

**Universidad Complutense de Madrid**

**Facultad de Informática**

Departamento de Ingeniería del Software e Inteligencia Artificial

**MÁSTER EN INVESTIGACIÓN EN  
INFORMÁTICA**

**2009-2010**



**SEGMENTACIÓN AUTOMÁTICA DE  
TEXTURAS EN IMÁGENES AGRÍCOLAS**

**PROYECTO FIN DE MÁSTER EN SISTEMAS INTELIGENTES**

**Alumna:**

**M. Isabel Riomoros Callejo**

**Directores:**

Gonzalo Pajares Martinsanz

María Guijarro Mata-García



# Autorización

La abajo firmante, matriculada en el Máster en Investigación en Informática de la Facultad de Informática, autoriza a la Universidad Complutense de Madrid (UCM) a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a su autor el presente Trabajo Fin de Máster: “Segmentación automática de texturas en imágenes agrícolas”, realizado durante el curso académico 2009-2010 bajo la dirección de Gonzalo Pajares Martinsanz y María Guijarro Mata-García en el Departamento de Ingeniería del Software e Inteligencia Artificial, y a la Biblioteca de la UCM a depositarlo en el Archivo Institucional E-Prints Complutense con el objeto de incrementar la difusión, uso e impacto del trabajo en Internet y garantizar su preservación y acceso a largo plazo.

Fdo.: M. Isabel Riomoros Callejo



*A mis hijas Isabel y Clara.*



# Agradecimientos

A María Guijarro y a Gonzalo Pajares, por facilitarme ampliamente la información utilizada, y por su disposición para ayudarme en todo momento con este proyecto. A Ángela Ribeiro Seijas y a Xavier Paolo Burgos Artizzu, investigadores ambos del Instituto de Automática Industrial del Consejo Superior de Investigaciones Científicas por las imágenes que han constituido la base de la investigación.



# Resumen

En los últimos años, ha aparecido el concepto de Agricultura de Precisión, gracias al desarrollo de las nuevas tecnologías. Esto ha hecho que los problemas surgidos con las prácticas agrícolas tradicionales, tal es el caso de la utilización de herbicidas o el abonado generalizado, se vayan solventando conforme avanzan las investigaciones. En la Agricultura de Precisión se hace especial hincapié en las técnicas orientadas a la aplicación selectiva de tratamientos, es decir, al uso de herbicidas y otros productos químicos sólo en aquellas zonas en las que sea necesario.

En esta investigación nuestro objetivo consiste en la identificación de forma automática de las diferentes texturas que aparecen en imágenes procedentes de campos de cultivo, concretamente de cereal y maíz. Por lo tanto, en nuestro trabajo, por un lado se identifica la parte vegetal mediante la fusión de cuatro imágenes obtenidas a partir de lo que técnicamente se conocen como índices cromáticos. Por otro lado se separan tanto la parte del suelo como del cielo, en este último caso cuando proceda, mediante el diseño de una estrategia también basada en índices de cromaticidad. Finalmente, las texturas identificadas como de vegetación o suelo se someten a un proceso de clasificación basado en el clasificador borroso con el fin de distinguir las diferentes tonalidades, que permiten discriminar diferentes tipos de vegetación y de suelo.

## Palabras clave:

Agricultura de precisión, visión artificial, clasificación, índices de validación, índices cromáticos.

# Abstract

In recent years has emerged the concept of Precision Agriculture, by developing new technologies. This has made the problems encountered with traditional farming practices, such is the case for the use of herbicides or fertilizer widespread as they move will be by solving the research. In Precision Agriculture with special emphasis on techniques aimed at the selective application of treatments, i.e. the use of herbicides and other chemicals products only in those areas where necessary.

In this research, the objective consists in the automatic identification of the different textures that appear in images from crop fields, particularly cereal and corn. Therefore, in our work, first we identify the plants by fusing four images obtained from what is technically known as chromatic indices. On the other hand, textures belonging to the soil and the sky are also separated based on the application of chromaticity. Finally, once the vegetation and the soil textures are identified, through a fuzzy clustering approach still is possible a classification for distinguishing different kinds of vegetation and soil, including shades.

## Keywords:

Precision agriculture, machine vision, classification, validity indices, chromaticity indices.

<b>Capítulo 1. Introducción</b>	<b>1</b>
1.1. Identificación del problema	1
1.2. Estructura de la memoria	2
1.3. Objetivos	3
1.3.1. Objetivos generales	3
1.3.2. Objetivos específicos	3
1.4. Metodología histórica	4
<b>Capítulo 2. Estado del arte</b>	<b>7</b>
2.1. Introducción	7
2.2. Índices de calidad	8
2.3. Métodos de clasificación	9
2.3.1. Mean Shift	10
2.3.2. Cuantificación Vectorial	11
2.3.3. Agrupamiento Borroso- “Fuzzy Clustering”	11
2.4. Índices cromáticos	12
<b>Capítulo 3. Revisión de métodos</b>	<b>15</b>
3.1. Introducción	15
3.2. Primera parte: automatización mediante clasificación.	16
3.2.1. Mean Shift	16
3.2.2. Cuantificación Vectorial mediante aprendizaje no supervisado	20
3.2.3. Índices de validación	21
3.3. Segunda parte: segmentación de texturas y clasificación	25
3.3.1. Agrupamiento borroso	26
3.3.2. Método de segmentación automático combinando índices cromáticos y agrupamiento borroso	29
3.3.3. Clasificación mediante agrupamiento borroso	36
<b>Capítulo 4. Análisis de resultados</b>	<b>41</b>
4.1. Objetivos del análisis	41
4.2. Descripción de las bases de datos utilizadas	42
4.3. Elección de los índices de calidad	45
4.4. Imágenes reales de campos de cultivo	47
4.5. Resultados con los índices cromáticos	48

<b>Capítulo 5. Conclusiones y trabajo futuro</b>	<b>53</b>
5.1. Introducción	53
5.2. Conclusiones	53
5.3. Trabajo futuro	54
<b>Bibliografía</b>	<b>55</b>

# Capítulo 1

## 1. Introducción

### 1.1. Identificación del problema

Las prácticas agrícolas tradicionales han estado orientadas hacia la explotación de los recursos agrícolas sin prestar excesiva atención a las labores que pudieran provocar situaciones no deseables respecto de la contaminación atmosférica, del suelo o del subsuelo. Tal es el caso de la utilización de herbicidas de forma no precisa o el abonado de campos con tendencia generalizada, por citar sólo dos casos. Además de lo anterior, estas situaciones generan el aumento de los costes de producción. Esto, unido al aumento de población, a la disponibilidad de menos tierras y agua para el cultivo hace que las prácticas agrícolas sean cada vez más costosas a nivel social, económico y medioambiental.

En los últimos años, gracias al desarrollo de las nuevas tecnologías, se ha producido un importante avance con la aplicación de sistemas de control y automatización en la agricultura, apareciendo el concepto de Agricultura de Precisión (AP), que engloba un conjunto de técnicas de cultivo dirigidas a ajustar de forma controlada el uso de agroquímicos considerando la diversidad tanto del medio físico como biológico (Kropff y col. 1997).

En la AP tienen especial importancia las técnicas orientadas a la aplicación selectiva de tratamientos, es decir, aplicación de herbicidas y otros productos químicos sólo en aquellas zonas en las que sea necesario. A modo de ejemplo, los herbicidas han de aplicarse exclusivamente allí donde se encuentren las malas hierbas. De esta forma se obtendría una reducción de costes de producción y una gestión agrícola más precisa y respetuosa con el medio ambiente (Earl y col. 1996).

Para que esta aplicación selectiva tenga éxito, sería conveniente que un tractor robotizado de forma automática y en tiempo real reconociera dónde se sitúa la zona de actuación concreta, esto es, en el caso de las malas hierbas dónde se localizan éstas. Hasta ahora hay métodos que, aunque funcionan relativamente bien, son demasiado lentos para su uso

directo en el campo, o utilizan equipos demasiado caros para que su uso sea rentable, mientras que otros parten de condiciones irreales.

Desde sus inicios, la detección automática de malas hierbas o la identificación de zonas con ciertas densidades de cultivo ha sido una tarea desalentadora, dada la gran cantidad de variables a tener en cuenta y la dificultad de adaptar las técnicas a la realidad. Aún así, algunos trabajos demuestran el potencial de la Visión Artificial aplicada a la Agricultura de Precisión, y permiten vislumbrar que la aplicación real de dichas técnicas no está lejos.

Un primer paso, motivo de nuestra investigación, para alcanzar estos objetivos, consiste en la identificación de las texturas naturales existentes en las imágenes, de forma que un tractor robotizado y equipado con un sistema de visión pueda localizar determinadas estructuras en las imágenes para su tratamiento selectivo, tal como la identificación de rodales de malas hierbas o la concentración de los cultivos. Esta tarea se presenta ciertamente difícil en el sentido de que el sistema debe trabajar en un entorno de exterior donde las condiciones de iluminación y otras variables adversas constituyen un serio problema.

Por tanto, el problema que nos planteamos abordar en este trabajo es la identificación de forma automática de texturas en imágenes procedentes de campos de cultivo, concretamente de cereal y maíz.

## **1.2. Estructura de la memoria**

Esta memoria se organiza en cinco capítulos.

Capítulo 1: en lo que resta del presente capítulo se exponen los objetivos que se plantearon en la investigación aquí recogida, en base a los planteamientos previos y que tratan de dar solución a la problemática existente. También se realiza una revisión histórica sobre la problemática a resolver respecto de la clasificación de texturas en imágenes de cultivos.

Capítulo 2: se realiza una revisión del estado del arte en los métodos inicialmente utilizados y en la clasificación de imágenes de cultivos, realizándose una explicación detallada de los métodos y técnicas elegidas.

Capítulo 3: se propone la estrategia de solución a la problemática planteada, junto con una breve revisión de los métodos empleados para llevarla a cabo.

Capítulo 4: se diseña una estrategia de pruebas con el objetivo de verificar la eficacia de los métodos propuestos cuando se comparan con otros métodos existentes.

Capítulo 5: se extraen las conclusiones pertinentes y se exponen las líneas de investigación futuras, que dan pie al inicio de la investigación en los estudios de Doctorado.

## **1.3. Objetivos**

Previamente, se ha identificado el problema, lo que permite plantear como objetivo principal el desarrollo de métodos automáticos para la detección de las distintas texturas que aparecen en una imagen captada a partir de campos de cultivo de cereal y maíz mediante un sistema de visión artificial acoplado en un tractor robotizado..

### **1.3.1. Objetivos generales**

- 1) Aprender a manejar referencias bibliográficas, así como la forma de abordar las investigaciones.
- 2) Identificar métodos de segmentación de imágenes tendentes a la identificación de texturas naturales existentes en la literatura.
- 3) Determinar los métodos que nos puedan ser más útiles en la resolución de nuestro problema.
- 4) Analizar las ventajas e inconvenientes de cada uno de ellos.
- 5) Identificar las técnicas de segmentación que mejoran el funcionamiento de los distintos métodos.
- 6) Analizar las ventajas e inconvenientes de cada una de ellas.
- 7) Realizar un aporte de carácter investigador con las conclusiones finales.

### **1.3.2. Objetivos específicos**

- 1) Seleccionar el método o métodos de segmentación de entre los más prometedores o apropiados que se hayan estudiado.

- 2) Seleccionar las bases de datos que constituirán los conjuntos de entrenamiento y de clasificación.
- 3) Seleccionar las imágenes que constituirán los conjuntos de clasificación.
- 4) Identificar una posible mejora de los métodos existentes o dar una solución a la problemática de la clasificación de imágenes de campos cultivados.
- 5) Implementar la mejora propuesta con el fin de analizar su comportamiento en base a los resultados obtenidos.
- 6) Identificar líneas de investigación futuras.
- 7) Difundir los resultados mediante publicaciones científicas u otro tipo de divulgación.

## **1.4. Metodología histórica**

A continuación se exponen de forma cronológica los pasos seguidos para llevar a cabo la investigación, junto con la actividad desarrollada en cada uno de ellos.

El trabajo de investigación tiene su origen en los proyectos de investigación que desde hace varios años vienen realizando miembros del grupo ISCAR (2010) en colaboración con el grupo de inteligencia Artificial del Instituto de Automática Industrial del Consejo Superior de Investigaciones Científicas. Concretamente se trata de sendos proyectos del plan nacional de I+D+i, a saber:

- Desarrollo de Métodos de Identificación de Texturas Naturales y su Localización Espacial mediante métodos de Visión Artificial (AGL2008-04670-C03-02)
- Extracción de Conocimiento Espacio-Temporal y Visión Artificial para la Automatización de Tratamientos Localizados (AGL2005-06180-C03-03)

En estos proyectos uno de los problemas, que en estos momentos está en fase de investigación, es precisamente el que se plantea en el presente trabajo, justificando de este modo su elección.

Para resolver nuestro problema hemos buscado inicialmente, métodos de clasificación de texturas, por los buenos resultados obtenidos en la clasificación de imágenes, elegimos el Mean Shift y el LVQ (Método de Cuantificación Vectorial), ambos necesitan de sendos

parámetros iniciales, ancho de banda (bandwidth) y un umbral respectivamente. Dado que el objetivo consiste en la clasificación automática de texturas en imágenes, la idea inicialmente propuesta consistía en la variación de estos parámetros hasta encontrar el valor más apropiado para los mismos en función de los resultados de clasificación obtenidos. Al ser dichos métodos de clasificación muy sensibles a los parámetros de entrada, es importante definir la aceptación de la clasificación como válida, para ello se han utilizado los siguientes índices de validación, que se encuentran en la literatura como razonablemente útiles: Davies-Bouldin, Dunn, Shilhouette, Separation, Calinski-Harabasz y Homogeneity.

Para determinar los índices que mejores resultados ofrecen, y dado que no existen informes en la literatura sobre su comportamiento con este tipo de imágenes, planteamos una serie de experimentos orientados a determinar su comportamiento sobre un conjunto de 22 bases de datos adquiridas durante el mes de Noviembre de 2009 del repositorio UCI Learning Machine Repository (Asunción y Newman, 2010). Se trata de bases de datos numéricas cuya dimensión varía en función del número de atributos que presente cada conjunto de muestras. La elección de este conjunto de datos estriba en que los mismos se proporcionan ya clasificados, siendo así posible la verificación del comportamiento de los mencionados índices.

Una vez seleccionados los índices que mejor se comportan con estas bases de datos, creamos una nueva base de datos propia constituida por imágenes sintéticas e imágenes reales, en las que aplicamos los algoritmos de clasificación tratando de validar las particiones mediante los índices de validación anteriormente mencionados. Se llega a la conclusión de que en las imágenes de texturas, objeto de este trabajo, el comportamiento de los citados índices no ofrece resultados convincentes. Esto nos conduce a la reorientación de la investigación en otra línea.

