



Máster en Ingeniería de Sistemas y Control

***Identificación de texturas vegetales en imágenes
agrícolas mediante el Análisis de Componentes
Principales.***

Alumno:

Jairo Ruiz Seco

Directores:

María Guijarro Mata-García

Martin Montalvo Martínez

Curso académico 2014/2015: Convocatoria de Junio

Máster en Ingeniería de Sistemas y Control

***Identificación de texturas vegetales en imágenes
agrícolas mediante el Análisis de Componentes
Principales.***

Proyecto Tipo A: Proyecto específico propuesto por un profesor

Alumno: Jairo Ruiz Seco

Directores: María Guijarro Mata-García / Martin Montalvo Martínez

Autorización

Autorizamos a la Universidad Complutense y a la Universidad Nacional de Educación a Distancia a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a sus autores, tanto la memoria de este Trabajo Fin de Máster, como el código, la documentación y/o el prototipo desarrollado.

Firmado: Jairo Ruiz Seco

A handwritten signature in blue ink, consisting of several loops and strokes, positioned above the text 'Firma del alumno'.

Firma del alumno

A Ana y al resto de mi familia por todos los ánimos que me han dado.

Agradecimientos

A María Guijarro y Martín Montalvo por toda la ayuda y atención prestadas durante estos meses para poder hacer este proyecto posible.

Resumen

El presente proyecto se encuentra enmarcado en el campo de la Visión por Computador y más concretamente en el área de la identificación de regiones aplicándose al mundo de la agricultura de precisión donde cada vez más los sistemas autónomos están reemplazando a las personas.

El objetivo principal del proyecto es mejorar la identificación de las zonas correspondientes a vegetación en imágenes correspondientes a campos de cultivo, las imágenes no proporcionan ninguna información por si solas y han de ser procesadas para obtener la información buscada.

La principal utilidad de la identificación de zonas de vegetación en imágenes de campos de cultivo es optimizar el uso de los recursos (fitosanitarios, abonos...) administrándolos tan solo en las zonas necesarias, en las dosis necesarias y reduciendo de esta manera el impacto ecológico de su utilización, mejorar la extracción y eliminación de plantas no deseadas (pueden restar horas de sol y nutrientes en los cultivos), hacer un uso más racional del agua, optimizar la recolección y en definitiva reducir los gastos de producción e incrementar los ingresos al obtener mejores cosechas que es el objetivo de cualquier negocio.

Se hará uso de una combinación de técnicas para poder identificar las texturas vegetales presentes en imágenes procedentes de campos agrícolas. Estas técnicas son la obtención de los índices vegetativos de la imagen, su reducción mediante el uso de un análisis de componentes principales y la posterior umbralización de la imagen resultante de considerar únicamente el autovector de mayor valor.

Palabras clave

Visión por computador, Agricultura de precisión, Análisis de componentes principales, Índices vegetativos, Umbralización, Extracción de regiones, Realce.

Abstract

This project belongs to the field of Computer Vision and more specifically to the area of extraction of regions, being applied to the world of precision farming, where autonomous systems are replacing people.

The main objective of this project is improving the identification of areas belonging to vegetation in crop fields. The pictures do not provide any information by themselves and must be processed to obtain the information we need.

The primary use of green zones identification in crop fields is the optimization of resources (pesticides, fertiliser...) by administering them just in the necessary places thus reducing the ecological impact of its utilisation, improving the extraction and elimination of weeds (they hide the crops from the sun and use their nutrients), making a rational use of water, optimising harvesting, and definitely, reducing costs and increasing incomes by obtaining better harvestings, which is the main reason for any business.

A combination of various techniques will be carried out to be able to identify vegetation textures in pictures proceeding from farming fields. These techniques are the calculation of the vegetative indexes from the image, their dimensionality reduction by using a principal component analysis and the subsequent thresholding of the result associated to the main eigenvector.

Keywords

Computer vision, Precision agriculture, Precision Farming, Principal component analysis, Vegetative index, Thresholding, Region extraction, Enhancement.

Índice

1.	Introducción	11
1.1.	Descripción del problema.	11
1.2.	Objetivos.	13
1.3.	Organización de la memoria	13
2.	Estado del arte	15
2.1.	Agricultura de precisión.	15
2.2.	Índices Vegetativos	16
2.3.	Análisis de componentes principales (PCA).	17
2.4.	Umbralización.	18
3.	Revisión de los métodos utilizados	20
3.1.	Introducción	20
3.2.	Índices vegetativos.	20
3.2.1.	Normalización del espacio de color.	20
3.2.2.	Excess Green (ExG).	21
3.2.3.	Excess Red (ExR).	21
3.2.4.	Excess green minus excess red (ExGR).	21
3.2.5.	Color Index of Vegetation Extraction (CIVE).	21
3.2.6.	Vegetative (VEG).	21
3.2.7.	Normalized difference index (NDI).	22
3.2.8.	Combined approach (COM):	22
3.2.9.	Resultados de la obtención de los índices.	22
3.3.	Análisis de componentes principales (PCA).	23
3.4.	Método de Otsu	26
4.	Aportación	31
4.1.	Acondicionamiento de la imagen.	32
4.2.	Obtención de índices.	33
4.3.	Acondicionamiento de índices.	34
4.4.	Cálculo de componentes principales.	36

4.5.	Recuperación de la imagen original	39
4.5.1.	Recuperación a partir del mayor autovector.	40
4.5.2.	Recuperación a partir de los tres mayores autovectores.	41
4.6.	Umbralizado mediante Otsu.	43
5.	Resultados y conclusiones.....	48
5.1.	Objetivo	48
5.2.	Descripción de las imágenes utilizadas.	49
5.3.	Metodología utilizada.	50
5.4.	Comparativa de resultados	51
5.5.	Conclusiones.....	55
6.	Trabajo futuro	56
	Bibliografía	58
	Listado de acrónimos	64

Índice de Figuras

<i>Fig. 1: Variación del índice NDVI entre los meses de junio (a) y octubre (b) de 2003 en las Islas Británicas.</i>	16
<i>Fig. 2: Imagen original(a), ExG (b) y ExGR (c), CIVE (d), NDI (f) y VEG (g).</i>	23
<i>Fig. 3: Conjunto de datos original.</i>	24
<i>Fig. 4: Conjunto de datos eliminando el valor medio de cada componente.</i>	24
<i>Fig. 5: Primera componente principal (azul) superpuesta a los datos originales (rojo).</i>	25
<i>Fig. 6: Imagen en grises (a) y resultado de umbralizar con Otsu (b).</i>	28
<i>Fig. 7: Histograma de la imagen en grises y umbral marcado en rojo de Fig. 6.</i>	29
<i>Fig. 8: Imagen en grises con mucha variación de luz (a) y resultado de umbralizar con Otsu (b).</i>	29
<i>Fig. 9: Histograma de la imagen en grises y umbral marcado en rojo de Fig. 8.</i>	30
<i>Fig. 10: Esquema general del sistema propuesto.</i>	31
<i>Fig. 11: Esquema de acondicionamiento de imagen.</i>	32
<i>Fig. 12: Imagen original (a) y resultado de normalizar las componentes (b).</i>	33
<i>Fig. 13: Procedimiento para la obtención de cada uno de los índices vegetativos necesarios.</i>	33
<i>Fig. 14: Imagen original (a) e índices ExG (b), ExGR (c), CIVE (d), NDI (e) y VEG (f).</i>	34
<i>Fig. 15: Esquema para el acondicionamiento de los índices vegetativos.</i>	35
<i>Fig. 16: Esquema para la obtención de las componentes principales.</i>	36
<i>Fig. 17: Serie de imágenes utilizadas para calcular las componentes principales.</i>	38
<i>Fig. 18: Esquema de la obtención de la imagen de grises a partir de las componentes principales.</i>	39
<i>Fig. 19: Imagen de grises PCA (a) e imagen grises COM (b) de Fig. 17 (a).</i>	40
<i>Fig. 20: Imagen grises PCA (a) e imagen grises COM (b) de Fig. 17 (b).</i>	41
<i>Fig. 22: Imágenes de grises procedentes de las tres primeras componentes principales (a), (b) y (c) de Fig. 17 (b).</i>	42
<i>Fig. 23: Imágenes de grises procedentes de las tres primeras componentes principales (a), (b) y (c) de Fig. 17 (g).</i>	42
<i>Fig. 24: Imagen binaria COM (a) y PCA (b) de de Fig. 17 (a).</i>	43
<i>Fig. 25: Aplicación de máscara binaria (a), (c) y máscara binaria negada (b), (d) procedente de imagen COM (Fig. 24 (a)) e imagen PCA (Fig. 24 (b)) sobre la imagen original (Fig. 17 (a)).</i>	44
<i>Fig. 26: Imagen binaria COM (a) y PCA (b) de Fig. 17 (b).</i>	45
<i>Fig. 27: Arriba: Diferencias en zona inferior derecha (Original (a), COM (b) y PCA (c)) – Abajo: Diferencias en zona media derecha (Original (d), COM (e) y PCA (f)) de de Fig. 17 (b).</i>	46
<i>Fig. 28: Arriba: Diferencias en zona superior izquierda (Original (a), COM (b) y PCA (c)) – Abajo: Diferencias en zona central (Original (d), COM (e) y PCA (f)) de de Fig. 17 (b).</i>	46
<i>Fig. 29: Imagen binaria COM (a) y PCA (b) de Fig. 17 (i).</i>	47
<i>Fig. 30: Detalle de zona inferior central para imagen binaria de COM (a) y de PCA (b) de la Fig. 17 (i).</i>	47
<i>Fig. 31: Imagen completa (a) y subimagen (b) utilizadas en el análisis.</i>	50

1. Introducción

1.1. Descripción del problema.

Vivimos en una época en la que el número de tareas que son llevadas a cabo por sistemas autónomos es cada vez mayor. Desde la gestión de mercancías en almacenes o el transporte de pasajeros entre diferentes terminales de aeropuertos, hasta la recolección de frutas y verduras pasando por la limpieza de casa o la clasificación de objetos defectuosos en una cadena de producción de cualquier tipo de industria.

Cualquiera de las tareas identificadas en el párrafo anterior lleva implícito el uso e integración de la información procedente de una gran diversidad de sensores que proporcionan medidas de todo tipo (temperatura, velocidad, posición, orientación, etc.), pero todas ellas tienen algo en común, proporcionan un valor exacto que mide la magnitud deseada.

Sin embargo, las imágenes procedentes de cámaras no dan ninguna información por sí mismas sino que necesitan una interpretación. Para una persona puede resultar sencillo, en condiciones normales, al ver una imagen determinar si existen patrones de formas, colores, contar objetos, decir a qué tipo de elementos corresponde cada región o simplemente determinar si en la imagen hay una persona e identificarla de entre una lista de candidatos. El problema es que para automatizar algo así han de buscarse herramientas que mediante cálculos y modificaciones de la imagen permitan realzar los rasgos que se deseen extraer o cuantificar.

Es en el mundo de la agricultura de precisión donde se encuentra enmarcado este proyecto, siendo posible extrapolar estas ideas a otras aplicaciones. Se dispone de una serie de imágenes con características diferentes (contenidos, iluminación, dimensiones, etc.) con las que se trabajará de modo que la metodología aplicada sea agnóstica en este aspecto y pueda ser capaz de funcionar en el mundo real y no solo en las simulaciones hechas en un ordenador. Para entender mejor el problema hay que comprender lo que es la agricultura de precisión.

Según IBM [1], la agricultura de precisión consiste en dejar de ejecutar las tareas como la siembra o la recolección según un calendario que varía de una regiones a otras y pasar a hacerlo analizando datos recolectados en tiempo real y procedentes del clima, calidad del suelo y del aire, madurez de los cultivos incluso de disponibilidad y precio de equipamiento consiguiendo de este modo tomar decisiones más inteligentes.

