

RED: Razonamiento Evidencial Dinámico, aplicado a la clasificación de cultivos en imágenes hiperespectrales

*Lic. Cecilia Sanz¹, PhD. Ramiro Jordan²
Laboratorio de Investigación y Desarrollo en
Informática³
Facultad de Informática
Universidad Nacional de La Plata*

Resumen

Este trabajo describe un nuevo método de clasificación (RED) basado en el razonamiento evidencial al que se le introduce una serie de modificaciones [1]. RED permite la inclusión de nueva evidencia para el proceso de clasificación y define una regla de decisión diferente. El algoritmo de razonamiento evidencial provee una forma de combinar evidencia a partir de distintas fuentes de información. Es una técnica de clasificación supervisada, que utiliza un conjunto de muestras de entrenamiento. Este método novedoso (Red) propone una etapa de aprendizaje para introducir nueva evidencia en caso que el clasificador lo requiera. Por otra parte, utiliza la medida de plausibilidad para definir la regla de decisión como una forma de incorporar la incertidumbre asociada a los datos. Se aplica el método propuesto para clasificar cultivos en imágenes hiperespectrales de la región de Nebraska (USA). Se presentan algunos resultados obtenidos para evaluar la precisión de RED.

Palabras Claves - Análisis hiperespectral, Razonamiento evidencial, Clasificación de cultivo.

1. INTRODUCCION

El avance tecnológico permite actualmente obtener imágenes hiperespectrales (muestreos continuos de intervalos anchos del espectro), con un volumen de datos considerablemente mayor comparado con el que se ha tenido hasta el momento con las imágenes multispectrales [2]. 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 [3]. 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 podían *discriminar* materiales.

Sin embargo, estos datos son de utilidad siempre y cuando se disponga de métodos capaces de procesarlos adecuadamente y obtener así la información necesaria para una aplicación particular.

Los métodos de clasificación a aplicarse para el análisis de imágenes hiperespectrales, deben permitir combinar numerosos datos de diferentes fuentes y posiblemente también de diferente naturaleza. Por ejemplo, puede ser necesario combinar información espectral con información espacial (como pueden ser rasgos de textura) [4] para lograr la clasificación de distintos cultivos como soja, maíz, etc.

El estudio de regiones cultivadas es un tema de sumo interés no sólo por su atractivo científico (encontrar métodos de clasificación adecuados) sino también por su importancia en relación con aspectos económicos. Poder estimar el porcentaje de áreas cultivadas para cada tipo de cultivo en la etapa de crecimiento de los mismos, puede dar una estimación de la producción que se tendrá. Sumado a esto, se

¹ Becaria CIC. Jefe de Trabajos Prácticos Dedicación Exclusiva. Facultad de Informática. Universidad Nacional de La Plata. E-mail: csanz@lidi.info.unlp.edu.ar

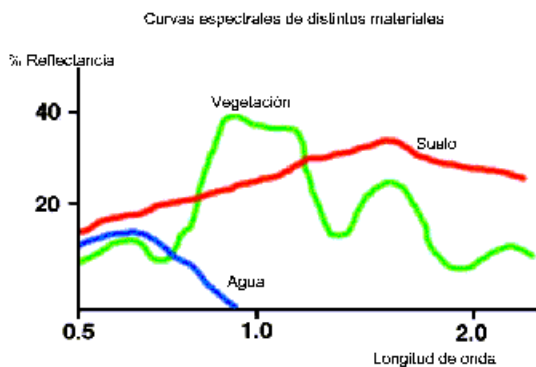
² Profesor. EECE. Universidad de New Mexico. USA

³ Calle 50 y 115 1er Piso, (1900) La Plata, Argentina, TE/Fax + (54)(221)422-7707. <http://lidi.info.unlp.edu.ar>

pueden detectar problemas que se presenten en ciertas zonas, como pueden ser plagas o falta de irrigación, y corregirlos oportunamente.

La vegetación verde y sana se caracteriza por tener una curva de reflectancia espectral con picos y valles (**figura 1**).

Figura 1



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 reflejada en alguna medida (por eso la mayoría de la vegetación se caracteriza por el color verde de las hojas). Si una planta está sujeta a alguna forma de “stress” que interrumpe su normal desarrollo, normalmente decremента o cesa su producción de clorofila. Esto provoca una menor absorción de la clorofila en las bandas azul y roja, y generalmente 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.

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, por ejemplo, en clasificación de bosques y de hielos permanentes en Canadá sobre imágenes multiespectrales [5] [6].

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, la tarea de 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**.

