiro, Xavier P. Burgos-Artizzu (2007). A new vision-based approach to differential spraying in precision agriculture. *"Computers and Electronics in Agriculture"*, Elsevier, In Press, Corrected Proof. Discutido en profundidad en la sección 3.7.

Los trabajos enviados a congresos nacionales e internacionales son los siguientes, en orden cronológico inverso:

1. Alberto Tellaeché, Xavier-P. Burgos Artizzu, Gonzalo Pajares, Ángela Ribeiro. A Vision-Based Hybrid Classifier for Weeds Detection in Precision Agriculture through the Bayesian and Fuzzy k-Means paradigms. 2nd International Workshop on Hybrid Artificial Intelligence Systems (HAIS). Innovations in Hybrid Intelligent Systems. Advances In Soft Computing, Vol. 44. Eds: Emilio Corchado, Juan M. Corchado, Ajith Abraham. Springer-Verlag Berlin Heidelberg 2007. ISBN 978-3-540-74971-4. Discutido en profundidad en la sección 3.6.1.
2. Alberto Tellaeché, Xavier P. BurgosArtizzu, Gonzalo Pajares, Ángela Ribeiro. A Vision-based Classifier in Precision Agriculture Combining Bayes and Support Vector Machines. IEEE International Symposium on Intelligent Signal Processing (WISP 2007), pp. 425-430 Conference Proceedings Book, IEEE Catalog Number: 07EX1620, ISBN 1-4244-0829-6 (CD-ROM), Alcalá de Henares, España, 2007. Discutido en profundidad en la sección 3.6.3.
3. A.Tellaeché, X.P. Burgos-Artizzu, G. Pajares y A. Ribeiro. On Combining Support Vector Machines and Fuzzy K-Means in Vision-based Precision Agriculture. International Conference on Computer, Electrical and Systems Science, and Engineering (WASET 2007), pp. 33-38, Volumen 22 Julio 2007,

ISBN 978-975-01752-1-3 (CD-ROM), Praga, República Checa 2007. Discutido en profundidad en la sección 3.6.2.

4. A.Tellaeche, X.P. Burgos, G. Pajares y A. Ribeiro. Segmentación de imágenes para Agricultura selectiva. XXVII Jornadas de Automática, pp. 860-865, ISBN 84-689-9417-0 (CD-ROM), Almería, España, 2006. Discutido en profundidad en la sección 2.4.

1.7. Contenido de la memoria

La memoria de tesis se presenta estructurada en capítulos, con el siguiente orden:

1. Capítulo 1: Introducción. Se plantean los objetivos de la tesis, motivación e introducción de las soluciones aportadas. Este capítulo contiene también el estado del arte relativo a todos los temas presentados en esta tesis.
2. Capítulo 2: En este capítulo se presenta el tratamiento de la imagen llevado a cabo, su segmentación y la extracción de atributos para el posterior uso de técnicas de clasificación.
3. Capítulo 3: Planteamiento de los métodos de clasificación desarrollados. En este capítulo se explican de forma teórica los algoritmos utilizados y su aplicación al problema concreto sobre el que versa esta tesis.
4. Capítulo 4: Presentación de los resultados obtenidos y análisis comparativo de los mismos.
5. Capítulo 5: Conclusiones obtenidas, líneas de investigaciones futuras y posibles mejoras.

2. Segmentación de la imagen y extracción de atributos

2.1. Introducción

El presente capítulo de la tesis recoge la estructura general del sistema desarrollado para dar solución al problema planteado, así como una descripción de las soluciones planteadas y los resultados alcanzados con cada una de ellas.

En un primer apartado se presenta una estructura general del sistema inteligente desarrollado, estableciendo sus componentes y estructura, para después explicar con más profundidad la solución desarrollada.

El sistema consta de dos partes esenciales, segmentación y decisión. Como se ha mencionado en el capítulo uno, el proceso de segmentación consiste en extraer de la imagen toda la información necesaria con la que se puede tomar la decisión sobre la pulverización de las celdas.

Históricamente, se ensayaron diferentes estrategias de segmentación hasta conseguir la secuencia de procesos que conforman el sistema que se presenta. El punto de partida siempre han sido las experiencias de trabajos previos hasta conseguir un método con resultados satisfactorios. En este sentido las variaciones desde el principio de la investigación han sido relativamente escasas y siempre tendentes al perfeccionamiento del método. El método de segmentación proporciona una partición de la imagen en celdas. Cada una de estas celdas se caracteriza por sus atributos, que permiten diferenciarlas entre sí. Estas propiedades o atributos son de dos tipos según la naturaleza de la medida realizada:

1. Relaciones de área.
2. Relaciones estructurales.

Las relaciones basadas en el área tratan de determinar si una celda debe o no ser pulverizada en función de la densidad de malas hierbas en relación al cultivo. Por el contrario, las relaciones estructurales consideran la distribución y los agrupamientos de las malas hierbas dentro de las celdas. Las relaciones de área son las que se han utilizado generalmente en algunos trabajos existentes en la literatura, para la introducción de las relaciones estructurales se han tenido en cuenta una serie de razones que se exponen más adelante. Se podría hablar en realidad de relaciones cuantitativas y cualitativas. A lo largo de este trabajo nos referiremos a ellas indistintamente bajo ambas denominaciones.

2.2. Estructura general del sistema

El sistema desarrollado responde a la estructura de un clasificador automático híbrido. En este tipo de sistemas existen dos procesos perfectamente diferenciados: *off-line* y *on-line*, figura 2-1.

Durante el procesamiento *off-line*, se lleva a cabo un proceso de aprendizaje, mientras que el procesamiento *on-line* es el modo de funcionamiento normal del sistema y el que toma la decisión final.

El proceso de segmentación es común en ambos y comprende los siguientes pasos:

1. Adquisición de imágenes: las imágenes son suministradas por un sistema de visión, que está instalado sobre un tractor robotizado. Dado que en el momento de llevar a cabo los experimentos relativos a este trabajo de investigación el sistema no se encuentra totalmente operativo, las imágenes se extraen de las correspondientes bases de datos disponibles y son capturadas en formato de vídeo durante la época en la que se lleva a cabo el tratamiento con herbicida.

2. Binarización, detección de surcos y partición en celdas: en este paso las imágenes de entrada son binarizadas de forma que la vegetación (cultivo y malas hierbas) aparece en blanco, mientras que el resto (suelo, cantos, etc.) en negro. Seguidamente se procede a la detección de las líneas de cultivo o surcos, que determinan la distribución dominante del cultivo. El paso final divide la imagen de entrada en celdas, que constituyen las unidades básicas de procesamiento.
3. Extracción de atributos: para cada celda se obtienen sus atributos cuantitativos y cualitativos.

En el propio proceso *off-line*, se lleva a cabo el aprendizaje propiamente dicho mediante el correspondiente entrenamiento, de forma que las imágenes que se seleccionan como imágenes de muestra o imágenes patrón son las que posteriormente y tras la segmentación se generan las celdas que constituirán las muestras de entrenamiento. Estas muestras se almacenan en la Base de Conocimiento (BC), junto con los parámetros y las funciones de decisión aprendidas. Todo ello estará disponible durante el proceso *on-line* con el fin de poder tomar la decisión más apropiada según el criterio de cada método durante dicho proceso.

En el procesamiento *on-line* se realizan los mismos pasos de segmentación que los descritos anteriormente, si bien con nuevas imágenes sobre las que es necesario tomar una decisión. Cuando el proceso de segmentación finaliza, las propiedades que caracterizan a las diferentes celdas se encuentran disponibles, de forma que recuperando de la BC la información necesaria (muestras, funciones de decisión, parámetros), según el método, se pueda tomar la decisión propiamente dicha de acuerdo con la correspondiente regla de decisión asociada con cada método. Dicha decisión finalmente se traducirá en si la celda que se analiza en cada momento debe ser o no pulverizada y en su caso qué cantidad de herbicida sería recomendable en función de los valores proporcionados por las funciones de decisión.

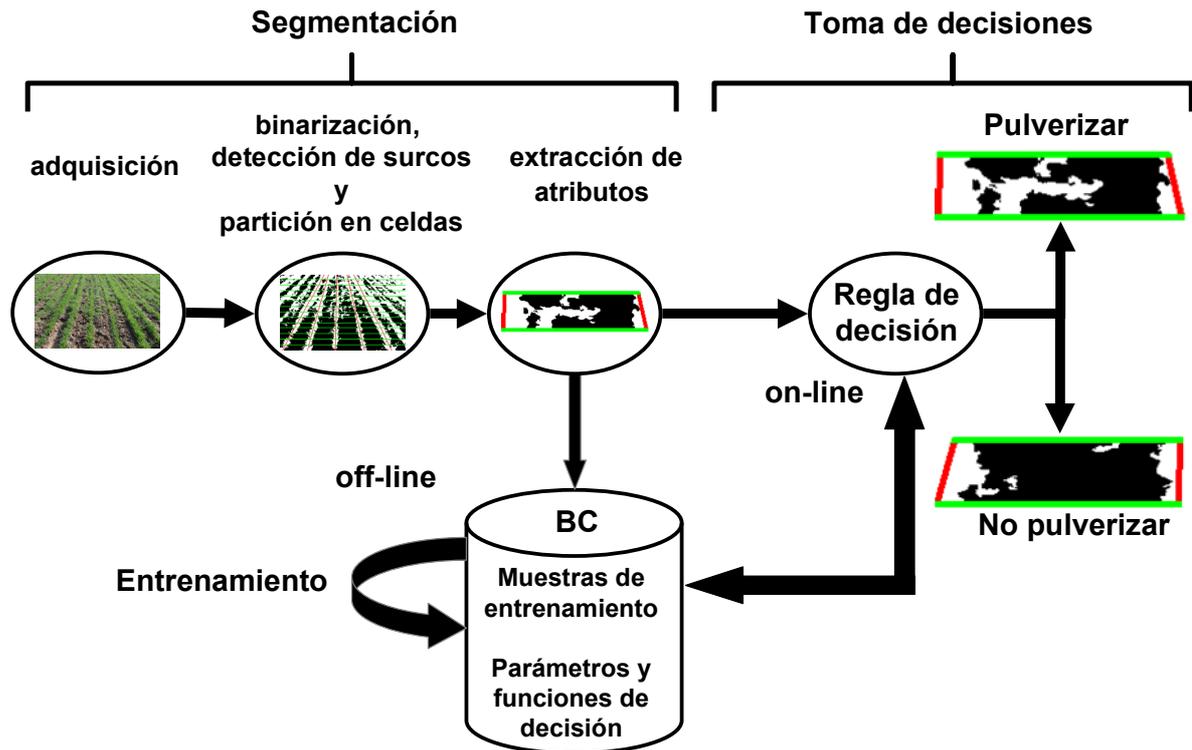


Figura 2-1: esquema general del sistema desarrollado

En este capítulo se explica con detalle el proceso de segmentación de la imagen dejando para el capítulo tres los procesos de aprendizaje y decisión propiamente dichos.

2.3. Segmentación: adquisición de imágenes

Las imágenes de entrada al sistema correspondientes tanto a los cultivos de cereal como de maíz están tomadas desde una posición de perspectiva según la colocación de la cámara en el tractor o una situación equivalente cuando se capturan manualmente. En estas imágenes se aprecia por tanto la zona más próxima en la parte inferior de la misma. En esta zona se ven perfectamente separados los surcos. A medida que aumenta la distancia en la escena los surcos se juntan cada vez más, haciendo más complicado la identificación de malas hierbas. En la parte superior de la imagen, las líneas de los surcos se unen en el horizonte. Más adelante se detalla la mencionada proyección de perspectiva.

Las imágenes de cereal utilizadas para este trabajo de investigación fueron tomadas en un campo experimental en el centro de investigación de La Poveda, Arganda del Rey, Madrid. El área de este campo era de aproximadamente 1,7 ha. La mala hierba predominante en el cereal era *A. sterilis* con densidades variables comprendidas entre 10 y 400 plantas por metro cuadrado. A pesar de la existencia de otras especies de malas hierbas en este campo (*Papaver rhoeas*, *Veronica hedaerefolia*, *Lamium amplexicaule*), en el momento de la captura de imágenes la mayoría de estas últimas habían sido eliminadas mediante un tratamiento basado en bromoxinil+mecocrop.

Las imágenes fueron tomadas a lo largo de la primavera del año 2003 (Abril). En esta época del año, las plantas de cereal estaban poco desarrolladas (del orden de tres a cinco hojas). El espaciado entre surcos era de aproximadamente 0.36 m.; aunque el ancho estándar entre filas en esta zona es de 0.17m, es común encontrar líneas de cultivo con más separación en lugares como Norte América o Australia. Líneas de cultivo con más separación simplifican la detección de malas hierbas.

Las imágenes digitales fueron tomadas con una cámara Sony DCR PC110E. El área cubierta por cada imagen es aproximadamente 2 x 15 m² y la resolución de las imágenes es 1152 x 864 píxeles.

Las imágenes correspondientes a los cultivos de maíz fueron adquiridas con una cámara digital HPR817 durante cuatro días diferentes en Mayo de 2006 y otros cuatro diferentes días en Abril/Mayo de 2007. Las capturas fueron espaciadas entre cinco y seis días, por tanto, su adquisición se realizó bajo diferentes condiciones de iluminación. La resolución de las imágenes y el área de cobertura son similares a las de las imágenes de cereal mencionadas anteriormente. Los campos de cultivo del maíz se localizan en la zona sur de Madrid cerca de la ribera del río Manzanares, del que se abastecen para los regadíos.

En ambos casos, las imágenes son capturadas bajo la proyección de perspectiva. La figura 2-2 muestra un esquema de este tipo de proyección, que tendrá su repercusión en el procesado y toma de decisiones posteriores. Bajo esta proyección se deriva el hecho de que las líneas paralelas de los surcos tienden a converger hacia un único punto en la imagen, denominado punto de fuga. A partir de la observación de dicha figura se puede observar que las áreas marcadas como *A* y *B*, con la misma dimensión real sobre el campo se proyectan bajo dimensiones diferentes en la imagen, zonas *a* y *b* respectivamente. Para cada imagen, la dimensión de las áreas del campo proyectadas es inversamente proporcional a su distancia al plano de la imagen. Por ello, el área *A* que se sitúa más próxima al plano de la imagen que la *B* se proyecta con una superficie mayor en la imagen. Otro aspecto importante a destacar es el hecho derivado de la dirección de movimiento del tractor ya que el método propuesto en Tellaeché y col. (2007a) utiliza esta información para la toma de decisiones. En efecto, *B* y *C* progresan hacia *A* según el movimiento del tractor, mientras que *A* tiende a desaparecer de la imagen.

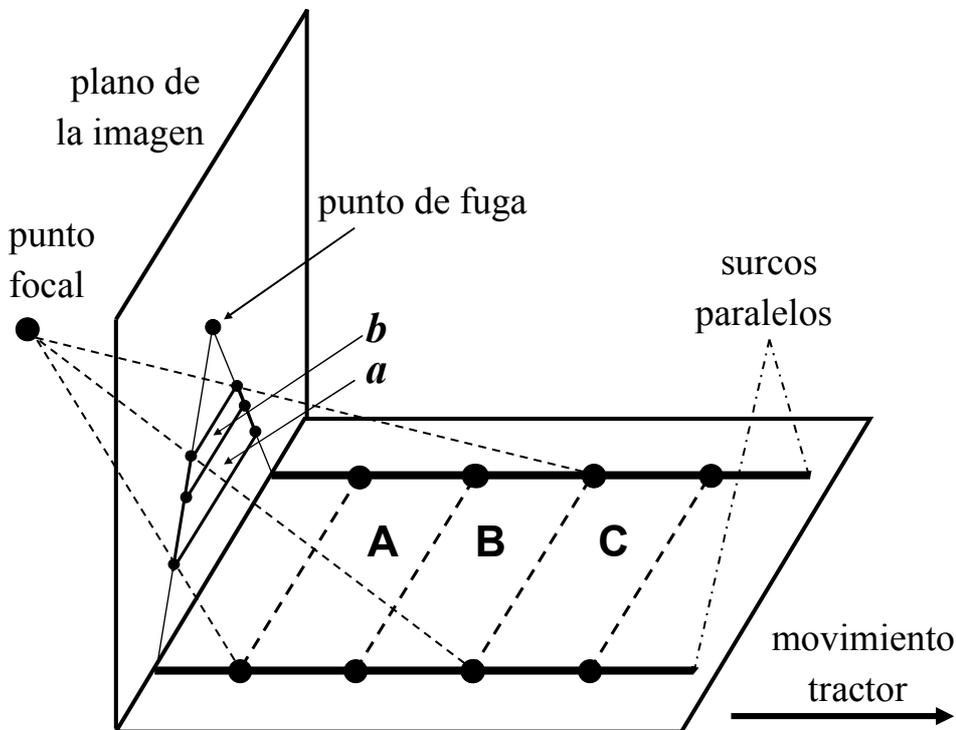


Figura 2-2: Proyección de perspectiva

2.4. Segmentación: binarización, detección de surcos y extracción de celdas

2.4.1. Binarización

La binarización constituye el primer paso de tratamiento propiamente dicho de la imagen, de suerte que a partir de una imagen original su objetivo consiste en separar de la imagen la parte vegetal de la no vegetal. La parte vegetal contiene tanto plantas de cultivo como de malas hierbas. El resultado final es proporcionar una imagen de salida binaria donde la parte vegetal se transforma en valores de intensidad máxima es decir, blancos; mientras la no vegetal se transforma a valores de intensidad mínima, es decir, negros. Esta imagen binaria es convenientemente tratada mediante técnicas morfológicas con el fin de mejorar su calidad. La imagen binarizada constituye la entrada para el siguiente proceso de extracción de las líneas de cultivo o surcos.

Previamente, Bacher (2001), había propuesto una estrategia de procesamiento similar basada en el conocimiento de distancias entre surcos. En este estudio la imagen original en formato RGB es binarizada aplicando una umbralización a la imagen en escala de grises obtenida a partir de la imagen original en RGB. La frecuencia de los píxeles de las plantas es indicada en la dirección correspondiente al surco. Un valor máximo indica un surco. Después de aplicar una dilatación morfológica, las malas hierbas aparecen aisladas y pueden ser identificadas. Esta estrategia no es aplicable a los campos de cereal infestados con *Avena Sterilis* debido a que el color y la forma de las hojas de esta mala hierba son prácticamente idénticos a las del cereal cultivado.

Aunque existen en la literatura varios métodos para la binarización de imágenes (Ribeiro, 2005, Granitto, 2005, Onyango, 2003, Tian y Slaughter, 1998), para el problema concreto que se investiga en este trabajo se ha seleccionado el método descrito en Ribeiro (2005). La segmentación está basada en tres componentes RGB que describen cada punto de la imagen. En una primera etapa, la segmentación transforma la imagen RGB original en una imagen binaria, tomando como característica para cada uno de los

píxeles (i,j) de la imagen el predominio de la componente verde $(G(i,j))$ sobre las otras dos componentes roja y azul $(R(i,j), B(i,j))$. La imagen se procesa según la siguiente ecuación (2.1),

$$T(i, j) = rR(i, j) + gG(i, j) + bB(i, j) \quad (2.1)$$

donde r , g y b son coeficientes reales que toman los valores $r = -1$, $g = 2$ y $b = -1$, de acuerdo con los experimentos llevados a cabo en Ribeiro y col. (2005). Si tras aplicar la ecuación resulta que $T(i, j) \leq 0$, entonces se hace $T(i, j) = 0$ y si por el contrario resulta que $T(i, j) \leq 255$, entonces $T(i, j) = 1$, obteniendo finalmente la imagen binarizada.

Una vez que la imagen está binarizada, para eliminar píxeles espúreos y para suavizar los contornos blancos, correspondientes a las líneas de cultivo, se aplica una operación de apertura morfológica (erosión seguida de dilatación) (Onyango y Marchant, 2003; Bacher, 2001). A continuación se procede a la limpieza de píxeles aislados eliminando regiones con un número de píxeles inferior al umbral T_a fijado a 10, cuyo valor se justifica en la sección 4.3.1. Como operación final se realiza una operación de rellenado de pequeños huecos.

Para la realización de la apertura morfológica se utiliza el conocimiento de que la imagen ha sido adquirida bajo proyección de perspectiva, por ello y para obtener un mejor resultado en esta operación, se aplican tres elementos estructurales diferentes. Las líneas de cultivo en el centro de la imagen son prácticamente verticales, mientras que estas mismas líneas en la parte derecha e izquierda de la imagen tienen diferentes pendientes. Por este motivo, la imagen es dividida en tres partes con la misma anchura: izquierda (L), central (C) y derecha (D). Para la operación de apertura morfológica se aplican los elementos estructurales S_L , S_C y S_R definidos en la ecuación 2.2.

Por último y debido a que las líneas de cultivo tienden a unirse en el horizonte, según la proyección de perspectiva, la zona de procesamiento se reduce al tercio inferior de la imagen, que es la parte más cercana al plano de la imagen.

$$S_L = \begin{bmatrix} 0 & 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 \end{bmatrix}, \quad S_C = \begin{bmatrix} 0 & 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 0 \end{bmatrix}, \quad S_R = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 \end{bmatrix} \quad (2.2)$$

2.4.2. Detección de las líneas de cultivo y obtención de celdas de procesamiento.

Como se ha indicado en el punto anterior, tras la operación de apertura morfológica, tanto los cultivos (cereal o maíz) como las malas hierbas se representan con blancos (valor 255), mientras que el resto (suelo, piedras, etc.) se representa con negros (valor 0).

Tomando como base esta imagen binaria, el siguiente paso a realizar consiste en la detección de las líneas que identifican los surcos. Para llevar a cabo esta operación se utiliza la transformada de Hough (González y Woods, 2002; González y col. 2004; Pajares y Cruz, 2007a,b). Esta transformada resulta ser un método muy probado y robusto en casos como el que nos ocupa, donde las líneas a determinar cubren toda la imagen como es el caso de los trabajos realizados por Astrand y Baerveldt (2002) y Billingsley y Schoenfish (1997).

La transformada de Hough obtiene ecuaciones de líneas que definen un grupo de puntos en el espacio xy de la imagen.

Si se considera un punto cualquiera (x_i, y_i) de la imagen, existe un número infinito de rectas teóricas que pasan por ese punto y satisfacen la ecuación $y_i = ax_i + b$ para

cualquier valor de los parámetros a y b . Si la ecuación anterior se reescribe de la forma $b = -x_i a + y_i$ y se establece el denominado espacio de parámetros (a, b) , se obtiene una única línea para un valor fijo de (x_i, y_i) . Si se sigue este procedimiento con puntos sucesivos (x_j, y_j) , se obtienen líneas asociadas a cada punto en el espacio de parámetros anteriormente definido.

En un siguiente paso de la transformación, se divide el espacio de parámetros en celdas de acumulación $A(i, j)$. Estas celdas de acumulación se corresponden con un cuadro asociado de coordenadas (a_j, b_j) . Inicializando estas celdas a cero y utilizando la anterior transformación de los puntos de la imagen original al espacio de parámetros, se establece el número de puntos en el espacio de parámetros correspondientes a cada una de las celdas de acumulación. Un valor Q en una determinada celda de acumulación $A(i, j)$ implica que Q puntos en la imagen original pertenecen a una misma recta, representada por las coordenadas asociadas a la celda de acumulación (a_j, b_j) .

En la figura 2-3 se representan gráficamente los valores del acumulador obtenidos tras aplicar la transformada de Hough a la imagen de la figura 1-4. Se observa, según la escala de color a la derecha, el valor Q de cada celda. Los valores más altos se representan con los colores más claros, que llegan incluso hasta el blanco. Los mayores valores, en cualquier caso, aparecen remarcados con un cuadrado indicando que los mismos han superado el valor de un umbral T_h , que será explicado inmediatamente.

Una vez obtenidos los valores Q para las diferentes celdas de acumulación asociadas a la imagen, se establece un umbral para determinar qué valores de Q deben seleccionarse, desechando todas las celdas de acumulación cuyo valor de Q sea inferior al umbral establecido T_h . Con esto se realiza la transformada inversa de Hough con las coordenadas (a_j, b_j) de las celdas de acumulación más significativas, representado únicamente las rectas en la imagen original que están formadas por un mayor número de puntos. Mediante este procedimiento de umbralización aplicado a las celdas se consigue

eliminar el efecto de los puntos de la imagen original que no forman realmente rectas entre ellos.

En la transformada de Hough pueden aparecer problemas al utilizar la ecuación de la recta $y = ax + b$, particularmente si la recta se aproxima a posiciones verticales. En estos casos, tanto la pendiente como la ordenada en el origen se aproximan a infinito. Para evitar este problema se utiliza la representación normal de la recta $(x \cos \theta + y \sin \theta = \rho)$, en cuyo caso el espacio de parámetros viene determinado por θ y ρ .

En las imágenes bajo transformación de perspectiva utilizadas en esta investigación se presenta el problema anteriormente citado, ya que las líneas de cultivo que se encuentran en la zona central de la imagen, se aproximan en muchos casos a la verticalidad. Por ello en la realización de la transformada de Hough para la obtención de las líneas de cultivo se utiliza la representación normal de la recta $x \cos \theta + y \sin \theta = \rho$, utilizando todo el rango de valores para θ , desde -90° a 90° . La transformada de Hough crea unas celdas de acumulación $A(\theta, \rho)$. Para el valor Q se ha establecido un valor $T_h = 100$, tomando como posibles líneas de cultivo a representar las líneas que cumplen $Q > T_h$ en el espacio de parámetros.

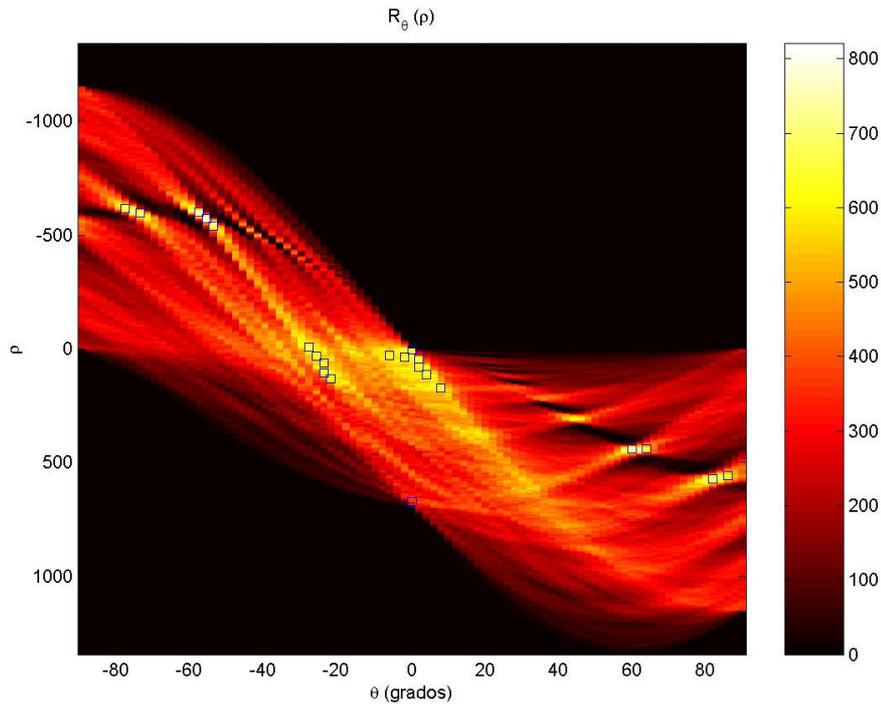


Figura 2-3: Espacio de parámetros y celdas de acumulación

Debido al grosor de las líneas de cultivo, ocurre que sobre un mismo surco aparecen asociadas con él varias ecuaciones que es necesario fusionar para identificar un surco de forma unívoca. Por otro lado, debido a la transformación de perspectiva es bien sabido que sólo aquellas ecuaciones con unos valores dados de los parámetros deben ser admitidos, por ejemplo no se admiten rectas con valores de parámetros que representan líneas horizontales. El procedimiento para describir de forma unívoca cada surco mediante una única ecuación es el siguiente:

1. Se establece un ángulo límite para la inclinación de las rectas definiendo las líneas de cultivo. Se eliminan las rectas que tienen una inclinación menor que 40°
2. Si se obtienen rectas verticales de parámetros similares, se unifican por similitud de parámetros.
3. Se unifican las rectas que presentan parámetros similares tanto en θ como en ρ . Dadas dos celdas de acumulación $A(\theta_i, \rho_i)$ y $A(\theta_j, \rho_j)$, se asume que representan la misma línea de cultivo en la imagen si $|\theta_i - \theta_j| \leq \varepsilon_1$

y $|\rho_i - \rho_j| \leq \varepsilon_2$, donde ε_1 y ε_2 son valores pequeños determinados empíricamente.

4. Se establece una longitud mínima para las rectas obtenidas y se eliminan aquellas con una longitud por debajo de un determinado valor por considerar que no definen un surco.

En la figura 2-4 se muestran las rectas marcadas en rojo, cuyas ecuaciones describen los surcos y obtenidas tras el proceso descrito previamente.

Establecida una única ecuación por surco, el siguiente paso consiste en realizar una partición en celdas. Para ello, se traza una malla formada por líneas horizontales sobre la imagen. Esta malla consta de líneas que cumplen la ecuación $y = kc$, en nuestro caso, con $c=50$ y $k=1..n$. Las intersecciones de las líneas de cultivo y de la malla horizontal establecen las regiones básicas de procesamiento de la imagen, de ahora en adelante denominadas celdas.

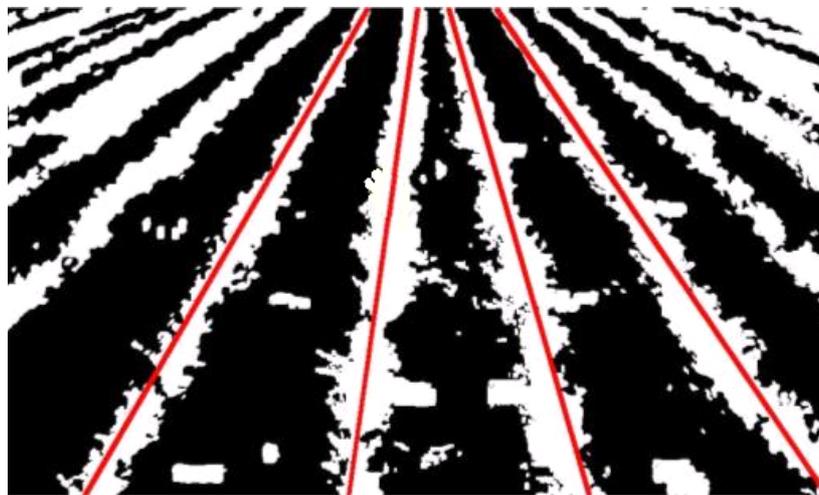


Figura 2-4: Resultado de la transformada de Hough

En la imagen de la figura 2-5 se muestran las celdas obtenidas e identificando, mediante la elipse resaltada, una de tales celdas que constituyen las unidades

elementales para ser consideradas y a partir de las cuales se extraerán las propiedades relevantes para la decisión sobre su pulverización.



Figura 2-5: Creación de la malla horizontal y establecimiento de celdas

2.5. Segmentación: extracción de atributos

Una vez obtenidas las celdas es necesario proceder a su descripción. Esto se lleva a cabo mediante la extracción de atributos o propiedades que la caracterizan. En el caso que nos ocupa, los atributos son de dos tipos distintos: cuantitativos y cualitativos. Los primeros miden la densidad de malas hierbas en la celda en relación al cultivo existente. Son los que también denominaremos atributos de área utilizando ambas expresiones indistintamente. Los segundos, por el contrario, miden la distribución de las malas hierbas en la celda independientemente de su densidad. Son atributos de naturaleza estructural, por ellos nos referiremos a ellos con esta terminología, que se utilizará indistintamente junto con el término cualitativo. A continuación se exponen las razones para la elección de estos atributos definiendo seguidamente los métodos para su obtención.

2.5.1. Razones para la elección de los atributos

Cuando las malas hierbas aparecen en grandes agrupaciones con una baja dispersión de plantas sobre el campo, los expertos agrícolas (ingenieros agrónomos, botánicos, agricultores) determinan visualmente si la densidad de malas hierbas está por encima de un determinado umbral que se considera como seguro desde el punto de vista de pérdidas en la producción del cultivo. Si la densidad de malas hierbas está por encima de dicho umbral, las celdas deben ser pulverizadas. Donde más se ha experimentado en este sentido es en los campos de cereal de forma que la *A. sterilis* apareciendo en razones de 5 a 10 plantas m^{-2} puede llegar a producir pérdidas de hasta el 10% (Torner y col. 1991) en cultivos de cebada de invierno. Esto justifica la elección de los atributos de las celdas basados en el área, que miden la densidad de malas hierbas.

Por otro lado las malas hierbas, aparecen también dispersas dentro de la celda (en general en el campo) formando pequeños agrupamientos o de forma aislada. En este caso, aunque no lleguen a los valores de densidad anteriormente descritos, las plantas aisladas de malas hierbas, dada su capacidad de resistencia y reproducción constituyen una seria amenaza para el cultivo. Barroso y col. (2005) ha estudiado algunos de estos comportamientos determinando que zonas infestadas de *A. sterilis* con densidades de 0.2 a 4 plantas m^{-2} representan un riesgo en las cosecha del año actual, así como en los 2-3 años siguientes, que se puede cuantificar en el 15%. Estas observaciones y experimentos determinan que las relaciones estructurales sean de interés en la decisión final.

Como ha quedado expuesto previamente, la imagen se divide en celdas, que son las unidades básicas de procesamiento. Debido a que las imágenes a procesar obtenidas de los campos de cultivo son tomadas bajo proyección de perspectiva, la forma y el tamaño de las celdas difiere dentro de la imagen.

Diversos estudios utilizan diferentes estrategias para identificar las malas hierbas dentro de los campos de cultivo. Granitto y col. (2005) y Astrand y Baerveldt (2002) utilizan propiedades topológicas (área, momentos invariantes, etc), color (varianza, operaciones basadas en el histograma de intensidad, etc) o textura. Desafortunadamente, tanto la *Avena Sterilis* en cereales como otras variedades de malas hierbas en maíz, aparecen en zonas con tamaños y formas irregulares. Otro inconveniente es que el color y la textura de las mismas son muy similares a la de ambos cultivos en el campo bajo estudio, con lo que las estrategias empleadas en los estudios citados no son aplicables a este problema.

Otra característica negativa de estas malas hierbas, particularmente de la *A. Sterilis*, que dificulta aún más su identificación es que su crecimiento es incontrolado dentro del campo de cultivo. Esto implica que tras tratar la imagen obtenida, las zonas verdes que aparecen entre los surcos son malas hierbas y por lo tanto, las líneas de cultivo de cereal o maíz próximas a esta zona estarán afectadas por ella, por lo tanto el objetivo es la identificación de malas hierbas en cada una de las celdas a tratar para tomar la decisión de pulverizarla o no.

El crecimiento incontrolado de las malas hierbas y en particular de la *Avena Sterilis* junto con la distribución irregular que puede llegar a tomar el cultivo (cereal o maíz) dentro de los surcos hace de la identificación de las malas hierbas una tarea dificultosa. Esta distribución irregular, particularmente en el cereal, es debida a los largos periodos de sequía en la zona central de España, donde se han llevado a cabo los estudios. Este problema no aparece tan agravado en el caso del maíz porque la sequía no es tal ya que este cultivo se riega regularmente y por tanto la sequía no genera esas irregularidades en los surcos.

Teniendo en cuenta todos estos problemas y el anteriormente mencionado del tamaño variable de las celdas debido a la perspectiva de la imagen, para la definición de las características de las celdas se hace necesaria la extracción de atributos que sean

independientes de la distribución de malas hierbas y cultivo, y también del tamaño y la forma de las celdas. Esto requiere la obtención de medidas relativas.

Para la obtención y definición de estas medidas relativas, se ha seleccionado un subconjunto de 30 imágenes de entre un total de 146 imágenes. Este subconjunto fue seleccionado manualmente teniendo en cuenta y analizando los diferentes casos de celdas que pueden aparecer. Esta selección podría ser tomada como el paradigma del razonamiento basado en casos. De cada imagen segmentada se han seleccionado 48 celdas, por lo tanto el número de celdas totales es de 1440. El número de celdas clasificadas como pulverizables fueron $F = 245$ (17% de 1440). Este porcentaje relativamente bajo de celdas a pulverizar justifica de nuevo el interés para la pulverización selectiva de los campos de cultivo.

Del conjunto de celdas restantes ($H = 1195$) se ha calculado el porcentaje de área blanca en cada celda (correspondiente a cultivo, ya que este subconjunto de celdas es el establecido como no pulverizable), con ello se obtiene el coeficiente r definido a continuación:

$$r = \frac{1}{H} \sum_{c=1}^H \frac{W_c}{A_c} \quad (2.3)$$

A_c es el área completa de una celda dada c y W_c es el área blanca en la celda, correspondiente a cultivo. Todas y cada una de las celdas contienen zonas blancas a la izquierda (I) y a la derecha (D) representando las líneas de cultivo contiguas. Tras el cómputo de r para las celdas analizadas se llega a que $r \approx 2/6$ con $r = r_I + r_D$, donde r_I y r_D son los ratios correspondientes a las áreas de cultivo izquierda y derecha, por lo que esto implica que $r_I = r_D \approx 1/6$. Cada área de cultivo lateral ocupa aproximadamente $1/6$ del área total de la celda.

Observando las celdas bajo estudio y teniendo en cuenta el procesamiento de la imagen, se ha analizado la distribución de las zonas verdes (cultivo o malas hierbas) en los dos conjuntos de celdas obtenidas F y H . Tras el estudio se pueden obtener los siguientes modelos generales de distribución de zonas verdes en las celdas:

1. La celda presenta dos únicas zonas verdes, correspondientes a las líneas de cultivo izquierda y derecha
2. La celda presenta las dos zonas verdes laterales y un número n de pequeñas zonas verdes en la zona central de la imagen.
3. La celda presenta un número p de zonas verdes prominentes que invaden la zona central de la celda partiendo de una de las zonas laterales.
4. Las dos zonas laterales izquierda y derecha se encuentran conectadas.

Estas cuatro modelos generales no son excluyentes entre sí, lo que implica que una misma celda puede cumplir más de uno de estos modelos a la vez. Como paso previo al cómputo de los atributos de naturaleza cuantitativa y cualitativa se procede a la eliminación de las zonas supuestamente verdes espúreas y por tanto blancos en la imagen binarizada. Esto se lleva a cabo suprimiendo las regiones blancas con un número de píxeles inferior a un determinado umbral T_a fijado a 10 (ver sección 4.3.1 para su justificación).

2.5.2. Relaciones cuantitativas

Las relaciones cuantitativas establecen el porcentaje de ocupación de una determinada celda por plantas de cultivo y malas hierbas. Estas relaciones también se han utilizado en otras investigaciones (Granitto y col. 2005; Bacher 2001; Pérez y col. 2000).

