

Análise de Imagens CBERS da Bacia do Rio São Francisco utilizando Mapas Auto-Organizados de Kohonen e Classificadores K-Médias e Fuzzy C-Médias

Cecília Cordeiro da Silva¹
Wellington Pinheiro dos Santos²

¹ Universidade Federal de Pernambuco – UFPE/CFCH
Departamento de Ciências Geográficas
Caixa Postal 7803 – 50670-901 – Recife – PE, Brasil
cecilia-cordeiro@hotmail.com

² Universidade de Pernambuco – UPE/POLI
Departamento de Sistemas e Computação
50720-001 – Recife - PE, Brasil
wellington@dsc.upe.br

Abstract. To perform supervised classification is highly necessary to know how many and what classes previously exist on under-analysis images. However, a classification approach based on non-supervised classifiers could furnish more interesting results when we are interested in detecting singularities expressed by new classes not expected by the specialists. The detection of singularities by non-supervised classifiers could be very useful in environmental applications. In this work we show that it is possible to use non-supervised classifiers based on self-organized maps and clustering methods to extract information of interest from images obtained by IRMSS sensor of CBERS-2 imaging system. The imaged area studied in this work approaches the city of Petrolina, Pernambuco, and River São Francisco.

Keywords: remote sensing, image processing, CBERS images, sensoriamento remoto, processamento de imagens, imagens CBERS.

1. Introdução

As tecnologias de Sensoriamento Remoto (SR) assumem uma importância cada vez maior, dada a sua aplicação em áreas diversas, desde a meteorologia, passando pelo monitoramento ambiental e indo até a geração de subsídios para a construção de políticas públicas de desenvolvimento humano e ambiental. Nesse sentido, dada a importância estratégica do domínio da tecnologia de SR, o Brasil tem investido, tendo a China como parceira, no programa CBERS (*China-Brazil Earth Resources Satellite*): uma parceria científica e tecnológica que resultou em 3 satélites, CBERS 1, CBERS 2 e CBERS 2B, que integram o Sistema Brasileiro de Coleta de Dados Ambientais, sendo previsto para os próximos anos o lançamento de mais dois satélites.

As imagens de SR ou combinações delas permitem a geração de mapas temáticos a partir da análise digital das imagens adquiridas, que podem ser monoespectrais ou multiespectrais. Neste trabalho se procura mostrar que é possível utilizar métodos de classificação não-supervisionada, baseados em mapas auto-organizados, combinados para extrair informação do sensor IRMSS, dotado de quatro bandas, sendo três de infravermelho, que permitem uma boa distinção entre tipos diferentes de vegetação e cultura. A área imageada abrange a cidade de Petrolina, Pernambuco, e o Rio São Francisco.

A classificação supervisionada pressupõe o conhecimento das classes existentes nas imagens. Contudo, uma abordagem de classificação baseada em classificadores não-supervisionados pode ser mais interessante quando se deseja detectar singularidades, ou seja, encontrar novas classes, não previstas usualmente, na montagem do conjunto de treinamento dos classificadores supervisionados (Ohata; Quintanilha, 2005). Essa pode ser uma característica

interessante para ser explorada em aplicações ambientais. Além disso, pode acontecer de o analista selecionar regiões associadas a classes diferentes como representantes de uma mesma classe, o que pode prejudicar a análise.

Dentre os classificadores não-supervisionados, classificadores como os mapas auto-organizados de Kohonen e o mapa *fuzzy* c-médias podem se tornar abordagens interessantes nos casos em que o número de classes não é previamente conhecido (Haykin, 2001). Além disso, pode-se, com o resultado da pré-classificação, selecionar um conjunto de treinamento tão confiável quanto for a avaliação da classificação realizada por pós-rotulação da pré-classificação. Com um conjunto de treinamento de maior confiabilidade, é possível aplicar um classificador supervisionado como, por exemplo, um classificador estatístico.

Este trabalho está organizado da forma que segue: na seção 2 são apresentadas as principais características das imagens adquiridas pelo sistema CBERS. Na seção 2 são ainda apresentadas as imagens utilizadas neste trabalho, além dos classificadores de imagens multiespectrais baseados em mapas auto-organizados de Kohonen, mapas *fuzzy* c-médias e o mapa de k-médias clássico. Na seção 3 são apresentados os resultados obtidos, enquanto na seção 4 são tecidos comentários e apresentadas conclusões gerais e noções de trabalhos futuros.