Otras tareas que se ejecutan solo cuando es necesario con la agricultura de precisión, y no de manera sistemática tal y como se hace en la agricultura tradicional, son las de fertilización, riego y fumigado. Todas estas tareas junto con la de recolección, anteriormente mencionada, hacen uso de los índices vegetativos para determinar la situación de la cosecha. Así, en una cosecha que esté aun creciendo y comience a mostrar zonas marrones se puede indicar la falta de riego o la presencia de algún tipo de hongo o bacteria.

Mientras que en la agricultura tradicional el agricultor fumigaría sistemáticamente todos los años para evitar la incidencia de enfermedades habituales en sus cultivos y en tipos de agricultura más modernos (y a menor escala) como la agricultura orgánica el agricultor inspeccionaría visualmente los cultivos in situ, en la agricultura de precisión se puede confiar en las imágenes, tomadas por satélites, avionetas o cualquier vehículo autónomo, y su posterior tratamiento para extraer los índices vegetativos, dando la posibilidad de este modo a analizar la situación en la que se encuentra el cultivo.

Entre los grandes problemas a los que se intenta hacer frente a través de la implantación de la agricultura de precisión está el de la sobreexplotación de los recursos hídricos. Por ejemplo el estado de California, uno de los mayores productores de frutas y verduras de EE.UU, está pasando los últimos años por una de las mayores épocas de sequía de las que se tienen registros. Además de la falta de agua procedente de las lluvias se están enfrentando a otro gran problema, como es el exceso de uso de los acuíferos subterráneos, lo que está haciendo que grandes extensiones de terreno se hundan literalmente, de hecho en algunos lugares, este hundimiento del terreno es tal que algunos puentes están llegando a destruirse al igual que carreteras y canales de riego. El adoptar la agricultura de precisión implicaría abandonar modelos tradicionales de riego como el riego por inundación y pasar a utilizar otros tipos de riego como el riego por goteo asistidos por los datos proporcionados por sistemas inteligentes que evalúen las condiciones del suelo y la planta para decidir el tiempo de activación y la duración del periodo de riego.

Otro de los problemas a los que se intenta hacer frente con el uso de la agricultura de precisión es al uso abusivo e indiscriminado de pesticidas. Algunos estudios [2], [3], [4] asocian el alto descenso en la población mundial de abejas al uso de ciertos tipos de pesticidas y sustancias químicas. Este descenso de población es un dato muy alarmante puesto que las abejas cumplen un papel clave en la polinización de los cultivos, valorándose la tarea que llevan a cabo en 153000 millones de euros anuales en todo el mundo. Mediante un uso más

racional de pesticidas y otros químicos apoyados por la implantación de la agricultura de precisión podría evitarse la catástrofe que supondría este problema.

El tercer gran problema contra el que se pretende luchar con este tipo de agricultura es el del hambre. Una explotación óptima del suelo se traduce en mejores rendimientos en las cosechas tanto por hacer las aportaciones de agua y nutrientes en el momento necesario como por poder atajar las plagas cuando comienzan a atacar al cultivo y no cuando puede ser demasiado tarde. Si bien es cierto que este puede ser uno de los puntos más difíciles de cumplir dados los problemas de implantar estos tipos de tecnología en países pobres por sus costes, sí que es cierto que mediante la investigación y el desarrollo se pueden llegar a conseguir mejoras que impliquen reducciones de los costes de implantación, haciendo estas técnicas accesibles a un mayor número de personas.

1.2. Objetivos.

El objetivo principal del proyecto se centra en la extracción de las zonas verdes de la imagen, separándolas del suelo y del resto de elementos presentes en la escena y carentes de interés. Bajo este fin se ha realizado un estudio de la literatura en la que se describen las diferentes técnicas utilizadas. El primer paso a realizar será el análisis de los distintos índices vegetativos que dan como resultado una imagen en escala de grises, en la que se realzan las partes verdes, y con la que posteriormente se aplicará sobre ellos el análisis de las componentes principales (PCA's). La utilización de las componentes principales permitirá reducir la dimensionalidad de los datos y conseguir realzar las zonas correspondientes a vegetación, ofreciendo una mejora con respecto a los métodos estudiados y publicados, para después poder aplicar algoritmos de umbralización.

1.3. Organización de la memoria

La memoria de este proyecto está organizada tal y como se describe a continuación:

- **Capítulo 1:** Se describe el problema a la hora de utilizar imágenes para extraer información de las escenas que registran y por qué este problema no se da en otro tipo de sensores; seguidamente se explica de manera breve lo que es la agricultura de precisión sus beneficios y por qué es importante su adopción por parte de los agricultores, tanto a pequeña escala como a gran escala. Finalmente se indican los objetivos de este proyecto.

- **Capítulo 2:** Se hace un breve recorrido por el estado del arte de los temas que se tratan en el proyecto. Esto incluye el mundo de la agricultura de precisión, cada vez más importante por el ahorro en costes y el beneficio medioambiental que proporciona. Se analizarán los trabajos publicados acerca de los índices vegetativos y sus actuales usos, así como aquellos relacionados con el análisis de las componentes principales. Finalmente se estudiarán trabajos relacionados con la umbralización y algunos de sus usos.
- **Capítulo 3:** Se hace una descripción detallada de lo que son los índices vegetativos y se indica el modo en que se obtienen los índices empleados en este trabajo. Seguidamente se muestran los resultados de su aplicación a una imagen de un campo de cultivo. Mostrar gráficamente el resultado de aplicar los índices de vegetación se explica en qué consiste el análisis de componentes principales de un conjunto de datos y como se aplica a imágenes. El último apartado de este capítulo es una explicación del método de Otsu, un algoritmo de umbralización muy utilizado para binarizar imágenes en otros trabajos del campo de la agricultura de precisión.
- **Capítulo 4:** En este capítulo se describe la aportación que se hace con este trabajo y se muestran los resultados que se obtienen de su aplicación. Se compararán con los proporcionados por el índice COM, ya que es un índice parecido que proporciona mejores resultados que los índices individuales al ser una combinación de ellos.
- **Capítulo 5:** En el quinto capítulo se muestran las conclusiones a las que se llega y un análisis de los resultados obtenidos con la técnica propuesta a través de una comparativa previa con el resto de índices utilizados en el trabajo y de un análisis individual más exhaustivo.
- **Capítulo 6:** En este último capítulo se explican las debilidades que presenta la técnica basada en el análisis de componentes principales para trabajar sobre ellas y así obtener unos mejores resultados. Finalmente se plantean varias líneas de trabajo futuro diferentes.

2. Estado del arte

En este apartado se realizará el estudio de las técnicas utilizadas en el análisis de imágenes agrícolas que se encuentran expuestas en la literatura. Comenzaremos este estudio viendo publicaciones donde se trata el tema de la agricultura de precisión y después se pasará a ver referencias sobre los índices vegetativos, para finalizar con los trabajos que hacen referencia al análisis de componentes principales en el mundo de la agricultura de precisión.

2.1. Agricultura de precisión.

Existen multitud de trabajos de diversos autores que demuestran los beneficios del uso de la agricultura de precisión en la evaluación de las necesidades de la cosecha, el impacto de ésta sobre el entorno, la reducción de costes o las predicciones sobre la evolución del cultivo.

Los beneficios de la utilización de sistemas de información geográfica (GIS) y sistemas de posicionamiento global (GPS) sobre pequeños campos de cultivo de algodón en la India, son manifestados en [5], mostrando al final un pequeño estudio del coste de instalación de una red DGPS (GPS diferencial) para la India como un primer paso para ayudar a los pequeños productores a mejorar sus resultados.

En el trabajo desarrollado en [6] se hace uso de la agricultura de precisión para obtener múltiples datos de las etapas de crecimiento de cultivos de algodón y hacer una predicción del rendimiento de la cosecha a través de regresiones lineales de diferentes indicadores del cultivo.

En [7] evalúa mediante vehículos aéreos no tripulados (UAVs) el estrés hídrico en campos de cultivo a través de diferentes índices de reflectancia obtenidos mediante imágenes y correlando esos datos con parámetros relacionados con el estrés hídrico. Los autores de [8] hacen uso de las imágenes procedentes de varias fuentes para modelar los parámetros de evapotranspiración de un viñedo en Irán a través del índice NDVI [9]. Estos parámetros son fundamentales para evaluar las necesidades de riego de las plantas ya que dicen la cantidad de agua que estas pierden y que es necesario reponer.

Tal vez lo más complejo de la agricultura de precisión es lograr adaptar las granjas y campos de cultivo tradicionales a los requerimientos que este nuevo tipo de agricultura necesita. En [10] se hace un completo estudio de los patrones de adaptación dentro de la cadena de actores en el mundo de la agricultura (proveedores de maquinaria, de fertilizantes productores...), la estructura necesaria en las granjas (ya sean sus dimensiones físicas o el acceso a diferentes

servicios en sus comunidades) e incluso se establecen una serie de directrices para practicar la agricultura de precisión.

Uno de los cambios que se necesitan, tal y como se ve en los artículos de algunos autores, es el de dotar a la maquinaria de los sensores necesarios para poder llevar a cabo la tarea. En el caso de [11] el sensor es una cámara para adquirir las imágenes que posteriormente se tratarán para obtener la superficie cubierta por cultivo. Como se puede ver en [12] también se utilizará un sistema con una cámara incorporada para identificar las malas hierbas en una plantación de tomates. Por otro lado los autores de [13] incorporan a su sistema cámaras de visión para identificar las malas hierbas de los arcones de la autovía y así reducir la cantidad de herbicida necesario en su eliminación.

2.2. Índices Vegetativos

El campo de la teledetección ha utilizado durante años estos índices en imágenes procedentes de satélites para determinar las cubiertas vegetales de diferentes zonas del planeta. La primera vez que se utilizaron índices vegetativos fue con el lanzamiento del Landsat 1 en el año 1972 aunque previamente ya existían trabajos sobre este tema, como el de Jordan que definió el índice SR (Simple Ratio) [14] o Pearson y Miller que definieron el índice RVI [15]. Los índices vegetativos obtenidos con este satélite se utilizaron para estudiar la variación de la capa de vegetación de una estación a otra en la región de las Grandes Llanuras de los EE.UU.

Uno de los índices más utilizados según la Confederación Hidrográfica del Guadalquivir [16], es el NDVI [9]. Este índice al igual que el resto de los utilizados en teledetección hace uso de los datos procedentes de sensores no solo en el rango visible sino también en el infrarrojo tanto cercano como lejano. Los resultados que ofrece este índice se pueden ver en la siguiente figura en la que se muestra la variación del índice NDVI entre los meses de junio de 2003 y octubre de 2003 para las Islas Británicas.




Fig. 1: Variación del índice NDVI entre los meses de junio (a) y octubre (b) de 2003 en las Islas Británicas.

Sin embargo las imágenes que se van a utilizar en este proyecto proceden de cámaras industriales que tan solo registran la información procedente del espectro visible, por lo que los índices que se utilizarán tan solo tendrán en cuenta las componentes RGB para poder realzar las zonas verdes.