En la búsqueda de nuevas soluciones, nos centramos en trabajos en los que se utilizan específicamente imágenes de cultivos (Liyang Zheng y col, 2009 y 2010, y Meyer y Neto, 2008), y decidimos utilizar los índices cromáticos, normalizando inicialmente la imagen tal y como se explica en Gée y col. (2008). Dado que nuestras imágenes se encuentran representadas en el espacio de color RGB, nos centramos en el estudio de los índices cromáticos identificados en Gée y col. (2008): exceso de verde (ExG), exceso de azul (ExB), exceso de rojo (ExR), diferencia del exceso de verde con el exceso de rojo (ExGR),

color index of vegetation extraction (CIVE) y vegetative (VEG). El objetivo consiste en clasificar las diferentes partes de la imagen, en un primer lugar fusionamos las imágenes correspondientes a los índices ExG, ExGR, CIVE y VEG con el fin de obtener una imagen donde los verdes están identificados. Una vez llegados a este punto, la utilización del clasificador basado en el agrupamiento borroso permite la identificación de varios tipos de verde diferentes y por tanto de texturas vegetales en los campos de cultivo.

En segundo lugar, el siguiente objetivo consiste en clasificar los diferentes tipos de suelo, para ello se separa la parte del cielo de la zona verde previamente identificada, quedándonos precisamente la parte del suelo. La aplicación del clasificador borroso sobre este tipo de texturas, permite la identificación de diferentes tipos de suelo.

Todos estos métodos se plantean de forma que no requieren intervención del usuario, proponiéndose un procedimiento automático que permite la identificación de diversos tipos de texturas vegetales y de suelo en las imágenes de los cultivos objeto de estudio.

# Capítulo 2

## 2. Estado del arte

### 2.1. Introducción

Desde los años 80 ha aumentado la conciencia sobre el daño que las prácticas agrícolas causan al medio en varios aspectos, como son entre otros, los posibles efectos malignos en el ecosistema del suelo, efectos directos en la salud de las personas y efectos sociales, como el uso de recursos no renovables. Las prácticas agrícolas tradicionales tratan el suelo de forma uniforme sin distinción específica. En grandes extensiones este tratamiento no es aconsejable, sobre todo a nivel de herbicidas, que sería conveniente aplicarlos de forma localizada, para minimizar las contaminaciones tanto del suelo como de las personas que los manipulan. Además, la identificación de zonas de especial interés dentro de los cultivos para su tratamiento hace que se requieran métodos específicos antes que generales.

Como consecuencia de estas necesidades surgen investigaciones encaminadas a la localización exacta de la mala hierba o de las zonas de cultivo específicas de interés, para ello se inician los estudios encaminados a la identificación de texturas en imágenes tomadas en los campos cultivados. Según (Liyang Zheng y col., 2010) es difícil separar las texturas en las imágenes en color, debido a que son imágenes de exterior donde las condiciones de iluminación son ciertamente cambiantes.

Por tanto, una tarea compleja consiste en clasificar las diferentes texturas existentes en las imágenes (partes verdes, suelo, cielo) de forma automática para su posterior tratamiento.

La utilización de técnicas de clasificación ha sido utilizada en diversos campos de aplicación, tienen como objetivo organizar objetos en distintos grupos con características similares entre ellos y diferentes respecto a los miembros de otros grupos. La clasificación es una técnica común en el área de análisis estadístico y se encuentra ampliamente extendida en otras áreas tales como reconocimiento de patrones, aprendizaje automático, biomedicina, minería de datos o análisis de imágenes, que es la parte que nos interesa.

En la literatura se han propuesto diferentes métodos de clasificación de texturas, de los cuales, los que nos interesan son aquellos capaces de tomar decisiones de forma automática, por lo que elegimos en un principio dos posibles candidatos: Mean Shift y LVQ. Estos métodos se fundamentan en sendos parámetros que es necesario fijar de antemano. El problema que se plantea es cómo fijar dichos parámetros. La propuesta que se intenta en este trabajo consiste en variar dichos parámetros de forma controlada hasta encontrar una buena partición, cuya medida de bondad la proporcionan determinados índices de calidad. La revisión de estos índices se realiza en la sección 2.2 como parte de la revisión bibliográfica. Por otra parte, dado que de clasificadores se trata, en la sección 2.3 se revisan algunos de los métodos de clasificación más relevantes en el área de la clasificación de texturas en imágenes, centrando el esfuerzo en las imágenes de exterior.

Dado que el planteamiento inicial no produjo los resultados esperados, y tal y como se ha mencionado en la introducción la reorientación de la investigación se realiza en el sentido de abordar la problemática desde el punto de vista de un tratamiento específico basado en índices cromáticos en imágenes procedentes de cultivos agrícolas, realizando la correspondiente revisión de técnicas en esta línea en la sección 2.4.

## **2.2. Índices de calidad**

Son utilizados para medir la bondad de las particiones obtenidas por los algoritmos de clasificación. Según Theodoridis y col. (1999) existen tres criterios con tal propósito: internos, externos y relativos.

Tanto los criterios internos como externos están basados en métodos estadísticos. Los índices internos son usados para medir la bondad de la clasificación sin información externa (Tsen y col., 2005), evalúan los resultados usando cantidades y rasgos inherentes al conjunto de datos. Por tanto, éstos son los que centran exclusivamente nuestro interés de cara a la automatización de los métodos de clasificación. Los índices internos más utilizados son: Silhouette (Kaufman y Rousseeuw, 1990; Chen y col., 2002), Davies-Bouldin (Dimitriadou y col., 2002; Bolshakova y Azuaje, 2003), Calinski-Harabasz (Dudoit y col., 2002; Shu, 2003), Dunn (Halkidi y col., 2001; Bolshakova y Azuaje, 2003), Hubert-Levin (C-index), Hartigan (Bolshakova & Azuaje, 2006; Dudoit y col., 2002), r-intra index (Strehl, 2002) y Homogeneity y Separation (Sharan y col., 2003).

Kaijun Wang y col., (2009), conscientes de que en las técnicas de clasificación es muy importante la evaluación de los resultados, pero que a su vez en ocasiones consumen mucho tiempo y son un complicado trabajo, han desarrollado una herramienta visual para la validación de los agrupamientos.

## **2.3. Métodos de clasificación**

Existe un gran número de algoritmos de clasificación cada uno adaptado a las necesidades específicas de los distintos problemas que tratan de resolver.

Durante las últimas décadas, se han propuesto en la literatura diversos métodos encaminados a la segmentación de las imágenes según sus texturas, ver por ejemplo Xia y col., (2007), y referencias asociadas.

La mayoría de ellos pueden considerarse como métodos con dos procesos sucesivos asociados: *extracción de características y segmentación basada en las características*. El término sucesivos hace referencia al hecho de que se realizan en ese orden durante la clasificación.

La extracción de características tiende a encontrar una medida apropiada para caracterizar la homogeneidad de cada región dentro de la imagen, estableciendo una asociación entre la región y una determinada textura (Valdovinos y col. 2005; Puig y García, 2006 o Hanmandlu y col. 2004).

La segmentación basada en las características consiste en el proceso de asignar a cada píxel de la imagen una etiqueta que lo identifique como perteneciente a una determinada clase.

Los algoritmos Mean-Shift y LVQ seleccionados en nuestra investigación como potenciales candidatos para la automatización del proceso han dado buenos resultados en la clasificación de imágenes como así lo avala la bibliografía encontrada sobre su aplicación. A continuación se realiza una revisión general de dichos métodos así como del clasificador borroso dado que en este último caso se utilizará para la clasificación de texturas vegetales y de suelo, una vez identificadas las mismas. En el capítulo tres se estudian en profundidad.

### 2.3.1. Mean Shift

Es una técnica de clasificación para encontrar grupos en espacios de características. El algoritmo Mean Shift fue propuesto primeramente por Fukunaga y col., (1975) y más tarde adaptado por Cheng, (1995), para su aplicación a imágenes, en este trabajo se hace una importante aportación consistente en la definición del núcleo y el ancho de banda del mismo que caracterizan a dicho método. Comaniciu y col., (2002), basan la utilización de esta técnica en aplicar iterativamente el método para encontrar el máximo local o punto estacionario de la función de densidad más cercano a un punto P del conjunto de datos. La mayor ventaja que presenta este algoritmo es que no es necesario el conocimiento a priori del número de clases y además permite que éstos se suministren al sistema de aprendizaje de forma arbitraria.

La razón para utilizar esta técnica de estimación de la densidad se debe a que el espacio de características se puede caracterizar como una función de densidad de probabilidad del parámetro representado. Regiones densas en el espacio de características se corresponden con los máximos locales de la función de densidad de probabilidad, esto es, las modas de la densidad desconocida. Una vez se ha encontrado la moda para cada punto, se asociarán en un grupo común a todas aquellas que se encuentren en un entorno determinado. Este algoritmo ha sido aplicado en diversos entornos Comaniciu y col., (2002), en la segmentación y el filtrado de imágenes. Aplicaciones más recientes y de mayor éxito se han aplicado en procesos de selección de características en alta dimensionalidad tal como se explica en L.Yu y col., (2008).

Con el fin de obtener mejores resultados se ha utilizado en combinación con otros métodos, por ejemplo, Ruhan He y col., (2009), hacen una aproximación híbrida con dos métodos el Mean Shift y C-Means Fuzzy, obteniendo con el primero una segmentación de calidad y con el segundo la eficiencia computacional. Por ello, en un primer paso extraen algunas regiones por aproximación con el Mean Shift con el que se obtiene una segmentación inicial y en el segundo paso, para llegar a las regiones finales, utilizan el C-Means Fuzzy. Este enfoque lo consideran bueno porque proporciona un equilibrio entre la facilidad de uso, la eficiencia y la calidad de la segmentación.

Para las imágenes de vegetación, Liying Zheng y col. (2009), proponen un algoritmo, introduciendo el Mean Shift en el algoritmo de segmentación. El algoritmo resultante consta de dos etapas, en la etapa inicial extraen características tales como el tono y la

saturación en el espacio HSI, así como los colores rojo, verde y azul del espacio RGB. En la segunda fase se realiza la segmentación de la imagen con las características extraídas, mediante el algoritmo de segmentación Mean-Shift y una red neuronal “back propagation” (BPNN), de esta forma la imagen es clasificada en dos, la parte de vegetación verde y la no verde. Esta combinación de algoritmos genera buenos resultados, si bien según sus autores no es adecuada para ser utilizada en tiempo real.

Para mejorar el rendimiento de la segmentación de imágenes de cultivo, Liying Zheng y col. (2010), implementan un método híbrido entre el Mean Shift y el discriminante lineal de Fisher, los resultados de las simulaciones muestran que esta estrategia aumenta la dispersión entre clases y disminuye la dispersión de las muestras dentro de la clase.

### **2.3.2. Cuantificación Vectorial (LVQ)**

Es un procedimiento que puede ser supervisado o no supervisado. En su versión supervisada se determina de antemano el número de clases existentes en la imagen, en la no supervisada el número de clases se obtiene a través del propio método en función de un umbral fijado previamente. Independientemente de la versión, se trata de un proceso de aprendizaje, que obtiene los centros de las clases. Trabajos que se basan en este método, que además utilizan información del color, son los propuestos por Giacinto y col. (2000), Chan y col. (2003) o Frate y col. (2007).

### **2.3.3. Agrupamiento borroso o fuzzy clustering**

Consideran el hecho cierto en las imágenes de que los colores tienden a agruparse en la formando clases que determinan la distinta naturaleza de las texturas. Dada la naturaleza fuzzy, en cada una de las clases, se admiten píxeles con cierta ambigüedad, en el sentido de que un mismo píxel podría pertenecer tanto a una textura como a otra según sus características. Este hecho se manifiesta más claramente en las zonas fronterizas de las texturas, donde se producen transiciones graduales en los valores de los píxeles de una zona a otra de la frontera. A la categoría fuzzy pertenece uno de los métodos más clásicos en clasificación como es el conocido Agrupamiento borroso o en inglés “Fuzzy Clustering”. Para la fase de entrenamiento utiliza un método de optimización, que permite conseguir agrupaciones compactas y resolver muchas de tales ambigüedades. En esta línea se encuentran los trabajos de Pajares y Cruz (2002), Pajares y col. (2002) o Lim y Lee (1990) entre otros.

Mohaddamzadeh y Bourbakis (1997) definen las regiones a segmentar como agrupaciones de píxeles que poseen similar color, mientras los cambios de región se manifiestan gradualmente como ya se ha indicado previamente. Para plasmar esta idea definen una función de naturaleza fuzzy en el espacio de color RGB (Pajares y Cruz, 2007a).

Cheng y col. (2001) utilizan el concepto de “homogram” para extraer regiones homogéneas en una imagen de color; a su vez definen el concepto de homogeneidad fuzzy para extraer regiones de similares características mediante la obtención de una serie de umbrales. Tras la segmentación vuelven a aplicar un criterio de similitud para fusionar regiones, se trata de un proceso similar al método de segmentación de regiones según la técnica de árboles cuaternarios (Pajares y Cruz, 2007a).

## 2.4. Índices cromáticos

Los trabajos encaminados a la resolución de nuestro problema tienen en común el primer paso: la separación de la capa vegetal (plantas) con respecto a los otros elementos que aparecen en la imagen. Los procedimientos de clasificación con los métodos mencionados previamente, agrupan bien los elementos en imágenes diferentes a las que constituyen el interés de este trabajo, dejando mucho que desear en las imágenes de cultivos.

Casi todas las cámaras actuales de captura de imágenes usan el espacio de color RGB para la representación de cada píxel, la segmentación se puede realizar analizando los valores de verde, como es el caso de Yang y col.(2003), que considera vegetación todo píxel cuya intensidad en el plano representando el color verde es mayor que un cierto umbral. Del mismo modo en Aitkenhead y col. (2003) se usa la proporción de verde  $G/(R + G + B)$ , combinado con el valor de un cierto umbral determinado mediante prueba y error.

En Woebbecke y col. (1995) se presenta un índice cromático para la discriminación de plantas que da buenos resultados, y que es usado en muchos trabajos. El índice cromático se obtiene mediante una combinación lineal de los planos de color RGB con constantes  $r = -1$ ,  $g = 2$ ,  $b = -1$ .

Existen otros índices cromáticos que obtienen buenos resultados tales como el exceso de verde, que define como vegetación aquellos píxeles cuya diferencia entre la componente roja y la componente verde  $G-R$  es suficientemente grande o la combinación lineal propuesta en Ribeiro y col. (2005), con constantes  $r = -0,7$ ,  $g = 0,588$ ,  $b = 0,136$ . En Pérez

y col. (2000) se propone un índice parecido al exceso de verde, aunque ponderado sobre la intensidad total:  $G-R/G+R$ . En Meyer y Neto (2008), Van Evert y col. (2006), se realiza un análisis comparativo de todos esos índices cromáticos.