La ocupación de plantas en la celda puede ser debida tanto a malas hierbas como al cultivo, por ello, se ha dividido la celda en zonas, para tratar de establecer esta

distinción, porcentaje ocupado por las malas hierbas y porcentaje ocupado por la líneas de cultivo.

En el desarrollo de los experimentos que han dado lugar a este trabajo las relaciones cuantitativas se aplicaron antes que las relaciones estructurales, habiendo sido utilizadas en exclusiva en las primeras aproximaciones de identificación de celdas a pulverizar o no.

Para explicar estas relaciones cuantitativas, se define m como el número total de regiones en una determinada celda i , A_{ij} es el área de la región j -ésima y A_{ic} el área total de la celda. A_{iI} y A_{iD} son las áreas de cultivo izquierda y derecha respectivamente. Estas dos últimas medidas son calculadas teniendo en cuenta la cantidad de píxeles dentro de las regiones establecidas como de cultivo, cuyos límites laterales se encuentran definidos por r_I y r_D .

Considerando lo anterior, se pueden calcular los siguientes valores:

1. Zona de cultivo cubierta.

$$C_{iC} = A_{iI} + A_{iD} \quad (2.4)$$

2. Zona cubierta por las malas hierbas.

$$C_{iW} = \sum_{j=1}^m A_{ij} - C_{iC} \quad (2.5)$$

3. Zona de suelo.

$$C_{iS} = A_{iC} - (C_{iC} + C_{iW}) \quad (2.6)$$

Teniendo en cuenta las expresiones anteriores se definen las dos primeras relaciones cuantitativas de las 8 que se calculan en total.

$$a_{i0} = \frac{C_{iW}}{A_{iC}} \quad \text{y} \quad a_{i1} = \frac{C_{iW}}{C_{iC}} \left(1 - \frac{C_{iS}}{A_{iC}} \right) \quad (2.7)$$

Las dos primeras relaciones cuantitativas determinan de manera global los porcentajes de ocupación vegetales de la celda completa y de su zona central. Como es en esta última zona donde se da la proliferación de las malas hierbas, las siguientes relaciones cuantitativas (a_{i2}, \dots, a_{i7}) se calculan de la misma forma que a_{i0} , pero restringiendo su cálculo a zonas concretas dentro de la zona central. Esta zona se subdivide a su vez en tres zonas verticales, de las cuales se calcula la presión de malas hierbas (a_{i2} a a_{i4}). Lo mismo se hace horizontalmente, obteniendo las últimas relaciones de área, a_{i5} a a_{i7} . Estas relaciones de a_{i2} a a_{i7} son secundarias y se pueden utilizar como apoyo en los cálculos a las dos relaciones de área fundamentales a_{i0} y a_{i1} . No obstante en esta investigación no se les ha encontrado una eficacia demostrable, por lo que no se han utilizado en los experimentos, habiendo optado por mantenerlos con el fin de poderlos utilizar en futuras aplicaciones si esto fuera preciso.

A continuación se describen de una forma más detallada estos atributos:

- a_{i2} establece el grado de ocupación por malas hierbas en el tercio izquierda de la zona central de la celda, tomado verticalmente.
- a_{i3} establece el grado de ocupación por malas hierbas en el tercio central de la zona central de la celda tomado verticalmente.
- a_{i4} establece el grado de ocupación por malas hierbas en el tercio derecha de la zona central de la celda tomado verticalmente.
- a_{i5} establece el grado de ocupación por malas hierbas en el tercio superior de la zona central de la celda tomado horizontalmente.
- a_{i6} establece el grado de ocupación por malas hierbas en el tercio medio de la zona central de la celda tomado horizontalmente.

- a_{i7} establece el grado de ocupación por malas hierbas en el tercio inferior de la zona central de la celda tomado horizontalmente.

Por su definición, cada uno de los componentes del vector de relaciones cuantitativas $\{a_{i0}, a_{i1}, a_{i2}, \dots, a_{i7}\}$, tiene un valor entero comprendido entre 0 y 1.

Volviendo sobre los atributos a_{i0} y a_{i1} es preciso señalar su especial significado histórico junto con su comportamiento y rango de variación. En efecto, a_{i0} es definida como el ratio de mala hierba en Tian y col. 1999 y Ribeiro y col. 2005 y a_{i1} se puede asociar con la presión de malas hierbas definida en Ribeiro y col. 2005. Por este motivo, a veces nos referimos a a_{i1} como presión de malas hierbas.

El siguiente análisis permite determinar el rango de variabilidad para estos dos primeros valores. Si la presencia de malas hierbas es nula, entonces a_{i0} y a_{i1} también son nulas, pero si las malas hierbas cubren la región entre líneas de cultivo de manera completa ($C_{iW} = \frac{4}{6} A_{iC}$), entonces $a_{i0} = \frac{4}{6}$, por lo tanto a_{i0} está en el rango $\left[0, \frac{4}{6}\right]$. El límite superior de a_{i1} se da cuando C_{iW} es máximo ($C_{iW} = \frac{4}{6} A_{iC}$) y C_{iC} mínimo ($C_{iC} = 0$), pero si C_{iC} es nulo, esto significa que la celda no posee líneas de cultivo. Este caso no se ha dado en los experimentos realizados. El mínimo valor obtenido para C_{iC} ha sido $\frac{1}{10} A_{iC}$. Por tanto, asumiendo que $C_{iW} = \frac{4}{6} A_{iC}$, entonces $C_{iS} = 0.23 A_{iC}$. Finalmente el límite superior para a_{i1} se puede calcular a partir de (2.7) obteniendo un valor de 5.13.

Basados en estos valores, los componentes del vector de relaciones cuantitativas se escalan linealmente en el intervalo [0,1]. Esto se justifica con el fin de

que todos los componentes de las relaciones cuantitativas contribuyan de manera equitativa en la función de decisión.

El atributo a_{i0} toma en cuenta la cantidad relativa de malas hierbas en una celda. El uso de la presión de malas hierbas a_{i1} , está basada en la experiencia de los expertos en este ámbito. De hecho, éstos asumen que el mismo número de malas hierbas en una celda causan diferentes efectos futuros sobre el cultivo dependiendo de la cantidad de cultivo. Esto es así debido a que durante la fase de crecimiento, grandes cantidades de cultivo tienden a adueñarse de las malas hierbas y viceversa.

La figura 2-6 muestra el comportamiento de la presión de malas hierbas en un ejemplo ilustrativo. Si en el ejemplo A_{iC} toma el valor 36, teniendo en cuenta la deducción realizada anteriormente, antes del proceso de normalización, C_{iC} varía de 3,6 a 12 (mínima / máxima presencia de cultivo) y C_{iW} varía de 0 a 24 (mínima / máxima presencia de malas hierbas). La presión de malas hierbas frente a C_{iC} y C_{iW} fijando C_{iW} y C_{iC} a un valor constante de 10, respectivamente, se muestra en las figuras 2-6(a) y (b). Otros valores constantes muestran comportamientos similares.

Como se puede ver en la figura 2-6 (a) la presión de malas hierbas decrece cuando la cantidad de cultivo aumenta, mientras en la figura 2-6 (b) se muestra el comportamiento contrario cuando crece la presencia de malas hierbas. Esto significa que si C_{iC} es alto, el cultivo vencerá a las malas hierbas, pero si por el contrario C_{iW} es alto las vencedoras serán las malas hierbas. Dependiendo del ganador esperado, se debe pensar en pulverizar con diferentes cantidades de herbicida.

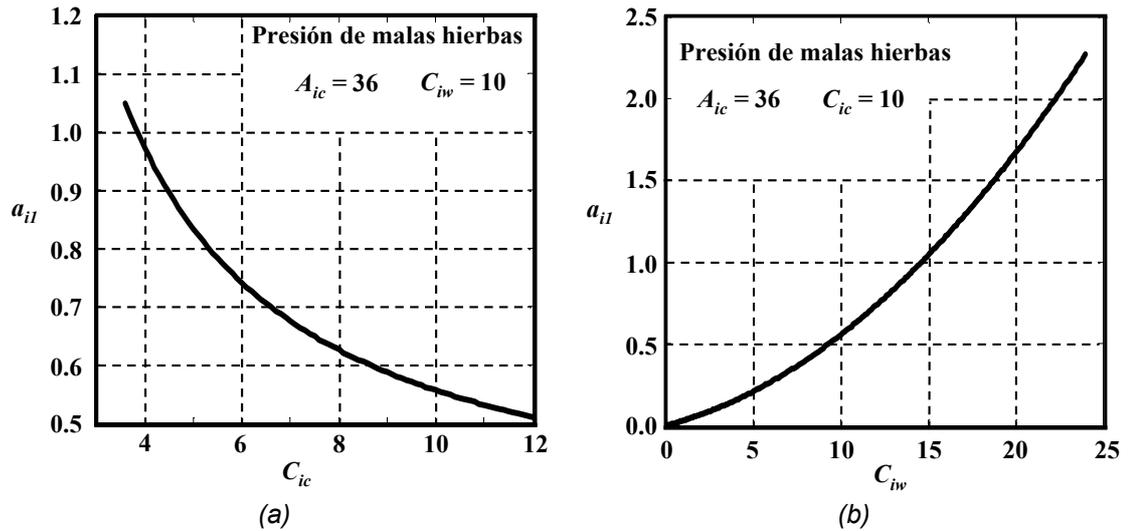


Figura 2-6: Comportamiento de la presión de malas hierbas. (a) presencia de malas hierbas constante, (b) presencia de cultivo constante

Para establecer medidas de similitud entre dos vectores de relaciones cuantitativas pertenecientes a dos celdas diferentes, se utiliza una medida basada en la distancia Euclídea, es decir, dados dos vectores a_i y a_j con 8 componentes cada uno, se define la distancia euclídea como:

$$E_{ij} = E(a_i, a_j) = \|a_i - a_j\| \quad (2.8)$$

donde $\|\cdot\|$ es la norma Euclídea.

Como los valores de a_i y a_j están restringidos al rango $[0,1]$, la máxima diferencia entre dos componentes de estos vectores se obtiene si $a_{ik} = 0$ y $a_{jk} = 1$ o viceversa. En el caso de mayor diferencia entre vectores de relaciones cuantitativas, esta condición se dará en las 8 componentes del vector y por lo tanto $\|a_i - a_j\| = \sqrt{8}$ y $E_{ij} \approx 2,82$.

Dada la definición de distancia Euclídea, el menor valor de E_{ij} dará la mayor similitud entre vectores de relaciones cuantitativas, por lo tanto las decisiones basadas en dicha distancia utilizan como criterio la mínima distancia.

2.5.3. Relaciones estructurales

En la sección 2.5.1 se definieron cuatro modelos generales según la distribución o dispersión de malas hierbas en las celdas, observando el conjunto de celdas disponibles ($F+H = 1440$) se establecen nueve formas de dispersión que generan a su vez nueve condiciones, algunas de ellas excluyentes entre sí. Estas nueve condiciones constituyen los antecedentes de un conjunto de reglas con las que se tomará la decisión sobre si una determinada celda ha de ser o no pulverizada.

Para el modelado matemático de las nueve condiciones mencionadas, se define una región dentro de una celda cualquiera de una imagen según la siguiente expresión matemática:

$$X_i(x, y, w, h) \quad (2.9)$$

donde:

- X = región dentro de una celda.
- i = número de la región en el total de regiones de la celda.
- x = coordenada en el eje de abscisas de la región.
- y = coordenada en el eje de ordenadas de la región.
- w = anchura en el eje de abscisas de la región.
- h = altura en el eje de ordenadas de la región.

Los ejes de abscisas y ordenadas se establecen de forma convencional.

Por otra parte, previamente se ha determinado que $r_i = r_D \approx 1/6$. Si se define Z como la anchura total de una celda según el eje de abscisas, se pueden obtener los límites de la zona central de la celda, excluyendo las partes que se consideran cultivo según (2.10),

$$\begin{aligned} x_{\min} &= r_i \\ x_{\max} &= Z - r_D \end{aligned} \quad (2.10)$$

Con estas premisas, las nueve condiciones matemáticas que definen las relaciones estructurales se definen como sigue:

1. No existen regiones aisladas intermedias ni regiones que sobrepasen los límites laterales correspondientes a las zonas de cultivo.

$$\begin{aligned} s_0 &\begin{cases} 1; & \sum_{i=1}^n X_i(x, y, w, h) = 0; \quad \forall X_i \mid x > x_{\min}, x + w < x_{\max} \\ 0; & \text{en otro caso} \end{cases} \\ s_1, \dots, s_8 &= 0 \end{aligned} \quad (2.11)$$

2. Existe una única región aislada entre las zonas límite izquierda y derecha de la celda

$$\begin{aligned} s_1 &\begin{cases} 1; & \sum_{i=1}^n X_i(x, y, w, h) = 1; \quad \forall X_i \mid x > x_{\min}, x + w < x_{\max} \\ 0; & \text{en otro caso} \end{cases} \\ s_2 &= 0 \\ s_3 &= 0 \end{aligned} \quad (2.12)$$

3. Existen entre dos y cinco regiones aisladas entre las zonas límite izquierda y derecha

$$\begin{aligned} s_2 &\begin{cases} 1; & 2 \leq \sum_{i=1}^n X_i(x, y, w, h) \leq 5; \quad \forall X_i \mid x > x_{\min}, x + w < x_{\max} \\ 0; & \text{en otro caso} \end{cases} \\ s_1 &= 0 \\ s_3 &= 0 \end{aligned} \quad (2.13)$$

4. Existen más de cinco regiones aisladas entre las zonas límite izquierda y derecha

$$s_3 \begin{cases} 1; & \sum_{i=1}^n X_i(x, y, w, h) > 5; \quad \forall X_i \mid x > x_min, x + w < x_max \\ 0; & \text{en otro caso} \end{cases} \quad (2.14)$$

$s_1 = 0$
 $s_2 = 0$

5. Una única región lateral derecha sobrepasa el límite de cultivo derecho de la celda

$$s_4 \begin{cases} 1; & \sum_{i=1}^n X_i(x, y, w, h) = 1; \quad \forall X_i \mid x < x_min, x_min < x + w < x_max \\ 0; & \text{en otro caso} \end{cases} \quad (2.15)$$

$s_5 = 0$

6. Más de dos regiones laterales derechas sobrepasan el límite derecho de la celda

$$s_5 \begin{cases} 1; & \sum_{i=1}^n X_i(x, y, w, h) > 1; \quad \forall X_i \mid x < x_min, x_min < x + w < x_max \\ 0; & \text{en otro caso} \end{cases} \quad (2.16)$$

$s_4 = 0$

7. Una única región lateral izquierda sobrepasa el límite izquierdo de cultivo de la celda

$$s_6 \begin{cases} 1; & \sum_{i=1}^n X_i(x, y, w, h) = 1; \quad \forall X_i \mid x + w > x_max, x_min < x < x_max \\ 0; & \text{en otro caso} \end{cases} \quad (2.17)$$

$s_7 = 0$

8. Más de dos regiones laterales izquierda sobrepasan el límite lateral izquierdo de la celda

$$s_7 \begin{cases} 1; & \sum_{i=1}^n X_i(x, y, w, h) > 1; \quad \forall X_i \mid x + w > x_{\text{max}}, x_{\text{min}} < x < x_{\text{max}} \\ 0; & \text{en otro caso} \end{cases} \quad (2.18)$$

$$s_6 = 0$$

9. Existe al menos una región continua en la zona central de la celda que une las regiones definidas por los dos límites laterales de cultivo.

$$s_8 \begin{cases} 1; & \sum_{i=1}^n X_i(x, y, w, h) \geq 1; \quad \forall X_i \mid x + w > x_{\text{max}}, x < x_{\text{min}} \\ 0; & \text{en otro caso} \end{cases} \quad (2.19)$$

Cada celda i genera un vector 9-dimensional de relaciones estructurales de la forma $S_i = \{s_{i0}, s_{i1}, \dots, s_{i8}\}$, donde cada componente se refiere a cada una de las nueve condiciones previas. Como queda establecido por su formulación, estas relaciones estructurales toman un valor binario, siendo 1 si se cumplen y 0 en caso contrario.

Estas relaciones, a diferencia de los modelos generales, son excluyentes entre sí a nivel de subgrupos, los subgrupos excluyentes entre sí son los siguientes: $\{s_{i1}, s_{i2}, s_{i3}\}$, $\{s_{i4}, s_{i5}\}$, $\{s_{i6}, s_{i7}\}$. Por otro lado si se da la condición s_{i0} , implica que la celda es no pulverizable, con lo que no se pueden dar ninguna otra de las condiciones restantes. En este caso, la condición s_{i0} , es excluyente de todas las demás.

Para establecer medidas de similitud entre dos celdas respecto a estas relaciones, dados dos vectores de relaciones estructurales S_i y S_j , se aplica el concepto de coincidencia de cadenas definido en González y Woods (2002) o Pajares y Cruz (2007a), comparando los dos vectores componente a componente. Tomamos N como el número de elementos en un vector de relaciones estructurales ($N = 9$), y M como el número de coincidencias en los dos vectores de relaciones estructurales bajo comparación, donde una coincidencia se da cuando $s_{ik} = s_{jk}$, para una componente k

concreta dentro de los vectores de relaciones estructurales. La medida de similitud se establece como la razón:

$$R_{ij} \equiv R(S_i, S_j) = \frac{M}{N} \quad (2.20)$$

Por lo tanto $R_{ij} = 1$ para una coincidencia perfecta entre vectores de relaciones estructurales ($M = N$) y $R_{ij} = 0$ cuando ninguno de los componentes S_i y S_j coinciden. Por lo tanto, cuanto mayor es el valor de R_{ij} mejor es la coincidencia. R_{ij} tiene un valor comprendido entre 0 y 1, siendo este un criterio a maximizar.

2.5.4. Base de conocimiento de celdas modelo

Como se ha explicado en la sección 2.2 el sistema desarrollado sigue la estructura de un sistema experto, con dos fases en funcionamiento bien diferenciadas, entrenamiento o aprendizaje (off-line) y funcionamiento normal o explotación (on-line).

Para la fase de aprendizaje es necesario disponer de unos modelos previos que permitan al sistema establecer unas reglas que sirvan después para la correcta clasificación de las celdas. Con este objetivo se ha generado una BC con datos de celdas basada en la experiencia empírica, de tal forma que los diferentes algoritmos de aprendizaje utilizados dispongan de las muestras de entrenamiento necesarias. La base de datos se ha constituido con imágenes de celdas modelo a no pulverizar y otras imágenes modelo de celdas a pulverizar, abarcando en este último grupo una amplia variedad de casos que se pueden dar. A tenor de los resultados obtenidos y que se expondrán más adelante, esta base de datos ha probado ser suficiente para el correcto funcionamiento de los diferentes algoritmos de aprendizaje desarrollados.

2.5.5. Datos utilizados en los algoritmos de decisión

Los algoritmos de decisión utilizados a lo largo de la investigación desarrollada tienen como denominador común que previamente a su funcionamiento correcto de clasificación tienen una fase de aprendizaje. Como se ha explicado en el punto anterior, los datos necesarios para el aprendizaje de estos algoritmos se extraen de un procesamiento previo de las celdas modelo presentes en la base de datos. Las celdas modelo son de dos tipos: celdas modelo para el caso de no pulverizar y celdas modelo para el caso de pulverizar.

Dada una celda i de la categoría de celdas a pulverizar se describe mediante los vectores de relaciones estructurales (RS) y cuantitativas (RC) como sigue:

- $RS_{pulv_i} = \{s_{pulv_{i0}}, s_{pulv_{i1}}, \dots, s_{pulv_{i8}}\}$ vector de 9 relaciones estructurales de una celda modelo i perteneciente al grupo de celdas modelo a pulverizar
- $RC_{pulv_i} = \{a_{pulv_{i0}}, a_{pulv_{i1}}, \dots, a_{pulv_{i7}}\}$ el vector de relaciones cuantitativas de esa misma celda modelo i .

Por otro parte dada una celda j de la categoría de celdas a no pulverizar, ésta se describirá de forma análoga como:

- $RS_{nopulv_j} = \{s_{nopulv_{j0}}, s_{nopulv_{j1}}, \dots, s_{nopulv_{j8}}\}$ como vector de relaciones estructurales de la celda j
- $RC_{nopulv_j} = \{a_{nopulv_{j0}}, a_{nopulv_{j1}}, \dots, a_{nopulv_{j7}}\}$ como vector de relaciones cuantitativas de esta misma celda.

Finalmente, si se dispone de u celdas a pulverizar y v celdas a no pulverizar en la BC tendremos los conjuntos:

$$RS_{pulv} = \{RS_{pulv_0}, RS_{pulv_1}, \dots, RS_{pulv_{u-1}}\} \quad (2.21)$$

$$RC_{pulv} = \{RC_{pulv_0}, RC_{pulv_1}, \dots, RC_{pulv_{u-1}}\} \quad (2.22)$$

$$RS_{nopulv} = \{RS_{nopulv_0}, RS_{nopulv_1}, \dots, RS_{nopulv_{v-1}}\} \quad (2.23)$$

$$RC_{nopulv} = \{RC_{nopulv_0}, RC_{nopulv_1}, \dots, RC_{nopulv_{v-1}}\} \quad (2.24)$$

Estos cuatro vectores de datos conjuntos obtenidos de la base de datos de celdas modelo son los que se utilizan en los procesos de aprendizaje de los algoritmos de clasificación utilizados en el presente trabajo.

3. Algoritmos de decisión

3.1. Introducción

En este capítulo se aborda el problema de la toma de decisión según el esquema de la figura 2-1. Desde un punto de vista general se aborda este problema desde la perspectiva de clasificación comprendiendo dos fases: entrenamiento y decisión propiamente dicha. Durante el entrenamiento se carga la *BC* con modelos de celdas a pulverizar y no pulverizar con sus correspondientes vectores de atributos. Con ellas se obtienen los parámetros y funciones derivadas del entrenamiento. Los datos almacenados en la *BC* se recuperan durante el proceso de decisión con el fin de determinar si una celda determinada debe o no ser pulverizada considerando la regla de decisión asociada con cada método. Las propiedades de esta nueva celda se obtienen mediante el proceso de segmentación descrito en el capítulo dos.

En este punto se plantea la necesidad de investigar sobre métodos de decisión. La decisión más simple que se puede tomar es la de determinar si una celda debe o no ser pulverizada. Estamos pues ante un método de clasificación de tipo biclase con decisión de sí o no. Inicialmente y siguiendo las líneas de investigación abiertas en el ámbito de la AP se eligen como atributos propiedades basadas en el área y uno de los métodos más prometedores en el campo de la clasificación biclase, el método de las denominadas *máquinas de vectores soporte* (*Support Vector Machines*, SVM). Con el avance de las investigaciones se determina que si bien seguimos ante un problema importante de clasificación, no resulta menos importante el hecho de que podría ser factible no sólo determinar si la celda debe o no ser pulverizada sino también y de forma simultánea decidir sobre la cantidad de herbicida a aplicar. Con este propósito se recurre a técnicas de clasificación capaces de proporcionar esta información, este es el caso de los clasificadores de naturaleza estadística como el clasificador Bayesiano y la ventana de Parzen. El primero es de naturaleza paramétrica y el segundo no paramétrica. En ambos casos se estima una función de densidad de probabilidad con la que se toma la

decisión según el valor de la probabilidad a posteriori. Siguiendo la misma línea se experimenta con el *clasificador borroso (Fuzzy Clustering)* de amplia difusión en problemas de clasificación, que proporciona grados de pertenencia con los que determinar la pulverización y la cantidad a aplicar.

Dentro del campo de los clasificadores, las técnicas de hibridación han sido ampliamente estudiadas, derivando de ellas una amplia teoría al respecto. Se acepta de forma general, que la hibridación, entendida como combinación de métodos, produce mejores resultados que los propios métodos utilizados separadamente. En la investigación de técnicas de hibridación consiste la segunda fase de la investigación.

Para los experimentos realizados con los métodos de clasificación mencionados, sólo se han utilizado las propiedades basadas en el área, en un intento de mejora de los resultados se amplía el campo de la decisión para incluir también las relaciones estructurales. Es en este momento cuando se acude a la denominada *teoría de la decisión multicriterio (Multicriteria decision making, MCDM)*.

A modo de resumen las técnicas de decisión analizadas son:

1. Clasificadores simples: máquinas de vectores soporte, clasificador Bayesiano, ventana de Parzen, Agrupamiento borroso (*Fuzzy Clustering*) y clasificador Hebbiano.
2. Clasificadores híbridos: SVM + Bayes, SVM + Clasificador borroso y Bayes + clasificador Borroso.
3. Teoría de la decisión multicriterio.

Los procesos que se describen a continuación tienen su base en la observación de un conjunto X de muestras (celdas) de entrenamiento, las cuales se etiquetan como celdas a pulverizar (CP) y a no pulverizar (CN) según corresponda. A partir de estos conjuntos de celdas patrón se obtienen los parámetros y funciones de decisión derivadas

del entrenamiento. El conjunto CP contiene u celdas a pulverizar con los conjuntos definidos por las ecuaciones (2.21) y (2.22) mientras que el conjunto CN posee v celdas catalogadas como celdas a no clasificar definidos por las ecuaciones (2.23) y (2.24). El conjunto X posee en total $N = u + v$ muestras.

3.2. Clasificación mediante máquinas de vectores soporte

Este método de clasificación fue el primero en dar resultados positivos en la clasificación de las celdas a pulverizar, objetivo principal de la tesis.

Las Máquinas de Vectores Soporte o *Support Vector Machines* (SVM) son uno de los clasificadores con un prestigio importante adquirido en la última década para resolver problemas de clasificación, particularmente de naturaleza biclase como el que se plantea en este trabajo. Esta técnica es la utilizada en Tellaeché y col. (2007c y d).

A continuación se expone la teoría de este método de clasificación y la explicación de la aplicación particular de este método al caso que se intenta resolver.

3.2.1. Teoría de las Support Vector Machines (SVM)

La principal utilidad de esta técnica está en la clasificación biclase, admitiendo la posibilidad de proyectar los datos en espacios de mayor dimensión que los originales con el fin de conseguir una separabilidad de las clases en el supuesto de que las mismas no sean separables. Como en todo sistema de clasificación el proceso consta de dos fases, entrenamiento y decisión.

3.2.1.1 Proceso de entrenamiento

El entrenamiento se basa en la observación del conjunto de X con las N muestras. En teoría las salidas del sistema son los dos valores simbólicos $y \in \{+1, -1\}$

de forma que el conjunto de entrenamiento está formado por los pares (\mathbf{x}_i, y_i) , $i = 1, \dots, N$; donde cada vector \mathbf{x}_i se corresponde con un vector de entrenamiento y los valores $y_i \in \{+1, -1\}$ indican la clase a la que pertenece cada vector; $y_i = +1$ si la muestra pertenece a CP e $y_i = -1$ si la muestra pertenece a CN .

El objetivo del proceso de entrenamiento consiste en encontrar una función de decisión capaz de separar las dos clases. En el caso de que las clases sean no separables, los vectores de entrenamiento se proyectan a un espacio de dimensión superior mediante el uso de funciones de transformación no lineales. En este caso, la función de decisión se sitúa en el hiperplano de esa dimensión (Cherkassky y Mulier, 1998; Vapnik, 2000; Bahamonde, 2006). La función de decisión tiene la forma dada en la siguiente ecuación:

$$f(\mathbf{x}) = \sum_{i=1}^n \alpha_i y_i H(\mathbf{x}_i, \mathbf{x}) - b \quad (3.1)$$

donde b es una constante.

Una representación gráfica del problema se muestra en la figura 3-1, donde se puede identificar la clase c_1 con CP y c_2 con CN .

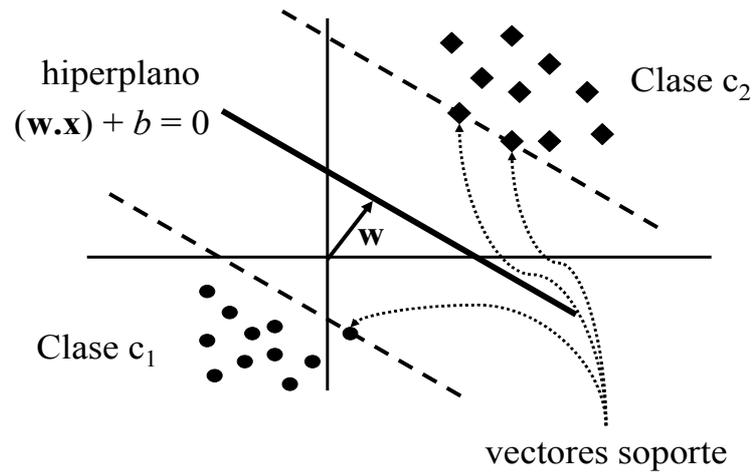


Figura 3-1: Entrenamiento de una máquina de vectores soporte para encontrar el hiperplano óptimo.

La ecuación (3.1) establece una expresión de la función de decisión $f(\mathbf{x})$ como una combinación lineal de núcleos centrados en cada punto. Los parámetros α_i , $i = 1, \dots, N$, son la solución para el siguiente problema de optimización:

Maximizar el funcional :

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j H(\mathbf{x}_i, \mathbf{x}_j) \quad (3.2)$$

sujeto a:

$$\sum_{i=1}^N y_i \alpha_i = 0, \quad 0 \leq \alpha_i \leq \frac{C}{N}, \quad i = 1, \dots, N \quad (3.3)$$

y dados los datos de entrenamiento (\mathbf{x}_i, y_i) , $i = 1, \dots, N$, el núcleo del producto interno H y el parámetro de regularización C . Como se menciona en Cherkassky y Mulier (1998) en este momento no existe una teoría bien desarrollada para seleccionar el mejor valor de C , si bien en varias aplicaciones se han utilizado valores altos, del orden de 2000.

Los patrones \mathbf{x}_i asociados con valores α_i distintos de cero se denominan *vectores soporte* (“*support vectors*”). Una vez se han determinado los vectores soporte como consecuencia de la solución del anterior problema de minimización la función de decisión toma la forma:

$$f(\mathbf{x}) = \sum_{\text{support vectors}} \alpha_i y_i H(\mathbf{x}_i, \mathbf{x}) - b \quad (3.4)$$

Para un vector \mathbf{x} dado, $f(\mathbf{x})$ proporciona como resultado un valor escalar cuya polaridad, signo de $f(\mathbf{x})$, determina la pertenencia a una u otra clase. La magnitud se puede interpretar como un índice de la certeza de la decisión tomada. La ventaja de utilizar sólo los vectores soporte es que permiten descartar el resto de datos en el cómputo de dicha función. En las SVM es interesante considerar la compresión de información y sus propiedades de almacenamiento. Los vectores soporte representan los puntos de datos más informativos y permiten comprimir la información contenida en el conjunto de muestras de entrenamiento. Resumiendo, en problemas de clasificación, sólo es necesario almacenar los vectores soporte, mientras que todos los ejemplos de entrenamiento pueden ser desechados (Evgeniou, 2000).

Existen diferentes núcleos, entre los que destacan los siguientes:

1. Lineal: $H(\mathbf{x}, \mathbf{y}) = \mathbf{x}^t \mathbf{y}$
2. Funciones de base radial “*Radial Basis Functions*”:

$$\text{Gaussiana: } H(\mathbf{x}, \mathbf{y}) = \exp\left\{-\|\mathbf{x} - \mathbf{y}\|^2 / 2\sigma^2\right\}$$

$$\text{Exponencial: } H(\mathbf{x}, \mathbf{y}) = \exp\left\{-\|\mathbf{x} - \mathbf{y}\| / 2\sigma^2\right\}$$

3. Polinomios: $H(\mathbf{x}, \mathbf{y}) = (1 + \langle \mathbf{x}, \mathbf{y} \rangle)^d$ con grado d
4. Función sigmoide: $H(\mathbf{x}, \mathbf{y}) = \tanh(\rho \langle \mathbf{x}, \mathbf{y} \rangle + \gamma)$

3.2.1.2 Proceso de decisión

Ahora dado un nuevo \mathbf{x} se determina la clase a la que pertenece de acuerdo con el signo (polaridad) de $f(\mathbf{x})$. La magnitud puede considerarse como una medida de certidumbre sobre la decisión realizada.

Los vectores soporte son los datos más representativos de todos los utilizados como se ha mencionado anteriormente. Esto implica que los vectores soporte son los patrones con mayor grado de información y que almacenando sólo estos vectores se consigue el mismo resultado que con todos los patrones, lo que puede llegar a representar un importante ahorro de espacio en el almacenamiento de los datos del aprendizaje.

La distancia mínima desde el hiperplano que separa las clases al patrón más cercano se denomina margen τ (Cherkassky y Mulier, 1998). Un hiperplano de separación se denomina óptimo si el margen es máximo. La distancia entre el hiperplano de separación y un patrón \mathbf{z} es $y_k |f(\mathbf{x})| / \|\mathbf{w}\|$ donde \mathbf{w} está dado por:

$$\mathbf{w} = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i = \sum_{\text{vectores soporte}} \alpha_i y_i \mathbf{x}_i \quad (3.5)$$

A la hora de calcular la función de decisión, la constante b se obtiene a partir de alguna de las condiciones de Karush-Kuhn-Tucker (Cherkassky y Mulier, 1998):

$$\alpha_i \{y_i [(\mathbf{w} \cdot \mathbf{x}_i) + b] - 1\} = 0 \quad (3.6)$$

Suponiendo que existe un margen τ , todas las muestras de entrenamiento siguen la desigualdad:

$$\frac{y_k f(\mathbf{x}_k)}{\|\mathbf{w}\|} \geq \tau, \quad k = 1, \dots, N \quad \text{donde } y_k = \{+1, -1\} \quad (3.7)$$

El problema de encontrar el hiperplano óptimo se reduce a encontrar el valor del vector \mathbf{w} que maximice el margen τ . Obsérvese que existe un número infinito de soluciones que difieren solo en el escalado de \mathbf{w} . Para disminuir dicho número se suele fijar la escala según el producto de τ y la norma de \mathbf{w} :

$$\tau \|\mathbf{w}\| = 1 \quad (3.8)$$

Por lo tanto, maximizar el margen τ es equivalente a minimizar la norma de \mathbf{w} .

3.2.2. Utilización de las SVM en el problema de clasificación de celdas de cultivo

Este método utiliza solamente los atributos de naturaleza cuantitativa por lo que los conjuntos de atributos utilizados resultan ser los definidos en las ecuaciones (2.22) y

$$(2.24): RC_{pulv} \text{ y } RC_{nopulv}.$$

Se ha experimentado con los núcleos que a continuación se relacionan para su utilización en la definición de la función de decisión definida en la ecuación (3.4).

1. Núcleo lineal: $H(\mathbf{x}, \mathbf{y}) = \mathbf{x}^t \mathbf{y}$
2. Núcleo polinomial: $H(\mathbf{x}, \mathbf{y}) = (1 + \langle \mathbf{x}, \mathbf{y} \rangle)^d$.
3. Función de base radial Gaussiana: $H(\mathbf{x}, \mathbf{y}) = \exp\left\{-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}\right\}$

Para las tres funciones de núcleo se establece el parámetro de regularización C a 2000, para el núcleo polinomial se establece un grado de 2 y para la función polinomial

Gaussiana un valor de σ igual a 50. Estos valores han sido establecidos empíricamente.

Después de establecer los parámetros del problema de optimización, se aborda su resolución y se obtienen las siguientes salidas:

1. Número de vectores soporte.
2. Multiplicadores de Lagrange (α)
3. Término de bias (b)

Con estos parámetros como resultado del entrenamiento ya es posible establecer la función de decisión $f(\mathbf{x}) = \sum_{\text{support vectors}} \alpha_i y_i H(\mathbf{x}_i, \mathbf{x}) - b$. Con esta función de decisión calculada, se realiza la clasificación de las celdas de cultivo de la imagen que está siendo procesada.

Para cada celda nueva a clasificar, r , se obtiene el vector de relaciones cuantitativas x_r y se calcula $f(x_r)$. Dependiendo del signo de $f(x_r)$, se determina la celda como celda a pulverizar o no.

3.3. Clasificadores estadísticos: Bayes y ventana de Parzen.

El método de las SVM se apoya en diferentes núcleos para conseguir una mayor separabilidad de clases mediante la proyección de los datos a clasificar a hiperespacios de más dimensiones que el que contiene originalmente los datos.

En un siguiente paso en el desarrollo de algoritmos de clasificación para el problema de clasificación que nos ocupa, se ha propuesto una solución desde una perspectiva estadística. En esta línea se encuentran dos tipos de clasificadores que se distinguen atendiendo a su naturaleza (Duda y col. 2001; Pajares y Cruz, 2007a):

1. Clasificación paramétrica: Clasificador Bayesiano

2. Clasificación no paramétrica: ventana de Parzen.

3.3.1. Teoría del clasificador Paramétrico Bayesiano

El clasificador Bayesiano ha sido utilizado en los trabajos previos de Tellaeché y col. (2007 a, b y d).

Previamente a la explicación teórica del clasificador Bayesiano, se establecen los dos principales casos estadísticos que se pueden dar tras la observación de las muestras a clasificar. Estos dos casos son el caso normal multivariable con media desconocida y el caso normal multivariable con media \mathbf{m} y matriz de covarianza C desconocidas. Estos son precisamente los parámetros que el método estima, identificándose de forma genérica como $\mathbf{w} \equiv (\mathbf{m}, C)$.

3.3.1.1 Caso Normal multivariable con media desconocida

Se supone que las muestras en cada clase siguen una distribución Normal con media \mathbf{m} y matriz de covarianza C . Se asume de forma general que una clase dada posee n muestras. Por simplicidad se establece para ese caso concreto que el único parámetro desconocido sea la media:

$$f(\mathbf{x}_i, \mathbf{w}) = p(\mathbf{x}_i/\mathbf{m}) = \frac{1}{(2\pi)^{d/2} |C|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x}_i - \mathbf{m})^t C^{-1}(\mathbf{x}_i - \mathbf{m})\right\} \quad (3.9)$$

$$\ln p(\mathbf{x}_i/\mathbf{m}) = -\frac{1}{2} \ln\{(2\pi)^d |C|\} - \frac{1}{2}(\mathbf{x}_i - \mathbf{m})^t C^{-1}(\mathbf{x}_i - \mathbf{m}) \quad (3.10)$$

La expresión anterior se obtiene haciendo $\mathbf{w} \equiv (\mathbf{m})$ y por tanto obviando C . Derivando con respecto a \mathbf{m} la ecuación (3.10) se obtiene,

$$\nabla_{\mathbf{m}} \ln p(\mathbf{x}_i / \mathbf{m}) = C^{-1}(\mathbf{x}_i - \mathbf{m}) \quad (3.11)$$

La minimización del riesgo empírico expresado por (3.11) supone que

$$\frac{1}{n} \sum_{i=1}^n C^{-1}(\mathbf{x}_i - \mathbf{m}) = \mathbf{0} \quad (3.12)$$

Con lo que multiplicando por C y despejando \mathbf{m} se obtiene una estima para la misma dada por (3.13),

$$\mathbf{m}^* = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (3.13)$$

Interpretando este resultado, se puede deducir que la estima de máxima verosimilitud para la media desconocida de una distribución es precisamente la media aritmética de las muestras de dicha distribución, o lo que es lo mismo, la media simple de las muestras.

