

Análisis de Imágenes Hiperespectrales. Clasificación de cultivos.

Lic. Cecilia Sanz

LIDI. Laboratorio de Investigación y Desarrollo en Informática.

Facultad de Informática. UNLP.

50 y 115. 1er Piso. La Plata

Introducción

El sensado remoto o remote sensing es la ciencia o arte de obtener información sobre un objeto, área o fenómeno a través del análisis de datos obtenidos por un *dispositivo que no tiene un contacto físico* con dicho objeto, área o fenómeno

El avance tecnológico permite actualmente obtener imágenes hiperespectrales (muestreos continuos de intervalos anchos del espectro), con un volumen de información considerablemente mayor comparado con el que se ha tenido hasta el momento con las imágenes multiespectrales.

Los sensores hiperespectrales son instrumentos de sensado remoto que combinan la presentación espacial de un sensor de imagen con las capacidades analíticas de un espectrómetro. Pueden contener hasta cientos de bandas espectrales angostas con una resolución espectral del orden de 10 nanómetros o menor [Goe85]. Los espectrómetros producen un espectro completo para todos los píxeles de la imagen. Como resultado de tener una mayor resolución espectral se tiene la posibilidad de *identificar* materiales, mientras que con los sensores de bandas más anchas (por ejemplo, Landsat Thematic Mapper TM) sólo se los podía *discriminar*.

Esto ha llevado a los investigadores a buscar nuevas técnicas de manejo y clasificación que permitan explotar adecuadamente los nuevos datos disponibles.

Esta línea de investigación tiene como objetivo estudiar, analizar y encontrar métodos de clasificación que permitan tomar ventaja de la información provista por este tipo de imágenes, donde se incorporan los datos espectrales como una 3ra dimensión dentro del reconocimiento de patrones. Es decir, a la información espacial comúnmente utilizada, se le agrega la espectral.

En particular, se estudia la clasificación de cultivos para una etapa específica de su evolución aplicando el método de clasificación conocido como **razonamiento evidencial**. Se utilizan imágenes hiperespectrales de la región de Nebraska (USA), provistas por PRA (Photon Research Association), quienes realizan investigación de los cultivos de la zona mencionada.

Conceptos básicos

La fuente principal de energía usada para iluminar destinos naturales es el sol. Los rayos solares pasan a través de la atmósfera, y cuando alcanzan la superficie terrestre una fracción de la energía es absorbida o reflejada, mientras que el resto es transmitida.[Kie94]

La cantidad de energía que es reflejada, transmitida y absorbida depende de la **longitud de onda** y del **tipo de material** con el que interactúa. Dentro de la porción visible del espectro, estas variaciones resultan en el efecto visual que se conoce como *color*. Por ejemplo, se dice que un objeto es "azul" cuando refleja una alta cantidad de energía en la porción azul del espectro.

Las características de reflectancia de los rasgos de la superficie terrestre pueden ser cuantificados midiendo la porción de energía incidente que es reflejada. Esto se mide como una función de la longitud de onda, llamada reflectancia espectral, ρ_λ .

$$\rho_{\lambda} = E_R(\lambda) / E_I(\lambda)$$

= (Energía reflejada desde el objeto en la long. de onda λ / Energía incidente en el objeto en la long. de onda λ) * 100

donde ρ_{λ} se expresa como porcentaje.

En principio, varios tipos de materiales de la superficie pueden ser reconocidos o distinguidos unos de otros por las diferencias en la reflectancia espectral.

Estrictamente, las medidas espectrales involucran interacciones entre las radiaciones de iluminación y las estructuras atómicas o moleculares de cualquier material.

Interacción de la energía solar con vegetación

Dado que esta línea de investigación involucra la clasificación de imágenes de cultivos es importante entender la interacción de la energía solar con la vegetación.

La vegetación verde y sana se caracteriza por tener una curva de reflectancia espectral con picos y valles.