Existen técnicas de segmentación que intentan adaptar la segmentación a cada imagen, para de esa forma resolver los problemas de las diferencias en iluminación y demás condiciones variables que tenemos en el entorno en el que nos movemos. En Andreasen y col. (1997), a partir del estudio del histograma de la componente verde, se determina el mejor índice a usar en cada imagen y se establece el umbral a partir del cual se considera la intensidad de verde suficientemente grande.

Aunque la mayoría de los trabajos usan directamente los planos de color RGB, algunos proponen la utilización del modelo HSI, (Matiz-Saturación-Intensidad o Hue-Saturation-Intensity) que ofrece la ventaja de separar el color de la intensidad, siendo más robusto ante cambios de iluminación. Una vez transformada la imagen RGB original al modelo HSI, puede segmentarse directamente la imagen aplicando una umbralización sobre las intensidades en el plano de matiz (Gottschalk y col., 2008), algún algoritmo de clasificación de colores basado en los planos de matiz y saturación, utiliza redes Bayesianas (Hemming y Rath, 2001, Lee y col., 1996, 1999) o por simple comparación con valores de matiz y saturación etiquetados en imágenes anteriores como vegetación (Blasco y col., 2002).



# Capítulo 3

## 3. Revisión de métodos

### 3.1. Introducción

En éste capítulo exponemos de forma cronológica los pasos seguidos para llevar a cabo la investigación, junto con la actividad desarrollada en cada uno de ellos.

Se inicia el trabajo de investigación ante la necesidad de reconocer de forma automática en un campo de cultivo de cereal y maíz el número de clases, más concretamente nuestro objetivo será separar la parte verde, donde se incluye el cultivo y las malas hierbas, del resto (cielo y suelo), tarea compleja por las condiciones de iluminación cambiantes en los entornos de exterior donde se trabaja. La segmentación en las imágenes de cultivos aparece como un reto que se aborda constantemente, como se comprueba a lo largo de la bibliografía, con aportaciones significativas pero no concluyentes. Este trabajo aborda la clasificación de las texturas en imágenes de los cultivos mencionados desde el punto de vista de su automatización.

La investigación se puede dividir en dos partes bien diferenciadas,

- **Primera parte**, búsqueda infructuosa de métodos utilizados en la clasificación de imágenes, que mediante la utilización de índices de validación podían clasificar una imagen de forma automática,
- **Segunda parte**, la utilización de índices cromáticos para extraer las tonalidades preferentemente verdes, rojizas y azules, correspondientes a texturas vegetales, suelo y cielo respectivamente. Las texturas vegetales y de cielo son además reclasificadas en otras texturas más finas. Es en esta línea donde se realiza la aportación fundamental del trabajo de investigación en el sentido de que se propone una nueva estrategia que realiza una fusión de índices de vegetación para la obtención de la cubierta vegetal y además se proponen métodos automáticos de separación y reclasificación de las texturas.

## 3.2. Primera parte: automatización mediante clasificación

Para clasificar las distintas texturas de la imagen, iniciamos el estudio de métodos ya implementados con el fin de mejorar los resultados obtenidos por los métodos existentes en la bibliografía, para ello, elegimos dos métodos de clasificación Mean Shift y Método de Cuantificación Vectorial (LVQ).

Ambos métodos necesitan dos parámetros el ancho de banda y el umbral respectivamente, variando estos valores, con cada uno de ellos se genera una partición, la idea consiste en determinar cuál de las particiones así obtenidas se considera la más apropiada, esta tarea se plantea mediante la utilización de los denominados índices de validación de particiones. Las propuestas basadas en los dos métodos de clasificación se formulan seguidamente en las secciones 3.2.1 y 3.2.2

### 3.2.1. Mean Shift

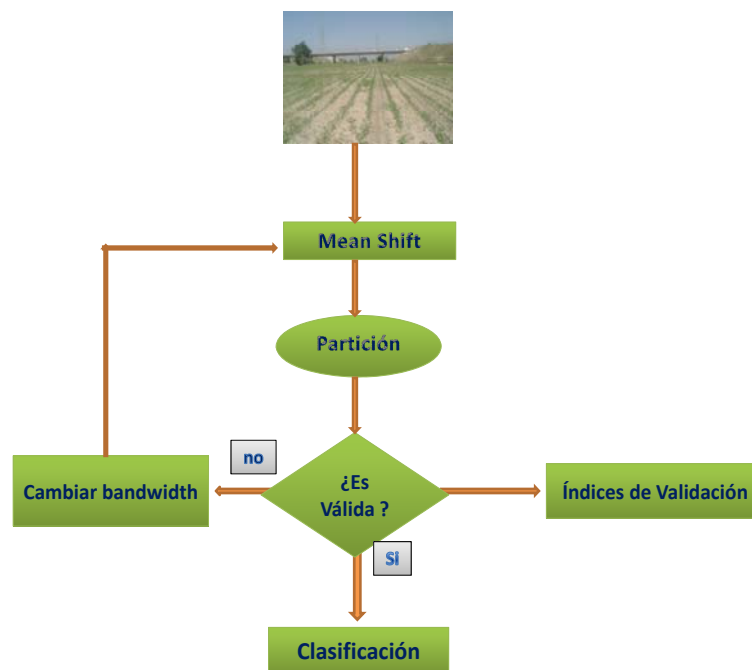


Figura 1.- Método de clasificación basado en el método MeanShift

Con el fin de automatizar el proceso de clasificación de texturas en imágenes, aplicamos el método Mean Shift, como se puede ver en la figura 1, para ello, tomamos una imagen y aplicamos el algoritmo con un ancho de banda inicial que es el parámetro requerido, de esta forma obtenemos una partición la cual es validada por los índices de validación, si la partición es aceptada nos quedamos con ella y si no lo es, cambiamos el parámetro de entrada, ancho de banda (bandwidth) y comenzamos otra vez con el proceso de clasificación.

El Mean Shift es uno de los métodos más conocidos de estimación de la densidad es el basado en la estimación del *kernel* de densidad. Dado un conjunto de datos  $x_i, i=1 \dots, n$  de un espacio de dimensión  $d$ ,  $x \in \mathfrak{R}^d$ , el estimador del kernel de densidad multivariante usando el Kernel  $K(x)$  con ancho de banda,  $h$ , es:

$$\hat{f}(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (3.1)$$

El objetivo de una función kernel es el de expresar en alguna forma la similitud entre dos objetos. Uno de los kernels más utilizados es el kernel gaussiano o normal, que es un kernel radialmente simétrico y se define como:

$$K_N(x) = (2\pi)^{-d/2} \exp\left(-\frac{1}{2} \|x\|^2\right) \quad (3.2)$$

Para todo kernel radialmente simétrico, como es el caso del kernel normal, ha de cumplirse:  $K(x) = c_{k,d} k(\|x\|^2)$ , siendo  $k(x)$  el perfil del kernel, para todo  $x \geq 0$ , y  $c_{k,d}$ , la constante de normalización que hace que la integral del kernel sea la unidad. En el caso del kernel gaussiano o normal, su perfil es:

$$K_N(x) = \exp\left(-\frac{1}{2} x\right) \quad x \geq 0 \quad (3.3)$$

El primer paso en el análisis del espacio de características con densidad  $f(x)$  es encontrar las modas de esta densidad. Estas modas se encuentran en los puntos donde el gradiente de la función de densidad se anula, es decir, cuando  $\nabla f(x) = 0$ . El método Mean Shift es una manera elegante de encontrar estos puntos sin necesidad de estimar la función de densidad.

El gradiente del estimador de densidad se define como:

$$\nabla f_{h,k}(x) = \frac{2c_{k,d}}{nh^{d+2}} \sum_{i=1}^n (x - x_i) g\left(\left\|\frac{x - x_i}{h}\right\|^2\right) = \quad (3.4)$$

$$= \frac{2c_{k,d}}{nh^{d+2}} \left[ \sum_{i=1}^n g\left(\left\|\frac{x_i - x}{h}\right\|^2\right) \right] \left[ \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)} - x \right] \quad (3.5)$$

donde  $g(s) = -k(s)$ . El primer término es proporcional al estimador de densidad en  $x$  calculado a partir del kernel  $G(x) = c_{g,d}g(\|x\|^2)$  y el segundo término:

$$m_h(x) = \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)} - x \quad (3.6)$$

es el vector Mean Shift o el vector de desplazamiento medio. Este vector apunta siempre a la dirección de máximo incremento de la densidad. El método Mean Shift se obtiene a través de la sucesión de los siguientes pasos:

- Cálculo del Mean Shift vector  $m_h(x^t)$
- Traslación de la ventana de desplazamiento  $x^{t+1} = x^t + m_h(x^t)$

Este procedimiento garantiza la convergencia a un punto donde el gradiente de la función de densidad es cero, asegurando así la obtención de un punto estacionario de densidad máxima.

En el caso de utilizar un kernel gaussiano, la expresión del vector Mean Shift nos queda:

$$m_h(x) = \frac{\sum_{i=1}^n x_i \exp\left(-\frac{1}{2}\left\|\frac{x - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n \exp\left(-\frac{1}{2}\left\|\frac{x - x_i}{h}\right\|^2\right)} - x \quad (3.7)$$

La ventaja de utilizar este kernel gaussiano es que el camino que se obtiene hasta llegar a la moda tiene una trayectoria suave, es decir, el ángulo entre dos vectores Mean Shift consecutivos es siempre menor que  $90^\circ$  (Comaniciu y col, 2002).

Existen cuatro técnicas diferentes para la selección del parámetro del ancho de banda, bandwidth, ( $h$ ) utilizado en la función kernel para el procedimiento Mean Shift:

- Selección estadística. Es el bandwidth que alcanza el mejor compromiso entre el sesgo y la varianza del estimador sobre todos los  $x \in \mathcal{R}^d$ .
- Por estabilidad de la descomposición. El bandwidth es el centro del rango más grande sobre el cual se obtuvo el mismo número de grupos para los datos dados.
- Bandwidth máximo. Es el mejor bandwidth que maximiza una función objetivo que expresa la calidad de descomposición.
- Información de alto nivel. Como en muchos de los casos la descomposición depende de la tarea a realizar, se puede tomar el bandwidth de la información dada por el usuario o por niveles altos de la tarea.

### Algoritmo

El algoritmo de agrupamiento basado en Mean Shift consiste en la aplicación práctica del procedimiento de búsqueda de modas, según se describe a continuación:

- Para los puntos del conjunto de datos dejar correr el procedimiento de búsqueda de puntos estacionarios de  $\hat{f}_{K,h}(x)$  o modas.
- Deshacerse de los puntos intermedios reteniendo sólo el máximo local.

En otras palabras, el algoritmo Mean Shift agrupa un conjunto de datos de dimensión  $n$  asociando a cada punto con la moda o el pico de la función de densidad de probabilidad del conjunto de datos. Para cada punto, el algoritmo obtiene la moda correspondiente.. En primer lugar, se define un kernel radial centrado en el punto con ancho de banda  $h$  y se calcula la media de los puntos que caen dentro del área definida bajo el kernel. Después, el algoritmo desplaza la ventana o el kernel hacia la media y se va repitiendo el proceso hasta que se produce la convergencia, es decir, hasta que el vector Mean Shift calculado recursivamente se mantiene constante o hasta que su variación es inferior a un umbral determinado. En cada iteración, la ventana se desplazará hacia zonas de mayor densidad de puntos hasta que se alcance el máximo, donde los datos están distribuidos de la misma manera en la ventana. El algoritmo siguiente muestra el pseudocódigo del agrupamiento basado en Mean Shift. Al finalizar el algoritmo, todos los puntos asociados a una moda de valor similar son asignados a un mismo grupo o clase.

**Entrada: Conjunto de datos X donde  $x_i \in \mathbb{R}^d$ ,  $i=1..n$  y ancho de banda h.**

```
1: for all  $x_i \in X$  do
2:    $x_t \leftarrow x_i$ 
3:   while  $m_h(x_t) \neq \text{umbral}$  do
4:     calcular  $m_h(t)$ ;
5:      $x_t \leftarrow x_t + m_h(t)$ 
6:   end while
7:    $\text{ClustCent}_i = \{x \in D \mid \text{dist}(x, x_t) \text{ es mínima}\}$ 
8:   if  $\text{ClustCent}_i$  no existe then
9:      $\text{ClustCent}_i = \text{nuevo ClusterId}$ ;
10:  end if
11: end for
Salida: Vector cluster  $\in \mathbb{R}^d$ 
```

### 3.2.2. Cuantificación vectorial mediante aprendizaje no supervisado (LVQ)

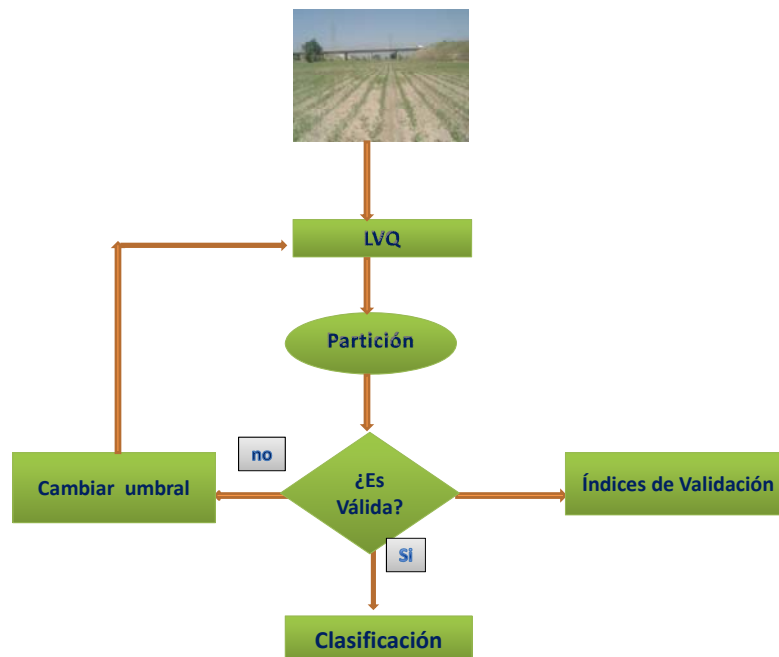


Figura 2.- Método de clasificación basado en el método LVQ

Al igual que lo explicado en el apartado 3.2.1. , figura 1, aplicamos el mismo proceso para el método de clasificación basado en el LVQ, figura 2, en este caso el parámetro de entrada requerido es el umbral.

