


Métodos de Classificação para Dados Simbólicos

Universidade Federal de Pernambuco

CIn.ufpe.br



Conteúdo

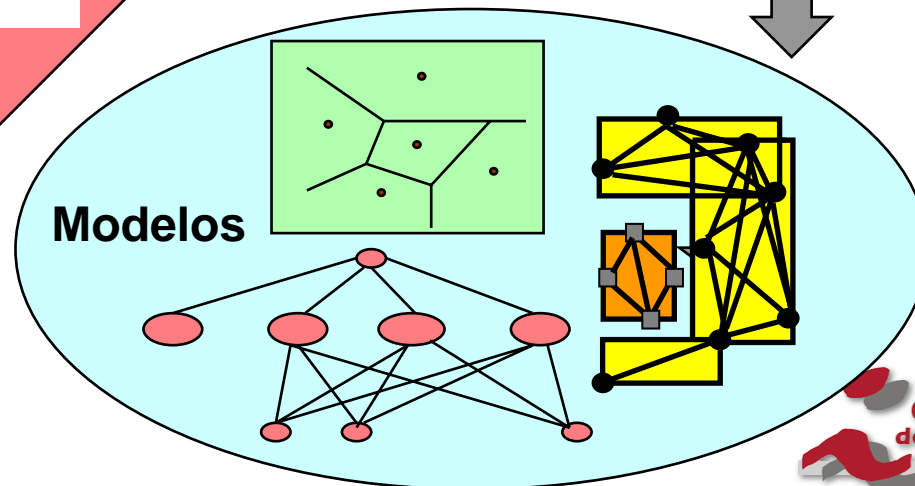
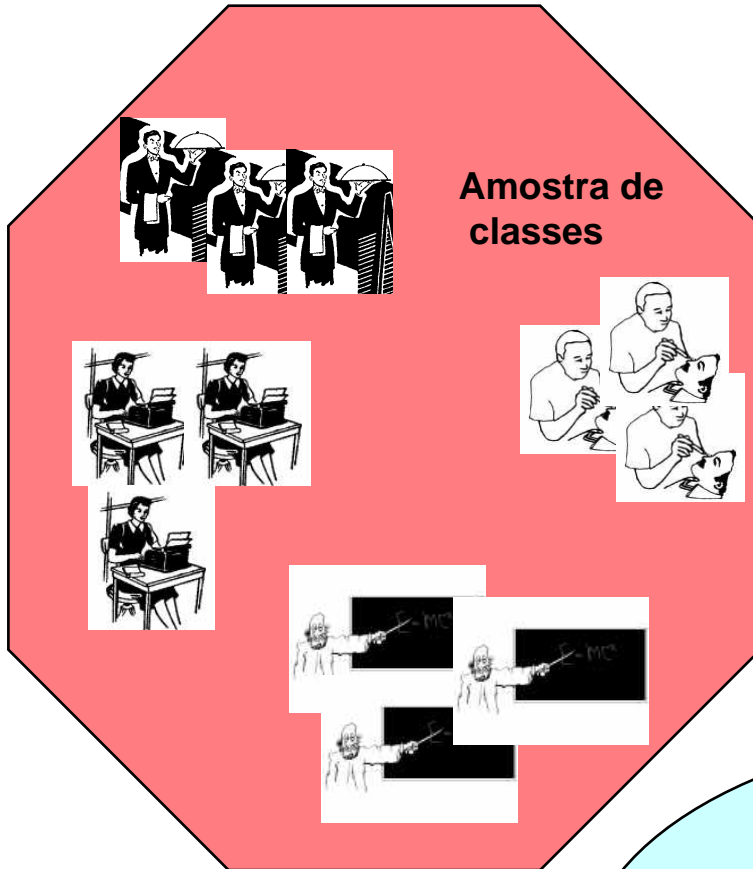


- 1 – Conceito de Classificação Supervisionada
- 2 – Métodos de Classificação para Dados Multivalorados, Modais e de Tipo Intervalo
- 3 – Um Método de Classificação Modal para Dados Multivalorados e de Tipo Intervalo
- 4 – Aplicação com Imagens SAR

Classificador



Etapa de Aprendizagem



Classificador

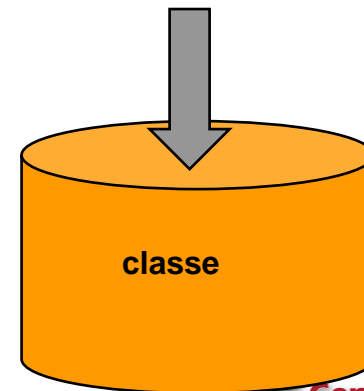



Etapa de Alocação

Novo exemplo



Índice de proximidade




classe

Descrições Simbólicas




classe	Marca	Distribuição de freq. do tempo de uso	Preço
e_1	{CITR, PEUG}	(A0.4 B0.3 C0.4)	[12000, 30000]
e_2	{BMW, FIAT}	(A0.2 B0.5 C0.3)	[15000, 35000]
e_3	{BMW, FIAT, ALFA}	(A0.6 B0.2 C0.2)	[8000, 45000]
:	:	:	:



Multivalorada



Modal



Intervalo



Classificadores para Dados Multivalorados, Modais e de Tipo Intervalo

Medida de Intensidade Kernel

(Rasson and Sandrine, 2000)



$\mathbf{d} = (d_1, \dots, d_p)$ – um vetor de dados simbólicos

P_k - população k , $k = 1, \dots, g$

s_{ki} – objeto simbólico i da classe k , $i = 1, \dots, n_k$

$\mathbf{d}_{ki} = (d_{ki1}, \dots, d_{kip})$ - vetor de descrição i da classe k

$D(\mathbf{d}_{ki}, \mathbf{d}_{mj})$ – medida de dissimilaridade

Medida de Intensidade Kernel



- Classificar um novo objeto ou indivíduo baseando-se em uma medida de intensidade de um dado simbólico.
- O problema é: encontrar um estimador de densidade que mede a concentração dos dados em uma vizinhança de uma observação \mathbf{d} .
- A construção de um kernel fornece um estimador de intensidade que aqui é considerado como uma densidade não padronizada.
- Suposição: A largura do kernel (tamanho da vizinhança) é igual para todas as classes.

