

## Classificador Simbólico para Imagens SAR

CÉZAR AUGUSTO DE FREITAS ANSELMO<sup>1</sup>  
FRANCISCO DE ASSIS TENÓRIO DE CARVALHO<sup>2</sup>  
RENATA MARIA CARDOSO RODRIGUES DE SOUZA<sup>2</sup>

<sup>1</sup>Departamento de Estatística

<sup>2</sup>Centro de Informática

UFPE - Universidade Federal de Pernambuco

50740-540 - Recife - PE, Brasil

cafa@cin.ufpe.br, fatc@cin.ufpe.br, rmcrs@cin.ufpe.br

**Abstract** The aim of this paper is to present the approach showed in De Carvalho et al (2000) to classify SAR images based on a Boolean symbolic classifier. A Monte Carlo experience is devised and the feasibility of the symbolic approach is quantitatively assessed.

**Keywords:** SAR images, symbolic objects, supervised classification

### 1 Introdução

Com os recentes avanços nas tecnologias da informação em todos os domínios da atividade humana, enormes bancos de dados são atualmente armazenados em grandes bases de dados. Nos dias de hoje, algumas abordagens têm sido propostas visando descobrir regularidades, para extrair conhecimento e resumir as informações armazenadas nessas grandes bases de dados. A abordagem aqui exposta é denominada Análise de Dados Simbólicos (ADS) (Diday (1988)). Seu primeiro passo consiste na extração de conhecimentos dessas grandes bases de dados como em *Data Mining* (Mineração de Dados). Esses conhecimentos são descritos por dados mais complexos chamados "dados simbólicos", que são estruturados e podem conter variação interna ou incertezas.

O segundo passo em ADS é aplicar novas ferramentas a esse conhecimento extraído visando estender a Mineração de Dados para a *Knowledge Mining* (Mineração de Conhecimentos) (Diday (1998)). Então, uma extensão da análise exploratória de dados e dos métodos estatísticos para os dados simbólicos se faz necessária.

O objetivo deste trabalho consiste em exibir a metodologia apresentada em De Carvalho et al (2000) que utiliza imagens SAR (*Synthetic Aperture Radar*) simuladas como um exemplo de grandes bases de dados para entrada em um classificador simbólico. A metodologia aplicada é baseada no trabalho de Ichino et al (1996) onde eles introduzem um classificador simbólico booleano como uma abordagem orientada a regiões. A principal idéia dessa abordagem é a adaptação do conceito de vizinhos mútuos, introduzido por Gowda et al (1978), para definir os conceitos de vizinhos mútuos entre objetos simbólicos booleanos (daqui em diante denotados por OS's) e grafo de vizinhos mútuos (GVM) entre grupos.

O classificador simbólico tem como conjunto de treinamento amostras de dados dos grupos pré-definidos (etapa de aprendizagem) apresentadas em uma tabela usual de valores. A etapa de aprendizagem organiza uma descrição completa e discriminante de cada grupo utilizando objetos simbólicos ou uma disjunção de objetos simbólicos que são obtidos usando como ferramentas de generalização uma aproximação do GVM e um operador simbólico booleano (junção). A regra de classificação é baseada em uma função de comparação que verifica se a descrição de um indivíduo é compatível com a descrição de um grupo.

## 2 Imagens SAR

O sistema SAR tem propiciado um crescente interesse pelos dados obtidos através desse sistema e, em suas aplicações, em atividades de sensoriamento remoto. Apesar da importância desses dados, evidenciada pelo volume de trabalhos elaborados, sabe-se que essas imagens possuem um ruído, denominado *speckle*, que está associado ao uso da radiação coerente produzida pelo mecanismo de formação da imagem. Esse aspecto torna o desenvolvimento e a implementação das técnicas automáticas de processamento e análise de imagens tarefas relativamente complexas (Frery et al (1997)).

O objetivo principal das aplicações em processamento de imagens é extrair características relevantes que levem à descrição ou ao entendimento de uma cena. O processo de análise de uma imagem envolve o estudo de técnicas de segmentação e de classificação.

A segmentação consiste em agregar pixels formando regiões denominadas de segmentos. Essas regiões são disjuntas, contínuas (segundo alguma topologia discreta) e, de acordo com algum critério tal como níveis de cinza, textura ou contraste, também são uniformes.