Yendo a los índices vegetativos que utilizan las componentes RGB para su obtención se pueden encontrar el ExG definidos por [17] y [18], en el primer caso para la extracción de características morfológicas a través de momentos invariantes de varios tipos de cultivos y en el segundo caso para identificación de zonas pertenecientes a cultivo, a mala hierba y a tierra. En [19] se propone una combinación del ExG y del índice ExR definido en [20] para la identificación y mapeado de diferentes especies de mala hierba, llamando a este índice ExGR. Por su parte [21] define el índice CIVE, para estimar el crecimiento de los cultivos (altura de la planta, tamaño de las hojas y cantidad de materia seca en la planta). El índice VEG definido por [11] se utiliza para evaluar las superficies ocupadas por cultivo y suelo en zonas donde los cultivos se encuentran ampliamente espaciados. Los autores de [22] utilizan una combinación de varios de los índices vistos en este párrafo (ExG, ExGR, CIVE y VEG) para obtener un índice mejorado que permite identificar las texturas vegetales con mayor precisión que el resto de índices de manera individual.

2.3. Análisis de componentes principales (PCA).

El análisis de componentes principales fue desarrollado por Pearson (1901) [23] y Hotelling (1933) [24] con el objetivo de encontrar una técnica estadística para simplificar un conjunto de datos. El principal objetivo del método [25] es reducir la dimensionalidad del conjunto de datos haciendo uso de un cambio de coordenadas. El procedimiento de cálculo es sencillo y tan solo requiere el cálculo de la matriz de covarianzas del conjunto de datos y posteriormente de los autovalores y autovectores de esta matriz.

Las componentes principales son una herramienta muy útil para el reconocimiento facial. A esta aplicación de las componentes principales se la conoce como eigenfaces (por el uso que hace de los autovalores y autovectores, en inglés eigenvalue y eigenvector) [26], en ella se parte de un conjunto de imágenes de caras a las que se aplica el análisis PCA para posteriormente, cuando se tenga una que se desee identificar, aplicar de nuevo las mismas operaciones y obtener la distancia euclídea. La menor distancia euclídea será la que indique a cuál de las imágenes originales es a las que más se parece la que se ha utilizado como entrada al proceso.

Esta técnica ya ha sido utilizada con anterioridad en el campo de la agricultura para tareas como por ejemplo en [27] donde se utiliza la técnica para distinguir plantas de arándano en imágenes de satélite, en [28] donde se utiliza para comprobar cambios en tierras destinadas a la agricultura o en [29] donde el análisis PCA se utiliza para diferenciar hojas de plantas de fresas a través de descriptores geométricos.

En este proyecto, el análisis de componentes principales se usará sobre imágenes al igual que en [27] y [28], pero en este caso no serán procedentes de satélites sino de una cámara de uso industrial, y en lugar de tener datos de múltiples bandas espectrales tan solo se tendrán para el espectro visible y se trabajará sobre las componentes RGB.

2.4. Umbralización.

La umbralización (thresholding en inglés) es un sencillo sistema de segmentación de imágenes que en su caso más elemental proporciona una imagen binaria. La finalidad es la de extraer ciertos objetos de la imagen y dejar de lado el resto.

Según [30] se puede dividir los métodos de umbralización en seis tipos básicos dependiendo en la información que maneje el algoritmo:

- Métodos basados en la forma del histograma (distribución de cada valor de gris): Se analizan, por ejemplo, los picos, valles y curvatura del histograma suavizado. En [31] se utiliza un análisis de concavidad del histograma como ayuda en la elección del umbral y en [32] se hace una búsqueda de los valles del histograma.
- Métodos basados en clustering: Se agrupan las muestras de gris en dos clases (primer y segundo plano) o bien se modelan como una mezcla de dos gaussianas. Por ejemplo el método de Otsu [33] o el algoritmo iterativo de Ridler-Calvard [34].
- Métodos basados en la entropía: Utilizan la entropía de la región en primer plano y de la región en segundo plano o la entropía cruzada entre la imagen original y la binarizada. En [35] y en [36] se pueden encontrar este tipo de métodos.
- Métodos basados en atributos de los objetos: Buscan similitudes entre las imágenes en grises y las imágenes binarizadas. En [37] se utilizan los bordes de los objetos para obtener el varios valores umbrales mientras que en [38] se aplica la condición de encontrar cierta forma en la imagen umbralizada para el cálculo del valor umbral.

- Métodos espaciales: Utilizan distribuciones de probabilidad de mayor orden y/o correlación entre píxeles. El autores de [39] y [40] se basan en una matriz de coocurrencias de niveles de gris a nivel local para calcular el valor umbral.
- Métodos locales: Adaptan el valor umbral en cada píxel a las características locales de la imagen. El valor del umbral es diferente para cada píxel de la imagen. Los autores de [41] dividen la imagen en ventanas y obtienen el valor umbral para cada una de las ventanas y posteriormente definen un valor de umbral variable para la imagen completa.

Las aplicaciones de umbralización son múltiples, yendo desde la extracción de caracteres en textos para su reconocimiento [42], hasta la identificación de zonas de interés en medicina [43], pasando por el control de calidad en cualquier tipo de industria [44] o el conteo de elementos en una imagen [45]. Sea cual sea la aplicación cada método se comporta mejor en unas condiciones de imagen que otro.

Por otro lado podemos ver el uso de umbrales en agricultura de precisión, como describimos a continuación. En [46] se utilizan el método de Otsu y el valor medio para umbralizar imágenes de grises procedentes de una combinación de los canales RGB similar a la que se hace en los índices vegetativos vistos en este mismo capítulo. La finalidad en este artículo era la discriminación entre cultivo y malas hierbas. En [47] se utiliza el método de Otsu para la verificación del uso de los índices vegetativos en sistemas automáticos para imágenes de cultivos, además al utilizar el índice ExGR (ver 3.2.4), este lleva implícito un umbral nulo, todos los píxeles positivos pertenecen a vegetación, por lo que se puede interpretar como una técnica de umbralización. En [48] y [49] se binariza mediante Otsu (por partida doble) a partir de imágenes de grises obtenidas de índices vegetativos para identificar las líneas de cultivo en campos con alta concentración de plantas de maíz en el primer caso y para diferenciar entre cultivo y malas hierbas en el segundo.

3. Revisión de los métodos utilizados

3.1. Introducción

El procedimiento de identificación de texturas vegetales en imágenes agrícolas mediante el uso de PCA's, que describimos en este trabajo, se basa en tres pilares fundamentales que se enumeran a continuación:

- Índices vegetativos.
- Análisis de componentes principales (PCA).
- Umbralización mediante el método de Otsu.

3.2. Índices vegetativos.

El método que se propondrá parte de la obtención de los índices ExG, ExGR, CIVE, NDI y VEG. Estos índices se obtienen a partir de las componentes RGB de las imágenes a partir de operaciones aritméticas sencillas.

Se procede a continuación a describir algunos de los índices existentes para la identificación de zonas vegetales.

3.2.1. Normalización del espacio de color.

Todos los índices parten de la normalización del espacio de color tal y como se indica en [50] para imágenes del mundo de la agricultura. Se parte de las componentes RGB y se obtienen las componentes normalizadas r , g y b en el rango $[0,1]$.

$$r = \frac{R'}{R' + G' + B'} , \quad g = \frac{G'}{R' + G' + B'} , \quad b = \frac{B'}{R' + G' + B'} \quad (3.1)$$

Donde a su vez las componentes R , G y B también han sido previamente normalizadas dentro de su rango:

$$R' = \frac{R}{R_{MAX}} , \quad G' = \frac{G}{G_{MAX}} , \quad B' = \frac{B}{B_{MAX}} \quad (3.2)$$

3.2.2. Excess Green (ExG).

Partiendo de las componentes normalizadas indicadas en la ecuación 3.1, se obtiene el índice de exceso de verde (ExG) aplicando la siguiente expresión [17] [18]:

$$ExG = 2g - r - b \quad (3.3)$$

3.2.3. Excess Red (ExR).

El índice ExR no será utilizado por sí mismo sino que es la base para el cálculo del ExGR que se verá más adelante. Para calcularlo se aplica la siguiente expresión [20]:

$$ExR = 1.4r - g \quad (3.4)$$

3.2.4. Excess green minus excess red (ExGR).

El procedimiento para calcular este índice necesita el cálculo previo de los índices ExG [17] [18] y ExR [20], siendo la expresión necesaria para obtenerlo la siguiente [19] que hace uso de las ecuaciones (3.3) y (3.4):

$$ExGR = ExG - ExR \quad (3.5)$$

3.2.5. Color Index of Vegetation Extraction (CIVE).

De nuevo se parte de las componentes *rgb* normalizadas y aplicando la siguiente fórmula obtenemos el índice CIVE [21]:

$$CIVE = 0.441r - 0.811g + 0.385b + 18.78745 \quad (3.6)$$

3.2.6. Vegetative (VEG).

La forma de este índice es un tanto diferente de la de los anteriores índices, su fórmula es la siguiente [11]:

$$VEG = \frac{g}{r^a b^{1-a}}, \quad a = 0.667 \quad (3.7)$$

3.2.7. Normalized difference index (NDI).

Este índice se calcula haciendo el cociente entre la diferencia y la suma de las componentes g y r [51]:

$$NDI = \frac{g - r}{g + r} \quad (3.8)$$

3.2.8. Combined approach (COM):

El cálculo de éste índice [22] se hace basándose en una combinación lineal de los índices ExG, ExGR, CIVE y VEG. El procedimiento que se utilizó para obtener los pesos que asignar a cada uno de los índices anteriores utilizó una base de 240 imágenes donde se comprobó la independencia respecto a las condiciones de iluminación y se verificó frente a resultados obtenidos a mano que los pesos óptimos son los siguientes:

$$w_{ExG} = 0.25; \quad w_{ExGR} = 0.3; \quad w_{CIVE} = 0.33; \quad w_{VEG} = 0.12 \quad (3.9)$$

Para calcular el índice COM se multiplica cada uno de los indicadores por su peso:

$$COM = w_{ExG} * ExG + w_{ExGR} * ExGR + w_{CIVE} * CIVE + w_{VEG} * VEG \quad (3.10)$$

$$COM = 0.25ExG + 0.3ExGR + 0.33CIVE + 0.12VEG \quad (3.11)$$

3.2.9. Resultados de la obtención de los índices.

Cada uno de los índices descritos en los apartados anteriores utiliza una imagen en color RGB para obtener una imagen en grises donde aparecen realzadas las zonas pertenecientes a vegetación.

Se muestran en la figura Fig. 2 los resultados de aplicar estos índices, que posteriormente se utilizarán en la metodología propuesta, sobre una imagen original:




Fig. 2: Imagen original(a), ExG (b) y ExGR (c), CIVE (d), NDI (f) y VEG (g).

Como se puede apreciar cada uno de los índices resalta de una manera diferente los elementos que conforman la escena pero todos destacan en mayor o menor medida la zona de interés, que son las líneas de cultivo.

3.3. Análisis de componentes principales (PCA).

El análisis de componentes principales es una técnica muy interesante a la hora de reducir la dimensionalidad de un conjunto de datos sin hacer que pierdan su sentido. Como se ha explicado en apartados anteriores, basan su funcionamiento en cambiar a un nuevo eje de coordenadas el conjunto de datos de modo que el nuevo conjunto de variables se representará como una función lineal del conjunto de datos original.

El resultado devuelve en primer lugar la componente con una mayor varianza (primera componente principal), en segundo lugar la componente con la segunda mayor varianza y así sucesivamente. Estas componentes se corresponden con los autovectores y autovalores de la matriz de covarianza del conjunto de datos.

El proceso para su obtención consta de los siguientes pasos.

- Obtención del conjunto de datos.
- Cálculo del valor medio y substracción del conjunto de datos.
- Obtención de la matriz de covarianzas.
- Cálculo de autovalores y autovectores.
- Ordenación de los autovectores de mayor a menor según su autovalor asociado.
- Obtención del nuevo conjunto de datos a partir de la proyección sobre los autovectores.

