

FUSIÓN DE IMÁGENES MEDIANTE WAVELETS PARA EXTRACCIÓN DE LAS PARTES VERDES EN IMÁGENES AGRÍCOLAS

PAULA YADRANKA ZITINSKI ELÍAS

MÁSTER EN INVESTIGACIÓN EN INFORMÁTICA, FACULTAD DE
INFORMÁTICA,
UNIVERSIDAD COMPLUTENSE DE MADRID



Trabajo Fin Máster en Sistemas Inteligentes

Julio, 2011

Directores:

Gonzalo Pajares Martinsanz
María Guijarro Mata-García

Convocatoria: junio 2011
Calificación: 10 (SOBRESALIENTE)

Autorización de Difusión

PAULA YADRANKA ZITINSKI ELÍAS

Junio 2011

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: “FUSIÓN DE IMÁGENES MEDIANTE WAVELETS PARA EXTRACCIÓN DE LAS PARTES VERDES EN IMÁGENES AGRÍCOLAS”, realizado durante el curso académico 2010-2011 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.

Resumen

En este trabajo se propone una estrategia de segmentación a partir de imágenes agrícolas de campos de cultivo con el fin de discriminar entre texturas vegetales, que contienen tanto cultivos como malas hierbas, y texturas procedentes del suelo que también aparecen en las imágenes.

Se propone una estrategia basada en la descomposición de wavelets con el fin de identificar con seguridad cuáles son las texturas vegetales. Esto se consigue mediante la descomposición por wavelets de la imagen original en cuatro bandas, donde tres de ellas contienen información de la parte vegetal en función de la alta variabilidad de intensidad que presentan dichas texturas. Esta información se utiliza para realzar la cuarta banda, que contiene información sobre las distintas tonalidades de las texturas. Previamente se aplican técnicas de extracción de índices vegetales, siendo éstos los que se resaltan mediante la estrategia basada en wavelets.

El correspondiente análisis de resultados muestra la eficacia de la estrategia propuesta frente a otros métodos de extracción de las mismas texturas vegetales.

Palabras clave

Segmentación de imágenes, wavelets, imágenes agrícolas, texturas vegetales, binarización, método de Otsu.

Abstract

In this paper we propose a segmentation strategy based on agricultural images in order to successfully distinguish between plant textures, which consist of both crop and weed, and textures from the soil that also appear in the images.

We propose a strategy based on wavelet decomposition to identify with certainty plant textures. This is achieved by doing a wavelet decomposition of the original image into four bands, where three of them contain information about the plants in terms of high variability in intensity shown in these textures. This information is used to enhance the fourth band, which contains information about the different hues of the textures. Previously, extraction techniques of green indexes are applied and their rates are highlighted by the strategy based on wavelets.

The corresponding analysis shows the effectiveness of the proposed strategy over other methods of extraction of the same plant textures.

Keywords

Image segmentation, wavelets, agricultural images, plant textures, binarization, Otsu's method.

Índice de contenidos

Autorización de Difusión.....	ii
Resumen.....	iii
Palabras clave.....	iii
Abstract.....	iv
Keywords.....	iv
Índice de contenidos.....	1
Agradecimientos.....	3
Capítulo 1 - Introducción.....	5
1.1 Identificación del problema.....	5
1.2 Estructura de la memoria.....	7
1.3. Objetivos.....	8
Capítulo 2 - Estado del arte.....	9
2.1 Introducción.....	9
2.2 Segmentación de verdes.....	10
2.3 Wavelets y fusión de imágenes.....	12
2.3.1 Familias wavelets.....	13
Capítulo 3 - Descripción y revisión del método basado en wavelets.....	15
3.1 Introducción.....	15
3.2 Segmentación de verdes.....	18
3.3 Transformada de wavelets.....	20
3.3.1 Familias de wavelets.....	22
3.4 Binarización de imágenes.....	24
3.4.1 Binarización mediante la media.....	25
3.4.2 Binarización mediante el método de umbralización de Otsu.....	27
3.4.3 Descomposición mediante wavelets.....	29
Capítulo 4 - Resultados y discusión.....	33
4.1. Introducción.....	33
4.2. Elección de los índices cromáticos y de la familia wavelets.....	34
4.3. Imágenes utilizadas.....	36

4.4. Resultados de la descomposición mediante wavelets.....	36
Capítulo 5 - Conclusiones y trabajo futuro.....	43
5.1 Introducción.....	43
5.2 Conclusiones.....	43
5.3 Trabajo futuro.....	45
Bibliografía.....	47

Agradecimientos

A María Guijarro y a Gonzalo Pajares, no solo por poder haber podido contar con su ayuda con toda facilitación de información y la considerable mejora que ha surgido como consecuencia de sus sugerencias, sino también por su franco apoyo a todas horas desde las primeras páginas. A Ángela Ribeiro Seijas y a Xavier Paolo Burgos Artizzu, investigadores del Centro de Automática y Robótica del Consejo Superior de Investigaciones Científicas por las imágenes proporcionadas con las que se ha podido llevar a cabo esta investigación.

Capítulo 1 - Introducción

1.1 Identificación del problema

Tradicionalmente existe la tendencia de aplicar pesticidas y herbicidas en los campos de cultivo. En los casos de aplicación automática de estos tratamientos la práctica consiste en esparcirlos por toda la superficie del campo, cosa no apropiada por varias razones. La primera cuestión es el impacto que estos tratamientos tienen sobre el medio ambiente, la atmósfera, el suelo y el subsuelo, en cualquier caso siempre dañino y contaminante. El segundo problema es el coste elevado que supone su aplicación a toda la superficie del campo, en lugar de limitarla exclusivamente a las zonas de malas hierbas como sería lo deseable. Si a esto se le añade el problema de la disminución constante de superficies agrícolas por motivos de hiperconstrucción y el coste creciente de la producción que esto conlleva, se puede, fácilmente, llegar a la conclusión de la importancia que tiene el ahorro y la eficiencia de una aplicación de pesticidas o herbicidas centrada exclusivamente en zonas de malas hierbas, que son realmente donde verdaderamente se necesitan.

En los últimos años, y con el desarrollo de nuevas tecnologías, especialmente en el campo de Inteligencia Artificial, nace el concepto de Agricultura de Precisión (AP), donde se introduce la idea de control selectivo de tratamientos, aplicándolos meramente a las partes del campo de cultivo donde su utilización es realmente necesaria. (Kropff y col. 1997).

Teniendo en cuenta que la aplicación automática de los tratamientos anteriormente mencionados se lleva a cabo principalmente en campos de cultivo grandes, ya que en esos casos la automatización tiene sentido, se puede llegar a la conclusión que la aplicación de AP supondría una gestión más precisa, que conllevaría no solo reducir significativamente el coste que supone aplicar tratamientos a toda la superficie del campo, sino que también resultaría una decisión ecológica inteligente, ya que ayudaría a preservar el medio ambiente.

La solución a este problema pasaría por la utilización de un tractor automatizado. Este tractor estaría equipado con un sistema de precisión dotado de una o más cámaras, en el segundo caso ante la posibilidad de aplicar técnicas basadas en visión estereoscópica del campo de cultivo (Rovira-Mas, 2008). Este sistema automatizado tendría que ser capaz de distinguir las partes vegetales del campo (cultivos y malas hierbas) y suelo. La otra cuestión que se plantea proviene

de la necesidad que este proceso tendría de que ser realizado en tiempo real, entendiendo por tiempo real el que se necesita en función de la velocidad del tractor. Aparte de esto, hay que tener en cuenta que las imágenes recibidas no siempre van a ser obtenidas bajo las mismas condiciones meteorológicas, pudiendo esperar variaciones significativas en función de la iluminación existente en el momento de la captura. Por poner un ejemplo, no existe la misma iluminación al atardecer que al mediodía o en días nublados que soleados. Es decir, nos enfrentamos a una problemática compleja, propia de los entornos de exterior.

Los métodos de reconocimiento actuales centrados en los campos de agricultura no resultan ser completamente eficaces, ya que ninguno resuelve todos los problemas que se presentan. Unas veces los procesos desarrollados no cumplen con las especificaciones de tiempo real, otras veces se ven afectados por los cambios de iluminación y en ocasiones la identificación de las texturas existentes en el campo de cultivo (suelo y cubierta vegetal) no se identifican como sería deseable.

Esta investigación se centra de manera especial en el último aspecto reseñado anteriormente, es decir en la identificación de las texturas vegetales (cultivo y malas hierbas). Una dificultad importante en esta tarea surge de las variaciones de iluminación existente en los entornos naturales. Este fenómeno, producirá reflejos brillantes unas veces con sombras oscuras en días de mucho sol e imágenes con los colores más atenuados y más oscuros en días nublados o al atardecer. Se pretende lograr resultados con la mínima tasa de error posible para su posterior implementación en tractores robotizados, que de esta manera serán capaces de reconocer satisfactoriamente las mencionadas texturas vegetales en campos de cultivo, incluyendo las malas hierbas.

Con el propósito antes mencionado, se ha propuesto una técnica basada en la descomposición de la imagen mediante la técnica de wavelets (Pajares, 2007). Como se explicará posteriormente, esta técnica tiene la particularidad de que las imágenes de partida se descomponen en diferentes bandas mediante las correspondientes combinaciones de filtros paso-bajo y paso-alto. Es precisamente distinto el comportamiento de las texturas vegetales y del suelo frente a los mencionados filtros, lo que va a permitir su aplicación. En efecto, las texturas vegetales se caracterizan por poseer una alta variabilidad en las componentes espectrales que presentan debido a su estado de crecimiento, a la aparición de distintas tonalidades por diferentes

contrastes, incluyendo las sombras. Los filtros paso-alto tienen la particularidad de captar muy bien tal variabilidad dado que los mismos capturan las componentes de alta frecuencia de la imagen. Por el contrario, las texturas del suelo poseen niveles menores de variabilidad en la intensidad, por lo que su comportamiento frente a los filtros paso-alto son bien diferentes. En consecuencia, aprovechando esta circunstancia y utilizando simultáneamente técnicas de fusión de imágenes (Pajares y Cruz, 2004) se lleva a cabo el trabajo de investigación que se presenta.

