

CLASSIFICADOR BASEADO EM DADOS SIMBÓLICOS DE SEMÂNTICA BOOLEANA APLICADO A IMAGENS SAR

FRANCISCO DE ASSIS TENÓRIO DE CARVALHO¹
SIMITH TUPINAMBÁ D'OLIVEIRA JÚNIOR¹

¹Centro de Informatica - CIn / UFPE
Av. Prof. Luiz Freire, s/n Cidade Universitária,
CEP: 50740-540 Recife - PE, Brasil
{fatc, stdj}@cin.ufpe.br

Abstract. This work aims at implementing a classifier based on the symbolic approach, and at applying the proposed method for SAR (Synthetic Aperture Radar) image recognition. The study yielded a system that can simulate, segment and classify SAR data. The SAR data have statistical properties which fit a multiplicative model for describing its probabilistic behavior. From this model, data are simulated and later on segmented by using a growing region approach, generating input data for the classifier. In the classification process, the learning step is achieved by constructing the symbolic objects, which provide complete and discriminating description of classes of examples through the combination of mutual neighbors concept with symbolic operators. The allocation step associates a segment to one of the classes through a proximity function among symbolic data. The outcome analysis is based on Monte Carlo experiments performed on the implemented system steps.

Keywords: SAR image, remote sensing, symbolic data analysis .

1. Processo de Simulação das Imagens SAR

1.1 Introdução

A maioria dos radares empregados em sensoriamento remoto são os de visada lateral (emissão dos pulsos em sentido lateral à linha de vôo da plataforma de transporte). No sistema RAR (*Real Aperture Radar*), os radares trabalham com o tamanho real da antena receptora. Já No sistema SAR (*Synthetic Aperture Radar*), O tamanho da antena é gerado sinteticamente.

É importante ressaltar que as imagens produzidas pelo sistema SAR possuem um ruído, denominado de *speckle*, que está associado ao uso da radiação coerente produzida pelo mecanismo de formação da imagem e, portanto também levamos em conta este detalhe no nosso trabalho.

No processo de simulação, as imagens foram obtidas através da criação de um *phantom* (imagem idealizada de classes, onde a cada uma delas associa-se um certo grau de homogeneidade da região). Cada um desses graus de homogeneidade é depois associado a um modelo estatístico para as observações provindas de cada classe, através de uma distribuição particular. Os diferentes graus de homogeneidade comumente observados nas imagens SAR são caracterizados por diferentes distribuições associadas ao modelo de formação das mesmas - Frery (1997).

O comportamento estatístico dos dados obtidos com radiação coerente, como é o caso dos dados SAR, tem sido comumente explicado por um modelo multiplicativo. Esse modelo considera que o valor em cada coordenada da imagem é a ocorrência de uma variável aleatória $Z = XY$, onde X representa a variável aleatória que modela o coeficiente da energia retrospalhada associado ao pulso incidente no terreno (*backscatter*) e Y representa a variável aleatória que modela o ruído associado à mecânica de formação da imagem que emprega radiação coerente; ainda é considerado que há independência entre as variáveis aleatórias X e Y .

As possíveis distribuições para o retorno estão associadas aos diferentes graus de homogeneidade envolvendo diferentes tipos de regiões, tais como: as homogêneas (área de cultura agrícola, pastagens, solo exposto, etc.), as heterogêneas (floresta) e as extremamente heterogêneas (áreas urbanas). O grau de homogeneidade de cada uma dessas regiões é função da configuração (frequência do sinal utilizado, resolução, etc.) do sistema empregado para a aquisição de imagem e das propriedades da área observada. A **Tabela 1** apresenta as distribuições usadas nesse trabalho - Vieira (1996).

Região	<i>Backscatter</i>	<i>Speckle</i>	Retorno
	XA	YA	ZA
Homogêneas	$C(\beta)^{1/2}$	$\Gamma^{1/2}(n,n)$	$\Gamma^{1/2}(n, n\beta^{-1})$
Heterogêneas	$\Gamma^{1/2}(\alpha, \lambda)$	$\Gamma^{1/2}(n,n)$	$KA(\alpha, \lambda, n)$
Extremamente Heterogêneas	$\Gamma^{1/2}(\alpha, \gamma)$	$\Gamma^{1/2}(n,n)$	$G_A^0(\alpha, \gamma, n)$

Tabela 1: Distribuições do modelo multiplicativo para os diferentes graus de homogeneidade

1.2. Phantom

Nessa aplicação, o *phantom* apresenta cinco classes de regiões: duas homogêneas, duas heterogêneas e uma extremamente heterogênea. Utilizando-se esta estrutura de regiões, criaram-se três modelos de *phantom*, com 64x64, 128x128 e 256x256 pixels cada um deles. A **Figura 1** ilustra a estrutura do *phantom*, onde as cores amarela e verde são as regiões homogênea 1 e homogênea 2, respectivamente; as cores azul e vermelha são as regiões

heterogênea 1 e heterogênea 2, respectivamente e a cor branca é a região extremamente heterogênea.