Para mostrar el funcionamiento lo haremos con un ejemplo sencillo, ya que las imágenes con las que trabajamos tienen tantos datos que hace imposible su representación visual con la que enseñar el proceso. Partimos del siguiente conjunto que consta de 100 pares de valores generados de manera aleatoria:




Fig. 3: Conjunto de datos original

El primer paso es eliminar el valor medio de las dos componentes, lo que deja el siguiente resultado:




Fig. 4: Conjunto de datos eliminando el valor medio de cada componente

Seguidamente hay que obtener la matriz de covarianza entre las componentes x e y del conjunto de datos:

$$C = 10^3 \begin{pmatrix} 1.1149 & 1.5416 \\ 1.5416 & 3.8415 \end{pmatrix} \quad (3.12)$$

Después se calculan los autovalores y los autovectores, que para la matriz anterior serán:

$$A = \begin{pmatrix} 0.4108 & -0.9117 \\ 0.9117 & 0.4108 \end{pmatrix} \quad (3.13)$$

$$\lambda = 10^3 (4.5361 \quad 0.4203) \quad (3.14)$$

La primera columna de la matriz A es el autovector asociado al mayor autovalor y por tanto la primera componente principal. Para obtener el nuevo conjunto de datos se debe multiplicar el autovector principal traspuesto por el conjunto de datos (con la media eliminada) traspuesto. De este modo se obtiene el conjunto de datos que aparece marcado en azul en la figura siguiente. Cabe destacar que este nuevo conjunto de datos sigue la misma tendencia que el anterior pero está más distribuido sobre el eje que mayor varianza tenía inicialmente.




Fig. 5: Primera componente principal (azul) superpuesta a los datos originales (rojo)

Al aplicar el análisis de componentes principales a un conjunto de datos se consigue eliminar las componentes menos significativas en estos, es equivalente a cuando se tiene una serie de observaciones agrupadas en torno a una recta y se aplican mínimos cuadrados para obtener

esa recta. Se consigue la dirección en la que los datos tienen una mayor varianza, y por tanto, donde más información proporcionan, y se eliminan las componentes con una varianza menor y que no interesan. Para el ejemplo anterior los puntos parecen agruparse alrededor de la recta $y=2x$ y al aplicar el análisis de componentes principales el conjunto de puntos resultante (azul) está mucho más agrupado en torno a esa recta, se ha eliminado variabilidad en otras direcciones que podría considerarse ruido.

Para la aplicación del análisis de componentes principales a imágenes se trata cada uno de los índices vegetativos como una de las dimensiones del conjunto de datos (es por eso que se representa como un vector, no se tiene en cuenta de ninguna manera la correlación espacial dentro de la propia imagen), si tan solo se tuvieran dos dimensiones sería equivalente al ejemplo mostrado donde las componentes son los ejes x e y . Por tanto para los índices vegetativos se dispondrá de cinco dimensiones, una para cada índice vegetativo (ExG, ExGR, CIVE, VEG y NDI). Al utilizar los mayores autovectores se desechará la información no relevante para dar significado al conjunto de datos tal y como sucede con los conjuntos de puntos rojo y azul en la Fig. 5.

3.4. Método de Otsu

El método de Otsu [33] se utiliza para convertir una imagen en niveles de gris en una en blanco y negro, proceso que se conoce como umbralizar.

La operación de umbralizado se define de modo que dado un umbral T la imagen binaria que se obtiene viene dada por las siguientes expresiones, siendo $f(x,y)$ la imagen en grises y $F(x,y)$ la imagen binaria:

$$F(x,y) = \begin{cases} 1 & \text{si } f(x,y) > T \\ 0 & \text{si } f(x,y) \leq T \end{cases} \quad (3.15)$$

La expresión de arriba puede invertirse dependiendo de si las regiones que se desea identificar son más claras o más oscuras que el resto de la imagen.

Dentro de la clasificación expuesta en el capítulo anterior, el método de Otsu se encuentra entre los métodos basados en agrupamiento. Su cálculo parte de la obtención del histograma de la imagen en grises y su objetivo es dividirla en dos clases donde la varianza entre ambas sea máxima.

La probabilidad de que un pixel de la imagen tenga una intensidad de gris i es de:

$$p_i = \frac{f_i}{N} \quad i = 1 \dots L \quad \text{niveles de gris} \quad (3.16)$$

Siendo f_i el número de píxeles que tienen un nivel i de gris y N el número total de píxeles en la imagen.

Si se hace un umbralizado en dos niveles en una imagen donde los niveles de gris se encuentran entre 1 y L , se obtendrán dos clases, donde la clase 1 contendrá los píxeles correspondientes a los niveles de gris entre 1 y t y la clase 2 los píxeles entre los niveles de gris de $t+1$ y L . Se tendrá que para cada una de esas dos clases la probabilidad de ocurrencia de la clase es de:

$$\omega_0 = \Pr(C_0) = \sum_{i=1}^T p_i = \omega(T) \quad (3.17)$$

$$\omega_1 = \Pr(C_1) = \sum_{i=T+1}^L p_i = 1 - \omega(T) = 1 - \omega_0 \quad (3.18)$$

Las medias dentro de cada una de las clases se obtienen como:

$$\mu_0 = \sum_{i=1}^T i \Pr(i|C_0) = \sum_{i=1}^T i \frac{p_i}{\omega_0} \quad (3.19)$$

$$\mu_1 = \sum_{i=T+1}^L i \Pr(i|C_1) = \sum_{i=T+1}^L i \frac{p_i}{\omega_1} \quad (3.20)$$

Y la intensidad media total de la imagen será:

$$\mu_T = \sum_{i=1}^L i p_i \quad (3.21)$$

Si se pasa a la varianzas tenemos que la varianza para cada una de las clases se puede obtener como:

$$\sigma_0^2 = \sum_{i=1}^T (i - \mu_0)^2 \Pr(i|C_0) = \sum_{i=1}^T (i - \mu_0)^2 \frac{p_i}{\omega_0} \quad (3.22)$$

$$\sigma_1^2 = \sum_{i=T+1}^L (i - \mu_1)^2 \Pr(i|C_1) = \sum_{i=T+1}^L (i - \mu_1)^2 \frac{p_i}{\omega_1} \quad (3.23)$$

Para evaluar la bondad del umbral se introducen los términos de varianza inter-clase, varianza intra-clase y varianza total:

$$\sigma_w^2 = \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2 \quad (3.24)$$

$$\sigma_B^2 = \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 = \omega_0 \omega_1 (\mu_1 - \mu_0)^2 \quad (3.25)$$

Otsu define el valor de umbral óptimo como aquel para el que la varianza entre las dos clases σ_B^2 es máxima o lo que es lo mismo, aquel valor para el que la varianza intra-clase σ_w^2 es mínima.

Las ventajas de este algoritmo son que se comporta bien ante imágenes reales, con ruido o poco iluminadas, sin embargo presenta algunos problemas cuando las regiones que se desea identificar están sometidas a condiciones muy diferentes de iluminación.

Como muestra de los resultados que se obtienen al aplicar el método de Otsu se tiene la siguiente figura donde se aprecia claramente como los objetos principales de la imagen (el edificio y el barco) se binarizan casi de manera perfecta.



Fig. 6: Imagen en grises (a) y resultado de umbralizar con Otsu (b)

Se representa además el histograma de la imagen en grises de la figura anterior. En color rojo se marca el valor de umbral calculado mediante el método de Otsu y que ha sido el utilizado para obtener la imagen binaria también presente en la figura anterior.




Fig. 7: Histograma de la imagen en grises y umbral marcado en rojo de Fig. 6

Se muestran también los resultados de aplicar el método de Otsu a una imagen en la que la iluminación de la zona de interés de la escena es muy variable. Como se ha comentado, en este tipo de situaciones el método de Otsu presenta algunas deficiencias debido a que es automatizado y además no tiene en cuenta ningún tipo de información que no sea la del histograma, por lo que se puede decir que el algoritmo no es “consciente” de la imagen que se está intentando binarizar.



Fig. 8: Imagen en grises con mucha variación de luz (a) y resultado de umbralizar con Otsu (b).

A simple vista las zonas cercanas a la fuente de luz se diferencian sin demasiado problema, sin embargo, a la hora de aplicar el método de Otsu esas zonas de la escena no se binarizan como cabría esperar. Sin embargo el abundante ruido de la escena no aparece casi reflejado en la imagen binaria.




Fig. 9: Histograma de la imagen en grises y umbral marcado en rojo de Fig. 8

Los principales motivos para la selección de este método para el proceso de umbralizado de la imagen de grises son varios:

- Es un método que no requiere de supervisión por lo que facilita el proceso de estudio y desarrollo del resto del método propuesto para identificar texturas pudiendo automatizar gran parte del mismo y no tener que preocuparse de ajustar el correcto funcionamiento de la etapa de umbralizado.
- El método ha sido previamente utilizado en el campo de la agricultura de precisión con resultados satisfactorios en varios trabajos [47], [46], [48], o [49].

Con todos estos ejemplos donde el uso del método de Otsu ha sido satisfactorio parece razonable pensar que es una buena elección para el enfoque de este proyecto.

4. Aportación

El esquema general del sistema propuesto para la identificación de texturas vegetales es el mostrado en la siguiente figura:




Fig. 10: Esquema general del sistema propuesto

Se parte de una imagen de componentes RGB para después de una serie de operaciones sobre las componentes y la obtención de diferentes índices, aplicar un análisis de componentes principales. Tras obtener las componentes principales, se selecciona la primera componente principal y se obtiene una imagen en escala de grises que será la utilizada para aplicar el método de umbralización de Otsu consiguiendo así una imagen binaria donde se resaltarán las texturas vegetales.

La técnica que se propone está formada por varios pasos que han demostrado ofrecer resultados satisfactorios por si solos (Ver [17], [29], [48] o [22] por poner algunos ejemplos), pero que en este caso van a trabajar en conjunto. El primero paso, si se obvia la preparación de las componentes RGB de la imagen, consiste en la obtención de una serie índices vegetativos cuyo correcto funcionamiento ya ha sido contrastado por varios autores por separado, seguidamente, tras preparar esos índices, se utiliza la técnica de las componentes principales, definida hace más de cien años [23] [24] y que aún hoy en día es ampliamente utilizada para diversas tareas como la compresión de imágenes [52], o la identificación de personas [26]. Finalmente, tras recuperar la imagen de grises, se utiliza el método de Otsu para la obtención de un valor umbral óptimo con el que ya se podrá identificar áreas pertenecientes o no a vegetación.

Se describen en los siguientes apartados los pasos necesarios para segmentar las texturas vegetales partiendo de las imágenes RGB y se muestran ejemplos de los resultados

intermedios que se van obteniendo en aquellos pasos donde la representación sea significativa.

4.1. Acondicionamiento de la imagen.

EL objetivo de este paso es obtener componentes normalizadas al rango [0,1] tal y como se sugiere en [50]




Fig. 11: Esquema de acondicionamiento de imagen

En primer lugar tal y como se ha explicado en el capítulo anterior y tal y como se puede ver en la figura superior, se debe proceder a la normalización en dos pasos.

En el primer paso las componentes se normalizan dentro de su mismo canal dividiendo cada componente R (rojo) entre el máximo de todos los píxeles en la componente R y lo mismo para las componentes G (verde) y B (azul). (Ec. 3.2)

Después, en el segundo paso, la normalización se hace respecto a la suma de las componentes R' , G' y B' de manera local (Ec. 3.1), es decir, se divide cada componente R' , G' y B' de cada píxel entre la suma de las 3. De este modo se obtiene el peso de cada componente dentro de un mismo píxel. El resultado de este proceso son las componentes r , g y b .