O resultado da segmentação permite gerar descrições sobre a estrutura da imagem. Essas descrições são obtidas através da associação de valores a atributos tais como média, desvio padrão ou medidas de curtose dos níveis de cinza dos segmentos e são afetadas à classe de uso e ocupação do solo a que os segmentos pertencem. Uma vez geradas as descrições realiza-se a classificação supervisionada permitindo alocar novos segmentos a uma das classes predefinidas.

## 3 Fundamentos em Objetos Simbólicos

Extração de conhecimentos quer dizer obtenção de novos conceitos, motivo pelo qual os OS's são introduzidos. Eles compõem uma modelagem matemática de conceitos e são usados como entrada e como saída explanatória de uma ADS (Diday (1998)).

Seja  $W$  um conjunto de indivíduos e  $\{D_1, \dots, D_p\}$  o domínio das variáveis  $y_j$  ( $j = 1, \dots, p$ ) selecionadas para descrever os indivíduos como também os OS's booleanos. Essas variáveis podem ser de diferentes tipos: nominal, ordinal, discretas ou contínuas, multivaloradas ou intervalos para um OS booleano.

Um OS booleano  $s$  é expresso pela tripla  $(a, R, d)$  onde

- i)  $d = (d_1, \dots, d_p)$ ,  $d_j \in D_j$ , é o conjunto de valores assumidos pelas variáveis em sua descrição;
- ii)  $R = (R_1, \dots, R_p)$  é o conjunto de relações (por exemplo:  $\subseteq, \in, \dots$ );

- iii)  $a$  é uma função booleana que permite comparar  $\mathbf{w} \in \mathbf{W}$  com  $s$  de tal modo que se  $a(\mathbf{w}) = \bigwedge_j [y_j(\mathbf{w}) R_j d_j] \in \{\text{verdadeiro}\}$  isto significa que  $\mathbf{w}$  respeita todas as propriedades em  $d$  por meio das relações em  $R$ . A extensão de um OS  $s$  em  $\mathbf{W}$  é definida como  $\text{Ext}(s/\mathbf{W}) = \{\mathbf{w} \in \mathbf{W} \mid a(\mathbf{w}) = \text{verdadeiro}\}$ .

*Exemplo.* Um segmento (conjunto de pixels) descrito como dados usuais pela média dos níveis de cinza ( $y_1$ ) e pelo desvio-padrão ( $y_2$ ) dos mesmos pode ser representado por um OS booleano como  $seg = [y_1 \in [167,5; 174,8]] \wedge [y_2 \in [4,3; 12,1]]$ .

Além disso, um OS pode ser descrito também por variáveis modais, quando é associada às categorias ou intervalos uma moda, isto é, uma medida de probabilidade, possibilidade ou crença. O OS é então chamado modal.


## 4 Classificador Simbólico

No início desta seção são lembradas algumas definições que serão necessárias para descrever as modificações que foram introduzidas na etapa de aprendizagem (ferramentas de generalização e aproximações ao GVM) e na etapa de alocação (funções de comparação) do classificador.

### 4.1 Operações Simbólicas Booleanas

Sejam  $a = [y_1 \in \bar{d}_1] \wedge \dots \wedge [y_p \in \bar{d}_p]$  e  $b = [y_1 \in \underline{d}_1] \wedge \dots \wedge [y_p \in \underline{d}_p]$  dois OS's booleanos. As seguintes operações podem ser definidas (Diday (1998), Ichino et al (1996)):