Una regla de decisión puede ser elegir la clase con mayor soporte [7][8]. Otra opción es seleccionar la clase con mayor plausibilidad [9][10]. También autores como Peddle han optado por la mayor suma de soporte y plausibilidad[11]. En este trabajo se propone una regla de decisión diferente, que toma en cuenta cuál es la clase con mayor soporte y luego en caso que no sea suficiente la evidencia a favor de la misma, se evalúa la plausibilidad para determinar si se asigna el pixel a la clase con mayor soporte o se considera que pertenece a la clase “desconocida”.

Uno de los interrogantes que introduce el método es cómo derivar la evidencia a partir de los datos de muestra que se poseen. Peddle

propone considerar la frecuencia de distribución como la medida de soporte para un dato en una fuente y clase dada. Esto provoca que los resultados de la clasificación se vean influidos muchas veces por valores particulares de las muestras. Lo cual es solucionado extendiendo la frecuencia de distribución con un tamaño ingresado (tamaño de bin). Este proceso es llamado transformación de bin.

El método de razonamiento evidencial dinámico propone una forma de incorporar nueva evidencia en caso que el clasificador lo necesite para mejorar su precisión. Se evalúan los resultados de la clasificación y en caso de no ser "óptimos" se agregan los datos de las muestras como nueva evidencia. La forma en que se analizan los resultados de la clasificación para determinar su precisión, es a través de la matriz de error y el indicador Khat [12]. Este indicador permite analizar el error ocurrido en la clasificación. Si el error supera el 10%, se establece que es necesario incorporar nueva evidencia.

Este método se aplicó para clasificar imágenes hiperespectrales de campos cultivados con soja, sorgo y maíz, para una etapa específica de su evolución. La implementación permite trabajar con una región de interés de la imagen dentro de la cual se obtiene como resultado un mapa de categorías, incluyendo entre las mismas la "desconocida".

2. PRESENTACION DEL MÉTODO (RED)

El método de razonamiento evidencial, como se mencionó anteriormente, calcula una medida de soporte para cada fuente de información y cada clase. Luego, se combina este soporte para obtener una medida única para cada clase, esto se realiza aplicando la regla de combinación de Dempster. Además de la medida de soporte se calcula la plausibilidad. A continuación se da una definición para ambas [13].

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:

La plausibilidad representa la masa o cantidad de evidencia que no refuta una clase. En el contexto de una clasificación de sentido remoto, la plausibilidad para la clase C_i , puede ser computada como $1 - S(\neg C_i)$, donde S representa el soporte evidencial y $\neg C_i$ es el complemento C_i en el conjunto de clases.

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 que tanto el soporte en favor de la clase como el nivel asociado de incertidumbre puedan ser incluido en una regla de decisión.

Suma ortogonal

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 (2.1). Luego, se aplica un factor de normalización (K) que corrige para cualquier masa que haya sido adjudicada al conjunto vacío (2.2).

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

$$m'(A_n) = K^{-1} \sum_{A_i \cap A_j = A_n} m_1(A_i) m_2(A_j) \quad (2.1)$$

$$K = 1 - \sum_{A_i \cap A_j = \phi} m_1(A_i) m_2(A_j) \quad (2.2)$$

La regla de decisión propuesta, consiste en seleccionar la clase que posee el mayor soporte. Si el máximo soporte es cero o es menor que un umbral seleccionado por el

usuario, se analiza la medida de plausibilidad. La medida de plausibilidad (para la clase elegida) nos dice cuánta evidencia no ha sido asignada a ninguna clase y podría estar a favor de la clase con máximo soporte. En caso que la medida de plausibilidad indique que, existe un 75% o más, de evidencia no asignada, el pixel es considerado "desconocido". El método, de esta manera, no arriesga a determinar la pertenencia a una clase si existe un alto grado de incertidumbre asociado al pixel en cuestión.

Por otra parte, RED presenta una forma de introducir nueva evidencia al clasificador. Se establecen regiones de interés a clasificar en la imagen y se determina a priori a qué clase pertenecen. Para entrenar al clasificador, se aplica el método de razonamiento evidencial utilizando la base actual de conocimiento y se evalúan los resultados. En caso, que el indicador Khat muestre un error superior al 10% en la clasificación, se introducen las muestras como nueva información para el sistema. Si por el contrario, el indicador muestra que el error no supera el 10%, no se incorpora la nueva evidencia, ya que no es considerado necesario. Este aprendizaje que realiza el clasificador está basado en un enfoque supervisado, en donde el usuario debe tener conocimiento de la pertenencia de las muestras a una de las categorías.

El razonamiento evidencial provee ventajas en varios aspectos. Permite analizar el nivel de incertidumbre, trabajar con información provista por diferentes fuentes y de distinta naturaleza, y además da la posibilidad de utilizar un alto número de variables en la clasificación. Esto resulta de suma importancia para el análisis de las imágenes hiperespectrales.

Las modificaciones propuestas tienen el objetivo de mejorar el método en dos aspectos:

- Permitir la incorporación de nueva evidencia para que el clasificador pueda aprender y dar resultados más precisos.