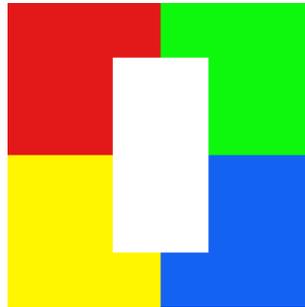


Figura 1: *Phantom* representando cinco regiões

1.3 Distribuições das regiões

Para a geração dos dados, Escolheu se uma situação em que as áreas de classificação por máxima verossimilhança estivessem bem definidas no gráfico das densidades das classes - Sousa (1999):

Região	Distribuição	μ	α	β	λ	γ
Homogênea 1	$\Gamma^{1/2}$	42	-	1.916,58	-	-
Homogênea 2	$\Gamma^{1/2}$	126	-	17.249,20	-	-
Heterogênea 1	KA	84	2	-	0,00023	-
Heterogênea 2	KA	168	8	-	0,00025	-
+ Heterogênea	G_A^0	210	-5	-	-	203.987

Tabela 2: Propriedades Distribucionais da Imagem

1.4 Redução do ruído Speckle

O *speckle* caracteriza o ruído que aparece quando uma imagem é formada através da iluminação por radiação coerente. Esse ruído causa uma aparência granular na imagem que dificulta a análise visual da região de interesse, além de tender a prejudicar o desempenho dos processos de segmentação e classificação.

Para redução do ruído foi utilizado o filtro Lee, que consiste em transformar os valores dos níveis de cinza de uma imagem digital, com o propósito de reduzir o seu aspecto ruidoso, assim como preservar as bordas e outras pequenas feições existente na mesma. Nessa técnica o novo valor do nível de cinza depende do valor antigo e também dos valores vizinhos, sendo que tipicamente os pontos mais próximos contribuem mais para o novo nível do que pontos mais afastados. Foi utilizado o desvio padrão igual a 5 e tamanho da janela 3 - Sousa (1999). Nas **Figuras 2 e 3** podemos observar a diferença entre as imagens simulada do Phanton não filtrada e filtrada.

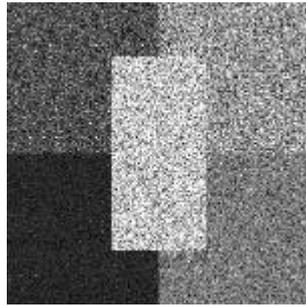


Figura 2: Imagem SAR não Filtrada

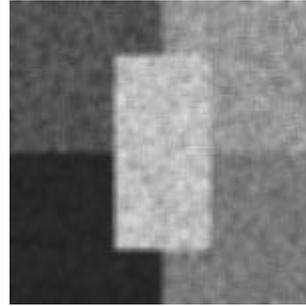


Figura 3: Imagem SAR filtrada pelo método Lee

2. Processo de Segmentação das Imagens SAR

As segmentações produzidas, através de crescimento de regiões, consistem em transformar sub-regiões em regiões, através da agregação de pixels. O método implementado inicia-se com duas regiões seminais adjacentes de 4 pixels (sentido horizontal da matriz de pixels). Para agregar os pixels adotou-se o seguinte critério: calcula-se o nível médio de cinza de cada região e verifica-se, através do teste de hipótese *t-student* a um nível de significância de 5%, se as médias são iguais; caso haja evidência, que as médias sejam iguais, agregam-se todos os pixels formando um novo segmento - Sousa (1999).

Concluída a segmentação, procede-se a etapa de alocação dos segmentos a uma das cinco classes definidas no processo de simulação. A alocação poderá ser feita de várias maneiras mas para os dados SAR adotou-se a seguinte regra: dado um segmento, associa-se à classe onde mais de 70% dos seus pixels pertencem - Sousa (1999).

Ao final desse processo, obtém-se uma matriz de dados onde cada linha representa um segmento descrito por duas colunas com os valores da média e do desvio padrão dos níveis de cinza. Uma coluna suplementar indica a pertinência de cada segmento a uma das classes de regiões predefinidas.