1.2 Estructura de la memoria

Este proyecto está dividido en cinco capítulos.

El Capítulo 1 – introducción, que incluye este apartado, se centra en proporcionar los detalles preliminares y el enfoque del problema, especificando también los objetivos que se pretenden conseguir con esta investigación.

El Capítulo 2 - estado del arte – tiene como objetivo realizar un estudio de los métodos utilizados en la bibliografía para afrontar problemas de este tipo o muy similares. En él también se hace un análisis de la investigación existente realizada por diferentes autores sobre los problemas de reconocimiento de texturas en imágenes en campos de cultivo.

El Capítulo 3 – descripción y revisión del método basado en wavelets – explica la estrategia diseñada para afrontar los problemas de reconocimiento de texturas en imágenes reales tomadas bajo diferentes condiciones de iluminación. También se explica la idea desarrollada en el trabajo de investigación, adentrándose en la terminología y en las investigaciones en la que se ha basado.

En el Capítulo 4 – resultados y discusión - se explica la forma en la que se realizaron las pruebas y se hace un análisis de los resultados obtenidos, comparándolos asimismo con los resultados obtenidos por otros métodos que tratan de resolver la misma problemática.

Finalmente en el Capítulo 5 – conclusiones y trabajo futuro – se extraen las conclusiones y se presentan las posibles líneas de investigación futuras.

1.3. Objetivos

El problema alrededor del cual se ha centrado esta investigación consiste en conseguir una identificación de texturas vegetales en imágenes reales de campos de cultivo a partir del reconocimiento de cultivos y malas hierbas. Este problema hace que el objetivo principal de la investigación sea aportar una solución satisfactoria al reconocimiento de tales texturas vegetales independientemente de la iluminación en el momento de la toma de la imagen.

En concreto, parte de este trabajo se basará en realizar un estudio de los métodos utilizados en investigaciones similares o bien investigaciones que se puedan aplicar al reconocimiento de texturas en un campo de cultivo. Uno de los objetivos consistirá en aplicar dichos métodos a las imágenes tomadas, para obtener las conclusiones pertinentes sobre la eficiencia de los mismos. Una vez conseguido este objetivo, se presentará una idea de posible mejora, que, según la hipótesis, daría como resultado un reconocimiento de texturas más eficaz.

Una vez constatada la hipótesis de partida, expuesta en el párrafo final de la sección 1.1, en relación a los diferentes tipos de textura y su identificación mediante la aplicación sucesiva de diferentes filtrados paso-bajo y paso-alto, se realizan los experimentos pertinentes con el fin de comprobar la eficacia del método y su comportamiento ante diferentes condiciones de iluminación de las imágenes capturadas bajo distintas situaciones meteorológicas.

Capítulo 2 - Estado del arte

2.1 Introducción

En las últimas décadas y ante la creciente conciencia sobre la importancia de la ecología han incrementado la atención hacia distintos aspectos relativos enfocados a la preservación del medio ambiente. Uno de esos aspectos se centra en la agricultura y más específicamente en la AP en diferentes campos de cultivo, donde hoy en día el uso de pesticidas y herbicidas no se puede considerar como ecológicamente satisfactorio. Sino más bien todo lo contrario. Además, lo habitual en un campo agrícola sigue siendo la aplicación de pesticidas y herbicidas en toda la superficie del cultivo, cosa que podría ser resuelta mediante sistemas inteligentes, aplicando tratamientos específicos exactamente allí donde se necesite.

Parte de la solución se basa en la implementación de un equipo de captura de imagen en las unidades móviles que realizan tales tratamientos. El objetivo, como ya se ha mencionado previamente, consiste en el procesado de las imágenes capturadas para identificar sobre ellas las zonas con cobertura vegetal y específicamente de malas hierbas. Posteriormente se aplica el tratamiento exclusivamente sobre las superficies que contienen malas hierbas y por tanto precisan de tal tratamiento. Esto conlleva un ahorro significativo de herbicidas y por consiguiente disminuye la contaminación medioambiental por un uso controlado del mismo.

El tratamiento y reconocimiento de imágenes para fines agrícolas es un campo de investigación fructífero en el que se centran numerosos proyectos. Sin embargo, trabajar con imágenes reales en tiempo real no resulta una tarea fácil.

En primer lugar, las imágenes tomadas poseerán elementos en común – conteniendo partes verdes correspondientes tanto al propio cultivo como a las malas hierbas, partes con tonalidades rojizas que se corresponden con la tierra y, probablemente, dependiendo de la posición de la cámara, partes azules que representan el cielo. Por otro lado, hay que tener en cuenta que las imágenes tomadas de una misma zona pueden variar de un día a otro, o incluso de una toma a otra, debido a las condiciones meteorológicas como pueden ser las correspondientes a un día de sol intenso, que en tal caso generaría colores más claros, en momentos de nubes densas o incluso al atardecer, que harán que las imágenes capturadas sean más oscuras, con poca luminosidad y menos intensidad en las correspondientes componentes espectrales. Por otro lado,

hay que tener en cuenta que el tratamiento y reconocimiento de las imágenes debe poder realizarse en un tiempo considerado como real en función de las condiciones de navegación donde va instalado el sistema de percepción visual.

Para valorar satisfactoriamente la solución al problema de identificación de las diferentes partes verdes de las imágenes la idea que se presenta en este trabajo consta básicamente de los siguientes pasos:

- 1) Aplicar una transformada sobre la imagen original basada en el cómputo de los denominados índices de verde
- 2) Aplicar la transformada de wavelets sobre la imagen resultante en el paso previo, obteniendo así una descomposición de la imagen en distintas bandas de frecuencia.
- 3) Fusionar las imágenes, obtenidas en la descomposición de wavelets con el objetivo de obtener una imagen mejorada y binarizada en la que se diferencien las partes verdes del resto con la máxima precisión posible.

La segmentación de verdes se estudia en Guijarro y col. (2010), mientras que la descomposición de imágenes agrícolas mediante la transformada de wavelets se puede ver en Chou y col. (2007), Ishak y col. (2008) y Bossu y col. (2008). A continuación se proporcionan algunos detalles relevantes en relación a la segmentación de las texturas vegetales y la descomposición de la imagen mediante la transformada de wavelets. Se pospone al capítulo tres la descripción de la estrategia de fusión en la que se fundamenta el presente trabajo de investigación.

2.2 Segmentación de verdes

Según Guijarro y col. (2010) el mayor problema en el campo de visión por computador estriba en la segmentación de imágenes, en nuestro caso, la segmentación de las partes verdes. Existen diversas estrategias para realizar tales tareas de segmentación, divididas entre las basadas en el espectro visible, utilizando un umbral definido, y las que se fundamentan en métodos de aprendizaje.

En la segmentación atendiendo a las componentes de la imagen procedentes del espectro visible se encuentran los siguientes que se citan a continuación, considerados como los más relevantes:

- 1) el método conocido como exceso de verdes, *ExG* de Woebbecke y col. (1995), Ribeiro y col. (2005),
- 2) el conocido como exceso de rojos *ExR* de Meyer y col. (1998).
- 3) el índice de extracción de vegetación *CIVE* de Kataoka y col. (2003).
- 4) la diferencia matemática entre la extracción de verdes y rojos *ExGR* de Neto (2004)
- 5) el índice vegetativo *VEG* descrito en Hague y col. (2006).

Reid y Searcy (1987) aplican un método de segmentación tal que para identificar las plantas y el suelo asignaron sendas clases a las dos texturas y supusieron que dichas clases seguían una distribución Gaussiana. Se trata pues de una estrategia conocida como bi-clase por el hecho de identificar dos clases, También, dentro de los métodos bi-clase se encuentra el método de umbralización de Otsu (1979), que se basa en la estima del mejor umbral a partir del histograma de intensidades. Sin embargo, este método tiende a producir una infra-segmentación, ya que proporciona un valor superior al valor medio del histograma, haciendo que ciertos píxeles de la imagen procedentes de texturas vegetales lleguen a descartarse, perdiendo así cierta información sobre tales texturas vegetales. Por el contrario, tiene la ventaja de que sólo se seleccionan con seguridad los píxeles de texturas, valorando mejor esta última opción frente a la primera.

Entre los estudios de segmentación de imágenes basadas en métodos de aprendizaje se encuentra el desarrollado por Meyer y col. (2004), donde se aplicaron aproximaciones fundamentadas en el agrupamiento borroso para la segmentación de zonas de exceso de verdes y rojos. Zheng y col. (2009, 2010) utilizan el algoritmo conocido como Mean-Shift, técnica de categorización, para encontrar grupos en espacios característicos.

Por otro lado, para resolver el problema de la segmentación de verdes, Guijarro y col. (2010) proponen la segmentación automática en tres pasos:

1. Extracción de verdes combinando los siguientes índices *ExG*, *CIVE*, *ExGR* y *VEG*. El procedimiento se basa en la uniformidad de los histogramas procedentes de las imágenes que contienen los mencionados índices. Con anterioridad, las imágenes que se encuentran en el espacio de color RGB se normalizan a valores *r*, *g* y *b* cuyos valores se restringen al rango [0, 1].
2. Extracción de rojos a través de *ExR* y azules mediante el mismo proceso cambiando la banda azul por la roja. Posteriormente, se determina en función de tales índices si la imagen contenía partes de cielo o solamente suelo.
3. Clasificación de diferentes tipos de plantas y suelo mediante el método basado en agrupamiento borroso.

