

Segmentação Binária de Imagens SAR pelo Algoritmo ICM

ALEJANDRO C. FRERY¹
NELSON D. A. MASCARENHAS²

Instituto Nacional de Pesquisas Espaciais
Divisão de Processamento de Imagens
Avenida dos Astronautas, 1758
12227-010 São José dos Campos, SP, Brasil
¹radar@dpi.inpe.br
²nelson@dpi.inpe.br

Abstract. We present a derivation and an implementation of the ICM (Iterated Conditional Modes) algorithm for the binary segmentation of Synthetic Aperture Radar (SAR) images contaminated by a signal-dependent noise called "speckle". The ICM algorithm is based on the modelling of the "a priori" distribution under the Markov Random Fields framework. The obtained results with real SAR images display a significant improvement with respect to the pixel-by-pixel maximum likelihood classification, at a reasonable computational cost, with the incorporation of the spatial context.

1 Introdução

As técnicas de processamento de imagens têm sofrido um crescimento explosivo nos últimos anos. Isto deve-se, entre outros motivos, ao fato de se dispor de um volume cada vez maior de imagens, provenientes de várias fontes. Sabe-se, por exemplo, que, até hoje, uma percentagem superior a 50% das imagens enviadas por satélites ambientais nunca foi vista por olhos humanos... e a grande maioria delas carrega informação preciosa.

Essa informação, quando recuperada dentro de prazos aceitáveis, está presente no cotidiano de todos nós: desde dados relevantes para a previsão do tempo, até estatísticas que influem em decisões políticas de concessão de créditos internacionais para as safras de uma nação.

Portanto, cada vez é mais importante poder processar imagens em forma rápida, e de tal forma que a informação procurada seja recuperada em forma precisa. É dentro deste contexto que as ferramentas estatísticas estão tendo um papel central. Outras ferramentas, como por exemplo as de Inteligência Artificial, também estão contribuindo ao desenvolvimento de técnicas para o processamento e a interpretação automática de imagens.

O imageamento em sensoriamento remoto por radar de abertura sintética (SAR) está tendo uma importância cada vez maior, devido aos vários satélites já lançados ou a serem lançados nesta década, além de missões aerotransportadas. Este tipo de imageamento, além de fornecer informação a respeito das características elétricas e texturais do solo, é pou-

co afetado por nuvens, chuva, etc. Também permite obter imagens à noite, pois o sensor é ativo.

Este trabalho propõe-se a utilizar um algoritmo derivado do modelo por campos aleatórios Markovianos para as classes de uma imagem SAR, para sua segmentação em duas classes. O desafio maior reside na contaminação dessas imagens por um ruído dependente do sinal (denominado "speckle") devido à natureza coerente da radiação emitida pelo radar.

2 Notação e Distribuições Importantes

Toda vez que apareçam variáveis aleatórias, usaremos maiúsculas; as suas ocorrências serão denotadas com minúsculas, isto é: X denota uma variável aleatória, e x denota uma ocorrência de X . Os vetores aleatórios serão escritos em negrito; para o caso anterior, e a sua correspondente ocorrência, teríamos escrito: \mathbf{X} e \mathbf{x} , respectivamente.

A função indicadora do conjunto A será denotada $\mathbb{I}_A(x)$, isto é

$$\mathbb{I}_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{caso contrário.} \end{cases}$$

Seja ξ um número real positivo; diremos que Y é uma variável aleatória Rayleigh com parâmetro ξ (e denotaremos essa variável aleatória como $Y \sim \mathcal{R}(\xi)$) se tem densidade dada por

$$f_{\xi}(y) = \frac{y}{\xi^2} \exp \left\{ -\frac{1}{2} \left(\frac{y}{\xi} \right)^2 \right\} \mathbb{I}_{(0,+\infty)}(y).$$

Se $X \sim \mathcal{R}(\xi)$, então temos que as suas esperança e

variância são dadas por

$$\mathbb{E}(X) = \sqrt{\frac{\pi}{2}} \xi \text{ e } \text{Var}(X) = \left(2 - \frac{\pi}{2}\right) \xi^2, \quad (1)$$

respectivamente.