Kernel uniforme para estimar Densidade (caso clássico)



- O estimador kernel de densidade uniform é dado por:

$$\hat{f}_k(x) = \frac{1}{n_k (2h_k)^d} \sum_{i=1}^{n_h} K\left(\frac{x - x_{ki}}{h_k}\right) \quad x \in \mathfrak{R}^d$$

- $h_k > 0$
- $K(\cdot)$ é um kernel uniforme em \mathfrak{R}^p
- $\|y\|_\infty = \max \{y_j\} \quad j=1, \dots, p$ $K(y) = \begin{cases} 1 & \text{se } \|y\|_\infty < 1 \\ 0 & \text{caso contrário} \end{cases}$



Kernel Uniforme Simbólico

- Kernel ao nível de variável

$$\hat{I}_k(d_j) = \frac{1}{n_k} \sum_{i=1}^{n_k} K_{d_j, h}(d_{kij})$$

$$K_{d_j, h}(d_{kij}) = \begin{cases} 1 & \text{se } d_{kij} = D(d_j, d_{ki}) < h \\ 0 & \text{caso contrario} \end{cases}$$

- Kernel global

$$\hat{I}_k(d) = \frac{1}{n_k} \sum_{i=1}^{n_k} \prod_{j=1}^p K_{d_j, h}(d_{kij}), \quad j = 1, \dots, p$$

Determinando as probabilidades a priori de cada classe



- 1. Iguais probabilidades a priori

$$\hat{p}_k = \frac{1}{g} \quad \text{para } k = 1, \dots, g$$

- 2. Proporções observadas no conjunto de treinamento

$$\hat{p}_k = \frac{n_k}{n} \quad \text{para } k = 1, \dots, g$$

Determinando as probabilidades a priori de cada classe



- 3. Algoritmo EM: Determinar $\hat{p} = (\hat{p}_1, \dots, \hat{p}_g)$
 - Inicialização: $\hat{p}_k(0) = \frac{1}{g}$ para $k = 1, \dots, g$
 - Calculando a verossimilhança

$$L(p) = \prod_{j=1}^m \sum_{k=1}^g p_k \hat{I}_k(x_j) \quad \text{para } k = 1, \dots, g$$

- Atualizando as probabilidades

$$\hat{p}_k(t+1) = \frac{1}{m} \sum_{j=1}^m \frac{\hat{p}_k(t) \hat{I}_k(x_j)}{\sum_{v=1}^g \hat{p}_v(t) \hat{I}_v(x_j)} \quad \text{para } k = 1, \dots, g \quad t = 0, 1, 2, \dots$$

- Critério de parada $\hat{p}_k(h+1) - \hat{p}_k(h) < \varepsilon$




Regra de decisão

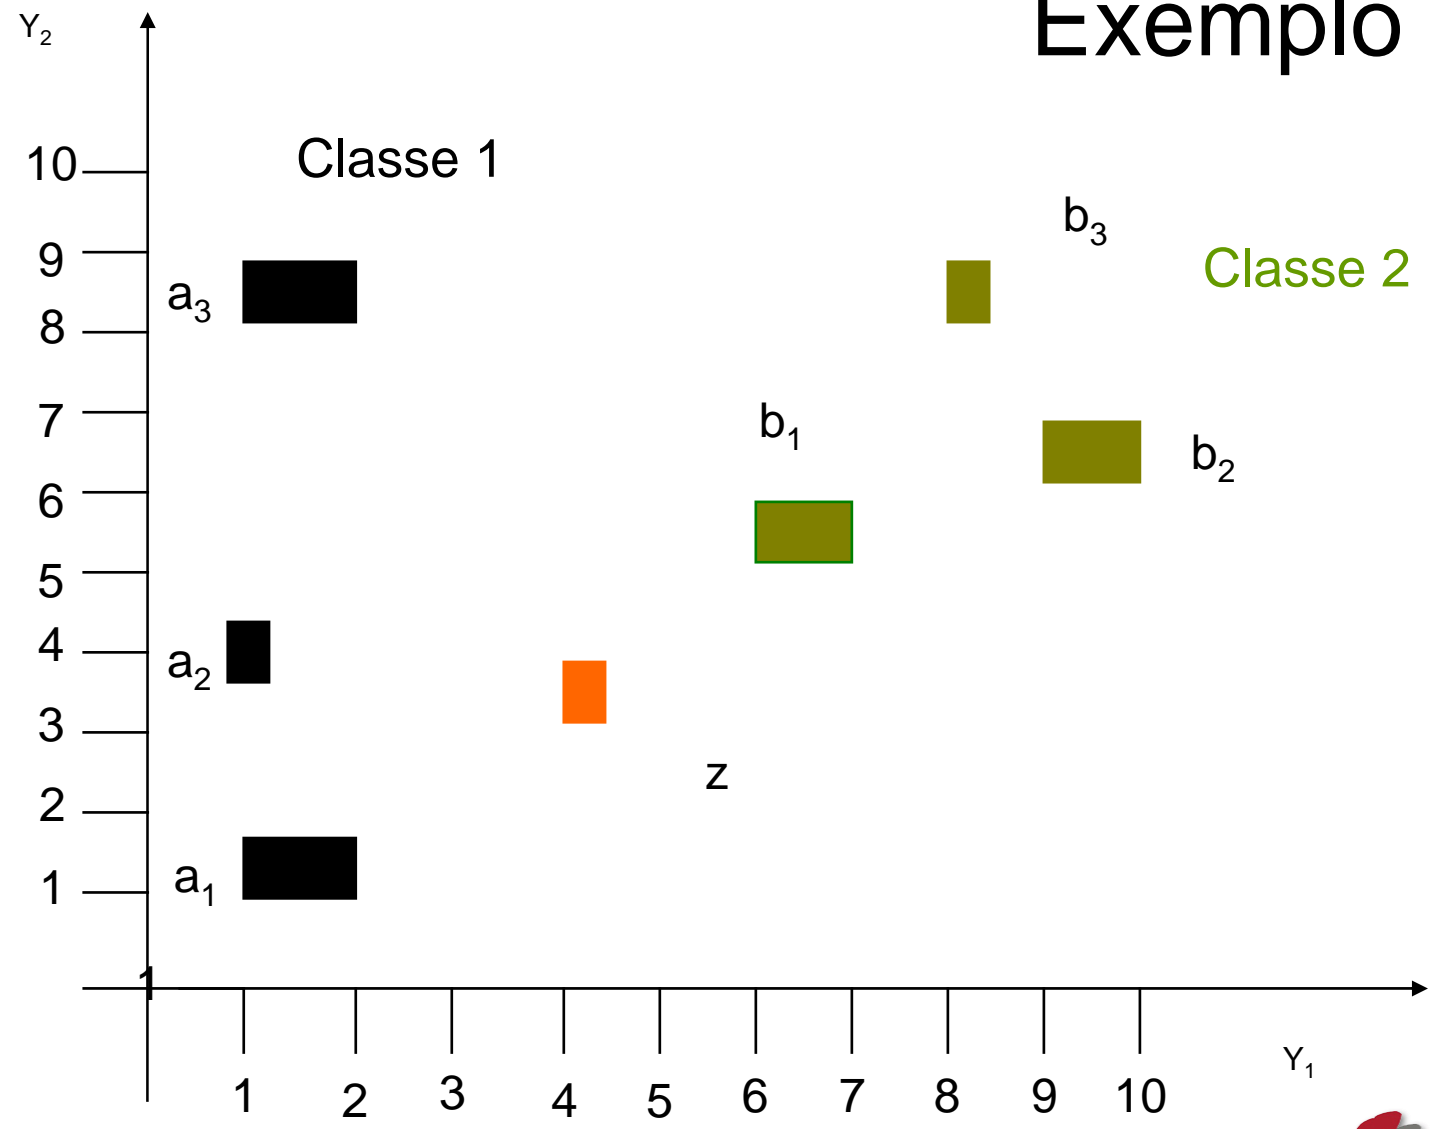
- Afetar o vetor de descrição \mathbf{x} à classe g tal que

$$\hat{p}_k \hat{I}_k(\mathbf{x}) \quad \text{para } k = 1, \dots, g$$

é máxima



Exemplo



Determinando as distâncias

(De Carvalho 1998)