2.3 Wavelets y fusión de imágenes

Las wavelets son familias de funciones en el espacio que examinan la señal de interés para obtener sus características de espacio, tamaño y dirección.

Existen tres trabajos de interés sobre fusión de wavelets recopilados en Pajares y Cruz (2004) que establecen una base de partida, a saber: Zhang y Blum (1999), Ranchin y Wald (2000) y Li y col. (1995). El primero establece una descomposición multiescala, el segundo introduce el concepto ARSIS (Amélioration de la Résolution Spatiale par Injection de Structures) haciendo uso de un método multiescala para la descripción y modelado de la información que está ausente en las imágenes que van a ser fusionadas. Li y col. (1995) realiza diversos experimentos con varios conjuntos de imágenes entre las que se incluyen imágenes multifoco. En este último el objetivo de la fusión consiste en lograr una imagen de alta calidad a partir de varias imágenes degradadas. En Ranchin y Wald (2000) el objetivo de la fusión consiste en lograr una alta resolución espacial junto con un alto contenido espectral de baja resolución en imágenes de satélite, es decir: 1) imágenes con alta calidad en el contenido espectral pero baja calidad en la resolución espacial y 2) imágenes con alta resolución espacial pero con una única banda espectral. Este es también el objetivo en Garguet-Duport y col. (1996).

La aplicación de técnicas de descomposición mediante wavelets centrada en imágenes agrícolas se puede estudiar en Bossu y col. (2008), Chou y col. (2007) e Ishak y col. (2008). Bossu y col. (2008), los cuales utilizaron más de 30 familias de wavelets y el filtro Gabor para diferenciar automáticamente entre cultivo y maleza. Haciendo un inciso, conviene señalar que los filtros de Gabor, se caracterizan por realizar una descomposición de la imagen en distintas frecuencias, similar a la descomposición de wavelets. De las 30 familias de wavelets utilizadas en el citado trabajo, se seleccionaron dos representativas, concretamente la familia que proporcionaba los mejores resultados y a la vez la que generaba los peores, en ambos casos se compararon con el filtro Gabor. Aparte de imágenes de cultivos reales, Bossu y col. (2008) crearon imágenes sintéticas con tres tipos diferentes de distribución espacial de malas hierbas.

Los resultados que obtuvieron mostraron que las familias de Daubechies y Meyer proporcionaban los mejores resultados, siendo la de Daubechies la que ofrecía el mejor compromiso entre tiempo de procesamiento y precisión. La familia con la que peores resultados se obtenían resultó ser la biortogonal. En cualquier caso, todas las familias de wavelets proporcionaron mejores resultados que el filtrado de Gabor.

Ishak y col. (2008) utilizaron una combinación de la descomposición basada en wavelets y Gabor utilizando una distribución de gradiente de campo. Todas las imágenes fueron tomadas bajo las mismas condiciones de iluminación, y optaron por clasificar las malas hierbas como hierba de hoja estrecha, mientras que el cultivo fue clasificado como textura vegetal de hoja ancha. Con esta categorización generaron un algoritmo de entrenamiento. Los resultados indicaron una exactitud de diferenciación de un 94%.

Aproximadamente el mismo porcentaje de acierto (94.63%) consiguieron Chou y col. (2007), en el que combinaron la transformada de wavelets basada en la familia Daubechies con la distancia bayesiana ponderada; en este caso también basándose en las características proporcionadas por las distintas clases de hojas existentes en las texturas vegetales.

2.3.1 Familias wavelets

Existen muy diversos tipos de familias de wavelets, entre ellas destacan: Haar, Daubechies, Meyer, biortogonal, Coiflet, Symlet, reversa biortogonal.

Entre las más populares se encuentra la propuesta por Daubechies (1992), que es la función más compacta para el número de orden utilizado (ver sección 3.3). Aunque estas funciones no son simétricas, para un orden lo suficientemente alto ($N > 15$) resultan óptimas.

Otra familia interesante es la de que se define en Meyer (1990), con una construcción basada en el espacio de Fourier. Esta función no es compacta, si bien puede ser aproximada correctamente con una versión truncada según Bossu y col. (2008).

Las familias de wavelets de orden superior suelen ser generalmente funciones suaves, sin picos fuertemente acentuados, y suelen proporcionar buena localización tanto en el espacio como en la frecuencia.

Capítulo 3 - Descripción y revisión del método basado en wavelets

3.1 Introducción

En este capítulo se describe con detalle el método desarrollado a raíz de la investigación siguiendo los pasos por orden cronológico. El objetivo de este trabajo consiste en automatizar el proceso de segmentación de verdes en imágenes de cultivos con el fin de obtener resultados satisfactorios en las imágenes procedentes de los campos objeto de estudio, que mejoran los obtenidos por otros métodos existentes en la literatura. Esta tarea resulta difícil por tratarse de imágenes reales, donde las condiciones de iluminación son variables. Con el fin de ilustrar este comportamiento, en la figura 3.1 se muestran tres imágenes representativas del conjunto de imágenes utilizadas obtenidas bajo diferentes condiciones de iluminación. En la imagen de la figura 3.1 (a) se muestra una imagen con una fuerte iluminación sin llegar a la saturación, conteniendo partes brillantes y con un fuerte contraste del verde, además de abundantes sombras. En la imagen de la Figura 3.1 (b) aparece una imagen con las zonas del suelo saturadas o próximas a la saturación. Finalmente, en la figura 3.1 (c) aparece una imagen muy oscura debido a la escasa iluminación con la que fue capturada.

Figura 3.1 Imágenes del campo de cultivo: (a) en un día normal. (b) en un día con mucha iluminación – imagen saturada (c) al atardecer – imagen no saturada



(a)



(b)



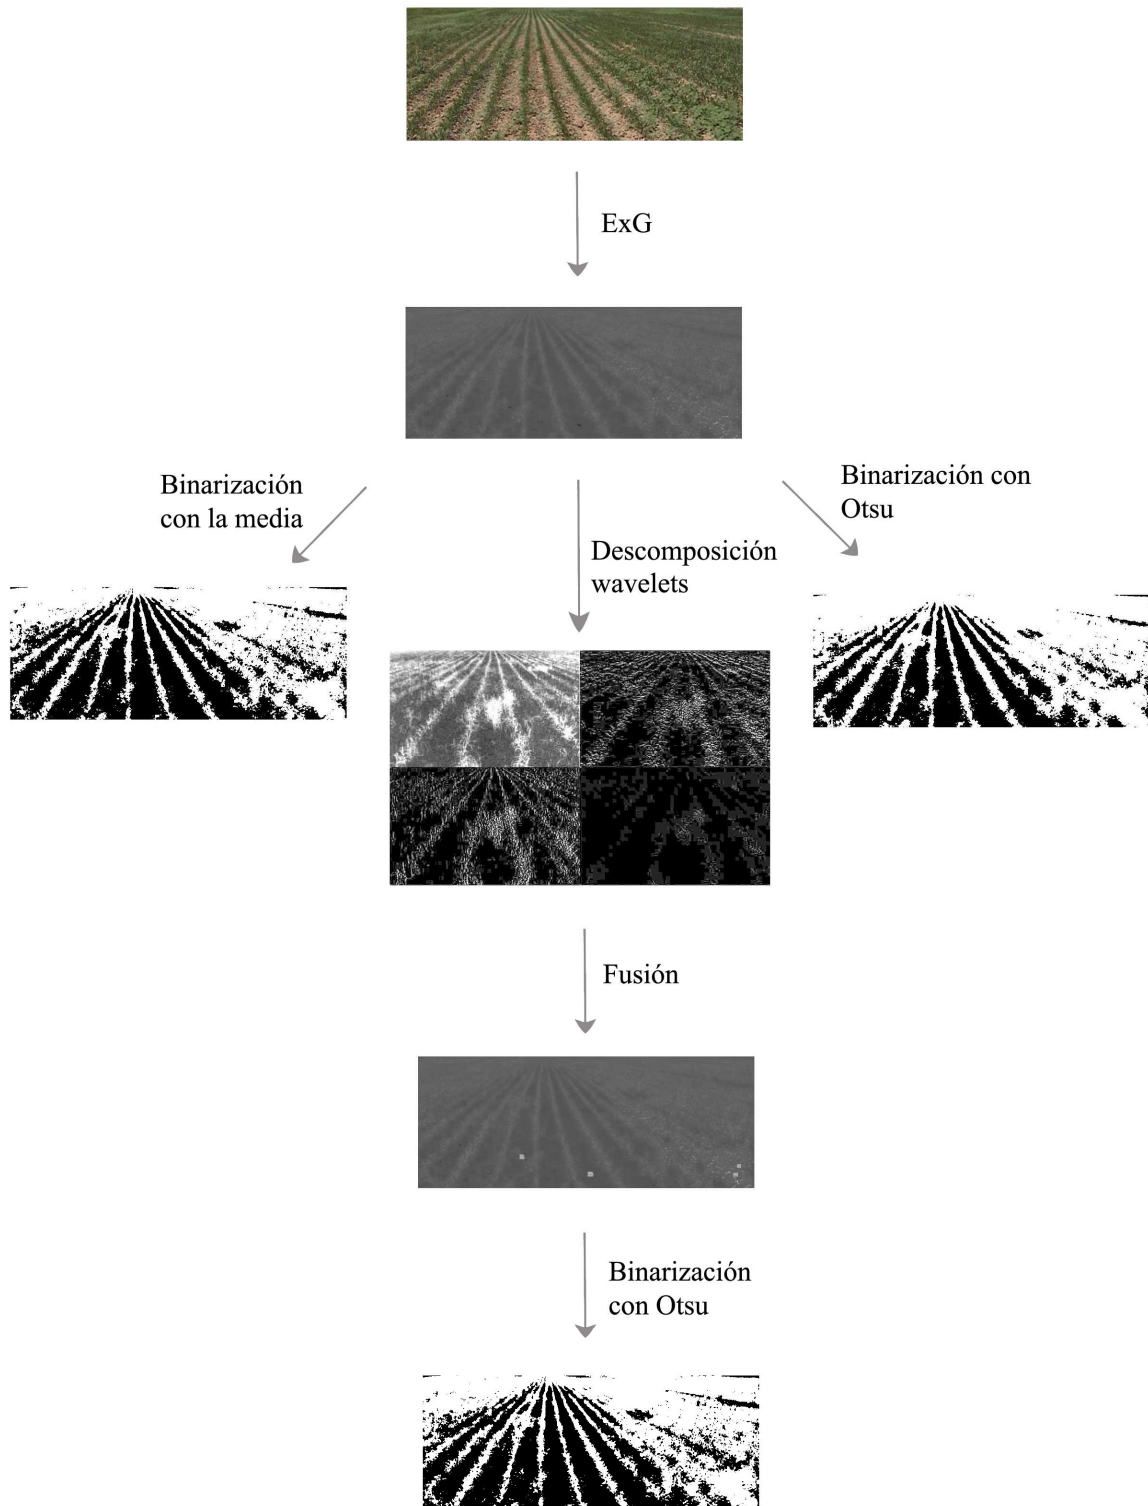
(c)

