

PROJETO, DESENVOLVIMENTO E AVALIAÇÃO DE CLASSIFICADORES ESTATÍSTICOS PONTUAIS E CONTEXTUAIS PARA IMAGENS SAR POLARIMÉTRICAS

Antonio Henrique Correia¹
Corina da Costa Freitas¹
Alejandro C. Frery²

¹INPE – Instituto Nacional de Pesquisas Espaciais
DPI – Divisão de Processamento de Imagens
Avenida dos Astronautas, 1758
12227-010 São José dos Campos, SP, Brasil
correia, corina@dpi.inpe.br

²UFPE – Universidade Federal de Pernambuco
DI – Departamento de Informática
CP 7851
50732-970 Recife, PE, Brasil
frery@di.ufpe.br

RESUMO

Este trabalho tem como objetivos investigar, implementar e avaliar um sistema amigável para classificar imagens. Os métodos de classificação implementados são o de Máxima Verossimilhança Pontual (MaxVer) e o classificador contextual ICM a oito vizinhos, para os dados polarimétricos *multi-look* de radares de abertura sintética (SAR). Com base nas propriedades estatísticas dos dados polarimétricos foram implementadas cinco opções de classificação, uma para cada tipo de dado polarimétrico univariado (diferença de fase e razão de intensidades) e bivariado (par de intensidades e par intensidade-diferença de fase) e outra que utiliza as distribuições multivariadas mais apropriadas para os dados em formato complexo. Essas opções funcionam através de interfaces gráficas, amigáveis ao usuário e desenvolvidas sob o paradigma *goal-driven*. O desenvolvimento foi realizado como um *plug-in* do sistema ENVI 3.0, com a finalidade de aproveitar os diversos recursos deste software no processamento e análise de imagens SAR bem como a sua ampla divulgação na comunidade de usuários de sensoriamento remoto. Para avaliar o comportamento do sistema desenvolvido foram utilizadas imagens polarimétricas *multi-look* (HH, HV e VV) da missão SIR-C/X-SAR, nas bandas L e C. A fim de se avaliar quantitativamente, através do coeficiente de concordância Kappa, o ganho de qualidade das classificações obtidas com dados polarimétricos sob diferentes modelagens estatísticas, foram utilizados diferentes tipos de dados SAR *multi-look*: univariados em amplitude (utilizando-se as distribuições mais apropriadas), polarimétricos uni/bivariados, multivariados em amplitude (utilizando-se a distribuição Normal multivariada) e multivariados complexos.

ABSTRACT

The purpose of this study is to investigate, implement and test a user-friendly system for image classification. The implemented methods are the Maximum Likelihood Classifier (MLC) and the ICM contextual classifier with eight neighbours, for multi-look Synthetic Aperture Radar (SAR) polarimetric data. Five classification options, related to the statistical properties of polarimetric data,

were implemented: one for each kind of univariate (phase difference and intensity ratio) and bivariate (intensity pair and intensity-phase difference pair) format, and a fifth that uses the most appropriate multivariate distribution for the complex multivariate data. This options communicate with the user with graphic interfaces, they are user-friendly and the whole system was developed under the *goal-driven* paradigm. The system works as a *plug-in* for the ENVI 3.0 platform, aiming at using tools this software offers for SAR image processing and analysis. Multi-look polarimetric images from SIR-C/X-SAR mission, in L and C bands, were used to assess the behaviour of the system. The Kappa coefficient of agreement was used to quantitatively evaluate the classification improvement obtained using polarimetric data in different formats: univariate (using the most appropriate distribution), univariate and bivariate polarimetric, multivariate in amplitude (using multivariate Normal distribution) and complex multivariate.

1 INTRODUÇÃO

A intensificação de estudos na área de Sensoriamento Remoto voltado para os radares imageadores de abertura sintética (*Sinthetic Aperture Radar* - SAR) tem proporcionado, cada vez mais, o melhor entendimento dos mecanismos de dispersão dos alvos terrestres na faixa de microondas. Desta forma, as aplicações de imagens SAR nos mais variados campos do conhecimento humano (Geologia, Cartografia etc.) tornam-se mais confiáveis, principalmente em regiões onde a obtenção de imagens geradas por sensores ópticos é muito difícil, devido a fatores climáticos ou ambientais.