- A junção entre  $a$  e  $b$  é definida como  $a \oplus b = [y_1 \in \bar{d}_1 \oplus \underline{d}_1] \wedge \dots \wedge [y_p \in \bar{d}_p \oplus \underline{d}_p]$ , onde
  - se  $y_i$  é quantitativa ou qualitativa ordinal,  $\bar{d}_i \oplus \underline{d}_i = [\text{mín}(\bar{i}_i, \underline{i}_i), \text{máx}(\bar{s}_i, \underline{s}_i)]$ , onde  $(\bar{i}_i, \underline{i}_i)$  e  $(\bar{s}_i, \underline{s}_i)$  são os limites inferior e superior dos intervalos  $\bar{d}_i$  e  $\underline{d}_i$ , respectivamente, como pode-se ver na **Figura 1**; mín e máx fornecem, respectivamente, o mínimo e o máximo entre dois valores;
  - se  $y_i$  é qualitativa nominal,  $\bar{d}_i \oplus \underline{d}_i = \bar{d}_i \cup \underline{d}_i$ .
- A disjunção entre  $a$  e  $b$  é definida como  $a \vee b = \{[y_1 \in \bar{d}_1] \wedge \dots \wedge [y_p \in \bar{d}_p]\} \vee [y_1 \in \underline{d}_1] \wedge \dots \wedge [y_p \in \underline{d}_p]$ .
- A conjunção entre  $a$  e  $b$  é definida como  $a \wedge b = [y_1 \in \bar{d}_1 \cap \underline{d}_1] \wedge \dots \wedge [y_p \in \bar{d}_p \cap \underline{d}_p]$ .




**Figura 1. Operadores simbólicos**

## 4.2 Relação de Vizinhos Mútuos

Seja  $C = \{C_i\}$  um conjunto de  $m$  grupos de OS's, onde  $C_i = \{a_{i1}, \dots, a_{in_i}\}$ ,  $a_{ij} = \bigwedge_{k=1}^p [y_k \in d_{ijk}]$ ,  $i \in \{1, \dots, m\}$  e  $j \in \{1, \dots, n_i\}$ . Assuma  $a_{ip}, a_{iq} \in C_i$ . A relação de vizinhos mútuos (RVM)  $R_v$  (Ichino et al (1996)) é definida dizendo-se que  $a_{ip} R_v a_{iq}$  é verdadeira se e só se  $\forall a_{jl} \in \bar{C}_i = \bigcup_{j \neq i}^m C_j, \exists k \in \{1, \dots, p\}$  tal que  $d_{jlk} \cap (d_{ipk} \oplus d_{iqk}) = \emptyset$ .

## 4.3 Grafo de Vizinhos Mútuos

O GVM (Ichino et al (1996)) de  $C_i$  e  $\bar{C}_i$ , denotado como  $GVM(C_i/\bar{C}_i)$ , é um grafo onde os nós são OS's de  $C_i$  e as arestas são os distintos pares de OS's de  $C_i$  satisfazendo a RVM, isto é,  $RVM(C_i/\bar{C}_i) = (N, E)$ , onde  $N = C_i$  e  $E = \{(a_{ip}, a_{iq}) \in C_i \times C_i / p \neq q \text{ e } a_{ip} R_v a_{iq} \text{ é verdadeira}\}$ , conforme pode-se ver na **Figura 2**.




**Figura 2. Grafos de Vizinhos Mútuos**

## 4.4 Etapa de Aprendizagem


A idéia central do algoritmo de aprendizagem é obter uma descrição simbólica de cada grupo baseada no GVM e no operador junção da seguinte maneira:

- i) se o GVM é um grafo completo, o grupo será descrito pelo OS obtido pela junção de seus membros;
- ii) caso contrário, o grupo será descrito por uma disjunção de OS's booleanos, cada um sendo obtido da junção dos membros do grupo que formam uma clique.

Infelizmente, encontrar todas as cliques desse grafo é um problema NP-completo. Para melhorar o tempo de execução do sistema ao lidar com grandes conjuntos de dados foram utilizadas as modificações apresentadas em De Carvalho et al (2000). As **Figura 3a** e **3b** ilustram, respectivamente, a idéia central do algoritmo e uma das modificações utilizadas.



**Figura 3a**



**Figura 3b**

#### 4.5 Etapa de Alocação

A alocação de uma nova observação a um grupo é baseada em funções de comparação entre uma descrição padrão de um indivíduo e um OS booleano que descreve um grupo. Note que um indivíduo, que é descrito de um modo usual, também pode ser descrito como um OS booleano.

Seja  $a = \bigwedge_{j=1}^p [y_j \in d_j^a]$  um OS booleano que descreve uma nova observação a ser classificada e seja  $r_i = \bigvee_v r_{iv}$ ,  $r_{iv} = \bigwedge_{j=1}^p [y_j \in d_{iv}^r]$  a disjunção de OS's booleanos que descreve o grupo  $C_i$ ,  $i \in \{1, \dots, m\}$ .