- $d(Z_1, A_{11}) = 0.75$
- $d(Z_2, A_{12}) = 0.50$
- $d(Z_1, A_{21}) = 0.75$
- $d(Z_2, A_{22}) = 0.62$
- $d(Z_1, A_{31}) = 0.75$
- $d(Z_2, A_{32}) = 0.86$
- $d(Z_1, B_{11}) = 0.67$
- $d(Z_2, B_{12}) = 0.75$
- $d(Z_1, B_{21}) = 0.83$
- $d(Z_2, B_{22}) = 0.80$
- $d(Z_1, B_{31}) = 0.80$
- $d(Z_2, B_{32}) = 0.86$



Classificando z

- Calculando kernel global com $h=0.76$

$$\hat{I}_1(z) = \frac{1}{2} \sum_{i=1}^3 \prod_{j=1}^2 K_{z_j, h}(d_{1ij}) = \frac{1}{2} ((1 \times 1) + (1 \times 1) + (1 \times 0)) = 1$$

$$\hat{I}_2(z) = \frac{1}{2} \sum_{i=1}^3 \prod_{j=1}^2 K_{z_j, h}(d_{2ij}) = \frac{1}{2} ((1 \times 1) + (0 \times 0) + (0 \times 0)) = 0.5$$

- Regra de decisão:

$$\hat{p}_1 \hat{I}_1(x) = 0.5 \times 1 = 0.5$$

Associa-se o objeto z à classe 1


$$\hat{p}_2 \hat{I}_2(x) = 0.5 \times 0.5 = 0.25$$



Classificador baseado em Regiões (Souza et al. (1999))

Entrada para Etapa de Aprendizagem:

Descrições usuais ou booleanas



segmento	níveis de cinza	
	média (y_1)	desvio padrão (y_2)
seg ₁	44.50	12.50
seg ₂	83.60	3.60
seg ₃	120.30	6.45
•	•	•
•	•	•

Etapa de Aprendizagem



Idéia Central da Abordagem

- ◆ Construção do Grafo de Vizinhos Mútuos (Ichino et al (1996))

Generalização: junção simbólica (Ichino (1979))

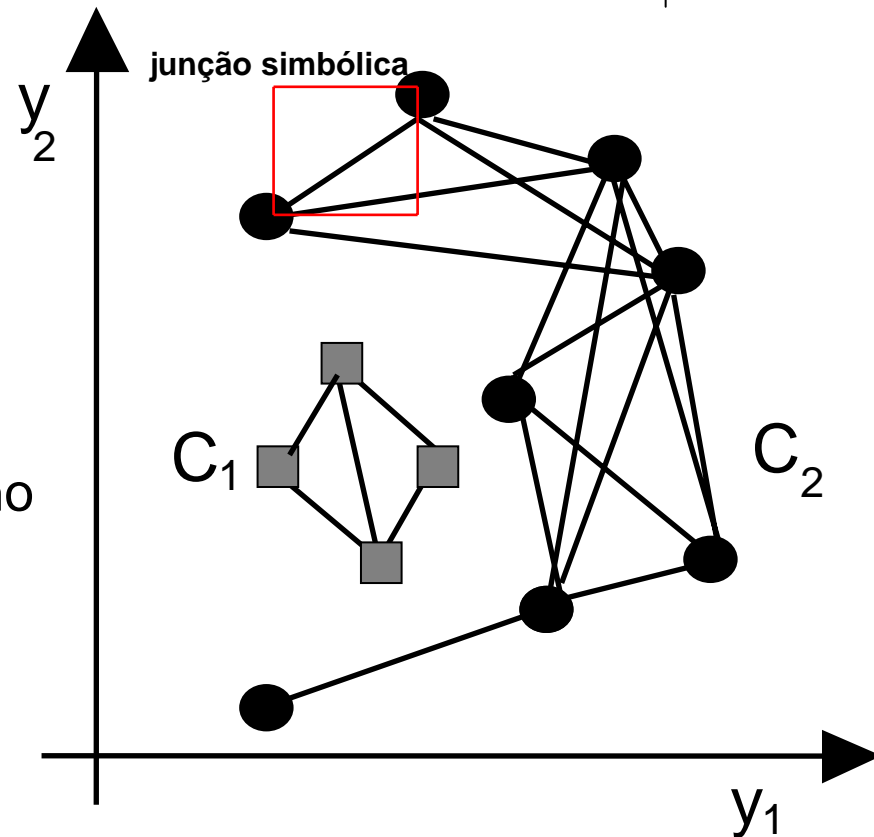


Figura 1. Grafo de Vizinhos Mútuos para duas classes

Etapa de Aprendizagem



Problema:

A complexidade do algoritmo é exponencial

Solução:

Obter uma aproximação do grafo de vizinhos mútuos




Figura 2. Objetos simbólicos

Aproximação do Grafo de Vizinhos Mútuos



Construção de uma clique

- **Escolha da semente**
- **Atualização da descrição**
- **Generalização**

Aproximações do Grafo de Vizinhos Mútuos

Abordagem Ichino et al (1996)



- **Escolha da semente:** o exemplo com o maior número de vizinhos mútuos
- **Atualização da descrição:** baseado no exemplo que tem o maior número de vizinhos mútuos com a descrição atual
- **Generalização:** junção simbólica

Restrição: cada exemplo somente poderá fazer parte de uma descrição simbólica

Aproximações do Grafo de Vizinhos Mútuos

Abordagem Ichino et al (1996)