Dentre essas aplicações destaca-se a classificação digital de imagens. Cada vez mais requer-se que os algoritmos de classificação para imagens SAR sejam mais precisos, e essa melhora está diretamente ligada, entre outros fatores, a uma modelagem mais adequada aos dados SAR, como mostrado em Nezry et al. (1996) e Frery et al. (1997).

Em Vieira (1996) isso fica bem evidente, através do uso das distribuições mais apropriadas às observações provindas de diferentes classes, além da informação contextual. Desta forma, são obtidas melhores classificações do que as obtidas com os classificadores convencionais, que não utilizam a informação contextual e modelam as observações provenientes das classes apenas através da distribuição Gaussiana. Por outro lado, o uso de dados monoespectrais tem suas limitações, principalmente pela quantidade limitada de informação proveniente da superfície imageada.

Desta forma, começam a aumentar os estudos voltados para os sistemas SAR polarimétricos, que fornecem uma quantidade maior de informação sobre a superfície imageada. Esse aumento da informação é devido ao fato que várias componentes são obtidas em amplitude (diferentes polarizações de transmissão e recepção do sinal), bem como a informação de fase.

Dentro desse novo campo de pesquisa para estas imagens, vários estudos foram realizados afim de se verificar a melhor maneira de modelar estatisticamente os dados polarimétricos *single-look* (Kong, 1988; Lim et al., 1989; Quegan e Rhodes, 1995; Yueh et al., 1989). Porém, para dados SAR polarimétricos *multi-look*, que permitem a redução do *speckle* e a compressão dos dados, pouco ainda foi realizado. Entretanto, os resultados obtidos demonstram a grande potencialidade desse tipo de dado (Lee e Grunes, 1992; Lee e Grunes, 1994; Lee et al., 1995).

Considerando-se que a modelagem disponível atualmente para dados polarimétricos *multi-look* somente seja feita para áreas consideradas homogêneas e heterogêneas, foi desenvolvida neste trabalho uma nova distribuição multivariada, denominada de G_C^0 multivariada, que modela áreas consideradas extremamente heterogêneas, utilizando-se os dados multivariados complexos *multi-look* (representados pela matriz de covariância dos dados polarimétricos).

Aproveitando-se as possibilidades de pesquisa com dados polarimétricos, este trabalho tem por objetivos investigar, implementar e testar classificadores pontuais e contextuais, que utilizem os dados SAR polarimétricos *multi-look*, afim de verificar se os resultados das classificações com dados polarimétricos são mais significativos que os obtidos com outros tipos de dados SAR.

2 SISTEMAS SAR POLARIMÉTRICOS

Os radares imageadores convencionais operam com um único canal e com uma única antena de polarização fixa, tanto para a transmissão como para a recepção do sinal de rádio. Desta forma, somente a amplitude do sinal é medida, acarretando com isso a perda de qualquer informação de fase contida no sinal eletromagnético complexo refletido.

Com a utilização de radares imageadores polarimétricos é possível medir a amplitude e a fase relativa de todas as configurações (componentes) das antenas de transmissão e recepção (HH, VV, VH e HV), para todos os elementos de resolução de uma cena (Ulaby e Elachi, 1990). A primeira e segunda letra de cada componente indicam, respectivamente, a polarização das ondas transmitida e recebida pelo radar. Por exemplo, a componente HV significa que o radar transmitiu uma onda polarizada na Horizontal e recebeu a onda polarizada na Vertical.

A relação entre as componentes do campo elétrico de transmissão (E^t) e o de recepção (E^r), dos sinais de rádio de um sistema radar, é dada por (Ulaby et al., 1986):

$$E^r = \frac{e^{ikR}}{R} S E^t, \quad (1)$$

$$\text{onde, } S = \begin{pmatrix} S_{vv} & S_{vh} \\ S_{hv} & S_{hh} \end{pmatrix}, E^r = \begin{pmatrix} E_v^r \\ E_h^r \end{pmatrix} \text{ e } E^t = \begin{pmatrix} E_v^t \\ E_h^t \end{pmatrix}$$

A matriz S é chamada de matriz de espalhamento complexa (*complex scattering matrix*) dos alvos. Na equação (1), R é a distância entre o alvo e a antena de recepção e k é o número de onda da onda incidente sobre o alvo. Os termos S_{pq} (onde $p, q = h \text{ ou } v$) são conhecidos como amplitude de espalhamento complexa (*complex scattering amplitude*) e dados por:

$$S_{pq} = |S_{pq}| e^{i\phi_{pq}} = \sum_{n=1}^N |s_{pq}^n| e^{i\phi_{pq}^n},$$

onde N é o número de dispersores de um elemento de resolução, cada um possuindo uma amplitude $|s_{pq}^n|$ e uma fase ϕ_{pq}^n .