Si se interpreta este resultado de una manera geométrica, considerando todas las muestras como una nube de puntos, la media simple sería el centroide de la nube, que puede ser considerado como el representante de dicha clase.

La media anteriormente obtenida tiene las propiedades estadísticas conocidas y siempre se tiene tendencia a utilizarla aunque no se tenga el conocimiento de que la misma es la solución de máxima verosimilitud.

3.3.1.2 Caso Normal Multivariable con media y matriz de covarianza desconocidas

El caso general y más típico de una distribución Normal multivariable es cuando la media \mathbf{m} y la matriz de covarianza \mathbf{C} son desconocidas. Estos dos parámetros desconocidos constituyen las componentes del vector de parámetros $\mathbf{w} \equiv (\mathbf{m}, \mathbf{C})$ a las que por simplicidad denominamos $\mathbf{w} \equiv (w_1, w_2)$. Si se considera los datos unidimensionales por simplificar se tiene $w_1 = m$ y $w_2 = \sigma^2$ de forma que:

$$\ln p(x_i/\mathbf{w}) = -\frac{1}{2} \ln 2\pi w_2 - \frac{1}{2w_2} (x_i - w_1)^2 \quad (3.14)$$

Y

$$\nabla_{\mathbf{w}} \ln p(x_i/\mathbf{w}) = \begin{bmatrix} \frac{1}{w_2} (x_i - w_1) \\ -\frac{1}{2w_2} + \frac{(x_i - w_1)^2}{2w_2^2} \end{bmatrix} \quad (3.15)$$

Minimizando los datos de entrenamiento se obtienen ahora las siguientes condiciones:

$$\frac{1}{n} \sum_{i=1}^n \frac{1}{\hat{w}_2} (x_i - \hat{w}_1) = 0 \quad -\frac{1}{n} \sum_{i=1}^n \frac{1}{2\hat{w}_2} + \frac{1}{n} \sum_{i=1}^n \frac{(x_i - \hat{w}_1)^2}{2\hat{w}_2^2} = 0 \quad (3.16)$$

donde \hat{w}_1 y \hat{w}_2 son las estimas de máxima verosimilitud para w_1 y w_2 respectivamente.

Si se sustituye $\hat{m} = \hat{w}_1$ y $\hat{\sigma}^2 = \hat{w}_2$ se obtienen las estimas de máxima verosimilitud para m y σ^2 dadas por:

$$\hat{m} = \frac{1}{n} \sum_{i=1}^n x_i \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{w}_1)^2 \quad (3.17)$$

donde como se sabe n es el número de muestras disponibles en una clase.

El análisis del caso multivariable es básicamente muy similar, requiriendo mayor desarrollo matemático. El resultado es muy bien conocido en estadística donde las estimas de máxima verosimilitud para \mathbf{m} y C están dadas por:

$$\mathbf{m} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad C = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \mathbf{m})(\mathbf{x}_i - \mathbf{m})^t \quad (3.18)$$

Las expresiones anteriores indican que la estima de máxima verosimilitud para el vector media es la media simple. La estima de máxima verosimilitud para la matriz de covarianza es la media aritmética de las n matrices $(\mathbf{x}_i - \mathbf{m})(\mathbf{x}_i - \mathbf{m})^t$. Como se sabe que la verdadera matriz de covarianza es el valor esperado de la matriz $(\mathbf{x}_i - \mathbf{m})(\mathbf{x}_i - \mathbf{m})^t$, el resultado obtenido resulta satisfactorio según la teoría al respecto.

3.3.1.3 Teoría de la decisión de Bayes, el clasificador Bayesiano

La teoría de clasificación de Bayes se basa en el supuesto de que el problema de la decisión se enfoca en términos probabilísticos y que todas las probabilidades relevantes resultan conocidas.

A continuación se establece el mecanismo de decisión basado en este clasificador planteando las premisas generales.

Si se tienen que clasificar dos elementos X e Y cuya aparición es a priori aleatoria, es muy difícil predecir cuál será el siguiente en aparecer, ya que ambos elementos presentan la misma probabilidad. Si asignamos cada aparición de cada uno de los elementos a un estado, podemos definir un estado y de pertenencia. Por lo tanto

$y=X$ o $y=Y$, dependiendo del elemento que aparezca. Si como se ha comentado consideramos la aparición de cada uno de los elementos aleatoria, y será una variable aleatoria.

Ahora se puede establecer que existe alguna probabilidad a priori $P(y = X)$ de que aparezca X y alguna probabilidad a priori $P(y = Y)$ de que aparezca Y . Estas probabilidades reflejan el conocimiento a priori de que aparezca un elemento o el otro. Las dos probabilidades $P(y = X)$ y $P(y = Y)$ son no negativas y su suma es la unidad. (Duda y col. 2001).

Si en un instante determinado hubiera que tomar una decisión, la única información de la que se dispondría serían las probabilidades a priori establecidas anteriormente, por lo tanto a la hora de tomar una decisión, se decidiría X si $P(y = X)$ es mayor que $P(y = Y)$ y en caso contrario se decidiría Y .

A la hora de tomar una decisión, la gran mayoría de las veces no se toma una decisión con tan poca información. En general la decisión suele estar condicionada a más variables. Atendiendo a esta característica se puede considerar una variable aleatoria x cuya distribución depende del tipo de elemento, X o Y . Se pueden establecer $p(x / y = X)$ y $p(x / y = Y)$ como las funciones de densidad de probabilidad condicionales para x dado que el tipo de elemento sea X o Y .

Si se conocen tanto las probabilidades a priori como las funciones de densidad de probabilidad, la siguiente pregunta es ¿cómo influye la medida x en la toma de decisión al clasificar un elemento? Esta relación se puede establecer mediante la regla de Bayes:

$$p(y = X / x) = \frac{p(x / y = X)P(y = X)}{p(x)} \quad (3.19)$$

$$p(y = Y / x) = \frac{p(x / y = Y)P(y = Y)}{p(x)}$$

Donde

$$p(x) = p(x / y = X)P(y = X) + p(x / y = Y)P(y = Y) \quad (3.20)$$

La regla de Bayes muestra cómo la observación del valor x cambia las probabilidades a priori a las probabilidades a posteriori $p(y = A / x)$ y $p(y = M / x)$.

Una vez que se determinan esas probabilidades a posteriori, la siguiente regla (función discriminante) se utiliza para clasificar x .

$$fd(x) = \begin{cases} X & \text{si } p(x / y = X)P(y = X) > p(x / y = Y)P(y = Y) \\ Y & \text{de otro modo} \end{cases} \quad (3.21)$$

Si ahora se amplía el número de objetos (celdas) a clasificar hasta N y el número de atributos dados por el vector de atributos $\mathbf{x} = \{x_1, x_2, \dots, x_d\}$ estamos ante un problema de clasificación general. Utilizando el teorema de Bayes y considerando que tanto las probabilidades a priori $P(y = c_j)$ como las densidades condicionales para cada clase $p(\mathbf{x} / y = c_j)$ son conocidas o se pueden estimar, es posible determinar para una observación dada \mathbf{x} la probabilidad de que esa observación pertenezca a una determinada clase, suponiendo que existen c clases. Estas probabilidades, llamadas probabilidades a posteriori pueden usarse para construir una regla discriminante

$$p(y = c_j / \mathbf{x}) = \frac{p(\mathbf{x} / y = c_j)P(y = c_j)}{p(\mathbf{x})} \quad (3.22)$$

Donde

$$p(\mathbf{x}) = \sum_{j=1}^c p(\mathbf{x} / y = c_j) P(y = c_j) \quad (3.23)$$

A partir de la regla discriminante anteriormente planteada, dado \mathbf{x} la regla de decisión viene establecida por:

$$\mathbf{x} \in c_i \text{ sii } P(y = c_i / \mathbf{x}) > P(y = c_j / \mathbf{x}) \quad \forall i \neq j, \quad i, j = 1, 2, \dots, c \quad (3.24)$$

Fijándose en el segundo término de la expresión del teorema de Bayes y eliminando el término no discriminante $p(\mathbf{x})$, ya que no aporta nada a la decisión, se tiene una forma alternativa de clasificar el vector de atributos \mathbf{x} :

$$\mathbf{x} \in c_i \text{ sii } P(\mathbf{x} / y = c_i) P(y = c_i) > P(\mathbf{x} / y = c_j) P(y = c_j) \quad \forall i \neq j, \quad i, j = 1, 2, \dots, c \quad (3.25)$$

Generalmente las distribuciones de densidad de probabilidad se eligen Normales o Gaussianas. Un caso especial surge cuando las probabilidades a priori son iguales para todas las clases, ya que en esta situación la distancia de Mahalanobis (Maravall, 1993; Pajares y Cruz, 2007a) se puede utilizar como función discriminante mediante la siguiente regla de decisión a partir de la ecuación anterior y teniendo en cuenta el signo negativo en el término exponencial de la función de densidad de probabilidad Normal:

$$\mathbf{x} \in c_i \text{ sii } d_M^2(\mathbf{x}, \mathbf{m}_i) < d_M^2(\mathbf{x}, \mathbf{m}_j) \quad \forall i \neq j, \quad i, j = 1, 2, \dots, c \quad (3.26)$$

Donde \mathbf{m}_i , \mathbf{m}_j son los vectores media de las clases c_i y c_j respectivamente. Sin pérdida de generalidad, la distancia de un vector \mathbf{x}_k a la clase c_i resulta ser:

$$d_M^2(\mathbf{x}_k, \mathbf{m}_i) = (\mathbf{x}_k - \mathbf{m}_i)^t C_i^{-1} (\mathbf{x}_k - \mathbf{m}_i) \quad (3.27)$$

En el supuesto de que las matrices de covarianza sean la identidad, la distancia de Mahalanobis al cuadrado resulta ser la distancia euclídea al cuadrado, en cuyo caso se tiene:

$$d_E^2(\mathbf{x}, \mathbf{m}_i) = (\mathbf{x} - \mathbf{m}_i)^t (\mathbf{x} - \mathbf{m}_i) = \mathbf{x}^t \mathbf{x} - 2\mathbf{x}^t \mathbf{m}_i + \mathbf{m}_i^t \mathbf{m}_i \quad (3.28)$$

En la expresión anterior el término $\mathbf{x}^t \mathbf{x}$ no discrimina, ya que se repite en todas las clases, de forma que puede suprimirse. Si se cambia de signo y se divide por 2 en la ecuación anterior se obtiene la siguiente función discriminante:

$$fd_i(\mathbf{x}) = \mathbf{x}^t \mathbf{m}_i - \frac{1}{2} \mathbf{m}_i^t \mathbf{m}_i \quad (3.29)$$

Al haber eliminado el término $\mathbf{x}^t \mathbf{x}$ y cambiado de signo los restantes, se deduce que la distancia euclídea al cuadrado mínima hace la expresión anterior máxima.

3.3.2. Teoría del clasificador no paramétrico. Ventana de Parzen

A diferencia de la estimación paramétrica, donde la función de densidad de probabilidad (*fdp*) se obtiene estimando los parámetros desconocidos (\mathbf{m} , C) de un modelo conocido (*fdp* Gaussiana), en la estima no paramétrica no se conoce el modelo. Las técnicas no paramétricas son básicamente variaciones de la aproximación del histograma de una *fdp* desconocida.

Se considera el caso unidimensional. A continuación se muestran dos ejemplos de una *fdp* y su aproximación por el método del histograma, esto es, el eje x (espacio unidimensional) se divide primero en intervalos de longitud h .

La probabilidad de una muestra x localizada en un intervalo se puede deducir fácilmente. Si N es el número total de muestras y una fracción de ellas k_N se sitúan dentro de uno de los intervalos, la correspondiente probabilidad se aproxima por la *razón de frecuencia*:

$$P \approx k_N / N \quad (3.30)$$

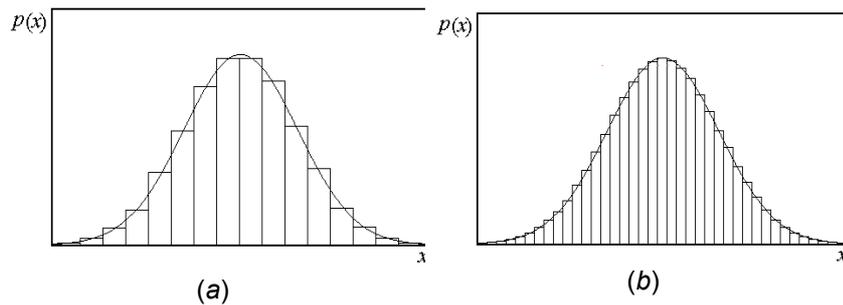


Figura 3-2: Aproximación de la función de densidad de probabilidad por el método del histograma con (a) intervalos de longitud grande y (b) pequeña.

Esta aproximación tiende a la verdadera probabilidad P a medida que $N \rightarrow \infty$. El correspondiente valor de la *fdp* se considera constante a lo largo del intervalo y se aproxima por:

$$\hat{p}(x) \equiv \hat{p}(\hat{x}) \approx \frac{1}{h} \frac{k_N}{N}, \quad |x - \hat{x}| \leq \frac{h}{2} \quad (3.31)$$

Donde \hat{x} es el punto medio del intervalo. Esto determina la amplitud de la curva del histograma sobre el intervalo. Ésta es una aproximación razonable para $p(x)$ continua y h suficientemente pequeña. Se puede demostrar que $\hat{p}(x)$ converge hacia el verdadero valor $p(x)$ a medida que $N \rightarrow \infty$ dado que:

$$\begin{aligned}
 h_N &\rightarrow 0 \\
 k_N &\rightarrow \infty \\
 \frac{k_N}{N} &\rightarrow 0
 \end{aligned}
 \quad (3.32)$$

Se introduce h_N para mostrar la dependencia de N . Estas condiciones se pueden comprender sin grandes detalles matemáticos. La primera ya ha sido discutida. Las otras dos muestran la forma en la que debe crecer k_N para garantizar la convergencia. En todos los puntos donde $p(x) \neq 0$, una vez fijada la dimensión h_N suficientemente pequeña, la probabilidad P de los puntos que caen en este intervalo es finita. Además, $k_N \approx PN$ y k_N tiende a infinito a medida que N crece a infinito. Por otra parte, a medida que la dimensión h_N del intervalo tiende a cero, la correspondiente probabilidad también tiende a cero, justificando la última condición. En la práctica el número N de datos es finito. Las condiciones precedentes dan idea de cómo deben elegirse los diferentes parámetros. N debe ser suficientemente grande, h_N suficientemente pequeño y el número de puntos dentro de cada intervalo también suficientemente grande. Cómo de grandes o pequeños depende del tipo de *fdp* y del grado de aproximación que se desea. A continuación se describe el método de la *Ventana de Parzen*.

En el caso multidimensional, en lugar de intervalos de dimensión h , el espacio p -dimensional se divide en hipercubos con la longitud de los lados h y volumen h^p . Sean \mathbf{x}_i , $i = 1, 2, \dots, N$ los vectores de atributos disponibles. Definimos la función $\phi(\mathbf{x})$ de modo que:

$$\phi(\mathbf{x}_i) = \begin{cases} 1 & \text{para } |x_{ij}| \leq \frac{1}{2} \\ 0 & \text{en otros casos} \end{cases} \quad (3.33)$$

Donde x_{ij} , $j = 1, \dots, d$ son las componentes de \mathbf{x}_i . En otras palabras, la función es igual a 1 para todos los puntos dentro del hipercubo de lado la unidad centrado en el origen y 0 fuera de él.

Con esto se puede obtener la siguiente ecuación:

$$\hat{p}(\mathbf{x}) = \frac{1}{h^p} \left(\frac{1}{N} \sum_{i=1}^N \phi \left(\frac{\mathbf{x}_i - \mathbf{x}}{h} \right) \right) \quad (3.34)$$

La interpretación de esta ecuación es sencilla, consideramos un hipercubo con longitud de lado h centrado en \mathbf{x} , que es el punto donde queremos estimar la *fdp*. La suma es k_N , es decir, el número de puntos que caen dentro del hipercubo. La estima de la *fdp* se obtiene dividiendo k_N por N y el respectivo volumen del hipercubo h^p . No obstante, volviendo a la ecuación y viéndola desde una perspectiva diferente, se puede observar que se está intentando aproximar una función continua $p(\mathbf{x})$ mediante una expansión de términos de funciones discontinuas $\phi(\cdot)$. Esto conduce a la generalización de la ecuación anterior propuesta por Parzen (1962) utilizando funciones continuas en lugar de $\phi(\cdot)$. Dichas funciones son conocidas como núcleos o funciones potenciales o ventanas de Parzen. Ejemplos típicos de funciones de este tipo son los núcleos Gaussianos:

$$p(\mathbf{x}) = \frac{1}{n} \sum_{j=1}^n \left\{ \frac{1}{(2\pi)^{p/2} |C|^{1/2} h^p} \exp \left[-\frac{1}{2h^2} (\mathbf{x} - \mathbf{x}_j)^T C^{-1} (\mathbf{x} - \mathbf{x}_j) \right] \right\} \quad (3.35)$$

Una vez estimadas las funciones de densidad de probabilidad para cada una de las c_1, c_2, \dots, c_c clases a través de núcleos Gaussianos, la clasificación de una muestra \mathbf{x} se lleva a cabo mediante la siguiente regla de decisión,

$$\mathbf{x} \in c_i \quad \text{sii} \quad p_i(\mathbf{x}) > p_j(\mathbf{x}) \quad \forall j \neq i \quad (3.36)$$

3.3.3. Utilización de los clasificadores estadísticos para la clasificación de las celdas de cultivo

Tanto el clasificador de Bayes paramétrico como la ventana de Parzen se han utilizado en nuestras investigaciones para la clasificación de las celdas de cultivo, bien por sí solos (Tellaeché y col., 2007a) o en combinación bajo la filosofía de hibridación (Tellaeché y col., 2007b y d).

Al igual que para el método basado SVM, para el empleo del clasificador estadístico se han utilizado únicamente las relaciones cuantitativas de las celdas de cultivo y por tanto las muestras de entrenamiento contenidas en: RC_{pulv} y RC_{nopulv} . Éstos son los datos que utilizará este clasificador como valores para obtener los parámetros estadísticos necesarios para su funcionamiento. Con el fin de preservar la terminología original de Duda y col. (2001) la clase de celdas a pulverizar que previamente se ha denominado como CP se identifica ahora como w_y , mientras que la de las celdas a no pulverizar denominada como CN se identifica ahora como w_n .

Como siempre, cada una de las celdas de entrada para clasificar es definida mediante su vector de relaciones cuantitativas x_i .

Se calculan la media y la matriz de covarianza de los vectores contenidos en los conjuntos de muestras RC_{pulv} y RC_{nopulv} , con estos valores obtenidos, dependiendo del clasificador que se utilice, se lleva a cabo una estrategia diferente para tomar la decisión sobre si una celda debe ser pulverizada o no.

Cuando se utilizan clasificadores estadísticos, uno de los principales problemas es la estimación de las funciones de densidad de probabilidad condicionada a las clases de decisión $p(x/w_y)$ y $p(x/w_n)$ y las probabilidades a priori $P(w_y)$ y $P(w_n)$ (Duda y col., 2001). La función de densidad de probabilidad $p(x)$ puede ser modelada como

una función de densidad mixta, con dos componentes de densidad asociados a las clases w_y y w_n respectivamente:

$$p(\mathbf{x}) = p(\mathbf{x}/w_y)P(w_y) + p(\mathbf{x}/w_n)P(w_n) \quad (3.37)$$

3.3.3.1 Clasificador no paramétrico de la ventana de Parzen

Como se ha explicado en apartados precedentes, este clasificador trabaja en dos pasos bien diferenciados, primero realizando un proceso de entrenamiento, referido como *off-line*, con los datos RC_{pulv} y RC_{nopulv} estimando una función de densidad de probabilidad. En una segunda fase *on-line* se toma la decisión de pulverizar o no cada una de las nuevas celdas que se presentan, basada en la función de densidad de probabilidad estimada en el paso anterior.

Etapa off-line: Entrenamiento

El problema comienza con la observación del conjunto X de N muestras disponibles etiquetadas según su pertenencia a las clases w_y y w_n con u y v muestras respectivamente hasta completar el total de N . Cada celda i es identificada con el vector de relaciones de área \mathbf{x}_i . Sin pérdida de generalidad y por simplicidad, de ahora en adelante nos referiremos a este vector como \mathbf{x} sin el subíndice i .

Bajo la perspectiva de este clasificador estadístico los dos principales problemas a resolver son:

1. La estima de las funciones de densidad de probabilidad condicionadas a una clase $p(\mathbf{x} | w_y)$ y $p(\mathbf{x} | w_n)$.
2. La obtención de las probabilidades *a priori* $P(w_y)$ y $P(w_n)$ de pertenencia de \mathbf{x} a cada una de estas clases respectivamente.

La función de densidad de probabilidad puede ser modelada como una distribución de densidad mixta consistente en dos componentes asociados a las clases w_y y w_n respectivamente.

$$p(\mathbf{x}) = p(\mathbf{x} | w_y)P(w_y) + p(\mathbf{x} | w_n)P(w_n) \quad (3.38)$$

Existen dos métodos posibles para la estima de $p(\mathbf{x}/w_y)$ y $p(\mathbf{x}/w_n)$ (Duda y col., 2001): paramétrico y no paramétrico. En nuestros experimentos hemos comprobado que las estimas mediante el clasificador no paramétrico generalmente producen mejores resultados que las estimas paramétricas asumiendo distribuciones Gaussianas como por otra parte se informa en Parzen (1962) o Coultrip y Granger (1994). En el caso que nos ocupa, esto es así porque las muestras utilizadas no parece que cumplan la ley de distribución Gaussiana, presentando importantes desviaciones.

Recordando que la clase $CP(w_y)$ contiene u muestras y la $CN(w_n)$ v muestras, siendo $N = u + v$, mediante la ventana de Parzen se estiman las respectivas funciones de densidad de probabilidad en \mathbf{x} (Jain y Rawaswami, 1998) como sigue:

$$p(\mathbf{x}/w_y) = \frac{1}{u} \sum_{j=1}^u K_h(\mathbf{x} - \mathbf{x}_j^y) \text{ y } p(\mathbf{x}/w_n) = \frac{1}{v} \sum_{j=1}^v K_h(\mathbf{x} - \mathbf{x}_j^n) \quad (3.39)$$

donde \mathbf{x}_j^y y \mathbf{x}_j^n se refieren a las muestras en las respectivas clases w_y y w_n ; además

$K_h(\mathbf{z}) = K(\mathbf{z}/h)/V_h$ y $K(\cdot)$ es la función ventana o núcleo con $\int_{-\infty}^{+\infty} K(t)dt = 1$, para

asegurar que el área bajo la función de densidad de probabilidad es 1 y h es el ancho de

ventana o el parámetro de suavizado, $h > 0$ (Fukunaga y Hummels, 1987). Este núcleo

obtiene la influencia del patrón de entrenamiento \mathbf{x}_j ejercida sobre el patrón teórico \mathbf{x}

dependiendo de la anchura y forma del núcleo. Esta influencia debe ser modelada para

que los patrones que quedan cerca de \mathbf{x} contribuyan más en la función estimada para \mathbf{x} que los patrones que se encuentran lejos de \mathbf{x} . Una distancia métrica puede solucionar este problema. Las ecuaciones anteriores de estimación de la ventana de Parzen pueden ser interpretadas como un centrado del núcleo K sobre cada patrón de entrenamiento y una suma de todos los puntos superpuestos en cada punto \mathbf{x} del espacio. Por lo tanto, este proceso de centrado de núcleos sobre los patrones de entrenamiento y su suma puede ser considerado como una convolución (Coultrip y Granger, 1994). Las propiedades de este estimador pueden encontrarse en Duda y col. (2001).

La forma del núcleo no es tan importante como su anchura en la estima de la densidad. Hay diferentes tipos de funciones para definir el núcleo (Escudero, 1977). El núcleo elegido ha sido el Gaussiano por las siguientes razones:

1. Con dicho núcleo, se tiene información sobre la correlación cruzada entre los dos atributos a través de la matriz de covarianza C_c , ya sea la covarianza de las celdas a pulverizar o la de las celdas a no pulverizar.
2. La segunda es que este núcleo presenta propiedades analíticas muy convenientes.
3. La tercera es que utiliza la distancia de Mahalanobis, $d_M(\mathbf{x}, \mathbf{x}_j^c) = (\mathbf{x} - \mathbf{x}_j^c)^t C_c^{-1} (\mathbf{x} - \mathbf{x}_j^c)$ para determinar la influencia ejercida por cada \mathbf{x}_j^c sobre \mathbf{x} . Esta distancia toma en cuenta la dispersión de las muestras en la clase.

Teniendo en cuenta los puntos anteriores, se puede obtener la siguiente función de densidad:

$$p(\mathbf{x}/w_c) = \frac{1}{n_c} \sum_{j=1}^{n_c} \left\{ \frac{1}{(2\pi)^{d/2}} \frac{1}{h_c^{n_c} |C_c|^{1/2}} \exp \left[\frac{-1}{2h_c^2} (\mathbf{x} - \mathbf{x}_j^c)^t C_c^{-1} (\mathbf{x} - \mathbf{x}_j^c) \right] \right\} \quad (3.40)$$

donde c hace referencia a una de las dos clases (y, n); d es la dimensión del espacio de patrones, en este caso $d = 2$ ya que el número de atributos cuantitativos es dos y por tanto la dimensión de los vectores $\mathbf{x} = (a_{i0}, a_{i1})$ es dos; t indica transposición de matrices; n_c se refiere al número de muestras en cada clase, siendo como ya se ha mencionado previamente $n_y = u$ y $n_n = v$. Cada función de núcleo considera una posible correlación cruzada entre atributos a través de C y también que las muestras están alrededor del patrón teórico \mathbf{x}_j^c , donde el vector medio para cada núcleo resulta ser el mismo patrón.

El parámetro de suavizado h_c se expresa como una función del número de patrones:

$$h_c = hn_c^{-\frac{k}{d}} \text{ para } 0 \leq k \leq 0.5 \text{ y } c = y, n \quad (3.41)$$

La elección del ancho de banda h es muy crítico en la estima de la densidad de Parzen (Duin, 1976). Un valor pequeño de h produce una estima ruidosa de $p(\mathbf{x}/w_c)$, con cada pico correspondiendo a los patrones de entrenamiento.

Cuando el valor de h es muy elevado, cada patrón de entrenamiento proporciona básicamente la misma contribución para la estima de densidad en cada uno de los puntos \mathbf{x} , y el resultado es una estima muy suavizada de $p(\mathbf{x}/w_c)$. Como se explica en Duin (1976), el parámetro del ancho de la ventana se fija de acuerdo con los conjuntos de datos obtenidos de las imágenes procesadas. Una discusión más en profundidad de la anchura de la ventana se puede encontrar en Duda y col. (2001), Escudero (1977) y Jain y Ramaswami (1988).

En Duda y col., 2001, se puede encontrar un caso de clasificación bi-dimensional, como el llevado a cabo en nuestra investigación, donde la ventana de Parzen se estima con un núcleo Gaussiano y donde se obtienen buenos resultados con $n_c = 256$ y $h = 1$, aunque los mejores resultados se obtienen cuando $n_c \rightarrow +\infty$ para cualquier valor de h .

Todavía queda por determinar el valor del parámetro k implicado en la ecuación (3.41), para su obtención se aplica una estrategia de validación cruzada (cross validation), que puede encontrarse descrita en Duda y col. (2001). En la sección 4.10.1 se detalla con precisión la estrategia seguida para su aplicación en la decisión sobre celdas en cultivos de maíz. El valor finalmente obtenido es $k = 0.3$, que resulta ser un valor válido de forma general en otros cultivos y aproximaciones.

Como se ha explicado anteriormente, $p(\mathbf{x}/w_c)$ es estimada para cada \mathbf{x} en el espacio bidimensional. Todavía es necesaria una red de valores teóricos \mathbf{x} a ajustar, así como el número de muestras de patrones pertenecientes al círculo centrado en cada \mathbf{x} y por último, la matriz de covarianza C_c para las muestras en el círculo correspondiente.

El método seguido se puede resumir en los siguientes pasos:

1. Para cada clase w_y y w_n se calcula el vector correspondiente de medias, \mathbf{m}^c , con $c=y,n$.
2. Para cada clase, determinar el número de muestras patrón de entrenamiento pertenecientes al círculo centrado en cada \mathbf{m}^c . Un patrón de muestra \mathbf{x}_j^c pertenece al círculo si $|(x_{ji}^c - m_i^c)/h| \leq 1$ donde i identifica cada componente del vector de atributos cuantitativos. De esta forma $Y^c \equiv \{\mathbf{y}_1^c, \mathbf{y}_2^c, \dots, \mathbf{y}_{N_c}^c\}$ del total de las n_c (u o v) muestras de cada clase que cumplen esta condición, teniendo en cuenta que $N_c < n_c$.
3. Con los conjuntos Y^c se calcula la matriz de covarianza de acuerdo con Duda y col. (2001).

$$C_c = \frac{1}{N_c - 1} \sum_{j=1}^{N_c} (\mathbf{y}_j^c - \mathbf{m}^c)(\mathbf{y}_j^c - \mathbf{m}^c)^t \quad (3.42)$$

Etapa on-line: toma de decisión.

Durante el proceso de decisión se procesan nuevas imágenes y por tanto, nuevas celdas, debiendo tomar una decisión sobre ellas. Con este propósito se recuperan las funciones de densidad de probabilidad condicionadas a una clase estimadas durante el procesamiento *off-line*.

Ahora, dada una nueva celda s con sus atributos contenidos en el vector de atributos cuantitativos \mathbf{x} , el problema es decidir a cuál de las clases pertenece. Esto se realiza aplicando la regla de Bayes, para obtener la probabilidad *a posteriori* $P(w_c/\mathbf{x})$.

$$P(w_c/\mathbf{x}) = \frac{p(\mathbf{x}/w_c)P(w_c)}{p(\mathbf{x})}, \quad c = y, n \quad (3.43)$$

Por lo que la decisión se puede expresar mediante la siguiente regla:

$$s \in w_y \quad \text{if} \quad P(w_y/\mathbf{x}) > P(w_n/\mathbf{x}); \quad \text{de otro modo} \quad s \in w_n \quad (3.44)$$

La regla de decisión anterior se puede reescribir eliminando el denominador $p(\mathbf{x})$ que aparece en la ecuación (3.43) ya que este término aparece en ambos miembros de la inecuación:

$$s \in w_y \quad \text{si} \quad p(\mathbf{x}/w_y)P(w_y) > p(\mathbf{x}/w_n)P(w_n); \quad \text{de otro modo} \quad s \in w_n \quad (3.45)$$

En resumen, para la decisión se utiliza la función de densidad de probabilidad bien obtenida por estimación paramétrica o bien no paramétrica, pero todavía es necesario obtener las probabilidades *a priori* $P(w_y)$ y $P(w_n)$ de alguna manera cuando esto sea posible. En los experimentos descritos en este trabajo se han propuesto dos

estrategias para su obtención. La primera es la propuesta para los campos de cereal mediante la combinación de clasificadores descritas en las secciones 3.6.1 y 3.6.2. La segunda es la propuesta para los campos de maíz tal y como se describe en la sección 4.4.2. Cuando no se pueden obtener por ningún procedimiento se fijan a un valor dado, que normalmente es 0.5 ya que es el valor intermedio en el rango de valores de probabilidad [0,1].

Otra de las mejoras de este clasificador con respecto a otras estrategias existentes (donde la decisión es sencillamente sí o no) es la siguiente: el valor de la probabilidad a posteriori $P(w_c | \mathbf{x})$ da información sobre el grado de pertenencia de \mathbf{x} a cada clase, esto permite determinar la cantidad de herbicida a aplicar sobre la celda que está siendo procesada.

3.4. Clasificación mediante agrupamiento borroso o Fuzzy Clustering

Un método clásico en clasificación es el conocido como agrupamiento borroso o “*Fuzzy Clustering*”. Según este método se establece el concepto de *grado de pertenencia*, de suerte que una muestra puede pertenecer a varias clases a la vez con distintos valores del grado de pertenencia.

3.4.1. Teoría del agrupamiento borroso.

La técnica de agrupamiento borroso, tiene como objetivo dividir N objetos $\mathbf{x} \in X$ caracterizados por p propiedades en c clústeres o grupos. Se parte del ya conocido conjunto de datos $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\} \in \mathfrak{R}^p$ un subconjunto del espacio real p -dimensional \mathfrak{R}^p . Cada \mathbf{x}_k es un vector de características donde x_{k_j} es la j -ésima característica del vector \mathbf{x}_k , en nuestro caso $p = 2$ dada la dimensionalidad de los vectores de área.

Los elementos de un determinado *clúster* deben ser tan similares entre ellos como sea posible, y a la vez lo más diferentes posibles de los elementos de los otros clústeres. Por este motivo, la similitud o diferencia de dos puntos cualquiera, x_k y x_j , puede interpretarse como la distancia entre esos dos puntos.

La distancia entre dos vectores patrón x_k y x_j se define como una función que toma valores reales $d : X \times X \rightarrow R^+$ cumpliendo la siguiente condición:

$$d(x_k, x_l) = d_{kl} \geq 0; \quad d_{kl} = 0 \Leftrightarrow x_k = x_l; \quad d_{kl} = d_{lk} \quad \text{y} \quad d_{kl} \leq d_{kj} + d_{jl} \quad (3.46)$$

Cada partición del conjunto $X = \{x_1, x_2, \dots, x_N\}$ se puede enfocar desde dos perspectivas, *fuzzy* y no *fuzzy*. La partición no *fuzzy* se conoce en la literatura especializada como partición *crisp*. A la hora de realizar una partición de un determinado conjunto X en c clústeres se obtendrá un determinado número de conjuntos $S_i \{i = 1, \dots, c\}$.

A partir de esta consideración, se establece como grado de pertenencia μ_{ik} de un objeto x_k a un determinado subconjunto S_i . En caso de conjuntos no *fuzzy* o *crisp*, un determinado patrón representado por x_k se dice que pertenece a un determinado S_i y no pertenece al resto. Esta pertenencia se expresa con los valores discretos, siendo $\mu_{ik} = 1$ para indicar que el objeto pertenece a un subconjunto y $\mu_{ik} = 0$ para indicar que no pertenece. En el caso de los conjuntos *borrosos (fuzzy)* por el contrario, un mismo patrón con vector x_k puede pertenecer a diferentes conjuntos, pudiéndose establecer por ejemplo que un objeto puede pertenecer a diferentes subconjuntos y así se habla por ejemplo de que x_k pertenece a un conjunto S_i con grado de pertenencia

μ_{ik} y a S_j con grado de pertenencia μ_{jk} . En este caso, los valores de pertenencia están restringidos al intervalo continuo $[0,1]$. La suma de los valores de pertenencia de un patrón \mathbf{x}_k a diferentes subconjuntos debe ser la unidad.

Dado $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ y el conjunto V_{cN} de todas las matrices reales de dimensión $c \times N$, con $2 \leq c < N$. Se puede obtener una matriz representando la partición de la siguiente manera $U = \{\mu_{ik}\} \in V_{cN}$. Tanto en el supuesto “*crisp*” como en el *fuzzy* se deben cumplir las siguientes condiciones:

$$1. \mu_{ik} \in \{0,1\} \text{ crisp o } \mu_{ik} \in [0,1] \text{ fuzzy} \quad 1 \leq i \leq c; \quad 1 \leq k \leq N \quad (3.47)$$

$$2. \sum_{i=1}^c \mu_{ik} = 1 \quad 1 \leq k \leq N \quad (3.48)$$

$$3. 0 < \sum_{k=1}^n \mu_{ik} < N \quad 1 \leq i \leq c \quad (3.49)$$

La localización de un clúster S_i se representa por su centro $\mathbf{v}_i = \{v_{i_1}, v_{i_2}, \dots, v_{i_p}\} \in \mathfrak{R}^p$ con $i = 1, \dots, c$, alrededor del cual se concentran los patrones.

Uno de los criterios ampliamente utilizados para obtener buenas particiones es el denominado criterio de la varianza que mide las desviaciones de las muestras patrón en un clúster respecto de su media o centro. Estas medidas se pueden llevar a cabo por medio de distancias. Por tanto aplicando el criterio de la varianza al problema de la partición borrosa para $m > 1$ el problema se reduce a minimizar la función objetivo dada por la siguiente ecuación:

$$\min z_m(U; \mathbf{v}) = \sum_{k=1}^N \sum_{i=1}^c \mu_{ik}^m \|\mathbf{x}_k - \mathbf{v}_i\|_G^2 \quad (3.50)$$

donde G es una matriz de dimensión $p \times p$ simétrica y definida positiva. Así se puede definir una norma general del tipo:

$$\|\mathbf{x}_k - \mathbf{v}_i\|_G^2 = (\mathbf{x}_k - \mathbf{v}_i)^t G (\mathbf{x}_k - \mathbf{v}_i) \quad (3.51)$$

Diferenciando la función objetivo para \mathbf{v}_i (suponiendo constante U) y μ_{ik} (suponiendo constante \mathbf{v}_i) y aplicando la condición de que $\sum_{i=1}^c \mu_{ik} = 1$, se obtiene:

$$\mathbf{v}_i = \frac{1}{\sum_{k=1}^N (\mu_{ik})^m} \sum_{k=1}^N (\mu_{ik})^m \mathbf{x}_k \quad i = 1, \dots, c \quad (3.52)$$

$$\mu_{ik} = \frac{\left(\frac{1}{\|\mathbf{x}_k - \mathbf{v}_i\|_G^2} \right)^{2/m-1}}{\sum_{j=1}^c \left(\frac{1}{\|\mathbf{x}_k - \mathbf{v}_j\|_G^2} \right)^{2/m-1}} \quad i = 1, \dots, c; k = 1, \dots, n \quad (3.53)$$

el exponente m se conoce como peso exponencial y disminuye la influencia del ruido al obtener los centros de los clústeres, reduciendo la influencia de los valores pequeños de μ_{ik} (puntos lejos de \mathbf{v}_i) frente a valores altos de μ_{ik} (puntos cercanos a \mathbf{v}_i). Cuanto mayor sea $m > 1$ mayor es dicha influencia. En nuestro caso $c = 2$ puesto que el número de clústeres es dos (pulverizar y no pulverizar).