En el esquema de la figura 3.2 se muestran los diferentes pasos que describen el procedimiento propuesto en este trabajo de investigación. Se comienza con la extracción de las partes verdes de la imagen. Este primer paso genera una imagen en la que los verdes quedan resaltados con tonalidades claras frente a aquellas partes que no corresponden a la vegetación en las que las tonalidades se manifiestan mucho más oscuras. Para realizar esta primera segmentación de la imagen se utilizan los índices cromáticos, concretamente el índice *ExG* introducido previamente (Woebbecke y col. 1995). Una vez obtenida esta imagen aplicaremos la descomposición de wavelets, aplicando la familia de Daubechies. El proceso de descomposición y posterior fusión constituye uno de los pasos esenciales del método propuesto. En el siguiente paso se realiza una binarización de la imagen mediante el método de umbral de Otsu. Los resultados binarios, finalmente obtenidos, se comparan con las imágenes que constituyen el “ground-truth”, que permite obtener el porcentaje de error real de la segmentación. Adicionalmente, y a efectos comparativos se utiliza el valor de la media correspondiente al histograma de la imagen *ExG* como umbral de binarización. No obstante, conviene aclarar aquí que la media no es en realidad un método propio de umbralización a diferencia del método de Otsu.

De esta comparación, se puede concluir que la descomposición y fusión de la imagen mediante la transformada de wavelets constituyen una aportación relevante en esta investigación, donde los porcentajes de error obtenidos para este tipo de imágenes se han visto reducidos, ofreciendo resultados satisfactorios, en comparación con otros métodos existentes en la literatura.

En lo que resta de capítulo se describen con detalle los diferentes expuestos previamente.

Figura 3.2 Esquema de los pasos seguidos en este trabajo de investigación



3.2 Segmentación de verdes

Para resolver el problema de la amplia gama de verdes que nos encontramos en algunas imágenes la idea subyacente en la literatura pasa por la binarización de dichas imágenes. El problema que nos encontramos es el de establecer un valor de umbral que diferencie las texturas verdes del resto, en nuestro caso principalmente suelo.

El primer paso consiste en aplicar una transformación a las imágenes originales para extraer los índices cromáticos con el fin de resaltar las texturas verdes, consiguiendo así intensificar la tonalidad deseada en función del grado de verdor.

Para poder calcular los índices cromáticos es necesario primero realizar una normalización del espacio de color. Las imágenes captadas se encuentran en el espacio de color RGB (rojo, verde y azul), con valores de cada banda espectral en el rango de 0 a 255, o sea, 256 valores en total, donde el valor 0 juntando los tres colores pertenece al negro y 255 al blanco. Sin embargo, para poder calcular los índices cromáticos, estos valores deberán ser transformados a valores relativos.

$$R = \frac{R}{R_{\max}} \quad G = \frac{G}{G_{\max}} \quad B = \frac{B}{B_{\max}} \quad (3.1)$$

donde R_{\max} , G_{\max} y B_{\max} serán 255 para imágenes de 24 bits. Ahora se puede proceder a la normalización, que se describe en Gée y col. (2008):

$$r = \frac{R}{R+G+B} \quad g = \frac{G}{R+G+B} \quad b = \frac{B}{R+G+B} \quad (3.2)$$

Una vez normalizados los valores, realizamos el cálculo de los índices cromáticos mediante la correspondiente transformación para la extracción de las texturas verdes. En la bibliografía se describen varios métodos, de entre los cuales en este trabajo se probaron los mencionados en la tabla 3.1. De entre todos ellos para su aplicación en la estrategia que se propone en este trabajo se seleccionaron los que mejores resultados ofrecieron.

Tabla 3.1 Índices cromáticos

Exceso de verdes ExG	$ExG = 2g - r - b$ Woebbecke (1995) y Ribeiro y col. (2005)	(3.3)
Exceso de rojo ExR	$ExR = 1.4r - b$ Meyer y col. (1998)	(3.4)
Exceso de verde con exceso de rojo ExGR	$ExGR = ExG - ExR$ Neto (2004)	(3.5)
“Colour Index of Vegetation Extraction” CIVE	$CIVE = 0.441r - 0.811g + 0.385b + 18.78745$ Kataoka y col. (2003)	(3.6)
Índice vegetativo VEG	$VEG = \frac{g}{r^a b^{1-a}}$, donde a se inicializa a 0.667 Hague y col. (2006)	(3.7)

Estas ecuaciones (3.3, 3.5, 3.6 y 3.7) transforman una imagen desde el espacio RGB a escala de grises, tal y como se puede observar en la figura 3.3.


Figura 3.3 Segmentación de la imagen mediante índices cromáticos: a) exceso de verdes – ExG ; b) diferencia entre verdes y rojos – $ExGR$, c) “Colour Index of Vegetation Extraction” – $CIVE$, d) índice vegetativo - VEG




a)



b)



c)



d)

Como puede deducirse a partir de la figura 3.3, las transformaciones realizadas contienen las correspondientes imágenes en escala de grises. En ellas se puede apreciar fácilmente que las partes pertenecientes a texturas vegetales, es decir las partes verdes, están representadas en tonos claros y muy claros, mientras que el resto en tonos más oscuros, llegando incluso al negro. En base a este criterio resulta fácil deducir que el mejor índice a aplicar en este tipo de imágenes será el que mayor contraste ofrezca. Bajo esta suposición es posible llegar a la conclusión de que el mejor resultado se ha producido con el método *ExG*, mientras que el peor resultado viene dado por el método *VEG*.

3.3 Transformada de wavelets

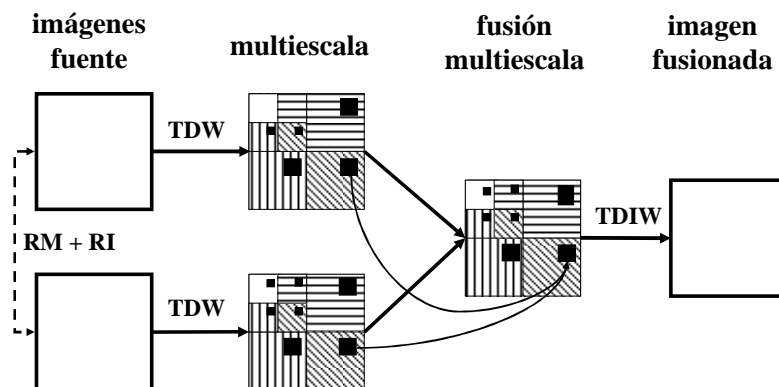
Las wavelets son familias de funciones en el espacio que transforman la señal de interés para obtener sus características de espacio, tamaño y dirección. La transformada wavelet, también conocida como transformada de óndula, es una clase de transformada de Fourier que representa una señal en términos de versiones trasladadas de la onda original. Esta transformada es una forma de representación simultánea de tiempo y frecuencia. Estas wavelets (y las transformadas) pueden ser continuas o discretas. La transformada continua se utiliza en física, mientras que la discreta se utiliza en el análisis de señales, encontrando un campo de aplicación en ingeniería e informática en análisis y compresión de imágenes digitales.

La Transformada Discreta de Wavelets (TDW) permite la descomposición de la imagen en diferentes escalas (multiresolución) de coeficientes a la vez que se preserva la información. En la descomposición se obtienen tanto coeficientes de aproximación como de detalle. Sobre los coeficientes de aproximación cabe, a su vez, aplicar nuevas transformaciones para conseguir un nivel inferior de resolución. Los coeficientes, tanto de aproximación como de detalle, para una

escala dada procedentes de distintas imágenes pueden combinarse (mezclarse) para la obtención de nuevos coeficientes. Una vez realizada la mezcla de coeficientes se procede a aplicar la Transformada Discreta Inversa de Wavelets (TDIW) para obtener finalmente la imagen fusionada.

En la figura 3.4 se muestra un diagrama para la descomposición multiescala mediante wavelets. Las imágenes fuente poseen idénticas resoluciones espaciales, por tanto, si sus resoluciones espaciales originales son diferentes, entonces es necesario un remuestreo (RM) hasta conseguir la misma resolución, seguido de un registro de las imágenes (RI). Se aplica la TDW a ambas imágenes consiguiendo una descomposición de cada imagen original.

