

" Paralelización del Algoritmo de Clasificación DER usando imágenes hiperespectrales"

Cecilia Sanz

Becaria CIC (Comisión de Investigaciones Científicas Pcia. Bs. As.)

LIDI (Laboratorio de Investigación y desarrollo en informática)

Facultad de Informática, Universidad de La Plata

La Plata (1900), BA, Argentina

fax: 54-(0221) 4227707

e-mail: csanz@lidi.info.unlp.edu.ar

Armando De Giusti

LIDI (Laboratorio de Investigación y desarrollo en informática)

Facultad de Informática, Universidad de La Plata

La Plata (1900), BA, Argentina

e-mail: degiusti@lidi.info.unlp.edu.ar

RESUMEN

En este trabajo se describe una posible paralelización del método de razonamiento evidencial dinámico (DER). Este método está basado en la teoría de Dempster y Shafer sobre la evidencia, y en este caso se lo utiliza para clasificar distintos tipos de cultivos en imágenes hiperespectrales de la región de Nebraska (USA).

La alternativa de paralelización estudiada permite mejorar el tiempo de respuesta del algoritmo en su versión secuencial, el cual tiene un importante costo computacional proveniente del hecho de trabajar con imágenes de 10 o más bandas espectrales y de gran dimensión espacial.

La versión paralela se implementó usando un "cluster" de PCs bajo Windows. Se presentan aquí los resultados obtenidos para esta aplicación particular y su comparación con los de la versión secuencial.

Palabras Claves – Procesamiento paralelo – Análisis Hiperespectral – Razonamiento Evidencial

1 INTRODUCCION

El avance tecnológico permite hoy día tener sensores que capturan imágenes de alta resolución espacial y espectral. Las imágenes hiperespectrales constituyen una evolución en el área de sensado remoto, están formadas por 10 a cientos de bandas angostas y continuas en el espectro, y dan información detallada sobre los distintos materiales de la superficie terrestre. Existe una amplia variedad de aplicaciones que utilizan las imágenes hiperespectrales, entre ellas se menciona la presentada aquí que consiste en clasificar la imagen en distintos tipos de cultivos y las rutas que pueden aparecer en ella. En el caso de encontrar elementos no conocidos se los asignará a la clase desconocida.

El método de clasificación propuesto es una variación de la técnica de razonamiento evidencial presentada por Peddle y Franklin [1]. Se lo llama DER (Dynamic Evidential Reasoning) ya que agrega un proceso de aprendizaje que permite la incorporación de nueva evidencia. Además modifica la regla de decisión, dividiéndola en dos etapas que estudian el rechazo o aceptación de la clase con mayor soporte para asignarla como clase final al objeto a clasificar (en este caso es un pixel). Se quiere destacar que el método ha sido probado en cuanto a su precisión sobre la aplicación descripta, la cual categoriza los pixeles entre distintas clases de cultivos (soja, sorgo, maíz) y la clase ruta. Los resultados obtenidos fueron los esperados.

La paralelización de este algoritmo se basa en dividir la imagen a clasificar en tantas partes como procesadores haya disponibles, cada uno de ellos trabajará en su parte correspondiente de la imagen y obtendrá resultados parciales para la clasificación. Un proceso maestro es el encargado de calcular e informar los resultados finales, utilizando para ello los parciales obtenidos de cada uno de los procesadores restantes. Cabe aclararse que cada proceso corre en un procesador distinto. La solución presentada aquí fue probada con 2, 4 y 6 procesos que trabajan clasificando la imagen y un proceso maestro encargado de sincronizar y recuperar los resultados. Los resultados obtenidos fueron analizados en cuanto al tiempo y speed-up como funciones de la resolución de la imagen y de la cantidad de procesadores utilizados.

2 DESCRIPCION DEL METODO DE RAZONAMIENTO EVIDENCIAL DINAMICO

La teoría de la evidencia, propuesta por Dempster y Shafer, 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**, obtenidas de la combinación de los valores de soporte aportados por cada una de las fuentes. La combinación de Dempster se conoce como la suma ortogonal, la cual permite que cada clase cuente con una medida de soporte y plausibilidad únicas. Cuando se tiene un objeto desconocido se evalúa qué soporte y plausibilidad tiene para cada una de las fuentes y luego se realiza la combinación. Finalmente, se aplica una regla de decisión para determinar la clase final a la que se asigna el objeto desconocido.

Una regla de decisión puede ser elegir la clase con mayor soporte [2][3]. Otra opción es seleccionar la clase con mayor plausibilidad [4][5]. También autores como Peddle han optado por la mayor suma de soporte y plausibilidad [6]. En este trabajo se propone una regla de decisión diferente, que toma en cuenta cuál es la clase con mayor soporte y evalúa si aceptarla o no como clase final de acuerdo a dos etapas de análisis. La primer etapa es llamada de rechazo y estudia si la

evidencia asociada a la clase con mayor soporte es “suficiente” para considerarla como clase final (se tomaron distintos significados de la palabra suficiente, en este caso se evalúa que dicha evidencia provenga de una cierta cantidad de fuentes de información como mínimo, que para este caso se utiliza como parámetro una restricción de 2 fuentes y que el soporte no sea cero). La segunda etapa es la de rechazo por ambigüedad, la cual analiza la distancia (en cuanto a soporte) entre la clase con mayor soporte y el del resto de las clases, si alguna de estas distancias entre soportes es inferior al umbral establecido por el parámetro de precisión (no hay claridad en la decisión), la clase final se calcula valiéndose de información adicional a la de soporte [7].