3 MODELAGEM DOS DADOS SAR POLARIMÉTRICOS

Considerando que os dados obtidos com radiação coerente, como é o caso de imagens SAR, possuem um ruído próprio (*speckle*), o modelo empregado para representar esse tipo de dado SAR deve ser capaz de separar tal ruído do que seria efetivamente a resposta do alvo na direção do sensor (*backscatter*). Desta forma, a maneira mais usual de modelar os dados SAR é através do modelo multiplicativo. Este modelo supõe que, sob certas condições (Tur et al., 1982), o valor observado em cada pixel é a ocorrência de uma variável aleatória $Z = XY$, onde X é a variável aleatória que modela o *backscatter* e Y é a variável aleatória que modela o *speckle*.

Quando se utilizam dados polarimétricos *multi-look*, como é o caso desse trabalho, os poucos estudos realizados (Lee e Grunes, 1992; Du e Lee, 1996) mostram que a melhor maneira de modelá-los é a partir da matriz de covariância complexa, que apresenta uma distribuição de Wishart complexa, apresentada na próxima seção. Porém, dependendo da região de estudo, como acontece com os dados monoespectrais, a modelagem do *backscatter* (X) deverá ser diferente, e consequentemente a distribuição associada ao retorno (Z) variará. Desta forma, tal abordagem será utilizada neste trabalho e será comentada a seguir.

3.1 REGIÕES HOMOGÊNEAS

Como mostrado em Ulaby e Elachi (1990), considerando-se que os satélites, de um modo geral, transmitem e recebem pela mesma antena, i.e. são monoestáticos, pode-se supor que os termos complexos S_{hv} e S_{vh} são iguais. Desta forma, a matriz S terá informação redundante, podendo ser resumida a:

$$Z_C = \begin{bmatrix} S_{hh} \\ S_{hv} \\ S_{vv} \end{bmatrix},$$

onde Z_C representa o retorno na forma de um vetor complexo.

Considerando que o elemento de resolução do terreno possui um número muito grande de dispersores, o vetor Z_C pode ser modelado por uma distribuição Gaussiana complexa multivariada (Goodman, 1963). Isso é verdade se o *backscatter* (X) é constante em cada uma das áreas imageadas, uma vez que a modelagem física impõe que o *speckle* (Y_C) obedeça uma distribuição Gaussiana complexa multivariada.

O vetor Z_C representa os dados polarimétricos *1-look* que, por serem dados complexos e poderem ter distintas polarizações (componentes), produzem um grande volume de dados da superfície imageada. Desta forma, para compressão dos dados e redução do ruído *speckle*, os dados SAR polarimétricos são freqüentemente processados com o aumento do número de *looks* (*multi-look*). Sendo assim, a partir do

vetor $Z_c(k)$, que representa a k -ésima amostra de l -look, pode-se obter a matriz de covariância para n -looks (*multi-look*), dada por (Lee et al., 1995):

$$Z_c^{(n)} = \frac{1}{n} \sum_{k=1}^n Z_c(k) Z_c^{*T}(k) = \begin{pmatrix} Z_{hh}^{(n)} & Z_{hhv}^{(n)} & Z_{hvv}^{(n)} \\ Z_{hhv}^{(n)*} & Z_{hv}^{(n)} & Z_{hvv}^{(n)} \\ Z_{hvv}^{(n)*} & Z_{hvv}^{(n)*} & Z_{vv}^{(n)} \end{pmatrix}, \quad (2)$$

onde Z_c^{*T} denota o conjugado transposto do vetor $Z_c(k)$, e os termos $Z_i^{(n)}$ e $Z_{ij}^{(n)}$ são imagens n -looks em intensidade e complexas, respectivamente ($i = j = hh, hv$ e vv).