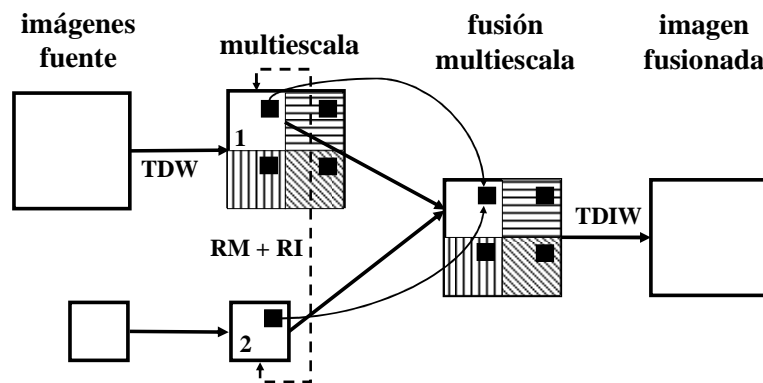
Figura 3.4 Diagrama de bloques de un esquema de descomposición en wavelets con la misma resolución espacial



En relación a la imagen de la figura 3.4 las diferentes orientaciones de las barras representan diferentes coeficientes: *aproximación* (imagen en blanco), *horizontales* (barras horizontales), *verticales* (barras verticales), *diagonales* (barras diagonales). Estos tres últimos se denominan de detalle. Los cuadrados negros, asociados a cada nivel de descomposición, representan coeficientes que se corresponden con la misma localización espacial en la imagen original, de suerte que sólo los píxeles de la misma resolución y localización espacial son los candidatos para su mezcla y por tanto para la fusión. Este es el concepto expresado por las líneas curvadas en la figura. Una vez que se ha llevado a cabo el proceso de fusión, se obtiene la imagen final fusionada a través de la TDIW.

En la figura 3.5 existen dos imágenes fuente con diferentes niveles de resolución, la DWT se aplica sólo a la imagen con la mayor resolución espacial, obteniéndose una representación en una escala inferior. La imagen con menor resolución no se transforma. En este momento, si las subimágenes 1 y 2 (coeficientes de aproximación) tienen todavía diferentes resoluciones espaciales, se requiere un remuestreo (RM) y un registro (RI). Como en el caso anterior, sólo los coeficientes con las mismas localizaciones espaciales se fusionan. La imagen fusionada final se obtiene tras la aplicación de la IDWT.

Figura 3.5 Diagrama de bloques de esquemas de descomposición en wavelets con diferente resolución espacial en las imágenes fuente



3.3.1 Familias de wavelets

Las transformadas wavelets representan la mejor herramienta para separar las componentes de bajas frecuencia de la imagen (ligeras variaciones de color) de las altas (los bordes que dan más detalle). Como se ha mencionado previamente, existen varios tipos de transformadas wavelets, denominados como familias wavelets, entre ellas Haar, Daubechies, biortogonal, Coiflet, Symlet, reversa biortogonal, etc., perfectamente descritas en la documentación asociada al toolbox de Matlab (The Mathworks, 2011). En este trabajo se realizan todas las pruebas con la familia de Daubechies por ser una de las más utilizadas en la literatura y que mejores resultados ofrece. Para poder explicar dicha familia, es necesario primero introducir la familia Haar, ya que ésta constituye la base de partida.

Wavelets de Haar

Se trata de la más simple de todas las familias ya que viene a ser una secuencia de funciones; fue introducida por primera vez por este matemático húngaro en 1909. La función de esta wavelet se describe como:


$$\psi(t) = \begin{cases} 1 & 0 \leq t < 1/2 \\ -1 & 1/2 \leq t < 1 \\ 0 & \text{de otra forma} \end{cases} \quad (3.8)$$

Su gráfica se muestra en la figura 3.6, donde fácilmente puede observarse su simplicidad. Cuenta con un solo momento de desvanecimiento, un concepto importante que permite conocer la forma de la wavelet, ya que se trata de un parámetro que define la suavidad de la wavelet. El i -ésimo momento de una wavelet se calcula con la integral:

$$\int_{-\infty}^{\infty} h(x)x^i dx = 0 \quad (3.9)$$

donde $h(x)$ es la función madre originaria de la wavelet. Una función tiene ν momentos de desvanecimiento si la integral es 0 para $i=0, \dots, \nu-1$.


Figura 3.6 Representación gráfica de la Wavelet de Haar



Wavelets de Daubechies

La wavelet de Daubechies pertenece a la familia de wavelets ortogonales, caracterizadas por un número máximo de momentos de desvanecimiento denominados como wavelet de orden N , donde N es un entero positivo y denota el número de coeficientes de filtro que posee la wavelet. Por ejemplo, la wavelet Daubechies de orden $N=1$ es la wavelet Haar. En la figura 3.7 se pueden observar las correspondientes representaciones gráficas de esta familia de wavelets para distintos órdenes.

Figura 3.7 Wavelets de Daubechies de distintos órdenes



3.4 Binarización de imágenes

Una vez las imágenes se han segmentado para realzar las partes de interés, en nuestro caso los verdes, se realiza un proceso de binarización que transformará las partes claras de la imagen a blanco y el resto a negro. El punto clave es seleccionar un umbral óptimo, es decir, un valor de gris desde el cual se decide cuáles de dichas tonalidades son o no verdes.

Hay que tener en cuenta que el objetivo es conseguir la automatización del proceso, así es que la umbralización debe producirse de forma automática, no manual. Además debe ser un procedimiento válido para todo tipo de imágenes, tanto para las saturadas como para las no saturadas y para las obtenidas con diferentes tipos de iluminación. La clave en cualquier caso consiste en utilizar el histograma de la imagen, que constituye el punto de partida del proceso.

Existen diferentes métodos en la literatura relativos a la umbralización. De entre ellos, el de Otsu (1979) es uno de los más clásicos y populares, que ofrece resultados satisfactorios en muy diversas aplicaciones, razón por la cual se utiliza en este trabajo. Cabe la posibilidad de utilizar la media estadística del histograma como valor de umbral, si bien se trata de una técnica que no se ubica con claridad dentro de los métodos de umbralización. No obstante, en nuestro caso, dadas las características de las imágenes los resultados obtenidos con la media resultan ser satisfactorios desde el punto de vista de la umbralización, razón por la cual en nuestro trabajo se utilizan ambos.


3.4.1 Binarización mediante la media

Por media se entiende el valor medio de los niveles de intensidad en la imagen que contiene los índices de vegetación. Se obtiene directamente a partir del histograma de la imagen.

El principal problema consiste en que al aplicar la media como método de umbralización, podemos caer en extremos si la imagen *ExG* contiene gran cantidad de verde (claros) o de suelo (oscuros), ya que este umbral tenderá a situarse en la zona del histograma que contenga la mayoría de los valores en uno u otro sentido.

El histograma de la imagen *ExG*, se puede observar en la figura 3.8, en el que se aprecia una clara tendencia a agrupar los niveles de intensidad hacia la parte baja del histograma.

Figura 3.8 Histograma obtenido a partir de *ExG*



El resultado de la binarización, mediante la media de la imagen obtenida al aplicar el índice cromático *ExG*, a la imagen original mostrada en la figura 3.1 (a), se puede observar en la figura 3.9.

Figura 3.9 Binarización mediante la media, índice cromático *ExG*



3.4.2 Binarización mediante el método de umbralización de Otsu

Como se ha indicado previamente, otro método que aparece ampliamente en la bibliografía es el método de Otsu (1979), utilizado en segmentación de imágenes agrícolas en Meyer y Camargo (2008). De nuevo se basa en conceptos estadísticos, en concreto la dispersión de los valores (en este caso, niveles de gris) a través de la varianza.

Este método calcula el mejor umbral de manera que la dispersión sea la menor posible entre un mismo segmento, y a su vez la más alta posible entre distintos segmentos. Se obtiene calculando un cociente entre ambas varianzas y buscando después un valor para que este cociente sea el máximo, este valor resulta finalmente ser el umbral.

Matemáticamente, buscamos un umbral t y dos segmentos del resultado deseado en la segmentación, $K_0(t)$ y $K_1(t)$.

Sea $p(g)$ la probabilidad de ocurrencia del valor de gris g , $0 < g < G$, siendo G el valor de gris máximo. Entonces la probabilidad de ocurrencia de los píxeles en los dos segmentos $K_0(t)$ y $K_1(t)$ es:

$$\text{Para } K_0(t): P_0(t) = \sum_{g=0}^t p(g) \quad (3.9)$$

$$\text{Para } K_1(t): P_1(t) = \sum_{g=t+1}^G p(g) = 1 - P_0(t) \quad (3.10)$$

La suma de estas dos probabilidades dará evidentemente 1.

Digamos ahora que \bar{g} es la media aritmética de los valores de gris de toda la imagen, y \bar{g}_0 y \bar{g}_1 las medias de cada segmento. La variancia dentro de cada segmento se puede calcular como sigue:

$$\text{para el segmento } K_0(t): \sigma_0^2(t) = \sum_{g=0}^t (g - \bar{g}_0)^2 p(g) \quad (3.11)$$

$$\text{y para el segmento } K_1(t): \sigma_1^2(t) = \sum_{g=t+1}^G (g - \bar{g}_1)^2 p(g) \quad (3.12)$$

Se pretende mantener la variancia dentro de cada segmento lo más pequeña posible, y entre los dos segmentos el más grande posible, así que obtenemos:

$$Q(t) = \frac{\sigma_{zw}^2(t)}{\sigma_{in}^2(t)} \quad (3.13)$$

La variancia entre los dos segmentos es:

$$\sigma_{zw}^2(t) = P_0(t) \cdot (\bar{g}_0 - \bar{g})^2 + P_1(t) \cdot (\bar{g}_1 - \bar{g})^2 \quad (3.14)$$

La variancia dentro de los segmentos se obtiene sumándolos:

$$\sigma_{in}^2(t) = P_0(t) \cdot \sigma_0^2(t) + P_1(t) \cdot \sigma_1^2(t) \quad (3.15)$$

El valor del umbral t se elige de tal manera que el cociente $Q(t)$ sea máximo. $Q(t)$ es por lo tanto la medida buscada. De esta forma elegimos un valor umbral que optimiza los dos segmentos en términos de variancia.