A complexidade do algoritmo é $O(n^3)$

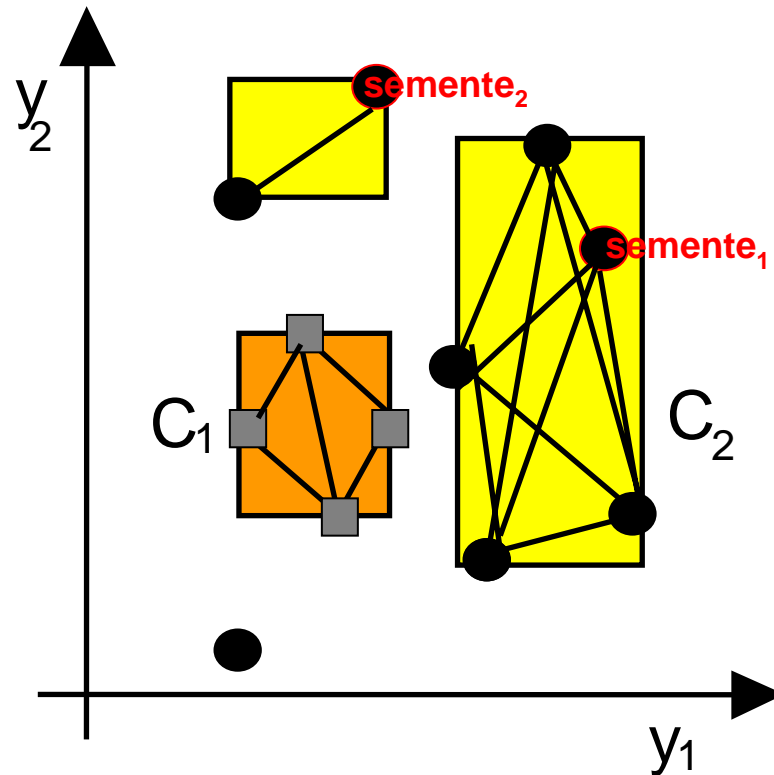


Figura 3. Objetos simbólicos

Aproximações do Grafo de Vizinhos Mútuos

Abordagem Souza et al (1999)



- **Escolha da semente:** ordem lexicográfica
- **Atualização da descrição:** ordem lexicográfica
- **Generalização:** junção simbólica

Aproximações do Grafo de Vizinhos Mútuos

Abordagem Souza et al (1999)



Restrição: cada exemplo somente poderá fazer parte de uma descrição simbólica

A complexidade do algoritmo é $O(n^2)$

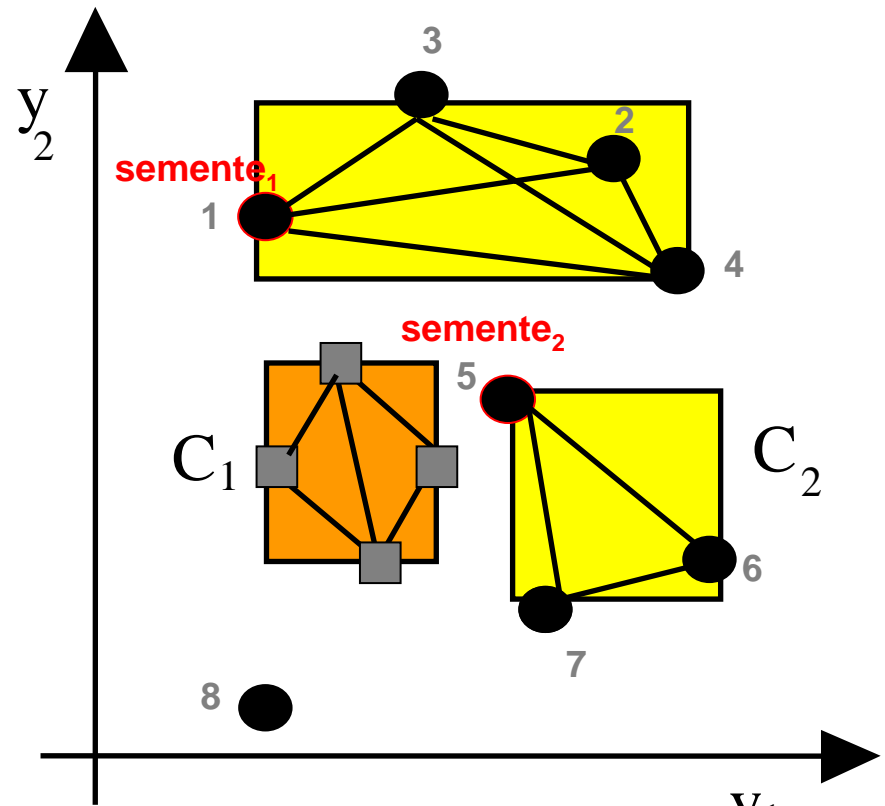


Figura 4. Objetos simbólicos

Aproximações do Grafo de Vizinhos Mútuos

Abordagens De Carvalho et al (2000)



Métodos 1 e 2:

- **Escolha da semente:** ordem lexicográfica
- **Atualização da descrição:** ordem lexicográfica
- **Generalização:** junção simbólica

Restrição 1: cada exemplo somente poderá fazer parte de uma descrição simbólica exceto os exemplos que estão na borda

Restrição 2: todos os exemplos podem fazer parte de mais de uma descrição simbólica, exceto a semente.

A complexidade do algoritmos é $O(n^2)$

Aproximações do Grafo de Vizinhos Mútuos

Abordagens De Carvalho et al (2000)



Restrição 1




Figura 5. Objetos simbólicos

Restrição 2

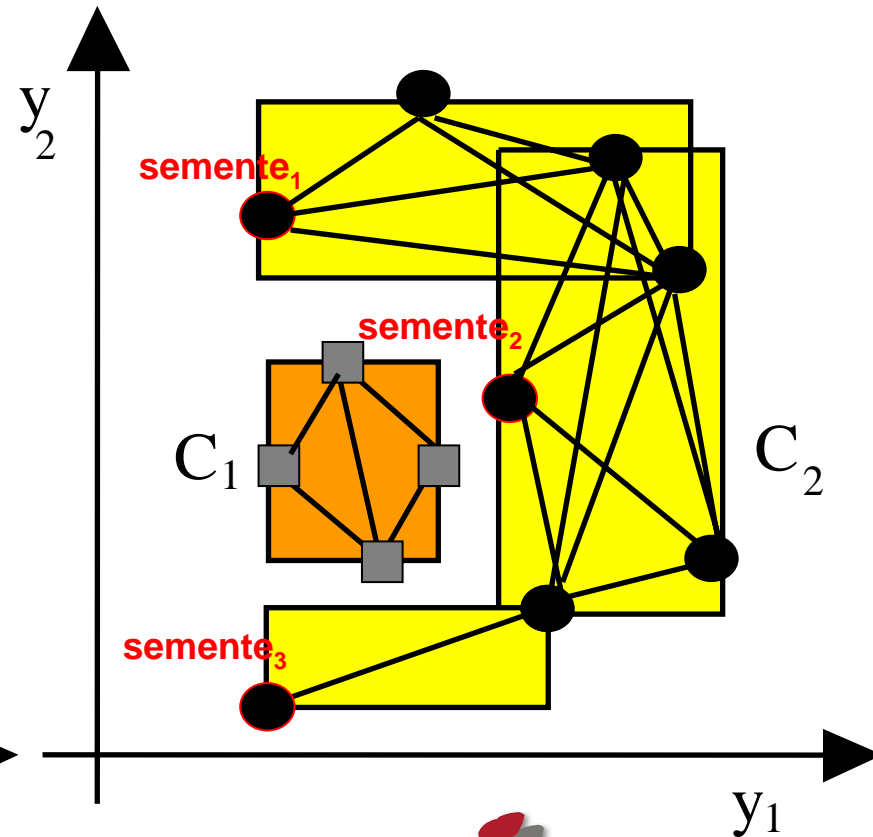


Figura 6. Objetos simbólicos

Aproximações do Grafo de Vizinhos Mútuos

Abordagens De Carvalho et al (2000)