No algoritmo de Ichino et al (1996) é usada a seguinte regra de afetação: uma nova observação  $a$  é afetada ao grupo  $C_i$ , descrito por  $r_i$ , se  $f(a, r_i) \geq f(a, r_h)$ ,  $\forall h \in \{1, \dots, m\}$ , onde  $f(a, r_h) = \max_v f(a, r_{hv})$  e

$$f(a, r_{hv}) = \frac{1}{p} \sum_{j=1}^p \frac{\mathbf{m}(d_{hv}^r)}{\mathbf{m}(d_{hv}^r \oplus d_j^a)} \text{ com } \mathbf{m}(d) = \begin{cases} \text{cardinal}(d), & \text{se } d \text{ é um conjunto finito} \\ \text{amplitude}(d), & \text{se } d \text{ é um intervalo} \end{cases}$$

Note que  $f$  é uma função de similaridade simétrica entre uma descrição usual de uma observação e a descrição simbólica booleana de um grupo.

Também foram utilizadas como alternativa funções de dissimilaridade. Nesse caso, a regra de afetação torna-se: uma observação representada por  $a$  é afetada ao grupo  $C_i$ , descrito por  $r_i$ , se  $d_I(a, r_i) \leq d_I(a, r_h)$ ,  $\forall h \in \{1, \dots, m\}$ , onde  $d_I(a, r_h) = \min_v d_I(a, r_{hv})$  e (De Carvalho et al (1999))

$$d_I(a, r_{hv}) = \frac{1}{p} \left[ \sum_{j=1}^p \{ \mathcal{Y}(a_j, r_{hvj}) \}^I \right]^{\frac{1}{I}}, \text{ k, r} \in \{1, 2, \dots\}, \text{ com}$$

$$\mathcal{Y}(a_j, r_{hvj}) = \left\{ \frac{1}{2} \left[ \left( \frac{\mathbf{f}_{1g}(a_j, r_{hvj})}{\mathbf{m}(d_j^a \oplus d_{hvj}^r)} \right)^k + \left( \frac{\mathbf{f}_{2g}(a_j, r_{hvj})}{\mathbf{m}(d_j^a \oplus d_{hvj}^r)} \right)^k \right] \right\}^{\frac{1}{k}} \text{ e}$$

$\mathbf{f}_{1g}$  e  $\mathbf{f}_{2g}$  para  $\gamma=0,5$  são dadas abaixo

$$\mathbf{f}_{1g}(a_j, r_{hvj}) = \overline{\mathbf{m}(d_j^a \cap d_{hvj}^r)} + \overline{\mathbf{m}(d_j^a \cap d_{hvj}^r \cap (d_j^a \oplus d_{hvj}^r))}$$

$$\mathbf{f}_{2g}(a_j, r_{hvj}) = \overline{\mathbf{m}(d_j^a \cap d_{hvj}^r)} + \overline{\mathbf{m}(d_j^a \cap d_{hvj}^r \cap (d_j^a \oplus d_{hvj}^r))}$$

Note que  $d_I$  é uma função de dissimilaridade simétrica que mede a compatibilidade entre uma descrição usual de uma observação e a descrição simbólica booleana de um grupo.


#### 5 Os Experimentos Monte Carlo

O modelo multiplicativo tem sido largamente usado na modelagem, processamento e análise de imagens SAR. Esse modelo assume que o retorno observado  $Z$  é uma variável aleatória definida como o produto entre duas variáveis aleatórias:  $Y$  (*backscatter*) e  $X$  (ruído *speckle*).

Diferentes tipos de região e de detecção (formato intensidade ou amplitude) podem ser associados a diferentes distribuições para o sinal de retorno. Três tipos de região foram utilizados neste trabalho: homogêneas (como campos agrícolas, solo nu, etc), heterogêneas (como floresta virgem, etc) e extremamente heterogêneas (como áreas urbanas, etc). Uma hipótese comum é

que o sinal de retorno na situação da amplitude tem uma distribuição Raiz de Gama, K-Amplitude e G<sup>0</sup>-Amplitude nas regiões homogêneas, heterogêneas e extremamente heterogêneas, respectivamente (Frery et al (1997)).