Denotaremos por S o suporte de uma imagem. Por definição $S \subset \mathbb{Z}^2$ é finito e da forma $S = S_1 \times S_2$, com $S_i = \{a_i, \dots, b_i\} \subset \mathbb{Z}$ para $i = 1, 2$.

O vetor aleatório $\mathbf{X} = [X_s]_{s \in S}$ é chamado *modelo de Ising* [Georgii (1988)] se tem por contradomínio, para cada sítio $s \in S$, os valores $\{-1, +1\}$ e se a sua distribuição conjunta é

$$\text{Pr}(\mathbf{X} = \mathbf{x}) = \frac{1}{Z_\beta} \exp \left\{ \beta \sum_{\|s-t\|=1} x_s x_t \right\} \quad (2)$$

com $Z_\beta = \sum_{\mathbf{x} \in \Xi} \exp \{ \beta \sum_{\|s-t\|=1} x_s x_t \}$, e o conjunto de configurações possíveis $\Xi = \{-1, +1\}^{\#S}$.

3 Propriedades das Imagens SAR

Duas referências completas para estes assuntos são os artigos [Derin et al. (1990), Kelly et al. (1988)] e os trabalhos aí indicados. Uma das hipóteses mais aceitas é que a distribuição marginal de observações obedece à distribuição de Rayleigh, devido à presença do chamado ruído "speckle".

Esta hipótese pode ser verificada, por exemplo, estimando $C(Y)$, o coeficiente de variação em regiões homogêneas, e conferindo que é constante pois, das equações (1), deduz-se que

$$C(Y) = \frac{\sigma(Y)}{\mathbb{E}(Y)} = 2\sqrt{\frac{1}{\pi} - \frac{1}{4}}$$

Assumindo válida esta hipótese, e dado que desconhecemos o valor do parâmetro da Rayleigh, podemos estimá-lo baseados no vetor de observações $\mathbf{y} = (y_1, \dots, y_n)$, usando, por exemplo, algum dos seguintes estimadores:

$$\hat{\xi} = \sqrt{\frac{1}{2n} \sum_{1 \leq i \leq n} y_i^2}, \quad (3)$$

$$\widehat{\xi^{(1)}} = \sqrt{\frac{2}{\pi} \sum_{i=1}^n y_i}, \quad (4)$$

$$\tilde{\xi} = \frac{1}{K} \text{Med}(\mathbf{z}), \quad (5)$$

onde $\mathbf{z} = (z_1, \dots, z_n)$, com $z_i = |y_i - \text{Med}(\mathbf{y})|$ para todo $1 \leq i \leq n$. As equações (3), (4) e (5) são, respectivamente, os estimadores de máxima verossimilhança, dos momentos baseado no primeiro momento amostral e o MAD (*Median Absolute Deviation*). A

constante K pode ser determinada usando métodos numéricos, e o seu valor aproximado é $K \approx 0.4485$; "Med(\mathbf{y})" denota a mediana amostral do vetor \mathbf{y} .

Supondo que a *verdade terrestre* é uma coleção de posições, cada uma com um valor ξ_{-1} ou ξ_{+1} (com $0 < \xi_{-1} < \xi_{+1} < +\infty$) de "backscatter", o sistema imageador retorna, para essa posição, a observação de uma variável Rayleigh com o parâmetro correspondente. É o *modelo multiplicativo* proposto para este tipo de imageamento [Derin et al. (1990), Kelly et al. (1988)].

Este modelo de degradação é um caso particular do proposto em [Geman-Geman (1988)], e modelaremos a imagem observada \mathbf{Y} segundo a seguinte distribuição conjunta:

$$f_{\mathbf{Y}|\mathbf{X}=\mathbf{x}}(\mathbf{y}) = \prod_{s \in S} f_{Y_s|x_s}(y_s) = \prod_{s \in S} \frac{y_s}{\xi_{x_s}} \exp \left\{ -\frac{1}{2} \left(\frac{y_s}{\xi_{x_s}} \right)^2 \right\} \Pi_{(0,+\infty)}(y_s).$$

A equação anterior supõe que, dado o "backscatter" do terreno, o ruído "speckle" é independente de pixel para pixel e que o imageamento SAR foi feito com uma visada ("look") e detecção linear.