Las modificaciones que estas normalizaciones producen sobre las imágenes se pueden ver en la figura siguiente.




Fig. 12: Imagen original (a) y resultado de normalizar las componentes (b)

4.2. Obtención de índices.

El segundo paso del proceso es la obtención de los índices vegetativos ExG, ExGR, CIVE, NDI y VEG haciendo uso de las componentes espectrales *rgb*, que son las componentes RGB tras aplicar las dos normalizaciones explicadas en el apartado anterior.

Todos ellos se obtienen con operaciones sencillas que ya se han explicado (Ver 3.2.2, 3.2.4, 3.2.5, 3.2.6 y 3.2.7) por lo que no será necesario detenerse a explicarlos de nuevo y basta con observar la figura siguiente para entender el proceso completo.




Fig. 13: Procedimiento para la obtención de cada uno de los índices vegetativos necesarios

Como resumen de este apartado se puede decir que se parte de las componentes normalizadas rgb obtenidas en 3.2.1 y se obtienen cinco imágenes en grises representando los índices vegetativos ExG, ExGR, CIVE, NDI y VEG, todos ellos realzan las zonas pertenecientes a vegetación, con el fin de posteriormente poder extraerlas. Se muestran a continuación los índices obtenidos para la misma imagen del apartado anterior:




Fig. 14: Imagen original (a) e índices ExG (b), ExGR (c), CIVE (d), NDI (e) y VEG (f)

4.3. Acondicionamiento de índices.

Para poder aplicar el análisis de componentes principales es necesario que los datos originales tengan media nula ya que si esto no se hace el primer autovector se parecerá bastante al vector con las medias de cada una de las componentes [53], quedando algo desvirtuados los resultados del análisis de componentes principales. Por este motivo la sustracción de la media debe de hacerse a cada uno de los índices como primera operación del análisis de PCA

La siguiente operación para poder aplicar el análisis de componentes principales sobre una imagen es la modificación de la representación de cada una de las imágenes obtenidas con los índices vegetativos centrados en el origen para que tomen la forma de un vector columna, por lo que se procede a concatenar todas las columnas una tras otra. El resultado para cada uno de

los índices vegetativos es un vector columna con número de filas igual al número de píxeles de la imagen.

Se muestra debajo un esquema de los pasos que han de darse para poder obtener la matriz de datos que se utilizara como entrada para el cálculo de las componentes principales de la imagen.




Fig. 15: Esquema para el acondicionamiento de los índices vegetativos

Si el análisis se hace para más de una imagen, el procedimiento ha de llevarse a cabo de la siguiente manera:

- Se genera la matriz de datos para una imagen, donde cada columna se corresponderá con la imagen de grises de uno de los índices vegetativos centrados en el origen.
- Para la siguiente imagen se procede exactamente del mismo modo y la matriz resultante se colocará inmediatamente después de la anterior de modo que en cada columna siempre se encuentre el mismo índice.
- Realizar el proceso para todas las imágenes.

De este modo si se tienen por ejemplo 10 imágenes de 160000 píxeles cada una (resolución de 400 x 400), con cada imagen se genera una matriz de datos de 5 columnas (debido a que utilizamos 5 índices vegetativos) y 160000 filas, por lo que tras concatenar una detrás de otra

las diez matrices de datos provenientes de los índices vegetativos de cada una de las imágenes el resultado final será una matriz de 5 columnas y 1600000 filas.

4.4. Cálculo de componentes principales.

El paso más importante del proceso es el de la obtención de las componentes principales. Para realizar este proceso se parte de la matriz de datos generada en el paso anterior y que contiene toda la información que aportan los diferentes índices calculados para todas las imágenes que se han analizado.

Esta matriz ya tiene todas sus columnas centradas en el origen tal y como requiere el análisis de componentes principales para proporcionar los resultados deseados.

Se muestra en la figura siguiente un breve esquema de los pasos a seguir para obtener la matriz de componentes principales a partir de la matriz de datos original.




Fig. 16: Esquema para la obtención de las componentes principales.

Como se observa en la Fig. 16, la obtención de las componentes principales consta de tres pasos, el primero es el cálculo de la matriz de covarianzas, el segundo es la obtención de los autovectores y autovalores de la matriz de covarianzas, y finalmente se calculan las componentes principales a partir de los mayores autovectores y la matriz de datos original.

El primer paso es la obtención de la matriz de covarianza. Esta matriz tiene la siguiente estructura:

$$Cov = \begin{pmatrix} C_{11} & C_{12} & C_{13} & C_{14} & C_{15} \\ C_{21} & C_{22} & C_{23} & C_{24} & C_{25} \\ C_{31} & C_{32} & C_{33} & C_{34} & C_{35} \\ C_{41} & C_{42} & C_{43} & C_{44} & C_{45} \\ C_{51} & C_{52} & C_{53} & C_{54} & C_{55} \end{pmatrix} \quad (4.1)$$

Además dado que se cumple que $Cov(x,y)=Cov(y,x)$, la matriz es simétrica. Si se tiene también en cuenta que la covarianza de una variable consigo misma es igual a su varianza $Cov(x,x)=Var(x)$, los elementos de la diagonal principal serán las varianzas de cada una de las columnas de la matriz, por lo que la matriz de covarianza se puede escribir también del siguiente modo.

$$Cov = \begin{pmatrix} \sigma_{ExG}^2 & C_{ExG,ExGR} & C_{ExG,CIVE} & C_{ExG,NDI} & C_{ExG,VEG} \\ C_{ExG,ExGR} & \sigma_{ExGR}^2 & C_{ExGR,CIVE} & C_{ExGR,NDI} & C_{ExGR,VEG} \\ C_{ExG,CIVE} & C_{ExGR,CIVE} & \sigma_{CIVE}^2 & C_{CIVE,NDI} & C_{CIVE,VEG} \\ C_{ExG,NDI} & C_{ExGR,NDI} & C_{CIVE,NDI} & \sigma_{NDI}^2 & C_{NDI,VEG} \\ C_{ExG,VEG} & C_{ExGR,VEG} & C_{CIVE,VEG} & C_{NDI,VEG} & \sigma_{VEG}^2 \end{pmatrix} \quad (4.2)$$

A partir de esta matriz que será cuadrada y con dimensión igual al número de índices utilizados en la matriz de datos original, que son cinco en este caso, se han de calcular sus autovectores y sus autovalores.

Para el caso de una matriz de covarianza de dimensión 5, se obtendrá un conjunto de 5 autovectores y 5 autovalores asociados. Los autovectores han de ordenarse en sentido decreciente según su autovalor asociado. Son los autovalores los que dan la importancia que tiene cada uno de los autovectores dentro de la imagen.

Llegados a este punto se ha experimentado con dos situaciones:

- Utilizar tan solo el primer autovector para recuperar la imagen.
- Utilizar los tres primeros autovectores para recuperar la imagen.

Si bien es la primera componente principal la que aporta la mayor cantidad de información, las siguientes componentes proporcionan matices que pueden ser de interés para el proceso de segmentación, bien sea realzando el contraste entre regiones, eliminando ruido o simplemente mejorando aún más el realce de las zonas pertenecientes a vegetación. Los resultados de aplicar estas dos aproximaciones se mostrarán en apartados siguientes. A continuación se muestran como ejemplo los autovectores y los autovalores de las matrices de covarianza obtenidas a partir de las siguientes imágenes:




Fig. 17: Serie de imágenes utilizadas para calcular las componentes principales

$$A = \begin{pmatrix} 0.4354 & 0.4659 & -0.2538 & -0.3663 & 0.6283 \\ 0.4525 & -0.1623 & -0.2949 & 0.8102 & 0.1600 \\ -0.4418 & -0.3630 & 0.2791 & 0.1253 & 0.7612 \\ 0.4537 & 0.1375 & 0.8754 & 0.0943 & -0.0077 \\ 0.4524 & -0.7784 & -0.0660 & -0.4300 & -0.0137 \end{pmatrix} \quad (4.3)$$

$$\lambda = 10^3 (4.1980 \quad 0.0947 \quad 0.0051 \quad 0.0005 \quad 0.0000) \quad (4.4)$$

Cabe destacar que este proceso es el que más requerimientos computacionales requiere por lo que si en algún momento se desea implementar el método en una plataforma HW se deberá

prestar especial atención en esta parte del proceso para que el resultado final no requiera un excesivo tiempo de cómputo. No se debe olvidar que el propósito de este tipo de operaciones es el de estar embarcadas en maquinaria agrícola que sea capaz de obtener la información en tiempo real para poder tomar las acciones oportunas sin que necesite estar deteniéndose continuamente para procesar los datos que va adquiriendo del entorno.

4.5. Recuperación de la imagen original

El siguiente paso del proceso es el de la recuperación de la imagen de grises a partir de los resultados obtenidos en el análisis de componentes principales. Este proceso consiste en seleccionar las filas correspondientes a la imagen que se desea recuperar del vector columna devuelto por el paso anterior y devolverle las dimensiones originales. Por ejemplo para el caso de seleccionar 160000 píxeles de entre todos los píxeles devueltos por las operaciones descritas en el apartado 4.4, se deberán dividir de 400 en 400 y formar 400 columnas. Se muestra debajo un esquema resumen de los pasos que se acaban de describir para llevar a cabo el último paso en la obtención de la imagen de grises.




Fig. 18: Esquema de la obtención de la imagen de grises a partir de las componentes principales

En este punto se pueden tener imágenes procedentes tan solo del mayor autovector (el asociado al mayor autovalor y descrito en la Fig. 18) o de los tres primeros autovectores, para los que sería necesario llevar a cabo el proceso de la Fig. 18 para cada uno de los 3 canales que componen la imagen. Los dos apartados siguientes muestran los resultados obtenidos por los dos métodos.

4.5.1. Recuperación a partir del mayor autovector.

En el caso de tan solo hacer uso del mayor autovector el resultado del proceso de recuperación es una imagen de grises.

Se muestran en las siguientes figuras algunas imágenes de grises obtenidas mediante este método y comparadas con las obtenidas mediante el método COM [22] mostrado en el capítulo 3 que ya de por si ofrece muy buenos resultados. La primera se obtiene a partir de Fig. 17 (a).




Fig. 19: Imagen degrises PCA (a) e imagen grises COM (b) de Fig. 17 (a)

Esta segunda se obtiene a partir de Fig. 17 (b), tanto en la anterior como en esta se puede observar como las líneas de cultivo aparecen con mayor contraste respecto al suelo.




Fig. 20: Imagen grises PCA (a) e imagen grises COM (b) de Fig. 17 (b)

4.5.2. Recuperación a partir de los tres mayores autovectores.

En el caso de hacer uso de los tres mayores autovectores el resultado del proceso de recuperación son tres imágenes de grises. Se muestran los resultados para 3 imágenes diferentes. Esta primera se corresponde con los resultados a partir de Fig. 17 (a).




Fig. 21: Imágenes de grises procedentes de las tres primeras componentes principales (a), (b) y (c) de Fig. 17 (a).

La segunda serie de imágenes se corresponde con lo que se obtiene de los tres primeros valores principales a partir de Fig. 17 (b).




Fig. 22: Imágenes de grises procedentes de las tres primeras componentes principales (a), (b) y (c) de Fig. 17 (b).

El tercer grupo de imágenes es el resultado de Fig. 17 (g).




Fig. 23: Imágenes de grises procedentes de las tres primeras componentes principales (a), (b) y (c) de Fig. 17 (g).