El número de clases no se conoce inicialmente, por lo tanto el algoritmo comienza suponiendo que hay sólo una clase. El algoritmo progresa como sigue:

1. Para cada patrón se calcula la distancia con todos los centros existentes, para el primer elemento, el cual constituye el primer centro.
2. Tomar el centro más cercano utilizando una medida de distancia, por ejemplo, la euclídea.
3. Si dicha distancia es menor que un umbral determinado previamente, se asocia el elemento a la clase y se calcula la media de todos los elementos, y se calcula la media de todos los elementos que pertenecen a dicha clase. Esta medida nos proporciona el centro.
4. Si la distancia es mayor que el umbral prefijado se crea una nueva clase, asignando el valor del centroide al del elemento.

### 3.2.3. Índices de validación

#### Índice Davies-Bouldin

Del trabajo de Davies y Bouldin (1979), este índice se define como sigue. Sea  $s_i$  una medida de dispersión del clúster  $C_i$  y  $d(C_i, C_j) \equiv d_{ij}$  la disimilaridad entre dos clústeres. Un índice de similaridad  $R_{ij}$  entre  $C_i$  y  $C_j$  satisface las siguientes condiciones:

- $R_{ij} \geq 0$
- $R_{ij} = R_{ji}$
- Si  $s_i = 0$  y  $s_j = 0$  entonces  $R_{ij} = 0$
- Si  $s_j > s_k$  y  $d_{ij} = d_{ik}$  entonces  $R_{ij} > R_{ik}$
- Si  $s_j = s_k$  y  $d_{ij} < d_{ik}$  entonces  $R_{ij} > R_{ik}$

Estas condiciones dicen que  $R_j$  es no negativo y simétrico. Un posible valor  $R_{ij}$  que satisface esta condición es

$$R_{ij} = \frac{s_i + s_j}{d_{ij}} \quad (3.8)$$

Entonces el índice Davies-Bouldin se define como:

$$DB_m = \frac{1}{m} \sum_{i=1}^n R_i \quad (3.9)$$

dónde  $R_i = \max_{j=1, \dots, m, j \neq i} R_{ij}$  y  $R_{ij}, i=1, \dots, m$

La disimilaridad entre el clúster  $C_i$  y el clúster  $C_j$ , en un espacio  $l$ -dimensional es definida como:

$$d_{ij} = \|\bar{x}_i - \bar{x}_j\| = \sqrt{\sum_{k=1}^l |\bar{x}_{ik} - \bar{x}_{jk}|^2} \quad (3.10)$$

y la dispersión de los clústeres  $C_i$  se define como:

$$s_i = \sqrt{\frac{1}{n_i} \sum_{x \in C_i} \|x - \bar{x}_i\|^2} \quad (3.11)$$

El  $DB_m$  mide la similitud promediada entre cada clúster y su más próximo en términos de agrupamiento. Valores pequeños de  $DB$  son indicativos de la presencia de un clúster compacto y bien separado.

### Índice de Dunn

Se define como sigue, (Dunn, 1974) :

$$D_m = \min_{i=1, \dots, m} \left\{ \min_{j=i+1, \dots, m} \left( \frac{d(C_i, C_j)}{\max_{k=i+1, \dots, m} \text{diam}(C_k)} \right) \right\} \quad (3.12)$$

Dónde la función de disimilitud entre dos clústeres  $C_i$  y  $C_j$  es

$$d(C_i, C_j) = \min_{x \in C_i, y \in C_j} d(x, y) \quad (3.13)$$

y el diámetro de un clúster  $C$  es

$$\text{diam}(C) = \max_{x,y \in C} d(x,y) \quad (3.14)$$

Si  $X$  contiene clústeres compactos y bien separados, el índice Dunn será grande, dado que la distancia entre los clústeres se espera que sea grande y a la vez el diámetro de los mismos es deseable que sea pequeño.

Este método fue propuesto por Rousseeuw (1987), usándose cuando se buscan clústeres compactos y claramente separados. Para construir las siluetas se necesita una partición obtenida por la aplicación de algún algoritmo de clasificación y la matriz de proximidad que determine distancias entre los objetos involucrados. Para un clúster dado, este método asigna para cada objeto del mismo una medida cuantitativa  $s(i)$ , conocida como la anchura de la silueta. La anchura de la silueta indica la pertenencia del objeto  $i$  en el clúster al que ha sido asignado. Sea  $i$  cualquier objeto en el conjunto de datos, llamando  $C_j$  a aquél al que se le ha asignado el objeto  $i$ . Sea  $a(i)$  la media de disimilitud entre  $i$  y todos los objetos del clúster  $C_j$ , además se puede calcular

$$b(i) = \min_{C_k \neq C_j} d(i, C_k) \quad (k = 1, 2, \dots, c; k \neq j) \quad (3.15)$$

A partir de los datos anteriores la anchura de la silueta se define como,

$$s(i) = \frac{b(i) - a(i)}{\max \{a(i), b(i)\}} \quad (3.16)$$

El clúster  $C_k$  para el cual es obtenido el mínimo, es decir,  $d(i, C_k) = b(i)$  es un vecino del objeto  $i$ . El clúster  $C_k$  representa la segunda mejor opción para el objeto  $i$ .

De esta definición podemos ver que  $-1 \leq s(i) \leq 1$ . Un valor de  $s(i)$  cerrado en el  $1$  es obtenido cuando la disimilitud dentro de  $a(i)$  es mucho más pequeña que la más pequeña entre la disimilitud  $b(i)$ . Por lo tanto, en este caso, podemos decir que el objeto  $i$  está bien agrupado. Por otra parte, si  $s(i)$  toma valores aproximándose a  $-1$ , esto implica que  $a(i)$  es mayor que  $b(i)$ . En este caso podemos decir que el objeto  $i$ , ha sido bien clasificado, aunque pueda ser reasignado. Si  $a(i)$  y  $b(i)$  tienen valores similares entonces  $s(i)$  se aproxima a cero. En esta situación el objeto  $i$  se encuentra igualmente lejos de ambos clústeres  $C_j$  y  $C_k$ .

## Índice de Separación

El índice de validación  $S$  está basado en la función objetivo  $J$ , determinando el número medio de datos y el cuadrado de las mínimas distancias de los centros de los clúster. El índice es definido (Sharan y col., 2003):

$$S(c) = \frac{\sum_{i=1}^c \sum_{j=1}^N u_{ij}^2 d(x_j - v_i)^2}{N \min_{\substack{m,n=1,\dots,c \\ \text{and } m \neq n}} \{d(v_m - v_n)\}^2} = \frac{\sum_{i=1}^c \sum_{j=1}^N u_{ij}^2 d(x_j - v_i)^2}{N * (d_{min})^2} \quad (3.17)$$

donde  $d_{min}$  es la distancia mínima euclídea entre centros de los clústeres. Cuanto más separados estén los clústeres, mayor es  $(d_{min})^2$ , haciendo que  $S$  disminuya. El valor más pequeño de  $S$  indica un valor óptimo de la partición.

## Índice Calinski-Harabasz

Propuesto por Calinski-Harabasz (1974) se define como:

$$C\&H = \frac{B/(c - 1)}{W/(n - c)} \quad (3.18)$$

donde:

$N$  es el número total de unidades

$C$  es el número de clústeres en la partición

$B$  es la suma total del cuadrado de las distancias entre clústeres

$W$  es la suma total del cuadrado de las distancias dentro de los clústeres

El máximo valor del índice se corresponde con la mejor partición.

## Índice de Homogeneity

La homogeneidad de un clúster se define como la similitud promedio entre sus miembros, este índice, propuesto por Sharan y col., (2003) mide la similitud entre los elementos de un clúster. Este índice está muy vinculado al “Separation” definido previamente, de suerte que a mayor homogeneidad menor separación y viceversa.

Sea  $N=\{e_1, \dots, e_n\}$  un conjunto de  $n$  elementos;  $C$  una partición de  $N$  en subconjuntos,  $C=(C_1, \dots, C_l)$ . De esta forma, dos elementos de  $N$  se dice que son miembros de un clúster, si los dos pertenecen al mismo.

$$H_{media} = \frac{1}{M} \sum_{i,j \text{ miembros de un cluster}, i < j} S(F(i), F(j)) \quad (3.19)$$

donde

$S$  es la función de similitud

$M$  es el número total de pares de clústeres

$F$  es la función que determina las características de un elemento

$$H_{min} = \min_{c \in C} \frac{\sum_{i,j \in c, i < j} S(F(i), F(j))}{\binom{|C|}{2}} \quad (3.20)$$

### 3.3. Segunda parte: segmentación de texturas y clasificación

Esta segunda etapa de la investigación surge como consecuencia de la falta de resultados convincentes durante la primera parte de la investigación. Aquí ahora la propuesta se formula en base a los índices de vegetación mencionados en la sección 2.4, gracias a los cuales es posible identificar las texturas correspondientes a las partes vegetales, suelo y cielo en las imágenes. Posteriormente, tal y como se ha mencionado previamente, las texturas vegetales y de suelo se vuelven a clasificar con el fin de poder identificar a su vez varias texturas de esta naturaleza, subyacentes. Esta subclasificación se realiza mediante la técnica de agrupamiento conocida como *Agrupamiento borroso o Fuzzy Clustering*, que describimos en la sección 3.3.1, para seguidamente proporcionar los detalles de la estrategia global en la sección 3.3.2.

#### 3.3.1. Agrupamiento borroso

El objetivo de la técnica de agrupamiento borroso consiste en dividir  $n$  objetos  $x \in X$  caracterizados por  $p$  propiedades en  $c$  clústeres o grupos. Supongamos el conjunto de datos  $X = \{x_1, x_2, \dots, x_N\} \in \mathfrak{R}^p$  un subconjunto del espacio real  $p$ -dimensional  $\mathfrak{R}^p$ . Cada

$x_k = \{x_{k_1}, x_{k_2}, \dots, x_{k_p}\} \in \mathfrak{R}^p$  se denomina vector de características,  $x_{k_j}$  es la  $j$ -ésima característica de la observación  $x_k$ .

Este clasificador puede encontrarse perfectamente especificado en las siguientes referencias clásicas: Bezdek (1981), Duda y Hart, (2000) o Zimmerman (1991).

Puesto que los elementos de un clúster deben ser tan similares entre sí como sea posible y a la vez deben ser tan diferentes a los elementos de otros clústeres como también sea posible, el proceso se controla por el uso de medidas de similitud basadas en distancias. Así la similitud o la diferencia entre dos puntos  $x_k$  y  $x_l$  puede interpretarse como la distancia entre esos puntos.

Una distancia entre dos objetos de un universo  $X$  es una función  $d : X \times X \rightarrow \mathbb{R}^+$  que toma valores reales que denotamos  $d(x_k, x_l) = d_{kl} \geq 0$  y que cumple tres propiedades:

1.  $d_{kl} = 0 \Leftrightarrow x_k = x_l$  para todo  $0 \leq k, l \leq N$
2. simetría:  $d_{kl} = d_{lk}$  para todo  $0 \leq k, l \leq N$
3. Desigualdad triangular  $d_{kl} \leq d_{kj} + d_{jl}$  para todo  $0 \leq k, j, l \leq N$  (3.21)

Cada partición del conjunto  $X = \{x_1, x_2, \dots, x_n\}$  puede enfocarse desde dos perspectivas: fuzzy y no fuzzy. Una partición no fuzzy se conoce en terminología inglesa como “crisp”. Si se desea realizar una partición del conjunto  $X$  en  $c$  clústeres tendremos  $S_i \{i = 1, \dots, c\}$  subconjuntos.

Para cada partición,  $S_i$  define un conjunto borroso  $\mu_i$  sobre el universo  $X$ ,  $\mu_i : X \rightarrow [0,1]$  que asigna lo que se conoce como grado de pertenencia  $\mu_{ik}$  de cada objeto  $x_k$  al subconjunto  $S_i$ . Así pues denotamos dicho grado de pertenencia del elemento  $x_k$  al clúster  $S_i$  como  $\mu_i(x_k) = \mu_{ik}$ . En el caso de conjuntos “crisp” un objeto  $x_k$  se dice que pertenece a un  $S_i$  dado y no pertenece al resto. Esto se expresa con los valores discretos  $\{0,1\}$  de la siguiente forma  $\mu_{ik} = 1$  para indicar pertenece y  $\mu_{ik} = 0$  para expresar que no pertenece. Por el contrario, en el caso de conjuntos fuzzy se dice 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  $\mu_{ik}$  y a  $S_j$  con grado de pertenencia  $\mu_{jk}$ . Como ejemplo, supongamos que se tienen tres conjuntos  $S_i$ ,  $S_j$  y  $S_h$ , en este caso podríamos decir que el objeto  $x_k$  pertenece a los conjuntos con los siguientes grados de pertenencia  $\mu_{ik} = 0.4$ ,  $\mu_{jk} = 0.5$  y  $\mu_{hk} = 0.1$ . Los valores tomados pertenecen al intervalo continuo  $[0,1]$ .

Dado  $X = \{x_1, x_2, \dots, x_n\}$  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)  $\mu_{ik} \in \{0,1\}$  *crisp* o  $\mu_{ik} \in [0,1]$  *fuzzy*  $1 \leq i \leq c; 1 \leq k \leq n$
- 2)  $\sum_{i=1}^c \mu_{ik} = 1 \quad 1 \leq k \leq n \quad (3.22)$
- 3)  $0 < \sum_{k=1}^n \mu_{ik} < n \quad 1 \leq i \leq c$

Para ilustrar los conceptos anteriores sea  $X = \{x_1, x_2, x_3\}$  con él podríamos construir las siguientes particiones teniendo en cuenta que  $c = 2$

<p>“crisp”</p> $U = \begin{bmatrix} x_1 & x_2 & x_3 \\ 1 & 0 & 0 \\ 0 & 1 & 1 \end{bmatrix}$	<p>“fuzzy”</p> $U = \begin{bmatrix} x_1 & x_2 & x_3 \\ 0.3 & 0.5 & 0 \\ 0.7 & 0.5 & 1 \end{bmatrix}$
$U = \begin{bmatrix} x_1 & x_2 & x_3 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix}$	$U = \begin{bmatrix} x_1 & x_2 & x_3 \\ 0.9 & 0.4 & 0.2 \\ 0.1 & 0.6 & 0.8 \end{bmatrix}$

La localización de un clúster  $S_i$  se representa por su centro  $v_j = \{v_{j_1}, v_{j_2}, \dots, v_{j_p}\} \in \mathbb{R}^p$  con  $j = 1, \dots, c$ , alrededor del cual se concentran los objetos.