Los valles en la porción visible del espectro se deben a los pigmentos en las hojas de las plantas. Por ejemplo, la clorofila absorbe en gran medida la energía en las bandas de longitud de onda centradas alrededor de los 0.45 y los 0.67 micrómetros (azul y rojo visibles). Estos colores son absorbidos mientras que la parte visible concentrada en el verde es en parte reflejada (por eso la mayoría de la vegetación se caracteriza por el color de las hojas verdes). Si una planta está sujeta a alguna forma de "stress" que interrumpe su normal desarrollo, es posible que decremente o cese su producción de clorofila. Esto provoca una menor absorción de la clorofila en las bandas azul y roja, y normalmente la reflectancia en la banda roja aumenta de tal manera que la planta se torna amarilla (combinación del rojo y verde).

Los picos se deben a la alta reflectancia entre los 0.7 y 1.3 micrómetros (infrarrojo cercano o Near IR) producidos por la interacción con las células mesofílicas de las hojas. La intensidad de esta reflectancia es comúnmente mayor que la de los materiales inorgánicos, de forma tal que la vegetación se describe como brillante en el Near IR.

Estas variaciones espectrales facilitan la detección precisa, identificación y monitoreo de la vegetación sobre la superficie terrestre.

Razonamiento evidencial

El razonamiento evidencial es un enfoque alternativo a los métodos de clasificación tradicionales basado en la teoría de Dempster - Shafer. Este método ha sido utilizado en clasificación de bosques y de hielos permanentes en Canadá sobre imágenes multiespectrales.[Ped93]

La teoría matemática de la evidencia fue propuesta por Shafer (1976) como una extensión y refinamiento de la Regla de Dempster de combinación (1967).

La teoría provee una base general y heurística para integrar cuerpos distintos de información, considerados piezas de evidencia, de fuentes independientes sobre un conjunto de clases.

Para un pixel dado (conjunto de valores de datos de diferentes fuentes para una unidad de imagen discreta), la tarea de una clasificación es asignar el pixel a un miembro de un conjunto de clases. Para ello, a cada clase de este conjunto se le asocia una medida de soporte y una de plausibilidad.

Soporte:

Usualmente es un número real entre 0 y 1, inclusive. Se dice que es la masa o cantidad de evidencia en favor de una clase dada.

Plausibilidad:

Además del soporte evidencial, la teoría considera una medida de **plausibilidad**. La plausibilidad representa la masa o cantidad de evidencia que no refuta una clase, y es calculada como 1 menos el soporte para todas las otras proposiciones.

En el contexto de una clasificación de sensado remoto, la plausibilidad para la clase C_i puede ser computada como $1 - S(\neg C_i)$, donde S representa el soporte evidencial. La verdadera factibilidad de una proposición está dentro del rango de valores posibles en el intervalo que va desde la medida de soporte y la de plausibilidad para la clase C_i , el cual es llamado **intervalo evidencial**. El uso del intervalo evidencial permite tanto el soporte en favor de la clase y el nivel asociado de incertidumbre para ser incluido en una regla de decisión.

Suma ortogonal

Dados los vectores evidenciales (por ejemplo, calculados para un pixel en un conjunto de datos multifuente), la tarea que queda es **combinar la evidencia** de todas las fuentes en una forma unidimensional conteniendo una medida de soporte por clase y una de plausibilidad.

La descomposición de los vectores evidenciales de una fuente específica en una función de masa resultante se alcanza por suma ortogonal usando la Regla de combinación de Dempster.

El poder de esta regla puede ser aplicado a cualquier número de fuentes cada una de las cuales conteniendo evidencia para un conjunto de clases.

La suma ortogonal de evidencia a partir de dos fuentes trabaja multiplicando secuencialmente la evidencia para una clase dada de una fuente por la evidencia de cada clase de la siguiente fuente. Luego se aplica un factor de normalización que corrige para cualquier masa que haya sido adjudicada al conjunto vacío.