Si se observa detenidamente se pueden ver las siguientes cosas:

- La primera componente principal siempre realza las regiones pertenecientes a vegetación tal y como se pretende.
- La segunda componente principal prácticamente no realza las zonas pertenecientes a vegetación, incluso en algunas regiones es difícil distinguir zonas de vegetación que en la primera componente sí que son distinguibles a simple vista.
- La tercera componente principal no siempre realza las zonas verdes, y en las ocasiones que si las realza, parece que no lo hace sobre la misma extensión que la primera componente principal sino tan solo sobre las zonas centrales de las superficies. Produce una especie de esqueleto de la zona que buscamos.

Tras estudiar los resultados obtenidos haciendo uso de las tres primeras componentes principales se observó que la mejora obtenida no era suficientemente significativa (y en

algunos clasos nula) como para justificar el aumento de la dimensionalidad de los datos, por tanto se decidió proceder a utilizar tan solo la primera componente principal.

4.6. Umbralizado mediante Otsu.

El sexto y último paso del proceso para la segmentación de texturas vegetales en imágenes es la obtención de la imagen binaria a partir de la imagen de grises que se genera haciendo uso de las componentes principales.

Como se ha comentado anteriormente el método seleccionado para obtener la imagen binaria es el de Otsu por sus buenos resultados ante la mayoría de situaciones y por ser un método automático que no requiere de ninguna supervisión.

Este paso es el que permitirá comparar frente a otros métodos como por ejemplo el COM. En las cuatro figuras siguientes se muestran las imágenes binarias procedentes de las imágenes de grises obtenidas a partir de la primera componente principal y a partir de la imagen COM.




Fig. 24: Imagen binaria COM (a) y PCA (b) de de Fig. 17 (a)

En la imagen procedente del índice COM se puede ver como en la zona superior izquierda gran parte del árbol aparece en negro, mientras que en la imagen procedente de la PCA se ha detectado mejor el área verde. Lo mismo sucede para el resto de árboles que hay en el fondo.

Otro detalle que se puede apreciar es que la imagen obtenida a partir de la PCA es menos ruidosa que la otra.

Se puede representar el resultado de aplicar la imagen binaria como máscara de la imagen original para los dos casos, y de este modo se obtendrán las zonas verdes identificadas. En esta representación aparecerán además las zonas que no son verdes, pero que si han sido identificadas como verdes. También se puede representar el resultado de aplicar la negación de la imagen binaria como máscara de la imagen original. En este segundo caso se representarán las zonas que se han identificado como no pertenecientes a texturas vegetales además de las que si pertenecen a texturas vegetales pero no se han identificado como tal.




Fig. 25: Aplicación de mascara binaria (a), (c) y máscara binaria negada (b), (d) procedente de imagen COM (Fig. 24 (a)) e imagen PCA (Fig. 24 (b)) sobre la imagen original (Fig. 17 (a))

Como se comentó al describir los resultados de la Fig. 24, es en la zona de los árboles de la parte superior donde radica la mayor diferencia en el resultado conseguido con cada método.

Se muestra claramente como con el método COM, gran parte de la superficie de los arboles queda mal clasificada.

Con esta forma de visualizar los resultados se aprecia mejor la diferencia en cómo se detectan los arboles del fondo y como se reduce el ruido en la imagen obtenida.

En la Fig. 26 también se puede apreciar la mejora introducida por el método.




Fig. 26: Imagen binaria COM (a) y PCA (b) de Fig. 17 (b).

Para este otro caso se puede apreciar la reducción de ruido en la esquina inferior derecha y en la zona media/derecha (ver figura siguiente):




Fig. 27: Arriba: Diferencias en zona inferior derecha (Original (a), COM (b) y PCA (c)) – Abajo: Diferencias en zona media derecha (Original (d), COM (e) y PCA (f)) de de Fig. 17 (b).

También se aprecia bastante diferencia en la zona superior izquierda y en la zona central, donde de nuevo la gran diferencia entre ambas es la reducción de ruido.




Fig. 28: Arriba: Diferencias en zona superior izquierda (Original (a), COM (b) y PCA (c)) – Abajo: Diferencias en zona central (Original (d), COM (e) y PCA (f)) de de Fig. 17 (b).

Observando la Fig. 17 (i), se puede comprobar que en la zona inferior central hay también una notable reducción de ruido.




Fig. 29: Imagen binaria COM (a) y PCA (b) de Fig. 17 (i)

Ampliando la zona descrita es más sencillo ver que, efectivamente, hay una buena reducción de ruido.




Fig. 30: Detalle de zona inferior central para imagen binaria de COM (a) y de PCA (b) de la Fig. 17 (i)

Después de observar todas estas imágenes se puede concluir que la utilización del análisis de componentes principales para la identificación de texturas vegetales en imágenes agrícolas es una opción muy interesante ya que combina los beneficios que proporcionan índices ya utilizados previamente por otros autores y además incluye el beneficio de la reducción de ruido.

En el siguiente capítulo se cuantificará la mejora introducida por esta técnica.

5. Resultados y conclusiones

5.1. Objetivo

Una vez descrita la técnica seleccionada para segmentar la imagen mediante el análisis de componentes principales (PCA) se trata de evaluar su efectividad con la finalidad de identificar las partes verdes que pertenezcan a plantas de la escena. Tras realizar una segmentación mediante la técnica PCA se realiza una umbralización con el método de Otsu para de este modo conseguir binarizar la imagen, que finalmente será mejorada mediante la operación morfológica de erosión. En el actual capítulo se analizan los resultados obtenidos mediante las distintas técnicas con la finalidad de identificar las plantas verdes presentes en la escena.

Los métodos empleados en el presente trabajo han sido desarrollados y probados en Matlab [54], con la versión 2014^a. El computador utilizado ha sido un portátil con un procesador Intel Core i7-2670 a 2.2GHz, con 4GB de memoria RAM y el sistema operativo Windows 7 de 64 bits.

Una de las ventajas de este lenguaje es que se puede desarrollar sistemas con una gran rapidez pudiéndole considerar de prototipado rápido. Esto es debido a que tiene operaciones matriciales en el conjunto base de instrucciones así como gran número de operaciones complejas, como pueden ser umbralizaciones y operaciones morfológicas, por lo que se pueden implementar códigos para el tratamiento de imágenes de una forma relativamente sencilla comparado con otros lenguajes como pueden ser java o c, además de esto se facilita la visualización de los resultados con sus múltiples formas de representación gráfica.

Entre sus desventajas se encuentra que se trata de un lenguaje interpretado y por lo tanto es coste computacional de los procesos implementados suele ser superior a otros lenguajes de distinta naturaleza y que el código no puede ser ejecutado directamente en sistemas que no tengan Matlab instalado a no ser que se distribuya junto al código el runtime environment. Sin embargo la desventaja del tiempo de ejecución puede ser disminuida mediante la utilización de la herramienta MATLAB Coder para generar código c que ejecutar, aunque existen funciones que no pueden ser traducidas.

Pero debido a que la finalidad del trabajo no es evaluar el coste en tiempo de los algoritmos sino su efectividad, el hecho de que se pueda tardar algo más de tiempo en ejecutar los algoritmos no es un problema y se decidió utilizar Matlab como lenguaje por la comodidad en el tratamiento de las imágenes.

5.2. Descripción de las imágenes utilizadas.

Las imágenes empleadas para evaluar los índices de vegetación y nuestra propuesta han sido capturadas mediante la cámara industrial svs-4050 CFLGEA de la compañía SVS-VISTEK [55]. Esta cámara es capaz de capturar imágenes a una tasa de máxima de 16 Hz gracias a su interfaz de comunicación GigE Vision con la que se comunica con el computador. Las imágenes obtenidas tienen una resolución de 2336 x 1756 píxeles con 24 bits por píxel en el modelo de color RGB y son almacenadas en el formato mapa de bits (BMP) para que no se pierda información debido a su compresión.

Todas las imágenes utilizadas en este estudio pertenecen a campos de maíz y fueron capturadas durante los meses de Abril y Mayo del año 2013 y 2014, bajo distintas condiciones de luminosidad. La cámara se encontraba a una altura de dos metros respecto del terreno y los ángulos de cabeceo, alabeo y deriva fueron 20°, 0° y 0° respectivamente. Las capturas de las imágenes se realizaron durante varios días, obteniendo conjuntos de imágenes con distintos estados de crecimiento y diferentes condiciones de iluminación.

En las imágenes aparecen áreas con distintas densidades de vegetación. El lugar donde fueron adquiridas las imágenes es en la finca experimental de 1.7 hectáreas situada en La Poveda, Arganda del Rey (Madrid), pertenecientes al Centro de Investigaciones Agrarias del Consejo Superior de Investigaciones Científicas (CSIC).

Debido a la gran resolución de las imágenes y con la finalidad de obtener con mayor facilidad el *ground-truth* de cada imagen se decidió dividir cada imagen en subimágenes más pequeñas. Estas subimágenes tienen una resolución de 400x400, excepto en los bordes de las imágenes en la que tendrán un tamaño de 335x400, 400x151 o 335x441, dependiendo de si se trata del borde derecha, el borde inferior o la esquina inferior derecha respectivamente. Estas subimágenes son con las que probaremos los algoritmos descritos. En la Fig. 31 se pueden ver la una imagen completa, así como una de estas subimágenes.




Fig. 31: Imagen completa (a) y subimagen (b) utilizadas en el análisis

5.3. Metodología utilizada.

Para evaluar la efectividad del método de PCA se comparan sus resultados con los obtenidos al procesar las imágenes con el resto de índices estudiados en capítulos anteriores y utilizados además en el método de las componentes principales. De este modo se obtienen tantas imágenes de un solo canal como índices se utilicen en la comparativa además de la propia imagen obtenida con nuestro método.

Cada una de estas imágenes será umbralizada mediante el método de Otsu, con el cual se obtiene un valor umbral con el que diferenciar entre pixel perteneciente a una planta y el resto de píxeles gracias al realce de las zonas vegetales conseguido con los índices vegetativos.

Tras obtener una imagen binaria mediante el método de Otsu se realiza la operación morfológica de erosión para obtener unos mejores resultados, de este modo se consiguen eliminar conjuntos pequeños y aislados de píxeles verdes que en condiciones normales no se encuentran formando este tipo de distribuciones sino mucho mayores.

Para obtener un resultado cuantitativo con el que poder evaluar los distintos índices se hace uso del estimador de la media, con el que se comparará la imagen binaria final, obtenida tras la operación de erosión, y la imagen binaria considerada como correcta, que se conoce con el nombre de *ground-truth*.

El modo en el que se han generado los *ground-truth* es manual, como no podía ser de otro modo, aunque intentando facilitar la labor ya que no podría ser factible ir pixel a pixel y tener

una amplia colección de *ground-truth*. El proceso para generar estas imágenes con las que poder evaluar los algoritmos es la que sigue:

- Dada la imagen original en el modelo de color RGB se extraen los píxeles cuya componente de color verde sea mayor que la roja y la azul juntas en al menos un 10%. Esto nos permite una importante parte de los píxeles pertenecientes a las plantas existentes en la imagen. Estos píxeles extraídos se etiquetan con el color blanco.
- Partiendo de nuevo de la imagen original en el modelo de color RGB se extraen los píxeles en los que la componente azul o roja sea la dominante. Para que una componente de las tres sea dominante en un píxel su valor debe sobrepasar en al menos un 10% a las otras dos. En este caso estos píxeles seleccionados se etiquetarán con el color negro.
- Descartando los píxeles ya etiquetados se procede a clasificar uno a uno los píxeles de la imagen que todavía no han sido seleccionados en los dos pasos anteriores. En caso de que se trate de un píxel perteneciente a vegetación se etiquetará con el color blanco y en caso contrario con el color negro. Esta clasificación la realiza un experto que ya ha tratado ampliamente con este tipo de imágenes anteriormente y acumula muchas horas en el terreno.