La definición básica de llevar a cabo el problema de la partición fuzzy para  $m > 1$  consiste en minimizar la función objetivo según la ecuación (3.23):

$$\min z_m(U; v) = \sum_{k=1}^n \sum_{j=1}^c \mu_{jk}^m \|x_k - v_j\|_G^2 \quad (3.23)$$

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

$$\|x_k - v_j\|_G^2 = (x_k - v_j)^t G (x_k - v_j) \quad (3.24)$$

Diferenciando la función objetivo para  $v_i$  (suponiendo constante  $U$ ) y  $\mu_{jk}$  (suponiendo constante  $v$ ) y aplicando la condición de que  $\sum_{j=1}^c \mu_{jk} = 1$ , se obtiene,

$$v_j = \frac{1}{\sum_{k=1}^n (\mu_{jk})^m} \sum_{k=1}^n (\mu_{jk})^m x_k \quad j = 1, \dots, c \quad (3.25)$$

$$\mu_{jk} = \frac{\left( \frac{1}{\|x_k - v_j\|_G^2} \right)^{2/m-1}}{\sum_{h=1}^c \left( \frac{1}{\|x_k - v_h\|_G^2} \right)^{2/m-1}} \quad j = 1, \dots, c; k = 1, \dots, n \quad (3.26)$$

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  $\mu_{jk}$  (puntos lejos de  $v_j$ ) frente a valores altos de  $\mu_{jk}$  (puntos cercanos a  $v_j$ ). Cuanto mayor sea  $m > 1$  mayor es dicha influencia.

Existen diferentes medidas escalares para validar la partición, siendo el objetivo encontrar el número de clústeres que obtenga las mejores medidas. De entre todos ellos destaca por su importancia (Balasto y col. 2006, Kim y col. 2003) el *Coefficiente de partición (CP)* que mide la cantidad de solapamiento entre los clústeres

$$CP = \frac{1}{n} \sum_{j=1}^c \sum_{i=1}^n (\mu_{ji})^2 \quad (3.27)$$

Cuanto más próximo sea este valor a la unidad tanto mejor será la clasificación de los datos llegando a ser una partición pura cuando toma el valor de la unidad.

### 3.3.2. Método de segmentación automático combinando índices cromáticos y agrupamiento borroso

La estrategia propuesta en este trabajo consta de los siguientes pasos que se detallan a continuación:

- 1) **Normalización del espacio de color:** partimos de una imagen a color tomada en el espacio de color RGB donde cada píxel está bien caracterizado por sus tres valores de intensidad en sus respectivos tres canales R, G y B. A esta imagen le aplicamos el siguiente esquema de normalización, tal y como suele ser habitual en los tratamientos de las imágenes agrícolas Gée y col., (2008),

$$r = \frac{R}{R+G+B} \quad g = \frac{G}{R+G+B} \quad b = \frac{B}{R+G+B} \quad (3.28)$$

donde  $R$ ,  $G$  y  $B$  son las componentes espectrales en el modelo de color RGB en el rango  $[0,255]$  o equivalentemente  $[0,1]$  y obtenidas de la siguiente forma:

$$R = \frac{R}{R_{\max}} \quad G = \frac{G}{G_{\max}} \quad B = \frac{B}{B_{\max}} \quad (3.29)$$

donde  $R_{\max} = G_{\max} = B_{\max} = 255$  para imágenes de 24-bits.

Las figuras 3 a 5 muestran tres ejemplos de imágenes con las texturas objeto de la identificación, a saber textura vegetal, suelo y cielo. Además se presentan bajo distintas condiciones de iluminación como es el caso de las imágenes de las figuras 3 y 4 obtenidas con iluminación suficiente, mientras que la imagen de la figura 5 se ha capturado con iluminación relativamente escasa.



Figura 3.- Imagen original mostrando sólo el suelo



Figura 4.- Imagen original mostrando el suelo y el cielo con mucha iluminación



Figura 5.- Imagen original mostrando el suelo y el cielo con poca iluminación

2) **Índices cromáticos:** a partir de la imagen original se calculan los siguientes índices

<b>Exceso de verde:</b>	$ExG = 2g - r - b$ Woebbecke (1995) y Ribeiro et al., (2005)	(3.30)
<b>Exceso de rojo:</b>	$ExR = 1.4r - g$ Meyer et al., (1998)	(3.31)
<b>Exceso de azul:</b>	$ExB = 1.4b - g$ derivado de ExR	(3.32)
<b>Diferencia del exceso de verde con el exceso de rojo</b>	$ExGR = ExG - ExR$ Neto (2004)	(3.33)
<b>Colour index of vegetation extraction</b>	$CIVE = 0.441r - 0.811g + 0.385b + 18.78745$ Kataoka et al., (2003)	(3.34)
<b>Vegetative</b>	$VEG = \frac{g}{r^a b^{1-a}}$ , con $a$ inicializado a 0.667 como en el trabajo de Hague y col. (2006)	(3.35)

3) **Combinación de los índices cromáticos:** los primeros cuatro índices tienen como objetivo la extracción de los verdes ( $ExG$ ,  $ExGR$ ,  $CIVE$  y  $VEG$ ). Si bien, la propuesta

realizada en este trabajo consiste en extraer de todos ellos la máxima información posible mediante un proceso de fusión de imágenes. Las figuras 6(a) y (b) muestran los resultados correspondientes a los índices  $ExG$  y  $ExGR$  respectivamente.



(a)



(b)

**Figura 6.- Diferentes grados de verdes (a)  $ExG$ ; (b)  $ExGR$**

Estas imágenes son obtenidas aplicando las ecuaciones (3.30) y (3.33) sobre la imagen original representada en la figura 4. Como puede observarse en este resultado, las plantas se distinguen por su mayor intensidad con respecto al resto, quedando tanto el cielo como el suelo en un tono bastante más oscuro. Los resultados obtenidos aplicando ambos índices cromáticos son muy parecidos, la diferencia estriba en la escala de grises que define los diferentes verdes. Basándonos en esta observación, podemos determinar que el mejor índice será el que ofrezca mayor contraste, ya que su contribución a la combinación será más relevante. El concepto de contraste puede ser medido basándonos en el histograma de la escala de grises, con el cual disponemos de dos medidas ya sea la uniformidad o la entropía (González y col., 2004). La uniformidad es máxima cuando todos los niveles de gris son iguales (máximo uniforme) y disminuye a partir de ahí. La entropía es una medida dentro de los procesos aleatorios, que es mínima cuando todos los niveles de gris son iguales. Por lo tanto, en nuestra aproximación buscamos uniformidad mínima y máxima entropía, ya que proporcionan un alto poder discriminatorio. En nuestros experimentos hemos verificado que las dos medidas tienen un comportamiento similar para el conjunto de imágenes utilizadas, por lo que finalmente hemos elegido el menos costoso computacionalmente hablando, es decir, la uniformidad, que se calcula como sigue,

$$U = \sum_{i=0}^{L-1} p^2(z_i) \quad (3.36)$$

donde  $z$  es una variable aleatoria que nos determina el nivel de gris y  $p(z_i)$  representa el histograma,  $i = 0, 1, 2, \dots, L-1$ , donde  $L$  es el número de distintos niveles de gris. Al ser nuestra representación de la imagen original de 8 bits en escala de grises, la representación máxima es de  $2^8 = 256$ , y por tanto  $L = 256$ . Los valores normalizados de la escala de grises varían de forma continua en el intervalo  $[0, 1]$ , dividimos este intervalo en 256 subintervalos etiquetados como  $i$  y asignamos a cada nivel de gris de la imagen de entrada el límite superior del subintervalo correspondiente. Este valor corresponde al  $z_i$  necesario para calcular el histograma  $p(z_i)$ .

- 4) **Cálculo de la relevancia de los índices de color verde (vegetación):** teniendo en cuenta que la uniformidad mínima es considerada mejor que la máxima, calculamos dicha uniformidad para cada imagen “verde” con  $U_{G_k}$ , donde  $\Omega = \{G_k \mid k \equiv ExG, ExGR, CIVE, VEG\}$ , teniendo en cuenta en primer lugar que las uniformidades se normalizan en el intervalo  $[0, 1]$ . Obtenemos a partir de aquí los pesos asociados a cada imagen “verde” donde el peso máximo se corresponde con la uniformidad mínima. Estos pesos determinan la relevancia de cada una de las imágenes a fusionar.

$$U_{G_k} = 1 - U_{G_k} / \sum_{G_h \in \Omega} U_{G_h}; \quad w_{G_k} = U_{G_k} / \sum_{G_h \in \Omega} U_{G_h} \quad (3.37)$$

- 5) **Fusión de imágenes “verde”:** a partir de las cuatro imágenes disponibles, y sus respectivos pesos asociados, la fusión se lleva a cabo mediante el cómputo de la media ponderada de las imágenes con dichos pesos a través de la regla siguiente,

$$G = \sum_{\Omega} w_{G_k} G_k \quad (3.38)$$

- 6) **Umbral de la imagen:** las tonalidades de gris correspondientes a los verdes en la imagen fusionada,  $G$ , se ha acentuado en relación con las otras dos bandas espectrales. El próximo objetivo será aislar las partes verdes con el fin de aprovechar esta mejora

obtenida. Como se mencionó anteriormente, varios de los métodos de umbralización estudiados en la literatura se han aplicado para alcanzar este objetivo. Puesto que la idea es la automatización del proceso, buscamos un enfoque para la umbralización también de naturaleza automática. Uno de los posibles candidatos es el método de Otsu (1979), que ya se ha aplicado en el trabajo de Meyer y Camargo (2008). Este método se basa en la estima del mejor umbral a partir del histograma de intensidades, en este caso de los grises en la imagen  $G$ . Sin embargo, el método de Otsu tiende a producir una infra-segmentación, ya que proporciona un valor superior al valor medio del histograma. Esto hace que muchos de los píxeles verdes lleguen a ser descartados del proceso, perdiendo así una valiosa información sobre las texturas vegetales. Esta es la razón por la cual en la propuesta que formulamos proponemos la utilización de la media como umbral para la binarización en lugar del umbral proporcionado por Otsu. Las figuras 7(a) y (b) muestran el resultado de la binarización de la imagen  $G$  a partir de los umbrales de histograma mediante la media y Otsu, respectivamente. La figura 7 (c) muestra las diferencias entre ambas imágenes, 7(a) y 7(b), siendo los píxeles blancos los correspondientes a los verdes extraídos por la media y ocultos por Otsu. Calculamos el valor medio de  $z$  (media de los niveles de grises) mediante la ecuación (3.39).

7)


$$m = \sum_{i=0}^{L-1} z_i p(z_i) \quad (3.39)$$



(a)



(b)



(c)

**Figura 7.- (a)-(b) Imágenes binarias obtenidas mediante la aplicación del histograma de la media y Otsu, (c) las diferencias entre (a) y (b) donde los píxeles blancos corresponden a los verdes ocluidos por Otsu**

En las imágenes anteriores, los valores obtenidos para los umbrales dados por la media y por Otsu son 0,2496 y 0,2706, respectivamente, teniendo en cuenta el rango de valores de niveles de gris en el intervalo  $[0,1]$ . Este comportamiento, es general para el conjunto de imágenes utilizadas, tal y como se ha indicado previamente.

Por último, aplicando la binarización por la media obtenemos la imagen binaria  $G_b$  donde los píxeles asociados con la vegetación se etiquetan con un valor binario de uno en contraposición al resto cuyo valor binario es cero.

- 8) **Detección de los azules:** partiendo del índice cromático  $ExB$  el objetivo es obtener una imagen binarizada de los azules. Como se explica más adelante en la siguiente sección, hay que tener en cuenta si las imágenes tienen o no cielo en la parte superior, puesto que los valores de azul se ven afectados y esto puede cambiar las decisiones tomadas con respecto al suelo o a los verdes. Por lo tanto, el objetivo es separar sólo las zonas con alto contenido de azul, lo cual se logra mediante el enfoque de la umbralización de Otsu por las razones anteriormente expuestas. En la figura 8, podemos ver el resultado de esta binarización. De hecho, en la parte (a) la imagen que se muestra es la obtenida mediante el índice cromático  $ExB$ ; y tanto en (b) como en (c) se muestran las imágenes binarias obtenidas mediante la aplicación de la media y el método de Otsu. Como se puede ver, en la figura 8(b) una parte importante de suelo tiene la etiqueta de color azul lo que no ocurre en 8(c), tal y como se esperaba. Este es un comportamiento común que se observa en el conjunto de imágenes analizadas.



(a)



(b)



(c)

Figura 8.- (a)  $ExB$  imagen obtenida con la ecuación (3.32); (b) (c) imágenes binarias de la imagen de (a) obtenidas mediante la aplicación de la media y Otsu respectivamente

- 9) **Detección de los rojos:** aplicando el índice cromático  $ExR$  obtenemos la imagen binarizada del suelo. Al contrario que con el azul, ahora el objetivo es extraer el rojo, el cual está íntimamente relacionado con el suelo por tener éste una tendencia cromática dominante hacia el rojo, por lo tanto, ya que el suelo es una parte relevante en los campos de cultivo, ahora tratamos de conservar el mayor número de los píxeles que son candidatos potenciales para el suelo. Esta detección es muy parecida al procedimiento realizado para la vegetación, por lo que aquí de nuevo se aplica la media como el mejor valor umbral para la binarización. En la figura 9(a) se muestra la imagen obtenida a partir de  $ExR$  y en la figura 9(b) la imagen binaria mediante la aplicación del criterio ya establecido.



(a)



(b)



(c)

Figura 9.- (a) *ExR* imagen obtenida de la ecuación (3.31); (b) imagen binaria obtenida aplicando el criterio de la media; (c) diferencias entre las imágenes binarias dadas en la figura 8(b) y 9(b)

### 3.3.3. Clasificación mediante agrupamiento borroso

El próximo objetivo es la identificación de las diferentes clases de verde y también diferentes clases de texturas pertenecientes al suelo.

Tanto con el azul como con el rojo surge un problema importante que hace necesario aislar los píxeles identificados como pertenecientes al suelo. Para solucionarlo, clasificamos los tipos de imágenes en dos grupos, aquellas que no tienen componente cielo y aquellas imágenes que sí lo poseen, tal y como se representa en las figuras 3 y 4. Si extraemos los azules y rojos del segundo tipo de imágenes, obtenemos una clara separación entre las componentes del cielo y el suelo, como se ve representado en las figuras 8(b) y 9(b) respectivamente. Pero si el azul y rojo se extraen para el primer tipo de imágenes nos encontramos con una importante cantidad de solapamiento entre ambos colores. Esto se puede observar en las imágenes de las figuras 10(a) y (b). Si calculamos la diferencia entre las imágenes binarias obtenidas a partir de los índices *ExB* y *ExR* el resultado de las imágenes sin cielo se muestra en la figura 10(c), donde podemos observar que la proporción de píxeles blancos es insignificante en comparación con la imagen completa.