El método de Otsu genera resultados satisfactorios cuando los números de píxeles en cada segmento están cerca uno del otro, tal como aparece en el trabajo de en Sezgin y Sankur (2004). De esta manera podemos constatar que al aplicar el método de Otsu el umbral se va a situar buscando el equilibrio entre los valores de la imagen más claros y los más oscuros.

El resultado de la binarización mediante el método de Otsu de la imagen obtenida al aplicar el índice cromático ExG , a la imagen original de la figura 3.1 (a), se puede observar en la figura 3.10.

Figura 3.10 Binarización mediante el método de Otsu, índice cromático ExG




3.4.3 Descomposición mediante wavelets

La aportación fundamental de este trabajo se encuentra en el contenido de este apartado. La idea se basa en que aplicando la transformada de wavelets, al hacer la binarización de la imagen mediante un umbral determinado se pueden conseguir mejores resultados.

Partimos de la imagen *ExG* obtenida al aplicar el mencionado índice cromático a la imagen original, figura 3.1 (a). Sobre esta imagen aplicamos la transformada de wavelets bajo el filtro de la familia Daubechies, consiguiendo así una imagen descompuesta en los cuatro coeficientes consabidos: aproximación, detalles horizontales, detalles verticales y detalles diagonales, como se puede ver en la figura 3.11.

Figura 3.11 Coeficientes resultantes de la descomposición mediante wavelets: *CAExG*, *CHExG*, *CVExG* y *CDExG*



Los coeficientes de aproximación contienen información acerca de las características más importantes obtenidas mediante un filtrado paso-bajo asociado a la familia Daubechies. Dicho de otro modo, estos coeficientes contienen la mayor parte de la información precedente de la imagen original, es decir, la información más relevante. Por este motivo se toman estos coeficientes como base para el procesamiento subsecuente.

La hipótesis de partida consiste en regenerar una imagen donde los píxeles más relevantes se correspondan con texturas de verde, bien cultivos o malas hierbas. Por otra parte,

precisamente son las texturas asociadas con los verdes las que presentan las mayores variaciones de intensidad debido a las diferentes alturas, sombras y sus propias irregularidades. El objetivo consiste en asegurar tras la fusión que el píxel que se va a modificar corresponda realmente a una de las texturas de verde anteriormente mencionadas. Es evidente, que en la imagen que contiene los coeficientes de aproximación, su valor máximo representa sin duda un píxel correspondiente a la vegetación (cultivo o mala hierba), por tanto, la idea consiste en realizar una fusión y garantizar que si el nuevo píxel generado tras la fusión es un píxel correspondiente a una textura verde, asignarle ese valor máximo que hemos determinado como píxel vegetal. Mediante la ecuación (3.16) se obtiene exactamente el valor máximo buscado de la imagen ExG conteniendo los coeficientes de aproximación.


$$a = \max \{CAExG\} \quad (3.16)$$

El problema que se plantea ahora consiste en cómo identificar o catalogar un determinado píxel como perteneciente a una textura vegetal. Según lo anteriormente expuesto, estos píxeles se caracterizan por presentar una alta variabilidad en cuanto a la distribución de los niveles de intensidad. Por consiguiente, los coeficientes de detalle, que en definitiva proceden de los correspondientes filtrados de alta frecuencia, proporcionan la suficiente información para identificar los píxeles como pertenecientes a la cubierta vegetal, dado que aparecen los detalles más significativos allí donde existe una alta variabilidad en la intensidad de la imagen ExG . En las zonas más o menos homogéneas como pueden ser las zonas asociadas con el suelo, esta variabilidad es mucho menor o incluso inexistente. Se trata pues de identificar zonas de alta variabilidad, lo cual se lleva a cabo mediante la aplicación de descriptores de textura capaces de capturar esta información. Uno de tales descriptores es precisamente la varianza estadística, o equivalentemente la desviación estándar, que es la que generalmente se aplica en las aplicaciones que involucran descriptores de textura (Pajares y Cruz, 2007).

Para capturar la variabilidad de la textura, el paso siguiente consiste en tomar las imágenes correspondientes a los coeficientes de detalle, $CHExG$, $CVExG$ y $CDExG$. A continuación se calcula la desviación típica, abriendo ventanas de 5×5 , centradas en el píxel que se está considerando. De esta manera, si el valor de la desviación típica en cualquiera de las tres ventanas asociadas con las correspondientes imágenes de detalle, supera un cierto umbral, en este caso 0.06, elegido tras diversos experimentos de ensayo y error, el píxel es catalogado como

perteneciente a una textura vegetal. En este caso, será sustituido por el valor de a , obtenido según la ecuación (3.16) en la imagen correspondiente a los coeficientes de aproximación, $CAExG$. En caso contrario, cuando el valor de la desviación típica no supera el valor del umbral establecido previamente, permanece inalterado. Este proceso constituye realmente la esencia del procedimiento de fusión que se presenta en este trabajo de investigación.

Figura 3.12 Binarización mediante wavelets, índice cromático ExG



Una vez procesada toda la imagen correspondiente a los coeficientes de aproximación, donde determinados valores se habrán cambiado en función del procedimiento descrito previamente, se obtiene finalmente la imagen fusionada, cuya apariencia en relación a la cobertura vegetal mejora considerablemente la imagen de partida, tal y como puede apreciarse en el ejemplo mostrado en la figura 3.13, correspondiente a una de las imágenes utilizadas en los diferentes experimentos.

Figura 3.13 Imagen obtenida tras la fusión mediante wavelets



La hipótesis es que la binarización de esta imagen mejorada producirá mejores resultados que la binarización obtenida de la imagen original *ExG*. Este hecho se justifica sobre la base de que durante el proceso de fusión se han seleccionado aquellos píxeles que ofrecían ciertamente un valor alto de variabilidad, que se corresponden exactamente con las texturas vegetales.

El resultado de la binarización de la imagen mejorada mediante la descomposición por wavelets, se puede observar en la figura 3.14.

Figura 3.14 Binarización de la imagen mejorada mediante wavelets con el umbral otsu



Capítulo 4 - Resultados y discusión

4.1. Introducción

La finalidad de este proyecto es la de conseguir aislar las partes verdes de la imagen frente a las de suelo u otras texturas diferentes. El proceso para conseguir ese fin pasa por varias etapas.

Primero, realizamos un realzado de la imagen aplicando los índices cromáticos, consiguiendo así destacar los tonos verdes de la imagen. Como resultado de esta etapa obtenemos una imagen en tonos grises, figura 3.3, donde los píxeles puramente verdes pasarán a ser blancos, mientras que los píxeles que solo contienen rojos y azules, sin rastros de verdes, se convertirán en negros. Con esta segmentación se consigue una imagen donde a cada pixel le corresponderá un valor en la escala de grises con valores de $[0,1]$, donde el 0 representará el negro y el 1 el blanco.

La tabla 3.1 contiene los distintos índices cromáticos expuestos en la literatura, tal como la extracción de verdes *ExG*, el exceso de verde con exceso de rojo *ExGR*, el denominado “colour index of vegetation extraction” *CIVE* y el índice vegetativo *VEG*. En este capítulo se verá el estudio comparativo por el cual se ha decidido utilizar el índice cromático *ExG*, descartando el resto de índices para las imágenes utilizadas en nuestros experimentos.

Una vez elegido el índice cromático a utilizar, el siguiente paso consiste en la descomposición de la imagen *ExG* mediante la transformada de wavelets. Esta transformada lleva consigo la aplicación de una familia de wavelets. Es en este capítulo donde se expone el estudio realizado para la elección de la familia de Daubechies, realizando un estudio comparativo con algunas de las familias wavelets más conocidas para este tipo de imágenes.

Para finalizar, una vez obtenida la imagen fusionada, hay que binarizarla. Para ello es necesaria la selección de un umbral. En este trabajo se han realizado las pruebas con el umbral basado en el mencionado método de Otsu y con la media como método de umbralización sustitutivo.

La bondad de nuestro método se ha contrastado con el “ground-truth”, base de imágenes binarizadas por un experto humano, con el que se han comparado los resultados obtenidos, lo que permite calcular el porcentaje de error.


4.2. Elección de los índices cromáticos y de la familia wavelets

Como se ha mencionado anteriormente, el primer paso consiste en elegir el mejor índice cromático a aplicar a este tipo de imágenes. Para esta elección se ha realizado un estudio con los cuatro índices cromáticos descritos en la tabla 3.1, a saber: *ExG*, *ExGR*, *CIVE* y *VEG*.

Una vez obtenidas las imágenes correspondientes a cada índice cromático, se ha realizado una umbralización tanto con el método de Otsu como con la media. Sobre las imágenes así obtenidas se ha aplicado el proceso propuesto en este trabajo con el fin de valorar con qué umbral se obtienen mejores resultados. La imagen binaria resultante de cada índice es comparada con la imagen correspondiente perteneciente al “ground-truth”.

En la figura 4.1 se muestran los resultados basados en porcentajes de error en relación a cada uno de estos índices.