Para el estudio se analizaron 310 imágenes y por lo tanto se tuvieron que construir el mismo número de *ground-truth*.

5.4. Comparativa de resultados

Los índices de vegetación que se analizaron fueron el ExG, ExGR, CIVE, NDI, VEG, COM y el obtenido mediante PCA, que de aquí en adelante se abreviará con las siglas IPCA. Con cada uno de los índices de vegetación se realiza el proceso que se detalla a continuación con cada imagen:

- I) Se normaliza la imagen como se ha comentado en el capítulo 3 de modo que todos los píxeles de cada uno de los canales de la imagen tengan valores normalizados entre 0 y 1.
- II) Se computa el índice de vegetación correspondiente.

- III) Se vuelve a normalizar para obtener una imagen en escala de grises cuyos píxeles tengan valores en el intervalo [0, 255].
- IV) Se procesa la imagen en escala de grises anterior con el algoritmo de Otsu, obteniendo un umbral t .
- V) Se binariza la imagen en escala de grises obtenida en el paso III mediante el umbral t . Los píxeles cuyo valor sea mayor o igual que el umbral t se consideran píxeles pertenecientes a plantas verdes y se etiquetan con el color blanco. Por el contrario los píxeles cuyo valor sea menor que el umbral t se consideran píxeles de objetos diferentes a la vegetación y se etiquetan con el color negro.
- VI) Se realiza una operación de erosión a la imagen binaria anterior.
- VII) Se compara la imagen binaria tras la operación morfológica con la imagen *ground-truth* y se computa el número de píxeles mal clasificados, tanto falsos positivos como falsos negativos, y se divide entre el número total de píxeles que constituyen la imagen, obteniéndose un porcentaje de error.

Una vez que se ha realizado el proceso descrito en los siete pasos anteriores con las 310 imágenes se realiza la media del porcentaje de error. Estos valores se muestran en la Tabla 1.

Índice	ExG	ExGR	CIVE	NDI	VEG	COM	IPCA
% error	11,15	11,21	10,42	12,05	19,14	8,93	8,07

Tabla 1: Porcentajes de error para cada uno de los índices vegetativos aplicados al conjunto de 310 imágenes.

A la vista de los resultados se puede llegar a la conclusión de que el método propuesto basado en la extracción de las componentes principales mejora los resultados ofrecidos por métodos ampliamente utilizados como el ExG o el NDI en gran medida.

Además mejora ligeramente los resultados que se obtienen con el método COM, que al igual que el IPCA se basa en obtener una combinación lineal de otros índices.

El índice VEG por sí solo no proporciona resultados demasiado buenos pero aplicado conjuntamente con el resto de índices para formar el PCA hace que este último funcione bastante bien.

Para evaluar el rendimiento de la técnica propuesta en más profundidad se debe recurrir a otras figuras de mérito que evalúen el tipo de errores que se han cometido a la hora de hacer la clasificación de los píxeles. Estos errores pueden ser debidos a clasificación de píxeles que son vegetación como si no lo fueran o a clasificación de píxeles que no son vegetación como si lo fueran. Para entender mejor los conceptos se va a explicar primero el significado de cada uno de los términos.

- TP (True positive): Verdaderos positivos, son los píxeles pertenecientes a vegetación que han sido clasificados como vegetación. Su clasificación ha sido correcta.
- TN (True negative): Verdaderos negativos, son los píxeles no pertenecientes a vegetación que no han sido clasificados como vegetación. Su clasificación ha sido correcta.
- FP (False positive): Falsos positivos, son los píxeles no pertenecientes a vegetación que si han sido clasificados como vegetación. Su clasificación no ha sido correcta.
- FN (False negative): Falsos negativos, son los píxeles pertenecientes a vegetación que no han sido clasificados como vegetación. Su clasificación ha sido incorrecta.

Con estos cuatro tipos de clasificación para los píxeles identificados se definen cuatro figuras de mérito:

- Precision: Es el cociente entre los verdaderos positivos y el número total de positivos (verdaderos + falsos). Este parámetro dice que porcentaje de los píxeles marcados como vegetación lo son en realidad pero no dice nada respecto a los píxeles de vegetación no identificados. Indica que se está fallando en las zonas que no son de vegetación. La expresión para su obtención es la siguiente:

$$precision = \frac{TP}{TP + FP} \quad (5.1)$$

- Recall: Es el cociente entre los píxeles marcados positivos y el total de píxeles pertenecientes a vegetación, es decir, verdaderos positivos + falsos negativos. Este parámetro dice el porcentaje de píxeles de vegetación identificados pero no dice nada respecto a los píxeles correspondientes a zonas que no son vegetación. Indica que se está fallando en las zonas de vegetación. La expresión que permite obtenerle es la siguiente:

$$recall = \frac{TP}{TP + FN} \quad (5.2)$$

- Accuracy: Este valor evalúa el porcentaje de aciertos, es decir, la suma de verdaderos positivos y verdaderos negativos dividida entre la suma total de píxeles, que con la clasificación en cuatro tipos dada más arriba es verdaderos positivos + verdaderos negativos + falsos positivos + falsos negativos. Su expresión es:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.3)$$

- F-measure (media armónica de Precision y Recall): Se calcula como dos veces el producto de Precision y Recall dividido entre su suma:

$$F = 2 \frac{precision \cdot recall}{precision + recall} \quad (5.4)$$

Si se manipula un poco esta expresión y se introducen las expresiones de cada uno de los términos se puede reescribir como:

$$F = \frac{2TP}{2TP + FP + FN} \quad (5.5)$$

Esta última expresión es otra forma de medir la bondad de la clasificación dando peso tanto a *precision* como a *recall* pero sin tener en cuenta la cantidad de verdaderos negativos. Su valor óptimo es la unidad, que implica $recall = precision$ y por tanto $FP=0$ y $FN=0$.

El valor de accuracy es complementario al porcentaje de error de Tabla 1, obsérvese que la suma de ambos es 100%.

Los resultados que se obtienen al aplicar las figuras de mérito anteriores a la técnica IPCA propuesta son las que se muestran en la Tabla 2:

	Precision	Recall	Accuracy	f-measure	Standard deviation
IPCA	89.07%	87.54%	91.93%	90.79%	0.94

Tabla 2: Resultado de la aplicación de varias figuras de mérito al indicador IPCA.

Los valores que se obtienen indican que por ejemplo de cada 100 píxeles 11 se clasifican como vegetación sin serlo (falsos positivos) y alrededor de 13 píxeles que pertenecen a vegetación

no se identifican (falsos negativos). Esto indica que se está cometiendo más error dejando de clasificar píxeles de vegetación (falsos negativos) que clasificando mal los que no pertenecen a vegetación (falsos positivos).

5.5. Conclusiones

Es en la forma de obtención y aplicación de los pesos para la combinación lineal entre los diferentes índices donde radica una de las principales diferencias entre los métodos COM e IPCA, mientras que el COM aplica un conjunto de pesos fijos calculados previamente, el IPCA utiliza una base de imágenes con varios indicadores para cada una de ellas y calcula directamente la combinación mediante pesos específicos para cada base de imágenes. Estos pesos se pueden considerar característicos para la escena en cuestión y depender de la fase del cultivo, tipo de cultivo, estado del terreno e incluso tipo de terreno.

Por tanto se puede concluir que la combinación de los índices debe ser adaptativa a la escena en cuestión, dadas la mejora observada entre los índices que aplican pesos fijos y este tipo de análisis que los calcula para un mismo campo de cultivo.

El análisis de componentes principales ha probado ser muy útil para proporcionar una forma de fusión de datos procedentes de varios índices vegetativos desechando los que no son suficientemente significativos y contribuyendo a la obtención de una imagen menos ruidosa.

6. Trabajo futuro

Con todas las observaciones y la experiencia adquirida durante el desarrollo del presente trabajo, y el análisis de los resultados y conclusiones a los que se ha llegado, se pueden plantear varias líneas sobre las que trabajar bien para mejorar los resultados bien para utilizar la herramienta de las componentes principales de un modo diferente al que se ha utilizado y así tratar de mejorar la efectividad de la identificación de las plantas verdes presentes en la escena.

La primera de las posibles líneas futuras sería mejorar el índice de vegetación empleado, ya que la segmentación de la imagen, para obtener una imagen en la que se clasifican los píxeles en función de su verdor, está fuertemente ligada a los resultados finales obtenidos. En el presente trabajo se han contemplado únicamente los índices de vegetación que hacen uso del espectro visible, pero cabe la posibilidad de emplear otras bandas del espectro electromagnético para mejorar los resultados, como podría ser la banda que cubre el infrarrojo. De este modo se añadiría información con la que posteriormente discriminar entre vegetación y el resto de elementos de la escena.

Dado el creciente uso de la fusión de información procedente de múltiples tipos de fuentes, parece una buena idea mejorar los resultados de la identificación de zonas pertenecientes a vegetación añadiendo información de sensores de otro tipo, como por ejemplo sensores tipo SONAR o LIDAR que se encuentren a una determinada altura sobre el suelo y apuntando en un eje paralelo al suelo se puede utilizar esa información para evitar falsos positivos en zonas donde tan solo existe suelo. De esta forma se tendría información de una tercera dimensión. Otra opción puede ser añadir una segunda cámara para intentar hacer uso de la combinación de las imágenes obtenidas en ambas. Esta se podría considerar la segunda línea de trabajo futuro.

Para finalizar y partiendo de la idea de la fusión de información de diferentes tipos, se plantea una tercera línea de trabajo futuro en la que se añadiría información morfológica (contornos, esqueletos, cadenas, etc) a los índices de vegetación. De este modo se añadiría información extra con la que poder realizar la clasificación de la vegetación de un modo más exacto.

Bibliografía

- [1] IBM, «<http://www.research.ibm.com/>,» IBM, [En línea]. Available: http://www.research.ibm.com/articles/precision_agriculture.shtml. [Último acceso: 2015 05 21].
- [2] M. G. Corral, «Abejas 'adictas' a pesticidas letales,» El Mundo, Madrid, 2015.
- [3] C. H. Krupke, G. J. Hunt, B. D. Eitzer, G. andino y K. Given, «Multiple Routes of Pesticide Exposure for Honey Bees Living Near Agricultural Fields,» *PLOS One*, vol. 7, nº 1, 2011.
- [4] C. Lu, K. M. Warchol y R. A. Callahan, «Sub-lethal exposure to neonicotinoids impaired honey bees winterization before proceeding to colony collapse disorder,» *Bulletin of Insectology*, vol. 67, nº 1, pp. 125-130, 2014.
- [5] B. Jayanthi y J. Prashanth, «Precision Farming-Scope and Scenario in Small Farms,» *International Journal of Agricultural Engineering*, vol. 5, nº 1, pp. 117-120, 2012.
- [6] G. Ruß y R. Kruse, «Feature Selection for Wheat Yield Prediction,» *Research and Development in Intelligent Systems*, vol. 26, pp. 465-478, 2010.
- [7] J. Gago, C. Douthe, R. Coopman, P. Gallego, M. Ribas-Carbo, J. Flexas, J. Escalona y H. Medrano, «UAVs challenge to assess water stress for sustainable agriculture,» *Agricultural Water Management*, vol. 153, pp. 9-19, 2015.
- [8] M. Mahour, A. Stein, A. Sharifi y V. Tolpekin, «Integrating super resolution mapping and SEBS modeling for evapotranspiration mapping at the field scale,» *Precision Agriculture*, 2015.
- [9] J. Rouse, R. Haas, J. Schell, D. Deering y J. Harlan, «Monitoring the Vernal Advancements and Retrogradation (Greenwave Effect) of Nature Vegetation,» NASA/GSFC Final Report, Greenbelt, MD, USA, 1974.
- [10] Board on Agriculture - National Research Council, «Precision Agriculture in the 21st Century,» National Academy Press, Washington D.C., 1997.