Uno de los más conocidos algoritmos para el agrupamiento "crisp" es el algoritmo conocido como C-medias o ISODATA. Existe su versión borrosa, que se sintetiza a continuación:

1. Elegir c ($2 \leq c \leq N$), m ($1 < m < \infty$) y la matriz G de dimensión $p \times p$ siendo simétrica y definida positiva. Inicializar $U^{(0)}$ y poner $t = 0$.
2. Calcular los c centros fuzzy de los clústeres $\{\mathbf{v}_i^{(t)}\}$ utilizando $U^{(t)}$

3. Calcular los nuevos grados de pertenencia de la matriz $U^{(t+1)}$ utilizando $\{v_i^{(t)}\}$ a partir de la última condición para el cálculo de μ_{jk} si $x_k \neq v_i^{(t)}$. De lo contrario establecer:

$$\mu_{jk} = \begin{cases} 1 & j = i \\ 0 & j \neq i \end{cases} \quad (3.54)$$

4. Elegir una norma matricial y calcular $\Delta = \|U^{(t+1)} - U^t\|_G$. Si $\Delta > \varepsilon$ poner $t = t + 1$ y regresar al paso 2, de lo contrario detener el proceso.

Como conclusión, para llevar a cabo un proceso de agrupamiento es necesario definir el número de *clústers* c ; el peso exponencial m , siendo generalmente un valor típico de dos; la matriz G que induce la norma; el método para inicializar $U^{(0)}$ y el criterio de terminación $\Delta \leq \varepsilon$.

La matriz G determina la forma del clúster. Si se elige la norma Euclídea, entonces G se corresponde con la matriz identidad I y los clústeres asumen forma de hipersfera. G también puede ser una matriz diagonal tal que $G_D = [\text{diag}(\sigma_j^2)]^{-1}$, o puede definirse mediante la norma de Mahalanobis con $G_M = [\text{cov}(x)]^{-1}$, donde σ_j^2 es la varianza de la característica j y cov la covarianza.

3.4.2. Utilización del método de agrupamiento borroso para la clasificación de celdas de cultivo

El problema a resolver mediante *Fuzzy Clustering* en la presente tesis es la clasificación de las celdas de entrada del sistema en celdas a pulverizar o a no pulverizar.

En el sistema existe una base de datos con celdas modelo a pulverizar y a no pulverizar, por lo tanto, se establecen dos *clústers* correspondientes a cada grupo de celdas modelo. Es decir, los habituales conjuntos CP y CN con sus atributos RC_{pulv} y RC_{nopulv} respectivamente.

Las celdas modelo a pulverizar tienen asignado un grado de pertenencia con valor la unidad al *clúster* correspondiente a pulverizar, y grado de pertenencia 0 al *clúster* correspondiente a no pulverizar. Las celdas modelo a no pulverizar tendrán los grados de pertenencia opuestos, 1 para el *clúster* de no pulverizar y 0 para el *clúster* de celdas a pulverizar.

Una vez establecidos estos grados de pertenencia de las celdas modelo a cada uno de los dos *clústers*, y como consecuencia la matriz inicial U , se aplica el algoritmo descrito previamente hasta obtener por un lado los centros de cada *clúster* v_1 y v_2 según la ecuación (3.52) asociados a las conocidas clases w_y y w_n respectivamente. Simultáneamente, mediante la ecuación (3.53) se obtienen los grados de pertenencia de las muestras a los dos *clústeres*.

Fijada una norma, la decisión sobre si pulverizar una celda dada s con vector de atributos x se establece en función de la regla que determina que s pertenece a la clase cuyo grado de pertenencia sea mayor. Estos grados de pertenencia se obtienen a través de la ecuación (3.53). Adicionalmente, en función del valor del grado de pertenencia se determina la cantidad de herbicida a aplicar teniendo en cuenta que los valores de dichos grados varían en el rango $[0,1]$.

3.5. El clasificador Hebbiano

Otro de los métodos de decisión para determinar si se pulveriza o no una determinada celda es el proporcionado por el clasificador basado en el denominado

aprendizaje Hebbiano. Por aplicación del postulado de Hebb, este clasificador tiene capacidades autoorganizativas, clasificando los datos alrededor de los centros de los clústeres sin supervisión (Haykin, 1994; Kosko, 1992).

3.5.1. Teoría del clasificador Hebbiano

Consideremos un par de nodos j y k conectados entre sí mediante el peso sináptico w_{kj} , de forma que el nodo j recibe una señal $x_j(n)$ en el tiempo n , mientras el nodo k genera una señal de salida, también en el tiempo n , $y_k(n)$. Estas señales se conocen en la terminología de redes neuronales como actividades presináptica y postsináptica respectivamente. En la figura 3-3 se muestra un esquema simple de este clasificador,

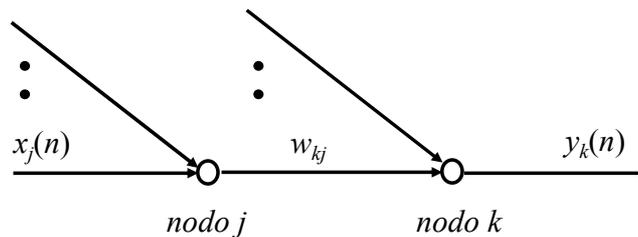


Figura 3-3: diagrama de flujo mostrando la conexión entre dos nodos de una red.

De acuerdo con el mencionado postulado de Hebb, el ajuste aplicado al peso sináptico w_{kj} en el tiempo n se puede expresar de la siguiente forma:

$$\Delta w_{kj}(n) = F(y_k(n), x_j(n)) \quad (3.55)$$

Donde $F(\cdot, \cdot)$ es una función de actividades presinápticas y postsinápticas. Los términos de actividad $x_j(n)$ e $y_k(n)$ son tratados como variables adimensionales.

Como un caso especial, la ecuación anterior se puede reescribir de la siguiente manera:

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n) \quad (3.56)$$

Donde η es una constante que determina la razón de aprendizaje. La ecuación anterior es la regla más simple para un cambio en el peso sináptico w_{kj} , expresado como un producto de señales de entrada y de salida. Esta regla enfatiza claramente la naturaleza correlacional de una sinapsis Hebbiana, y es referida algunas veces como regla de productos de actividades.

La línea superior de la figura 3-4 muestra una representación gráfica de la ecuación anterior, con el cambio Δw_{kj} representado respecto a la entrada x_j .

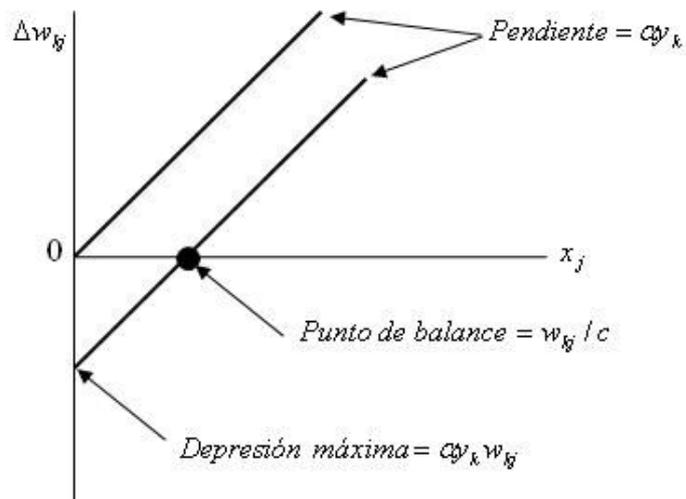


Figura 3-4: Regla de Hebb y su modificación de acuerdo a la ecuación anterior.

A partir de esta representación se puede observar que la aplicación repetida de la señal de entrada (actividad presináptica) x_j produce un crecimiento exponencial que

finalmente lleva al peso sináptico w_{kj} a la saturación. Para evitar estas situaciones es necesario establecer un límite para el aumento de los pesos sinápticos. Un método para lograr esto es la introducción de un factor de olvido no lineal en la fórmula para el ajuste sináptico de $\Delta w_{kj}(n)$. Más concretamente, $\Delta w_{kj}(n)$ se redefine de la manera siguiente (Kohonen 1988):

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n) - \alpha y_k(n) w_{kj}(n) \quad (3.57)$$

donde α es una nueva constante positiva y $w_{kj}(n)$ es el peso sináptico en el tiempo n .

De manera equivalente, se puede escribir:

$$\Delta w_{kj}(n) = \alpha y_k(n) [c x_j(n) - w_{kj}(n)] \quad (3.58)$$

Donde c es equivalente a η / α . La ecuación anterior es referida generalmente como regla de productos de actividades generalizada. Esta ecuación implica que para entradas para las cuales $x_j(n) < w_{kj}(n) / c$, el peso sináptico modificado $w_{kj}(n+1)$ en el tiempo $n+1$ decrecerá en una cantidad proporcional a la actividad postsináptica $y_k(n)$, como se ilustra en la línea inferior de la figura 3-4. Por otro lado cuando $x_j(n) > w_{kj}(n) / c$, el peso sináptico modificado $w_{kj}(n+1)$, se incrementa en proporción a $y_k(n)$. El punto de balance de actividad para modificar el peso sináptico en el tiempo $n+1$ es una variable, equivalente a w_{kj} / c , proporcional al valor de w_{kj} en el tiempo de activación presináptica. El uso de esta aproximación elimina el problema de inestabilidad de pesos.

3.5.2. Utilización del clasificador Hebbiano para la clasificación de celdas de cultivo

El objetivo de este clasificador, como en los casos anteriores es clasificar las celdas obtenidas a partir del tratamiento de la imagen de los campos de cultivo como pulverizables o no, por lo tanto es un problema de clasificación bi-clase.

El clasificador Hebbiano es un método adecuado con capacidades autoorganizativas, en el cual los datos pueden ser clasificados en clases sin supervisión. Como cualquiera de las estrategias anteriores, este clasificador trabaja en dos etapas: etapa de entrenamiento (*off-line*) y toma de decisiones (*on-line*). En el problema a resolver, el objetivo es la agrupación de datos en dos clústeres: w_y (pulverizar) y w_n (no pulverizar), es decir los habituales conjuntos CP y CN . Los centros respectivos de estos *clusters*, $v^y \equiv v_1$ y $v^n \equiv v_2$ son estimados durante la etapa *off-line*. Los centros de los clústeres estimados son almacenados en la BC y recuperados para llevar a cabo la decisión mediante la regla de decisión durante la etapa *on-line*.

3.5.2.1 Etapa *off-line*: entrenamiento

Dada una celda i , se representa por su vector de área $x_i = \{x_{i1}, \dots, x_{in}\}$, por lo tanto, los centros de los clústeres son r -dimensionales $v^c = \{v_1^c, \dots, v_r^c\}$, $c = y, n$. El proceso de entrenamiento se puede sintetizar en los puntos siguientes:

1. Sea $X = \{x_1, x_2, \dots, x_N\}$ un grupo de vectores de atributos representando celdas $i = 1, 2, \dots, N$. Bajo la supervisión del criterio experto, este grupo se divide en dos subgrupos X^y y X^n con $X = X^y \cup X^n$. Por lo tanto, si $x_i \in X^y / X^n$, la celda i pertenece al clúster w_y / w_n respectivamente. Inicialmente los centros para cada subgrupo son obtenidos promediando los datos de ese subgrupo, obteniendo $v^y(0)$ y $v^n(0)$.

2. Para cada celda de 1 a N, se actualizan los centros de acuerdo con el postulado de Hebb (Pajares y col. 2007c; Haykin, 1994; Kosko, 1992):

$$\mathbf{v}^c(i) = \mathbf{v}^c(i-1) + \alpha z^c(\mathbf{x}_i, \mathbf{v}^c(i-1)) [\mathbf{x}_i - \mathbf{v}^c(i-1)] \quad c = y, n \quad (3.59)$$

donde α es la velocidad de aprendizaje, establecida a 0.01 (aprendizaje suave) en los experimentos llevados a cabo en este trabajo; $\mathbf{v}^c(i)$ es el valor del centro actualizado, una vez que la celda i , con el vector de atributos \mathbf{x}_i es procesada; $\mathbf{v}^c(i-1)$ es el valor previo del centro. Bajo el paradigma de Hebb expresado en la forma de la ecuación anterior, $z^c(\cdot)$ es la actividad postsináptica modelada como un entorno basado en el criterio de la red neuronal autoorganizativa (Kohonen, 1988), limitada al intervalo $(0,1]$ y viene dada por:

$$z^c(\mathbf{x}_i, \mathbf{v}^c(i-1)) = 2 \left(1 - \frac{1}{1 + \exp\{-\beta d(\mathbf{x}_i, \mathbf{v}^c(i-1))\}} \right) \quad (3.60)$$

donde $d(\mathbf{x}_i, \mathbf{v}^c(i-1)) = (\mathbf{x}_i - \mathbf{v}^c(i-1))^T C^{-1} (\mathbf{x}_i - \mathbf{v}^c(i-1))$ es la distancia de Mahalanobis (Duda y col., 2001), elegida porque es una métrica que incluye la dispersión de las muestras en el clúster a través de la matriz de covarianza C ; t indica transpuesta; β es una constante elegida de tal manera que para las distancias máximas ($d_{\max} \approx 2,4$) la influencia de z es mínima, estableciendo $\beta = 6$, la influencia es aproximadamente de 10^{-6} contra 1.0, lo que representa una influencia máxima para mínimas distancias ($d_{\min} = 0$). Este valor es suficiente para el caso estudiado. Después del proceso de entrenamiento ($i = N$), los centros de los clústeres estimados $\mathbf{v}^c = \mathbf{v}^c(N)$, son almacenados en la base de conocimiento (BC).

Siguiendo con la comparación de las ecuaciones anteriores, se identifica que en el modelo propuesto los centros de los clústeres se corresponden con los pesos sinápticos del modelo de red, mientras que los vectores representativos de las clases se corresponden con la actividad presináptica.

3.5.2.2 Etapa *on-line*: decisión.

Durante la etapa *on-line* se procesan nuevas imágenes, y por lo tanto, nuevas celdas. Se debe llevar a cabo una decisión para cada una de las celdas. Dada una celda s con sus atributos en el vector de área \mathbf{x} , el problema es decidir a qué clase o clúster pertenece (w_y, w_n) . Se calculan las distancias de Mahalanobis entre el vector \mathbf{x} y cada uno de los centros almacenados en la base de conocimiento, por lo que la decisión se lleva a cabo de acuerdo con la siguiente regla:

$$s \in w_y \quad \text{si} \quad d(x, v^y) < d(x, v^n); \quad \text{de otro modo} \quad s \in w_n \quad (3.61)$$

3.6. Combinación de clasificadores

Un aspecto importante a destacar en el tema de la clasificación en general es el hecho de que la *combinación* de clasificadores obtiene mejores resultados que los clasificadores utilizados de forma individual (Valdovinos y col. 2005, Kuncheva, 2004, Kumar y col. 2002 o Kittler y col. 1998). Este campo está actualmente en auge bajo el paradigma conocido como clasificadores *híbridos*. En este sentido destacan dos importantes estrategias comúnmente aceptadas para llevar a cabo la combinación de clasificadores, a saber: *selección* y *fusión* (Valdovinos y col. 2005). Existen diferentes estudios relativos al tema de la combinación donde se destacan las ventajas de este planteamiento en el sentido de que la combinación permite resaltar las bondades de los clasificadores al mismo tiempo que se atenúan o desaparecen las desventajas (Partridge y Griffith, 2002; Deng y Zhang 2006). En nuestros experimentos hemos optado por la

fusión por entender que de esta forma se aprovechan mejor las ventajas proporcionadas por los clasificadores individuales.

Se ha optado por la combinación de dos estrategias, aún siendo conscientes de que probablemente la combinación de más de dos métodos podría proporcionar mejores resultados. En este sentido los experimentos llevados a cabo en este trabajo se basan en la combinación de clasificadores dos a dos. Así los métodos combinados son los siguientes:

1. Clasificador de Bayes con clasificador borroso (Tellaeché y col. 2007b)
2. Máquinas de vectores soporte con clasificador borroso (Tellaeché y col. 2007c)
3. Clasificador de Bayes con máquinas de vectores soporte (Tellaeché y col. 2007d)

El esquema general de un clasificador combinado viene representado en la figura 3-5.

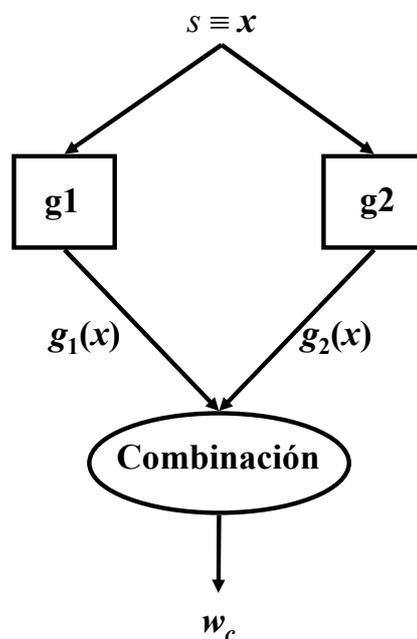


Figura 3-5: Esquema general de un clasificador combinado.

Dada una muestra a clasificar s con su vector de atributos asociado \mathbf{x} (los dos atributos de área habituales) el objetivo consiste en clasificarla como perteneciente a una de las dos clases w_y u w_n . Cada clasificador (g_1 y g_2) genera una salida ($g_1(\mathbf{x})$, $g_2(\mathbf{x})$) de forma que mediante la combinación de ambas se determina a través de la correspondiente regla de decisión su pertenencia a una de las dos clases en juego.

Para los clasificadores híbridos descritos en esta sección se siguen utilizando los conjuntos de muestras a pulverizar y no pulverizar con los dos atributos cuantitativos ya mencionados y por tanto con los conocidos conjuntos RC_{pulv} y RC_{nopulv} para las respectivas clases w_y y w_n respectivamente. Según la figura 3-5 la clase genérica w_c puede ser una de las dos clases mencionadas.

3.6.1. Clasificador híbrido: Bayes y agrupamiento borroso

En la ecuación (3.45) se establece la regla de decisión basada en el clasificador de Bayes. En dicha regla, tal y como se desprende de la mencionada ecuación, en la decisión intervienen por un lado la función de densidad de probabilidad y por otro la probabilidad a priori. Como se ha explicado en la sección 3.3 dicha función se puede estimar de forma paramétrica o no paramétrica. En el caso del clasificador híbrido que nos ocupa dicha función se estima exactamente siguiendo el procedimiento descrito en dicha sección. Es en el cómputo de la probabilidad a priori donde se introduce la novedad relativa que aporta este método. En efecto, dado que tal y como se ha explicado en la sección 3.4 se puede obtener el grado de pertenencia de una muestra a una determinada clase es posible utilizar esta información como probabilidad a priori. Aunque el grado de pertenencia no tiene propiedades de una función de probabilidad sí que aporta un valioso conocimiento para ser utilizado como información previa y por tanto introducirla en el término de probabilidad a priori en la decisión. En cualquier caso se distinguen como en los clasificadores base o sencillos los dos consabidos procesos de entrenamiento y decisión.

3.6.1.1 Etapa *off-line*: entrenamiento

El proceso de entrenamiento se sintetiza como sigue teniendo en cuenta las muestras de entrenamiento disponibles:

1. Estimar las funciones de densidad de probabilidad asociadas a cada clase teniendo en cuenta las muestras disponibles para cada una de ellas. Siguiendo el esquema del estimador paramétrico, se trata de obtener las medias y las matrices de covarianza para cada clase mediante las ecuaciones (3.18), tras lo cual se puede determinar la función de densidad buscada a través de la ecuación (3.9). En el supuesto de optar por una estima no paramétrica las funciones de densidad de probabilidad se estiman mediante la ecuación (3.40).
2. Determinar los centros de cada clúster mediante el procedimiento de agrupamiento borroso descrito en la sección 3.4 a través de las ecuaciones (3.52) y (3.53).

3.6.1.2 Etapa *on-line*: decisión

Dada una muestra s con vector de atributos \mathbf{x}_s correspondiente a los dos atributos cuantitativos utilizados hasta aquí la decisión se toma de acuerdo con la siguiente regla,

$$s \in w_y \text{ sii } p(\mathbf{x} / w_y)P(w_y) > p(\mathbf{x} / w_n)P(w_n); \text{ en caso contrario } s \in w_n \quad (3.62)$$

donde $P(w_y) \equiv \mu_{sy}$ y $P(w_n) \equiv \mu_{sn}$, siendo μ_{sy} y μ_{sn} los grados de pertenencia de la muestra s a cada una de las clases respectivas w_y y w_n obtenidas a través de las ecuación (3.53). Según la figura 3-5 se tiene la siguiente correspondencia $g_1(\mathbf{x}) = p(\mathbf{x}/w_c)$ y $g_2(\mathbf{x}) = \mu_{sc}$.

3.6.2. Clasificador híbrido: máquinas de vectores soporte y agrupamiento borroso

En este caso, la combinación se produce entre la salida generada por las máquinas de vectores soporte y la proporcionada por el método de agrupamiento borroso. Se distinguen como siempre las clásicas etapas de entrenamiento y clasificación.

3.6.2.1 Etapa *off-line*: entrenamiento

El proceso de entrenamiento se sintetiza como sigue teniendo en cuenta las muestras de entrenamiento disponibles:

1. Estimar la función de decisión mediante el SVM según la ecuación (3.4)
2. Determinar los centros de cada clúster mediante el procedimiento de agrupamiento borroso descrito en la sección 3.4 a través de las ecuaciones (3.52) y (3.53).

3.6.2.2 Etapa *on-line*: decisión

Teóricamente, la función de decisión estimada $f(\mathbf{x})$ toma valores positivos y negativos ilimitados, con el fin de restringir el rango de valores al intervalo $[0,+1]$ se aplica la función sigmoide según la ecuación (3.63) (Haykin, 1994). El valor de +1 indica que una celda debe ser pulverizada con mucha intensidad y viceversa.

$$d_{sy}(\mathbf{x}) = (1 + \exp(-af(\mathbf{x})))^{-1} \quad (3.63)$$

donde a es una constante fijada experimentalmente al valor 0.1.

Según la expresión (3.63) la salida del clasificador SVM resulta ser $g_1(\mathbf{x}) = d_{sy}(\mathbf{x})$.

Por otro lado, el clasificador basado en el agrupamiento borroso genera su correspondiente salida que como en el caso anterior es $g_2(\mathbf{x}) = \mu_{sc}(\mathbf{x})$.

La fusión de ambas salidas se lleva a cabo mediante un operador de agregación borroso (Zimmermann, 1991). Existen diferentes operadores de agregación de esta naturaleza:

1. *Operadores no paramétricos*: diferencia y suma vinculadas, Einstein (producto y suma), algebraico (producto y suma), mínimo y máximo.
2. *Operadores paramétricos*: Hamacher (intersección, unión), Yager (intersección, unión), Dubois (intersección, unión) y “and compensatorio”.

Se han realizado diversos experimentos con ellos, concluyendo que los mejores resultados se obtienen con la suma Einstein cuya expresión viene dada por (3.64) en la que se ha suprimido la dependencia de la variable \mathbf{x} por simplicidad:

$$h_{iy} = \frac{d_{iy} + \mu_{iy}}{1 + d_{iy}\mu_{iy}} \quad (3.64)$$

La decisión final de este clasificador híbrido se realiza basada en el valor h_{iy} , que determina para una determinada celda el nivel de herbicida a pulverizar en una determinada celda de acuerdo con su valor, siendo 1 el máximo y 0 el mínimo.

3.6.3. Clasificador híbrido: Bayes y Máquinas de Vectores Soporte

En este caso se sigue una estrategia similar a la expuesta en la sección 3.6.1 con la misma función de decisión pero con las dos diferencias siguientes:

1. En la etapa de entrenamiento la función de densidad de probabilidad se estima siguiendo la estrategia del estimador no paramétrico cuya expresión se concreta en la ecuación (3.40) y en lugar de utilizar el agrupamiento borroso para el

segundo clasificador se ha elegido el SVM estimando la función de decisión dada en (3.4) como en la sección anterior.

2. En la etapa de decisión las probabilidades a priori se determina a partir de la función de decisión proporcionada por el SVM según las expresiones dadas en (3.65)

$$P(w_y) = d_{sy} \quad y \quad P(w_n) = 1 - d_{sy} \quad (3.65)$$

3.7. Clasificación mediante el algoritmo MCDM basado en lógica borrosa

Este es el último de los métodos de clasificación utilizados en la presente tesis. La justificación para el uso de un marco de decisión multicriterio viene dado porque la investigación realizada ha establecido que para la obtención de un resultado lo más fiable posible es necesario tener en cuenta tanto la densidad de malas hierbas (relaciones cuantitativas) como la dispersión de las mismas en el campo y por tanto en la celda (relaciones estructurales), (Tellaeché y col. 2007e).

Principalmente se dan dos casos que justifican esta afirmación:

1. Existen celdas con zonas de malas hierbas aisladas cuya área conjunta es muy pequeña comparada con las zonas de cultivo derecha e izquierda. Estas zonas representan un riesgo potencial porque corresponden a malas hierbas diseminadas que todavía están en fase de crecimiento. Si este tipo de malas hierbas no son pulverizadas, dichas malas hierbas afectarán al cultivo en este ciclo de crecimiento o en ciclos posteriores en los próximos años.
2. Pueden darse casos de zonas de cultivo que sobrepasan los límites de las zonas de cultivo izquierda o derecha y que en el tratamiento de la celda dan como resultado un área central ocupada de la celda muy elevada (alta

densidad). A pesar de esta situación, este tipo de celdas no necesitan ser pulverizadas.

Con estas dos consideraciones queda patente que los algoritmos de decisión anteriormente expuestos, basados únicamente en áreas de ocupación de la celda pueden dar resultados incorrectos. Esto justifica la elección de dos tipos de atributos para establecer una clasificación correcta de las celdas a pulverizar: atributos basados en el área de las malas hierbas (relaciones cuantitativas) y atributos basados en la dispersión de las zonas donde aparecen las malas hierbas (relaciones estructurales). Esta conclusión y el uso de un algoritmo del tipo MCDM para la resolución del problema es una de las contribuciones más importantes de esta tesis, ya que en trabajos previos de clasificación de cultivos sólo se han utilizado parámetros basados en el área para la clasificación.

El algoritmo MCDM desarrollado en el presente trabajo está basado en los trabajos de Wang y Fenton (2006); Gu y Zhu (2006) y Chen (2000). En realidad se lleva a cabo un proceso de síntesis con base en los mencionados trabajos. A continuación se describen los aspectos teóricos relacionados con el mismo, así como las adaptaciones pertinentes para dar solución al problema que nos ocupa junto con algunas mejoras de interés.

3.7.1. Teoría del MCDM basado en lógica borrosa.

Los algoritmos del tipo MCDM (*Multicriteria decision making*) o toma de decisión multicriterio surgen para buscar una solución a los problemas de toma de decisiones, en los cuales es necesario encontrar la mejor opción dentro de un grupo finito de alternativas posibles, sujetas a su vez a un número finito de condiciones, restricciones o criterios. Las alternativas pueden ser referidas también como candidatos o acciones y los criterios a los cuales pueden estar sujetas pueden ser independientes o presentar algún tipo de conflicto entre ellos.

Un problema de decisión multicriterio se caracteriza por:

1. La medida de cada alternativa con respecto a cada criterio.
2. Los pesos dados a cada uno de los criterios.

Los métodos clásicos de MCDM asumen que la medida de las alternativas y los pesos de los criterios son números reales, pero cada vez más, esta aproximación ha demostrado ser muy poco realista. Generalmente las incertidumbres proceden de casos de información sin cuantificar, información incompleta, información que no se puede obtener e ignorancia parcial del problema.

Los métodos clásicos de MCDM no están diseñados para manejar problemas con este tipo de información imprecisa. Para abordar esta problemática, entre todas las opciones posibles, la más comúnmente utilizada es la teoría borrosa conjuntamente con la teoría clásica del MCDM.

Un problema MCDM puede ser expresado de manera muy concisa en forma matricial:

$$D = \begin{matrix} & C_1 & C_2 & \cdots & C_n \\ A_1 & \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \end{bmatrix} \\ A_2 & \begin{bmatrix} x_{21} & x_{22} & \cdots & x_{2n} \end{bmatrix} \\ \vdots & \begin{bmatrix} \vdots & \vdots & \vdots & \vdots \end{bmatrix} \\ A_m & \begin{bmatrix} x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix} \end{matrix} \quad W = [w_1 \quad w_2 \quad \cdots \quad w_n] \quad (3.66)$$

donde A_1, A_2, \dots, A_m , son las posibles alternativas entre las que elegir, C_1, C_2, \dots, C_n los criterios con los que las alternativas son evaluadas y x_{ij} son los ratios de la alternativa A_i con respecto al criterio C_j ; w_j es el peso del criterio C_j .

Los criterios pueden ser clasificados según dos grupos:

1. Criterio de beneficio (donde cuanto más grande sea el valor de x_{ij} mejor contribuye a la decisión).
2. Criterio de costo (donde el menor valor de x_{ij} favorece la decisión).

Como se van a utilizar una aproximación *fuzzy*, de ahora en adelante se utilizará la siguiente notación:

$$\tilde{D} = [\tilde{x}_{ij}] \quad y \quad \tilde{W} = (\tilde{w}_j) \quad (3.67)$$

donde \tilde{x}_{ij} representa el ratio *fuzzy* de la alternativa A_i con respecto al criterio C_j y \tilde{w}_j representa el criterio de peso *fuzzy* para el criterio C_j .

Dentro de la teoría *fuzzy*, una manera intuitiva y fácil para representar la incertidumbre sobre un número de valor desconocido son los números *fuzzy* triangulares.

Un número *fuzzy* triangular \tilde{a} está definido por un triplete del tipo (a_1, a_2, a_3) .

La pertenencia a la función viene definida por:

$$\mu_{\tilde{a}}(x) = \begin{cases} (x - a_1)/(a_2 - a_1), & a_1 \leq x \leq a_2, \\ (a_3 - x)/(a_3 - a_2), & a_2 \leq x \leq a_3, \\ 0, & \text{en otro caso} \end{cases} \quad (3.68)$$

Un número *fuzzy* triangular está basado en un juicio de tres valores: el mínimo valor posible a_1 , el valor más probable a_2 y el máximo valor posible a_3 .

Para poder trabajar con criterios que están a diferentes escalas, se aplica un proceso de normalización. Los números *fuzzy* presentes en la matriz de decisión se normalizan para obtener la matriz de *performance*:

$$\tilde{P} = [\tilde{p}_{ij}] \text{ donde}$$

$$\tilde{p}_{ij} = \begin{cases} \left(\frac{x_{ij1}}{M}, \frac{x_{ij2}}{M}, \frac{x_{ij3}}{M} \right), & M = \max_i x_{ij3}, C_j \text{ es criterio de beneficio} \\ \left(\frac{N - x_{ij3}}{N}, \frac{N - x_{ij2}}{N}, \frac{N - x_{ij1}}{N} \right), & N = \max_i x_{ij3}, C_j \text{ es criterio de costo} \end{cases} \quad (3.69)$$

Con este método se consigue normalizar los números triangulares *fuzzy* en el rango de [0,1].

Una vez obtenida la matriz de *performance* es necesario utilizar los pesos asignados a cada criterio, para obtener la matriz de *performance* ponderada. Esta operación se realiza multiplicando el vector de pesos por la matriz de decisión:

$$\tilde{P}^w = [\tilde{p}_{ij}^w] \quad (3.70)$$

donde:

$$p_{ij1}^w = w_{j1} p_{ij1}, \quad p_{ij2}^w = w_{j2} p_{ij2}, \quad p_{ij3}^w = w_{j3} p_{ij3} \quad (3.71)$$

$$i = 1, 2, \dots, m \text{ y } j = 1, 2, \dots, n.$$

Para calcular la alternativa óptima dentro del conjunto de alternativas posibles, se utiliza el método de vértice. La alternativa óptima es aquella que presenta la distancia mínima a la solución ideal positiva y la mayor distancia a la solución ideal negativa de entre todas las alternativas.

Si se tienen dos números *fuzzy* triangulares positivos $\tilde{a} = (a_1, a_2, a_3)$ y $\tilde{b} = (b_1, b_2, b_3)$, el método del vértice define la distancia entre ambos números como:

$$d(\tilde{a}, \tilde{b}) = \sqrt{\frac{(a_1 - b_1)^2 + (a_2 - b_2)^2 + (a_3 - b_3)^2}{3}} \quad (3.72)$$

Para la matriz de *performance fuzzy* normalizada, se define la solución ideal positiva como $p_j^* = (1, 1, 1)$ y la solución ideal negativa como $p_j^- = (0, 0, 0)$. Mediante el método del vértice, la distancia entre cada alternativa y la solución ideal positiva es:

$$d_i^* = \sum_{j=1}^n d(\tilde{p}_{ij}^w, \tilde{p}_j^*) \quad (3.73)$$

donde $i = 1, \dots, m$ y $j = 1, \dots, n$.

y para la solución ideal negativa:

$$d_i^- = \sum_{j=1}^n d(\tilde{p}_{ij}^w, \tilde{p}_j^-) \quad (3.74)$$

donde $i = 1, \dots, m$ y $j = 1, \dots, n$.

El índice de *performance* para cada alternativa será entonces:

$$p_i = \frac{d_i^- + n - d_i^*}{2n} \quad (3.75)$$

donde $i = 1, \dots, m$ es el número de alternativas y n es el número de criterios.

La alternativa elegida será aquella que presente un índice de *performance* más próximo a la unidad. Esta es la regla de decisión asociada a este método MCDM.

3.7.2. Cálculo de los pesos del algoritmo MCDM: algoritmo ID3

Un inconveniente que posee el algoritmo MCDM en la versión expuesta hasta el momento estriba en el hecho de que a priori no resulta fácil conocer los pesos a asignar a cada uno de los criterios. Si inicialmente no se tiene conocimiento de cuáles son los valores de dichos pesos, siempre será posible realizar algún tipo de ensayo inicial para determinar una serie de pruebas de las que se deducen aciertos y errores. El objetivo final consiste en establecer una relación entre los criterios de forma que se pueda establecer su importancia relativa y de ahí deducir los valores de los pesos buscados.

Para deducir cuál es el mérito de cada uno de los pesos se utiliza la teoría de la información. Dentro de las diferentes técnicas existentes se utiliza el algoritmo de aprendizaje ID3 (Pajares y Santos, 2005).

El algoritmo ID3 es una técnica de aprendizaje inductivo. El objetivo de este tipo de aprendizaje basado en ejemplos consiste en establecer rasgos comunes entre una serie de ejemplos de concepto desconocido, de tal forma que esa descripción no incluya al resto de ejemplos que no pertenecen al concepto.

Los ejemplos para este tipo de aprendizaje pueden ser suministrados externamente o bien por el propio aprendiz de conceptos, correspondiendo ambos casos a aprendizaje de naturaleza supervisada. Los ejemplos de entrenamiento pueden suministrarse de uno en uno o todos a la vez, correspondiendo cada uno de los casos a un tipo de aprendizaje incremental y no incremental respectivamente.

A partir de las consideraciones anteriores, el procedimiento de aprendizaje inductivo puede ser formalizado de la siguiente manera:

Encontrar una hipótesis h que:

1. Describa todos (o la mayoría) de los ejemplos positivos.
2. Excluya todos (o la mayoría) de los ejemplos negativos.

3. Tenga expectativas de clasificar futuros ejemplos.

Dados:

1. Conjunto de ejemplos positivos y negativos de un concepto de clase.
2. Conocimiento de base: reglas de inferencia dependientes o independientes del dominio y restricciones o criterios de preferencias en el espacio de hipótesis.

A veces los valores de los atributos son erróneos o presentan valores incompletos, conociéndose este efecto como ruido.

Los ejemplos mostrados para que el sistema aprenda se presentan indicando su pertenencia a una clase, habiendo sido determinada esta pertenencia por un clasificador previamente, generalmente experiencia empírica.

Como se ha explicado previamente, en el aprendizaje inductivo, el algoritmo de aprendizaje trata de encontrar un modelo de clasificación sencillo y general. Uno de los modelos más simples es el que encuentra una regla de clasificación. Esto es lo que realiza el algoritmo ID3. Una regla modelo a aprender podría ser la siguiente:

$$\text{Si } (a_1 = \text{val}_1) \wedge (a_2 = \text{val}_2) \wedge \dots \wedge (a_n = \text{val}_n) \text{ entonces } (C_k = \text{val}_k) \quad (3.76)$$

Donde a_1, \dots, a_n son los atributos de los objetos a clasificar y C_k el objeto que ha resultado seleccionado a partir de la clasificación.

El algoritmo ID3 construye un árbol de decisión. Los árboles de decisión (*Decision Trees* o *Top-Down Inductive Decision Trees, TDIDT*) se generan a partir de los ejemplos de forma inductiva siguiendo un proceso iterativo que comienza en la raíz del árbol y termina en sus hojas. Los nodos que no son hojas representan atributos de los

ejemplos de muestra, las ramas representan los valores de dichos atributos y las hojas son los valores de la clase. La clasificación de un objeto se determina preguntando en cada nodo del árbol, desde la raíz, por el atributo del nodo. La rama que coincide con la respuesta es la elegida hasta alcanzar los valores de la clase.

Para construir el árbol de decisión, el orden de los atributos se elige de mayor a menor capacidad discriminante. Una forma de realizarlo es atendiendo al contenido de la información derivada de la teoría de la información. Para ello se definen los siguientes términos:

$$\begin{aligned} p : \text{porcentaje de ejemplos } + &= \frac{|E +|}{|E +| + |E -|} \\ n : \text{porcentaje de ejemplos } - &= \frac{|E -|}{|E +| + |E -|} \end{aligned} \quad (3.77)$$

Siendo $|E +|$ y $|E -|$ respectivamente el número de ejemplos positivos y negativos observado. El contenido de información de un conjunto de datos es:

$$\text{infor}(p, n) = -p \log_2(p) - n \log_2(n) \quad (3.78)$$

Siendo ésta una medida de la entropía o grado de desorden existente. Se considera que $0 \log_2(0) = 0$. Según la teoría de la información un evento seguro con $p = 1$ no contiene información. Por tanto, la información está relacionada con la entropía, a mayor entropía menor información. Por consiguiente, para construir el árbol de información hay que elegir los atributos con mayor información, menor entropía, que se mide a través de la función de mérito como sigue:

$$a_m : \text{mérito}(a_m) = \sum r_i \text{infor}(p_i, n_i) \quad (3.79)$$

Siendo:

1. $p_i =$ % de ejemplos + en la rama i ; $n_i =$ % de ejemplos – en la rama i .
2. $r_i = \frac{p_i + n_i}{N}$ porcentaje de ejemplos en la rama i , con N número de ejemplos.

Este coeficiente mide de manera ponderada el grado de desorden de la rama correspondiente con respecto a los ejemplos que contiene.

Para explicar y aclarar estos conceptos, considérese el siguiente ejemplo teórico.

