

Algoritmos de extracción de *endmembers* en imágenes hiperespectrales

A. Plaza, P. Martínez, J. Plaza, R. M. Pérez, P. L. Aguilar, M. C. Cantero
aplaza@unex.es

*Grupo de Redes Neuronales y Procesamiento de Señal (GRNPS).
Departamento de Informática, Universidad de Extremadura
Avda. de la Universidad s/n, 10071 Cáceres*

RESUMEN

En este trabajo, presentamos una nueva metodología para el análisis de píxeles mezcla en imágenes hiperespectrales cuya principal aportación es la integración de información espacial y espectral en el proceso de análisis. La técnica propuesta se basa en la extensión de operadores morfológicos clásicos. Para validar el método utilizamos imágenes sintéticas y reales proporcionadas por el sensor aerotransportado AVIRIS. Los resultados obtenidos con imágenes sintéticas demuestran que el método es robusto en presencia de ruido. Una comparativa del método con otras aproximaciones estándar refleja las elevadas prestaciones del mismo a la hora de procesar datos reales.

PALABRAS CLAVE: Análisis hiperespectral, *endmembers*, desmezclado espectral, morfología matemática.

ABSTRACT

We present in this work a novel automated method for the analysis of mixed pixels in hyperspectral data that integrates both spatial and spectral responses in simultaneous fashion. The method is based on mathematical morphology, a classic image processing technique that provides a remarkable framework to achieve the desired integration. An evaluation of the proposed approach is carried out by using both simulated and real hyperspectral data, collected by the AVIRIS imaging spectrometer. Results with simulated data reveal that the method is robust in the presence of noise. On other hand, experiments with real hyperspectral data show that the proposed method produces results which can improve those found using other widely accepted hyperspectral analysis methodologies.

INTRODUCCIÓN

En los últimos años, la evolución en los sensores hiperespectrales ha supuesto un salto cualitativo en las aplicaciones orientadas a la observación remota de la tierra. Estos instrumentos se caracterizan por su capacidad para medir la radiación reflejada en una amplia gama de longitudes de onda, pudiendo registrar información en cientos de canales espectrales (Green y col., 1998). Las técnicas de desmezclado espectral o spectral unmixing son, en la actualidad, las más ampliamente aceptadas a la hora de llevar a cabo el análisis y clasificación de imágenes hiperespectrales. Estas técnicas suelen consistir en dos pasos claramente diferenciados: en primer lugar, se identifican firmas espectrales asociadas a componentes espectralmente puros en la imagen, denominados *endmembers*. A continua-

ción, el resto de componentes de la imagen se expresan mediante combinaciones de *endmembers*, evitando así el habitual problema de la mezcla espectral y permitiendo realizar una cuantificación a nivel sub-píxel. A lo largo de los últimos años se han desarrollado diversos los métodos supervisados y no supervisados para identificar *endmembers* en imágenes hiperespectrales (Chang, 2003). Uno de los métodos supervisados más utilizados es PPI (Píxel Purity Index), que tiene como objetivo localizar los puntos espectralmente más puros de la imagen hiperespectral. Para ello, el método se basa en la suposición de que los puntos más extremos de la nube de puntos son los mejores candidatos para ser utilizados como *endmembers*. Esta misma suposición es utilizada por otros métodos de naturaleza automática, como N-FINDR, que utiliza una técnica basada en identificar los *endmembers* como los

vértices del simplex de mayor volumen que puede formarse en la nube de puntos dada por todos los píxeles de la imagen hiperespectral.

A pesar de la fuerte interrelación entre la información espacial y espectral que reside en las imágenes hiperespectrales, la mayor parte de las técnicas de identificación de *endmembers* y desmezclado existentes en la actualidad tienden a considerar únicamente la información espectral, descartando la correlación espacial entre los píxeles de la imagen. En la actualidad, la importancia de analizar de forma simultánea los patrones espaciales y espectrales ha sido reconocida por la comunidad científica como un objetivo altamente deseable, el cual puede introducir una mejora en los resultados proporcionados por técnicas estándar de análisis hiperespectral (Landgrebe, 2002). En este trabajo, describimos un nuevo método automático para el análisis y clasificación de imágenes hiperespectrales, cuya principal aportación es la consideración simultánea de información espacial y espectral. El método se basa en conceptos de morfología matemática, una técnica clásica de análisis de imágenes que es generalizada al caso de imágenes multi-dimensionales en este trabajo. A la hora de validar la nueva metodología propuesta, utilizamos datos simulados y reales adquiridos por el sensor hiperespectral de altas prestaciones AVIRIS, demostrando su utilidad en diferentes aplicaciones.