Por el contrario, si las imágenes contienen cielo, la diferencia entre las imágenes binarias obtenidas a partir de los índices  $ExB$  y  $ExR$  genera la imagen que aparece en la figura 9(c), donde se puede observar que la relación entre los píxeles blancos en comparación con toda la imagen es bastante elevada. En base a este estudio, se calcula un factor de proporción según la siguiente relación,

$$r = \frac{N_w}{N_T} \quad (3.40)$$


donde  $N_w$  es el número de píxeles con valores comprendidos entre  $+1$  o  $-1$  en la imagen  $Y$  obtenida como la diferencia entre las imágenes binarias de  $ExR$  y  $ExB$ ;  $N_T$  es el número total de píxeles de la imagen. Por último, con el fin de aislar los píxeles que se consideran como pertenecientes al suelo se aplica la siguiente regla de decisión:

$$\begin{aligned} & \text{if } r < T \text{ then} \\ & \quad S_b = ExR_b \wedge \neg ExG_b \\ & \text{else} \\ & \quad S_b = ExR_b \wedge \neg ExG_b \wedge \neg ExB_b \end{aligned} \quad (3.41)$$


donde el subíndice  $b$  representa la imagen binaria y los símbolos  $\wedge$  y  $\neg$  son las operaciones lógicas *and* y *not* sobre las imágenes binarias;  $S_b$  es la imagen binaria final que contiene los píxeles del suelo etiquetados como uno (blanco), y por último  $T$  es un umbral inicializado a 0.6, valor obtenido mediante diversos experimentos de ensayo y error con el conjunto de imágenes existentes.



(a)



(b)



(c)

**Figura 10.- Imágenes binarias obtenidas desde la imagen original de la figura 3 (a) ExB; (b) ExR; (c) diferencia entre la binarización de imágenes ExB y ExR**

Por lo tanto, tenemos disponibles dos imágenes binarias principales,  $G_b$  y  $S_b$  que representan los grados de verde y de rojo en las imágenes originales, respectivamente. Con base a estas dos imágenes extraemos dos conjuntos de muestras de la imagen original identificándolas como  $X_G$  y  $X_S$ . El primer conjunto,  $X_G$ , contiene muestras representativas de los píxeles de la imagen original que han sido identificados como píxeles verdes en la imagen  $G_b$  y el segundo contiene los píxeles que representan al suelo. Sin pérdida de generalidad, representamos los dos conjuntos denominándolos  $X$ , con  $n$  muestras de entrenamiento, es decir,  $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\} \in \mathfrak{R}^d$ , donde  $d$  es la dimensionalidad de los datos. Cada muestra se va a asignar a una clase determinada  $w_j$ , donde el número de clases es  $c$ , con,  $j = 1, 2, \dots, c$ . Cada nueva muestra identificada por el vector  $\mathbf{x}_i$  representa un píxel de la imagen, donde sus componentes son las componentes RGB de ese píxel en la ubicación de la imagen  $(x, y)$  dada por  $G_b$  y  $S_b$ , por lo que en nuestros experimentos la dimensionalidad de los datos es  $d = 3$ .

Este proceso recibe las muestras de entrada  $\mathbf{x}_i$  para el entrenamiento y establece una partición, suponiendo que el número de clases  $c$  es conocido. El proceso calcula para cada muestra  $\mathbf{x}_i$  en cada iteración  $t$ , su grado de pertenencia a la agrupación  $w_j$  ( $\mu_i^j$ ) y actualiza los centros de los clústers de la siguiente manera (Zimmermann, 1991):

$$\mu_i^j(t+1) = \frac{1}{\sum_{r=1}^c (d_{ij}(t)/d_{ir}(t))^{2/(b-1)}}; \mathbf{v}_j(t+1) = \frac{\sum_{i=1}^n [\mu_i^j(t)]^b \mathbf{x}_i}{\sum_{i=1}^n [\mu_i^j(t)]^b} \quad (3.42)$$

siendo  $d_{ij}^2 \equiv d^2(\mathbf{x}_i, \mathbf{v}_j)$  la distancia Euclídea al cuadrado. El número  $b$  es el peso exponencial (Bezdek, 1981; Duda y col., 2000),  $b > 1$ . El criterio de parada viene determinado por  $\|\mu_i^j(t+1) - \mu_i^j(t)\| < \varepsilon \forall ij$  o por un número máximo de iteraciones  $t_{max}$ .

El método requiere la inicialización de los centros de los clusters, de modo que la ecuación (3.42) se puede aplicar en la iteración  $t = 1$ . Para ello, aplicamos el procedimiento descrito en Balasko y col. (2010):

- 1) **Realizar una transformación lineal**  $Y = f(X)$  de la muestra de entrenamiento para que los valores varíen en el intervalo  $[0,1]$ .
- 2) **Inicializar**  $\mathbf{v} = 2D\bar{\mathbf{M}} \circ \mathbf{R} + D\bar{\mathbf{m}}$ , donde  $\bar{\mathbf{m}}$  es el vector de medias para las muestras de entrenamiento en  $Y$ ;  $\bar{\mathbf{M}} = \max(\text{abs}(Y - \bar{\mathbf{m}}))$ , con tamaño  $1 \times d$ ;  $D = [1 \dots 1]^T$  con tamaño  $c \times 1$ ;  $\mathbf{R}$  es una matriz aleatoria de tamaño  $c \times d$  con valores entre  $[0,1]$  y la operación  $\circ$  representa la multiplicación elemento por elemento.
- 3) **Proceso de fusión**: una vez que la clasificación se ha realizado mediante el clasificador basado en el agrupamiento borroso, tendremos la partición de las muestras de entrada y asociados para cada clase  $w_j$  un centro  $\mathbf{v}_j$ . Consideramos como una sola clase, dos clases que estén lo suficientemente próximas entre sí. El criterio para fusionar las clases se establece en base a la proximidad de los centros, por lo que dados dos centros  $\mathbf{v}_i$  y  $\mathbf{v}_j$  representantes de sus respectivas clases, éstas se fusionarán si  $d(\mathbf{v}_i, \mathbf{v}_j) < t_1$ ; donde  $d$  es la distancia Euclídea y  $t_1$  es un umbral fijado en el 20% de la máxima distancia posible entre las muestras dentro de la clase, es decir, los valores de los píxeles van desde (0,0,0) (negro) a (1,1,1) (blanco) en el espacio de color RGB y su distancia máxima es la longitud de la diagonal principal en el cubo que representa este espacio. Cuando dos clases se fusionan, se calcula su centro para la nueva clase como la media entre todas las muestras pertenecientes a las dos clases que se han fusionado.

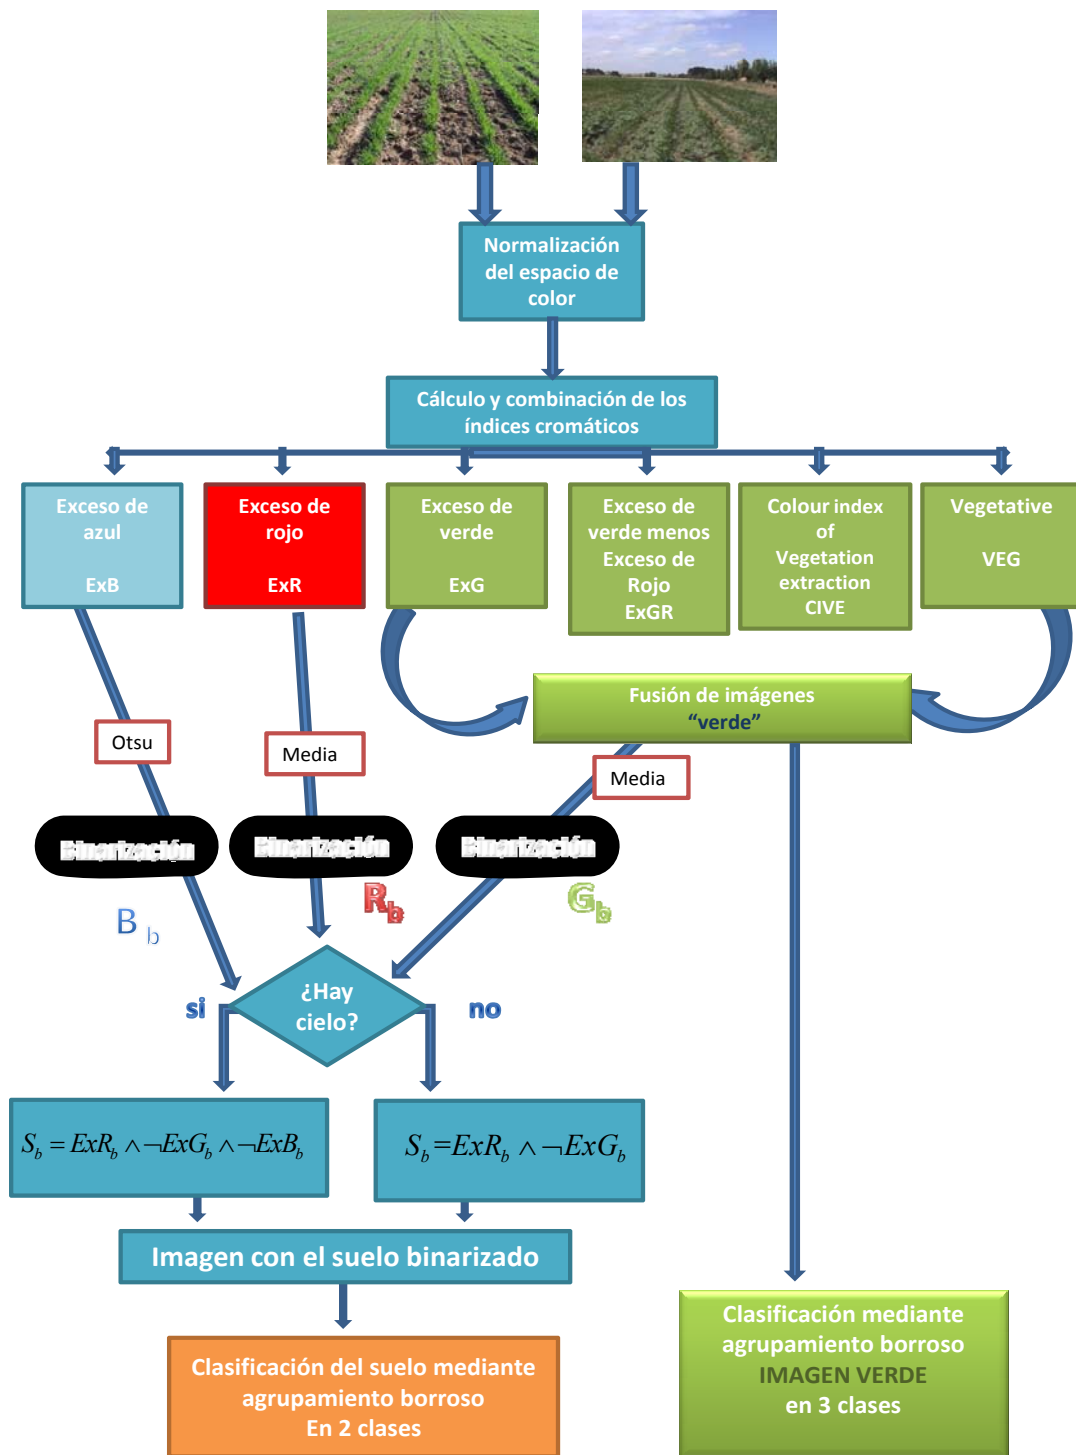


Figura 11.- Esquema de los pasos seguidos en nuestra investigación

# Capítulo 4

## 4. Análisis de resultados

### 4.1. Introducción

Una vez establecidas las distintas estrategias que hemos seguido para la resolución del problema planteado en nuestra investigación, en este capítulo se hace el correspondiente análisis de valoración de las mismas. El objetivo principal de nuestro trabajo es la identificación automática de texturas en campos de cultivo de maíz y cereal, más concretamente la identificación de la parte vegetal y la parte del suelo, donde a su vez cada una de ellas puede de nuevo reclasificarse para encontrar otros niveles de textura más finos.

Como hemos comentado previamente, nuestro trabajo de investigación ha tenido dos fases.

Una primera fase en la cual no se han podido clasificar de forma automática las imágenes de un campo cultivado, ya que no ha sido factible encontrar el mejor número de clases posibles para las imágenes dadas y sobre las que por supuesto no se conoce el número de clases existentes en ellas. Los pasos seguidos para alcanzar este objetivo han sido los que se exponen seguidamente, utilizando las bases de datos de la sección 4.2 para llegar a los resultados de la sección 4.3

1. Encontrar índices de validación de particiones internos, para así poder automatizar los algoritmos de clasificación. Como no existen resultados en la literatura con respecto a su comportamiento en imágenes, comprobamos cuál es el mejor con un conjunto de bases de datos publicadas Asuncion y Newman (2010). En este punto no se llegó a resultados convincentes, no obstante en el siguiente paso utilizamos los mismos índices sin descartar ninguno.
2. Creamos una base de datos de imágenes sintéticas y comprobamos el comportamiento de los mismos índices, tampoco fue posible concluir con resultados concretos.
3. Finalmente, probamos con imágenes reales, elaborando las mismas también de forma sintética y procurando que contengan un número de clases fácilmente

identificables. De nuevo, los resultados fueron negativos, por lo que al no poder determinar la bondad de las particiones realizadas decidimos entrar en una segunda fase, es decir, replantearnos como solucionar nuestro problema por otro camino.

En esta segunda fase, los resultados han sido bien distintos ya que se han obtenido resultados concluyentes, que aportamos a este trabajo de investigación. En principio nos centramos en los trabajos que utilizan imágenes de cultivos y tenemos en cuenta que nuestras imágenes están representadas en el espacio de color RGB. Los pasos seguidos aquí son los explicados en la sección 3.3.2, aplicados sobre el conjunto de imágenes descritas en la sección 4.4 y con los resultados de la sección 4.5.

## 4.2. Descripción de las bases de datos utilizadas

Se dispone de un conjunto de bases de datos descargadas de la web durante el mes de Noviembre de 2009 procedentes del repositorio *UCI, Learning Machine Repository* (Asunción y Newman, 2010). Se trata de bases de datos numéricas cuya dimensión varía en función del número de atributos que presente cada conjunto de muestras. En la tabla 1 se describen en su conjunto.

#	Categorías de datos	A	c	n	Descripción
1	Breast Cancer Wisconsin	12	2	569	Las características son computerizadas de imágenes digitales con el FNA (fine needle aspirate) de la masa mamaria. Describen las características del núcleo de la célula presentado en la imagen.
2	Bupa liver disorders	6	2	345	BUPA Medical Research Ltd.: resultados de análisis de sangre, cuya presencia parece que sean los causantes de desórdenes en el funcionamiento del hígado.
3	Australian	15	2	6650	Sirve para aplicaciones de tarjetas de crédito. Es interesante porque mezcla atributos con valores pequeños y grandes. Todos los valores reales se han cambiado por símbolos por seguridad.