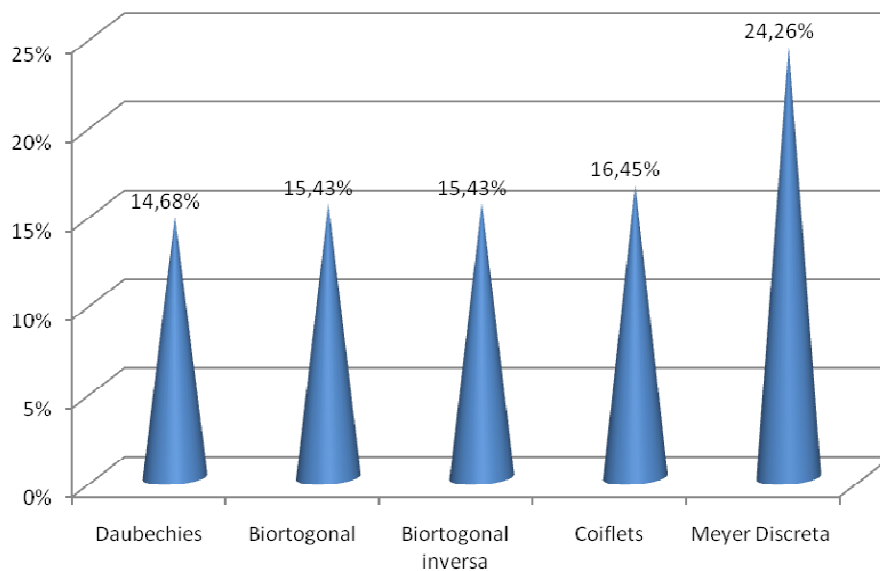
Figura 4.1 Porcentaje de error para los índices cromáticos



En vista de los resultados mostrados en esta figura se pueden deducir dos evidencias. Primera, que el índice cromático basado en el índice vegetativo es el que genera los peores resultados, mientras que los demás métodos producen resultados satisfactorios, obteniendo un porcentaje de error que varía entre el 14% y 22%. La segunda deducción es que el índice cromático que mayores aciertos consigue es el *ExG*, con un 14.19% bajo el método de descomposición y fusión propuesto en este trabajo. Esta constatación también se puede comprobar observando la figura 3.3, donde se ve claramente que las imágenes con mayor grado de contraste son las de los índices cromáticos *ExG* y *ExGR*, mientras que con el índice vegetativo *VEG* la imagen no tiene suficiente contraste.

El siguiente paso a realizar consiste en determinar cuál puede ser la mejor familia de wavelets con la que trabajar. Para esto, una vez obtenida la imagen *ExG*, realizamos la descomposición mediante la transformada de wavelets aplicando diferentes familias, concretamente: Daubechies, Biortogonal, Biortogonal inversa, Coiflets, y Meyer Discreta. Estas familias han sido elegidas por ser las más conocidas y ampliamente utilizadas en la literatura. Los resultados se muestran en la figura 4.2.

Figura 4.2 Porcentaje de error de índices cromáticos



De esta figura se puede deducir claramente que la menor tasa de error se produjo con la familia Daubechies, con un 14.68% de error, y la mayor con la Meyer Discreta, con un 24.26%

de error. Estos valores confirman que para este tipo de imágenes agrícolas el filtro paso-alto de la familia Daubechies es capaz de capturar con bastante eficiencia el contenido de alta frecuencia asociado con las texturas vegetales.

4.3. Imágenes utilizadas

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 con el fin de realizar diferentes experimentos 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 1152×864 píxeles y 800×600 , respectivamente, guardándolas en el modelo de color RGB (rojo, verde y azul) y en formato JPG. Las imágenes han sido procesadas con los toolboxes Image Processing y Wavelets de Matlab R2010a (The MathWorks, 2011) específicos para el tratamiento de imágenes y wavelets respectivamente. El conjunto de imágenes que finalmente se ha procesado está formado por 240 imágenes.

4.4. Resultados de la descomposición mediante wavelets

A continuación se sintetiza el proceso seguido junto con los resultados obtenidos a modo de resumen del procedimiento propuesto.

Las imágenes agrícolas reales fueron tratadas de distintas maneras para obtener la menor tasa de error posible. Se hizo una segmentación de las partes verdes mediante cuatro métodos distintos, *ExG*, *ExGR*, *CIVE* y *VEG*, y se pudo comprobar que los mejores resultados se obtenían con el índice cromático de extracción de verdes, *ExG*. Después se prosiguió con la comprobación de las siguientes familias wavelets: Daubechies, la Biortogonal, Biortogonal inversa, Coiflets y

Meyer Discreta. Los mejores resultados se han obtenido con la descomposición mediante la familia Daubechies.

Una vez obtenidos estos resultados y pudiendo elegir tanto qué índice cromático utilizar para extraer los verdes en una primera aproximación, así como la familia a usar en la descomposición, se realizó un estudio de los resultados sobre un conjunto de imágenes con el fin de verificar la validez y eficacia del método propuesto.

A partir de la descomposición de la imagen *ExG*, mediante la familia Daubechies, se recorre tanto los coeficientes de aproximación como los tres de detalles, abriendo ventanas de 5x5 píxeles. Una alta variabilidad de los píxeles en la ventana es indicativa de la presencia de una textura vegetal. Dicha variabilidad se calcula a través de la desviación estándar y se determina que es alta en función de un valor de umbral que se establece en base a distintas pruebas de ensayo y error, fijándose finalmente en el valor de 0.06 en cualquiera de los coeficientes de detalle. Si se supera dicho valor en cualquiera de las ventanas de los coeficientes de detalle el píxel central de esta ventana en los coeficientes de aproximación *CAExG*, es sustituido por el valor *a* (ecuación 3.16). En esto consiste realmente el proceso de fusión planteado en este trabajo. De esta manera obtenemos una imagen cuya calidad ha sido mejorada, ya que se logra obtener contrastes mayores.

Por tanto, las pruebas para verificar el comportamiento de la propuesta formulada se realizan comparando las soluciones proporcionadas al realizar la binarización, tanto con el método que hemos propuesto, como con los umbrales de Otsu y de la media. 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 4.3 es una de las imágenes del conjunto “ground-truth” obtenida a partir de la imagen original mostrada en la figura 3.1 (a) siguiendo el procedimiento anteriormente descrito.

Figura 4.3 Ground-truth



En la figura 4.4 se pueden observar los resultados del porcentaje de error en la binarización con el método de Otsu, la media y con la descomposición de wavelets descrita previamente. Para este estudio se han seleccionado 10 imágenes representativas del conjunto de imágenes disponibles. La tasa de error de las imágenes analizadas dependía sobre todo de la iluminación en el momento de su adquisición. Las imágenes que más error mostraron fueron las que contenían abundantes sombras, ya que en tales casos el verde oscuro de la sombra se confundía con el suelo, y viceversa. Las imágenes con menor tasa de error fueron aquellas tomadas en momentos de iluminación moderadamente alta, ya que no producían sombras tan acentuadas y en tal caso se podían distinguir las texturas.


Figura 4.4 Comparación del porcentaje de error de mediante wavelets, media y Otsu




Como se puede ver en esta gráfica, los mejores resultados se obtienen con el método propuesto basado en la descomposición mediante wavelets.

Las siguientes imágenes muestran la segmentación realizada con los resultados obtenidos mediante la fusión. Como se puede apreciar, las zonas de verdes y de suelo han sido segmentadas obteniendo resultados bastantes favorables.

Figura 4.5 Clasificación de diferentes imágenes agrícolas según el método propuesto





Tal y como se puede apreciar en estas imágenes, la segmentación obtenida se ajusta bastante a la realidad. La extracción de verdes de la imagen conserva tanto las zonas de cultivo como las malas hierbas, lo cual nos permite un acercamiento a la agricultura de precisión. Al conseguir separar de manera fiable los verdes de la imagen facilitamos el tratamiento de los cultivos, consiguiendo así el objetivo propuesto en este trabajo.

Capítulo 5 - Conclusiones y trabajo futuro

5.1 Introducción

Este capítulo pretende concluir el trabajo realizado en esta investigación. Se hace mención de los métodos utilizados y de los objetivos señalados para cada uno de ellos, presentando las conclusiones que hemos obtenido a lo largo de la investigación realizada. Finalmente se exponen las distintas líneas que se podrían englobar como trabajo futuro.

5.2 Conclusiones

En los campos de cultivo cada vez se opta más por automatizar las distintas tareas que han de ser llevadas a cabo. Una de estas tareas es la aplicación de pesticidas, herbicidas y productos químicos de forma selectiva para evitar su aplicación de forma indiscriminada a todo el campo de cultivo. La solución basada en aplicaciones no selectivas no resulta eficaz, tanto por el elevado coste que supone dispersar la sustancia sin diferenciar si es necesaria o no, desde el punto de vista del medio ambiente, puesto que dichos productos no son componentes saludables ni beneficiosos para la naturaleza en general.

El objetivo principal de esta investigación es tratar de encontrar una solución más efectiva en el tema de reconocimiento de texturas, concretamente aplicado en reconocimiento de texturas vegetales en un campo agrícola. De esta manera, un robot automatizado equipado con cámaras de visión artificial podrá tomar imágenes del campo, analizarlas diferenciando texturas pertenecientes al suelo de entre las correspondientes a la cubierta vegetal, y aplicando tratamientos selectivos allí donde sea necesario, tal y como establecen los criterios basados en Agricultura de Precisión.

Con ese fin, se tomaron imágenes de un campo de cultivo y se inició la investigación. Se empezó revisando los métodos existentes en la literatura en busca de técnicas aplicables al caso que nos ocupa. Una vez hecho esto, se diseñó una estrategia supuestamente más eficaz para abordar el problema, basada en una técnica de fusión mediante la transformada de wavelets. El hecho de llegar a una descomposición de la imagen con wavelets a nivel vertical, horizontal y diagonal, permite el análisis píxel a píxel, comparándolos con la imagen original y generando una imagen fusionada con mayor contraste.

Finalmente, se hicieron pruebas con los métodos existentes – el método de Otsu y la media – y con las imágenes tratadas con wavelets, realizando una comparación entre estos métodos.