- [11] T. Hague, N. tillet y H. Wheeler, «Automated crop and weed monitoring in widely spaced cereals,» *Precision Agriculture*, vol. 1, nº 1, pp. 95-113, 2006.
- [12] W. Lee, D. Slaughter y D. Giles, «Robotic weed control system for tomatoes using machine vision and precision chemical application,» *Precision Agriculture*, vol. 1, pp. 95-113, 1999.
- [13] D. C. Slaughter, D. K. Gilles y C. Tauzer, «Precision Offset Spray System for Roadway Shoulder Weed Control,» *Journal of Transportation Engineering*, vol. 125, nº 4, pp. 364-371, 1999.
- [14] C. F. Jordan, "Derivation of leaf area index from quality measurements of light on the forest floor,," *Ecology*, pp. 663-666, 1969.
- [15] R. Pearson y L. Miller, «Remote Mapping of Standing Crop Biomass and Estimation of the Productivity of the Short Grass Prairie, Pawnee National Grasslands, Colorado.,» de *Proceedings of the 8th International Symposium on Remote Sensing of the Environment*, Ann Arbor, MI, USA, 1972, pp. 1357-1381.
- [16] Confederación hidrográfica del Guadalquivir, «<http://idechg.chguadalquivir.es/>,» Oficina de Planificación Hidrológica, CHG, [En línea]. Available: http://idechg.chguadalquivir.es/geoportale/es/teledeteccion/introduccion.html#indice_ndvi. [Último acceso: 20 05 2015].
- [17] D. Woebbecke, G. Meyer, K. v. Barga y D. Mortensen, «Shape features for identifying young weeds using image analysis.,» *Transactions of the American Society of Agricultural Engineering*, vol. 38(1), pp. 271-281, 1995.
- [18] A. Ribeiro, C. Fernández-Quintanilla, J. Barroso y M. García-Alegre, «Development of an image analysis system for estimation of weed.,» *Proceedings of the 5th European Conference On Precision Agriculture (5ECPA)*, pp. 169-174, 2005.
- [19] J. Neto, «A Combined Statistical - Soft Computing Approach for Classification and Mapping Weed Species in Minimum Tillage Systems,» 2004.
- [20] G. Meyer, T. Hindman y K. Lakshmi, «Machine Vision Detection Parameters for Plant Species Identification,» *SPIE*, 1998.

- [21] T. Kataoka y e. al, «Crop growth estimation system using machine vision,» *The 2003 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, 2003.
- [22] M. Guijarro, G. Pajares, I. Riomoros, P. Herrera, X. Burgos-Artizzu y A.Ribeiro, «Automatic segmentation of relevant textures in agricultural images,» Elsevier, Madrid, 2010.
- [23] K.Pearson, «On lines and planes of closest fit to systems of points in space,» *Philosophical Magazine, Series 6*, vol. 2, nº 11, pp. 559-572, 1901.
- [24] H. Hotelling, «Analysis of a Complex of Statistical Variables Into Principal Components,» *Journal of Educational Psychology*, vol. 124, pp. 417-441;498-520, 1933.
- [25] M. Sewell, «<http://www.stats.org.uk>,» [En línea]. Available: <http://www.stats.org.uk/pca/>. [Último acceso: 28 05 2015].
- [26] S. Serrano, «Drexel University,» [En línea]. Available: <http://www.pages.drexel.edu/~sis26/Eigenface%20Tutorial.htm>. [Último acceso: 28 05 2015].
- [27] S. S. Panda, G. Hoogenboom y J. Paz, «Distinguishing blueberry bushes from mixed vegetation land use using high resolution satellite imagery and geoespatial techniques,» *Computers and Electronics in Agriculture*, nº 67, pp. 51-58, 2009.
- [28] N. T. T. Hanh y T. N. Dien, «Application of Principal Component Analysis Technique to Multispectral Image LANDSAT for Monitoring Change of Agricultural Land in the North Delta, Vietnam,» de *Asian Association on Remote Sensing*, 2013.
- [29] J. Wang, Y. Han, Z. Fu, D. Li, J. Chen y S. Wang, «Edge Geometric Measurement Based Principal Component Analysis in Strawberry Leaf Images,» de *Computer and Computing Technologies in Agriculture VI*, Beijing, 2013.
- [30] M. Sezgin y B. Sankur, «Survey over image thresholding techniques and quantitative performance evaluation,» *Journal of Electronic Imaging*, vol. 1, nº 13, pp. 146-165, 2004.
- [31] A. Rosenfeld y P. d. I. Torre, «Histogram concavity analysis as an aid in threshold selection,» *IEEE Transactions on Systems, Man and Cybernetics*, vol. 13, nº 2, pp. 231-235, 1983.
- [32] S. C. Sahasrabudhe y K. S. D. Gupta, «A valley-seeking threshold technique,» de *Computer*

Vision and Image Processing, Boston, L. Shapiro and A. Rosenfeld, 1992, pp. 55-65.

- [33] N. Otsu, «A threshold selection method from gray-level histogram,» *IEEE Transaction on System Man and Cybernetics*, nº 9, pp. 62-66, 1979.
- [34] T. W. Ridler y S. Calvard, «Picture thresholding using an iterative selection method,» *IEEE Transactions on Systems, Man and Cybernetics*, vol. 8, nº 8, pp. 630-632, 1978.
- [35] J. N. Kapur, P. K. Sahoo y A. K. C. Wong, «A new method for gray-level picture thresholding using the entropy of the histogram,» *Graph. Models Image Process.*, vol. 29, pp. 273-285, 1985.
- [36] C. H. Li y C. K. Lee, «Segmentation of die patterns using minimum cross entropy,» de *International Conference on Industrial Electronics, Control, Instrumentation, and Automation. Power Electronics and Motion Control*, San Diego, 1992.
- [37] L. Hertz y R. Schafer, «Multilevel thresholding using edge matching,» *Computer Vision, Graphics, and Image Processing*, vol. 44, nº 3, pp. 279-295, 1988.
- [38] X. Fernandez, «Implicit model-oriented optimal thresholding using the Komolgorov-Smirnov similarity measure,» *International Conference on Pattern Recognition*, vol. 1, pp. 466-469, 2000.
- [39] W. N. Lie, «An efficient threshold-evaluation algorithm for image segmentation based on spatial gray level cooccurrences,» *Signal Processing*, vol. 33, nº 1, pp. 121-126, 1993.
- [40] B. Chanda y D. D. Majumder, «A note on the use of gray level co-occurrence matrix in threshold selection,» *Signal Processing*, vol. 15, pp. 149-167, 1988.
- [41] Y. Nakagawa y A. Rosenfeld, «Some experiments on variable thresholding,» *Pattern Recognition*, vol. 11, nº 3, pp. 191-204, 1979.
- [42] J. M. White y G. D. Rohrer, «Image thresholding for optical character recognition and other applications requiring character image extraction,» *IBM Journal of Research and Development*, vol. 27, nº 4, pp. 400-411, 1983.
- [43] S. Aja-Fernández, G. Vegas-Sánchez-Ferrero y M. A. M. Fernández, «Soft thresholding for medical image segmentation,» de *Engineering in Medicine and Biology Society (EMBC)*,

Buenos Aires, 2010.

- [44] D. Aiteanu, «Content based threshold adaptation for image processing in industrial application,» de *International Conference on Control and Automation (ICCA)*, Budapest, 2005.
- [45] Fiji.sc, «Fiji Is Just ImageJ,» [En línea]. Available: http://fiji.sc/Particle_Analysis. [Último acceso: 11 6 2015].
- [46] X. P. Burgos-Artizzu, A. Ribeiro, M. Guijarro y G. Pajares, « Real-time image processing for crop/weed discrimination in maize fields,» *Computers and electronics in Agriculture*, vol. 2, nº 75, pp. 337-346, 2011.
- [47] G. E. Meyer y J. Camargo-Neto, «Verification of color vegetation indices for automated crop imaging applications,» *Computers and Electronics in Agriculture*, nº 63, pp. 282-293, 2008.
- [48] M. Montalvo, G. Pajares, J. M. Guerrero, J. Romeo, M. Guijarro, A. Ribeiro, J. J. Ruz y J. M. Cruz, «Automatic detection of crop rows in maize fields with high weeds pressure,» *Expert Systems with Applications*, vol. 15, nº 39, pp. 11889-11897, 2012.
- [49] M. Montalvo, J. M. Guerrero, J. Romeo, L. Emmi, M. Guijarro y G. Pajares, «Automatic expert system for weeds/crops identification in images from maize fields,» *Expert Systems with Applications*, vol. 1, nº 40, pp. 75-82, 2013.
- [50] C. Gée, J. Bossu, G. Jones y F. Truchetet, «Crop/weed discrimination in perspective agronomic images.,» *Computers and Electronics in Agriculture* 60, pp. 49-59, 2008.
- [51] G. Rees, *The Remote Sensing Data Book*, Cambridge, UK: Cambridge University Press, 1999, pp. 245-6.
- [52] R. d. E. Santo, «Principal Component Analysis applied to digital image compression,» *Einstein*, vol. 10, nº 2, pp. 135-139, 2012.
- [53] A. A. Miranda, Y.-A. L. Borgne y G. Bontempi, «New Routes from Minimal Approximation Error to Principal Components,» 2007. [En línea]. Available: http://www.ulb.ac.be/di/map/yleborgn/pub/NPL_PCA_07.pdf. [Último acceso: 5 6 2015].
- [54] Matlab, «Matlab: El lenguaje del cálculo técnico,» Mathworks, [En línea]. Available:

<http://es.mathworks.com/products/matlab/>. [Último acceso: 4 6 2015].

- [55] SVS-VISTEK, «The focal point of machine vision,» SVS-VISTEK, [En línea]. Available: <https://www.svs-vistek.com>. [Último acceso: 4 6 2015].
- [56] R. Gonzalez, R. Woods y S. Eddins, *Digital Imagen Processing using Matlab*, Upper Saddle River, NY: Prentice Hall, 2004.
- [57] J. Blasco, N. Aleixos, J. Roger, G. Rabatel y E. Moltó, «Robotic weed control using machine vision,» *Biosyst. Eng.*, vol. 83, nº 2, pp. 149-157, 2002.
- [58] W. Lee, D. Slaughter y D. Giles, «Development of a machine vision system for weed control using precision chemical application,» *Proceedings of International Conference on Agricultural Machinery Engineering*, pp. 802-811, 1996.
- [59] J. Hamming y T. Rath, «Computer-vision based weed identification under field conditions using controlled lighting,» *Agricultural Engineering Research*, vol. 78, nº 3, pp. 233-243, 2001.
- [60] L. Zheng, J. Zhang y Q. Wang, «Mean-shift-based color segmentation of images containing green vegetation,» *Computer Electronics in Agriculture*, vol. 65, pp. 93-98, 2009.

Listado de acrónimos

CIVE	Color Index of Vegetation Extraction
COM	Combined approach
ExG	Excess Green
ExGR	Excess Green minus excess Red
ExR	Excess Red
FN	False Negative
FP	False Positive
IPCA	Image COM
LIDAR	Light Detection And Ranging / Laser Imaging Detection And Ranging
NDI	Normalized Difference Index
PCA	Principal Component Analysis
RGB	Red, Green and Blue
SONAR	Sound Navigation And Ranging
TN	True Negative
TP	True Positive
UAV	Unmanned Aircraft Vehicle
VEG	Vegetative (index)