#	Categorías de datos	A	c	n	Descripción
4	Ozone	73	2	2536	Es una colección de muestras ordenadas cronológicamente para establecer mediante sus atributos si un día es normal o es propenso a elevados índices de ozono.
5	Pima Indians	8	2	768	National Institute of Diabetes and Digestive and Kidney Diseases (V. Sigillito): parámetros de herencia en la tribu India Pima.
6	Ionosphere	34	2	351	Sistema cuyo objetivo es recoger la estructura en la ionosfera mediante antenas de alta frecuencia. La señal atraviesa esta capa y el radar devuelve la calidad de la estructura.
7	Heart SpectF	44	2	267	Diagnóstico cardíaco por imágenes. Cada paciente es clasificado en las categorías normal o anormal.
8	Heart	13	2	270	Mediante los atributos de cada muestra (cada pacientes) se determina si son propensos a tener una enfermedad cardíaca.
9	Sonar	60	2	208	Cada atributo representa la energía en una banda de frecuencia tomada en distintos ángulos en un periodo de tiempo, y clasifica objetos como rocas y metálicos.
10	Survival	3	2	306	El conjunto de datos es de un estudio de pacientes que entre 1958 y 1970 sobrevivieron a operaciones de cáncer de pecho.
11	Hepatitis	19	2	155	Utiliza atributos como características de los pacientes, y en función de los valores determinan si tienen hepatitis.
12	Iris	4	3	150	R.A. Fisher & M. Marshall: diferentes clases de lirios (plantas).
13	Wine	13	3	178	Forina, M. y col, PARVUS & S. Aeberhard: análisis químicos de distintas clases de vinos.
14	Ann Thyroid	21	3	3428	El problema es determinar si un paciente es hipotiroideo.

#	Categorías de datos	A	c	n	Descripción
15	New Thyroid	5	3	215	Los test realizados sirven para intentar predecir si los pacientes tienen tiroides, distinguiendo entre tres tipos.
16	Waveform Noise	20	3	825	Son valores numéricos que evalúan el tipo de ondas.
17	Balance Scale	4	3	625	Utilizada para el modelado de resultados psicológicos, pudiendo indicar el balanceo de las muestras o su equilibrio.
18	Vehicle	18	4	946	Turing Institute, Glasgow, Scotland. Clasificación de vehículos por medio de su silueta, para lo que se ofrecen distintos ángulos para cada muestra.
19	Lymphography	18	4	148	University Medical Centre, Institute of Oncology, Ljubljana, Yugoslavia. Gracias a M. Zwitter y M. Soklic por suministrar esta base de datos. Usado para diagnóstico de tratamientos.
20	Glass	10	6	214	B. German, V. Spiehler from Central Research Establishment & Diagnostic Products Corporation: diferentes propiedades de cristales.
21	Satimage	36	6	432	Department of Statistics and Data Modelin, University of Strathclyde, Glasgow. Utiliza imágenes digitales de una misma escena con distintos espectros.
22	Shuttle	9	7	1934	La NASA ha permitido el uso de esta base de datos numérica, que está ordenada según fue extraída aunque una parte del total de los datos ha sido eliminada para la validación.

Tabla 1: Descripción detallada de las bases de datos numéricas utilizadas

### 4.3. Elección de los índices de calidad

Los índices internos utilizados para la validación del número de clases son los enumerados a continuación y descritos en la sección 3.2.2: Davies-Bouldin, Dunn, Shilhouette, Separation, Calisnski-Harabasz y Homogeneity.

En las bases de datos mencionadas se conoce tanto el número de clases como la distribución de los datos en las clases. Esto permite comprobar el comportamiento de los mencionados índices sobre los datos anteriores. La figura 12 muestra el porcentaje de acierto (eje vertical) para todas las clases analizadas y para cada uno de los índices. Como puede fácilmente deducirse, para todos ellos, el porcentaje de acierto se sitúa por debajo del 50%, lo cual a todas luces representa unos resultados ciertamente poco convincentes.





Figura 12.- Porcentaje de acierto en el número de clases sobre las bases de datos utilizadas

A pesar de los resultados negativos obtenidos previamente, el siguiente paso consiste en verificar el comportamiento de los mencionados índices sobre imágenes, con el fin de comprobar su comportamiento con este nuevo tipo de datos. Para controlar el proceso, de forma que se puedan conocer tanto el número de clases como la distribución de los píxeles en las mismas, se crean imágenes de dos tipos, unas sintéticas y otras reales procedentes de los campos de cultivo objeto de estudio. Las sintéticas a su vez son de dos tipos, unas puras y un segundo grupo que contienen mezcla de reales y sintéticas, como se pueden ver en la figura 13, donde la imagen *a* es sintética pura, la *b*) mezcla de sintética y real y la *c* real

pura. Se han utilizado veinte imágenes diferentes de cada tipo, haciendo un total de sesenta.



**Figura 13.- a) imagen sintética pura b) imagen sintética mezcla c) Imagen real**

Realizamos la clasificación con los algoritmos MeanShift y LVQ, según la figura 1 y 2 respectivamente, propuestos en la sección 3.2, y se utilizan los seis índices de validación de las particiones anteriormente reseñados. No ha sido posible automatizar el proceso dado el dispar comportamiento de los índices. Dado el fracaso del método hemos obviado la inclusión exhaustiva de datos, si bien cabe exponer las siguientes consideraciones ya que los resultados varían según el tipo de imágenes,

- Con las imágenes sintéticas puras, todos los índices tenían un comportamiento adecuado en cuanto que identifican correctamente el número de clases.
- Con las imágenes sintéticas mezcladas, cabe hacer la siguiente distinción,
  - Calinski-Harabasz y Homogeneity, dan en promedio cinco clases más de las realmente existentes
  - Davies-Bouldin, Dunn y Shilhoutte, indican todos una clase menos de las esperadas
  - Separation, siempre da al menos 2 clases menos de las esperadas.
- Con las imágenes reales de campos de cultivo, según el tipo de imágenes: sólo suelo, vegetación y cielo, distintos tipos de iluminación, dan unos resultados bien diferentes a los esperados sin poder concluir nada al respecto ya que incluso en imágenes similares los resultados son totalmente diferentes, de suerte que unas veces se obtienen muy pocas clases y en ocasiones un número elevado muy superior al esperado.

Es a partir de este punto cuando se abandona la investigación en esta línea para continuar con la apertura de la propuesta formulada en la segunda opción de la sección 3.3.2.

#### **4.4. Imágenes reales de campos de cultivo**

Las imágenes utilizadas para este trabajo pertenecen a dos tipos de cultivos de cereales y maíz. El primer grupo de imágenes han sido capturadas con una cámara Sony DCR PC110E durante el mes de abril de 2005 en un campo experimental de 1,7 hectáreas de cebada en La Estación de Investigación de Poveda, Arganda del Rey, Madrid. El segundo grupo de imágenes han sido adquiridas con una cámara digital, HPR817, durante cuatro días diferentes en los meses de abril y mayo de 2007. Estas capturas de imágenes fueron tomadas dejando cinco o seis días entre toma y toma para que fueran obtenidas bajo diferentes condiciones de iluminación y diferentes estados de desarrollo de los cultivos, esto es de la parte vegetal. Las imágenes digitales se han almacenado en el formato de color de 24 bits y con resoluciones de  $1152 \times 864$  píxeles y  $800 \times 600$ , respectivamente, guardándolas en el modelo de color RGB (rojo, verde y azul) y en formato JPG. Las imágenes han sido procesadas con el toolbox Image Processing de Matlab R2009a (The MathWorks) específico para tratamiento de imágenes. El conjunto de imágenes que finalmente se ha procesado está formado por 240 imágenes.

Volviendo sobre la figura 3, ésta representa una de las imágenes originales que pertenece a un campo de cebada (primer tipo), donde sólo el suelo es capturado bajo una alta calidad de iluminación. También las figuras 4 y 5 pertenecen a un campo de maíz (segundo tipo), donde tanto el suelo como el cielo son capturados bajo diferentes condiciones de iluminación (alto y bajo de contraste), siendo en este caso la figura 5 tomada al atardecer, es decir, con poca iluminación.

## 4.5. Resultados con los índices cromáticos

La estrategia propuesta consta de dos partes principales, a saber: a) extracción de los verdes, rojos y azules, b) identificación de los diferentes tipos de verdes y rojos.

La extracción del verdor se basa en un nuevo procedimiento, que combina la información proporcionada por los resultados procedentes de los índices cromáticos: *ExG*, *ExGR*, *CIVE* y *VEG*. Estos índices, en realidad, de forma individual proporcionan sus propios resultados de segmentación. Cuando se apliquen de forma individual nos referiremos a ellos como métodos simples de forma genérica.

Por tanto, las pruebas para verificar el comportamiento de la propuesta formulada se realizan comparando las soluciones proporcionadas por los métodos simples con la fusión de los propios índices. Esto se lleva a cabo utilizando un conjunto de imágenes de referencia o “ground truth”, que es como técnicamente se les conoce en la terminología especializada. Este conjunto está formado por imágenes ya clasificadas y binarizadas según el objeto a clasificar. Para la elaboración de las mismas procedemos como sigue. Como en nuestro caso lo que buscamos clasificar son los diferentes verdes de la imagen, lo primero que se hace es extraer de la imagen original, representada en el espacio de color RGB, todos los píxeles donde la componente verde es mayor que las restantes al menos en un valor del 10%. Esto nos permite obtener una parte importante de las plantas verdes, que son etiquetadas con un uno lógico, esto es en blanco. Seguidamente se extraen aquellos píxeles donde el rojo y el azul sean dominantes también al menos en otra cantidad representada por el 10%, etiquetándose en este caso con el valor uno lógico, esto es en negro. El tercer paso consiste en refinar y clasificar de forma manual, bajo el asesoramiento de un experto aquellos píxeles que aún no hayan sido etiquetados correctamente, comparándolos con la imagen original. La figura 14 es una de las imágenes del conjunto “ground truth” obtenida a partir de la imagen original mostrada en la figura 3 siguiendo el procedimiento anteriormente descrito.




Figura 14.- Ground truth

Hemos utilizado en nuestros experimentos 240 imágenes originales adquiridas del modo descrito en la sección 4.4, donde 190 son imágenes que contienen cielo y las demás, es decir, 50, no lo contienen. Aproximadamente, el 10% de cada grupo fueron adquiridas en condiciones de escasa iluminación. Hemos construido el “ground truth” a partir de 60 imágenes del conjunto que contienen cielo y 15 sin cielo, en ambos casos bajo diferentes condiciones de iluminación.

La tabla 2 muestra el porcentaje medio de error sobre el número de imágenes comparadas con el conjunto “ground truth” para *ExG*, *ExGR*, *CIVE* y *VEG* de forma individualizada y comparándolo con nuestro enfoque que combina los índices anteriores (*COM*).

Tabla 2.- Porcentaje de error medio comparándolo con el conjunto de imágenes del “ground truth”


	<i>ExG</i>	<i>ExGR</i>	<i>CIVE</i>	<i>VEG</i>	<i>COM</i>
% de error para los verdes	11.19	10.71	10.37	18.23	<b>8,31</b>

Para cada imagen fusionada se obtienen cuatro pesos a través de la ecuación (3.37), que se aplican en la ecuación (3.38) para calcular el resultado de la combinación de los índices cromáticos que extraen el verde. La media de los valores para el conjunto de las 240 imágenes son:  $w_{G_{ExG}} = 0.25$ ,  $w_{G_{ExGR}} = 0.30$ ,  $w_{G_{CIVE}} = 0.33$  y  $w_{G_{VEG}} = 0.12$ . Como podemos ver, existe una especie de relación directa entre el peso promediado y el porcentaje de error que se muestra en la tabla 2, obtenidos para los cuatro métodos utilizados para calcular el verdor según nuestro enfoque. A partir de los mismos se deduce que el método más relevante resulta ser *CIVE*, ya que su contribución a la imagen fusionada ha sido en promedio de 33%. El menos relevante ha sido *VEG* con el 12%. Probablemente, esto sea

debido al parámetro  $a$ , que participa en la ecuación (3.35), aunque bien es cierto que tras diversos experimentos, no hemos encontrado una clara relación entre este comportamiento y su influencia.

En las imágenes que contienen cielo, el valor de umbral de Otsu es, en promedio, un 16% superior al valor de la media utilizada como umbral y en las imágenes sin cielo, disminuye hasta el 12%. Esto hace que si utilizáramos el umbral de Otsu, en lugar de la media, al ser superior, consideraríamos muchos píxeles que son verdes como si no lo fueran, aumentando el porcentaje de error aproximadamente un 5% en relación al alcanzado con nuestra propuesta COM.

En las figuras 15(a) y 15(b) se muestran los resultados obtenidos tras aplicar el clasificador del *agrupamiento borroso* a la imagen de la figura 4. El número de clases utilizado para este clasificador se fijó inicialmente en  $c = 3$ . En (a) podemos ver los resultados obtenidos para la clasificación de las plantas verdes, donde podemos observar la distinción entre tres clases de plantas, etiquetadas en tres colores diferentes. De hecho, desde el punto de vista de un observador humano, es fácil deducir que existen tres clases, donde una de ellas está asociada a una tonalidad verde oscuro que pertenece a los árboles y las sombras en los surcos. Las otras dos corresponden a dos tonalidades diferentes en las plantas. Por el contrario, en (b) el proceso de clasificación se ha llevado a cabo con el fin de obtener las dos clases mostradas.



**Figura 15.- Clasificación de imagen para la figura 4: (a) Tres tipos diferentes de clases de plantas verdes; (b) 2 clases diferentes de suelo**

Como antes, la figuras 16 (a) y (b) muestran los resultados obtenidos después de aplicar el clasificador del *agrupamiento borroso* a la imagen original de la figura 1 con  $c = 2$  en

imágenes sin cielo. En (a) vemos los resultados obtenidos para las plantas verdes, donde la clasificación en este caso se ha realizado con las dos clases previstas. Y en (b) vemos los resultados de haber clasificado las zonas de suelo, también en dos clases.



**Figura 16.- Resultados de la clasificación de la imagen de la figura 3: (a) 2 clases distintas de plantas verdes; (b) 2 clases diferentes de suelo**



## 5. Conclusiones y trabajo futuro

### 5.1. Introducción

En este capítulo se hace necesario plantear un balance global sobre las líneas de investigación seguidas, que desembocan en las conclusiones expuestas. Por otra parte, se abren una serie de perspectivas de futuro en relación con los temas de investigación abordados y sus posibilidades de ampliación futuras.

### 5.2. Conclusiones

En una primera fase se optó por el diseño de una estrategia automática basada en la clasificación de las texturas mediante clasificadores controlados por parámetro y determinando la validez de las clasificaciones por medio de seis índices de validación. No se llegó a resultados convincentes, originando el cambio de rumbo en la investigación, llegando en este caso a formular una propuesta basada en la fusión de los resultados obtenidos mediante la utilización de los denominados índices cromáticos junto con la utilización del clasificador basado en el agrupamiento borroso. En este caso, los resultados son realmente satisfactorios.