En el trabajo aquí descrito se utilizan 13 fuentes de información, 9 de los cuales proveen información espectral y 4 de ellas dan información espacial (rasgos de textura). Por lo tanto, esto permite ver la importancia del método que permite combinar datos de distinta naturaleza.

A continuación se presenta un esquema del algoritmo descrito:

Inicialización

Abrir imágenes (hiperespectral y de textura)

Clasificación de la imagen

Reporte de los resultados

Cierre de las imágenes

{ Clasificación de la imagen }

Para cada pixel

Tomar la información de las fuentes de información

- *Formar un vector con los valores de cada fuente*
- *Buscar los valores de soporte para cada componente del vector por cada clase*
- *Combinar (**suma ortogonal**) los valores de soporte de todas las fuentes para obtener un único valor de soporte por clase*
- *Aplicar la regla de decisión para decidir el rótulo de clase a asignar*
- *Calcular el total de píxeles en cada clase*

3 PARALELIZACIÓN DEL ALGORITMO

Se estudiaron diferentes alternativas de paralelización, algunas de las cuales buscaban paralelizar el algoritmo de clasificación propiamente dicho, en particular las búsquedas de soporte. Esta posibilidad fue dejada para posteriores trabajos y se optó por la división de la imagen como alternativa. Este enfoque es simple y efectivo, se basa en la distribución de los datos a procesar entre un número de procesadores, cada uno de los cuales realiza la clasificación explicada. Dado que cada pixel a clasificar es independiente del resto se trabaja sobre un modelo SDMP. También podemos afirmar que se tiene una granularidad ajustable, ya que pueden agregarse tantos procesadores como se necesiten para trabajar en las distintas partes de la imagen. Las pruebas experimentales realizadas trabajan con 2, 4 y 6 procesadores.

La arquitectura usada es un esquema de maestro – esclavo en un “cluster” de PCs bajo Windows, cada procesador esclavo trabaja sobre diferentes partes de la imagen y obtiene los resultados parciales correspondientes [8].

La imagen está replicada en cada uno de los procesadores y es el proceso maestro el que indica el comienzo de ejecución de todos los procesos esclavos, los cuales trabajan en paralelo en la porción que le corresponde de la imagen. Cuando estos procesos finalizan su trabajo almacenan sus resultados en archivos locales a cada procesador. El proceso maestro (que reside en un procesador diferente) espera a que todos los procesos terminen para calcular e informar los resultados finales.

La comunicación se realiza utilizando archivos compartidos por lo que el tiempo invertido en ella es prácticamente nulo.

4 RESULTADOS EXPERIMENTALES

En esta sección se presentan los resultados obtenidos con la versión paralela descripta. Para ello se utilizaron 4 imágenes hiperespectrales de la región de Nebraska (USA). Estas imágenes tienen 10 bandas espectrales y fueron obtenidas usando un sensor CASI [9]. La tabla I a continuación muestra los tamaños de estas imágenes:

TABLA I
Tamaño de las Imágenes

Imagen	Tamaño
IM_1	1160 pixeles
IM_2	5103 pixeles
IM_3	10404 pixeles
IM_4	24780 pixeles

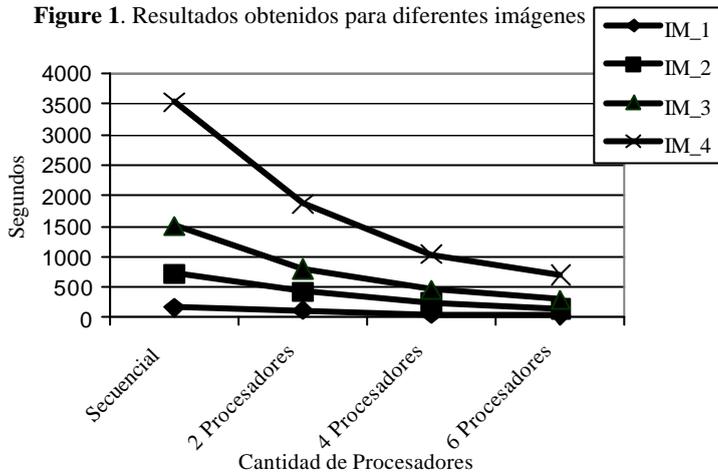
El propósito de esta aplicación es identificar diferentes tipos de cultivos en una etapa específica de su evolución (etapa de crecimiento). Se utiliza DER como técnica de clasificación y en particular, se evaluó el tiempo y Speed up de su versión paralela.

