

Memorias



Sociedad Latinoamericana en
Percepción Remota y Sistemas
de Información Espacial
Capítulo Colombia

30
AÑOS

Medellín, Colombia
29 de Septiembre al 3 de Octubre de 2014



INTEGRACIÓN DE LA INFORMACIÓN ESPACIAL Y ESPECTRAL A TRAVÉS DE REPRESENTACIONES EN MULTIESCALA PARA EL PROCESAMIENTO DE IMÁGENES HIPERESPECTRALES

Maria C. Torres-Madroño

Instituto Tecnológico Metropolitano

Campus Fraternidad Cll 54 A 30-01, Medellín Colombia

mariatorres@itm.edu.co

Docente Ocasional Facultad de Ingenierías

RESUMEN

El incremento de la disponibilidad de sensores con alta resolución espacial y espectral abre nuevas posibilidades para la exploración remota de la superficie de la tierra. Al mismo tiempo, nuevos retos son impuestos para el desarrollo de algoritmos que permitan de una forma efectiva y precisa extraer la información contenida en las imágenes capturadas con sensores de este tipo. Uno de los mayores retos es el desarrollo de técnicas de procesamiento que exploren la información espacial y espectral de las imágenes hiperespectrales. Se ha demostrado que las técnicas que se basan en la información espacial y espectral proporcionan mejores resultados que las técnicas que únicamente usan el espectro. Una forma de incorporar la información espacial en el procesamiento de imágenes hiperespectrales es el uso de representación en multiescala de la imagen obtenida desde la solución de ecuaciones diferenciales parciales. Las representaciones en multiescala construyen una familia de imágenes donde los detalles más finos son sistemáticamente

removidos. Las representaciones en multiescalas permiten realizar un pre-procesamiento a las imágenes. Sin embargo, es necesario seleccionar una de las escalas para realizar el análisis de las imágenes. En este artículo se presenta la comparación de varios criterios para la selección de escala aplicado a la clasificación de imágenes hiperespectrales.

Palabras claves: imágenes hiperespectrales, procesamiento de imágenes, representación en multiescala, percepción remota, difusión no lineal, selección de escala.

INTRODUCCIÓN

La percepción remota emplea sensores sobre plataformas satelitales o aéreas para adquirir información de la superficie terrestre, la atmósfera y los océanos. La gran diversidad de aplicaciones que tienen los sistemas de percepción remota ha permitido el desarrollo de diferentes tipos de sensores, entre los que se destacan los sensores hiperespectrales. Los sensores hiperespectrales miden la radiancia emitida o reflejada por una superficie a lo largo del espectro electromagnético, al mismo tiempo que capturan información espacial (Schowengerdt 2007), permitiendo así identificar remotamente materiales, monitorear las superficies terrestres, estudiar el cambio climático, y desarrollar aplicaciones militares (Schowengerdt 2007, Richards & Jia 2006).

Entre las técnicas más empleadas para el procesamiento de imágenes hiperespectrales se encuentran la clasificación y el desmezclado lineal (Shaw & Manolakis 2002). La clasificación de una imagen consiste en la asignación de etiquetas (clases) a cada pixel del cubo espectral a partir de reglas aprendidas desde datos de entrenamiento (clasificación supervisada) o desde la identificación automática de píxeles similares (clasificación no

supervisada). Por otra parte, el desmezclado lineal extrae las firmas espectrales de los materiales presenten en una escena y las fracciones de áreas en las cuales cada uno de estos materiales cubren un pixel.

