

Um método de classificação de imagens baseado em teoria de possibilidades e agrupamento

Isabela N. Drummond¹ e Sandra Sandri²

1: Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, Brazil

2: Campus Univ. Autònoma de Barcelona, Bellaterra 08193, Spain

E-mail: ¹ isabela@lac.inpe.br, ² sandri@iia.csic.es

Resumo

Este trabalho propõe um método geral de classificação baseado em teoria de possibilidades e agrupamento. A abordagem é aplicada a uma imagem CBERS e alguns dos resultados obtidos são apresentados.

Palavras-chave: *classificação de imagens, agrupamento, teoria de possibilidades, relação de similaridade.*

1 Introdução

A classificação de uma imagem consiste em identificar diferentes feições que apresentam padrões espectrais similares, e atribuí-los a uma determinada classe. Várias técnicas podem ser usadas para realizar a classificação, como heurísticas, estatísticas, redes neurais, morfologia matemática, agrupamento, entre outras. Geralmente, emprega-se na classificação teoria de probabilidades e ferramentas estatísticas. Neste trabalho propõe-se um método de classificação supervisionada baseado em teoria de possibilidades e agrupamento difuso. Como em [1, 2], avalia-se o desempenho de novas teorias e heurísticas na classificação de imagens.

Existem essencialmente duas abordagens na classificação de imagens: supervisionada e não supervisionada, distintas em função da presença ou ausência de uma fase de treinamento, pela qual o analista fornece as amostras que orientam a classificação digital. Na classificação supervisionada, tem-se de antemão algum conhecimento sobre as classes presentes na imagem quanto ao seu número e aos pixels representativos destas classes. Já a técnica não supervisionada é utilizada quando não se tem nenhum tipo de conhecimento prévio e baseia-se numa análise de agrupamento onde são identificados os grupos ou classes formados por pixels espectralmente similares no espaço de atributos.

A abordagem aqui resumida é descrita em [3], que

apresenta resultados a partir de uma imagem CBERS [4] comparando-os com outros, obtidos a partir da aplicação de diferentes métodos de classificação. O processo parte do agrupamento das respostas espectrais dos elementos que compõem a amostra de cada classe, ou seja, são criados protótipos de cada classe. Em seguida uma relação de similaridade é aplicada a cada protótipo fazendo com que as classes sejam “engordadas”. Para classificar um pixel da imagem verifica-se sua semelhança com relação aos protótipos, calculando a distância da resposta espectral do pixel para cada protótipo das classes. Em seguida, uma heurística é utilizada para determinar se o pixel pertence a uma única classe ou a uma composição delas. Ao final um algoritmo de vizinhança é empregado para obter a classificação da imagem.

Dentre os fundamentos empregados nesta abordagem, além das teorias de possibilidades [5] e dos conjuntos difusos [6], destacam-se a relação de similaridade que é uma relação binária difusa S que satisfaz as propriedades de reflexividade e simetria e o algoritmo de agrupamento FCM (fuzzy c-means) [7] que consiste num método onde os elementos pertencem a todos os grupos com graus de pertinência diferentes, obtidos a partir da distância entre o elemento e os centros dos grupos.

As seções que se seguem dedicam-se ao método proposto, sua aplicação e as considerações finais.

2 Método de classificação

O método é dividido em duas fases, a fase de pré-processamento e o método propriamente dito.

Seja I uma imagem multiespectral, $C = \{c_1, \dots, c_n\}$ o conjunto de n classes, m o número de bandas da imagem e $V = (x, f(x))$, $f(x) = (f_1(x), \dots, f_m(x))$ a posição do pixel, com $f_l(x)$ igual ao valor radiométrico de V na banda l , definido em uma escala não binária Ω . O conjunto de todos os pontos do espaço de atributos é denotado por $P = \Omega^m$; $I_i \subseteq I$ é a amostra associada à

classe c_i e $P_i \subseteq P$ é o conjunto de pontos associados a $c_i \in C$ no espaço de atributos. P_i é obtido a partir de I_i , ou seja, para cada pixel $(x, f(x)) \in I_i$ tem-se $f(x) \in P_i$. E seja ainda $d(p_1, p_2)$ a distância entre os pontos p_1 e p_2 em P , de acordo com a métrica determinada.

Na fase de pré-processamento, para cada classe c_i são agrupados os pontos em P_i , criando k centros (ou protótipos) $p_{i,j}$. Para cada centro $p_{i,j}$, associa-se a menor e a maior distância dele para os elementos de P_i . Além disso, são calculadas as distâncias entre cada par de centros, identificando os centros que têm o maior potencial de apresentar pontos classificados erroneamente como pertencentes a uma determinada classe c_i .