- Utilizar una regla de decisión que tenga en cuenta la plausibilidad y no arriesgue por una clase si no posee la evidencia suficiente.

3. APLICACIÓN

Se aplica el método al análisis de imágenes hiperespectrales de la región de Nebraska (USA), donde se quieren reconocer tres tipos de cultivos diferentes: soja, maíz y sorgo, para una etapa específica de su evolución. Las imágenes fueron adquiridas en agosto de 1998, por un sensor *casi* (Compact Airborne Spectrographic Imager) [14] [15] con una resolución de píxeles de 1m, y fueron provista por la empresa PRA (Photon Research Associates, Albuquerque, USA), quienes investigan y realizan desarrollos para análisis de "stress" y vigor de la vegetación. Las imágenes fueron geocorregidas a coordenadas UTM.

Para el entrenamiento se toman muestras para cada una de las clases antes dichas y una clase que no es vegetación (específicamente rutas que aparecen en las imágenes). De cada una de las muestras se obtiene su patrón espectral y 3 estadísticas de primer orden para analizar la textura de la región ("kurtosis", "skewness" y media) [16] y de esta forma se incorpora información espacial. Estos datos son los que permiten entrenar al clasificador para comenzar a trabajar. A partir de los mismos se calcula el soporte para cada clase y fuente. Esta información es la que se combina por medio de la suma ortogonal de Dempster al momento de clasificar un pixel desconocido.

Si la evidencia incorporada no permite obtener buenos resultados y se dispone de nuevas muestras es posible incorporar la información al sistema, de la forma ya explicada.

4. RESULTADOS

Se presentan a continuación algunos resultados obtenidos en la aplicación del método RED en las imágenes descriptas. Los resultados se evalúan utilizando la matriz de confusión, la precisión general y el indicador Khat.

Se seleccionaron conjuntos de test diferentes de los utilizados para entrenar. El primer conjunto de test muestra la necesidad de seguir entrenando el clasificador. Se realizó la etapa de aprendizaje del clasificador hasta que el mismo se estabilizó, los últimos conjuntos de test muestran los buenos resultados que ya se obtienen luego del aprendizaje.

Test1

Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	31	13	2	0	39	85
Maíz	6	1	16	2	87	112
Sorgo	1	0	24	0	38	63
Ruta	0	0	0	4	41	45
Desc.	0	0	0	0	0	0
total	38	14	42	6	205	305

Precisión general: 0.196721

Khat: 0.124087

Se incorporó el conjunto de muestras a la base de conocimiento del clasificador y se recalcularon los soportes para cada fuente y clase. Luego, se evalúa el clasificador con el conjunto de test 2.

Test2

Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	84	0	0	0	0	84
Maíz	0	38	3	0	39	80
Sorgo	0	0	56	0	0	56
Ruta	0	0	0	17	0	17
Desc.	0	0	0	0	0	0
Total	84	38	59	17	39	237

Precisión general: 0.822785

Khat: 0.765678

Nuevamente, se incorpora la información para que continúe el aprendizaje.

Test 3

Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	77	0	0	0	0	77
Maíz	0	60	0	0	0	60
Sorgo	0	0	90	0	0	90
Ruta	0	0	0	30	0	30
Desc.	0	0	0	0	0	0
Total	77	60	90	30	0	257

Precisión general: 1.00

Khat: 1.00

No se incorporan los datos del conjunto de test3, ya que el clasificador ha arrojado buenos resultados. Lo mismo ocurre con los siguientes conjuntos de test.

Test 4

Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	90	0	0	0	0	90
Maíz	0	70	0	0	0	70
Sorgo	0	0	96	0	0	96
Ruta	0	0	0	42	12	54
Desc.	0	0	0	0	0	0
Total	90	70	96	42	12	310

Precisión general: 0.961290

Khat: 0.948056

Test 5

Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	49	0	0	0	15	64
Maíz	0	90	0	0	0	90
Sorgo	0	0	100	0	0	100
Ruta	0	0	0	30	0	30
Desc.	0	0	0	0	0	0
Total	49	90	100	30	15	284

Precisión general: 0.947183

Khat: 0.927204

Test 6

Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	90	0	0	0	0	90
Maíz	0	72	0	0	0	72
Sorgo	0	0	130	0	0	130
Ruta	0	0	0	25	5	30
Desc.	0	0	0	0	0	0
Total	90	72	130	25	5	322

Precisión general: 0.984472

Khat: 0.977869

Test 7

Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	64	0	0	0	0	64
Maíz	0	60	0	0	0	60
Sorgo	0	0	90	0	0	90
Ruta	0	0	0	40	0	40
Desc.	0	0	0	0	0	0
Total	64	60	90	40	0	254

Precisión general: 1.00

Khat: 1.00

Como se aprecia en las tablas anteriores los resultados obtenidos tienen un error inferior al 10%.