Outros métodos

- **Escolha da semente:**
 - a) O exemplo que tem o maior número de vizinhos mútuos
 - b) O elemento central
- **Atualização da descrição:**

O exemplo que tem o maior número de vizinhos mútuos ou mais similar com **a semente** ou com o **último exemplo selecionado**
- **Generalização:** intervalo de confiança

A complexidade dos algoritmos é $O(n^2)$

Generalização

Descrições Boelanas



Grupo	Sub-Grupo	níveis de cinza	
		média (y_1)	desvio padrão (y_2)
Região 1	G_{11}	[37.35,57.70]	[0,20,5.62]
Região 2	G_{21}	[132.56,160.79]	[0.73,6.84]
	G_{22}	[167.12,196.67]	[1.30,10.66]
•	•	•	•
•	•	•	•

Etapa de Alocação



Etapa de alocação: baseada em funções de similaridade e dissimilaridade.

1 - Distância (De Carvalho et al (1998))

$$d_r(s, s') = \frac{1}{p} \left[\sum_{i=1}^p \{ \Phi_{k\gamma}(s_i, s'_i) \}^r \right]^{1/r}$$

$0 \leq \gamma \leq 0.5$, $k \in \{1, 2, \dots\}$ e $r \in \{1, 2, \dots\}$.

$$\Phi_{k\gamma}(s_i, s'_i) = \left\{ \frac{1}{2} \left[\left(\frac{\phi_{1\gamma}(s_i, s'_i)}{\mu(d_i \oplus d'_i)} \right)^k + \left(\frac{\phi_{2\gamma}(s_i, s'_i)}{\mu(d_i \oplus d'_i)} \right)^k \right] \right\}^{\frac{1}{k}}$$

versão normalizada

Etapa de Alocação



Exemplo - Distância (De Carvalho et al (1998)), $r=1$, $k=1$ e $\gamma = 0.5$

Exemplo: $\text{seg}_1 = [39.92 ; 45.35]$
 $\text{seg}_5 = [35.36 ; 40.05]$

$$\phi_1 (A_1, B_1) = (39.92 - 35.36) / 9.99 = 0.46$$

$$\phi_2 (A_1, B_1) = (45.35 - 40.05) / 9.99 = 0.5.3$$

$$d(\text{seg}_1, \text{seg}_5) = 0.49$$

Etapa de Alocação



2 - Função para medir diferenças (Palumbo et al (1996))

$$q_{ss'} = \frac{\pi(s \oplus s') - \pi(s)}{\pi(s)}, \pi(s) \neq 0$$

$$u_{ss'} = \sum_{i=1}^p \frac{\mu(d_i \oplus d'_i) - \mu(d_i)}{\mu(d_i)}, \mu(d_i) \neq 0 \forall i = 1, \dots, p$$
 versão modificada

“Quanto maior o potencial de descrição de um objeto, maior é a sua capacidade de conter a descrição de um outro objeto”

Etapa de Alocação



3 - Função de similaridade (Ichino et al (1996))

$$f_{ss'} = \frac{1}{p} \sum_{i=1}^p \frac{\mu(d'_i)}{\mu(d_i \oplus d'_i)}, \mu(d_i \oplus d'_i) \neq 0 \forall i = 1, \dots, p$$

$$t_{ss'} = \frac{\pi(s')}{\pi(s \oplus s')}, \pi(s \oplus s') \neq 0$$

versão modificada



Classificador Modal para Dados de Tipo Intervalo (De Cavalho et al. (2001))

Entrada



Exemplo: Conjunto de segmentos descritos por intervalos de níveis de cinza

segmento	níveis de cinza (y_1)	classe
seg ₁	[10,30]	1
seg ₂	[25,35]	1
seg ₃	[40,60]	1
seg ₄	[90,130]	2
seg ₅	[125,140]	2
seg ₆	[150,155]	2

Pré-processamento dos dados



Passo 1: Obter um conjunto com todos os limites inferiores e superiores pertencentes aos dados do conjunto de treinamento

Nesse exemplo o conjunto de limites é

$$L = \{10, 25, 30, 35, 40, 60, 90, 125, 130, 140, 150, 155\}$$

Passo 2: Transformar as dados de tipo intervalo em dados modais da seguinte forma:

Uma descrição modal para seg_1 : $[10,25] p_1$; $[25,30] p_2$ onde

$$p_1 = \frac{25 - 10}{30 - 10} = 0.75$$

$$p_2 = \frac{30 - 25}{30 - 10} = 0.25$$

Entrada para a etapa de aprendizagem:

Descrições modais



segmento	níveis de cinza (y_1)	classe
seg ₁	[10,25] 0.75 ; [25,30] 0.25	1
seg ₂	[25,30] 0.50 ; [30,35] 0.50	1
seg ₃	[40,60] 1.00	1
seg ₄	[90,125] 0.87 ; [125,130] 0.13	2
seg ₅	[125,130] 0.33 ; [130,140] 0.67	2
seg ₆	[150,155] 1.00	2


Etapa de Aprendizagem

Abordagem De Carvalho et al (2001)





Idéia: Obter uma descrição modal para cada classe de exemplos

Exemplos da Classe 1



Exemplos da Classe 2



Junção de intervalos

Etapa de Aprendizagem



Abordagem De Carvalho et al (2001)





Descrição modal para classe 1




Descrição modal do exemplo seg_1



Descrição modal do exemplo seg_2



Descrição modal do exemplo seg_3



Descrição modal para classe 1

Generalização

Descrições modais



classe	níveis de cinza (y_1)
1	[10,25] 0.25 ; [25,30] 0.25 [30,35] 0.17 ; [35,40] 0.0 ; [40,60] 0.33
2	[90,125] 0.29 ; [125,130] 0.16; [130,140] 0.22 ; [140,150] 0.0 ; [150,155] 0.33

Etapa de Alocação



A alocação é baseada em um índice de dissimilaridade entre a descrição de uma classe e a descrição de um exemplo do conjunto de teste.

Esse índice é uma função híbrida que mede a proximidade entre duas descrições modais (histogramas) observando as diferenças em:

a) Conteúdo – componente dependente do contexto

b) Separação – componente independente do contexto

Etapa de Alocação



Pré-processamento:

Durante esta etapa as descrições dos novos exemplos são transformadas em descrições modais.

Esse procedimento será mostrado nos exemplos que serão descritos em seguida.