Cada um dos valores das variáveis descritoras é expresso por um intervalo cujos limites inferior e superior são iguais, permitindo assim que cada segmento seja representado por um objeto simbólico de volume zero. Por exemplo,

$$\text{seg} = [y_1 \in [44,50;44,50]] \wedge [y_2 \in [7,50;7,50]]$$

onde, y_1 é a média e y_2 é o desvio padrão dos níveis de cinza de um segmento.

Na nossa implementação foi usada uma matriz de dados associado a uma imagem simulada do Phantom para construção do classificador e outra matriz para testá-lo.

3. Processo de Classificação das Imagens SAR

3.1 Etapa de aprendizagem

Essa etapa consiste em obter as descrições completas e discriminantes das classes de exemplos observados. Nas próximas seções vamos apresentar alguns conceitos para que possamos definir como será o algoritmo de aprendizagem usado.

3.1.1 Relação de vizinhos mútuos

Sejam $C = \{C_i\}$ um conjunto de m classes de objetos simbólicos, onde:

$$C_i = \{s_{i1}, s_{i2}, \dots, s_{in_i}\}, \quad s_{ij} = \bigwedge_{k=1}^p s_{ijk} = \bigwedge_{k=1}^p [y_k \in d_{ijk}],$$

$i \in \{1, 2, \dots, m\}$ e $j \in \{1, 2, \dots, n_i\}$.

A relação de vizinhos mútuos R_v é definida da seguinte forma:

Sejam dois objetos simbólicos s_{iq} e s_{ip} pertencentes à classe C_i . Diz-se que $s_{iq} R_v s_{ip}$ se,

$$\forall s_{jl} \in \overline{C_i} = \bigcup_{\substack{j=1 \\ j \neq i}}^m C_j,$$

$\exists k \in \{1, 2, \dots, p\}$ Tal que

$$d_{jlk} \cap (d_{iqk} \oplus d_{ipk}) = 0$$

3.1.2 Grafo de vizinhos mútuos

Um grafo de vizinhos mútuos de C_i em relação à $\overline{C_i}$, denominado $MNG(C_i/\overline{C_i})$, é um grafo cujos vértices são os objetos da classe C_i e cujas arestas são formadas pelos pares distintos de objetos de C_i que satisfazem à relação de vizinhos mútuos, isto é, $MNG(C_i/\overline{C_i}) = (V, A)$, onde $V = C_i$ e $A = \{(s_{ip}, s_{iq}) \in C_i \times C_i / s_{ip} \neq s_{iq} \text{ e } s_{ip} R_v s_{iq}\}$.

O $MNG(C_i/\overline{C_i})$ é um grafo simples não orientado.

3.1.3 Casca convexa 2D

A casca convexa de um conjunto de ponto em um plano é definida como o menor polígono convexo contendo todos eles. O menor polígono refere-se a tanto a área como conseqüentemente também o tamanho do perímetro. É importante observar um polígono convexo tem a propriedade que qualquer reta que passa por ele corta-o em no máximo dois pontos. Vários algoritmos foram desenvolvidos para achar a casca convexa mas optamos pelo embrulho de pacote (Package Wrapping) pois é simples e fácil de implementar.

Este algoritmo não garante retornar todos os pontos na casca mas como estamos interessados na área, não é importante este detalhe. A maior desvantagem é que tem ordem N^2 (para N o número de pontos) no pior caso mas pode ser generalizado para mais de duas dimensões.

3.1.4 Área de um polígono geral

O cálculo da área de um polígono geral é baseado no teorema de Green no plano. Dado os pontos (x_i, y_i) , $i = 0, \dots, n$, com $x_0 = x_n$ e $y_0 = y_n$, a seguinte fórmula pode ser usada para calculo rápido da área de um polígono no plano:

$$A = \frac{1}{2} \sum_{i=0}^{n-1} a_i$$

onde $a_i = x_i y_{i+1} - x_{i+1} y_i$.

O valor da área é positivo se os vértices estiverem em ordem horária, caso contrário, será negativo.

4.1.5 Algoritmo de aprendizagem

A primeira etapa do algoritmo de aprendizagem é encontrar todas as cliques (um subgrafo em que para todos os pares possíveis de vértices existe uma aresta) que compõem a classe. Se o grafo de uma classe for completo, esta será descrita por um objeto simbólico obtido pela disjunção de todos os seus elementos de um único clique, caso contrário, por uma disjunção de objetos simbólicos, cada objeto sendo obtido pela disjunção dos objetos da classe que formam uma clique.