MÉTODOS

En este apartado presentamos la nueva metodología propuesta para identificar firmas espectrales puras o *endmembers* en imágenes hiperespectrales. Inicialmente, describimos un esquema para extender las operaciones morfológicas clásicas al caso de imágenes hiperespectrales. Este paso permite obtener operadores morfológicos capaces de caracterizar de forma precisa cada uno de los píxeles de la imagen en el dominio espacial y espectral. A continuación, se describe en detalle el algoritmo propuesto, basado en la aplicación de operadores morfológicos extendidos sobre la imagen original, tarea que se complementa con técnicas de crecimiento de regiones.

Matemática morfológica extendida

Las operaciones morfológicas básicas (dilatación y erosión) se basan respectivamente en el cálculo del valor máximo y mínimo en una vecindad o

región espacial alrededor de cada píxel de la imagen a procesar, donde la forma y tamaño de la región considerada vienen determinadas por las propiedades espaciales de una función de vecindad denominada elemento estructural (Soille, 1999). El principal problema a la hora de extender estas operaciones al caso de imágenes hiperespectrales consiste en la ausencia de una relación de orden en los píxeles de la imagen. Este hecho se debe al carácter vectorial de dichos píxeles, que vienen caracterizados por un vector de N valores cada uno, siendo N es el número de bandas espectrales. El esquema desarrollado para lograr la extensión se basa en las siguientes definiciones (Plaza y col., 2002). Sea $f(x,y)$ un vector de N dimensiones asociado con un píxel en las coordenadas espaciales (x,y) . Sea $K = \{f(x,y); (x,y) \in Z^2(K)\}$ un conjunto que denota los vectores que pertenecen al elemento estructural K utilizado en la operación morfológica, donde $Z^2(K)$ constituye el conjunto de posiciones (s,t) de dicho elemento. Del mismo modo, sea M el número de elementos en la vecindad impuesta por el elemento estructural K alrededor del píxel $f(x,y)$. Si denotamos como $k(s,t)$ al vector asociado a cada uno de los elementos del elemento estructural y denominamos Dist a la distancia angular entre los vectores correspondientes a dos píxeles $f(x,y)$ y $f(x',y')$ de la imagen, podemos definir la distancia acumulada D entre un determinado píxel, $f(x,y)$, donde $(x,y) \in K$, y el resto de los elementos de K mediante las dos siguientes expresiones:

$$D^+(f(x,y), K) = \sum_{(s,t) \in Z^2(K)} \text{Dist}(f(x,y), f(x-s, y-t) + k(s,t))$$

$$D^-(f(x,y), K) = \sum_{(s,t) \in Z^2(K)} \text{Dist}(f(x,y), f(x+s, y+t) - k(s,t))$$

Una vez definidas estas expresiones, es posible extender las operaciones de dilatación y erosión a imágenes hiperespectrales de forma intuitiva. En concreto, las operaciones de dilatación y erosión hiperespectral pueden expresarse, respectivamente, de la siguiente forma:

Abundancia Vegetación (verdad terreno)	Abundancia <i>endmember</i> 1 (SNR=10:1)	Abundancia <i>endmember</i> (SNR=3:1)
--	--	---



En ambos casos, los operadores \arg_Max y \arg_Min seleccionan, respectivamente, el píxel de la vecindad para el cual el valor de la distancia acu-

mulada D es máximo/mínimo. Estos elementos corresponden al píxel espectralmente más puro y al menos puro en la vecindad espacial definida por el elemento estructural.

Algoritmo propuesto

El método propuesto ha sido denominado Automated Morphological *Endmember* Extraction (AMEE), y su funcionamiento aparece ilustrado mediante un diagrama de bloques en la Figura 1.




Figura 1. Diagrama de bloques que resume el funcionamiento del método propuesto.