O método geral de classificação é descrito como:

- (1) Associa-se uma distribuição de possibilidade $\pi_{i,j} : P \rightarrow [0, 1]$ a cada protótipo $p_{i,j} \in T$, e para cada ponto $p \in P$ associa-se uma distribuição $\pi_p : T \rightarrow [0, 1]$. Essas distribuições são calculadas como $\pi_{i,j}(p) = \pi_p(p_{i,j}) = S(p_{i,j}, p)$, onde S é uma relação de similaridade.
- (2) Para cada pixel $(x, f(x))$ na imagem é obtida a distribuição de possibilidade da sua classe, definida como $\pi_{(x, f(x))} : C \rightarrow [0, 1]$, e calculada como $\forall c_i \in C, \pi_{(x, f(x))}(c_i) = \perp_{1 \leq j \leq k} \pi_{f(x)}(p_{i,j})$, onde \perp é uma t-conorma.
- (3) Utiliza-se um critério de classificação para determinar um conjunto “crisp” de classes associadas a $f(x)$, denotadas como $class(f(x))$.
- (4) A cada pixel $(x, f(x))$ é associada uma classe como $class(x, f(x)) = class(f(x))$.
- (5) Emprega-se um critério de vizinhança para obter uma única classe para $(x, f(x))$ usando informação sobre as classes associadas a $f(x)$ e a $f(y)$, onde $(y, f(y))$ é um pixel na vizinhança do pixel $(x, f(x))$ na imagem.
- (6) Emprega-se algum índice para verificar se a qualidade da classificação é aceitável.

3 Aplicação

3.1 Critério de classificação

A seguir é apresentada a implementação do critério de classificação adotado no passo 3 do método de classificação. Seja $p \in P$ um ponto do espaço de atributos e $\pi_p : T \rightarrow [0, 1]$ a distribuição de possibilidade de p pertencente à c_i , de acordo com o centro $p_{i,j}$. E seja ainda $p_{a,b}$ e $p_{c,d}$, $1 \leq a, c \leq n$, $1 \leq b, d \leq k$, os centros que apresentam os maiores graus de possibilidade

em π_p , tal que $\pi_p(p_{a,b}) \geq \pi_p(p_{c,d})$. Para valores arbitrários de $\alpha \in \mathbf{R}$, $\alpha > 1$, e $\beta \in]0, 1]$ o algoritmo de classificação proposto pode ser descrito como:

Se $a = c$
então $class(p) = c_a$
senão se $\pi_{p_{c,d}}(p_{a,b}) \geq \alpha \pi_p(p_{a,b})$
então $class(p) = indefinido$
senão se $\pi_p(p_{c,d}) / \pi_p(p_{a,b}) \geq \beta$
então $class(p) = \{c_a, c_b\}$
senão $class(p) = c_a$.

3.2 Experimentos e resultados

Neste trabalho foi utilizada uma imagem CBERS multi-espectral, com 3 bandas para ilustrar e validar o método de classificação proposto. A imagem tem dimensão 839×650 (Figura 2a), com escala $\Omega = \{0, \dots, 255\}$ e representa a região nordeste do Rio Grande do Sul, no Brasil.

Na fase de pré-processamento o agrupamento dos pontos que compõem o espaço de atributos P , representado na Figura 1, é realizado através do algoritmo FCM. O número de centros é fixado em $k = 3$.




Figura 1: Espaço de atributos P .

A relação de similaridade proposta para implementar o passo 1 do método geral é a seguinte:

$$S_{\gamma, \lambda} = \begin{cases} 1, & \text{se } |x - y| \leq \gamma \\ S_{\lambda - \gamma}, & \text{senão} \end{cases} \quad (1)$$

com $\gamma \leq \lambda$ e $\gamma, \lambda \geq 0$.

A t-conorma \perp empregada é o max. O algoritmo do vizinho mais próximo é adotado no passo 5, onde cada pixel da imagem pertence à mesma classe a qual pertence a maioria dos seus 8 vizinhos. A análise dos resultados foi feita a partir do índice kappa [8].

A Tabela 1 apresenta os resultados obtidos a partir de alguns experimentos realizados empregando a relação de similaridade 1; kappa' e kappa'' são os índices obtidos antes e depois da aplicação

Tabela 1: Experimentos.