Sejam $d_i = (I_{i1} p_{i1}, \dots, I_{im} p_{im})$ a descrição modal de um exemplo e $d_j = (I_{j1} p_{j1}, \dots, I_{jn} p_{jn})$ a descrição modal de uma classe onde

$$I_{d_i} = \bigcup_k I_{ik} \quad e \quad I_{d_j} = \bigcup_s I_{js}$$

Etapa de Alocação



Diferenças em conteúdo

$$\phi_{cont}(d_i, d_j) = 0.5 \times \left(\sum_{k=1}^m p_{ik} \frac{|I_{ik} \cap (\bar{I}_{d_j} \cap I_{d_i})|}{|I_{ik}|} \delta(k) + \sum_{s=1}^n p_{js} \frac{|I_{js} \cap (\bar{I}_{d_i} \cap I_{d_j})|}{|I_{js}|} \delta(s) \right)$$

onde

$$\delta(k) = \begin{cases} 1, & \text{se } I_{ik} \subseteq (I_{d_i} \cap \bar{I}_{d_j}) \\ 0, & \text{caso contrário} \end{cases}$$

$$\delta(s) = \begin{cases} 1, & \text{se } I_{js} \subseteq (\bar{I}_{d_i} \cap I_{d_j}) \\ 0, & \text{caso contrário} \end{cases}$$

Etapa de Alocação



Diferenças em separação

$$\phi_{posi}(d_i, d_j) = \frac{|\bar{I}_{d_i} \cap \bar{I}_{d_j} \cap (I_{d_i} \oplus I_{d_j})|}{|I_{d_i} \oplus I_{d_j}|}$$

A função de dissimilaridade entre d_i e d_j é

$$\Phi(d_i, d_j) = \phi_{cont}(d_i, d_j) + \phi_{posi}(d_i, d_j)$$

Etapa de Alocação



Observações:

- 1 – Quando existe interseção entre o suporte da descrição da classe e o suporte da descrição do exemplo, o valor das diferenças em conteúdo varia no intervalo $[0,1]$ enquanto que o valor das diferenças em posição é uma constante nula.
- 2 – Quando não existe interseção entre os dois suportes o valor das diferenças em conteúdo é uma constante igual a 1 enquanto que o valor das diferenças em posição varia entre $[0,1]$.

Etapa de Alocação




Exemplo 1 :


Descrição modal da classe 1:

$d_1 = [10,25] 0.25 ; [25,30] 0.25 [30,35] 0.17 ; [35,40] 0.0 ; [35,40] 0.33$

Descrição de tipo intervalo de um novo exemplo : $d_2 = [30,70]$



Descrição da classe 1




Descrição modal do exemplo

onde $w_1 = \frac{60-30}{70-30} = 0.75$ $w_2 = \frac{70-60}{70-30} = 0.25$


Etapa de Alocação



Exemplo 1 :



Descrição da classe 1



Descrição modal do exemplo

a) Diferenças em conteúdo $\gamma = 0.5$

b) Diferenças em posição

$$\phi_{\text{cont}}(d_1, d_2) = 0.5(0.25 + 0.25 + 0.25) = 0.375$$

$$\phi_{\text{posi}}(d_1, d_2) = 0$$

Então

$$\Phi(d_1, d_2) = 0.375$$

Etapa de Alocação




Exemplo 2 :

Descrição modal da classe 1:



$d_1 = [10,25] 0.25 ; [25,30] 0.25 [30,35] 0.17 ; [35,40] 0.00 ; [35,40] 0.33$

Descrição do novo exemplo

$d_2 = [90,125]$



d_1



d_2

a) Diferenças em conteúdo

$$\phi_{\text{cont}}(d_1, d_2) = 1$$

b) Diferenças em posição

$$\phi_{\text{posi}}(d_1, d_2) = \frac{90 - 60}{125 - 10} = 0.26$$

Então $\Phi(d_1, d_2) = 1.26$




Aplicação

Classificação de Imagens SAR

Imagens SAR



SAR- Radar de Abertura Sintética



- ❖ Possui iluminação própria
- ❖ Produz imagens com alta capacidade de discriminar objetos
- ❖ Emprega o uso de radiação coerente, gerando imagens com ruído *speckle*

Imagens SAR



Os dados SAR possuem comportamento estocástico que tem sido comumente explicado por um modelo multiplicativo (Frey et al (1997)).

Esse modelo considera que o valor em cada coordenada de uma imagem é o resultado do produto de duas variáveis aleatórias

$$Z = X \cdot Y$$

onde Z modela o sinal de retorno

X modela o terreno

Y modela o ruído *speckle*

Classificador de Máxima Verossimilhança



A classificação estatística de imagens é usualmente baseada na máxima verossimilhança. Nesse caso as regras de decisão são geradas através das propriedades distribucionais das imagens analisadas.

Cada regra de decisão é definida da seguinte forma: “Associa-se um pixel à classe onde verossimilhança calculada sobre o valor do nível de cinza observado é máxima”.

Exemplo do Classificador de Máxima Verossimilhança



Imagens SAR simuladas de tamanho 256×256 pixels com formato amplitude de 3 *looks*




Figura 7a. Imagem situação 1




Figura 7b. Imagem situação 2

Exemplo do Classificador de Máxima Verossimilhança



Densidades das imagens SAR

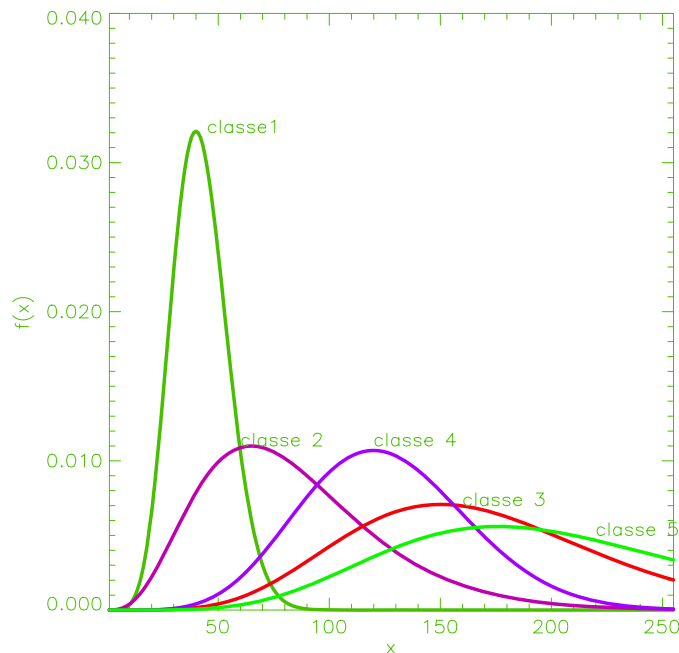


Figura 8a. Densidades da imagem situação 1




Figura 8b. Densidades da imagem situação 2

Exemplo do Classificador de Máxima Verossimilhança



Regras de decisão

Seja z um valor do nível de cinza gerado por uma certa distribuição e $C(z)$ a classe de z . Então

Imagem situação 1

$$C(z) = \begin{cases} \text{classe 1, se } z \in (0;58.81] \\ \text{classe 2, se } z \in (58.81;95.48] \\ \text{classe 3, se } z \in (159.43;195] \\ \text{classe 4, se } z \in (95.48;159,43] \\ \text{classe 5, se } z \in (195,255] \end{cases}$$