2. Metodologia de Trabalho

2.1. O Sistema CBERS

A partir da cooperação técnico-científica firmada entre Brasil e China no setor espacial, nasceu o programa CBERS. O sistema CBERS colocou ambos os países no seleto grupo dos países detentores de tecnologia de sensoriamento remoto. O Brasil passa então a contar com uma importante ferramenta para monitorar seu imenso território.

O programa CBERS inicialmente tinha por objetivo a criação e lançamento de apenas dois satélites, o CBERS-1 e CBERS-2. Contudo, o sucesso no funcionamento de ambos fez com que a parceria fosse prorrogada para a criação do CBERS-2B, CBERS-3 e CBERS-4.

Os satélites CBERS-1, CBERS-2 e CBERS-2B estão em uma órbita síncrona com o sol a uma altitude de 778 km, completando 14 revoluções da terra por dia. Assim o satélite sempre cruza o Equador às 10h30 da manhã, hora local, o que possibilita que as imagens sejam captadas com as mesmas condições de iluminação, favorecendo assim uma melhor comparação entre imagens adquiridas em dias diferentes.

O sistema CBERS possui um conjunto de sensores ou instrumentos: WFI (Câmera de Amplo Campo de Visada), CCD (Câmera Imageadora de Alta Resolução), IRMSS (Imageador por Varredura de Média Resolução), e HRC (Câmera Pancromática de Alta Resolução) com alto potencial de atender a múltiplos requisitos de aplicações. Cada um desses sensores tem características próprias que os tornam mais adequados a certas categorias de aplicações. Os satélites CBERS-1 e CBERS-2 possuem sistemas ópticos CCD, IRMSS e WFI (Câmera Imageadora de Amplo Campo de Visada usadas para observação da Terra). O satélite CBERS-2B é muito semelhante aos satélites CBERS-1 e CBERS-2, mas o IRMSS é substituído pela HRC (Freitas; Haertel; Shimabukuro, 2007).

A câmera CCD fornece imagens de uma faixa de 113 km de largura, com uma resolução de 20 m. Esta câmera tem capacidade de orientar seu campo de visada dentro de aproximadamente 32 graus, possibilitando a obtenção de imagens estereoscópicas de uma determinada região. A câmera de varredura IRMSS possui 4 faixas espectrais. O IRMSS produz imagens de uma faixa de 120 km de largura com uma resolução de 80 m (160 m no canal termal). Ela leva 26 dias para obter uma cobertura completa da Terra. O WFI produz imagens de uma faixa de 890 km de largura, permitindo a obtenção de imagens com resolução espacial de 260 m. No período aproximado de cinco dias obtém-se uma cobertura completa do globo. Já a câmera HRC opera

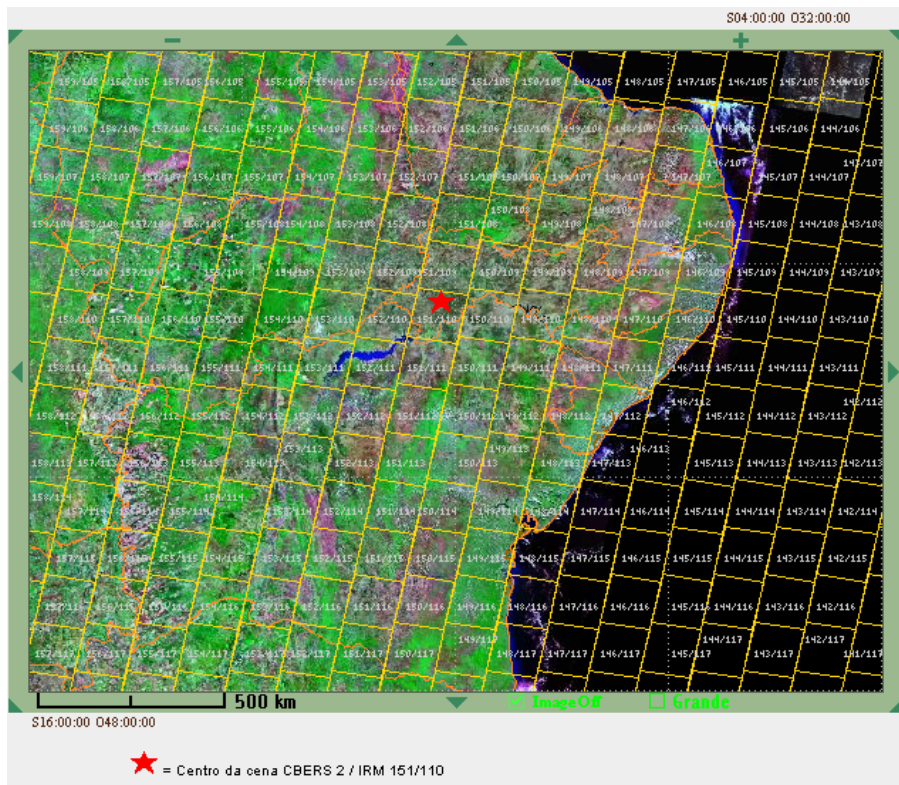


Figura 1: Localização da área imageada

numa única faixa espectral, que cobre o visível e parte do infravermelho próximo. Ela está presente apenas no CBERS-2B, produzindo imagens de uma faixa de 27 km de largura com uma resolução de 2,7 m.