Se supone que se tienen tres atributos A_1 , A_2 y A_3 . Para el atributo A_1 se tienen tres opciones posibles ($op_{11}, op_{12}, op_{13}$), para el A_2 dos opciones (op_{21}, op_{22}), y para el A_3 tres opciones ($op_{31}, op_{32}, op_{33}$). En las tablas 3.1 se expresan directamente las probabilidades de ejemplos positivos y negativos.

Tabla 3-1: contenido de información para cada uno de los casos

A_1	$op_{11} = 4$	$op_{12} = 2$	$op_{13} = 2$
	$p_1 = 1/4$	$p_2 = 2/2$	$p_3 = 0/2$
	$n_1 = 3/4$	$n_2 = 0/2$	$n_3 = 2/2$

A_2	$op_{21} = 5$	$op_{22} = 3$
	$p_1 = 2/5$	$p_2 = 0/3$
	$n_1 = 3/5$	$n_2 = 3/3$

A_3	$op_{31} = 5$	$op_{32} = 2$	$op_{33} = 1$
	$p_1 = 2/5$	$p_2 = 1/2$	$p_3 = 0/1$
	$n_1 = 3/5$	$n_2 = 1/2$	$n_3 = 1/1$

Si se calcula el mérito para cada uno de estos atributos:

$$\text{mérito}(A_1) = \frac{4}{8} \text{inf or} \left(\frac{1}{4}, \frac{3}{4} \right) + \frac{2}{8} \text{inf or} \left(\frac{1}{2}, \frac{1}{2} \right) + \frac{2}{8} \text{inf or} \left(\frac{0}{2}, \frac{2}{2} \right) = 0.4057$$

$$\text{mérito}(A_2) = \frac{5}{8} \text{inf or} \left(\frac{2}{5}, \frac{3}{5} \right) + \frac{3}{8} \text{inf or} \left(\frac{0}{3}, \frac{3}{3} \right) = 0.6069$$

$$\text{mérito}(A_3) = \frac{5}{8} \text{inf or} \left(\frac{2}{5}, \frac{3}{5} \right) + \frac{2}{8} \text{inf or} \left(\frac{1}{2}, \frac{1}{2} \right) + \frac{1}{8} \text{inf or} \left(\frac{0}{1}, \frac{1}{1} \right) = 0.8568$$

En consecuencia, el orden de los atributos por su valor informativo es A_1 , A_2 y A_3 . La siguiente figura muestra el árbol de decisión que representa los datos:

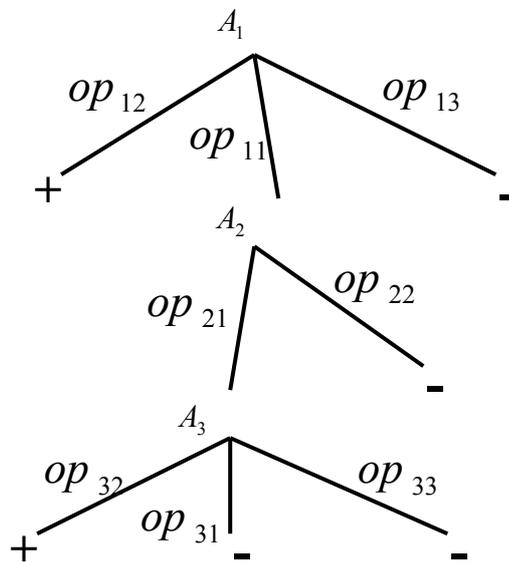


Figura 3-6: Árbol de decisión creado a partir del ejemplo

El algoritmo ID3 es el siguiente:

Algoritmo ID3 (lista-ejemplos, lista-atributos)

- Si *lista-ejemplos* está vacía, "regresar"; en caso contrario, seguir.
- Si todos los ejemplos en *lista-ejemplos* son +, devolver "+"; de otro modo seguir
- Si todos los ejemplos en *lista-ejemplos* son -, devolver "-"; de otro modo seguir

- Si *lista-atributos* está vacía, devolver "error"; en caso contrario:
 - llamar *mejor* al elemento *a* de *lista-atributos* que minimice *mérito(a)*.
 - iniciar un árbol cuya raíz sea *mejor*:
 - para cada valor v_i de *mejor*
 - incluir en *ejemplos-restantes* los elementos de *lista-ejemplos* que tengan valor v_i del atributo *mejor*.
 - dejar en *atributos-restantes* todos los elementos de *lista-atributos* excepto *mejor*.
 - devolver el valor de: *ID3* (*ejemplos-restantes*, *atributos-restantes*) (llamada recursiva al algoritmo)

Una vez construido el árbol, el siguiente paso consiste en reflejar ese conocimiento mediante un conjunto de reglas. Básicamente, la conversión del árbol en reglas consiste en considerar como *antecedente* de una regla la conjunción de las decisiones asociadas a una rama del árbol, siendo su *consecuente* el valor de la clase indicado por el extremo de dicha rama.

3.7.3. Utilización del algoritmo MCDM basado en lógica borrosa para la clasificación de celdas de cultivo

Para la toma de decisión de las celdas a pulverizar o no pulverizar, el algoritmo MDCM desarrollado trata de resolver un problema con dos alternativas: F_1 y F_2 . Dada una celda i se debe decidir si se debe pulverizar (F_1) o si por el contrario no es necesario hacerlo (F_2). Para la resolución de este problema, se plantean dos criterios para tomar la decisión:

1. C_1 , criterio de similitud entre el vector de relaciones estructurales de la celda a procesar y los vectores de relaciones estructurales de las celdas modelo almacenados en la *BC*.

2. C_2 , criterio de similitud entre el vector de relaciones cuantitativas de la celda a procesar y los vectores de relaciones cuantitativas de las celdas modelo almacenados en la BC .

Los criterios de comparación de relaciones estructurales y cuantitativas se han establecido en el capítulo 2 según las ecuaciones (2.20) y (2.8) respectivamente a través del coeficiente R_{ij} y la distancia Euclídea E_{ij} para sendas celdas i y j . En el caso de la comparación de las relaciones estructurales, cuanto mayor es el valor R_{ij} resultante de la comparación, mejor es para el proceso de decisión con lo que C_1 se trata de un criterio de beneficio. Por el contrario, en el caso de las relaciones cuantitativas, cuanto menor es el valor resultante de la comparación E_{ij} , mejor es para el proceso de decisión, con lo que al contrario que C_1 , C_2 es un criterio de costo (Wang y Fenton, 2006).

Para cada uno de los criterios, se asigna un peso relativo, w_1 para C_1 y w_2 para C_2 . En una primera aproximación se establecieron estos valores a $w_1 = 0.4$ y $w_2 = 0.6$, de tal forma que $w_1 + w_2 = 1$. Estos dos valores fueron fijados experimentalmente tras un conjunto de pruebas de ensayo y error utilizando el procedimiento de validación cruzada descrito en Duda y col. (2001) y teniendo en cuenta además el criterio de los expertos en temas agrícolas relativos a la aplicación de herbicida.

Considerando todo lo expuesto hasta el momento, el algoritmo de decisión MCDM, desarrollado para el problema de la pulverización selectiva se sintetiza como sigue en los siguientes pasos:

1. Dada una celda i , calcular su vector de relaciones estructurales

$$S_i = \{s_{i0}, s_{i1}, \dots, s_{i8}\} \quad \text{y su vector de relaciones cuantitativas}$$

$$a_i = \{a_{i0}, a_{i1}, \dots, a_{i7}\}$$

2. Obtener los vectores de relaciones cuantitativas y estructurales de las celdas modelo o patrón contenidas en la BC . Para la explicación matemática de este método, estos vectores se redefinen de una manera alternativa a la definición planteada en el capítulo 2. Definiendo KB_1 como las celdas modelo a pulverizar y KB_2 como las celdas modelo a no pulverizar. Para cada una de las celdas j presentes en KB_1 y KB_2 , calcular los vectores:

$$x_i^k \equiv \{R_{i1}^k, R_{i2}^k, \dots, R_{ij}^k\}, \quad y_i^k \equiv \{E_{i1}^k, E_{i2}^k, \dots, E_{ij}^k\}, \quad k = 1, 2; \quad j = 1, 2, \dots, J_k;$$

donde J_1 y J_2 son el número de celdas en KB_1 y KB_2 respectivamente.

3. Para cada x_i^k seleccionar los tres mayores valores (ya que representan un criterio de beneficio) $R_{ia}^k < R_{ib}^k < R_{ic}^k$, donde $R_{ij}^k < R_{ia}^k$. Para cada y_i^k seleccionar los tres valores más pequeños (ya que representan un criterio de coste). $E_{ia}^k > E_{ib}^k > E_{ic}^k$, donde $E_{ij}^k > E_{ia}^k$ y $j \neq a, b, c$.
4. Construir la tabla de decisión 3.2 donde R^1, R^2, E^1 y E^2 son números *fuzzy* triangulares. Estos números *fuzzy* justifican los valores elegidos en el punto anterior.

Tabla 3-2: Tabla de decisión de acuerdo a los criterios y los pesos

		Criterios (pesos)	
		$C_1(w_1)$	$C_2(w_2)$
decisión	F_1	$R_i^1 = [R_{ia}^1, R_{ib}^1, R_{ic}^1]$	$E_i^1 = [E_{ia}^1, E_{ib}^1, E_{ic}^1]$
	F_2	$R_i^2 = [R_{ia}^2, R_{ib}^2, R_{ic}^2]$	$E_i^2 = [E_{ia}^2, E_{ib}^2, E_{ic}^2]$

5. Construir la tabla de *performance* normalizada 3.3, teniendo en cuenta que

$$M = \max\{R_{ic}^1, R_{ic}^2\} \text{ y } N = \min\{E_{ic}^1, E_{ic}^2\}. \quad (3.80)$$

Tabla 3-3: Tabla de *performance* normalizada acorde con los criterios y los pesos

		Criterios (pesos)	
		$C_1(w_1)$	$C_2(w_2)$
decisión	F_1	$R_{iM}^1 = [R_{ia}^1 / M, R_{ib}^1 / M, R_{ic}^1 / M]w_1$	$E_{iN}^1 = [N / E_{ia}^1, N / E_{ib}^1, N / E_{ic}^1]w_2$
	F_2	$R_{iM}^2 = [R_{ia}^2 / M, R_{ib}^2 / M, R_{ic}^2 / M]w_1$	$E_{iN}^2 = [N / E_{ia}^2, N / E_{ib}^2, N / E_{ic}^2]w_2$

6. Elegir la mejor alternativa. Esta elección se lleva a cabo, como se ha explicado anteriormente por el método del vértice. Por lo tanto teniendo las soluciones ideales positivas y negativas ($p^+ \equiv (1,1,1)$ y $p^- \equiv (0,0,0)$), se calculan las distancias siguientes:

$$\begin{aligned}
 d_{i1}^+ &= d(R_{iM}^1, p^+) + d(E_{iN}^1, p^+) \\
 d_{i2}^+ &= d(R_{iM}^2, p^+) + d(E_{iN}^2, p^+) \\
 d_{i1}^- &= d(R_{iM}^1, p^-) + d(E_{iN}^1, p^-) \\
 d_{i2}^- &= d(R_{iM}^2, p^-) + d(E_{iN}^2, p^-)
 \end{aligned} \tag{3.81}$$

Y por lo tanto el índice de *performance* para cada alternativa $h=1,2$ es:

$$p_i^h = \frac{d_{ih}^- + c - d_{ih}^+}{2c} \tag{3.82}$$

donde c , que es el número de criterios, es 2 en el caso que nos ocupa. Por lo tanto si $|p_i^1 - 1| \leq |p_i^2 - 1|$, entonces la alternativa F_1 (pulverizar) es seleccionada, en caso contrario, la alternativa elegida es F_2 (no pulverizar).

4. Resultados: estrategias de test y análisis

4.1. Introducción

En los tres capítulos previos se han propuesto varias estrategias que conducen hacia una solución al problema de la pulverización selectiva en campos de cultivo mediante los dos procesos ya mencionados de segmentación y decisión. En este capítulo se presentan los resultados obtenidos a partir de los planteamientos realizados y las estrategias propuestas. Revisando dichas estrategias se deduce lo siguiente:

1. Tras el proceso de segmentación se obtienen dos tipos de atributos, las relaciones de área o cuantitativas y las relaciones estructurales o cualitativas. A su vez los atributos cuantitativos son ocho, si bien se analizan sólo los dos más relevantes, a saber: ratio de malas hierbas (a_{i0}) y presión de malas hierbas (a_{i1}). El resto de atributos cuantitativos representan valores locales de la presión de malas hierbas, en la zona central de la celda tal y como se describe en la sección 2.5.2., por las causas allí mencionadas son atributos no relevantes para la investigación llevada a cabo en este trabajo y por eso no se han utilizado, si bien se mantiene su referencia por si en futuras aplicaciones fuese útil su uso.
2. El proceso de decisión se ha diseñado teniendo en cuenta que se trata de un proceso de clasificación, para lo cual se han utilizado los clasificadores descritos en el capítulo previo, que se mencionan a continuación por simplicidad junto con los acrónimos que los identificarán posteriormente. Se trata de clasificadores simples, clasificadores híbridos y el MCDM.

Clasificadores Simples

1. Método de clasificación basado en las *Máquinas de Vectores Soporte* o *Support Vector Machines* (SVMA).
2. Clasificadores estadísticos de naturaleza Bayesiana.
 - a. Estimador paramétrico (BAYP).
 - b. Estimador no paramétrico de la ventana de Parzen (BAYN).

3. Clasificación mediante *Agrupamiento Borroso o Fuzzy Clustering* (FUCL).
4. Método de clasificación basado en el Clasificador Hebbiano (HEBB).

Clasificadores Híbridos

5. Combinación de clasificadores, distinguiendo en el caso del clasificador Bayesiano si se trata del estimador paramétrico o no paramétrico:
 - a. Bayes y *Fuzzy Clustering* (BAYP + FUCL)
 - b. *Support Vector Machines* y *Fuzzy Clustering* (SVMA + FUCL)
 - c. Bayes y *Support Vector Machines* (BAYN + SVMA)

Teoría de la decisión multicriterio

6. Toma de decisión multicriterio o Multicriteria Decisión Making (MCDM).

Los clasificadores anteriormente mencionados conllevan implícitamente una fase de entrenamiento y una fase de clasificación, según se describe en el capítulo 2 siguiendo el esquema de la figura 2-1.

Como se ha mencionado reiteradamente, los métodos se han experimentado en dos campos de cultivo distintos: cereal y maíz.

Se presenta en este capítulo una batería de experimentos cubriendo los distintos aspectos involucrados según los diferentes métodos. La estrategia de pruebas se orienta según los objetivos siguientes:

1. Probar la eficacia de los métodos de decisión según los atributos utilizados. De este modo, las pruebas diseñadas se realizan: a) con un único atributo de área, que en realidad será bien a_{10} o bien a_{11} ya que los atributos del a_{12} al a_{17} no se utilizan por las razones expuestas previamente; b) con los dos principales atributos de área a_{10} y a_{11} ; c) con los dos atributos de área a_{10} y a_{11} junto con los atributos estructurales (s_{10} a s_{18}).

2. Probar la eficacia de los métodos de clasificación híbridos frente a los métodos de clasificación simples.
3. Verificar la eficacia del proceso de entrenamiento a medida que el número de muestras disponibles para el entrenamiento (celdas) aumenta. La introducción de nuevas muestras se realiza en diferentes pasos de tal modo que tras cada uno de los pasos, las nuevas muestras clasificadas según los criterios de cada clasificador se añaden a la *BC* con el propósito de realizar un nuevo proceso de entrenamiento, lo que implica el aumento, a su vez, del grado de conocimiento del sistema. Se trata de una forma de verificar la influencia del aprendizaje incremental en cada paso, donde se actualizan los parámetros y funciones de decisión involucrados en cada método de clasificación según corresponda de acuerdo con el proceso de aprendizaje llevado a cabo.

En la tabla 4.1 se recogen los métodos utilizados en su doble vertiente de actuación simple y combinada frente al tipo de atributos, el tipo de cultivo y si se incorporan nuevas muestras durante el proceso y por tanto existe aprendizaje incremental. En realidad el único método donde no se verifica la influencia del aprendizaje incremental es en el método MCDM, ya que en este caso la estrategia de test no lo contempla por tener como objetivo principal la combinación de atributos de área y estructurales. En las dos primeras columnas se identifican los diferentes métodos según sus acrónimos, diferenciándose entre métodos simples y combinados (híbridos). En las tres siguientes columnas se identifican los atributos procedentes de las relaciones de área, distinguiéndose según se prueben de forma aislada o simultánea. Como puede apreciarse, en todos los métodos se utilizan bajo las dos modalidades. En la columna seis se indica que las relaciones estructurales sólo se utilizan en el método MCDM. En la columna siete se indica si el método utiliza aprendizaje incremental o no. En la columna ocho se especifica el tipo de cultivo donde se han probado. A la vista de la tabla se deduce que sólo el método BAYN se ha utilizado en los dos tipos de cultivo. Si bien, el planteamiento en ambos casos difiere considerablemente como se verá posteriormente. Finalmente, en la novena columna se indica la referencia donde el método ha sido

publicado. El conjunto de imágenes utilizadas en las citadas referencias para las pruebas no es exactamente el mismo que el utilizado en el presente trabajo, de ahí que los resultados obtenidos en las referencias y los presentados en este capítulo sean en general diferentes. En este trabajo todos los métodos se han probado con el mismo número de imágenes.

Por otra parte, es necesario recordar que las imágenes de prueba se capturan exactamente en el momento en el que el herbicida debe aplicarse por su estado de crecimiento. Esto sólo ocurre una vez al año coincidiendo con el desarrollo de los cultivos en la época de primavera. Existe una ligera variación temporal entre el cereal y maíz. En el cereal la aplicación del herbicida se lleva a cabo más bien al principio de la primavera, mientras que en el maíz se realiza más avanzada la primavera, en ambos casos depende siempre del estado de crecimiento tanto de las malas hierbas como de los cultivos. No obstante, tanto en el cereal como en el maíz se presenta la misma problemática de forma que sólo se pueden capturar en un único momento del ciclo anual, es decir, una vez al año. Esto se traduce en el hecho de que ante cualquier problemática surgida o inconveniente se hace necesario esperar hasta el próximo ciclo de crecimiento, lo que ocurrirá al año siguiente.

Para la verificación de la eficacia de los métodos es necesario definir una métrica que cuantifique los resultados obtenidos por los mismos. Esto se lleva a cabo en la sección 4.2, donde se definen dos coeficientes de medida.

Dado que para la validación de los experimentos no hay disponible una base de imágenes clasificadas, es necesario recurrir a la valoración por parte de los técnicos agrícolas así como a los agricultores involucrados en el proceso. En la sección 4.3 se concretan los criterios de valoración establecidos.

El conjunto de imágenes de prueba utilizado, así como la estrategia de pruebas diseñada se concreta en la sección 4.4.

Tabla 4-1: Relación de métodos y su naturaleza frente a los atributos utilizados y el tipo de cultivo donde se aplican.

	Métodos	Relaciones de área			Relaciones estructurales	Aprendizaje	Cultivo	Referencia bibliográfica
		a_{i0}	a_{i1}	a_{i0} y a_{i1}				
Simples	SVMA	Si	Si	Si	No	Si	cereal	Tellaeché y col. 2007c y d
	BAYP	Si	Si	Si	No	Si	cereal	Tellaeché y col. 2007b
	BAYN	Si	Si	Si	No	Si	cereal y maíz	Tellaeché y col. 2007a y d
	FUCL	Si	Si	Si	No	Si	cereal	Tellaeché y col. 2007b y c
	HEBB	Si	Si	Si	No	Si	cereal	Pajares y col. 2007c
Híbridos	BAFU: BAYP + FUCL	Si	Si	Si	No	Si	cereal	Tellaeché y col. 2007b
	BASV: BAYN + SVMA	Si	Si	Si	No	Si	cereal	Tellaeché y col. 2007d
	FUSV: FUCL + SVMA	Si	Si	Si	No	Si	cereal	Tellaeché y col. 2007c
	MCDM	Si	Si	Si	Si	No	cereal	Tellaeché y col. 2007e

Dada la especificidad de cada método, se realiza un análisis individual y pormenorizado de cada uno de ellos por separado. Primeramente se analizan los resultados obtenidos por los métodos simples (sección 4.6), a continuación se realiza el análisis de los métodos utilizados de forma combinada (sección 4.7); seguidamente se analizan los resultados del método MCDM (sección 4.8). En la sección 4.9 se incluye un análisis conjunto de los diferentes métodos utilizados en el cultivo de cereal. En la sección 4.10 se describe la especificidad del método no paramétrico de la ventana de Parzen aplicado al cultivo de maíz junto con los resultados obtenidos por el mismo.

4.2. Valores y medidas de rendimiento

Para la evaluación del rendimiento y eficacia de las diferentes estrategias de clasificación se utilizan los mismos conjuntos de imágenes para todos los métodos, independientes del tipo de clasificador utilizado, que representan los errores y aciertos de clasificación de las celdas procesadas. Estos valores son los que se muestran a continuación según los criterios definidos en Sneath y Sokal (1973) y que mantenemos la nomenclatura original por ser suficientemente significativa:

1. *True Spraying (TS)*: número de celdas correctamente clasificadas como celdas a pulverizar.
2. *True No Spraying (TN)*: número de celdas que no requieren pulverización correctamente detectadas.
3. *False Spraying (FS)*: número de celdas que no requieren pulverización, pero que han sido identificadas como celdas a pulverizar.
4. *False No Spraying (FN)*: número de celdas que deben ser pulverizadas y que han sido identificadas por el método de clasificación como celdas que no requieren pulverización.

Tradicionalmente, para estas cuatro cantidades se han utilizado diferentes funciones de medida para la clasificación en general (Sneath y Sokal, 1973). Las mejores son las que combinan los cuatro valores anteriores, que se definen a continuación:

1. Porcentaje de clasificación correcta:
$$CCP = \frac{TS + TN}{TS + FS + TN + FN} \quad (4.1)$$

2. Coeficiente de Yule:
$$Yule = \left| \frac{TS}{TS + FS} + \frac{TN}{TN + FN} - 1 \right| \quad (4.2)$$

El criterio de valoración asociado con los dos coeficientes anteriores es que cuanto mayor es su valor obtenido mejor es el rendimiento del método. El Coeficiente de Yule no aporta nada especial a los valores obtenidos por el coeficiente CCP, por lo tanto en la presentación de resultados de los diferentes clasificadores se dará únicamente el

valor del CCP, junto con el porcentaje de celdas a pulverizar ,que así han sido clasificadas.

4.3. Criterio experto

Como se ha mencionado previamente, los experimentos se han llevado a cabo en dos tipos de campos de cultivo: cereales y maíz. Tradicionalmente, los primeros experimentos se llevaron a cabo en campos de cereal para el tratamiento de la *Avena Sterilis* como se ha mencionado en el capítulo primero. En lo que sigue, se hace hincapié precisamente en los criterios aplicables a este tipo de malas hierbas. Como se ha mencionado en varias ocasiones, se diferencian tanto los aspectos relacionados con los atributos que se centran en la densidad de malas hierbas (relaciones de área) como los que se derivan de la dispersión de las mismas en los campos de cultivo, originando en este último caso la definición y uso de los atributos de naturaleza estructural.

En los cultivos de maíz no existe la problemática generada por la *Avena Sterilis*, dándose otros tipos de malas hierbas. En este caso no existen estudios tan exhaustivos, al menos hasta donde se ha podido investigar, en relación a la dispersión de las malas hierbas. Como quiera que la dispersión de éstas es un concepto íntimamente relacionado con los atributos de naturaleza estructural, en el caso de los experimentos llevados a cabo en los campos de maíz no se han utilizado este tipo de atributos. No obstante, en lo que respecta a la densidad de malas hierbas son aplicables los mismos criterios que se utilizan para el caso de la *Avena Sterilis*. En lo que resta de esta sección el análisis se refiere exclusivamente a este último tipo de mala hierba, siendo extrapolable y aplicable para el caso de otros tipos de malas hierbas en cuanto a la densidad de las mismas se refiere. Esto es así debido a que su comportamiento a nivel de identificación de rodales es similar.

Para la realización de las pruebas y el entrenamiento de los algoritmos, la imágenes adquiridas han sido analizadas por un profesional experto para la detección de *A. Sterelis* en zonas con suficiente densidad y distribución con el fin de validarlas para el

tratamiento localizado. La observación visual humana fue guiada por la propia imagen segmentada según se describe en el capítulo dos. El experto identifica las celdas a pulverizar según los siguientes criterios, que se explican posteriormente:

1. Teniendo en cuenta la densidad y dispersión de las malas hierbas.
2. Analizando factores adicionales que afecten a los cultivos y al campo.
3. Inspección visual.

4.3.1. Densidad y dispersión de malas hierbas

Cuando las malas hierbas aparecen en zonas amplias con poca dispersión, el experto determina visualmente si la densidad de la mala hierba está por encima del límite considerado seguro desde el punto de vista de pérdidas en el cultivo. Si la densidad de la mala hierba supera el umbral establecido, las celdas deben ser pulverizadas. De acuerdo con estudios experimentales, la *A. Sterilis* a densidades por encima de 25 partículas por metro cuadrado (5 a 10 plantas por metro cuadrado) puede llegar a disminuir la cosecha de cereal (generalmente cebada) en un 10% (Torner y col. 1991).

Si las malas hierbas aparecen dispersas en áreas pequeñas o aisladas, el experto utiliza un umbral diferente. De acuerdo con Barroso y col. (2005), infestaciones residuales de *A. Sterilis* en el rango de 1 a 10 partículas por metro cuadrado (0.2 a 4 plantas por metro cuadrado) representan un riesgo de pérdidas en el año presente y en los dos o tres años siguientes (estimadas en un 15%).

Teniendo en cuenta la proyección de perspectiva, figura 2-2, con la que se capturan las imágenes utilizadas en los experimentos, considerando la distancia focal de la cámara (20 mm aproximadamente) y usando técnicas simples de triangularización se puede establecer la relación entre los objetos del campo y sus imágenes. Gracias a esta relación, que varía según la distancia de los objetos a la imagen se ha calculado que las celdas en la parte inferior de la imagen cubren un área de aproximadamente 0.4 m² con

8500 píxeles. Las celdas en la fila 13 cubren un área de aproximadamente 8 m^2 con 1660 píxeles. De media, el tamaño de las celdas se reduce de una fila a la siguiente a un ritmo de un 6% en términos de número de píxeles. Sin embargo, el área real del terreno en m^2 proyectada sobre esa celda que se disminuye a ese ritmo aumenta un promedio del 15%. De media una planta o agrupación de dos o tres plantas de malas hierbas en la primera fila de celdas se representa por aproximadamente 12 píxeles. Teniendo en cuenta la reducción de número de píxeles (72% en la fila 13), en esta fila, la misma planta o agrupación de malas hierbas es representada por 3 o 4 píxeles. Esto justifica la elección del umbral T_a (ver sección 2.4.1) y la eliminación de áreas pequeñas sólo en la parte inferior de la imagen.

4.3.2. Factores adicionales

El profesional experto tiene disponible un mapa de riesgo del campo, establecido después de tener en cuenta los siguientes datos: estabilidad de las malas hierbas a lo largo de los años, aparición de malas hierbas en años previos, propiedades bioquímicas del suelo y densidades de malas hierbas, estas últimas estimadas visualmente en años precedentes. La relativa gran estabilidad espacial de la *A. Sterilis* se ha utilizado para mejorar la precisión de la detección de esta clase de malas hierbas (Barroso y col., 2004a). Varios estudios llevados a cabo por Walter y col. (1997) y Christensen y Heisel (1998) han utilizado mapas de malas hierbas para dividir el campo en zonas donde se detectan las malas hierbas. Después de esta operación, las zonas que se han identificado como problemáticas son analizadas con mayor resolución, usando técnicas de detección en tiempo real.

4.3.3. Observación visual

La inspección visual en la etapa de crecimiento tanto del cultivo como de las malas hierbas verifica la decisión del experto basado en los dos puntos anteriores.

Aunque el consejo experto es válido para un uso práctico, hay que reconocer varias fuentes de errores en las estimaciones. La primera de ellas viene dada por el hecho de que la inspección visual del tamaño de la zona de malas hierbas y la densidad ofrece cierto grado de incertidumbre. En efecto, aunque la densidad de malas hierbas puede ser estimada de manera más fehaciente en áreas más cercanas al observador, el grado de seguridad decrece rápidamente a medida que la distancia se incrementa. Además, aunque es relativamente fácil detectar altas densidades de malas hierbas visualmente, no es tan fácil detectar las bajas densidades (1 planta por metro cuadrado). Esto, junto con el hecho de que las zonas de malas hierbas ofrecen a menudo formas irregulares y bordes no definidos, puede introducir algunos errores definiendo el perímetro de la zona de malas hierbas. Otro factor potencial de errores es la incertidumbre en la estimación de pérdidas en la cosecha. Dependiendo de las condiciones meteorológicas en un año determinado, las pérdidas ocasionadas por la *A. Sterilis* pueden variar sustancialmente (Torner y col., 1991). Debido a esta variabilidad del tiempo meteorológico, el uso de umbrales para el control de malas hierbas no ha recibido mucha atención práctica en el pasado.

En los trabajos de campo experimentales con *A. Sterilis*, se han usado cuatro categorías, con niveles de infestación variando en una escala logarítmica (>0.1 plantas m^{-2} , $0.1-1$ plantas m^{-2} , $1-10$ plantas m^{-2} , y >10 plantas m^{-2}). Este tipo de sistema de marcado de los campos por categorías puede contribuir a minimizar dos de los mayores problemas inherentes a toda actividad humana, preparación inadecuada y reducción de la calidad del trabajo realizado debido a la fatiga, lo que justifica el uso de sistemas automáticos de visión por computador, debido principalmente a que están libres de fatiga. En el peor de los casos, estos sistemas siempre servirán como guía, si bien lo ideal es perfeccionarlos hasta conseguir que sustituyan, hasta donde se pueda, el trabajo de detección humano.

4.4. Descripción del conjunto de imágenes de prueba y su procesamiento secuencial

Dado que la experiencia se ha llevado a cabo en dos tipos de cultivos, existen también diferentes tipos de imágenes, distinguiendo entre las imágenes procedentes de los campos de cereal y las imágenes obtenidas en los campos de maíz.

4.4.1. Imágenes de los campos de cereal

Se dispone de un conjunto de 146 imágenes, que se divide en tres subconjuntos de forma aleatoria, esto es, sin tener en cuenta ningún criterio sobre ellos. Dichos subconjuntos se denominan B_1 , B_2 y B_3 , cada uno de los cuales consta de 30, 20 y 96 imágenes respectivamente. Cada subconjunto es segmentado aplicando el proceso descrito en el capítulo dos obteniendo 48 celdas por cada imagen. Cada celda se describe por sus atributos cuantitativos a_i y cualitativos S_i según el proceso explicado en el punto 2.5 de esta memoria.

La descripción de cada uno de los subconjuntos se proporciona a continuación:

1. El subconjunto B_1 es el utilizado en la sección 2.5.1 con $F = 245$ y $H = 1195$ que se utilizan para obtener las diferentes zonas en el campo de cultivo y de aquí los umbrales característicos de cada celda en relación a la zona de cultivos y malas hierbas. Estas celdas se almacenan en la BC con sus correspondientes valores de atributos. En este momento se dispone ya de un primer conjunto de patrones de entrenamiento.
2. El subconjunto B_2 se utiliza para ajustar los pesos w_1 y w_2 que determinan la importancia relativa de los criterios de beneficio y coste del método MCDM según se explica en la sección 3.7 a través del algoritmo ID3. Como en el caso anterior, para cada imagen se extraen 48 celdas por lo que este conjunto consta de 960 celdas. Basándonos en el criterio del experto expuesto previamente en la sección 4.3, un total de 182 celdas de este

subconjunto fueron clasificadas como celdas que requieren pulverización, lo que representa un total del 19%; el resto (81%) se clasificaron como celdas que no requieren pulverización.

3. El subconjunto B_3 se divide a su vez en otros tres subconjuntos, B_{31} , B_{32} y B_{33} , cada uno de ellos contiene 32 imágenes. Esta subdivisión se vuelve a realizar de forma aleatoria, siendo su objetivo la verificación del proceso de aprendizaje, como se describe más adelante en esta misma sección.

Conviene destacar que las imágenes que forman los conjuntos anteriores son todas ellas diferentes entre sí y que una misma imagen no forma parte de más de un subconjunto a la vez. En la figura 4-1 se muestran tres imágenes representativas de los tres subconjuntos de imágenes utilizadas. En (a), (c) y (e) aparecen tres imágenes originales representativas de los subconjuntos B_1 , B_2 y B_3 ; en (b), (d) y (f) se muestran esas mismas imágenes ya segmentadas según el procedimiento descrito en el capítulo dos. Como puede apreciarse, todas ellas aparecen bajo la proyección de perspectiva, tal y como se describió en la sección 2.3, puede observarse cómo el ángulo de inclinación de la cámara varía de unas imágenes a otras con lo que los surcos de las imágenes aparecen bajo diferentes grados de inclinación. Esta circunstancia fue considerada al obtener las medidas relativas de los atributos tanto cuantitativas como cualitativas, otorgando al método propuesto un cierto grado de robustez frente a este tipo de variaciones, que por otro lado son relativamente frecuentes dada la posición de la cámara en el tractor.

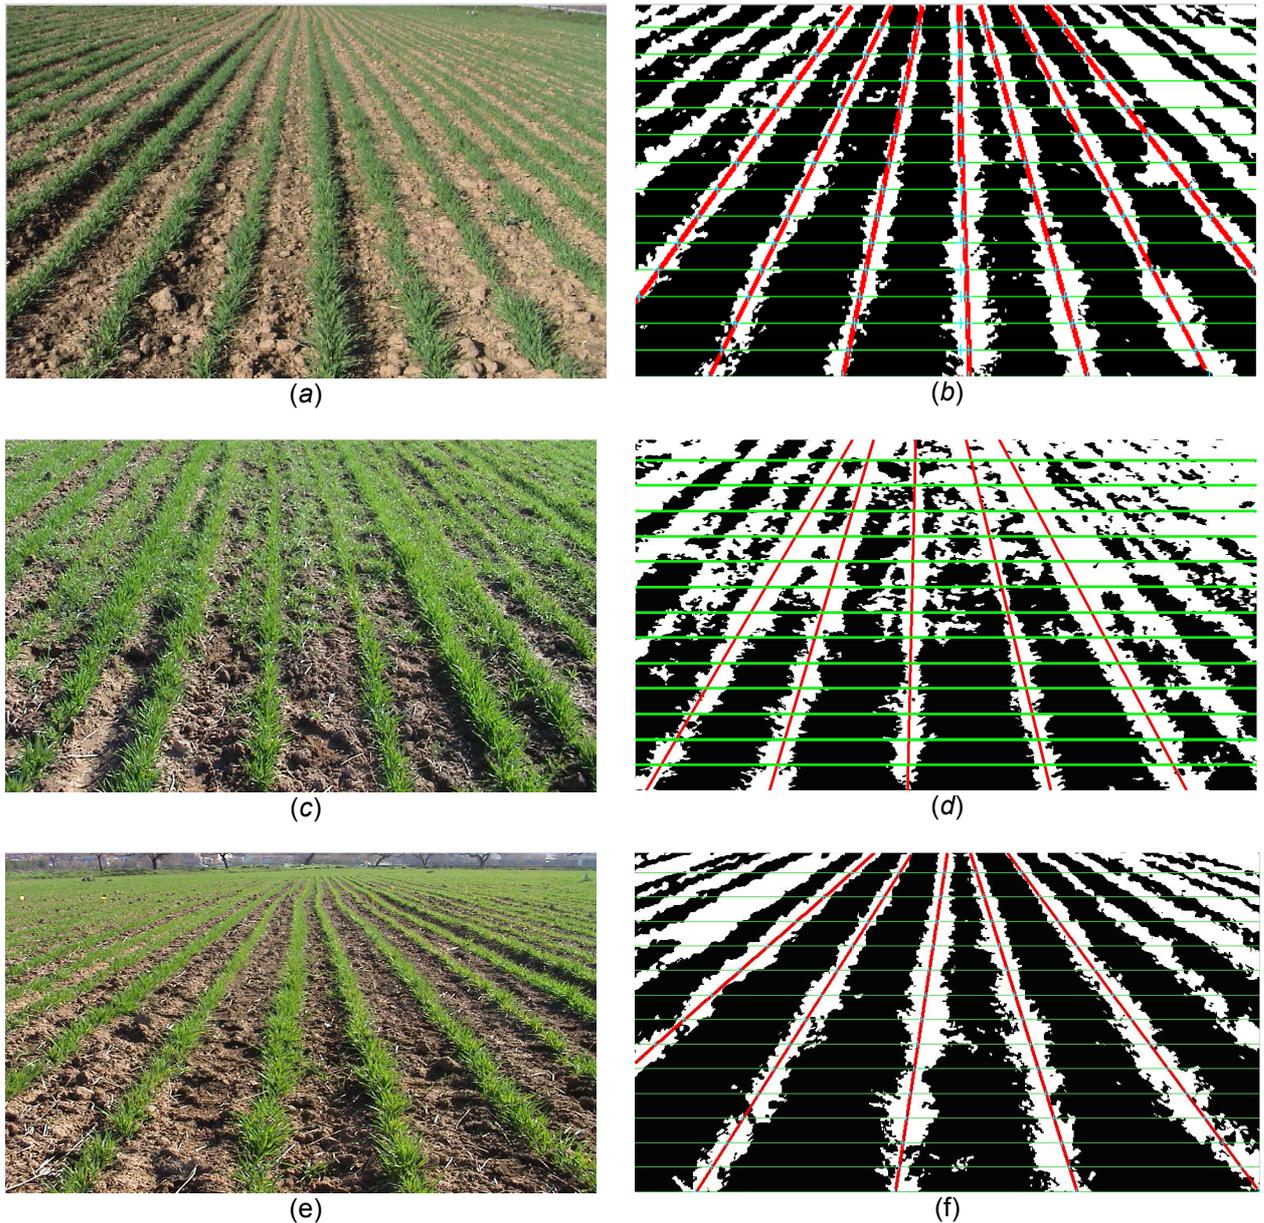


Figura 4-1: Imágenes representativas de los tres subconjuntos (B1, B2 y B3) de imágenes de cereal. En la parte izquierda se representa la imagen original y en la derecha las correspondientes imágenes segmentadas.