Nas situações em que o grafo de vizinhos mútuos de uma classe não é completo, uma etapa fundamental para obter a descrição da mesma é encontrar todas as cliques. É sabido que esse tipo de problema faz parte de uma classe chamada de NP-completo. Isto significa que, nas situações reais, quando estão presentes um grande número de observações, encontrar todas as cliques torna-se impraticável.

Uma solução é obter um subconjunto de cliques, onde é proibido que um objeto possa fazer parte de mais de uma clique. Desta forma, a construção da clique consiste de duas etapas: na primeira, escolhe-se um objeto de uma determinada classe que será a semente da clique e na segunda, selecionam-se os demais objetos dessa classe, um de cada vez e verifica-se se o mesmo é vizinho mútuo dos objetos que fazem parte da clique que está sendo formada. Para isso, usa-se o fato de que se um objeto é vizinho mútuo da junção de um conjunto de objetos, então ele é vizinho mútuo de cada um deles. Construída a clique exclui-se os seus objetos do conjunto dos objetos da classe que está sendo descrita e repete-se o processo até que todos os objetos dessa classe tenham sido adicionados a uma clique.

No tratamento com os dados SAR, implementou-se um algoritmo em que a semente correspondeu ao objeto de menor índice e os objetos, que podem fazer parte da clique, foram escolhidos baseando-se na ordem lexicográfica (descrições dos segmentos). Na **figura 4** vemos um exemplo do algoritmo acima referido: a primeira semente da classe 2 é o objeto de índice 1, formando uma clique com objetos de índice 2, 3, 4. Como o objeto 5 não forma clique com o 1 então torna-se a próxima semente que forma clique com 6 e 7 mas não com o 8, que fica isolado. A classe 1 é completa e forma só uma clique.

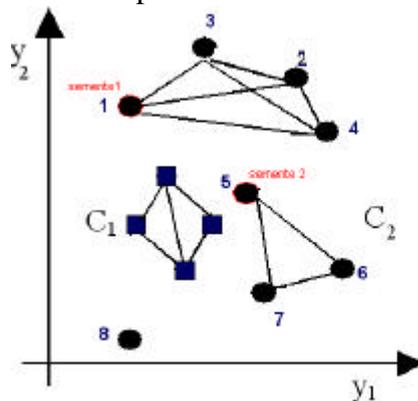


Figura 4: formação das cliques

3.2 Etapa de alocação

É importante observar que no exemplo acima, a classe C2 é composta da disjunção de três objetos simbólicos sendo um com volume zero (com índice 8). Este fato é importante, pois na função de proximidade utilizada não vamos considerar objetos de volume zero, portanto a classe C2 passa a ser composta apenas da disjunção de dois objetos simbólicos para efeito de alocação.

3.2.1 Função de proximidade: Abordagem De Carvalho

Uma variação da abordagem De Carvalho (1994) combina a diferença de conteúdo e a diferença de posição de dois objetos simbólicos para formar a função de dissimilaridade baseado no volume dos acordos e desacordos entre estes dois objetos simbólicos.

Dado:

$$a = [Y_1 R_1 A_1] \wedge \dots \wedge [Y_j R_j A_j] \wedge \dots \wedge [Y_p R_p A_p]$$

$$b = [Y_1 R_1 B_1] \wedge \dots \wedge [Y_j R_j B_j] \wedge \dots \wedge [Y_p R_p B_p]$$

Os índices de acordo e desacordo estão sumarizados na **Tabela 3**:

	Acordo	Desacordo
Acordo	$\alpha = \pi(a \wedge b)$	$\beta = \pi(a) - \pi(a \wedge b)$
Desacordo	$\gamma = \pi(b) - \pi(a \wedge b)$	$\delta = \pi(a \oplus b) - \pi(a) - \pi(b) + \pi(a \wedge b)$

Tabela 3: índices de acordo e desacordo

Onde $\pi(\)$ é o volume do objeto simbólico resultante.

Diferença de posição:

$$\phi_p(a,b) = ((\pi(a \oplus b) - \pi(a) - \pi(b) + \pi(a \wedge b)) / \pi(a \oplus b))$$

Diferença de conteúdo:

Existem várias funções de comparação, mas foi escolhida a seguinte:

$$\phi_c(a,b) = 1 - (\pi(a \wedge b) / (\pi(a) + \pi(b) - \pi(a \wedge b)))$$

Função de Dissimilaridade:

$$\phi(a,b) = \frac{1}{2}[\phi_c(a,b) + \phi_p(a,b)]$$

A idéia da alocação de um novo dado SAR para uma determinada classe é comparar este novo dado com todas as cliques de todas as classes, e alocá-la a classe que pertence a clique que estiver mais próxima do novo dado.