Por otra parte, cabe destacarse que el costo computacional que introduce el método propuesto es alto respecto de algunos de los métodos tradicionales de clasificación. Sin embargo, esto está influenciado por la cantidad de fuentes de información con las que se trabaja (para este caso particular, se utilizan 10 bandas espectrales y las medidas de textura mencionadas). En muchos de los clasificadores convencionales resulta difícil incorporar como entrada una numerosa cantidad de variables, como puede ser necesario para procesar imágenes hiperspectrales. Se cree importante analizar, entonces los datos que se poseen antes de la elección del método de clasificación a utilizar.

5. CONCLUSIONES

El método propuesto tiene ciertas ventajas respecto de los métodos convencionales de clasificación, se muestra particularmente atractivo para el análisis de imágenes hiperspectrales. Al igual que el método de razonamiento evidencial presentado por Peddle, permite integrar numerosos datos de diferente naturaleza. No es necesario presuponer una distribución de los datos como ocurre con el clasificador de máxima verosimilitud, el cual supone una distribución "gaussiana". [17][18]

Además RED permite que la base de conocimiento con la que se trabaja no sea estática, sino que por medio de un proceso de aprendizaje se de la posibilidad de incorporar nuevos datos al sistema. Además, el tener en consideración la incertidumbre asociada a los datos (por ejemplo, por no poseer suficiente información) resulta en mejores decisiones.

Se ha experimentado que el método arroja buenos resultados para la clase de problemas que se ha presentado.

Sin embargo, el método resulta más complejo y más lento que algunos de los métodos convencionales de clasificación. Por ello, se debe evaluar de acuerdo a la aplicación qué método utilizar.

6. REFERENCIAS

- [1] D. Peddle. "MERCURY \oplus : An Evidential Reasoning Image Classifier". *Computers & Geosciences*, vol. 21, No.10, pp. 1163-1176. 1995.
- [2] Jensen. "Introductory Digital Image Processing. A remote sensing perspective", 2da Edition, Prentice Hall. 1996
- [3] A. F. H. Goetz , and V. Srivastava, "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, pp. 22-29. 1985
- [4] T. M. Lillesand, R. W. Kiefer. "Remote Sensing and Image Interpretation", 3rd Edition, John Wiley. 1994.
- [5] D. Peddle, and S. Franklin. "Multisource evidential classification of surface cover and frozen ground". *International Journal R. S.*, vol. 13- Nro. 17. 1992
- [6] D. Peddle, and S. Franklin. "Classification of Permafrost Active Layer Depth from Remotely Sensed and Topographic Evidence", *Remote Sensing Environment*, vol. 44, No.1, pp. 67-80. 1993.
- [7] T. Lee, J. Richards, and P. Swain. "Probabilistic and Evidential Approaches for Multi-source Data Analysis", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 25, No. 3, pp. 283-292. 1987

- [8] G. Wilkinson, and J. Megier. "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. 1990
- [9] H. Kim, and P. Swain. "A Method for Classification of Multisource Data Using Interval- Valued Probabilities and its Applications to Hiris Data", in *Proceedings of a Workshop on Multisource Data Integration in Remote Sensing*, NASA Conference Publication 3099, pp. 75-81. 1990.
- [10] A. Srinivasan, and J. Richards. "Knowledge-based Techniques for Multi-source Classification", *International Journal of Remote Sensing*, vol.11, No.3, pp.505-525. 1990.
- [11] D. Peddle. "Knowledge Formulation for Supervised Evidential Classification". *Photogrammetric Engineering & Remote Sensing*, vol.61, No.4., pp. 409-417. 1995.
- [12] D. 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, No.1. 1993.
- [13] Anger C.D., Mah, S., Babey, S.K. "Technological enhancements to the compact airborne spectrographic imager (*casi*).". In *Proceedings of the First International Airborne Remote Sensing Conference and Exhibition*. Strasbourg, France. Vol. II, pp. 205-213. 1994.
- [14] Babey, S.K., Anger, C.D. "Compact airborne spectrographic imager (*casi*): A progress review." In *Proceedings of the SPIE Conference*. Orlando, Florida. SPIE Vol. 1937, pp. 152-163. 1993.
- [15] R. G. Congalton, K. Green. "Assessing the Accuracy of Remotely Sensed Data: Principles and Practices". Lewis Publishers. 1997.
- [16] Jensen. "Introductory Digital Image Processing. A remote sensing perspective". 2da edición. Prentice Hall. 1996.
- [17] "Remote Sensing Digital Image Analysis: An Introduction". J. A. Richards, X. Jia. Springer-Verlag New York, Incorporated. 1999.