Los subconjuntos B_{31} , B_{32} y B_{33} permiten establecer tres pasos PS1, PS2 y PS3 que junto con el subconjunto B_1 determinan el proceso de entrenamiento como sigue:

1. Inicialmente, con las celdas procedentes de B_1 se establece un primer paso denominado paso cero, PS0 que permite cargar la *BC*. Es decir se determina, mediante el criterio del experto, las celdas que son consideradas como celdas a

pulverizar (CP_0) y las que no lo son (CN_0). Con estos dos conjuntos de muestras clasificadas se realiza un primer proceso de entrenamiento (*off-line*) por parte de los diferentes algoritmos de clasificación utilizados, se obtienen los parámetros o funciones de decisión derivadas del aprendizaje, que se almacenan en la BC junto con las propias muestras.

2. El segundo paso, PS1, consiste en clasificar las celdas procedentes del conjunto B_{31} como celdas a pulverizar o no mediante el correspondiente proceso *on-line*. De este modo se obtienen dos nuevos conjuntos de celdas que añadidas a las ya existentes generan de nuevo sendos conjuntos de celdas a pulverizar (CP_1) y a no pulverizar (CN_1) Realizada esta operación las nuevas celdas clasificadas se añaden a la BC, procediéndose a realizar un nuevo proceso de entrenamiento (*off-line*) con el fin de actualizar los parámetros y funciones de decisión, que quedan de este modo disponibles para futuros procesos *on-line*.
3. El tercer paso, PS2, consiste en realizar la misma operación que en el paso previo, si bien con el subconjunto B_{32} , obteniéndose así los nuevos conjuntos de celdas a pulverizar CP_2 y CN_2 que se añaden a las ya existentes en la BC. Con ellas y mediante un nuevo proceso de entrenamiento se actualizan de nuevo los parámetros y funciones de decisión.
4. Finalmente, en el paso cuatro, PS3, se vuelven a clasificar las muestras procedentes del conjunto B_{33} . En este caso ya no es necesario actualizar la BC porque no se realizan más procesos de clasificación.

Los grupos de celdas CP_0 , CP_1 , CP_2 , CP_3 , CN_0 , CN_1 , CN_2 y CN_3 que generan los diferentes métodos difieren de un método a otro como cabe esperar del distinto comportamiento entre ellos.

En la Tabla 4.2 se muestran ejemplos significativos tanto de celdas que requieren pulverización como de celdas que no lo requieren a juicio del experto. Dentro de las primeras se pueden observar a su vez dos tipos de celdas, distinguiéndose entre

las que la pulverización es requerida por alta densidad de malas hierbas y las que requieren pulverización por una dispersión alta de las mismas.

Tabla 4-2: Celdas tipo a pulverizar y a no pulverizar

<i>Ejemplos de celdas a pulverizar</i>		<i>Ejemplos de celdas a no pulverizar</i>
<i>Alta densidad</i>	<i>Alta dispersión</i>	
		
		
		

4.4.2. Imágenes de los campos de maíz

Para las pruebas del clasificador en cultivos de maíz se han utilizado un conjunto de 340 imágenes. Estas imágenes fueron adquiridas a lo largo de 4 días diferentes en Abril de 2006 y otros 4 días también diferentes en Abril y Mayo de 2007. Cada uno de las adquisiciones fueron espaciadas 5 ó 6 días entre sí. Estas imágenes, al igual que las imágenes capturadas para cereal, también fueron obtenidas en condiciones de iluminación variables. De las 340 imágenes, 160 han sido utilizadas para la inicialización del clasificador y las restantes 180 se han organizado como se expone a continuación con el fin de comprobar la validez y rendimiento de este clasificador:

1. Se han seleccionado 18 secuencias de video conteniendo imágenes consecutivas, adquiridas realizando un movimiento de avance con la cámara, posicionada en la parte frontal de un tractor agrícola.
2. Para cada secuencia de video, se extraen 10 frames. Por lo tanto, el frame k^{th} en la secuencia i es f_i^k , donde $k = 1, \dots, 10$ e $i = 1, \dots, 18$.
3. Dados dos frames consecutivos f_i^k y f_i^{k+1} , deben diferenciarse en 3c filas de imagen, que equivale a tres filas de celdas. Tomando la esquina inferior izquierda

como el origen de coordenadas, la fila número 1 en f_i^{k+1} debe coincidir con la fila 3c en f_i^k , la constante c es un parámetro definido previamente y establecido a un valor de 50. Esta coincidencia de filas se debe a la transformación de perspectiva con la que se capturan las imágenes. Esto implica que la decisión final debería realizarse con la primera, segunda y tercera fila de celdas de la imagen. La cuarta y quinta fila se utilizan para calcular la información *a priori*, que es usada junto con la información posterior en la decisión para el siguiente frame. En el caso del primer frame en la secuencia con $k = 1$, no habrá información *a priori* durante el proceso de decisión final, porque las filas de celdas primera, segunda y tercera no han sido procesadas previamente.

4. Como resultado de lo expuesto en los tres puntos anteriores, para cada frame se procesan diez celdas, pertenecientes a las cinco filas inferiores de la imagen. La decisión se lleva a cabo para las seis más próximas a la parte inferior de la imagen, mientras que las cuatro celdas restantes son usadas como la probabilidad *a priori* para el siguiente frame.

En la figura 4-2 se muestran en (a) y (b) sendas imágenes originales correspondientes a dos frames consecutivos representativas de los campos de cultivo de maíz. En (c) y (d) las correspondientes imágenes segmentadas. No obstante, lo que conviene destacar es el hecho que se pone de manifiesto en ellas. En efecto, la imagen (a) muestra un rodal de malas hierbas que aparece en una posición determinada de la imagen y en una localización concreta del campo. A medida que el tractor avanza en su tarea de pulverización del campo, este rodal se manifiesta en la imagen (b) en una posición diferente, concretamente en la parte más inferior de la imagen como consecuencia de su mayor proximidad al sistema de visión en la realidad. Se observa que como consecuencia del acercamiento del tractor al rodal y debido a la mencionada transformación de perspectiva la mancha se ha expandido sobre la imagen. En efecto, en la imagen (c) ocupa cuatro celdas mientras que en la imagen (d) las celdas ocupadas son seis. Este hecho determina que la probabilidad *a priori* aplicable en la imagen (d) sobre las mencionadas seis celdas procede de la probabilidad obtenida en la imagen (c) para las cuatro celdas mencionadas y que ahora se han convertido en seis. Esto es lo que

determina el criterio utilizado para elaborar la estrategia de test anteriormente mencionada para este tipo de imágenes.

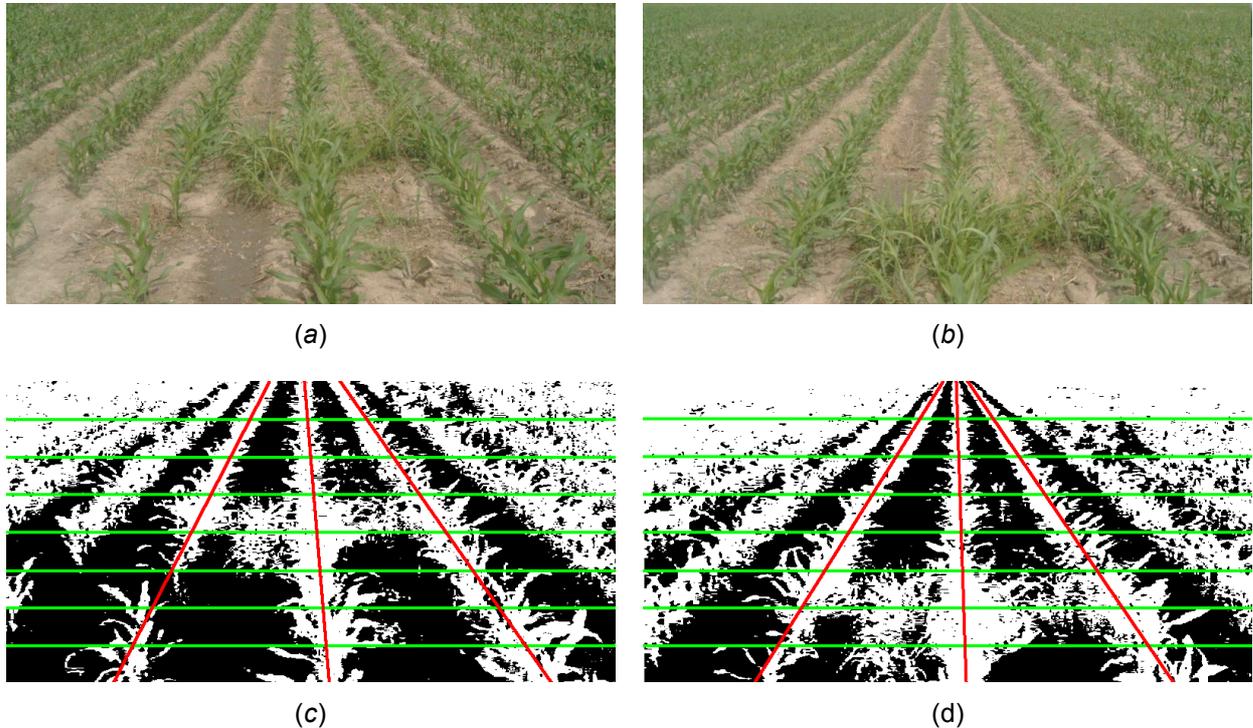


Figura 4-2: Diferentes perspectivas según el avance del tractor de un campo de maíz y sus respectivas imágenes segmentadas.

4.5. Estrategia de test para los métodos de clasificación simples e híbridos en los campos de cereal.

La estrategia de test que se describe a continuación se aplica a los campos de cereal para los siguientes métodos de clasificación, cuyos acrónimos aparecen en la tabla 4.1.

1. Simples: SVMA, BAYP, BAYN, FUCL, HEBB.
2. Híbridos: BAFU, BASV, FUSV.

Para el análisis de los resultados obtenidos por medio de los diferentes tests se distingue entre el proceso *off-line* y *on-line*, de forma que durante el primero se realiza el

proceso de aprendizaje y durante el segundo la decisión, según lo establecido desde el principio en la figura 2-1.

Como se ha mencionado anteriormente, se realizan cuatro pasos desde $n = 0$ a $n = 3$. En cada paso se llevan a cabo los correspondientes procesos *off-line* y *on-line* dependiendo del tipo de test aplicado. Como ya se ha comentado también previamente, para cada paso se añaden nuevas celdas a las ya existentes. En el PASO 0 se utilizan las 30 imágenes correspondientes al subconjunto B_1 . Para los PASOS 1 a 3 se utilizan las imágenes correspondientes a los grupos B_{31} , B_{32} y B_{33} , que son las 32 imágenes que constituyen cada grupo. Como de cada imagen se extraen 48 celdas, esto significa que el número de celdas utilizadas en cada paso son las que se muestran en la tabla 4.3.

Tabla 4-3: Número de celdas procesadas en cada paso

	PASO 0	PASO 1	PASO 2	PASO 3
número de celda	1440	2976	4512	6048

Siguiendo la estrategia de pruebas general descrita previamente se realizan exactamente los mismos cuatro pasos tal y como se describe a continuación para mayor concreción,

1. PASO 0 ($n = 0$): Proceso *off-line* con las celdas de los grupos CP_0 y CN_0 se obtienen los parámetros y funciones de decisión correspondientes mediante el proceso de entrenamiento.
2. Para $n=1$ a $n=3$ realizar:
 - a. PASO n : Procesamiento *on-line*, donde se realiza el proceso de decisión según el método correspondiente.
 - b. Tras la decisión se obtienen los grupos de celdas CP_n y CN_n que se utilizan para realizar un nuevo proceso *off-line*, actualizándose de nuevo los parámetros y funciones de decisión en cada paso n .

Tabla 4-4: Métodos simples: resumen de parámetros obtenidos mediante el proceso de entrenamiento (off-line) y decisión en el proceso de clasificación (on-line)

<i>Métodos Simples</i>	<i>Parámetros resultantes del proceso de entrenamiento (off-line)</i>	<i>Proceso de decisión (on-line)</i>
	Se dispone de los dos conjuntos CP y CN , que forman dos clústeres	Dada una nueva celda s con su vector de atributos cuantitativos \mathbf{s} se procede a su clasificación como perteneciente a CP o CN según el criterio de clasificación de cada método
SVMA	Vectores soporte según ecuaciones (3.2) y (3.3)	Obtener: $f(\mathbf{s}) = \sum_{\text{vectores soporte}} \alpha_i y_i H(\mathbf{x}_i, \mathbf{s}) - b$ Si $f(\mathbf{s}) > 0$ entonces $s \in CP$ y a CN en caso contrario
BAYP	Vectores media (centroides) y matrices de covarianza de los dos clústeres $\mathbf{m}_1, \mathbf{m}_2$ y C_1, C_2 según la ecuación (3.18) Función de densidad de probabilidad Gaussiana según la ecuación (3.9) para cada clúster	Obtener las probabilidades de pertenencia de la muestra a cada clúster $p_1(\mathbf{s})$ y $p_2(\mathbf{s})$ $s \in CP$ si $p_1(\mathbf{s}) > p_2(\mathbf{s})$ y a CN en caso contrario
BAYN	Todas las muestras disponibles junto con las matrices de covarianza de los dos clústeres C_1, C_2 Función de densidad de probabilidad según la ecuación (3.35)	Obtener las probabilidades de pertenencia de la muestra a cada clúster $p_1(\mathbf{s})$ y $p_2(\mathbf{s})$ $s \in CP$ si $p_1(\mathbf{s}) > p_2(\mathbf{s})$ y a CN en caso contrario
FUCL	Centroides de los clústeres $\mathbf{v}_1, \mathbf{v}_2$, según la ecuación (3.52)	Obtener: $\ \mathbf{s} - \mathbf{v}_i\ _G^2 = (\mathbf{s} - \mathbf{v}_i)^t G(\mathbf{s} - \mathbf{v}_i)$ Si $\ \mathbf{s} - \mathbf{v}_1\ _G^2 < \ \mathbf{s} - \mathbf{v}_2\ _G^2$ entonces $s \in CP$ y a CN en caso contrario
HEBB	Vectores centroides de los dos clústeres $\mathbf{v}_1, \mathbf{v}_2$, según la ecuación (3.59) y las matrices de covarianza C_1, C_2 según la ecuación (3.18)	Obtener las distancias de Mahalanobis de la muestra a los centros de cada clúster $d_M^2(\mathbf{s}, \mathbf{v}_i)$ $s \in CP$ si $d_M^2(\mathbf{s}, \mathbf{v}_1) < d_M^2(\mathbf{s}, \mathbf{v}_2)$ y a CN en caso contrario

Tabla 4-5: Métodos híbridos: resumen de parámetros obtenidos mediante el proceso de entrenamiento (off-line) y decisión en el proceso de clasificación (on-line)

Métodos Híbridos	Parámetros resultantes del proceso de entrenamiento (off-line)	Proceso de decisión (on-line)
	Se dispone de los dos conjuntos CP y CN , que forman dos clústeres	Dada una nueva celda s con su vector de atributos cuantitativos \mathbf{s} se procede a su clasificación como perteneciente a CP o CN según el criterio de clasificación de cada método
BAFU	Parámetros de BAYP y FUCL BAYP: estimar las funciones de densidad de probabilidad según la ecuación (3.9), $p(\mathbf{x}/w_1)$, $p(\mathbf{x}/w_2)$ FUCL: determinar los centroides de cada clúster \mathbf{v}_1 , \mathbf{v}_2 , según la ecuación (3.52)	Obtener el grado de pertenencia de s a cada clúster μ_{s1} y μ_{s2} según la ecuación (3.53) y hacer $P(w_1) = \mu_{s1}$ y $P(w_2) = \mu_{s2}$ Obtener la probabilidad de pertenencia de s a cada clúster: $p(\mathbf{s}/w_1)$, $p(\mathbf{s}/w_2)$ $s \in CP$ si $p(\mathbf{s}/w_1) P(w_1) > p(\mathbf{s}/w_2) P(w_2)$ y a CN en caso contrario
BASV	Parámetros de BAYN y SVMA BAYN: estimar las funciones de densidad de probabilidad según la ecuación (3.35), $p(\mathbf{x}/w_1)$, $p(\mathbf{x}/w_2)$ SVMA: vectores soporte según ecuaciones (3.2) y (3.3)	Obtener el valor generado por la función sigmoideal para \mathbf{s} según la ecuación (3.63) y hacer $P(w_1) = d_{sy}$ y $P(w_2) = 1 - d_{sy}$ Obtener la probabilidad de pertenencia de \mathbf{s} : $p(\mathbf{s}/w_1)$, $p(\mathbf{s}/w_2)$. $s \in CP$ si $p(\mathbf{s}/w_1) P(w_1) > p(\mathbf{s}/w_2) P(w_2)$ y a CN en caso contrario
FUSV	Parámetros de FUCL y SVMA FUCL: determinar los centroides de cada clúster \mathbf{v}_1 , \mathbf{v}_2 , según la ecuación (3.52) SVMA: vectores soporte según las ecuaciones (3.2) y (3.3)	Obtener el grado de pertenencia de \mathbf{s} a cada clúster μ_{s1} y μ_{s2} según la ecuación (3.53) Obtener el valor generado por la función sigmoideal para \mathbf{s} según la ecuación (3.63) d_{sy} y hacer $d_{sn} = 1 - d_{sy}$. Computar h_{s1} y h_{s2} según la ecuación (3.64) $s \in CP$ si $h_{s1} > h_{s2}$ y a CN en caso contrario

Por otro lado, en cada uno de los pasos se llevan a cabo tres tipos de test: Test 1, Test 2 y Test 3. El Test 1 utiliza las dos componentes a_{i0} y a_{i1} de las relaciones cuantitativas. El Test 2 utiliza sólo la primera de estas componentes a_{i0} , mientras que el Test 3 utiliza sólo la segunda de las componentes a_{i1} . El primero de los atributos cuantitativos es utilizado también en Tian y col. (1999), y el segundo de los atributos es utilizado en Ribeiro (2005), por lo tanto, el método desarrollado utilizando todas las

relaciones cuantitativas se compara implícitamente con estas dos estrategias existentes en la literatura.

4.6. Resultados de los métodos de clasificación simples en cultivos de cereal

4.6.1. Máquinas de vectores soporte: SVM

Se han realizado una serie de experimentos previos para determinar cuál es el mejor de los núcleos disponibles para las *máquinas de vectores soporte*. La tabla 4.6 muestra el número de imágenes procesadas en cada paso PS_n , según el procedimiento descrito previamente. También se calculan los valores del margen τ , ecuación (3.8), para los siguientes núcleos:

1. Funciones gaussianas de base radial (RBF):

$$H(\mathbf{x}, \mathbf{y}) = \exp\left\{-\|\mathbf{x} - \mathbf{y}\|^2 / \sigma^2\right\} \text{ con } \sigma^2 = 3.0.$$

2. Polinomial (POL): $H(\mathbf{x}, \mathbf{y}) = \langle \mathbf{x}, \mathbf{y} \rangle^d$ con grado $d = 2$.

3. Sigmoide (SIG): $H(\mathbf{x}, \mathbf{y}) = \tanh(\rho \langle \mathbf{x}, \mathbf{y} \rangle + \gamma)$ con $\rho = 2$ y $\gamma = 3$.

Los parámetros para cada uno de los núcleos han sido seleccionados mediante prueba y error; $\langle \mathbf{x}, \mathbf{y} \rangle$ representa el producto escalar.

Tabla 4-6: Número de imágenes y valores de margen para las funciones gaussianas de base radial (RBF), Polinomiales (POL) y sigmoides (SIG)

τ	PASO 0	PASO 1	PASO 2	PASO 3
# de imágenes	30	62	94	126
RBF	0.52	0.59	0.65	0.78
POL	0.39	0.40	0.51	0.57
SIG	0.33	0.35	0.42	0.50

El margen τ determina cuál es el mejor núcleo de acuerdo con el hiperplano óptimo, ya que según sea éste la decisión final se verá afectada. En este sentido, cuanto mayor sea el valor de τ la decisión está sujeta a un menor error potencial. Por lo tanto, a la vista de los resultados de la tabla 4.6, el núcleo RBF es el más prometedor, siendo éste el núcleo utilizado en los experimentos realizados en este trabajo para el método SVMa.

La tabla 4.7 muestra el número de celdas a ser pulverizadas (CP_n) y el número de celdas que no necesitan ser pulverizadas (CN_n) en cada paso n . Para cada Test también se muestra el número total de vectores soporte obtenido.

Tabla 4-7: Número de imágenes, número de celdas a pulverizar (CP) y a no pulverizar (CN); vectores soporte para cada test.

		PASO 0	PASO 1	PASO 2	PASO 3
<i>número de celdas</i>		1440	2976	4512	6048
<i>Test 1</i>	CP_n	312	815	1165	1385
	CN_n	1128	2161	3347	4663
	<i>número de vectores soporte</i>	67	71	79	83
<i>Test 2</i>	CP_n	312	931	1285	1598
	CN_n	1128	2045	3227	4450
	<i>vectores soporte</i>	87	96	112	123
<i>Test 3</i>	CP_n	312	997	1433	1765
	CN_n	1128	1979	3097	4283
	<i>vectores soporte</i>	84	78	89	104

La tabla 4.8 muestra los resultados basados en el coeficiente CCP, ecuación (4.1). Se calculan los coeficientes de clasificación correcta y el porcentaje de las celdas a pulverizar. Para mayor claridad de los resultados en la Figura 4-3 se muestra el coeficiente CCP en los tres pasos establecidos y para los tres tests diseñados.

Tabla 4-8: Valores de CCP y porcentaje de celdas a pulverizar para los tres tests y los pasos realizados

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	73	30	80	25	85	22
Test 2	63	33	67	31	66	31
Test 3	64	32	71	31	71	31

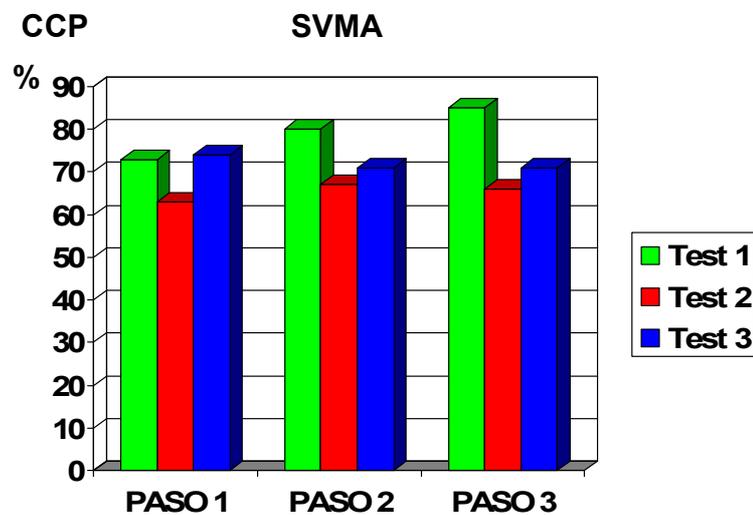


Figura 4-3: SVMA: Valores del coeficiente de CCP para los tres tests

Mediante la observación de los resultados obtenidos en las tablas 4.7 y 4.8 se puede deducir que el mejor rendimiento se obtiene en el Test 1 para el PASO 3. Esto significa que el uso de los dos atributos cuantitativos utilizados mejora el rendimiento si se compara con el uso de un único atributo (Test 2 y Test 3). También se produce una mejora de rendimiento en el proceso de aprendizaje, como se deduce de los resultados obtenidos en el PASO 3.

Por otro lado, conviene señalar que cuanto menor sea el porcentaje de celdas a pulverizar menor será la contaminación medioambiental por herbicida y mayor el ahorro económico de la operación de tratamiento de malas hierbas. Según estos dos criterios, es el Test 1 el que obtiene los mejores resultados.

4.6.2. Clasificador de Bayes paramétrico: BAYP

4.6.2.1 Propiedades estadísticas de las clases

En la tabla 4.9 se presentan los valores de los centroides obtenidos en cada paso para cada una de los clústeres o clases *CP* y *CN* y los tres tests especificados para el clasificador de Bayes paramétrico.

Tabla 4-9: Valores de los centros obtenidos durante los cuatro pasos para los tres tests y los dos grupos de celdas.

Centros de los clústeres		PASO 0	PASO 1	PASO 2	PASO 3
Test 1	CP	(0.63, 0.68)	(0.67, 0.72)	(0.66, 0.75)	(0.67, 0.79)
	CN	(0.05, 0.11)	(0.08, 0.13)	(0.10, 0.14)	(0.11, 0.15)
Test 2	CP	0.63	0.66	0.69	0.70
	CN	0.05	0.06	0.11	0.12
Test 3	CP	0.73	0.74	0.75	0.77
	CN	0.08	0.10	0.12	0.14

Las matrices de covarianza asociadas a cada una de las clases obtenidas en el PASO 3 para el Test 1 son las dadas a continuación:

$$C^{CP} = \begin{bmatrix} 0.0065 & 0.0011 \\ 0.0011 & 0.0109 \end{bmatrix} \quad \text{y} \quad C^{CN} = \begin{bmatrix} 0.0091 & 0.0009 \\ 0.0009 & 0.0088 \end{bmatrix}$$

donde C^{CP} y C^{CN} son las matrices de covarianza asociadas a las respectivas clases *CP* y *CN*.

Como se ha mencionado previamente el Test 1 utiliza las dos componentes a_{i0} y a_{i1} de las relaciones cuantitativas. Por tanto los vectores patrón son de la forma $\mathbf{x} = (x_1, x_2) = (a_{i0}, a_{i1})$ donde las componentes x_1 y x_2 se denominan características.

Como bien es sabido, de la teoría basada en los reconocedores estadísticos (Duda y col., 2001; Maravall, 1993), una matriz de covarianza genérica para una clase cuyos patrones son bidimensionales (como el caso que nos ocupa) tiene la siguiente representación:

$$C = \begin{bmatrix} \sigma_1^2 & r_{12}\sigma_1\sigma_2 \\ r_{12}\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix} \quad (4.3)$$

donde σ_1 y σ_2 son las desviaciones típicas de las características x_1 y x_2 respectivamente; r_{12} es el coeficiente de correlación, de forma que si dicho coeficiente es cero, se dice entonces que las características x_1 y x_2 están incorreladas, que resulta ser siempre una propiedad deseable. Dicho de otra manera, lo que interesa es que las características se escojan de tal forma que la matriz de covarianza sea diagonal principal pura.

En el caso que se estudia se tiene que para la clase *CP* el coeficiente de correlación de las dos variables involucradas obtenido a partir de la matriz de covarianza

$$C^{CP} \text{ resulta ser el siguiente } r_{12}^{CP} = \frac{C_{12}^{CP}}{\sigma_1^{CP}\sigma_2^{CP}} = \frac{0.0011}{\sqrt{0.0065}\sqrt{0.0109}} = 0.1307;$$

que el coeficiente de correlación para la clase *CN* y también para las dos variables se

$$\text{deduce de forma similar, resultando } r_{12}^{CN} = \frac{C_{12}^{CN}}{\sigma_1^{CN}\sigma_2^{CN}} = \frac{0.0009}{\sqrt{0.0091}\sqrt{0.0088}} = 0.1006.$$

Teniendo en cuenta que el coeficiente de correlación puede tomar valores en el intervalo $[-1, +1]$, los valores obtenidos se sitúan relativamente próximos al cero y por tanto se puede decir que la correlación entre las variables x_1 y x_2 es baja de forma que los valores que toma el atributo a_{i0} no influye grandemente en el valor que pueda tomar el atributo a_{i1} y viceversa, lo cual indica que se trata de dos descriptores de celdas apropiados.

A partir de las medias y matrices de covarianza se pueden obtener los valores de la divergencia y la distancia de Jeffries-Matusita (Pajares y Cruz, 2007a; Pinilla, 1995) que indican la separación entre las clases *CP* y *CN*.

Divergencia:

$$\begin{aligned}
 Diverg_{ij} = & \frac{1}{2} Tr[(C_i - C_j)(C_j^{-1} - C_i^{-1})] \\
 & + \frac{1}{2} Tr[(\mathbf{m}_i - \mathbf{m}_j)(C_i^{-1} + C_j^{-1})(\mathbf{m}_i - \mathbf{m}_j)]
 \end{aligned} \quad (4.4)$$

donde $Tr[\cdot]$ es la traza de una matriz (suma de los elementos de la diagonal principal), C_i y C_j son las matrices de covarianza de dos supuestas clases w_i y w_j y \mathbf{m}_i y \mathbf{m}_j son los vectores media de dichas clases; finalmente el superíndice t indica vector transpuesto. A mayor divergencia, mayor separabilidad de las clases, que es una situación deseable

Distancia de Jeffries-Matusita:

$$J_{ij} = 2(1 - e^{-B_{ij}}) \quad (4.5)$$

donde B es la distancia de *Bhattacharya* dada por,

$$B_{ij} = \frac{1}{8} (\mathbf{m}_i - \mathbf{m}_j)^t \left(\frac{C_i + C_j}{2} \right)^{-1} (\mathbf{m}_i - \mathbf{m}_j) + \frac{1}{2} \ln \frac{2|C_i + C_j|}{\sqrt{|C_i|}\sqrt{|C_j|}} \quad (4.6)$$

$|C|$ indica el determinante de C . Cuanto mayor sea su valor mayor separabilidad de las clases.

Los valores obtenidos para el PASO 3 y el Test 1 han sido los siguientes:

1. Divergencia = 74.9274
2. Distancia de Jeffries-Matusita = 1.99

Para deducir la separabilidad de las clases no se puede establecer un criterio relativo ya que son medidas absolutas, lo que si es cierto es que cuanto mayor sea su diferencia respecto de cero tanto mejor será la separabilidad. El valor más significativo es el proporcionado por la divergencia ya que su separación de cero es considerable.

Del análisis de correlación y separabilidad de las clases se deduce que los atributos utilizados como medidas cuantitativas son satisfactorios y que a juzgar por los índices de separabilidad, los dos tipos de clases estudiadas se encuentran lo suficientemente separadas como para suponer que las decisiones gocen de un cierto grado de confianza.

4.6.2.2 Resultados obtenidos

En la tabla 4.10 se muestran los resultados obtenidos con el clasificador Bayesiano paramétrico, para cada uno de los pasos y los tres test establecidos, junto con el porcentaje de celdas sobre las que finalmente se toma la decisión de pulverizar. La figura 4-4 muestra gráficamente los mismos resultados que la tabla para el coeficiente CCP.

Tabla 4-10: Valor de CCP y porcentaje de celdas a pulverizar para el clasificador Bayesiano paramétrico

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	75	25	82	23	87	23
Test 2	71	29	76	26	78	25
Test 3	64	34	71	32	72	31

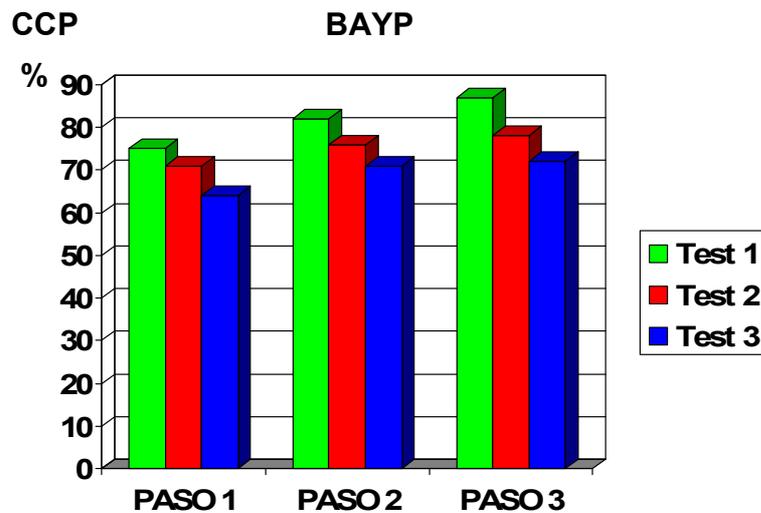


Figura 4-4: BAYP: valores del coeficiente de CCP para los tres tests

Como puede observarse de nuevo, los mejores resultados se obtienen para el PASO 3 (mayor número de celdas de entrenamiento), donde hay más celdas para el entrenamiento y el Test 1, que utiliza los dos atributos cuantitativos.

4.6.3. Clasificador de Bayes no paramétrico: BAYN

En la tabla 4.11 se muestran los resultados obtenidos con el clasificador Bayesiano no paramétrico, para cada uno de los pasos y los tres test establecidos, junto con el porcentaje de celdas sobre las que finalmente se toma la decisión de pulverizar. La figura 4-5 muestra gráficamente los mismos resultados que la tabla para el CCP.

Tabla 4-11: Valor de CCP y porcentaje de celdas a pulverizar para el clasificador Bayesiano no paramétrico

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	74	26	82	25	86	24
Test 2	69	32	73	28	77	27
Test 3	61	35	68	34	73	32

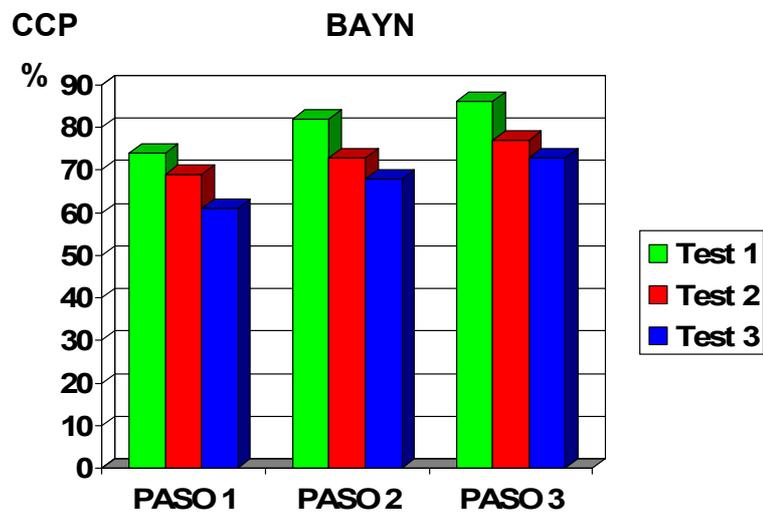


Figura 4-5: BAYN: valores del coeficiente de CCP para los tres tests.

De nuevo es el Test 1 en el PASO 3 el que obtiene los mejores resultados.

4.6.4. Fuzzy Clustering: FUCL

En la tabla 4.12 se presentan los valores de los centroides obtenidos en cada paso para cada una de las clases *CP* y *CN* y los tres tests especificados.

Tabla 4-12: Valores de los centros obtenidos durante los cuatro pasos para los tres tests y los dos grupos de celdas.

Centros de los clústeres		PASO 0	PASO 1	PASO 2	PASO 3
Test 1	CP	(0.61, 0.70)	(0.62, 0.73)	(0.64, 0.73)	(0.66, 0.74)
	CN	(0.03, 0.09)	(0.07, 0.10)	(0.08, 0.12)	(0.11, 0.12)
Test 2	CP	0.63	0.65	0.66	0.68
	CN	0.01	0.04	0.11	0.14
Test 3	CP	0.69	0.72	0.74	0.75
	CN	0.06	0.08	0.09	0.10

En la tabla 4.13 se muestran los resultados obtenidos con el clasificador basado en agrupamiento borroso, para cada uno de los pasos y los tres test establecidos, junto con el porcentaje de celdas sobre las que finalmente se toma la decisión de pulverizar.

Tabla 4-13: Valor de CCP y porcentaje de celdas a pulverizar para el clasificador basado en Fuzzy Clustering

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	73	30	82	24	86	22
Test 2	71	31	76	25	81	24
Test 3	66	34	72	30	75	26

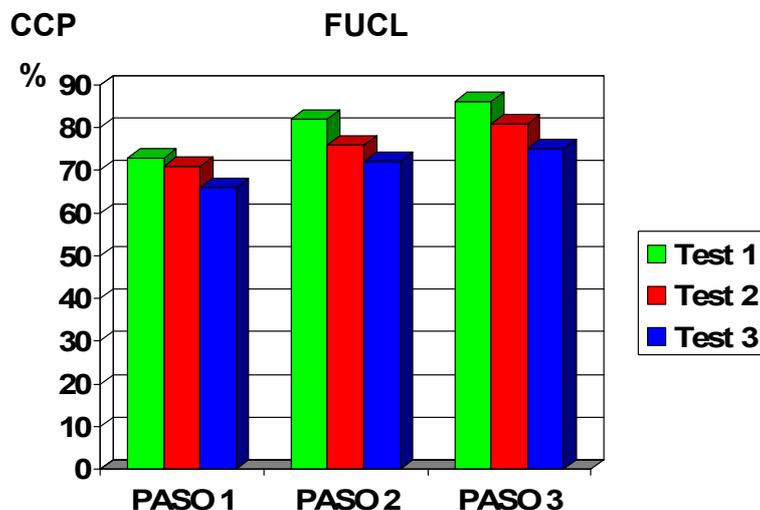


Figura 4-6: FUCL: valores del coeficiente de CCP para los tres tests

A tenor de los resultados obtenidos, vuelve a ponerse de manifiesto los mejores resultados obtenidos por el Test 1 en el PASO 3.

4.6.5. Clasificador Hebbiano: HEBB

En la tabla 4.14 se presentan los valores de los centroides obtenidos en cada paso para cada una de las clases *CP* y *CN* y los tres tests especificados.

Tabla 4-14: Valores de los centros obtenidos durante los cuatro pasos para los tres tests y los dos grupos de celdas.

<i>Centros de los clústeres</i>		<i>PASO 0</i>	<i>PASO 1</i>	<i>PASO 2</i>	<i>PASO 3</i>
<i>Test 1</i>	<i>CP</i>	(0.64, 0.69)	(0.64, 0.71)	(0.63, 0.75)	(0.68, 0.77)
	<i>CN</i>	(0.04, 0.09)	(0.06, 0.12)	(0.06, 0.14)	(0.09, 0.14)
<i>Test 2</i>	<i>CP</i>	0.66	0.65	0.68	0.69
	<i>CN</i>	0.02	0.05	0.12	0.13
<i>Test 3</i>	<i>CP</i>	0.70	0.72	0.74	0.75
	<i>CN</i>	0.09	0.09	0.10	0.11

En la tabla 4.15 se muestran los resultados obtenidos con el clasificador Hebbiano, para cada uno de los pasos y los tres test establecidos, junto con el porcentaje de celdas sobre las que finalmente se toma la decisión de pulverizar. La figura 4-7 muestra gráficamente los mismos resultados que la tabla para el CCP.