Uma consequência imediata desta modelagem é que, se observamos uma imagem de 128×128 pixels, teremos 2^{128^2} possíveis segmentações para a mesma.

4 O Algoritmo ICM

Existem várias propostas para, dada a observação de uma imagem, obter uma segmentação. Exemplos disto são a segmentação por máxima verossimilhança pontual, e os estimadores MAP e MPM [Besag (1989)].

Uma forma de obter o estimador da verdade terrestre é a proposta apresentada em [Besag, (1986)]: as ICM (*Iterated Conditional Modes*), Modas Condicionais Iterativas. O algoritmo é definido por: dada $\hat{\mathbf{x}}(k)$, a estimacão da imagem \mathbf{x} na iteração k , formar a nova estimacão $\hat{\mathbf{x}}(k+1)$ atualizando o valor do pixel s , $\hat{x}_s(k)$, com o valor modal da distribuição condicional dada pela expressão $\text{Pr}(X_s | \mathbf{x}_{S \setminus \{s\}}, \mathbf{y})$; no próximo passo, atualizar o pixel t , e assim por diante; parar quando houver evidência de convergência.

É possível ver que este algoritmo, desde que implementado em forma sequencial, assegura uma seqüência de estimacões $(\hat{\mathbf{x}}(k))_{k \geq 0}$ tal que $\text{Pr}(\mathbf{X} = \hat{\mathbf{x}}(k) | \mathbf{y})$ é não decrescente em k ; isto é $\text{Pr}(\hat{\mathbf{x}}(0) | \mathbf{y}) \leq \text{Pr}(\hat{\mathbf{x}}(1) | \mathbf{y}) \leq \text{Pr}(\hat{\mathbf{x}}(2) | \mathbf{y}) \leq \dots$.

O algoritmo pode ser implementado, também, em forma paralela; porém, a propriedade de assegurar uma seqüência de estimacões com a característica descrita acima, só está provada para implementações

sequenciais (veja o uso da imagem intermediária w no algoritmo).

Para detalhes de implementação (a respeito da seqüência de pixels visitados s, t, \dots , da estimação inicial $\hat{x}(0)$ e dos possíveis critérios de parada), para a conexão das ICM com técnicas de relaxação estocástica e para resultados experimentais ver as referências [Besag (1986, 1989)].

Vários detalhes não estão completamente especificados no que diz respeito a este algoritmo; por exemplo, que parâmetros usar em cada iteração? Isto é, os parâmetros da distribuição a priori e da degradação devem ser atualizados em cada iteração, ou não?

A seguir mostramos uma implementação feita para trabalhar com seis opções diferentes:

1. Sem atualizar nem ξ_{-1}, ξ_{+1} nem β .
2. Atualizando ξ_{-1}, ξ_{+1} mas não β .
3. Sem atualizar ξ_{-1}, ξ_{+1} e atualizando β .
4. Sem atualizar ξ_{-1}, ξ_{+1} e atualizando β , mas fixando-lhe um limitante superior.
5. Atualizando ξ_{-1}, ξ_{+1} e β .
6. Atualizando ξ_{-1}, ξ_{+1} e β , mas fixando um limitante superior ao último parâmetro.

A possibilidade de fixar limitantes superiores para algum(ns) parâmetro(s) da distribuição a priori, está relacionada ao aparecimento de *transição de fase*, assunto que pode ser visto em [Georgii (1988)].