É importante observar que sempre estamos comparando um objeto de volume não nulo com um objeto de volume nulo (no caso do novo dado SAR a ser alocado), portanto a diferença de posição torna-se 1 dado que o volume do resultado da interseção de destes dois objetos será zero. Obtemos então:

$$\phi(a,b) = \frac{1}{2}[1 + \phi_p(a,b)] = \frac{1}{2} + \frac{1}{2} \phi_p(a,b)$$

Como a soma e multiplicação com constantes não vão influenciar no resultado da alocação do novo dado podemos ignorá-los, resultando em:

$$\phi(a,b) = \phi_p(a,b)$$

Na Implementação da função de dissimilaridade usamos o algoritmo da casca convexa 2D (os dados SAR usam duas variáveis apenas) da seção 3.1.3 e da área de um polígono geral de seção 3.1.4 para calcular $\pi(\)$. Abaixo um exemplo da casca convexa (linha preta) em contraste com o resultado da operação de junção (linha vermelha) dos objetos do clique. Os pontos azuis representam os objetos na casca convexa enquanto os vermelhos representam os objetos no interior da mesma:

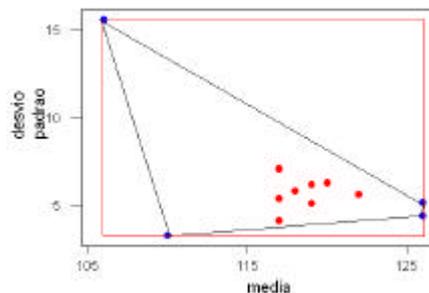


Figura 5: casca convexa de um clique

Podemos observar que a junção generaliza muito em relação à casca convexa e com isso perde a precisão na alocação.

4. Análise dos Resultados

Nessa seção serão expostos os resultados da classificação usando a abordagem simbólica. A avaliação do desempenho do classificador foi baseada na estimativa da taxa de erro obtida pelo Método Monte Carlos com 101 replicações - Sousa (1999). A finalidade da aplicação do método Monte Carlos é proporcionar uma melhor avaliação quantitativa do desempenho do classificador simbólico com imagens SAR.

O valor da estimativa de taxa de erro foi obtido pela média das taxas de erro encontradas nas 101 replicações executadas. Também foram obtidos o intervalo [mínimo global, máximo global] e o desvio padrão das taxas de erro.

Foram utilizados Phantos de tamanho 256x256, 128x128, 64x64 pixels. A **Tabela 4** apresenta o resultado das experiências:

	Média de erro(%)	Limite inferior(%)	Limite superior(%)	Desvio padrão
256x256	2,97	1,48	6,5	1,13
128x128	4,7	0	11,7	2,85
64x64	14,8	0	50	10,50

Tabela 4: Resultado das experiências

Podemos concluir que quanto maior é o Phantom, melhor o resultado obtido e que apesar dos resultados médios dos Phantoms 128x128 e 64x64 terem sido pior, estes tiveram limite inferior 0% de erro o que significa que não ocorreu erro nem uma vez, um resultado bastante surpreendente.

Ainda é preciso fazer um estudo comparativo com outras abordagens para tirar melhores conclusões a respeito dos resultados obtidos, principalmente para o caso da abordagem De Carvalho clássica.

5 Bibliografia

- De Carvalho, F. A T. (1994). *Uma abordagem para calcular a proximidade entre objetos simbólicos booleanos*. In: XI Simpósio Nacional de Probabilidade e Estatística. Belo Horizonte, 24-29 de junho, 303-308.
- Frery, A C. (1997) *Robust interference techniques for speckle noise reduction in 1-look amplitude SAR images*. Applied Signal Processing. 4(2), 61-76.
- Paul Heckbert (editor) 1994, *Graphics Gems IV*, Academic Press.
- Sedge Wick, Robert, 1946 – *Algorithms in C*, Princeton University.
- Sousa, R. M. C. (1999). *Classificação de Imagens SAR Baseada em uma Abordagem Simbólica*. Recife. Tese de Mestrado. Universidade Federal de Pernambuco.
- Vieira, R. (1996). *Desenvolvimento de Classificação de Máxima Verossimilhança e ICM para imagens Sar*. São José dos Campos. Tese de Mestrado. Instituto Nacional de Pesquisas Espaciais.