Como puede apreciarse en la Figura 1, el primer paso del algoritmo consiste en la aplicación de operadores morfológicos extendidos sobre la imagen hiperespectral original. Cada píxel es evaluado en términos de su pureza espectral en el dominio espacial definido por el elemento K de la operación morfológica. En este paso, se consideran elementos estructurales progresivamente crecientes, lo cual permite interpretar la pureza espectral del píxel en diferentes escalas espaciales. El segundo paso del algoritmo propuesto tiene como objetivo la identificación automatizada de un conjunto de píxeles puros a partir de la información obtenida en la etapa anterior. El proceso de selección de píxeles puros a partir de dicha imagen se realiza utilizando el método de umbralizado automático de Otsu. La tercera etapa del algoritmo consiste en aplicar un proceso opcional de crecimiento de regiones, que permite obtener un conjunto de regiones coherentes desde un punto de vista espacial y espectral, a partir de las cuales se obtiene una lista de *endmembers*. El último paso del algoritmo propuesto tiene como objetivo la eliminación de posibles instancias redundantes en la lista final de *endmembers* obtenida como resultado de la etapa de crecimiento.

RESULTADOS

En este apartado presentamos una evaluación del método propuesto utilizando imágenes sintéticas y reales. Las pruebas con imágenes sintéticas están orientadas a evaluar de forma preliminar el funcionamiento de la metodología propuesta, estudiando el ajuste de parámetros y su impacto en el resultado final. Por otra parte, el uso de imágenes reales permite establecer un estudio comparativo del algoritmo propuesto con respecto a otros ya existentes de amplia utilización por parte de la comunidad científica dedicada al análisis de imágenes hiperespectrales.

Datos sintéticos

El procedimiento adoptado a la hora de generar imágenes sintéticas consta de los siguientes pasos. Inicialmente, se selecciona un conjunto base de firmas espectrales de referencia obtenidas a partir de un sensor real (AVIRIS). A continuación, se establece de forma artificial la abundancia de cada una de las referencias elegidas en cada píxel de la imagen, de forma que la contribución individual de cada firma se expresa mediante un conjunto de coeficientes de abundancia que cumplen las restricciones de no-negatividad y suma unitaria, propias del modelo lineal de mezcla (Landgrebe, 2002). Finalmente, se realiza un proceso de simulación de ruido utilizando el procedimiento descrito en (Chang, 2003). El ruido se añade en diferentes proporciones, dando lugar a diferentes valores de relación señal-ruido (SNR).




Figura 2. Mapas de abundancia verdad terreno y valores de abundancia estimados por AMEE en presencia de diferentes valores de SNR.

A continuación, mostramos los resultados obtenidos con una imagen sintética que representa una situación de mezcla progresiva entre dos componentes espectrales claramente diferenciados: vegetación y suelo. La imagen simulada consta de 100x100 píxels de 224 valores espectrales cada uno. Las firmas empleadas para generar la imagen han sido extraídas de una imagen obtenida en 1997 por el sensor AVIRIS sobre la región Jasper Ridge en California, Estados Unidos. La Figura 2 muestra los mapas de abundancia obtenidos al aplicar el método propuesto sobre esta imagen, generada utilizando valores SNR de 10:1, 30:1 y 50:1. Por razones ilustrativas, los coeficientes de abundancia verdad terreno para vegetación y suelo aparecen también representados en forma de imagen en la Figura 2.




Figura 3. Diagramas de dispersión de abundancias reales/estimadas para *endmembers* extraídos.

Los diagramas de dispersión y sus correspondientes coeficientes de correlación, mostrados en la Figura 3, revelan que la estimación de abundancias realizada por el método propuesto es muy elevada para valores de SNR de 30:1 o superior. Si tenemos en cuenta las elevadas prestaciones en cuanto a SNR ofrecidas por los sensores actuales, podemos concluir que el método propuesto ofrece resultados satisfactorios en condiciones de ruido extremo. Con vistas a poder comprobar esta afirmación en un escenario real, presentamos a continuación resultados obtenidos con datos hiperespectrales reales.