Usualmente, la clasificación y desmezclado de imágenes espectrales se realiza empleando únicamente la información espectral, es decir, no se tiene en cuenta la relación espacial que existe entre pixeles. Varios investigadores han señalado la importancia de desarrollar técnicas para el procesamiento de imágenes espectrales que tenga en consideración tanto la información espectral como la información espacial (Blaschke 2010; Blaschke, & Strobl 2001; Plaza et al. 2009). Tanto para la clasificación como desmezclado de imágenes espectrales, se encuentran en la literatura algunas técnicas que combinan la información espacial-espectral. Ejemplo de estas técnicas son los trabajos desarrollados por Plaza et al. (2002), Jimenez et al. (2005), Yu et al. (2006), Rogge et al. (2007), Martin & Plaza (2011), y otros. Las técnicas encontradas en la literatura que combinan la información espacial y espectral se pueden dividir en dos categorías. La primera incluye las técnicas que usan kernels espaciales (ventanas) que permiten incluir la información espacial en métodos espectrales. El mayor problema con estas técnicas es la dependencia de los resultados con el tamaño del kernel seleccionado. La segunda categoría de técnicas incluyen los algoritmos que usan segmentación para identificar regiones homogéneas en las imágenes. La segmentación consiste en dividir la imagen dentro de regiones con características espectrales similares, este proceso es no supervisado y puede tener un alto costo computacional.

Duarte et al. (2008) desarrolló una técnica de representación en multiescala para imágenes hiperespectrales que permite combinar la información espacial y espectral para la

clasificación. Por otro lado, Torres-Madronero (2013) usa la representación en multiescala desarrollada por Duarte et al. (2008) para incluir la información espacial en el desmezclado lineal. La representación en multiescala permite incluir la información espacial en los procesos espectrales sin la necesidad de definir kernels espaciales o usar segmentación. La representación multiescala construye una familia de imágenes donde los detalles finos son sistemáticamente eliminados usando operaciones de suavizado (Lindeberg 1994). Por ejemplo, una representación en multiescala puede obtenerse usando filtros gaussianos lineales con diferentes varianzas. El conjunto de varianzas genera varios niveles de suavizado que define lo que se conoce como un espacio de escala para una imagen. La operación de suavizado usando filtros gaussianos se conoce como difusión isotrópica debido al efecto de difundir la información de la misma forma en todas las direcciones. El problema con la difusión isotrópica es que además de eliminar el ruido en las imágenes también elimina información relevante como los bordes. De esta manera, para la generación de representaciones multiescala de imágenes, en vez de usar difusión isotrópica, se emplea técnicas de difusión no lineal. La difusión no lineal suaviza una imagen manteniendo los bordes (Lindeberg 1994; Sapiro 2001). Esta difusión se obtiene a partir de la solución sucesiva de ecuaciones diferenciales parciales, para lo cual existen diferentes métodos como los que se pueden encontrar en Duarte et al. (2007) y Marin-Quintero (2012).

Duarte et al. (2008) y Torres-Madronero (2013) reconocen la importancia que tiene el uso de representaciones multiescala en los procesos de clasificación y desmezclado. Sin embargo, para hacer un uso apropiado de estas representaciones es necesario identificar una escala de la imagen que sea adecuada para mejorar los resultados obtenidos por la clasificación y el desmezclado lineal de imágenes hiperespectrales. En este artículo se

presenta una comparación entre diferentes métodos de selección de escala para la clasificación de imágenes hiperespectrales reales.

METODOLOGÍA

Representación Multiescala

La difusión no lineal de una imagen hiperespectral $\mathbf{Y} = [y_1, \dots, y_m]^T$ con n bandas espectrales y m píxeles se obtiene al solucionar la ecuación diferencial parcial no lineal de la ecuación (1), donde: y_σ es una versión suavizada de la imagen original $\mathbf{Y}$ que se obtiene a partir de un filtro Gaussiano con media cero y desviación estándar σ , θ es una medida para identificar los bordes y g es el coeficiente de difusión (Duarte et al. 2008).

$$\frac{\delta y_i}{\delta t} = \nabla[g(\theta)\nabla y_i] \quad i = 1, \dots, m \quad (1)$$

El coeficiente de difusión está dado por la ecuación (2) donde α es un umbral que controla la difusión (Weickert et al. 1998).

$$g(\theta) = \begin{cases} 1 & \theta = 0 \\ 1 - e^{-\frac{3.31488}{(\theta/\alpha)^8}} & \theta > 0 \end{cases} \quad (2)$$

Para solucionar las ecuaciones diferenciales parciales y obtener la representación multiescala de una imagen hiperespectral, se emplea el algoritmo propuesto por Duarte et al. (2008) basado en métodos *mutligrid*.