Al completar el análisis de las pruebas, la primera conclusión que se puede hacer constar es que existe una mejora sustancial entre las imágenes tratadas con la transformada de wavelets y las imágenes simplemente sometidas a los métodos de binarización de Otsu y de la media. También se puede observar en el capítulo anterior que las imágenes a las que se les ha aplicado la transformada de wavelets han resultado ser imágenes con más diferencia en los niveles de gris entre las partes verdes (malas hierbas y cultivo) y el resto de la imagen (suelo o cielo). Esto ha llevado a que, una vez realizada la binarización, ésta haya resultado más eficaz que las imágenes no tratadas por wavelets.

En concreto, las imágenes a las cuales se les ha aplicado la transformada de wavelets muestran una tasa de error media de 16.67%, mientras que en las que no se ha aplicado wavelets y sólo binarización mediante Otsu presentan un error medio de 19.48%, lo que supone un incremento de casi el 3%, mientras que con la binarización mediante la media se obtuvo un resultado de error medio de 21.94%, que supone más de un 5% de incremento con respecto a las imágenes tratadas con wavelets.

Esto se puede atribuir a la naturaleza de la transformada de wavelets. Al hacer el primer paso de la descomposición se obtienen imágenes con los coeficientes de aproximación y los de detalles verticales, horizontales y diagonales realzados. La idea de este trabajo ha sido recorrer los coeficientes de detalle en ventanas de 5x5 píxeles para calcular la desviación estándar del píxel central en relación a los píxeles del resto de la ventana. Si el valor de la desviación del píxel en cualquiera de los coeficientes de detalle sobrepasaba el umbral establecido, el valor del píxel en los coeficientes de aproximación era sustituido por a (ecuación 3.16). De esta manera, debido a la mejora de los coeficientes de aproximación, al realizar la fusión de la imagen se obtuvo una imagen más precisa y con detalles realzados.

Otra conclusión a la que se puede llegar es cuando se comparan las imágenes tomadas en días de sol fuerte, con mucha iluminación, con las tomadas en momentos con poca iluminación, como en el caso de días nublados o al atardecer. Se puede observar que las últimas muestran resultados con más tasa de error que los resultados de las imágenes tomadas en momentos de iluminación buena. Es más, la tasa de error media sube del 13.83% al 20.93% con las imágenes

en las que fue aplicada la transformada wavelets, de 15.70% a 25.15% con las imágenes binarizadas con el método de Otsu y de 17.06% a 29.27% en las imágenes binarizadas con la media. Estos cambios en las tasas de error, proporcionales independientemente del método utilizado, fueron los esperados, ya que las imágenes con poca luminosidad se encuentran poco saturadas, lo que significa que los colores no manifiestan una diferenciación importante entre sí, y los métodos utilizados se basan en la diferenciación de texturas precisamente por color.

5.3 Trabajo futuro

De esta investigación surgen varias líneas de investigación posibles.

- 1) Debe continuarse la investigación sobre la base de búsqueda de métodos capaces de capturar la variabilidad de las texturas vegetales probablemente diferentes a los estadísticos, como el propuesto en este trabajo.
- 2) Otra de las ideas a desarrollar dentro de la descomposición de wavelets sería el estudio de diferentes familias, para analizar diferentes comportamientos en las imágenes agrícolas.
- 3) Como métodos de descomposición multiresolución se pueden investigar otros tales como los filtros de Gabor o las descomposiciones piramidales

Bibliografía

- Bossu, J., Gée, Ch., Jones, G. y Truchetet, F. (2009). Wavelet transform to discriminate between crop and weed in perspective agronomic images. En: *Computers and Electronic in Agriculture*, pp. 133-143.
- 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.
- Cheng, H.D., Jiang, X.H., Sun, Y. and Wang, J., (2001). Color image segmentation: advances and prospects. *Pattern Recognition* 34 (12), 2259–2281.
- Daubechies, I., 1992. *Ten Lectures on Wavelets*. SIAM, Philadelphia, PA, USA.
- 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>).
- 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.
- Garguet-Duport, B., Girel, J., Chassery, J. and Pautou, J. G. (1996). The use of Multiresolution Analysis and Wavelets Transform for Merging SPOT Panchromatic and Multispectral Image Data. En: *Photogrammetric Engineering and Remote Sensing* 62(9),pp. 1057-1066.
- Gebhardt, S., Käuhbauch, 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.
- Gée, Ch., Bossu, J., Jones, G., Truchetet, F. 2008. Crop/weed discrimination in perspective agronomic images. *Computers and Electronics in Agriculture* 60, 49-59.
- Guijarro, M. Pajares, G., Riomoros I., Herrera, P.J., Burgos-Artizzu, X.P. y Ribeiro, A. (2010). Automatic segmentation of relevant textures in agricultural images. En: *Computers and Electronics in Agriculture*, Volumen 75, Edición 1, pp. 75-83

- Hague, T., Tillet, N.D, 2001. A bandpass filter-based approach to crop row location and tracking. *Mechatronics* 11, 1–12.
- Hague, T., Tillet, N., Wheeler, H. 2006. Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture*, 1(1), pp. 95–113.
- Hemming, J., Rath, T., 2001. Computer and vision-based weed identification under field conditions using controlled lighting. *J. Agric. Eng. Res.* 78, 233–243.
- Ishak, A. J., Hussain, A., Mustafa, M.M. (2009). Weed image classification using Gabor wavelet and gradient field distribution. En: *Computers and Electronics in Agriculture*, Volumen 66, Edición 1, pp. 53-61
- Jones, G., Gée, C., Truchetet, F., 2007a. Crop/weed discrimination in synthetic agronomic images. In: *Proc. IS&T/SPIE 19th Annual Symposium on Electronic Imaging Science and technology—“Image Processing: Algorithms and Systems VI”*, vol. 6497, San Jose, CA, USA.
- Jones, G., Gée, C., Truchetet, F., 2007b. Simulation of agronomic images for an automatic evaluation of crop/weed discrimination algorithm accuracy. In: *Proceedings of 8th international conference on Quality Control by Artificial Vision (QCAV)*, SPIE, vol. 6356, Paper No. 33, Le Creusot, Fr.
- Jui Jen Chou, Chun Ping Chen, Joannie T. Yeh (2007). Crop identification with wavelet packet analysis and weighted Bayesian distance, En: *Computers and Electronics in Agriculture*, Volumen 57, Edición 1, pp. 88-98, ISSN 0168-169
- Kataoka, T., Kaneko, T., Okamoto, H., Hata, S., (2003). Crop growth estimation system using machine vision. En: *The 2003 IEEE/ASME Internat. Conf. on Advanced Intelligent Mechatronics*.
- 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.
- 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

- Li, H., Manjunath, B.S. and Mitra, S.K. (1995). Multisensor Image Fusion Using the Wavelet Transform. *Graphical Models and Image Processing* 57(3), pp. 235-245.
- Mallat, S., 1989a. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE PAMI* 11, 69–87.
- Mallat, S., 1989b. Multiresolution approximations and wavelet orthonormal bases of $L_2(\mathbb{R})$. *Trans. Am. Math. Soc.* 315, 69–87.
- Mallat, S., 1989c. Multifrequency channel decomposition of images and wavelet models. *IEEE Trans. Accoustic Speech Signal Proc.* 37, 2091–2110.
- Mehmet S. y Bülent S. (2004). Survey over image thresholding techniques and quantitative performance evaluation. En: *J. Electron. Imaging* 13, 146
- Método del valor umbral. http://es.wikipedia.org/wiki/M%C3%A9todo_del_valor_umbral
- Meyer, Y., 1990. *Ondelettes et Opérateurs I-Ondelettes*. Hermann, Paris.
- Meyer, G.E., Hindman, T.W., Lakshmi, K., 1998. *Machine Vision Detection Parameters for Plant Species Identification*. SPIE, Bellingham, WA.
- 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.
- 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.
- Meyer, G., Metha, T., Kocher, M., Mortensen, D., Samal, A., 1998. Textural imaging and discriminant analysis for distinguishing weeds for spot spraying. *T. ASAE* 41 (4), 1189–1197.
- 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.
- Otsu, N. (1979). A threshold selection method from gray-level histogram. *IEEE Trans. System Man and Cybernetics* 9, pp. 62-66.

- Pajares, G. y 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
- Pajares, G. and Cruz, J.M. (2007). Visión por Computador: Imágenes Digitales y Aplicaciones, RA-MA, Madrid.
- Ranchin, T. y Wald, L. (2000). Fusion of High Spatial and Spectral Resolution Images: The ARSIS Concept and its Implementation. En: Photogrammetric Engineering and Remote Sensing, 66(1), pp. 49-61.
- Reid, J., Searcy, S. (1987). Vision-based guidance of an agriculture tractor. En: Control Systems Magazine, IEEE, Volumen 7, Edición 2, pp. 39-43.
- 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), pp. 169–174.
- Rovira-Mas, F., Zhang, Q. Reid, J.F. (2008) Stereo vision three-dimensional terrain maps for precision agriculture. computers and electronics in Agriculture, 60, 133-143.
- Tellaache, 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.
- Tellaache, 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.
- Teoría de wavelets.
http://catarina.udlap.mx/u_dl_a/tales/documentos/lem/hernandez_d_m/capitulo2.pdf
- TheMathworks (2011). <http://www.mathworks.com/>
- Wobbecke, D.M., Meyer, G.E., von Bargen, K. and Mortensen, D.A. 1995. Shape features for identifying young weeds using image analysis. Trans. Am. Soc. Agric. Eng. 38 (1), 271–281.

- Zhang, Z. y Blum, R.S. (1999). A categorization of Multiscale-Decomposition-Based Image Fusion Schemes with a Performance Study for a Digital Camera Application. En: Proceedings of the IEEE, 87(8),pp 1315-1326.
- Zheng, L. Shi, D., Zhang, J. (2010). Segmentation of green vegetation of crop canopy images based on mean shift and Fisher linear discriminate. En: Pattern Recognition Letters
- 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.