Por otra parte, puede considerarse suficientemente cumplidos los objetivos enumerados en el capítulo 1 tal y como se expresa a continuación,

- Seleccionar el método o métodos de segmentación de entre los más prometedores o apropiados que se hayan estudiado. En este caso disponemos de los métodos basados en los índices cromáticos.
- Seleccionar las bases de datos que constituirán los conjuntos de entrenamiento y de clasificación. Se han realizado pruebas sobre el conjunto de datos descritos en el capítulo cuatro.
- Seleccionar las imágenes que constituirán los conjuntos de clasificación. En este caso imágenes reales sobre campos de cultivo.

- Identificar una posible mejora de los métodos existentes o dar una solución a la problemática de la clasificación de imágenes de campos cultivados. En este caso, se ha formulado una propuesta basada en la fusión de índices cromáticos, junto con un mecanismo de identificación de las diferentes texturas de interés y además de forma automática.
- Implementar la mejora propuesta con el fin de analizar su comportamiento en base a los resultados obtenidos.
- Identificar líneas de investigación futuras.
- Difundir los resultados mediante publicaciones científicas u otro tipo de divulgación. En este caso se encuentra en proceso de revisión un artículo que recoge la propuesta formulada, habiendo sido enviado a la revista *Computers and Electronics in Agriculture* indexada en el *Journal Citation Report*.

### **5.3. Trabajo futuro**

La continuación del trabajo debe orientarse en varias líneas. Por un lado, se plantea la investigación de nuevos métodos de fusión específicos en el campo de la Visión por Computador, destacando los siguientes (Pajares y Cruz, 2007):

- Selección por máximos
- Selección por componentes principales
- Media ponderada general
- Media ponderada adaptativa
- Fusión basada en regiones por detección de características
- Eliminación del fondo
- Basada en la varianza

Mejoras de la clasificación de texturas mediante la combinación de clasificadores donde en otros contextos han demostrado su efectividad, como es el caso del método propuesto en Guijarro y Pajares para imágenes aéreas en Pajares y col, (2009), Guijarro y Pajares (2009) y Guijarro (2009). Finalmente, es necesario ampliar la investigación y comprobar la validación de la propuesta formulada para otros tipos de cultivos tales como arroz o leguminosas, donde las condiciones de las plantas varían.

## 6. Bibliografía

1. Asuncion, A. and Newman, D.J. (2010). UCI Machine Learning Repository. Irvine, CA: University of California, School of Information and Computer Science, available on-line <http://www.ics.uci.edu/~mllearn/MLRepository.html>.
2. Balasko, B., Abonyi, J. and Feil, B. (2006). Fuzzy Clustering and Data Analysis Toolbox for Use with Matlab, Veszprem University, Hungary
3. URL:<http://www.fmt.vein.hu/softcomp/fclusttoolbox/FuzzyClusteringToolbox.pdf>
4. Bezdek, J.C. (1981). Pattern Recognition with Fuzzy Objective Function Algorithms. Kluwer, Plenum Press, New York
5. Burgos-Artizzu, X.P., Ribeiro, A., Tellaeché, A., Pajares, G., Fernández-Quintanilla, C. (2009). Improving weed pressure assessment using digital images from an experience-based reasoning approach. *Computers and Electronics in Agriculture*, 65, 176-185.
6. Calinski and Harabasz, 1974. Calinski, T. and Harabasz, J. 1974. A Dendrite Method for Cluster Analysis. *Communications in Statistics* 3:1–27.
7. Comaniciu, D. and Meer, P. (1997). Robust analysis of feature spaces: color image segmentation. In Proc. IEEE Conf. Computer Vision and Pattern Recognition, San Juan, PR, 750-755.
8. Comaniciu, D. and Meer, P. (2002). Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 24 (2002), 603–619.
9. Chan, J.C.W., Laporte, N. and Defries, R.S. (2003). Texture Classification of logged forest in tropical Africa using machine-learning algorithms. *Int. J. Remote Sensing*, 24(6), 1401-1407.
10. Cheng, H.D., Jiang, X.H., Sun, Y. and Wang, J., (2001). Color image segmentation: advances and prospects. *Pattern Recognition* 34 (12), 2259–2281.
11. Chen, G., Jaradat, S. A., Banerjee, N., Tanaka, T. S., Ko, M. S. H., & Zhang, M. Q. (2002) Evaluation and Comparison of Clustering Algorithms in Analyzing ES Cell Gene Expression Data. *Statistica Sinica*, 12: 241-262.
12. CVAP:Cluster Validity Analysis Platform. Kaijun Wang. 12 abril 2007. (Actualizado 25 julio 2009)
13. Davies, G., Casady, W., Massey, R., 1998. Precision agriculture: an introduction. Water Quality Focus Guide (WQ450, available on-line <http://extension.missouri.edu/explorepdf/envqual/wq0450.pdf>).
14. Davies & Bouldin, 1979. Davies, D.L., Bouldin, D.W., (2000) A cluster separation measure. *IEEE Trans. Pattern Anal. Machine Intell.*, 1(4), 224-227.
15. Duda, R.O., Hart, P.E. & Stork, D.S. (2000). *Pattern Classification*, Wiley.
16. Duda, R.O., Hart, P.E. and Stork, D.S. (2001). *Pattern Classification*. New York: Wiley & Sons.

17. Dunn, 1974. Dunn, J. (1974) Well separated clusters and optimal fuzzy partitions. *Journal of Cybernetics* ,4, 95-104.
18. Earl, R.; Wheeler, P.N.; Blackmore, B.S. y Godwin, R.J. (1996). Precision Farming: The management of variability. *Landwards*, 51(4), pp. 18–23.
19. Frate, F. Del, Pacifici, F., Schiavon, G. and Solimini, C. (2007). Use of Neural Networks for Automatic Classification from High-Resolution Images. *IEEE Trans. Geoscience and Remote Sensing*, 45(4), 800- 809.
20. Gebhardt, S., Schellberg, J., Lock, R. Kauhbauch, W.A. 2006. Identification of broad-leaved dock (*Rumex obtusifolius* L.) on grassland by means of digital image processing. *Precision Agriculture*, 7 (3), 165–178.
21. Gebhardt, S., Kauhbauch, W.A. 2007. A new algorithm for automatic *Rumex obtusifolius* detection in digital image using colour and texture features and the influence of image resolution. *Precision Agriculture*, 8(1), 1–13.
22. Gée, Ch., Bossu, J., Jones, G., Truchetet, F. 2008. Crop/weed discrimination in perspective agronomic images. *Computers and Electronics in Agriculture* 60, 49-59.
23. Giacinto, G., Roli, F. and Bruzzone, L. (2000). Combination of neural and statistical algorithms for supervised classification of remote-sensing image. *Pattern Recognition Letters*, 21(5), 385-397
24. Gonzalez, R.C., Woods, R.E. 2008. *Digital Image Processing*, Prentice-Hall, Upper Saddle River, NY.
25. Gonzalez, R.C., Woods, R.E., Eddins, S.L. 2004. *Digital Image Processing using Matlab*, Prentice-Hall, Upper Saddle River, NY.
26. Guijarro, M. and Pajares, G. (2009). On combining classifiers through a fuzzy multicriteria decision making approach: applied to natural textured images. *Expert Systems with Applications*, 36(3P2), 7262-7269.
27. Guijarro, M. (2009). *Combinación de clasificadores para identificación de texturas en imágenes naturales: nuevas estrategias locales y globales*. Tesis doctoral.
28. K. Fukunaga, *Introduction to Statistical Pattern Recognition*, Second Edition Computer Science and Scientific Computing Series. Academic Press, September 1990.
29. Kaufman, L. & Rousseeuw, P. J. (1990) *Finding Groups in Data: An Introduction to Cluster Analysis*. New York, John Wiley & Sons.
30. Hanmandlu, M., Madasu, V.K. and Vasikarla, S. (2004). A Fuzzy Approach to Texture Segmentation, in: *Proc. of the IEEE International Conference on Information Technology: Coding and Computing (ITCC'04)*, The Orleans, Las Vegas, Nevada, USA (636-642).
31. Hague, T., Tillet, N., Wheeler, H. 2006. Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture*, 1(1), 95–113.
32. Kataoka, T. et al., 2003. Crop growth estimation system using machine vision. In: *the 2003 IEEE/ASME Internat. Conf. on Advanced Intelligent Mechatronics*.
33. Kim, D.W., Lee, K.H. and Lee, D (2003). Fuzzy Cluster validation index based on inter-cluster proximity. *Pattern Recognition Letters*, 24 (2003) 2561-2574.

34. Kirk, K., Andersen, H.J., Thomsen, A.G., Jørgensen, J.R. 2009. Estimation of leaf area index in cereal crops using red-green images. *Biosystems Engineering*, 104, 308–317.
35. Kropff, M.J.; Wallinga, J. y Lotz, L.A.P. (1997). Modelling for precision weed management. En: *Precision Agriculture: spatial and temporal variability of environmental quality.*, pp. 182–204. Wiley, Chester.
36. Lim, Y.W. and Lee, S.U. (1990). On the color image segmentation algorithm based on the thresholding and the fuzzy c-means technique. *Pattern Recognition*, 23(9), 935-952.
37. Ling, P.P., Ruzhitsky, V.N., 1996. Machine vision techniques for measuring the canopy of tomato seedling. *Journal Agricultural Engineering Research*, 65 (2), 85–95.
38. Lusciér J D; Thompson W L; Wilson J M; Gorham B E; Dragut L D (2006). Using digital photographs and object-based image analysis to estimate percent ground cover in vegetation plots. *Frontiers in Ecology and the Environment*, 4(8), 408–413.
39. Meyer, G.E., Hindman, T.W., Lakshmi, K., 1998. *Machine Vision Detection Parameters for Plant Species Identification*. SPIE, Bellingham, WA.
40. Meyer, G.E., Camargo-Neto, J., Jones, D.D., Hindman, T.W. 2004. Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images. *Computers and Electronics in Agriculture* 42, 161-180.
41. Meyer, G.E., Camargo-Neto, J. 2008. Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture* 63, 282-293.
42. Mohaddamzadeh A. and Bourbakis, N. (1997). A fuzzy region growing approach for segmentation of color images. *Pattern Recognition*, 30(6), 867-881.
43. Neto, J.C., 2004. *A Combined Statistical–Soft Computing Approach for Classification and Mapping Weed Species in Minimum Tillage Systems*. University of Nebraska, Lincoln, NE.
44. 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.
45. Otsu, N. 1979. A threshold selection method from gray-level histogram. *IEEE Trans. System Man and Cybernetics* 9, 62-66.
46. Pajares, G. and Cruz, J. M. (2002). Clasificación de Texturas Naturales mediante K-Means, *Revista Electrónica de Visión por Computador* <http://revc.uab.es/revista/06/> ISSN 1575-5258), no. 6, 1-18, Ed. Centre de Visió per Computador, Universidad Autònoma Barcelona
47. Pajares, G., de la Cruz, J. M. and Moreno, V. (2002). Clasificación de texturas naturales mediante agrupamiento borroso. *Ingeniería Civil. Centro de Estudios y Experimentación de Obras Públicas (CEDEX).*- Ministerio de Fomento, 127, 83-89
48. Pajares, G. and Cruz, J.M. (2007a). *Visión por Computador: Imágenes Digitales y Aplicaciones*, RA-MA, Madrid.

49. Pajares, G., Guijarro, M., Herrera, P.J. and Ribeiro, A. (2009). Combining classifiers through fuzzy Cognitive Maps in natural images. IET Computer Vision (aceptado para publicación Mayo 2009).
50. Puig, D., and García, M.A. (2006). Automatic texture feature selection for image píxel classification. *Pattern Recognition*, 39 (11), 1996-2009.
51. Ribeiro A., Fernández-Quintanilla C., Barroso J., García-Alegre, M.C. 2005. Development of an image analysis system for estimation of weed. In Proc. 5th European Conf. On Precision Agriculture (5ECPA) 169–174.
52. Rousseeuw, 1987. Rousseeuw, P.J., (1987) Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53-65.
53. Ruiz-Ruiz, G., Gómez-Gil, J., Navas-Gracia, L.M. 2009. Testing different color spaces based on hue for the environmentally adaptive segmentation algorithm (EASA). *Computers and Electronics in Agriculture* 68, 88-96.
54. Sharan, R., Maron-Katz, A., & Shamir, R. (2003) CLICK and EXPANDER: A System for Clustering and Visualizing Gene Expression Data. *Bioinformatics*, 19: 1787-1799.
55. Shrestha, D.S., Steward, B.L., Birrell, S.J., 2004. Video processing for early stage maize plant detection. *Biosyst. Eng.* 89 (2), 119–129.
56. Tellaeche, A., Burgos-Artizzu, X. Pajares, G., Ribeiro, A. and Fernández-Quintanilla, C. (2008a). A new vision-based approach to differential spraying in precision agriculture. *Computers and Electronics in Agriculture*, vol. 60(2), 144-155.
57. Tellaeche, A., Burgos-Artizzu, X.P., Pajares, G. and Ribeiro, A. (2008b). A vision-based method for weeds identification through the Bayesian decision theory. *Pattern Recognition*, 41, 521-530.
58. TheMathworks (2010). <http://www.mathworks.com/>
59. Valdovinos, R.M., Sánchez, J.S. and Barandela, R. (2005). Dynamic and Static weighting in classifier fusion, in: J.S. Marques, N. Pérez de la Blanca and P. Pina (Eds.), *Pattern Recognition and Image Analysis, Lecture Notes in Computer Science*, Springer-Verlag, Berlin, 59-66.
60. D.M. et al., 1992. Lant species identification, size, and enumeration using machine vision techniques on near-binary images. *SPIE Opt. Agric., Forestry, Biological Process*. 1836, 208–219.
61. Woebbecke, D.M., Meyer, G.E., von Bargaen, K. and Mortensen, D.A. 1995. Shape features for identifying young weeds using image analysis. *Trans. Am. Soc. Agric. Eng.* 38 (1), 271–281.
62. Xia, Y., Feng, D., Wang, T., Zhao, R. and Zhang, Y. (2007). Image segmentation by clustering of spatial patterns. *Pattern Recognition Letters*, 28, 1548-1555.
63. Zheng, L.; Zhang, J. y Wang, Q. (2009). Mean-shift-based color segmentation of images containing green vegetation. *Computers and Electronics in Agriculture*, 65, pp. 93–98.

64. Zheng, L. Shi, D., Zhang, J., 2010, Segmentation of green vegetation of crop canopy images based on mean shift and Fisher linear discriminate. *Pattern Recognition Letters* (doi:10.1016/j.patrec.2010.01.016).
65. Zimmermann, H.J. (1991). *Fuzzy Set Theory and its Applications*. Kluwer Academic Publishers, Norwell.