A grande vantagem de se trabalhar com a matriz de covariância, quando o retroespalhamento é modelado através de uma constante (regiões homogêneas), é que a matriz $A_c = nZ_c^{(n)}$ apresenta uma distribuição de Wishart complexa multivariada, conforme Srivastava (1963). Sendo assim, a distribuição da variável aleatória $Z_c^{(n)}$, associada à matriz $Z_c^{(n)}$, é dada por:

$$f_{Z_c^{(n)}}(z) = \frac{n^q |z|^{(n-q)} \exp[-n \text{Tr}(C_c^{-1} z)]}{K(n, q) |C_c|^n} \quad n, q > 0, \quad (3)$$

onde q denota o número de componentes, $K(n, q) = \pi^{(1/2)q} \Gamma(n) \cdots \Gamma(n - q + 1)$, Tr denota o traço de uma matriz, $C_c = E[Z_c Z_c^{*T}]$ e E denota a esperança matemática. Pode-se notar que se o número de componentes do vetor Z_c for um (e consequentemente de $Z_c^{(n)}$), ou seja se $q = 1$ (caso monoespectral), então a equação (3) se reduz a distribuição Γ (Frery et al., 1997; Vieira, 1996).

A partir da equação (3) é que todas as densidades para dados polarimétricos, considerando o *backscatter* constante, a seguir comentadas, são derivadas (Lee et al., 1994a; Lee et al., 1994b; Lee et al., 1995). É importante ressaltar que segundo Lee et al. (1994a) as densidades das imagens diferença de fase e razão de intensidades n -looks, a seguir mostradas, independem da região imageada. Apenas para facilitar a notação, o sobrescrito “(n)” será omitido nos termos Z_i e Z_{ij} , que continuarão indicando imagens n -looks em intensidade e complexa, respectivamente.

3.1.1 DISTRIBUIÇÃO DO PAR DE IMAGENS EM INTENSIDADE *MULTI-LOOK*

Sejam duas imagens em intensidade *multi-look* representadas pelas variáveis aleatórias Z_1 e Z_2 , obtidas a partir de duas componentes S_r e S_s da matriz de espalhamento, dadas por:

$$Z_1 = \frac{1}{n} \sum_{k=1}^n |S_r(k)|^2 \quad \text{e} \quad Z_2 = \frac{1}{n} \sum_{k=1}^n |S_s(k)|^2$$

A distribuição do par de imagens em intensidade *multi-look*, derivada em Lee et al. (1994a), é dada por:

$$f_{(Z_1, Z_2)}(z_1, z_2) = \frac{n^{n+1} (z_1 z_2)^{\frac{(n-1)}{2}} \exp\left(-\frac{n(z_1/h_{11} + z_2/h_{22})}{1-|\rho_c|^2}\right)}{(h_{11} h_{22})^{\frac{(n+1)}{2}} \Gamma(n) (1-|\rho_c|^2) |\rho_c|^{n-1}} I_{n-1}\left(\frac{2n|\rho_c|}{1-|\rho_c|^2} \sqrt{\frac{z_1 z_2}{h_{11} h_{22}}}\right), \quad (4)$$

onde $h_{11} = E[Z_1]$, $h_{22} = E[Z_2]$,

$$\rho_c = \frac{E[S_r S_s^*]}{\sqrt{E[|S_r|^2] E[|S_s|^2]}} = |\rho_c| e^{i\xi},$$

$|\rho_c|$ representa a magnitude (módulo) e ξ a fase do coeficiente de correlação complexo *multi-look*, $i = \sqrt{-1}$ e I_{n-1} representa a função modificada de Bessel de ordem $n-1$.

3.1.2 DISTRIBUIÇÃO DA IMAGEM DIFERENÇA DE FASE *MULTI-LOOK*

Seja uma imagem diferença de fase *multi-look* representada pela variável aleatória Ψ , obtida a partir de duas componentes S_r e S_s da matriz de espalhamento, dada por (Lee et al., 1994a):

$$\Psi = \text{Arg}\left(\frac{1}{n} \sum_{k=1}^n S_r(k) S_s^*(k)\right),$$

onde Arg denota o argumento de um número complexo. A distribuição de Ψ , derivada em Lee et al. (1994b), é dada por:

$$f_{\Psi}(\psi) = \frac{\Gamma(n+1/2)(1-|\rho_c|^2)^n \delta}{2\sqrt{\pi} \Gamma(n)(1-\delta^2)^{n+1/2}} + \frac{(1-|\rho_c|^2)^n}{2\pi} {}_2F_1(n, 1; 1/2; \delta^2) \quad (-\pi < \psi \leq \pi), \quad (5)$$

onde $\delta = |\rho_c| \cos(\psi - \xi)$, ${}_2F_1$ denota a função hipergeométrica Gaussiana (Gradshteyn e Ryzhik, 1980) e ξ é a fase do coeficiente de correlação complexo.