	$S_{(\gamma,\lambda)}$	α	β	kappa' (%)	kappa'' (%)
experimento 1	$S_{\lambda 1} \perp S'_{\gamma 1}$	1.2	0.98	75.7	84.7
experimento 2	S_{200}	1.4	0.98	77	83.4
experimento 3	$S_{200} \perp S'_{\gamma 2}$	1.2	0.98	75.7	82
experimento 4	$S_{(\gamma 1, \lambda 1)}$	1.2	0.98	66.7	77.4

do algoritmo de vizinhança, respectivamente. Na tabela tem-se $\lambda 1 = \min(200, k * dmax)$, $k = 20$, $\gamma 1 = \min(dmax, dext, \max(0, din))$ e $\gamma 2 = f(\min(dext, dmax * k1), \max(din, dmin * k2))$; $k1 = k2 = 2$; $f(a, b) = (a + b)/2$. Na Figura 2b é mostrada a imagem classificada obtida a partir do experimento 1.

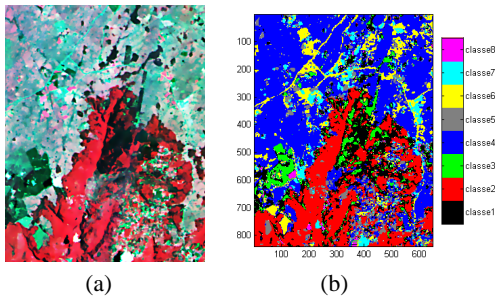


Figura 2: a) Imagem de teste. b) Imagem classificada

4 Conclusão

Espera-se que a abordagem aqui proposta seja um método eficiente em aplicações reais, supondo que as características dos próprios grupos sejam úteis no processo de classificação. O processo pode envolver outras técnicas na busca de classificações mais precisas, entre diferentes métodos de agrupamento na fase de pré-processamento e diferentes relações de similaridade no processo propriamente dito, levando em conta que o resultado obtido mostra uma abordagem promissora.

A escolha do método de agrupamento empregado na fase de pré-processamento é importante, uma vez que os métodos tem características referentes à inicialização, que na maioria deles é aleatória e depende da forma dos grupos. Algoritmos como aqueles apresentados em [9] buscam pelo número ideal de grupos dentro do conjunto de dados. Em se tratando de processamento de imagens o alto custo computacional destes algoritmos pode ser inviável, uma vez que a aplicação em si já apresenta um custo significativo.

Para o caso testado os resultados obtidos foram satisfatórios, apesar de terem sido decorrentes da aplicação em apenas uma imagem de teste. Os testes se limitaram a um número fixo de grupos na etapa em que foi empregado o método FCM. Este é um parâmetro dependente das amostras para cada caso em particular, considerando que cada imagem tem suas particu-

laridades, seu contraste e seu número de classes bem definidas. No entanto, bons resultados não seriam obtidos se algumas das classes fossem muito grandes ou com distribuição muito espalhada. Isto acarretaria raio das classes muito grande, fazendo com que as classes menores fossem completamente confundidas. Por outro lado, se um número muito grande de centros fosse empregado o custo poderia se tornar proibitivo. Nestes casos, seria possível que as técnicas que trabalham com número variável de centros se mostrassem vantajosas.

O trabalho, ainda em desenvolvimento, está buscando diferentes conjuntos de dados para validação do procedimento apresentado. O método será aplicado a uma imagem CBERS de outra região brasileira e a imagens de ressonância magnética.

Referências

- [1] Malinski, P.; Sandri, S.; Freitas, C. An imprecision-based image classifier. *Proc. FUZZ-IEEE'01 Melbourne* (Au), dec. 2001.
- [2] Roux, L.; Desachy, J. Multisource information-fusion application for satellite image classification. in *Fuzzy information Engineering: A Guided Tour of Applications*, 1997. p. 111-121.
- [3] Drummond, I., Sandri, S. A clustering-based possibilistic method for image classification. *Proc of SBIA 2004*, São Luís (Brasil), September, vol 3171, 454-463, 2004.
- [4] Instituto Nacional de Pesquisas Espaciais - INPE, 2004. **CBERS Program**, S. J. dos Campos (Br). http://www.cbbers.inpe.br/en/index_en.htm
- [5] R.R. Yager, S. Ovchinnikov, R.M. Tong and H.T. Nguyen. *Fuzzy Sets and Applications: selected papers by L.A. Zadeh*, Wiley, 1987.
- [6] Zadeh, L. A. Fuzzy Sets, *Information and Control*, v. 8, p.338-353, 1965.
- [7] Bezdek, J., Ehrlich, R. e Full, W. FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences* vol 10, n. 2-3, 191-203, 1984.
- [8] Bishop, Y. M.; Feinberg, S. E.; Holland, P. W. *Discrete Multivariate Analysis: Theory as Practice* MIT Press, Cambridge, MA, 1975.
- [9] Kaymak, U. ; Setnes, M. Extended fuzzy clustering algorithms. In: *ERIM Report Series Research in Management ERS2000-51-LIS*, Erasmus Research Inst. of Management, 2000. <http://www.erim.eur.nl>