Criterios de Selección de Escala

La representación en multiescala obtiene una familia de imágenes hiperespectrales suavizadas $\{\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_T\}$. Por lo tanto, para utilizar este tipo de representaciones para el procesamiento de imágenes hiperespectrales se requiere seleccionar una de las imágenes, es decir, seleccionar la escala en la cual se realizara el análisis. Varios criterios de selección de

escala han sido propuesto (Weickert 2009, Mrazek & Navarra 2003, Sporring & Weickert 1999, Vanhamel et al. 2009, Jiabin & Guizhong 2008, Torres-Madronero & Velez-Reyes 2013). La mayoría de estos criterios se han desarrollado para aplicaciones de filtrado, y algunos para reconstrucción de imágenes.

Sporring & Weickert (1999) sugieren usar la escala donde se obtiene el mínimo cambio de entropía. La entropía de una imagen hiperespectral se puede obtener desde el promedio de la entropía de cada una de sus bandas espectrales dada por la ecuación (3), donde p_i es el número de píxeles para cada valor de intensidad.

$$S_l = -\sum_{i=1}^K p_i \log p_i \quad (3)$$

Mrazek & Navarra (2003) proponen el método de decorrelación. Este criterio busca minimizar la correlación entre la imagen suavizada $\mathbf{Y}_t$ y la imagen de diferencia $\mathbf{Y}_t - \mathbf{Y}$. Se espera que esta correlación decrezca en la medida que más iteraciones de suavizado son realizadas. Sin embargo, cuando las operaciones de suavizado empiezan a remover detalles significativos de la imagen, esta correlación empieza a incrementar. Seleccionar la escala donde la correlación es mínima busca garantizar que los detalles importantes de la imagen no sean removidos. Este método fue inicialmente formulado para imágenes en escala de grises, su generalización para imágenes vectoriales se obtiene al calcular el promedio de las correlaciones obtenidas en cada banda espectral (Vanhamel et al. 2009).

Jiabin & Guizhong (2008) proponen un criterio de selección de escala que busca el balance de la difusión, es decir, el balance entre la energía de la imagen suavizada $\mathbf{Y}_t$ y la imagen de diferencia $\mathbf{Y}_t - \mathbf{Y}$. Para generalizar este criterio a imágenes vectoriales, se usa la norma Frobenious como la medida de la energía.

Los criterios anteriormente presentados han sido diseñados para aplicaciones de filtrado de imágenes en escala de grises. Torres-Madronero & Velez-Reyes (2013) introducen un criterio de selección de escala para aplicaciones con imágenes hiperespectrales. Este criterio se basa en el hecho que la diferencia entre la imagen suavizada y la imagen original tiene más detalles a medida que las iteraciones de suavizado son realizadas. De esta forma, la entropía de las imágenes de diferencia $Y_t - Y$ incrementa con el número de iteraciones. Este criterio asume la entropía como una medida de información. Por lo tanto, cuando más iteraciones de suavizados son realizadas, más información es removida de la imagen. Torres-Madronero & Velez-Reyes (2013) proponen seleccionar la escala donde el cambio de la entropía de $Y_t - Y_0$ es pequeño, es decir, donde la curva de cambio de entropía tiene un punto de quiebre.

Usualmente, los criterios de selección de escala buscan el punto mínimo de alguna medida. Sin embargo, y como se demuestra en los experimentos a continuación, la mayoría de las veces este mínimo no existe, en cambio, los criterios generan una curva que decrece suavemente con un codo o un punto de quiebre. De esta manera, cuando no existe un punto mínimo, la escala optima se selecciona como el punto de quiebre o el final del codo.