Datos reales

Para evaluar el método propuesto con datos reales, hemos utilizado una imagen hiperespectral adquirida en 1995 por el sensor AVIRIS sobre la

región *Cuprite mining district*, en Nevada, Estados Unidos. La imagen consta de 400x350 píxels, cada uno de los cuales consta de 50 valores de reflectancia en el rango espectral 2 a 2.5 μm . En este rango de longitudes de onda se manifiestan singularidades que permiten discriminar entre una amplia gama de minerales de tipo calizo. La información de verdad terreno para la imagen ha sido hecha pública por *U.S. Geological Survey* (Clark, 1999). La disponibilidad de esta información de verdad terreno, que incluye valores de abundancia de diferentes minerales en la imagen, ha motivado la estandarización de esta imagen como referencia a la hora de testear el funcionamiento de nuevos algoritmos de análisis hiperespectral. En concreto, en este apartado comparamos los resultados proporcionados por nuestro método con otros métodos estándar de extracción de *endmembers*. Así, la Tabla 1 muestra el error cuadrático medio (RMSE) obtenido al estimar la abundancia de cuatro minerales (*alunite*, *buddingtonite*, *calcite* y *kaolinite*) presentes en la zona de estudio, utilizando los métodos de extracción de *endmembers* PPI, N-FINDR y AMEE.

Mineral	AMEE	N-FINDR	PPI
Alunite	0.05	0.05	0.05
Buddingt.	0.12	0.13	0.15
Calcite	0.07	0.08	0.09
Kaolinite	0.05	0.06	0.04

Figura 1. RMSE entre abundancias reales/estimadas por PPI, N-FINDR y AMEE para cuatro minerales.

Los resultados mostrados en la Tabla 1 revelan un comportamiento muy similar de los tres métodos, en términos globales, para el mineral *alunite*, siendo el error cometido del 5% en todos los casos. En el caso del mineral *buddingtonite*, el error cometido aumenta en los tres casos, siendo siempre superior al 10%. Por último, la estimación de la abundancia en el caso de los minerales *calcite* y *kaolinite* es bastante precisa en todos los casos, siendo el algoritmo PPI el que ofrece los resultados más bajos para el mineral *calcite*, con un error global del 9%, y N-FINDR el que ofrece los resultados más bajos para el mineral *kaolinite*, con un error global del 6%. Como puede apreciarse en la tabla, los resultados proporcionados por el método AMEE son ligeramente superiores a los obtenidos por PPI y N-

FINDR. Este hecho pone de manifiesto la importancia de considerar de forma conjunta la información espacial y espectral a la hora de llevar a cabo el proceso de selección de *endmembers*.

CONCLUSIONES Y LÍNEAS FUTURAS

En este trabajo hemos presentado y evaluado un nuevo método automático para el análisis y clasificación de imágenes hiperespectrales que considera la información espacial y espectral de forma combinada. La evaluación del método con imágenes hiperespectrales simuladas revela que las operaciones morfológicas extendidas pueden ser utilizadas para extraer *endmembers* a partir de las características espaciales y espectrales de los objetos presentes en la escena. El ajuste de las propiedades espaciales de las operaciones morfológicas permite adaptar el método a aplicaciones muy diversas, siendo su funcionamiento muy robusto en presencia de ruido. Por otra parte, los experimentos realizados con imágenes reales demuestran que el método proporciona resultados superiores a los obtenidos utilizando otras técnicas estándar de análisis hiperespectral. Entre las líneas futuras de trabajo destacamos el desarrollo de implementaciones paralelas del méto-

do propuesto en arquitecturas especializadas y supercomputadores paralelos, con vistas a aumentar el rendimiento computacional del mismo y su explotación en tiempo casi real.

BIBLIOGRAFÍA

- CHANG, C.-I. 2003. *Hyperspectral imaging: spectral detection and classification*. Kluwer Academic Publishers.
- CLARK, R. N. 1999. *Spectroscopy of rocks and minerals, and principles of spectroscopy*. John Wiley and sons.
- GREEN, R. O. y col. 1998. Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (AVIRIS). *Remote Sensing of Environment*, vol. 65, pp. 227–248.
- LANDGREBE, D. 2002. Hyperspectral Image Data Analysis. *IEEE Signal Processing Magazine*, vol. 19, pp. 17–28.
- PLAZA, A., MARTÍNEZ, P., PÉREZ, R. y PLAZA, J. 2002. Spatial/spectral *endmember* extraction by multidimensional morphological operations. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 40, pp. 2025–2041.
- SOILLE, P. 1999. *Morphological Image Analysis – Principles and applications*. Springer-Verlag.