O processo para obtenção de imagens simuladas consiste da criação de uma imagem idealizada em classes (**Figura 4**) e de associar a cada classe uma particular distribuição. Essas distribuições estão apresentadas nas **Tabelas 1** e **Tabela 2**. Foram consideradas duas situações de imagens: uma de moderada dificuldade de classificação e outra de extrema dificuldade de classificação.



**Figura 4. Phantom**


**Tabela 1. Distribuições e parâmetros para a imagem na situação 1**

Região	Dist	$\mu$	$\alpha$	$\beta$	$\lambda$	$\gamma$
1	$\Gamma^{1/2}$	42	-	1916	-	-
2	K-A	84	2	-	0.00023	-
3	K-A	168	8	-	0.00025	-
4	$\Gamma^{1/2}$	126	-	17249	-	-
5	G <sup>0</sup> -A	210	-5	-	-	203987


**Tabela 2. Distribuições e parâmetros para a imagem na situação 2**

Região	Dist	$\mu$	$\alpha$	$\beta$	$\lambda$	$\gamma$
1	$\Gamma^{1/2}$	130	-	1831	-	-
2	K-A	150	5	-	0.00019	-
3	K-A	110	4	-	0.00028	-
4	$\Gamma^{1/2}$	160	-	27814	-	-
5	G <sup>0</sup> -A	190	-5	-	-	166982

A filtragem é realizada com o propósito de mitigar o efeito potencialmente nocivo do ruído *speckle* na segmentação e na classificação. Nessa etapa empregou-se o filtro Lee com tamanho de janela 7x7. A **Figura 5a** exibe uma imagem SAR simulada da situação 1, enquanto a **Figura 5b** mostra essa imagem após empregado o filtro Lee.



**Figura 5a**



**Figura 5b**

Na segmentação foi aplicado uma técnica de crescimento de regiões que consiste na agregação de pixels em grupos, supondo que não existem diferenças entre as médias dos níveis de cinza de duas vizinhanças, cada uma contendo no mínimo 4 elementos. Para agregar os pixels aplicou-se o teste estatístico *t-student* com nível de significância de 10% supondo matrizes de covariâncias iguais.

O experimento Monte Carlo foi realizado com imagens de formato amplitude com tamanho  $256 \times 256$  para as duas situações citadas. 100 réplicas foram obtidas com propriedades estatísticas idênticas e a taxa de erro de classificação foi computada. Os resultados foram, em média, em torno de 3% a 23%.

## **6 Comentários Finais e Conclusões**

Foi apresentada a metodologia proposta em De Carvalho et al (2000) para a classificação de imagens SAR simuladas. O desempenho do classificador foi avaliado através da taxa de erro estimada pelo método Monte Carlo. Os resultados obtidos para as situações abrangidas tanto para o caso de classificação moderada quanto para o caso de alta dificuldade de classificação são satisfatórios.

## **Referências**

- De Carvalho, F.A.T.; Anselmo, C.A.F.; Souza, R.M.C.R. **Symbolic Approach to Classify Large Data Sets**. In Data Analysis, Classification and Related Methods. Proceedings of the 7<sup>th</sup> International Conference of Classification Societies (IFCS-2000), Springer, Namur, 2000, 375-380.
- Diday, E. **The symbolic approach in clustering and related methods of data analysis The basic choices**. Classification and Related Methods of Data Analysis. Elsevier Publisher B. V, 1988, 673-683.
- Diday, E. **Symbolic Data Analysis: a Mathematical Framework and Tool for Data Mining**. Advances in Data Science and Classification, Springer-Verlag, Heidelberg, 1998, 409-416.
- Frery, A.C.; Mueller, H.J.; Yanasse, C.C.F.; Sant'ana, S.J.S. **A model for extremely heterogeneous clutter**. IEEE Transactions on Geoscience and Remote Sensing, 1, 648-659, 1997.
- Gowda, K.C.; Krishna, G. **Agglomerative clustering using the concept of mutual nearest neighbourhood**. Pattern Recognition, 10, 1978, 105-112.

Ichino, M.; Yaguchi, H.; Diday, E. **A fuzzy symbolic pattern classifier.** Ordinal and Symbolic Data analysis. Springer, Heidelberg, 1996, 92-102.

Yaguchi, H.; Ichino, M.; Diday, E. **A knowledge acquisition system based on the Cartesian space model.** Ordinal and Symbolic Data analysis. Springer, Heidelberg, 1996, 113-122.