Experimentos

La comparación de los criterios de selección de escala para la clasificación de imágenes hiperespectrales se realiza usando una imagen real capturada con el sensor AVIRIS en junio de 1992, sobre un área de agricultura en West Lafayette en Estados Unidos. La imagen denominada Indian Pines tiene 145x145 píxeles y 220 bandas espectrales entre los 400 y 2500 nm. Para esta imagen existe un mapa de clasificación que discrimina 16

diferentes tipos de materiales (disponible en <https://engineering.purdue.edu/~biehl/MultiSpec/>). La Figura 1 presenta una composición en RGB de la imagen hiperespectral y la Figura 2 muestra el mapa de clasificación.



Figura 1. Composición RGB Indian Pines: bandas 42, 32 y 14.




Figura 2. Mapa de clasificación Indian Pines.

Usando el algoritmo desarrollado por Duarte et al. (2008) se obtiene una representación en multiescala de la imagen Indian Pines. Se realizaron 20 iteraciones de suavizado con un coeficiente de difusión igual a 0.01. La Figura 3 muestra la composición RGB de una imagen suavizada en la iteración 4.



Figura 3. Imagen suavizada en la iteración 4.

En el primer experimento, se clasificó la imagen original y las 20 imágenes suavizadas usando un clasificador basado en máquinas de soporte vectorial con un kernel polinomial de segundo orden. Para la clasificación se seleccionaron aleatoriamente 20 muestras de entrenamiento por clase y se calculó la precisión del clasificador. La clasificación se repitió 100 para cada imagen variando las muestras de entrenamiento. A partir de este experimento, se determina el desempeño del clasificador respecto al número de interacciones de suavizado.

En el segundo experimento, se aplicaron los métodos de selección de escala anteriormente presentados, y se comparó el desempeño del clasificador en cada una de las escalas seleccionadas.

Resultados

La Tabla 1 presenta la precisión de clasificación obtenida para la imagen Indian Pines sin suavizado y para cada una de las imágenes en la representación multiescala en las primeras

12 iteraciones. La precisión mostrada en la Tabla 1 es el resultado de promediar los resultados obtenidos de las 100 pruebas donde se variaron las muestras de entrenamiento.

Tabla 1. Precisión de Clasificación Indian Pines.

Imagen sin suavizado												
Precisión (%)	67.2											
Imágenes con suavizado												
Iteración	1	2	3	4	5	6	7	8	9	10	11	12
Precisión (%)	87.9	90.1	90.3	90.4	90.0	89.5	88.1	88.7	88.9	88.9	88.5	88.1

La Figura 4 presenta el resultado obtenido para el criterio de selección de escala propuesto por Mrazek & Navarra (2003). Para este criterio, se obtuvo el resultado descrito por Mrazek & Navarra (2003), donde se nota que la correlación entre la imagen suavizada Y_t y la imagen de diferencia $Y_t - Y$ decrece hasta la iteración seis, donde alcanza el punto mínimo, y empieza a crecer en las posteriores iteraciones de suavizado.




Figura 4. Criterio de decorrelación de Mrazek & Navarra (2003).

La Figura 5 presenta los resultados obtenidos para el criterio de balance de difusión. Para este caso, no se obtuvo un punto mínimo, en cambio se obtuvo una curva suave con un

codo. Para seleccionar la escala se determinó el final del codo aproximadamente ya que después de este punto la diferencia de los cambios de energía es pequeña, obteniendo que la escala adecuada está dada por el suavizado en la iteración 12.




Figura 5. Criterio de Balance de Difusión de Jiabin & Guizhong (2008).

La Figura 6 presenta el resultado obtenido con el criterio de mínimo cambio de entropía propuesto por Sparring & Weickert (1999). Similar al resultado obtenido para el criterio de balance de difusión, en este caso también se obtuvo una curva suave donde el final de codo fue aproximado a la iteración 10.




Figura 6. Criterio de mínimo cambio de entropía de Sparring & Weickert (1999).