Tabla 4-15: Valor de CCP y porcentaje de celdas a pulverizar para el clasificador Hebbiano

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	78	24	85	21	88	20
Test 2	73	27	77	24	81	23
Test 3	66	33	73	30	74	30

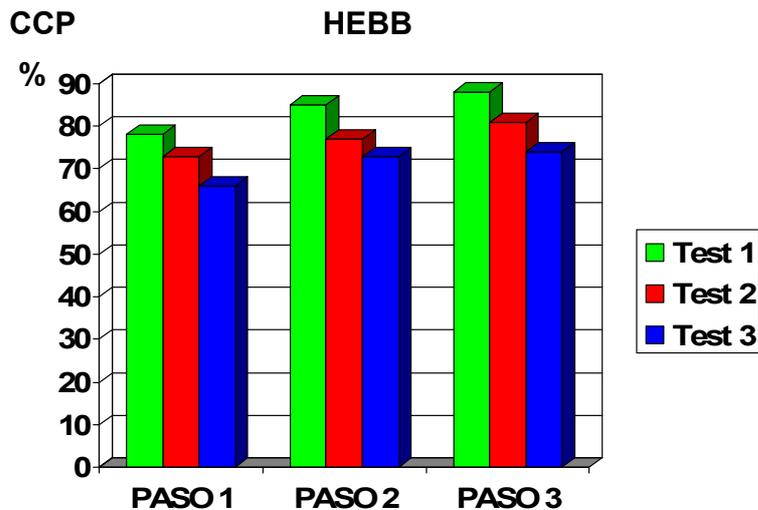


Figura 4-7: HEBB: valores del coeficiente de CCP para los tres tests

Como puede observarse, una vez más los mejores resultados se obtienen en el PASO 3 con el test 1.

4.6.6. Comparativa de resultados para los clasificadores simples

La primera conclusión que se obtiene del análisis de resultados para los clasificadores simples es que los mejores resultados se obtienen siempre con el Test 1 en el PASO 3. Por tanto, resulta conveniente utilizar los dos atributos cuantitativos que se usan en dicho Test frente a un único atributo que se utiliza en los Tests 2 y 3. Dado que es en el PASO 3 donde se utiliza el mayor número de muestras, es evidente que a mayor número de patrones mejores son los resultados finales.

El objetivo de la figura 4-8 consiste en mostrar el rendimiento de forma comparada de los diferentes métodos en función del CCP para el Test 1 en el PASO 3.

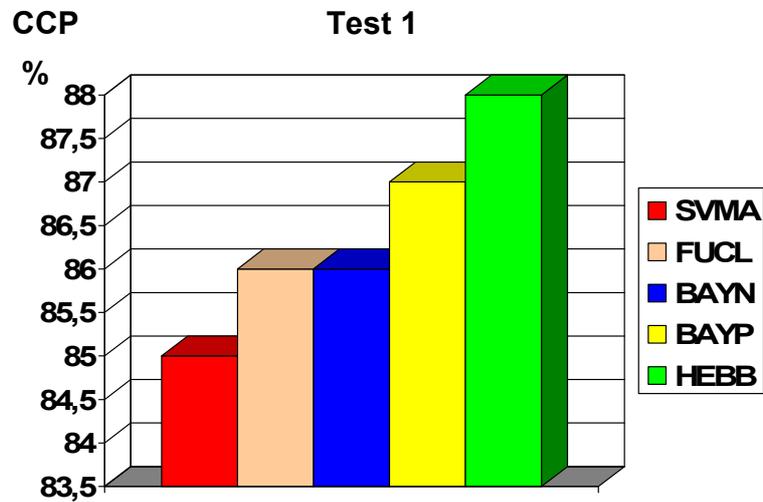


Figura 4-8: Comparativa del rendimiento para los clasificadores simples

Como se puede apreciar en las gráficas, el clasificador Hebbiano ofrece un rendimiento superior a los otros dos clasificadores utilizados, tanto en términos de valor del CCP como en porcentaje de celdas a pulverizar. Será éste clasificador el que se tome de base al comparar el rendimiento de los clasificadores simples con otras aproximaciones estudiadas en la presente tesis.

4.7. Resultados de los métodos de clasificación híbridos en cultivos de cereal

4.7.1. Hibridación de Bayes paramétrico y Fuzzy Clustering: BAFU

La tabla 4.16 muestra los resultados obtenidos para los tres Tests en los tres pasos especificados en función del coeficiente CCP, así como el número de celdas que necesitan pulverización de acuerdo con la decisión del método. La figura 4-9 muestra también estos resultados.

Tabla 4-16: Valores de CCP para las diferentes estrategias en los tres Test y PASOs

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	79	23	84	22	90	19
Test 2	65	32	70	33	72	32
Test 3	69	30	70	32	71	31

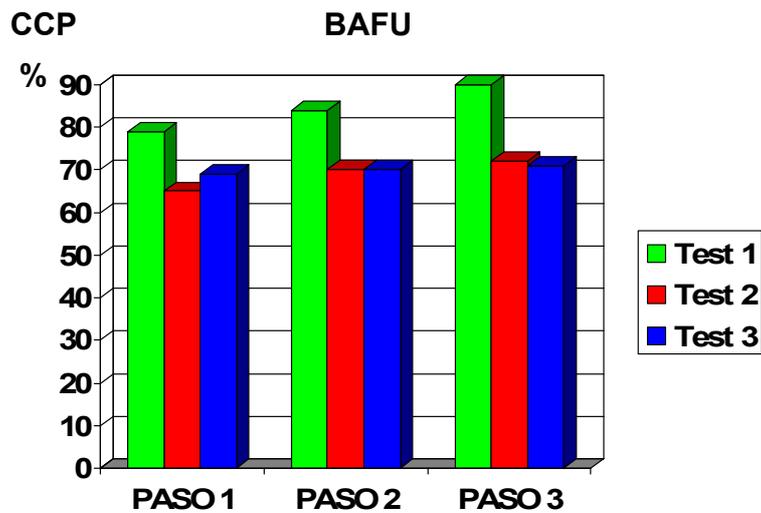


Figura 4-9: BAFU: valores del coeficiente de CCP para los tres tests

De nuevo, los mejores resultados se obtienen con el Test 1 en el PASO 3.

4.7.2. Hibridación de Fuzzy clustering y Máquinas de Vectores

Soporte: FUSV

En la tabla 4.17 se presentan los resultados obtenidos en valores de CCP y el porcentaje de las celdas que han sido clasificadas con celdas a pulverizar. La figura 4-10 muestra estos resultados gráficamente.

Tabla 4-17: Valor CCP y porcentaje de celdas a pulverizar para los diferentes PASOs y Tests

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	80	22	84	24	88	21
Test 2	69	34	69	31	70	24
Test 3	72	31	73	30	76	25

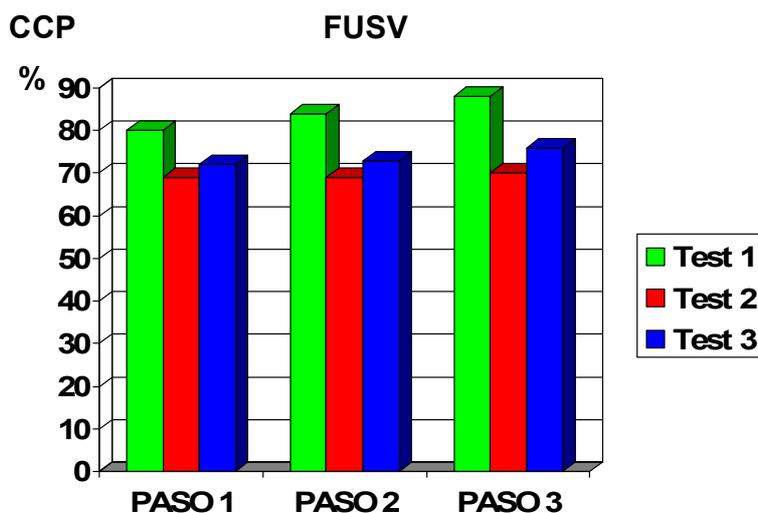


Figura 4-10: FUSV: valores del coeficiente de CCP para los tres tests

Obsérvense, los mejores resultados obtenidos por el Test 1 en el PASO 3 como viene siendo la tónica habitual en los resultados mostrados.

4.7.3. Hibridación de Bayes no paramétrico y Máquinas de Vectores

Soporte: BASV

La tabla 4.18 presenta los resultados de este clasificador híbrido en base a los diferentes Test y PASOs. Se presenta el valor de CCP y el porcentaje de celdas sobre las que se ha decidido pulverizar.

Tabla 4-18: Valor CCP y porcentaje de celdas a pulverizar para los diferentes PASOs y Tests

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	77	25	85	22	90	21
Test 2	62	36	63	35	64	33
Test 3	65	36	69	33	71	31

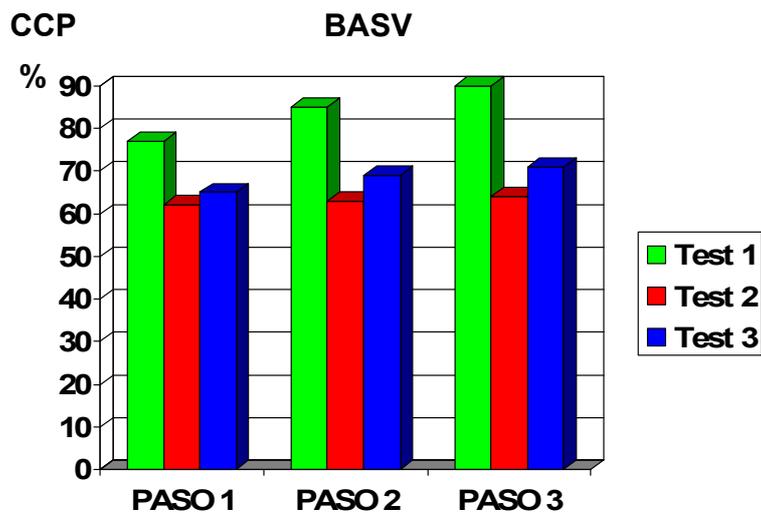


Figura 4-11: BASV: valores del coeficiente de CCP para los tres tests

Una vez más los mejores resultados corresponden al Test 1 en el PASO 3.

4.7.4. Comparativa de resultados para los clasificadores simples e híbridos

A la vista de los resultados mostrados en las diferentes gráficas y figuras, se deduce que a medida que el número de muestras aumenta, lo que ocurre en el PASO 3, los resultados mejoran. Esto significa que a medida que el número de muestras de entrenamiento aumenta, los resultados mejoran. Por otra parte, en todos los experimentos, es con el Test 1 con el que se obtienen los mejores resultados, poniendo de manifiesto de nuevo las mejoras logradas al utilizar los dos atributos cuantitativos frente a un único atributo. En la figura 4-12 siguiente, se muestran los resultados de los

tres métodos híbridos junto con los resultados de los métodos simples para el Test 1 en el PASO 3.

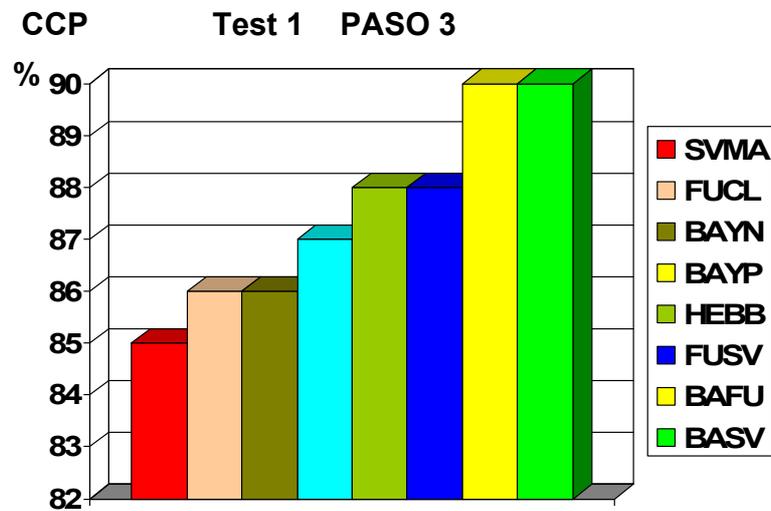


Figura 4-12: Resultados del coeficiente CCP para los métodos simples e híbridos para el Test 1 en el PASO 3

A la vista de los resultados mostrados en la figura 4-12 y teniendo en cuenta el análisis previo se infieren las siguientes observaciones:

1. Los mejores resultados se obtienen en general con las estrategias híbridas, salvo en el caso del método Hebbiano (HEBB) que consigue igualar los resultados con el FUSV
2. Dentro de las estrategias híbridas son los métodos de Bayes los que mejores resultados obtienen, independientemente del método utilizado como pareja de hibridación (SVMA o FUCL).
3. No ha sido posible superar el 90% en ninguno de los casos, esto es debido a que existe un porcentaje de celdas que representa aproximadamente el 17% del total con un elevado índice de dispersión de malas hierbas y baja densidad que son erróneamente clasificadas debido a que hasta el momento los métodos aplicados utilizan sólo los atributos de área sin considerar los estructurales que se incluyen seguidamente.

4.8. Método de decisión multicriterio MCDM en campos de cereal

La estrategia basada en el método MCDM contempla tanto la densidad de malas hierbas como la dispersión de las mismas dentro de las celdas. Mediante esta estrategia se consigue minimizar el error de clasificación derivado de las celdas que poseen elevada dispersión y baja densidad, que no detectan los métodos estudiados hasta aquí.

Por este motivo ahora se utilizan los dos tipos atributos basados en las conocidas relaciones cuantitativas y cualitativas.

4.8.1. Diseño de la estrategia de test

La estrategia de Test varía respecto de la expuesta en la sección 4.5. Los conjuntos de imágenes utilizadas siguen siendo los mismos que los descritos en la sección 4.4.1, a saber: B_1 , B_2 y B_3 . Igualmente, para cada imagen se obtienen 48 celdas como en los experimentos estudiados hasta el momento. En la BC se almacenan inicialmente las celdas procedentes del subconjunto B_1 junto con los atributos de naturaleza cuantitativa y cualitativa. Este conjunto aporta 1440 celdas distribuidas en sendos subconjuntos con los que se carga la BC, a saber: KB_1 y KB_2 . Por tanto KB_1 contiene 245 celdas y KB_2 contiene 1195 celdas representando celdas para ser pulverizadas y celdas que no requieren pulverización respectivamente. Se ha preferido mantener la nomenclatura KB_1 y KB_2 frente a CP y CN utilizada en los métodos anteriores con el fin de hacerla coincidir con la utilizada en la sección 3.7.3 durante el desarrollo teórico y a su vez con el trabajo de Tellaeché y col. 2007e, que constituye la referencia fuente.

B_2 es utilizado para establecer los pesos del clasificador multicriterio, w_1 y w_2 , para el criterio de beneficio y el criterio de coste respectivamente. En un principio para el cálculo de los pesos, éstos se fueron variando desde 0.25 a 0.75, teniendo en cuenta que $w_1 + w_2 = 1$. Como paso posterior se obtenía el error de decisión comparando los

resultados obtenidos mediante el proceso de decisión a través del método MCDM con aquellos obtenidos aplicando el criterio del experto, para acabar buscando el error mínimo. Este proceso es en realidad el procedimiento de validación cruzada ampliamente utilizado en aquellos métodos que necesitan fijar el valor de algún parámetro empírico (Duda y col., 2001). Los resultados mostrados en el trabajo de Tellaeché y col. (2007e) se han obtenido con los valores de los pesos resultantes de aplicar el procedimiento de validación cruzada siendo $w_1 = 0.39$ y $w_2 = 0.61$ con un valor mínimo de error del 17%. No obstante, los resultados mostrados en esta memoria se han obtenido con los pesos obtenidos mediante el algoritmo ID3 descrito en el capítulo 3 y particularizado para este propósito como se explica a continuación.

Se aplica el algoritmo ID3 sobre el mismo subconjunto de imágenes sobre el que se había realizado la validación cruzada, es decir sobre el subconjunto B_2 . Las celdas de cultivo que se generan a partir de este subconjunto de imágenes han sido clasificadas previamente como celdas a pulverizar o no por los expertos en agricultura.

Una vez que se tienen estas celdas clasificadas, se aplica el algoritmo ID3, descrito en la sección 3.7.2, para el cálculo de los pesos w_1 y w_2 . Las celdas a pulverizar se consideran ejemplos positivos, mientras que las celdas a no pulverizar son ejemplos negativos. Con ellos se calculan los correspondientes porcentajes según la ecuación (3.77). Como bien es sabido, en el caso que nos ocupa se dispone de dos tipos de atributos: cualitativos (A_1) y cuantitativos (A_2). Los cualitativos se definen mediante las nueve relaciones estructurales definidas por las ecuaciones (2.11) a (2.19), por tanto del nodo de decisión que representa este atributo saldrán nueve ramas. Los cuantitativos se definen mediante los dos atributos de área definidos por la ecuación (2.7), por tanto en este caso del nodo que represente a este atributo saldrán dos ramas. Mediante la ecuación (3.79) se calcula el mérito de cada atributo obteniéndose $mérito(A_1) = 0.83$ y $mérito(A_2) = 0.39$. Por tanto, normalizando al rango $[0,1]$ se obtienen finalmente los valores de los pesos siguientes:

$$w_1 = \frac{\text{mérito}(A_1)}{\text{mérito}(A_1) + \text{mérito}(A_2)} = 0.68$$

$$w_2 = \frac{\text{mérito}(A_2)}{\text{mérito}(A_1) + \text{mérito}(A_2)} = 0.32$$

En consecuencia la importancia relativa de los atributos estructurales aumenta con respecto a la importancia obtenida mediante validación cruzada. Es decir, el ID3 otorga un mayor peso específico a estos atributos.

Con la BC inicializada y los pesos del algoritmo MCDM obtenidos, se utiliza el último subconjunto B_3 para las pruebas según la estrategia de test que se muestra a continuación:

1. Test 1: Utiliza únicamente las medidas estructurales.
2. Test 2: Utiliza únicamente la primera componente del vector de relaciones cuantitativas (Tian y col., 1999).
3. Test 3: Utiliza únicamente la segunda componente del vector de relaciones cuantitativas (Ribeiro y col., 2005).
4. Test 4: Utiliza las dos componentes del vector de relaciones cuantitativas.
5. Test 5: Utiliza los dos tipos de atributos extraídos de las celdas, es decir, las relaciones estructurales y cuantitativas. Para estas últimas las dos componentes.

En todos los Tests se utiliza el método MCDM por lo que la comparación de los resultados obtenidos por el Test 5 con los obtenidos por el resto de los tests permite establecer el rendimiento del método bajo análisis propuesto en Tellaeché y col. 2007e y mejorado en este trabajo a través del algoritmo ID3.

Antes de continuar conviene aclarar que los resultados mostrados en Tellaeché y col. 2007e difieren ligeramente de los obtenidos en este trabajo por el hecho de aplicar el algoritmo ID3 mejorando aquéllos como se verá posteriormente.

4.8.2. Toma de decisiones

Dada una celda i perteneciente a B_3 se toma una decisión sobre ella (pulverizar o no) mediante la comparación de sus atributos con los de las j celdas pertenecientes a los grupos KB_1 y KB_2 . Un aspecto a destacar es el derivado del hecho de que es el Test 5 el que utiliza la estrategia basada en el MCDM para la toma de decisiones. El proceso de toma de decisiones en los cuatro tests restantes se describe a continuación:

- Test 1: $\forall j, j \in \{KB_1, KB_2\}$ calcular $m_k = \max\{R_{ij}\}_{j=k}$, R_{ij} es la medida de similitud entre dos celdas i y j . Si $k \in KB_1$ la celda debe ser pulverizada, de otro modo no debe ser tratada.
- Test 2, 3, 4: $\forall j, j \in \{KB_1, KB_2\}$, calcular E_{ij} es la distancia Euclídea de dos vectores de relaciones cuantitativas, esta norma será calculada dependiendo del número de componentes del vector de relaciones cuantitativas que se utilicen en los diferentes test. A continuación se obtiene $M_k = \min\{E_{ij}\}_{j=k}$; si $k \in KB_1$, la celda debe ser tratada; de lo contrario no debe ser pulverizada.

4.8.3. Análisis de resultados

La tabla 4.19 muestra los resultados de la correcta clasificación para los cinco tests. Se ha calculado el CCP para el grupo de 96 imágenes. Dado que se han procesado 48 celdas para cada una de las imágenes, el total de celdas utilizadas es de 4608. Como ya se ha mencionado, valores más elevados del CCP indican mejor rendimiento. La tercera fila indica el porcentaje de celdas a pulverizar. Se muestran los resultados obtenidos utilizando los pesos w_1 y w_2 según se utilice el procedimiento de

correlación cruzada o el algoritmo ID3. Los resultados que aparecen en el resto de la sección se han obtenido con los pesos calculados mediante el algoritmo ID3. En la figura 4-13 se muestran los mismos valores en forma de diagrama de barras con el fin de facilitar su visualización; VCR expresa resultados obtenidos con los pesos calculados mediante validación cruzada e ID3 los calculados mediante este algoritmo.

Tabla 4-19: Valores de CCP y porcentaje de las celdas a pulverizar para los tests.

		Test 1	Test 2	Test 3	Test 4	Test 5
<i>w₁ y w₂ obtenidos mediante validación cruzada (VCR)</i>	CCP	73	76	79	86	92
	%de celdas a pulverizar	38	32	30	24	25
<i>w₁ y w₂ obtenidos mediante el algoritmo ID3</i>	CCP	75	80	84	89	94
	%de celdas a pulverizar	38	36	33	29	27

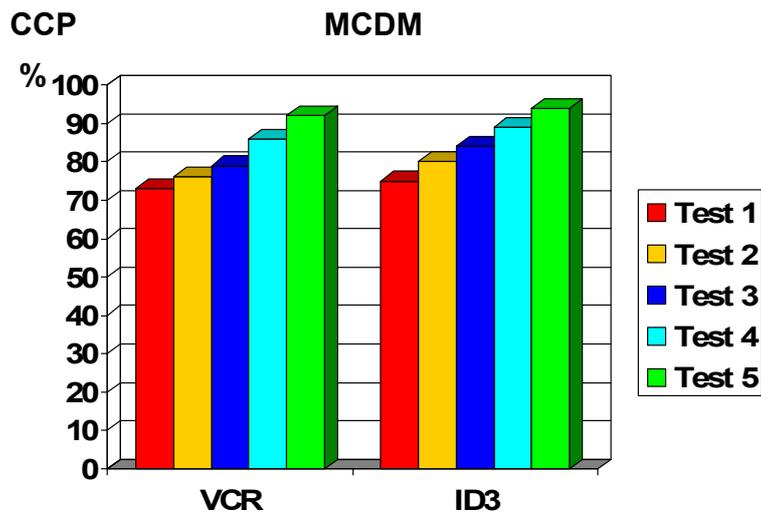


Figura 4-13: Resultados del coeficiente CCP para el método MCDM con los pesos obtenidos mediante el procedimiento de validación cruzada (VCR) y mediante el algoritmo ID3

Los resultados presentados en la tabla permiten llegar a las siguientes conclusiones:

1. El Test 5 es el que ofrece mejor rendimiento.

2. El Test 5 obtiene mejor rendimiento que el Test 4, esto implica que la inclusión de medidas estructurales han mejorado los resultados obtenidos únicamente mediante las relaciones cuantitativas.
3. El Test 4 ofrece un mejor rendimiento que los Test 2 y 3. Esto significa que la utilización de los atributos cuantitativos ofrece un mejor resultado que el uso de los atributos individuales.
4. Los peores resultados se obtienen utilizando un único atributo cuantitativo, Test 1.
5. Los mejores resultados se obtienen cuando los pesos se calculan mediante el algoritmo ID3, que implícitamente engloba el concepto de información de los datos.
6. Se observa que el porcentaje de celdas a pulverizar es ligeramente superior en el caso del algoritmo ID3 y a su vez también ligeramente superior respecto del obtenido en los métodos descritos previamente. Esto es así porque ahora existe un cierto número de celdas (17%, ver sección previa) con dispersiones de malas hierbas que ahora se clasifican como celdas a pulverizar, cosa que no ocurre en el caso de los métodos previos donde no se tiene en cuenta el hecho de la dispersión de las malas hierbas en la celda.

Existen una serie de condiciones que se pueden establecer, de acuerdo con las distribuciones posibles de malas hierbas en una determinada celda y que vienen determinadas por el criterio del experto humano. Según la observación de los expertos, se identifican las siguientes distribuciones generales de malas hierbas en las celdas:

1. Hay dos únicas zonas de cultivo en la celda identificando la zona izquierda y derecha de cultivo de los respectivos surcos.
2. Existen las dos zonas laterales de cultivo y un cierto número de zonas de aisladas de malas hierbas en el centro.
3. Existen zonas extensas de malas hierbas conectadas a una de las zonas laterales de cultivo.

4. Las zonas laterales de cultivo están conectadas entre sí por una zona de mala hierba que atraviesa toda la celda.

Definamos los siguientes parámetros:

1. n_i = número de regiones aisladas en una celda;
2. p_I = número de regiones que aparecen como protuberancias pegadas a la parte izquierda del surco dentro de una celda sobrepasando por tanto el valor medio del límite del surco fijado en r_I según se definió en la sección 2.5.1 a partir de la ecuación (2.3) para la región I.
3. p_D = como p_I pero para la región derecha D del surco.

Según lo anterior se establecen las siguientes condiciones:

1. $c_1 \rightarrow n_i = 0$
2. $c_2 \rightarrow n_i = 1$
3. $c_3 \rightarrow 1 < n_i \leq 5$
4. $c_4 \rightarrow n_i > 5$
5. $c_5 \rightarrow p_I = 1$
6. $c_6 \rightarrow p_I = 2$
7. $c_7 \rightarrow p_D = 1$
8. $c_8 \rightarrow p_D = 2$
9. $c_9 \rightarrow I - D$ conectadas

La tabla 4.20 muestra la clasificación de celdas de acuerdo con las condiciones c_1 a c_9 . En ella se presentan también los valores correspondientes a las dos relaciones cuantitativas utilizadas (a_{i0} , a_{i1}) incluyendo sus valores medios m_0 , m_1 respectivamente y sus desviaciones estándar σ_0 y σ_1 respecto del conjunto de celdas procesadas también respectivamente.

Tabla 4-20: Clasificación de las celdas en celdas a pulverizar y a no pulverizar, con sus parámetros estructurales y cuantitativos

	<i>Relaciones estructurales</i>									<i>Relaciones cuantitativas</i>			
	c_1	c_2	c_3	c_4	c_5	c_6	c_7	c_8	c_9	a_{i1}		a_{i2}	
										m_0	σ_0	m_1	σ_1
<i>Celdas a pulverizar (20,8%)</i>	31	89	223	616	314	217	41	53	111	0.73	0.0875	0.68	0.0922
<i>Celdas a no pulverizar (79,2%)</i>	2147	1215	216	71	436	321	132	98	15	0.20	0.0769	0.17	0.834

A partir de los resultados mostrados en esta tabla no se pueden determinar valores de umbral claros para tomar la decisión de pulverizar para su utilización en experimentos futuros, a pesar de esto, se pueden sacar las siguientes conclusiones:

1. El mayor número de celdas a pulverizar cumplen c_4 y aquellas a no pulverizar la condición c_1 .
2. La media de los valores de área m_0 sobrepasa un hipotético valor de umbral, mientras m_1 está por debajo de dicho umbral. El valor de umbral se ha fijado a 0.5 como valor intermedio en el rango [0,1] para pulverizar y no pulverizar según se sitúe por encima o debajo respectivamente.

El número de combinaciones para todas las características es alto y algunas de ellas no generan información significativa. No obstante, sí que se han encontrado grupos de combinaciones significativas, que se describen en la tabla 4.21 debido a su especial relevancia. Se realiza una distinción entre dos categorías de celdas: las que necesitan ser pulverizadas y las que no. También se muestra el número y porcentaje de las celdas situadas en cada categoría por cada combinación, siempre que su porcentaje sea superior al 80%. Los símbolos \wedge y \vee denotan las operaciones lógicas “and” y “or”. Los valores cuantitativos basado en área a_{i1} y a_{i2} están normalizados en el rango [0,1].

Tabla 4-21: Combinación de atributos y porcentajes de celdas clasificadas como a pulverizar y no pulverizar

<i>Categoría</i>	<i>Combinación de atributos</i>		<i>Número de celdas</i>	<i>% de celdas</i>
<i>Pulverizar</i>	1	$c_1 \wedge (c_6 \vee c_8) \wedge (a_{i1} > 0.7) \wedge (a_{i2} > 0.8)$	325	95
	2	$c_1 \wedge (c_5 \vee c_7) \wedge (a_{i1} > 0.6) \wedge (a_{i2} > 0.6)$	297	94
	3	$c_4 \wedge (a_{i1} > 0.5) \wedge (a_{i2} > 0.4)$	524	91
	4	$(c_2 \vee c_3) \wedge c_9 \wedge (a_{i1} > 0.4) \wedge (a_{i2} > 0.3)$	198	85
	5	$(a_{i1} > 0.8) \wedge (a_{i2} > 0.7)$	254	82
<i>No pulverizar</i>	6	$(a_{i1} < 0.2) \wedge (a_{i2} > 0.1)$	665	90
	7	$(c_1 \vee c_2) \wedge (c_5 \vee c_6 \vee c_7 \vee c_8) \wedge (a_{i0} < 0.6) \wedge (a_{i1} < 0.5)$	1835	86

De la tabla 4.21 se puede deducir que el umbral para los atributos cuantitativos de área varía según la combinación de las relaciones estructurales. Pudiéndose inferir las siguientes conclusiones:

1. Combinaciones 1 y 2: Si no hay zonas de malas hierbas aisladas (c_1) y existen zonas de malas hierbas adyacentes a las líneas de cultivo (c_5 a c_8), se requiere pulverización si los valores de los parámetros cuantitativos de área son altos.
2. Combinación 3: Si las zonas de malas hierbas están muy dispersas (c_4), se requiere pulverización incluso cuando los parámetros de área son relativamente pequeños.
3. Combinación 4: Si el número de zonas de malas hierbas aisladas (c_2, c_3) es pequeño, con zonas de malas hierbas grandes uniando las zonas de cultivo (c_9), es necesario pulverizar aunque los valores de área de las zonas de malas hierbas sean relativamente pequeños.
4. Combinaciones 5 y 6: Si los valores de área son altos, es necesario pulverizar independientemente de las relaciones estructurales existentes. Si los valores de área son bajos, no es necesario pulverizar.

5. Combinación 7: Si el número de zonas aisladas de malas hierbas (c_1, c_2) es pequeño apareciendo además zonas de malas hierbas adyacentes a las líneas de cultivo (c_5 a c_8), no es necesario pulverizar aunque los valores de área sean relativamente grandes.

Un aspecto a tener en cuenta son las malas hierbas ocultas en nuestro sistema basado en visión. Las malas hierbas están ocultas cuando aparecen mezcladas con el cultivo y no hay malas hierbas entre las filas de cultivo. Debido a que el cultivo y las malas hierbas presentan una firma espectral similar, las posibles malas hierbas ocultas pueden ser detectadas mediante el análisis de grandes densidades de plantas de cultivo en las regiones izquierda y derecha.

De hecho, si la densidad de malas hierbas tiende a cubrir toda la zona de cultivo (A_{iL} o A_{iR}), significa que el espacio entre las líneas de cultivo podrían ser infestadas con malas hierbas. Adicionalmente, la presencia de dos zonas de malas hierbas (c_6 o c_8) adyacentes a los surcos es considerado un síntoma sobre la presencia de malas hierbas ocultas. Si a este síntoma se añade el cumplimiento de la condición c_1 , el síntoma se convierte en un hecho consumado salvo raras excepciones. Se han identificado las siguientes dos condiciones como malas hierbas ocultas, dependiendo de si éstas se asocian a la línea de cultivo izquierda o derecha:

$$1. \text{ Izquierda: } \left| A_{iL} - \frac{1}{6} A_{ic} \right| < \varepsilon \wedge (c_5 \vee c_7) \wedge c_1 \quad (4.7)$$

$$2. \text{ Derecha: } \left| A_{iD} - \frac{1}{6} A_{ic} \right| < \varepsilon \wedge (c_6 \vee c_8) \wedge c_1 \quad (4.8)$$

Donde ε es un valor de tolerancia establecida a 0.05, que implica que A_{iL} o A_{iD} son consideradas iguales a $\frac{1}{6} A_{ic}$ (sección 2.5.2), cumpliendo que no difieren en una cantidad superior a ε . Se han encontrado 125 celdas cumpliendo las dos condiciones

anteriormente expuestas, donde de ellas 79 (63%) estaban clasificadas en la categoría de pulverizar, perteneciendo a las combinaciones 1 y 2 en la tabla 4.21.

4.9. Análisis comparativo de resultados para los diferentes métodos en cultivos de cereal

En la sección 4.7.4 se constata el mejor comportamiento de los métodos híbridos en general frente a los métodos simples de clasificación analizados. Añadiendo a la figura 4-12 el valor del coeficiente CCP obtenido por el método MCDM para el Test 5 y con los pesos obtenidos mediante el algoritmo ID3 se obtiene el gráfico de la figura 4-14,

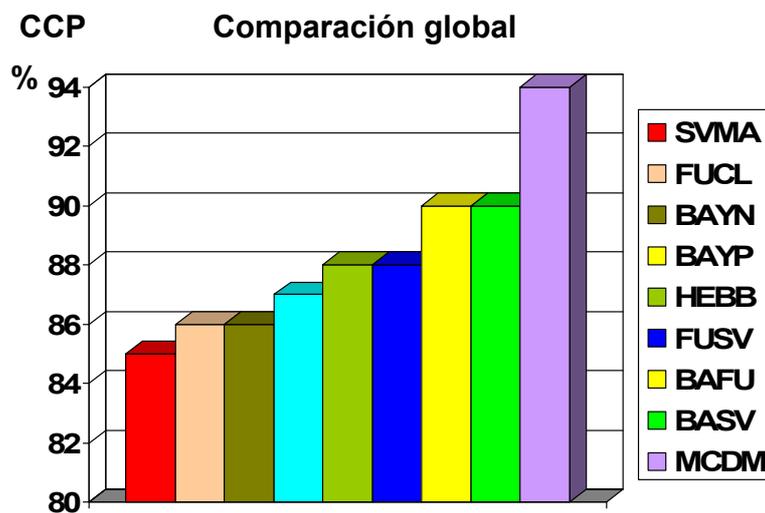


Figura 4-14: Resultados del coeficiente CCP para los métodos simples, híbridos y MCDM en su mejor rendimiento

Se observa en la gráfica de la figura 4-14 cómo ahora el método MCDM consigue una mejora de cuatro puntos porcentuales respecto del mejor resultado obtenido con los métodos previos, es decir con respecto a los métodos híbridos BAFU y BASV.

En la figura 4-15 se muestra el porcentaje de celdas a pulverizar para cada uno de los métodos que aparecen representados en la figura 4-14 y más concretamente en la

fase donde los mismos obtienen los mejores resultados, que por otra parte son los representados en la propia figura 4-14.

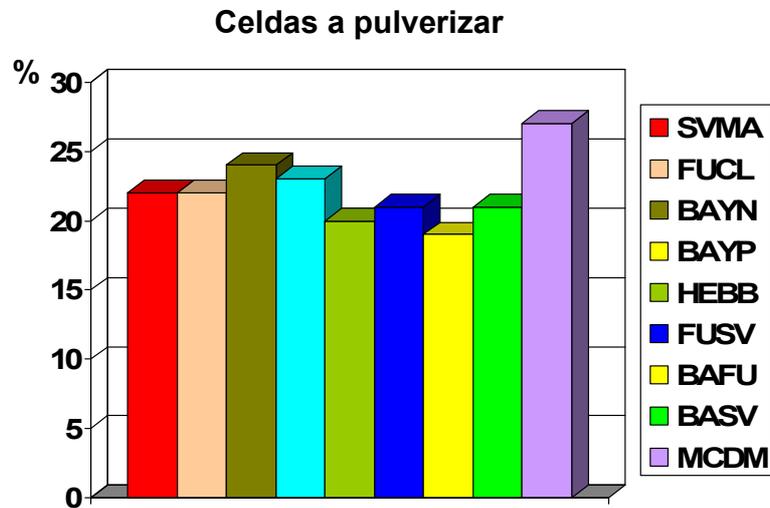


Figura 4-15: Porcentaje de celdas a pulverizar según los diferentes métodos

Se observa como hecho destacable que el método MCDM decide pulverizar mayor número de celdas que el resto llegando a superar en tres puntos porcentuales al más próximo. Esto es debido a que en este caso se toma la decisión de pulverizar sobre una serie de celdas que presentan densidades bajas de malas hierbas pero con una elevada dispersión de las mismas dentro de la celda. Este hecho encaja dentro de la filosofía del tratamiento selectivo de herbicida.

Por el contrario, el resto de métodos no consiguen el efecto anteriormente mencionado, observándose de forma general que los híbridos son los que menor porcentaje consiguen.

En cualquier caso, se consigue un ahorro superior al 70% en cuanto a la aplicación de herbicida. Este hecho ya justifica de forma convincente la utilidad de las técnicas propuestas en cuanto a disminución de costes y contaminación.

4.10. Estrategia de test y resultados para el estimador de Parzen en cultivos de maíz

Este método se basa en la utilización del estimador no paramétrico de Parzen, que utiliza información procedente del procesamiento previo en cada paso del procesamiento actual. Del procesamiento previo se obtiene la probabilidad a priori para tomar la decisión actual tal y como se describe en la sección 4.4.2.

4.10.1. Diseño de la estrategia de test

Con el fin de verificar la eficacia de este procedimiento, se diseña la estrategia de test que se explica a continuación siguiendo los pasos que se mencionan:

1. PASO 0 (inicialización): Proceso *off-line* con 160 imágenes y el siguiente número de celdas $CP_0 = 304$ y $CN_0 = 1296$. En este paso se determina el valor de k utilizado en la ecuación (3.41) mediante el proceso descrito al final de esta subsección.
2. Para los pasos $n = 1$ a $n = 3$ hacer STEP n :
 - i. Seleccionar las siguientes tres secuencias: $\{f_{3n-2}^j, f_{3n-1}^j, f_{3n}^j\}$, $j=1, \dots, 10$.
 - ii. Procesamiento *on-line*: Para cada frame k tomar la decisión para las seis celdas en la parte inferior. Después de la decisión, obtener un grupo de celdas CP_n para ser pulverizadas (pertenecientes a W_y) y un grupo de celdas que no requieren ser pulverizadas (pertenecientes a W_n). Si $j = 1$, no hay conocimiento previo almacenado, la probabilidades *a priori* se establecen a 0.5; en otros casos las probabilidades *a priori* son las probabilidades *a posteriori* calculadas para las cuatro celdas previas en el frame.
 - iii. Procesamiento *off-line*: actualización de la base de conocimiento añadiendo tanto las celdas CP_n y CN_n a las celdas ya existentes.

Contadas las celdas clasificadas como pertenecientes a w_y y w_n , y almacenadas en la base de conocimiento, se obtiene una nueva estima de la función de densidad de probabilidad condicional a través de:

$$p(\mathbf{x}/w_c) = \frac{1}{n_c} \sum_{j=1}^{n_c} \left\{ \frac{1}{(2\pi)^{d/2}} \frac{1}{h_c^{n_c} |C_c|^{1/2}} \exp \left[\frac{-1}{2h_c^2} (\mathbf{x} - \mathbf{x}_j^c)^t C_c^{-1} (\mathbf{x} - \mathbf{x}_j^c) \right] \right\} \quad (4.9)$$

donde $c = y, n$.