5 Uma Implementação do ICM para Imagens SAR

A contribuição deste artigo é o desenvolvimento do algoritmo ICM específico para este caso. Para tanto, usaremos como distribuição a priori a descrita na equação (2), isto é, o modelo de Ising. As distribuições condicionais envolvidas no ICM são

$$\begin{aligned} \text{IPr}(x_s | y, x_{S \setminus \{s\}}) &\propto f_{Y_s | x_s}(y_s) \text{IPr}(x_s | x_{\partial_s}), \\ \text{com } \text{IPr}(x_s | x_{\partial_s}) &= \frac{\exp\{\frac{\beta}{2}(1 + x_s)v(s)\}}{1 + \exp\{\beta v(s)\}} \\ \text{e } v(s) &= \sum_{t \in \partial_s} x_t, \end{aligned}$$

onde ∂_s denota a vizinhança-4 da posição s , isto é, $\partial_s = \{t \in S : \|s - t\| = 1\}$.

Na Figura 4 mostramos, em pseudo-código, uma implementação experimental do algoritmo ICM que se tem mostrado bastante eficiente. A configuração inicial $\hat{x}(0)$ será, por escolha, a segmentação de máxima verossimilhança pontual da imagem y (passo 4 do algoritmo). Nesse algoritmo empregamos

a notação que descrevemos a seguir. O conjunto $S = \{1, \dots, 128\} \times \{1, \dots, 128\}$ foi particionado nos quatro subconjuntos descritos abaixo (o subíndice "p" usado é por *partição*):

$$\begin{aligned} S_1 &= \{(i, j) \in S : i = 1(2)127, j = 1(2)127\}, \\ S_2 &= \{(i, j) \in S : i = 2(2)128, j = 2(2)128\}, \\ S_3 &= \{(i, j) \in S : i = 2(2)128, j = 1(2)127\}, \\ S_4 &= \{(i, j) \in S : i = 1(2)127, j = 2(2)128\}, \end{aligned}$$

é claro que trata-se de uma partição pois $\bigcup_{p=1}^4 S_p = S$, e $S_i \cap S_j = \emptyset$ sempre que $i \neq j$. Utilizamos esta partição para evitar os efeitos indesejáveis que varreduras sistemáticas podem acarretar: o efeito diagonal citado por alguns autores.

No algoritmo descrito na Figura 4, denotamos $v(s) = \sum_{t \in \partial_s} x_t(k-1) \in \{-4, -2, 0, 2, 4\}$. O produto $\hat{\beta}(k)v(s)$ contem a informação contextual, diferenciando assim o algoritmo ICM (desta implementação), de uma segmentação por máxima verossimilhança pontual. Este valor fará com que o pixel s seja atribuído à classe -1 ou à classe $+1$ em função, tanto do valor observado y_s , quanto das classes às quais foram atribuídos os seus vizinhos.

A estimação dos parâmetros da distribuição de Rayleigh (que na Figura 4 denotamos $f_{c,o}$, c por *classe* e o por *opção*) pode ser feita usando algum dos estimadores descritos nas equações (3), (4), (5) ou outros (da Mediana, o baseado na distância interquartil, etc.) Esta estimação é ativada se $o = 2$ ou se $o = 3$; caso contrário é empregado um valor fixo que o usuário deve estipular e que será mantido em todas as iterações. Tal estimação é feita usando a segmentação atual $\hat{x}(\cdot)$, que serve para separar as observações, y , em dois grupos.

O parâmetro de atratividade do modelo de Ising, β , pode ser atualizado a cada iteração ou não, dependendo da opção escolhida pelo usuário. Caso ele deva ser estimado, devemos lançar mão da equação de pseudo-verossimilhança [Jensen-Møller (1989)]. No algoritmo escrevemos $f_{2,o,l}(\hat{x}(k)) = \min\{\beta_{PL}(\hat{x}(k)), \beta_M\}$ se $o = 1$ ou se $o = 3$. Caso contrário, é empregado um valor fixo que o usuário deve estipular e que será mantido em todas as iterações. A possibilidade de empregar um limitante superior para o parâmetro de atratividade está presente na constante β_M , fornecida pelo usuário.