Por último, la Figura 7 presenta la curva obtenida para el cambio de entropía de la diferencia $Y_t - Y$. El resultado presenta el comportamiento esperado, decreciendo la cantidad de información significativamente en las iteraciones iniciales. La escala seleccionada se estableció al final del codo de la curva que se aproximó a la iteración 8.




Figura 7. Criterio cambio de entropía de la diferencia de Torres-Madronero & Velez-Reyes (2013).

La Tabla 2 presenta el resumen de las escalas seleccionadas por cada uno de los criterios y la precisión de clasificación obtenida en cada una de ellas.

Tabla 2. Resultados Criterios de Selección de Escala.

Método	Decorrelación	Balance de difusión	Cambio de entropía	Cambio de entropía de diferencia
Escala Seleccionada (iteración)	6	12	10	8
Precisión (%) de Clasificación	89.5	88.1	88.9	88.7

Discusión de Resultados

Los resultados de clasificación obtenidos a partir de la imagen de Indian Pines sin suavizado y con suavizado desde la representación multiescala (Tabla 1), muestra claramente como la precisión incrementa con el uso de representaciones multiescala. Para las diferentes escalas se obtuvo un mejor resultado que la clasificación de la imagen sin suavizado. Adicionalmente, estos resultados muestran que la precisión mejora en las primeras iteraciones, sin embargo, después de cierto punto la precisión empieza a decrecer consecuencia de la información relevante que elimina las iteraciones de suavizado. A partir de estos resultados, la escala ideal para realizar la clasificación es la iteración cuatro, donde se obtiene el mejor resultado de clasificación con un 90.4% de precisión.

Aplicando los criterios de selección de escala encontrados en la literatura notamos que, dependiendo del criterio utilizado, obtenemos diferentes escalas. Sin embargo, ninguno de ellos selecciona la imagen obtenida en la iteración cuatro. De las escalas seleccionadas, el mejor resultado fue el obtenido por la imagen en la iteración seis, seleccionada con el criterio de decorrelación de Mrazek & Navarra (2003). Adicionalmente, este criterio muestra

el comportamiento esperado, identificando un punto mínimo de la correlación de la imagen suavizada Y_t y la imagen de diferencia $Y_t - Y$.

Para los otros criterios estudiados, se ve un claro problema en el momento de determinar la escala, ya que esta depende de la aproximación del final del codo de la curva. Con estos resultados se plantea la necesidad de diseñar criterios diferentes que permitan de manera automática la selección de la escala para la representación multiescala de imágenes hiperespectrales para aplicaciones de clasificación.

CONCLUSIONES

A través de los resultados presentados, se muestra claramente como la representación en multiescala mejora los resultados de clasificación de imágenes hiperespectrales. Sin embargo, la selección de escala con la mayoría de los criterios existentes es difícil, dado que los resultados obtenidos para estos describen curvas suaves, donde la escala debe ser determinada desde la selección del punto al final del codo de la curva. De los criterios comparados en este artículo, los mejores resultados los presento el criterio de decorrelación propuesto por Mrazek & Navarra (2003).

Como trabajo futuro se plantea, diseñar criterios de selección de escala que se puedan entrenar desde las muestras de entrenamiento disponibles. Adicionalmente, se buscará extender este tipo de comparaciones para otros procedimientos de imágenes hiperespectrales como son el desmezclado lineal.

REFERENCIAS BIBLIOGRÁFICAS

Blaschke, T., (2010). Object based image analysis for remote sensing. *Journal of photogrammetry and remote sensing*. 4, 2-16.