En la TABLA II, se muestran los resultados obtenidos (en tiempo absoluto) para el algoritmo secuencial y se comparan con los de la solución paralela con distinto número de procesadores.

Una primera conclusión surgida de esta comparación es que los tiempos para las versiones paralelas son mejores que para la secuencial y más aún se ve una mejora considerable para las imágenes de mayor dimensión (figura 1).

TABLA II
Resultados obtenidos en tiempo por el algoritmo secuencial y paralelo (en segundos)

	Secuencial	2 Procesadores Esclavos	4 Procesadores Esclavos	6 Procesadores Esclavos
IM_1	171.09 s	119.46 s	57.08 s	34 s
IM_2	729.25 s	426.82 s	242.66 s	146.98 s
IM_3	1504.85 s	798.07 s	468.35 s	298.57 s
IM_4	3538.13 s	1862 s	1042.27 s	701.20 s



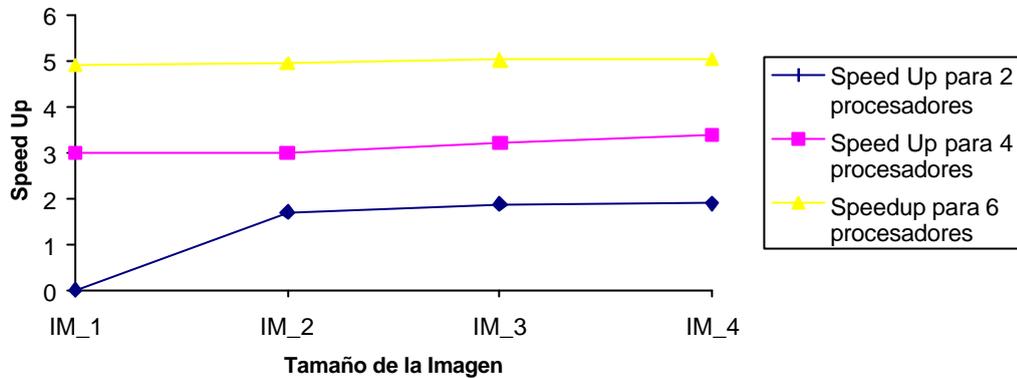
La Tabla III muestra los resultados de Speed-Up, cuando se utilizan 2 y 4 procesadores. Como es de esperar, el Speed-Up mejora para imágenes de mayor dimensión cuando se mantiene constante el número de procesadores (Figura 2). Hay que resaltar nuevamente que la comunicación es casi insignificante, ya que no existe prácticamente dependencia entre los procesos esclavos cuando trabajan sobre cada porción de la imagen.

TABLA III
Resultados de Speedup

	Speedup para 2 procesos esclavos	Speedup para 4 procesos esclavos	Speedup para 6 procesos esclavos
IM_1	1.43	2.99	4.91
IM_2	1.70	3.00	4.96
IM_3	1.88	3.21	5.04
IM_4	1.90	3.39	5.05

5 CONCLUSIONES

Figura 2 Curvas de Speed Up



En este artículo se presentó una versión paralela del método de clasificación de razonamiento evidencial dinámico (DER). Los resultados obtenidos son prometedores, pero se pretende realizar una paralelización del algoritmo propiamente dicho, atacando las búsquedas de los soportes.

Esta solución paralela trabaja sobre una arquitectura que usa un esquema de maestro-esclavo con procesos esclavos asociados con procesadores físicos.

Se analizó el Speed-Up y la eficiencia para imágenes de diferente dimensión y utilizando distintos números de procesos. Se observó una mejora para aquellas imágenes de mayor dimensión. Además de obtener mejores respuestas en tiempo para una misma imagen cuando se aumenta la cantidad de procesadores.

Se está trabajando para extender este estudio a un número mayor de procesador y con un juego más amplio de imágenes.

6 REFERENCIAS

- [1] D. Peddle, “Mercury \oplus : An evidential reasoning image classifier,” *Computers & Geosciences*, vol. 21, no. 10, pp. 1163-1175, 1995
- [2] 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
- [3] 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
- [4] 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.
- [5] 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.

[6] D. Peddle. “Knowledge Formulation for Supervised Evidential Classification”. *Photogrammetric Engineering & Remote Sensing*, vol.61, No.4., pp. 409-417. 1995.

[7] C. Sanz, “DER (Dynamic Evidential Reasoning), applied to the classification of hyperspectral images”, *Igarss 2001*, July, 2001. To be published.

[8] V. Kumar, A. Grama, A. Gupta, G. Karypis, *Introduction to Parallel Computing. Design and Analysis of Algorithms*, The Benjamin/Cummings Pub. Company, Inc., 1994.

[9] ITRES – Compact Airborne Spectrographic Imager

<http://www.itres.com/docs/top.html>

En este sitio se describe el tipo de sensor Casi (utilizado para adquirir las imágenes con las que se trabaja en este artículo)