Exemplo do Classificador de Máxima Verossimilhança



Regras de decisão

Imagem situação 2

$$C(z) = \begin{cases} \text{classe 1, se } z \in (107.73;149.93] \\ \text{classe 3, se } z \in (0;107.73] \\ \text{classe 4, se } z \in (149.93;209] \\ \text{classe 5, se } z \in (209;255] \end{cases}$$

Exemplo do Classificador de Máxima Verossimilhança



Resultados

Probabilidade de classificação incorreta

Imagens SAR	Valor médio
situação 1	0.543
situação 2	0.676

Classificação de Imagens SAR baseado em descrições simbólicas



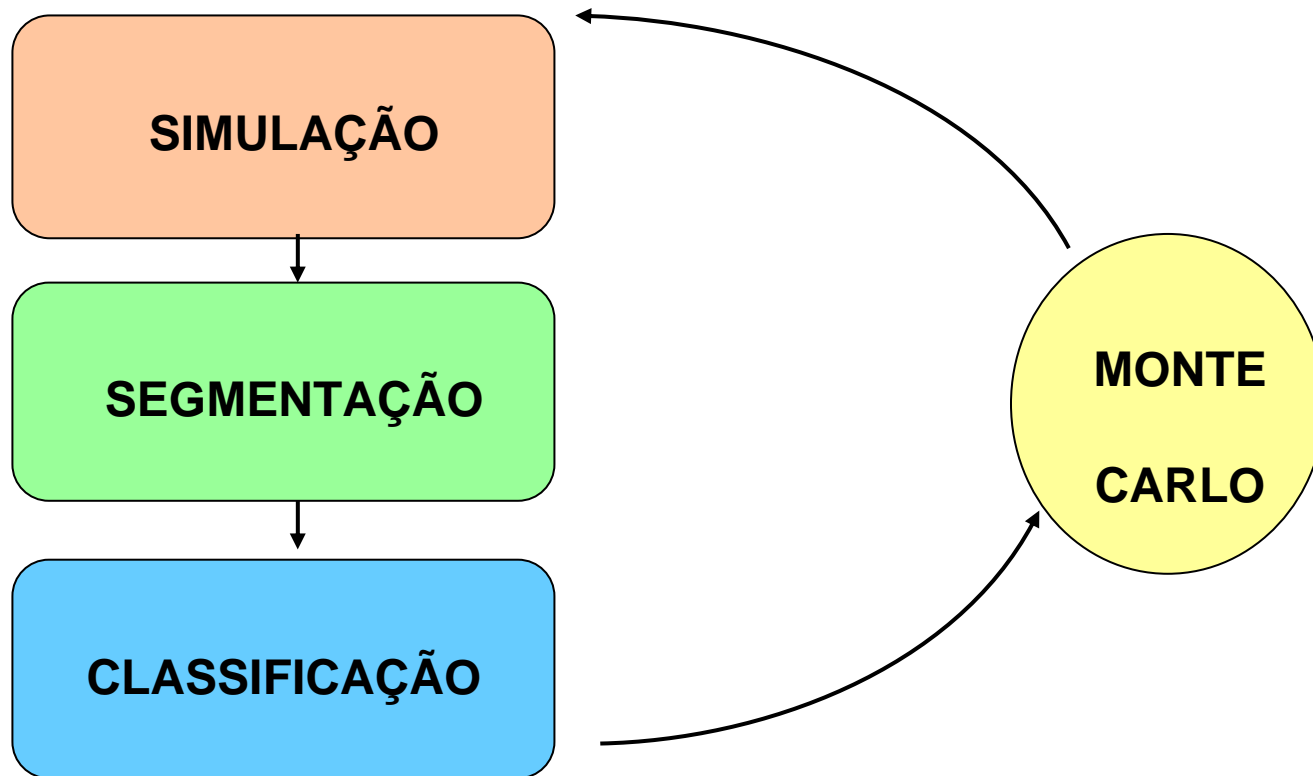
O objetivo desta aplicação é avaliar o desempenho dos classificadores Simbólicos (abordagem regiões e modal) em imagens SAR.

Para essa aplicação foi implementado um sistema (Linguagens C e IDL – *Interactive Data Language*) que será descrito a seguir.

Classificador Simbólico



Estrutura do Sistema



Classificador Simbólico

EXPERIMENTOS MONTE CARLO



O desempenho do classificador foi medido através da taxa de erro estimada pelo Método Monte Carlo.

Para cada experimento foram executadas 100 replicações de imagens com idênticas propriedades estatísticas de tamanho:

- a) 256×256 pixels, para o modelo booleano
- b) 512×512 pixels, para o modelo modal

Duas situações de imagens foram consideradas: uma moderada (situação 1) e outra (situação 2) difícil de classificação.


A estimativa da taxa de erro correspondeu a uma média das taxas de erro encontradas nessas replicações.

Classificador Simbólico




SIMULAÇÃO

Etapa 1: Criação de um *phantom* (imagem idealizada de classes)



Classes



teste



treinamento

Figura 10. *Phantom* com cinco classes

Classificador Simbólico



SIMULAÇÃO

Gerar e filtrar as imagens utilizando um algoritmo de geração de variáveis gama e o filtro Lee, respectivamente




Figura 10a. Imagem filtrada
situação 1




Figura 10b. Imagem filtrada
situação 2

Classificador Simbólico



SEGMENTAÇÃO

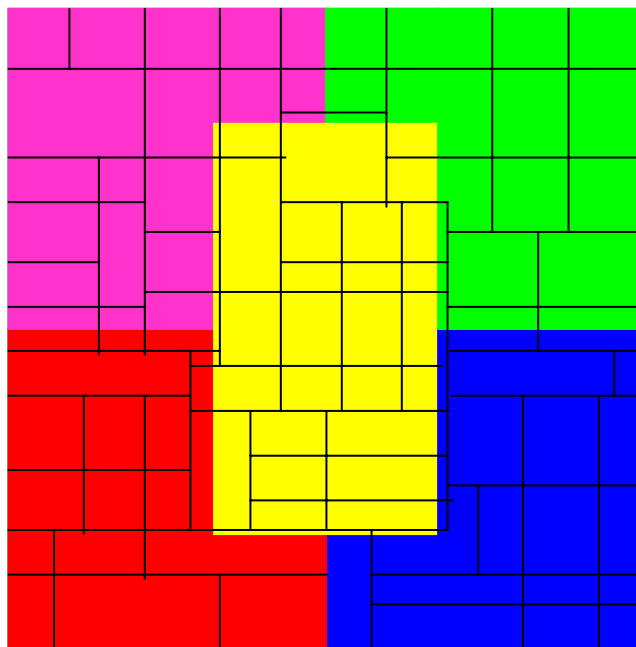


Figura 11. *Phantom* segmentado

Abordagem “Crescimento de Regiões” (*Region Growing*) utilizando o teste *t-student* para diferenças de médias com 95% de confiança.