- Blaschke, T., & Strobl, J., (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and gis. *Zeischrift fur geoinformation systeme*, 44, 12-17.
- Duarte, J. M., Castillo, P., & Velez-Reyes, M., (2007). Comparative study of semiimplicit schemes for nonlinear diffusion in hyperspectral imagery. *IEEE Transactions on Image Processing*, 16(5), 1303–1314.
- Duarte, J. M., Sapiro, G., Velez, M., & Castilo, P., (2008). Multiscale representation and segmentation of hyperspectral imagery using geometric partial differential equations and algebraic multigrid methods. *IEEE Transactions on Geosciences and Remote Sensing*, 46(8), 1303–1314.
- Jiabin, Y., & Guizhong, L. (2008). A Novel Anisotropic Diffusion Time Estimation Method. *Congress on Image and Signal Processing*, 3, 241–244.
- Jimenez, L., Rivera-Medina, J., Rodriguez-Diaz, E., Arzuaga-Cruz, E., & Ramirez-Velez, M., (2005). Integration of spatial and spectral information by means of unsupervised extraction and classification for homogeneous objects applied to multispectral and hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 43(4), 844–851.
- Lindeberg, T., (1994). *Scale-space Theory in Computer Vision*. Kluwer Academic Publisher.
- Marin-Quintero, M. J., (2012). *An adaptive spectrally weighted structure tensor applied to tensor anisotropic nonlinear diffusion for hyperspectral images*. Tesis de Doctorado, Universidad de Puerto Rico, Mayaguez, Puerto Rico.

- Martin, G., & Plaza, A., (2011). Region-based spatial preprocessing for endmember extraction and spectral unmixing. *IEEE Geoscience and Remote Sensing Letters*, 8(4), 745–749.
- Mrázek, P., & Navara, M. (2003). Selection of optimal stopping time for nonlinear diffusion filtering. *International Journal of Computer Vision*, 52(2-3), 189-203.
- Plaza, A., Benediktsson, J., Boardman, J., Brazile, J., Bruzzone, L., Camps-Valls, G., Chanussot, J., Fauvel, M., Gamba P., Gualtieri, A., Marconcini, M., Tilton, J., & Trianni, G., (2009). Recent advances in techniques for hyperspectral image processing. *Remote sensing of environment*. 113, s110-s122.
- Plaza, A., Martinez, P., Perez, R., & Plaza, J., (2002). Spatial/spectral endmember extraction by multidimensional morphological operations. *IEEE Transactions on Geosciences and Remote Sensing*, 40(9), 2025–2041.
- Richards, J. A., & Richards, J. A. (2006). *Remote sensing digital image analysis*. Berlin: Springer.
- Rogge, D. M., Rivard, B., Zhang, J., Sanchez, A., Harris, J., & Feng J., (2007). Integration of spatial-spectral information for the improved extraction of endmembers. *Remote Sensing of Environment*, 110 (3), 287–303.
- Sapiro, G., (2001). *Geometric Partial Differential Equations and Image Analysis*. Cambridge University Press.
- Schowengerdt, R. A. (2007). *Remote sensing: models and methods for image processing*. Academic press.
- Shaw, G., & Manolakis, D. (2002). Signal processing for hyperspectral image exploitation. *Signal Processing Magazine, IEEE*, 19(1), 12-16.

- Sporring, J., & Weickert, J. (1999). Information measures in scale-spaces. *Information Theory, IEEE Transactions on*, 45(3), 1051-1058.
- Torres-Madronero, M., & Velez-Reyes, M. (2014). Integrating Spatial Information in Unsupervised Unmixing of Hyperspectral Imagery Using Multiscale Representation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, June.
- Vanhamel, I., Mihai, C., Sahli, H., Katartzis, A., & Pratikakis, I. (2009). Scale selection for compact scale-space representation of vector-valued images. *International journal of computer vision*, 84(2), 194-204.
- Weickert, J. (1999). Coherence-enhancing diffusion of colour images. *Image and Vision Computing*, 17(3), 201-212.
- Weickert, J., Romeny, B. T. H., & Viergever, M. A. (1998). Efficient and reliable schemes for nonlinear diffusion filtering. *Image Processing, IEEE Transactions on*, 7(3), 398-410.
- Yu, Q., Gong, P., Chinton, N., Biging, G., Kelly, M., & Schirokauer, D., (2006). Object based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering and Remote Sensing*, 72, 799–811.