3.1.3 DISTRIBUIÇÃO DA RAZÃO DE IMAGENS EM INTENSIDADE *MULTI-LOOK*

A partir de duas imagens em intensidade *multi-look*, representadas pelas variáveis aleatórias Z_1 e Z_2 , a distribuição da razão $W = Z_1/Z_2$ foi derivada por Lee et al. (1994a), e é dada por:

$$f_W(w) = \frac{\tau^n \Gamma(2n)(1-|\rho_c|^2)^n (\tau+w) w^{n-1}}{\Gamma^2(n)[(\tau+w)^2 - 4\tau|\rho_c|^2 w]^{(2n+1)/2}}, \quad (6)$$

onde $\tau = h_{11}/h_{22}$.

3.1.4 DISTRIBUIÇÃO DO PAR DE IMAGENS INTENSIDADE-DIFERENÇA DE FASE MULTI-LOOK

Sejam duas imagens *multi-look*, uma em intensidade, representada pela variável aleatória Z_1 , e uma diferença de fase, representada pela variável aleatória Ψ , obtidas de duas componentes S_r e S_i da matriz de espalhamento. Seja uma imagem representada pela variável aleatória B_1 , definida por (Lee et al., 1995):

$$B_1 = \frac{nZ_1}{h_{11}} = \frac{\sum_{k=1}^n |S_r(k)|^2}{h_{11}}$$

A distribuição conjunta de B_1 e Ψ foi derivada em Lee et al. (1995), e é dada por:

$$j_{(B_1, \Psi)}(b_1, \psi) = \frac{b_1^{n-1} \exp\left(-\frac{b_1}{d}\right)}{2\pi \Gamma(n)} {}_1F_1\left[1; \frac{1}{2}; \frac{\delta^2 b_1}{d}\right] + \frac{\delta b_1^{n-\frac{1}{2}} \exp\left(-\frac{b_1(1-\delta^2)}{d}\right)}{2\sqrt{\pi}\Gamma(n)\sqrt{d}}, \quad (7)$$

onde $d = 1 - |\rho_c|^2$, $\delta = |\rho_c| \cos(\psi - \xi)$ e ${}_1F_1$ denota a função hipergeométrica degenerada ou confluyente (Abramowitz e Stegun, 1965).

Estimadores dos parâmetros das distribuições dadas pelas equações (4) a (7) podem ser encontrados em Correia (1998).

3.2 REGIÕES HETEROGÊNEAS

Como apresentado na seção anterior, a suposição de *backscatter* constante só se aplica bem para regiões homogêneas. Entretanto, quando se trata de regiões heterogêneas, o *backscatter* pode ser modelado pela distribuição $\Gamma(\alpha, \lambda)$, como no caso de dados monoespectais em intensidade (Jakeman, 1980; Jakeman e Pusey, 1976). Baseado nesta modelagem, Lee et al. (1994c) desenvolveram, a partir da equação (2), a distribuição de $Z_c^{(n)}$ para o caso heterogêneo, denominada K_c multivariada *multi-look*, que é caracterizada por:

$$f_{Z_c^{(n)}}(z) = \frac{2|z|^{n-q} (n\alpha)^{(\alpha+qn)/2} K_{\alpha-qn}\left(2\sqrt{n\alpha \text{Tr}(C_c^{-1}z)}\right)}{K(n, q) |C_c|^n \Gamma(\alpha) \text{Tr}(C_c^{-1}z)^{(qn-\alpha)/2}} \quad \alpha, n, q > 0, \quad (8)$$

onde $K_{\alpha-qn}$ é a função de Bessel de terceiro tipo e ordem $\alpha - qn$.

3.3 REGIÕES EXTREMAMENTE HETEROGÊNEAS

Em Frery et al. (1997) é mostrado que, para regiões extremamente heterogêneas, a melhor maneira de modelar o *backscatter*, para dados monoespectrais em intensidade, é através da distribuição $\Gamma^{-1}(\alpha, \gamma)$.