Definimos $\beta_{PL}(\hat{x}(k))$, o estimador de máxima pseudo-verossimilhança de β , baseado na segmentação $\hat{x}(k)$, à raiz da seguinte equação [Frery (1991)]

$$\begin{aligned} 2(C_4^1 - C_{-4}^1) + (C_2^1 - C_{-2}^1) + \\ 2(C_{-4}^{-1} + C_4^1)\Upsilon(-4\hat{\beta}) + (C_{-2}^{-1} + C_2^1)\Upsilon(-2\hat{\beta}) - \end{aligned}$$

$$(C_2^{-1} + C_2^1)\Upsilon(2\hat{\beta}) - 2(C_4^{-1} + C_4^1)\Upsilon(4\hat{\beta}) = 0.$$

Nesta última equação, escrevemos $\Upsilon(\nu) = \frac{\exp(\nu)}{1+\exp(\nu)}$, $C_m^n = \#\{w \in W: x_w(k) = n, v(w) = m\}$, e $W = \{2, \dots, 127\} \times \{2, \dots, 127\}$.

A seguir mostramos um exemplo de aplicação desta técnica a uma imagem SAR aerotransportado obtida pelo sensor SAR-580 (Banda L), sobre a região de Freiburg, Alemanha, com uma visada e detecção linear. Nela observam-se duas regiões homogêneas: uma clara, de floresta e uma escura, de solo exposto.

A Figura 1 é um pedaço de 128×128 pixels da imagem original, apresentando o ruído "speckle", típico das imagens SAR. Na Figura 2 apresentamos a segmentação ponto a ponto por máxima verossimilhança da imagem anterior (após uma estimação, também por máxima verossimilhança, dos parâmetros); é evidente o efeito de pontilhado causado pelo ruído "speckle". Na Figura 3 vemos o resultado de aplicar o algoritmo descrito acima, obtendo um resultado bem mais satisfatório, devido à utilização do contexto espacial das classes, expresso pelo campo aleatório Markoviano.

O algoritmo foi implementado na linguagem de programação C++; foi usado o compilador C++ da SUN, versão 2 e rodado em uma SUN SPARCstation 2, sob OpenWindows versão 2 e UNIX versão 4.1.1.

O tempo para obter a segmentação por máxima verossimilhança (Figura 2) foi de, aproximadamente, 1 segundo de CPU. A segmentação pelo algoritmo ICM (Figura 3 com opções $o = 3$ e $\ell = N$) foi feita em 9 iterações e demandou, aproximadamente, 30 segundos de CPU. É importante notar que boa parte desse tempo adicional deve-se a que o estimador MAD, envolvido no algoritmo e que omitimos por simplicidade, requer duas aplicações de rotinas de ordenamento; isto é computacionalmente demorado para o número de dados envolvidos (aprox. 8000 valores em precisão dupla). Quando essa estimação é desativada, o tempo reduz-se a uns 8 segundos.

O critério de parada escolhido foi o seguinte: parar na iteração k se $\hat{x}(k) = \hat{x}(k-1)$, isto é, quando não houver mais mudança de valores de uma iteração para a próxima.

Pretende-se dar continuidade a este trabalho pela utilização de

- o modelo Markoviano "a priori" das classes denominado *Multi-Level Logistic* (MLL) [Kelly et al. (1988)], para um número maior de classes na imagem;
- outras vizinhanças, por exemplo a vizinhança-8, onde $\partial_s = \{t \in S \setminus \{s\}: \|s - t\| \leq \sqrt{2}\}$.

6 Referências

- Besag, J., On the Statistical Analysis of Dirty Pictures (with discussion). *Jr. R. Statist. Soc. B-48* (1986) 259-302.
- Besag, J., Towards Bayesian Image Analysis. *Jr. Appl. Statist.*, **16** (1989) 395-407.
- Derin, H.; Kelly, P.; Vézina, G. and Labbit, S., Modelling and Segmentation of Speckled Images Using Complex Data. *IEEE Trans. on Geoscience and Remote Sensing GRS-28* (1990) 76-87.
- Frery, A., Markovian Fields: Theory, Simulation and Parameter Estimation. *Informes de Matemática B-064* (1991) IMPA, Rio de Janeiro, Brasil.
- Geman, S. and Geman, D., Stochastic Relaxation, Gibbs Distribution and the Bayesian Restoration of Images. *IEEE Trans. on Pattern Analysis and Machine Intelligence PAMI-6* (1984) 721-741.
- Georgii, H., *Gibbs Measures and Phase Transitions*. De Gruyter Studies in Mathematics **9**. Walter De Gruyter. 1988.
- Jensen, J. and Møller, J., Pseudolikelihood for Exponential Family Models of Spatial Processes. Research Report; Department of Theoretical Statistics, Århus University. 1989.
- Kelly, P.; Derin, H. and Hartt, K., Adaptive Segmentation of Speckled Images Using a Hierarchical Random Field Model. *IEEE Trans. on Acoustics, Speech and Signal Processing ASSP-36* (1988) 1628-1641.