Classificador Simbólico

CLASSIFICAÇÃO



Etapa de Aprendizagem: Obtenção das descrições simbólicas associadas as classes do conjunto de treinamento




Figura 12. As Descrições simbólicas para uma imagem SAR 64×64 situação 1

Classificador Simbólico

CLASSIFICAÇÃO



Etapa de Alocação: Associar cada exemplo do conjunto de teste a uma das classes

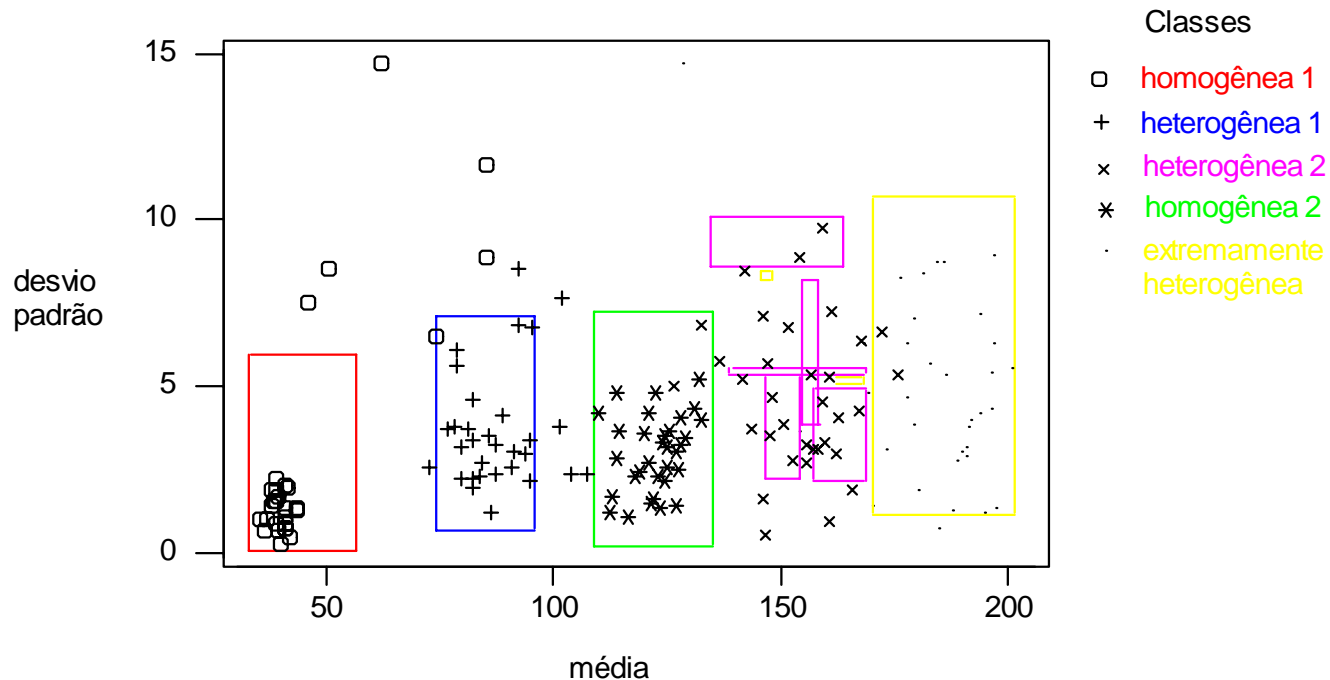


Figura 13. As descrições simbólicas para uma imagem SAR 64×64 situação 1 e o conjunto de teste

Classificador Simbólico

RECONSTRUÇÃO



Imagens SAR de tamanho 64×64 pixels




Figura 14a. Reconstrução da Imagem situação 1




Figura 14b. Reconstrução da Imagem situação 2

Classificador Simbólico

RESULTADOS DOS EXPERIMENTOS MONTE CARLO



Imagens SAR	Estimativa da taxa média de erro (%)	Intervalo de confiança (%)	
		Limite inferior	Limite superior
situação 1	3.06	1.70	4.42
situação 2	22.94	20.71	25.17

Observações: O intervalo de confiança foi construído utilizando a estatística com distribuição *t-student* ao nível de significância de 5%.

Classificador Simbólico Modal



RESULTADOS DOS EXPERIMENTOS MONTE CARLO

Imagens SAR	Estimativa da taxa média de erro (%)	Intervalo de confiança (%)	
		Limite inferior	Limite superior
situação 1	2.09	1.69	4.18
situação 2	17.29	17.08	17.50

Observações: O intervalo de confiança foi construído utilizando a estatística com distribuição *t-student* ao nível de significância de 5%.

Considerações Finais



- ❁ Baseando-se no desempenho dos classificadores usuais empregados em tratamento de imagens, verifica-se que os classificadores simbólicos (modal e boleano) obtiveram um bom desempenho na imagem situação 1 e um aceitável desempenho na situação 2
- ❁ Não é possível fazer um comparativo entre as abordagens simbólica e verossimilhança, pois a classificação simbólica é precedida de uma segmentação, e por esse motivo têm-se conjuntos de semânticas diferentes.
- ❁ O modelo modal têm um aspecto bastante favorável em relação ao modelo regiões; a eliminação do grafo de vizinhos mútuos na etapa de aprendizagem. Com isto obteve-se um algoritmo viável para classificar imagens de tamanho 512×512.
- ❁ Os classificadores simbólicos apresentam três características relevantes:
 - a) podem ser aplicados para dados usuais ou simbólicos;
 - b) são métodos do tipo não linear;
 - c) são métodos não paramétricos

Bibliografia



Ichino, M., Yaguchi, H. and Diday E. “A fuzzy symbolic pattern classifier”. Ordinal and Symbolic Data analysis, 92-102 (1996).

Souza, R. M. C. R., De Carvalho F. A. T and Frery, A. C., “Symbolic approach to SAR image classification” in International Geoscience and Remote Sensing Symposium – IGARSS’99, (1999).

De Carvalho F. A. T., Anselmo, C. A. F and Souza, R. M. C. R., “Symbolic approach to classify large data sets” in Data Analysis Classification and Related methods. Proceedings of the 7th International Conference Societies (IFCS-2000), 375-380 (2000).

De Carvalho F. A. T and Souza, R. M. C. R., “Statistical proximity functions of boolean symbolic objects based on histograms”, in New Advances in Data Science and Classification. Rizzi, ^a et al, Eds. Heidelberg: Springer – Verlag, 391-396 (1998).

De Carvalho, F. A. T., Cananéa, I. C. and Verde, Rosana, “Symbolic classifier based on modal description” in CLADAG’2001 (aceito para publicação).

Frery, A. C., Mueller H. J. and Yanasse, C. C. F. “A model for extremely heterogeneous clutter” in IEEE Transactions on Geoscience and Remote Sensing, vol 14 648-659, (1997).