Para establecer el rendimiento de los atributos cuantitativos descritos en la sección 4.5, se diseña una estrategia basada en tres tests. Al igual que en el caso de los cultivos de cereal. El Test 1 utiliza las dos componentes ya mencionadas del vector de atributos cuantitativos a_{i0} y a_{i1} ; el Test 2 solamente la primera a_{i0} y el Test 3 solamente la segunda a_{i1} .

Se aplica el marco de trabajo Bayesiano para cada uno de los test, por lo tanto la función de densidad de probabilidad para el Test 1 es multidimensional y para los Tests 2 y 3 unidimensional.

Obtención del parámetro k de la ecuación (3.41)

El parámetro k en la ecuación (3.41) se obtiene en el PASO 0 mediante validación cruzada a partir de las celdas CP_0 y CN_0 como sigue. De acuerdo con duda y col. (2001) se obtienen unos resultados aceptables con $n_c = 256$ y $h = 1$. El conjunto de celdas CP_0 se divide en dos partes: un conjunto de *entrenamiento* con 256 celdas y un conjunto de *validación* con 48 celdas (18.75%). Esta partición se selecciona de forma aleatoria. Se han utilizado cinco particiones diferentes. El conjunto CN_0 se divide en cinco conjuntos disjuntos con 259 celdas cada uno (19.98%). Se realizan cinco procesos de entrenamiento donde cada proceso utiliza un conjunto diferente como validación. El resto de celdas para cada proceso de entrenamiento se utilizan como el conjunto de entrenamiento. Esta distribución también se realiza aleatoriamente. Con esta estrategia

se garantiza que el número de muestras de entrenamiento es siempre mayor o igual que 256 como un valor aceptable según Duda y col. (2001); el parámetro h se fija al valor de 1 como también se menciona en esta misma referencia. Para cada conjunto de validación se varía k y se obtiene el error de clasificación. Los errores se promedian para cada conjunto y para cada valor de k . Los mejores resultados se obtienen para el valor de k con el mínimo error medio. Este es el procedimiento de validación cruzada que se describe en Duda y col. (2001). En la figura 4-16 se muestra el comportamiento del error medio en términos de porcentaje contra k , donde $0 \leq k \leq 0.5$ como se define en la ecuación (3.41). Se deduce de dicha figura que el error medio mínimo se obtiene para un valor de $k = 0.3$, que es el valor utilizado en los experimentos llevados a cabo en este trabajo.

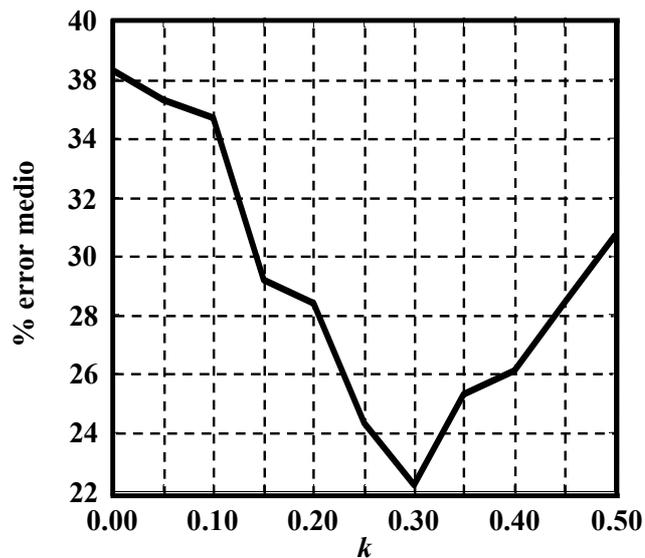


Figura 4-16: Porcentaje de error medio para diferentes valores de k

4.10.2. Análisis de resultados

La tabla 4.22 muestra el número de imágenes procesadas en cada PASO n , donde este número n es la suma de las imágenes acumuladas hasta el PASO $n-1$ (previo) más las nuevas obtenidas en el PASO n . En la tabla 4.22 también se muestra el número de celdas total teniendo en cuenta que para cada frame se procesan 10 celdas.

Para cada PASO 1 a 3 se muestran dos porcentajes. En la columna de la izquierda el porcentaje de celdas a pulverizar (CP_n) asumiendo que no hay conocimiento previo, por lo que todas las probabilidades a priori se fijan a 0.5. En la segunda columna, se tiene en cuenta el conocimiento adquirido durante la decisión previa y las probabilidades a priori se calculan según los pasos descritos en la sección 4.4.2. En el PASO 0, las celdas se seleccionan manualmente, sin considerar proceso de aprendizaje previo alguno.

Tabla 4-22: Número de imágenes y número de celdas a pulverizar y no pulverizar de acuerdo al clasificador utilizado

		PASO 0	PASO 1		PASO 2		PASO 3	
# de imágenes		160	220		280		340	
Número de celdas		1600	2200		2800		3400	
		% columna izda: sin conocimiento a priori % columna dcha: con conocimiento a priori						
Test 1	CP_n	19	29	24	27	22	24	19
Test 2	CP_n	19	38	33	35	29	33	28
Test 3	CP_n	19	36	30	33	27	29	25

Para medir el rendimiento se utiliza como siempre el coeficiente CCP tal y como se describe en la sección 4.2.

La tabla 4.23 muestra los resultados de los tres tests en los tres pasos especificados en relación con el coeficiente CCP, así como el porcentaje de celdas a pulverizar para un grupo de 180 imágenes pertenecientes a las 18 secuencias, recordando que mayores porcentajes del CCP expresan mejor rendimiento. En las figuras 4-17 y 4-18 se reproducen gráficamente estos mismos resultados.

Tabla 4-23: Valores de CCP y porcentaje de celdas a pulverizar para los tests y los pasos realizados.

	PASO 1		PASO 2		PASO 3	
	CCP	%	CCP	%	CCP	%
Test 1	76	29	84	24	92	20
Test 2	65	34	66	33	67	32
Test 3	63	35	70	31	74	30

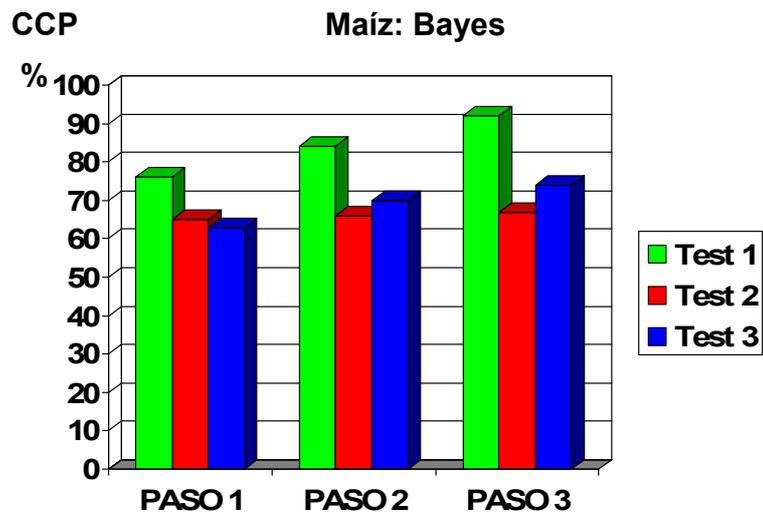


Figura 4-17: Resultados del coeficiente CCP para el método de Bayes en cultivos de maíz

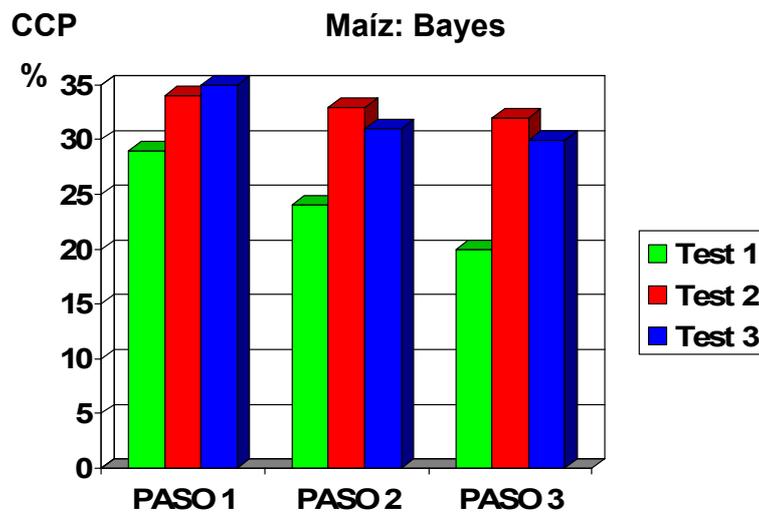


Figura 4-18: Porcentaje de celdas a pulverizar según los diferentes métodos

Como en las pruebas en los campos de cereal, el mejor resultado se obtiene con el Test 1 en el PASO 3. El uso de varios atributos cuantitativos mejora el resultado sobre las pruebas realizadas en las que sólo se utilizan uno de estos parámetros.

Tomando como referencia los resultados obtenidos, se puede observar también que únicamente el 20% de las celdas bajo estudio deben ser pulverizadas, lo que de nuevo implica un importante ahorro en el coste del tratamiento y una disminución de la contaminación medioambiental.

5. Conclusiones y trabajo futuro

5.1. Conclusiones

En la presente tesis se ha aportado una solución, consecuencia de la investigación realizada, al problema de la identificación de malas hierbas en campos de cultivo con el fin de aplicar un tratamiento selectivo con herbicida de esas hierbas dañinas. Esta selectividad se encuadra dentro de la denominada Agricultura de Precisión que está cobrando un importante auge en los últimos tiempos.

Como se indica en la revisión del estado de arte relacionado con la Agricultura de Precisión (AP), esta manera de cultivar constituye un reto en el futuro inmediato para las explotaciones agrícolas a gran escala, ya que proporciona numerosas ventajas que inciden en el mantenimiento o aumento de la productividad de los cultivos agrícolas a la vez que se minimizan los costes de producción y lo que es más importante si cabe, se disminuye notablemente la contaminación medioambiental por la reducción en el volumen de herbicida aplicado. Como bien es sabido, los herbicidas agrícolas son productos altamente tóxicos y contaminantes por su composición química. Cualquier reducción en su uso constituye un importante avance.

En este trabajo se ha desarrollado una estrategia basada en técnicas de segmentación de imágenes y decisión, cuya aplicación se ha mostrado suficientemente válida a raíz de los resultados obtenidos tanto en campos de cereales como en campos de maíz. El hecho de llegar a esta solución ha supuesto un aporte y una contribución importante en el ámbito de la AP para este tipo de cultivos. Concretamente, en los campos de cereal se ha hecho especial hincapié en un tipo especial de mala hierba conocida como *Avena Sterilis*, que presenta unas características específicas que le hacen especialmente difícil de detectar y tratar de forma automática y selectiva en dichos campos. En el caso de los campos de cultivo de maíz las malas hierbas son diferentes, si bien la problemática de su detección y tratamiento es la misma.

En síntesis, las ventajas que aporta el método propuesto son las siguientes:

1. *Método automático de pulverización:* se propone un método automático de detección selectiva de malas hierbas basado en imágenes digitales que combina técnicas de segmentación y clasificación para la decisión. Respecto de la decisión, la mayoría de los métodos investigados proporcionan valores en un rango numérico dinámico, que permite no solamente decidir si pulverizar o no sino también en qué cantidad. En efecto, las probabilidades, los grados de pertenencia o los límites de las funciones de decisión permiten deducir este conocimiento. El hecho de ser automático implica que elimina el cansancio y el estrés en los procesos de pulverización llevados a cabo directamente mediante la decisión de un operador humano que tuviera que realizar esta misma operación sin ayuda automática.
2. *Flexibilidad:* en el proceso de decisión se han probado diferentes métodos basados principalmente en la teoría derivada del reconocimiento de patrones. En este campo existen otros muchos métodos y estrategias que pueden aplicarse sin necesidad de variar el concepto de segmentación y decisión.
3. *Universalidad:* la estrategia propuesta se ha experimentado en campos de cultivos de cereal y maíz; no obstante, dadas las características de su diseño puede aplicarse a otros tipos de cultivos cuya disposición espacial en forma de surcos sea similar. Incluso podría variarse la parte de segmentación para adaptarla a otro tipo de cultivos con disposiciones de surcos diferentes sin necesidad de variar los métodos de decisión en general. La única restricción a esta propiedad de universalidad podría venir en el caso de la estrategia propuesta en los campos de maíz donde se utiliza una información previa derivada de la disposición geométrica de las cámaras. Hecha esta salvedad incluso la disposición geométrica de las cámaras podría también variarse para obtener imágenes con proyección ortogonal.
4. *Eficacia:* los resultados obtenidos, aunque mejorables en el sentido de lograr mayores porcentajes de aciertos, son satisfactorios.
5. *Agricultura de precisión:* se consigue disminuir el número de superficie para ser pulverizada, lo que conlleva un importante ahorro económico, así como una no menos

importante reducción de la contaminación medioambiental respecto de los tratamientos no selectivos que se están aplicando en la actualidad.

5.2. Trabajo de investigación futura

Los métodos desarrollados en esta investigación para la detección de malas hierbas han demostrado su efectividad para el conjunto de imágenes y las pruebas realizadas. No obstante existen todavía algunos aspectos identificados durante el desarrollo de la investigación que sin duda contribuirán en el futuro a la mejora de la estrategia presentada en este trabajo:

1. Las imágenes utilizadas en los experimentos han sido adquiridas bajo diferentes grados de iluminación ambiental. Con ellas se han realizado tanto los procesos de entrenamiento como los de decisión obteniendo los resultados mostrados. No obstante, como bien es sabido de la teoría de formación de imágenes la intensidad finalmente recibida por el sensor de la cámara procede de dos fuentes, a saber: la reflectancia y la iluminación. La reflectancia es una característica intrínseca del material de los objetos, en nuestro caso plantas de cereal, plantas de malas hierbas, suelo, etc., mientras que la iluminación depende de las condiciones atmosféricas del momento de la captura (sol, nubes, etc.) o incluso del sentido de avance del tractor, cuando el sol entra de frente a la cámara la iluminación es distinta a cuando lo hace por la parte posterior. Es evidente, que los parámetros del sistema dependen de la iluminación existente en el momento. La decisión también se ve afectada en el mismo sentido. Pues bien, existen técnicas encaminadas a eliminar la componente de iluminación con el fin de dejar solamente la de reflectancia que no depende de las condiciones ambientales. Un sistema aislado de tales condiciones podría operar en cualquier circunstancia ambiental sin preocuparse de ello. Una de tales técnicas es la conocida como filtrado homomórfico (Pajares y Cruz, 2007a, Gonzalez y Woods, 2001). Una línea de investigación se abre naturalmente bajo esta perspectiva de robustez del sistema frente a cambios en la iluminación.

2. El estudio de nuevas técnicas de decisión fundamentalmente en lo que respecta a procesos de decisión basados en clasificadores híbridos constituye otra de las posibles ampliaciones de la investigación con el fin de mejorar los resultados.
3. La captura y análisis de más imágenes, obtenidas durante diferentes años de cosecha constituye otro de las tareas a considerar, si bien en este caso involucrando otros aspectos relacionados con la ingeniería agraria y biológica antes que con las técnicas de visión por computador.
4. Un aspecto final a considerar a partir del sistema creado sería su implementación para su operatividad en tiempo real sobre un tractor agrícola. Toda la investigación realizada y las pruebas para los diferentes algoritmos se ha realizado en el lenguaje de computación científica *MATLAB*. Este lenguaje es un lenguaje muy potente para la programación de algoritmos matemáticos, si bien es un lenguaje interpretado y no ofrece la máxima velocidad en su respuesta, lo que le hace inapropiado para el desarrollo de sistemas en tiempo real. Actualmente, el código en *MATLAB* del sistema desarrollado está siendo analizado para llevar a cabo su traducción a *C / C++*, lenguaje compilado que ofrece una velocidad de ejecución mucho mayor y posibilita el funcionamiento del sistema en tiempo real. Junto con la traducción del sistema a un lenguaje de programación adecuado, también será necesario probablemente el diseño de una plataforma hardware apropiada para su instalación en el sistema final de pulverización sobre el tractor agrícola.

6. Referencias

AITKENHEAD, M.J., DALGETTY, I.A., MULLINS, C.E., McDONALD, A.J.S., STRACHAN, N.J.C. 2003. Weed and crop discrimination using image analysis and artificial intelligence methods. *Computers and Electronics in Agriculture* 39,157-171.

ASTRAND, B., BAERVELDT, A.J., 2002. An agricultural mobile robot with vision-based perception for mechanical weed control. *Autonomous Robots* 13, 21–35.

ATENCIANO S, LÓPEZ-GRANADOS F, JURADO-EXPÓSITO M, GONZÁLEZ-ANDÚJAR JL & GARCÍA-TORRES L. 2001. Discriminación entre Girasol y Malas Hierbas por medio de espectroscopía de infrarrojo cercano. Aplicación a la Teledetección. VIII Congreso de la Sociedad Española de Malherbología. León, España. pp: 169-173.

BACHER, B. 2001. Weed density estimation from digital images in spring barley. Phd. Thesis Dpt. Agricultural Sciences, Section of AgroTechnology. The Royal Veterinary and Agricultural University. Denmark.

BAHAMONDE, A. 2006. Una aplicación de las SVM: aprendizaje de preferencias. En *aprendizaje Automático: conceptos básicos y avanzados* (B. Sierra, coordinador). Prentice-Hall, Madrid.

BARON, R.J, 2005,. Spatial Leed distribution determined by Ground cover Measurments. PhD Thesis. Dpt. of Agricultural and Bioresource Engineering. University of Saskatchewan, Saskatoon

BARROSO J, FERNANDEZ-QUINTANILLA C, RUIZ D, HERNALIZ P & REW LJ. 2004a. Spatial stability of *Avena sterilis* ssp. *ludoviciana* populations under annual applications of low rates of imazamethabenz. *Weed Res.* 44: 178-186.

BARROSO J , FERNANDEZ-QUINTANILLA C , MAXWELL B D y REW L J. 2004b. Simulating the effects of weed spatial pattern and resolution of mapping and spraying on economics of site specific management. *Weed Res.* 44: 460-468.

BARROSO J , RUIZ D, FERNANDEZ-QUINTANILLA C , HERNAIZ P, RIBEIRO A, DIAZ B, MAXWELL B D & REW L J. 2005. Comparison of sampling methodologies for site specific management of *Avena sterilis*. *Weed Research*, 45, 165-174.

BILLINGSLEY, J., SCHOENFISCH, M., 1997. The successful development of a vision guidance system for agriculture. *Comput. Electron. Agric.* 16, 147–163.

BLANCO-MORENO JM, CHAMORRO L, MASALLES RM, RECASENS J & SANS FX. 2004. Spatial distribution of *Lolium rigidum* following seed dispersal by combine harvesters. *Weed Res.* 44: 375-387.

BURGOS-ARTIZZU X. P. 2007. Detección de malas hierbas en imágenes naturales mediante técnicas de Visión Artificial. Memoria Trabajo de Investigación Doctorado. Dpto. Ingeniería del Software e Inteligencia Artificial. Facultad de Informática. Universidad Complutense, Madrid.

BURGOS-ARTIZZU, X. P., RIBEIRO, A., SANTOS, M. 2007. Controlador Borroso Multivariable para el ajuste de tratamientos en Agricultura de Precisión. *Revista Iberoamericana de Automática e Informática Industrial*, 4(2), 64-71

CHANG J, CLAY SA, CLAY DE & DALSTED K. 2004. Detecting weed-free and weed-infested areas of a soybean field using near-infrared spectral data. *Weed Sci.* 52: 642-648.

CHEN, C.T., 2000. Extensions of the TOPSIS for group decision-making under fuzzy environment. *Fuzzy Sets Syst.* 114, 1–9.

CHERKASSKY, V., MULIER, F. 1998. Learning from data: concepts, theory and methods. Wiley, New York.

CHRISTENSEN, S., HEISEL, T., 1998. Patch spraying using historical, manual and real time monitoring of weeds in cereals. Zeitschrift für Pflanzenkrankheiten und Pflanzenschutz, Sonderheft XVI, pp. 257–265.

CLOUTIER, D.C., ASCARD, J. 2004. European Weed Research Society, Proceedings. In Proc. 6th European Weed Research Society (EWRS). Workshop on Physical and Cultural Weed Control. 8-10. Lillehammer, Norway.

COULTRIP, R.L., GRANGER, R.H., 1994. Sparse random networks with LTP learning rules approximate Bayes classifiers via Parzen's method. Neural Networks, 7(3), 463-476.

DABERKOW S, FERNANDEZ-CORNEJO J & PADGITT M. 2002. Precision Agriculture adoption continues to grow. Economic Research Service/USDA. Agricultural Outlook, November 2002, 35-39.

DENG, D., ZHANG, J. 2006. Combining Multiple Precision-Boosted Classifiers for Indoor-Outdoor Scene Classification, Internal Report N° 2006/09, Dpt. Information Science, University of Otago, Dunedin, New Zeland, 2006.

DIAZ B., RIBEIRO A RUIZ D., BARROSO J., FERNANDEZ-QUINTANILLA C., 2003 A genetic algorithm approach to discover complex associations between wild-oat density and soil properties. En: Precision Agriculture (ed. J Stafford & A. Werner). pp. 149-155. Wageningen Academic Publishers.

DIAZ B, RIBEIRO A, GONZALEZ-BUENO R, GUINEA D, BARROSO J, RUIZ D & FERNÁNDEZ-QUINTANILLA C. 2005. Modelling wild-oat density in terms of soil factors: A machine learning approach. Precision Agriculture (Aceptado).

DIELEMAN JA, MORTENSEN DA, BUHLER DD & FERGUSON RB 2000. Identifying associations among site properties and weed species abundance. II. Hypothesis generation. *Weed Sci.* 48: 576-587.

DUDA, R.O., HART, P.E., STORK, D.G., 2001. *Pattern Classification*, Jhon Willey and Sons, New York.

DUIN, R.P.W., 1976. On the choice of smoothing parameters for Parzen estimators of probability density functions. *IEEE Trans. Comput.*, C-25, 1175-1179.

ESCUADERO, L.F., 1977. *Reconocimiento de patrones*, Paraninfo, Madrid, Spain

EVGENIOU, T., PONTIL, M., POGGIO, T. 2000. *Statistical Learning Theory: A Primer*. *Int. J. Computer Vision.* 38(1), 9-13.

FUKUNAGA, K., HUMMELS, M.D., 1987. Bayes error estimation using Parzen and K-NN procedures. *IEEE Trans. Pattern Anal. Machine Intell.*, 9(5), 634-643.

GARCÍA-PÉREZ L., MARCHANT J., HAGUE T., GARCÍA-ALEGRE M.C., 2000. Fuzzy Decision System for Threshold Selection to Clúster Cauliflower Plant Blobs from Field Visual Images. *SCI2000*, Orlando: 23-28.

GARCÍA-PÉREZ L., GARCÍA-ALEGRE M.C., MARCHANT J., HAGUE T.. 2001 Dynamic Threshold Selection for Image Segmentation Based Upon a Performance Criterion. *3ECPA-3 European Conf. On Precision Agriculture*, Montpellier: 193-198.

GERHARDS R & CHRISTENSEN S. 2003. Real-time weeded detection, decision making and patch spraying in maize, sugarbeet, winter wheat and winter barley. *Weed Res.* 43: 385-392.

GERHARDS R., OEBEL, H. 2006. Practical experiences with a system for site-specific weed control in arable crops using real-time image analysis and GPS-controlled patch spraying. *Weed Research*, 46, 185-193.

GIBSON KD, DIRKS R, MEDLIN CR & JOHNSTON L. 2004. Detection of weed species in soybean using multiespectral digital images. *Weed Tech.* 18: 742-749.

GODWIN RJ, RICHARDS TE, WOOD GA, WELSH JP & KNIGHT SM. 2001. An economic analysis of the potential for precision farming in UK cereal production. Project Report 267, Precision Farming of cereal crops: a five year experiment to develop management guidelines. Cranfield University at Silsoe, Silsoe, Bedford (UK).

GONZÁLEZ, R.C., WOODS, R.E., EDDINS, S.L., 2004. Digital Image Processing using Matlab. Prentice Hall, New York.

GONZÁLEZ, R.C., WOODS, R.E., 2002. Digital Image Processing. Addison-Wesley, New York.

GRANITTO, P.M., VERDES, P.F. CECCATTO, H.A. 2005. Large-scale investigation of weed seed identification by machine vision. *Computers and Electronics in Agriculture* 47,15-24.

GU, X., ZHU, Q., 2006. Fuzzy multi-attribute decision-making method based on eigenvector of fuzzy attribute evaluation space. *Decision Support Syst.* 41, 400–410.

GUMPERTSBERGER E & JURGENS C. 2003. Acceptance of precision agriculture in Germany – results of a survey in 2001. En: Precision Agriculture (J. Stafford & A. Werner Eds.) Wageningen Academic Publishers, pp. 259-264.

HAYKIN, S. 1994. Neural Networks: A comprehensive Foundation. Macmillan College Publishing Co., New York.

HUETE AR, JACKSON RD & POST DF. 1985. Spectral response of a plant Canopo with diffeent soil backgrounds. *Remote Sensing and Envir.* 17: 37-53.

JAIN, A.K. and RAMASWAMI, M.D., 1988. Classifier design with Parzen windows. In E.S. Geselma and L.N. Kanal (Eds.) *Pattern Recognition and Artificial Intelligence toward an integration*, pp. 211-218, Amsterdam, The Netherlands.

JURADO-EXPÓSITO M, LÓPEZ-GRANADOS F, ATENCIANO S, GARCÍA-TORRES L & GONZÁLEZ-ANDÚJAR JL. 2003a. Discrimination of weed seedlings, wheat (*Triticum aestivum*) stubble and sunflower (*Helianthus annuus*) by near-infrared reflectance spectroscopy (NIRS). *Crop Prot.* 22: 1177-1180.

JURADO-EXPÓSITO M, LÓPEZ-GRANADOS F, GARCÍA-TORRES L, GARCÍA-FERRER A, SÁNCHEZ DE LA ORDEN M & ATENCIANO S. 2003b. Multi-species weed spatial variability and site-specific management maps in cultivated sunflower. *Weed Sci.* 51: 319-328.

JURADO-EXPÓSITO M, LÓPEZ-GRANADOS F, GONZÁLEZ-ANDÚJAR, JL & GARCÍA-TORRES L. 2004. Spatial and temporal análisis od *Convolvulus arvensis* L. populations over four growing seasons. *Eur. J. of Agron.* 21:287-296.

KITTLER J, HATEF M, DUIN R, MATAS J.1998. On Combining Classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20 no. 3.

KOGER CH, SHAW DR, REDDY KN & BRUCE LM. 2004. Detection of pitted morningglory (*Ipomoea lacunosa*) by hyperspectral remote sensing. 1. Effects of tillage and cover crop residue. *Weed Sci.* 52: 222-229.

KOHONEN, T. *An introduction to neural computing*, 1988, 1, pp 3-16.

KOSKO, B. 1992 Neural Networks and Fuzzy Systems: A dynamical systems approach to machine intelligence. Prentice-Hall. Englewood Cliffs. New Jersey.

KUMAR S., GHOSH J., CRAWFORD M.M., 2002. Hierarchical Fusion of Multiple Classifiers for Hyperspectral Data Analysis. Pattern Analysis and Applications, 5, 210.220.

KUNCHEVA, L.I. 2004. Combining Pattern Classifiers: Methods and Algorithms, Wiley.

LAMB DW & BROWN RB. 2001. Remote-sensing and mapping of weeds in crops. J. of Agric. Eng. Res. 78: 117-125.

LAMB DW & WEEDON M. 1998. Evaluating the accuracy of mapping weeds in fallow fields using airborne digital imaging: Panicum effusum in oilseed rape stubble. Weed Res. 38: 443-451.

LÓPEZ-GRANADOS F, JURADO-EXPÓSITO M, PEÑA-BARRAGÁN JM, & GARCÍA-TORRES L. 2005 Using geostatistical and remote sensing approaches for mapping soil properties. Euro. J.of Agron. (aceptado).

MAIN CL, ROBINSON DK, MCELROY JS, MUELLER TC & WILKERSON JB. 2004. A guide to predicting spatial distribution of weed emergence using Geographic Information Systems (GIS). Online Applied Turfgrass Science doi:10.1094/ATS-2004-1025-01-DG.

MARAVALL D, 1993, Reconocimiento de Formas y visión artificial, Ra-Ma, Madrid.

MARTIN P, ORTEGA AB, FERNANDEZ-QUINTANILLA C & HERNAIZ P. 2005. Discrimination of grassweeds in winter cereal crops by radiospectrometry. 13th EWRS Symposium, Bari. 250-252.

McCLOSKEY, W.B. 2007. Innovations in citrus weed control. Dpt. of Plant Sciences. Cooperative Extension. University of Arizona. (presentación disponible on-line).

MENGES RM, NIXON PR & RICHARDSON AJ. 1985. Light reflectance and remote sensing of weeds in agronomic and horticultural crops. *Weed Sci.*33: 569-581.

MORAN MS, INOUE Y & BARNES EM. 1997. Opportunities and limitations for image-based remote sensing in precision crop management. *Remote Sensing of Environment* 61: 319-346.

NRC (NATIONAL RESEARCH COUNCIL). 1997. Precision agriculture in the 21th Century. National Academy Press. Washington D.C. 149 pp.

ONYANGO, C.M., MARCHANT, J.A. 2003. Segmentation of row crop plants from weeds using colour and morphology. *Computers and Electronics in Agriculture* 39, 141-155.

PAJARES, G, DE LA CRUZ, J.M, 2007a. *Visión por Computador, Imágenes Digitales y Aplicaciones*, Ra-Ma, Madrid.

PAJARES, G, DE LA CRUZ, J.M, 2007b. *Ejercicios resueltos de Visión por Computador*. Ra-Ma, Madrid.

PAJARES, G., TELLAECHÉ, A., BURGOS-ARTIZZU, X.P., RIBEIRO, A., 2007c. Design of a computer vision system for a differential spraying operation in precision agriculture using Hebbian learning (Aceptado para publicación. Journal: "IET Computer Vision", 2007)

PAJARES, G. y SANTOS, M., 2005. *Inteligencia artificial e ingeniería del conocimiento*. Ra-Ma, Madrid.

PARZEN, E. (1962). On estimation of a probability density function and mode. *Ann. Math. Statist.*, 33, 1065-1076.

PARTRIDGE, D. and GRIFFITH, N. 2002. Multiple Classifier Systems: Software Engineered, Automatically Modular Leading to a Taxonomic Overview. *Pattern Analysis and Applications*, 5, 180-188, 2002.

PEÑA-BARRAGÁN JM, JURADO-EXPÓSITO M, LÓPEZ-GRANADOS F, ATENCIANO S, SÁNCHEZ DE LA ORDEN M, GARCÍA-FERRER A & GARCÍA-TORRES L. 2004. Assessing land uses in olive groves from aerial photographs. *Agric., Ecosyst. and Environ.* 103:117-122.

PÉREZ, A.J., LÓPEZ, F., BENLLOCH, J.V., CHRISTENSEN, S. 2000. Colour and Shape Analysis techniques for weed detection in cereal fields. *Computers and Electronics in Agriculture* 25, 197-212.

PERRY N & LUTMAN P JW. 2000. Spatial population dynamics of patches of wild oats and alternative methods of mapping weeds. 1st Workshop of the EWRS Working Group "Site-Specific Weed Management", 20-22 November, Odense, Dinamarca.

PIERCE FJ & NOWAK P 1999. Aspects of Precision Agriculture. *Adv. in Agron.* 67: 1-85.

PINILLA, C. 1995. Elementos de Teledetección, Ra-Ma, Madrid.

RADHAKRISHNAN J, LIANG S, TEASDALE JR & SHUEY C J.2002. Remote sensing of weed canopies. In: *From laboratory spectroscopy to remotely sensed spectra of terrestrial ecosystems*, 175-202. Kluwer Academic Publishers.

RIBEIRO, A., DIAZ, B., GARCIA-ALEGRE, M.C., GUINEA, D., FERNANDEZ-QUINTANILLA, C., BARROSO, J., RUIZ, D.. 2001. A GPS/GIS based system for the acquisition of spatially structured field properties. En: *Proceedings 3rd European Conference on Precision Agriculture*: 97-102.

RIBEIRO A, GARCÍA-ALEGRE M, NAVARRETE L & FERNANDEZ-QUINTANILLA C. 2003. Improving the information obtained from yield maps. Precision Agriculture (ed. J Stafford & A. Werner). pp. 585-590. Wageningen Academic Publishers.

RIBEIRO, A., FERNÁNDEZ-QUINTANILLA, C., BARROSO, J., GARCÍA-ALEGRE, M.C., 2005. Development of an image analysis system for estimation of weed. Proceedings of the 5th European Conf. On Precision Agriculture (5ECPA), pp. 169–174.

RIBEIRO, A. 2005 Extracción de Conocimiento Espacio-Temporal y Visión Artificial para la Automatización de Tratamientos Agrícolas Localizados. Referencia AGL2005-06180-C03-03. Memoria del Plan Nacional de I+D+i para el trienio 2005-2008.

SHEARER SA & JONES PT. 1991. Selective application of post-emergence herbicides using photoelectrics. Transactions of the ASAE 34: 1661-1666.

SNEATH, P., SOKAL, R., 1973. Numerical Taxonomy: The Principle and Practice of Numerical Classification. W.H. Freeman, San Francisco.

SOGAARD, H.T., OLSEN, H.J. 2003. Determination of crop rows by image analysis without segmentation. Computers and Electronics in Agriculture 38, 141-158.

STONE, M. L., SOLIE, J.B. and REED, S.D. 2004. Nozzle attitude controller for spot and variable rate application of agricultural chemicals and fertilizers. US Patent 6702200. <http://www.patentstorm.us/patents/6702200-fulltext.html>

TELLAECHE A., BURGOS X.P., PAJARES G., RIBEIRO A. 2006, Segmentación de imágenes para Agricultura selectiva. XXVII Jornadas de Automática, pp. 860-865, ISBN 84-689-9417-0 (CD-ROM) Almería, España.

TELLAECHE, A., BURGOS-ARTIZZU, X.P., PAJARES, G., RIBEIRO, A., 2007a. A vision-based method for weeds identification through the Bayesian decision theory (Journal: "Pattern Recognition", Elsevier, Volumen 41, pp 521-530, Febrero 2008).

TELLAECHE, A., BURGOS-ARTIZZU, X.P., PAJARES, G., RIBEIRO, A., 2007b. A Vision-Based Hybrid Classifier for Weeds Detection in Precision Agriculture through the Bayesian and Fuzzy k-Means paradigms. 2nd Internacional Workshop on Hybrid Artificial Intelligence Systems (HAIS 2007), Salamanca, España.

TELLAECHE, A., BURGOS-ARTIZZU, X.P., PAJARES, G., RIBEIRO, A., 2007c. On Combining Support Vector Machines and Fuzzy K-Means in Vision-based Precision Agriculture. International Conference on Computer, Electrical and Systems Science, and Engineering (WASET 2007) pp 33-38, Volumen 22 Julio 2007, ISBN 978-975-01752-1-3 (CD_ROM), Praga, República Checa.

TELLAECHE, A., BURGOS-ARTIZZU, X.P., PAJARES, G., RIBEIRO, A., 2007d. A Vision-based Classifier in Precision Agriculture Combining Bayes and Support Vector Machines. IEEE International Symposium on Intelligent Signal Processing (WISP 2007), pp.425-430 Conference Proceedings Book, IEEE Catalog Number: 07EX1620, ISBN 1-4244-0829-6 (CD_ROM), Alcalá de Henares, España.

TELLAECHE, A., BURGOS-ARTIZZU, X.P., PAJARES, G., RIBEIRO, A., FERNÁNDEZ-QUINTANILLA, C., 2007e. A new vision-based approach to differential spraying in precision agriculture. Computers and Electronics in Agriculture (In Press, Corrected Proofs).

THORP KR & TIAN LF. 2004. A review of remote sensing of weeds in agriculture. Prec. Agric. 5: 477-508.

TIAN L. 2002. Sensor-based precision chemical application system. *J. Comp. and Electr. In Agric.* 36: 133-149.

TIAN, L., REID J.F., and HUMMEL J., 1999 Development of a precision sprayer for site-specific weed management. *Transactions of the ASAE Vol. 42(4)*: 893-900.

TIAN, L.F., SLAUGHTER, D.C., 1998. Environmentally adaptive segmentation algorithm for outdoor image segmentation. *Comput. Electron. Agric.* 21, 153–168.

TORNER, C., GONZÁLEZ-ANDÚJAR, J.L., FERNÁNDEZ-QUINTANILLA, C., 1991. Wild oat (*Avena sterilis*) competition with winter barley: plant density effects. *Weed Res.* 31, 301–308.

VALDOVINOS, R.M.; SÁNCHEZ, J. S. and BARANDELA, R. 2005. Dynamic and Static weighting in classifier fusion. In *Pattern Recognition and Image Analysis*, Lecture Notes in Computer Science (J.S. Marques, N. Pérez de la Blanca and P. Pina, Eds.), Springer-Verlag, Berlin, pp. 59-66.

VAN WYCHEN LR, LUSCHEI EC, BUSSAN AJ & MAXWELL BD. 2002. Accuracy and cost effectiveness of GPS-assisted wild oat mapping in spring cereals crops. *Weed Sci.* 50: 120-129.

VAPNIK, V.N., 2000. The nature of statistical learning theory. Springer-Verlag, New York.

WALTER, A.M., CHRISTENSEN, S., HEISEL, T., 1997. Patch spraying using weed maps from previous years. In: *Proceedings of the 10th EWRS Symposium Poznan 1997*, p. 141.

WANG,W., FENTON, N., 2006. Risk and confidence analysis for fuzzy multicriteria decision making. *Knowledge Based Syst.* 19, 430–437.

WEBSTER TM, CARDINA J & WOODS SJ. 2000. Spatial and temporal expansion patterns of *Apocynum cannabinum* patches. *Weed Sci.* 48: 728-733.

YANG C.C, PRASHER S.O., LANDRY J.A and RAMASWAMY H.S. 2003a. Development of an image processing system and a fuzzy algorithm for site-specific herbicide applications. Precision Agriculture 4, 5-18.

YANG CC, PRASHER SO, LANDRY JA & RAMASWAMY HS. 2003b. Development of a herbicide application map using artificial neural networks and fuzzy logic. Agric. Syst. 76: 561-574.

ZIMMERMANN H.J., 1991, Fuzzy Set Theory and its Applications, Kluwer Academic Publishers, London.