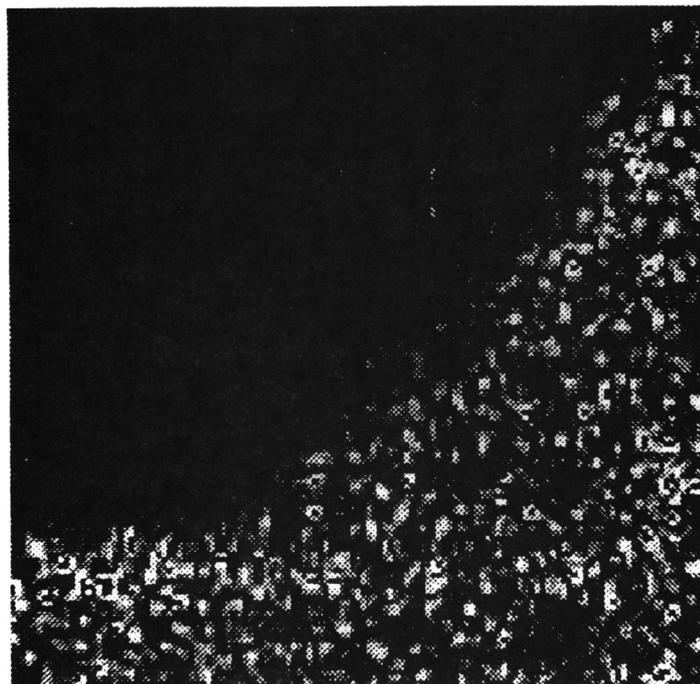


Figura 1: Imagem SAR-580, banda L.

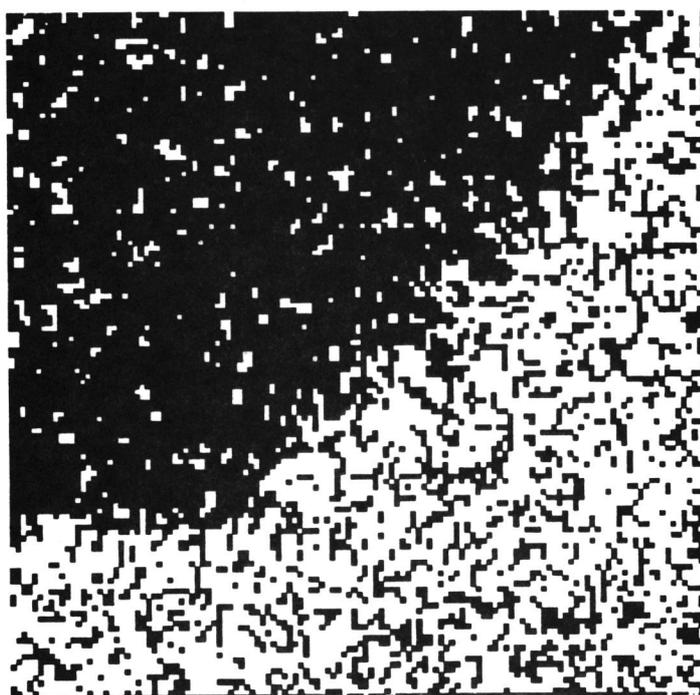


Figura 2: Segmentação da imagem SAR-580 por máxima verossimilhança pontual.