La suma ortogonal de dos vectores de evidencia m_1 y m_2 se denota por $m_1 \oplus m_2$.

$$m'(A_n) = K^{-1} \sum_{A_i \cap A_j = A_n} m_1(A_i) m_2(A_j)$$

$$K = 1 - \sum_{A_i \cap A_j = \phi} m_1(A_i) m_2(A_j)$$

Una regla de decisión puede ser elegir la clase con mayor soporte [Lee87][Wil90]. Otra opción es seleccionar la clase con mayor plausibilidad [Kim89][Sri90]. También autores como Peddle han optado por la mayor suma de soporte y plausibilidad [Ped93].

Conclusiones y líneas de trabajo futuras

La aplicación de la técnica de razonamiento evidencial en las imágenes hiperespectrales permite combinar la información espectral disponible con información espacial, como rasgos de textura. Se vienen realizando experimentos para la clasificación de maíz, soja, y sorgo.

Actualmente se estudia una modificación al método propuesto, donde se realiza un proceso de aprendizaje para el entrenamiento del clasificador.

Por otra parte, como línea futura de investigación se propone analizar la evolución de un cierto cultivo en el tiempo, permitiendo distinguir entre las distintas etapas por las que atraviesa.

Bibliografía

- [Fra93] Peddle and Franklin. "Classification of Permafrost Active Layer Depth from Remotely Sensed and Topographic Evidence" *Remote Sensing Environment*. 1993
- [Goe85] Goetz, A. F. H., Vane, G., Solomon, J. E., and Rock, B. N., 1985, *Imaging spectrometry for Earth remote sensing: Science*, v. 211, p. 1147 - 1153.
- [Goe85] Goetz, A. F. H., and Srivastava, V., 1985, *Mineralogical mapping in the Cuprite Mining District, Nevada: in Proceedings of the Airborne Imaging Spectrometer Data Analysis Workshop, JPL Publication 85-41, Jet Propulsion Laboratory, Pasadena, CA*, p. 22-29.
- [Jen96] Jensen. "Introductory Digital Image Processing. A remote sensing perspective" 2da edición. Prentice Hall. 1996
- [Kie94] Thomas M Lillesand, Ralph W Kiefer. "Remote Sensing and Image Interpretation" 3rd Edition. John Wiley. 1994
- [Kim89] Kim, H., and Swain, P., 1990. "A Method for Classification of Multisource Data Using Interval- Valued Probabilities and its Applications to Hiris Data", *Proceedings of a Workshop on Multisource Data Integration in Remote Sensing, NASA Conference Publication 3099*, pp. 75-81.
- [Lee87] Lee, T., Richards, J., and Swain P., 1987. "Probabilistic and Evidential Approaches for Multi-source Data Analysis", *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 25, No. 3, pp. 283-292.
- [PED&DUG98] Peddle and Duguay. "Mountain Terrain Analysis using a knowledge-based interface to a GIS". *Geomática*. Vol.52 – Nro. 3- 1998
- [Ped93] Peddle. "An Empirical comparison of evidential reasoning, linear discriminant analysis, and maximum likelihood algorithms for alpine land cover classification". *Canadian Journal of Remote Sensing*. Vol.19. Nro.1- 1993
- [Ped95] Peddle. "Knowledge Formulation for Supervised Evidential Classification". *Photogrammetric Engineering & Remote Sensing*. Vol. 61- Nro. 4 – 1995
- [Ped95] Peddle. "Mercury: An evidential reasoning image classifier". *Computers & Geosciences*. Vol. 21 – Nro. 10- 1995
- [Sri90] Srinivasan, A., and Richards J., 1990. "Knowledge-based Techniques for Multi-source Classification", *International Journal of Remote Sensing*, Vol.11, No.3, pp.505-525.
- [Wil90] Wilkinson, G., and Megier, J., 1990. "Evidential Reasoning in a Pixel Classification Hierarchy – A Potential Method for Integrating Image Classifiers and Expert System Rules Based on Geographic Context", *International Journal of Remote Sensing*, Vol. 11, No.10, pp. 1963-1968.