2.2. Área Imageada

A área imageada utilizada neste trabalho abrange os municípios de Petrolina e Lagoa Grande, PE, e Juazeiro, BA. O centro das imagens engloba a meזורregião do Rio São Francisco pernambucano. As imagens foram geradas a partir do sensor IRMSS, do satélite CBERS-2, e obtidas em 2004, com clima bom e sem incidência de nuvens, pelo Instituto Nacional de Pesquisas Espaciais, INPE.

A Figura 1 mostra a localização da área imageada no mapa do estado de Pernambuco. A área imageada foi adquirida a partir da órbita 151, ponto 110, em 17 de novembro de 2004, com revolução de 5645, latitude Norte -8,34581, longitude Oeste -40,74420, latitude Sul -9,57166, longitude Leste -39,90360, tempo central (GMT) 12h 58min 44s, orientação da imagem 8,50435, ângulo nadir 22,987, azimute sol 118,222, elevação do sol 67,013. A aquisição aconteceu sem cobertura de nuvens.

As quatro bandas fornecidas, ou seja, uma banda pancromática (ver Figura 2), duas bandas de infravermelho médio (Figuras 3 e 4) e uma de infravermelho termal (Figura 5), foram integradas numa só imagem multiespectral. Para tanto foi realizado o registro manual das imagens, a partir de pontos marcadores.

Para facilitar a estimativa da quantidade máxima de classes presentes na imagem multiespectral montada, foram realizadas composições coloridas, onde cada banda da imagem obtida pelo sensor IRMSS foi inserida em uma das três bandas (R, G e B) de imagens coloridas RGB 8 bits. As Figuras 6, 7, 8 e 9 correspondem às seguintes composições: R0-G1-B2, R1-G0-B3, R2-G0-B3 e R3-G1-B2, respectivamente, onde a letra representa a banda da imagem



Figura 2: Banda pancromática (banda 0) do sensor IRMSS




Figura 3: Primeira banda de infravermelho médio (banda 1) do sensor IRMSS




Figura 4: Segunda banda de infravermelho médio (banda 2) do sensor IRMSS



Figura 5: Banda de infravermelho termal (banda 3) do sensor IRMSS




Figura 6: Composição colorida R0 G1 B2




Figura 7: Composição colorida R1 G0 B3

colorida RGB que recebe a banda da imagem IRMSS de número correspondente.

3. Resultados e Discussão

Para classificação das imagens e detecção dos tipos de vegetação e cultura presentes na área imageada, foram utilizados os seguintes métodos, a partir do *software* AnImed: mapa auto-organizado de Kohonen, mapa auto-organizado de Kohonen modificado (função de distância retangular), rede *fuzzy* c-médias e mapa de k-médias (Haykin, 2001; Duda; Hart; Stork, 2001). Foram estudadas diversas configurações em todos os métodos citados, até o máximo de 7 classes, número máximo de iterações de 200, e passo de 0,1.

A partir da classificação utilizando o mapa de k-médias (ver Figura 10), foram identificadas no máximo 3 classes das 7 classes requeridas nos parâmetros de entrada, o que implica que, com




Figura 8: Composição colorida R2 G0 B3




Figura 9: Composição colorida R3 G1 B2

o k-médias, não foi possível distinguir mais do que 3 populações estatisticamente significativas.

Resultados semelhantes foram encontrados utilizando-se a rede *fuzzy* c-médias (Figura 11), com a diferença que uma das três classes correspondentes, ao se comparar os resultados de classificação com os dois métodos, acabou ocupando uma área ligeiramente maior na rede *fuzzy* c-médias do que no mapa de k-médias. Essas duas classes, após rotulação usando conhecimento especialista, provaram ser dois tipos de vegetação distintos. Não há identificação clara das construções presentes na área imageada. A terceira classe, nesses casos, acaba sendo o próprio rio.