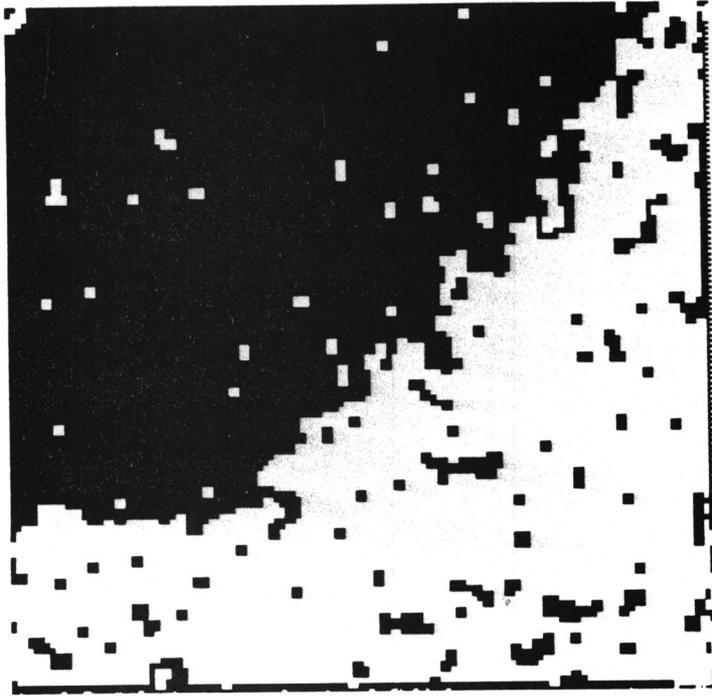


Figura 3: Segmentação ICM da imagem SAR-580.

1. Atribuir $k = 0$, $I = N$ e $\ell = N$.
2. Ler $o \in \{0, 1, 2, 3\}$.
 - (a) Se $o = 0$ ou $o = 2$ então ler $\hat{\beta}(k)$; seguir em 3). Se não ler $\ell \in \{S, N\}$.
 - (b) Se $\ell = S$ ler β_M . Se não atribuir $\beta_M = +\infty$.
3. Ler $\hat{\xi}_{-1}(k)$ e $\hat{\xi}_{+1}(k)$.
4. Para todo $s \in S$ atribuir

$$\hat{x}_s(k) = \begin{cases} -1 & \text{se } y_s \leq \sqrt{\frac{4 \ln \left(\frac{\hat{\xi}_{+1}(k)}{\hat{\xi}_{-1}(k)} \right)}{(\hat{\xi}_{-1}(k))^{-2} - (\hat{\xi}_{+1}(k))^{-2}}} \\ +1 & \text{caso contrário} \end{cases}$$

5. Fazer,
 - (a) Atribuir $k = k + 1$.
 - (b) Atualizar as estimações dos parâmetros das distribuições Rayleigh: $\hat{\xi}_c(k) = f_{c,o}(\hat{\mathbf{x}}(k-1))$ para $c = -1, +1$, e atualizar a estimaco do parâmetro da distribuio a priori: $\hat{\beta}(k) = f_{2,0,\ell}(\hat{\mathbf{x}}(k-1))$.
 - (c) Atribuir $\mathbf{w} = \hat{\mathbf{x}}(k-1)$.
 - (d) Para cada $p = 1, 2, 3, 4$ e para todo $s \in S_p$ fazer

i. Atribuir

$$w_s = \begin{cases} -1 & \text{se } y_s \leq \sqrt{\frac{4 \ln \left(\frac{\hat{\xi}_{+1}(k)}{\hat{\xi}_{-1}(k)} \right) - 2\hat{\beta}(k)v(s)}{(\hat{\xi}_{-1}(k))^{-2} - (\hat{\xi}_{+1}(k))^{-2}}} \\ +1 & \text{caso contrário.} \end{cases}$$

ii. Se $w_s \neq \hat{x}_s(k-1)$ atribuir $I = S$.

(e) Atribuir $\hat{\mathbf{x}}(k) = \mathbf{w}$

enquanto $I = S$.

6. Retornar $(\hat{\mathbf{x}}(k), k)$.
7. Fim.

Figura 4: Pseudo-código da implementaço do algoritmo ICM para segmentaço binária de imagens SAR.