Os mapas auto-organizados de Kohonen utilizados foram de dois tipos: com função de vizinhança gaussiana (padrão, ver Figura 12) e com função modificada (retangular, conforme Figura 13). Ao se utilizar o mapa de Kohonen padrão, foram identificadas todas as 7 classes desejadas, que podem ser identificadas por: construção; vegetação 1 e 2; culturas 1, 2 e 3; e o próprio rio. A classificação com o mapa de Kohonen modificado retornou resultados semelhantes.

A Figura 14 mostra o resultado da classificação com pós-rotulação. As cores verde escuro e verde claro estão associadas às classes vegetação 2 e 1, nesta ordem, que correspondem a tipos de vegetação nativa; amarelo, vermelho e róseo correspondem às classes de cultura 1, 2 e 3; o tom amarelo queimado, tendendo ao marrom, está associado à classe construção, enquanto o rio São Francisco está mapeado em azul. Note-se a região circular no centro-sul da Figura 14, à beira do Rio São Francisco, onde está localizada uma região de cultura.

O resultado da classificação pelo mapa auto-organizado de Kohonen com função de vizinhança retangular foi avaliado utilizando pós-classificação e tendo como referência regiões de interesse de teste (Santos et al., 2003), obtendo-se índice κ de 0,9943 e taxa de acerto global de 99,56%, o que garante uma alta confiança para a estimativa das áreas ocupadas pelas classes de interesse, respectivamente: vegetação 2 (2571,66 km²), vegetação 1 (1449,76 km²), construção (480,48 km²), cultura 2 (731,9 km²), cultura 3 (231,07 km²) e cultura 1 (65,88 km²).

4. Conclusões

Dos estudos realizados pode-se concluir que os mapas auto-organizados de Kohonen, em suas versões com função de distância gaussiana e com distância retangular, foram os que melhor se comportaram na detecção de novidades na área imageada, uma vez que tornaram evidente a existência de três tipos de culturas diferentes, dois tipos de vegetação e a classe construção, enquanto os mapas de k-médias e *fuzzy* c-médias confundiram as classes vegetação 1, cultura 1 e construção, associando-as a uma única classe. Além disso, as classes de culturas 2, 3 e vegetação 2 também são confundidas e classificadas como uma só classe nos classificadores *fuzzy* c-médias e k-médias.




Figura 10: Resultado da classificação usando o classificador k-médias




Figura 11: Resultado da classificação usando o mapa *fuzzy* c-médias




Figura 12: Resultado da classificação usando o mapa auto-organizado de Kohonen com função de distância gaussiana (padrão)




Figura 13: Resultado da classificação usando o mapa auto-organizado de Kohonen com função de distância retangular




Figura 14: Pós-rotulação da classificação da Figura 13

Os resultados obtidos com o mapa auto-organizado de Kohonen padrão e com função de vizinhança retangular mostraram que classificadores não-supervisionados conjugados com pós-rotulação podem ser utilizados para gerar resultados interessantes e tão precisos quanto aqueles obtidos com classificadores supervisionados.

Como trabalhos futuros estão sendo feitos experimentos baseados em ferramentas de otimização, para otimizar a classificação das imagens em função de parâmetros como o índice κ e elementos específicos da matriz de confusão, que podem implicar em otimização da classificação em nível global e local, respectivamente.

Referências

Duda, R.; Hart, P.; Stork, D. G. *Pattern Classification*. [S.l.]: John Wiley and Sons, 2001.

Freitas, R. M.; Haertel, V.; Shimabukuro, Y. E. Análise multisensor e multiresolução de imagens cbers-2 através do modelo linear de mistura espectral. In: SOCIEDADE BRASILEIRA DE SENSORIAMENTO REMOTO. *XIII Simpósio Brasileiro de Sensoriamento Remoto*. Florianópolis, Brasil, 2007. p. 895–902.

Haykin, S. *Redes Neurais: Princípios e Prática*. Porto Alegre: Bookman, 2001.

Ohata, A. T.; Quintanilha, J. A. O uso de algoritmos de clustering na mensuração da expansão urbana e detecção de alterações na região metropolitana de são paulo (1991-2002). In: SOCIEDADE BRASILEIRA DE SENSORIAMENTO REMOTO. *XII Simpósio Brasileiro de Sensoriamento Remoto*. Goiânia, Brasil, 2005. p. 647–655.

Santos, W. P. et al. Uma nova técnica de classificação de imagens baseada em lógica nebulosa não iterativa. In: SOCIEDADE BRASILEIRA DE SENSORIAMENTO REMOTO. *XI Simpósio Brasileiro de Sensoriamento Remoto*. Belo Horizonte, Brasil, 2003. p. 1091–1098.