Desta forma, a mesma modelagem foi utilizada em Correia (1998) para dados polarimétricos complexos, a partir da equação (2), desenvolvendo para a matriz $Z_c^{(n)}$ uma nova distribuição, denominada G_c^0 multivariada *multi-look*, que é caracterizada por:

$$f_{Z_c^{(n)}}(z) = \frac{n^{qn} |z|^{n-q} \Gamma(qn - \alpha)}{(-\alpha)^a \Gamma(-\alpha) K(n, q) |C_c|^n (n \text{Tr}(C_c^{-1} z) - \alpha)^{qn-a}} \quad -\alpha, n, q > 0, \quad (9)$$

4 CLASSIFICAÇÃO DE IMAGENS

Em sensoriamento remoto, uma das técnicas de processamento de imagens mais importantes e utilizadas é a classificação digital. Este processo consiste em, a partir de uma imagem de entrada, gerar uma imagem rotulada ou mapa. Neste mapa cada *pixel* recebe um rótulo que identifica a classe à qual a posição foi atribuída, segundo uma regra de decisão. O classificador é denominado pontual quando a classificação é feita *pixel a pixel* ou por região quando a classificação é realizada num conjunto de *pixels* simultaneamente.

Os métodos de classificação podem ser divididos em dois grupos: supervisionados (semi-automáticos) ou não supervisionados (automáticos). Nos primeiros, supondo-se conhecido o número de classes presentes na imagem, define-se um conjunto de amostras como pertencentes a cada uma das classes (amostras de treinamento), e a partir das informações extraídas das amostras das classes (etapa de aprendizado ou treinamento), constroem-se critérios para agrupar os *pixels* ou regiões com características similares (classificação propriamente dita). Nos segundos, desconhece-se o número de classes existente na imagem e, portanto, procura-se verificar a existência de grupos de *pixels* ou regiões, de modo que elementos de um mesmo conjunto (classe) tenham características semelhantes.

A seguir, serão apresentados os dois métodos de classificação supervisionada utilizados neste trabalho, sendo os dois classificadores estatísticos pontuais. A diferença é que o segundo método incorpora a informação contextual com o objetivo de melhorar a classificação pontual.

4.1 CLASSIFICADOR PONTUAL

Os classificadores que adotam técnicas estatísticas requerem modelos tanto para os *pixels* quanto para as classes. As hipóteses de independência entre *pixels*, equiprobabilidade e Gaussianidade das classes são as hipóteses mais comuns no desenvolvimento e implementação deste tipo de classificador.

O classificador estatístico mais conhecido e comumente utilizado em sensoriamento remoto é o de Máxima Verossimilhança (MaxVer), que é pontual, supervisionado e possui baixo custo computacional. Este classificador, baseado na formulação Bayesiana, consiste da maximização da distribuição *a posteriori* de uma classe ω dada a ocorrência de um *pixel* com valor x . Isto é equivalente, após algumas simplificações, à maximização da seguinte função de verossimilhança:

$$L(\omega) = Pr(\omega/x) = Pr(x/\omega).Pr(\omega).$$

Dada a hipótese de equiprobabilidade das classes (isto é, $Pr(\omega)$ é igual para todas as classes), a expressão anterior se reduz ao modelo de degradação adotado para o sinal ($Pr(x/\omega)$). A maximização

de $L(\omega)$ é conhecida como a regra decisão por máxima verossimilhança, a qual dá o nome ao classificador. Para imagens ópticas, geralmente, adota-se a distribuição Gaussiana para modelar a $Pr(x/\omega)$. Tal como foi visto acima, esta hipótese é pouco realista para imagens SAR e, portanto, neste trabalho foi abandonada essa hipótese em favor das distribuições decorrentes do modelo multiplicativo.

4.2 CLASSIFICADOR PONTUAL/CONTEXTUAL

A suposição de que os dados observados numa imagem são provenientes da distribuição Gaussiana, pode conduzir a resultados da classificação MaxVer pobres ou não satisfatórios. Isto ocorre quando este modelo não é o mais adequado para descrever os dados e/ou a relação sinal/ruído das imagens é baixa. Portanto, para os dados SAR, que se enquadram nestas duas situações, há a necessidade de se melhorar o desempenho do classificador MaxVer. Sem abandonar a teoria estatística e baseado na formulação Bayesiana, tem-se como alternativas: a adoção de modelos mais realistas para os dados SAR observados (modelar $Pr(x/\omega)$ adequadamente, como visto na seção anterior) e/ou a incorporação da informação contextual, considerando uma distribuição espacial para as classes (modelar $Pr(\omega)$).

Um classificador que, além de considerar o nível de cinza do *pixel*, incorpore a informação da vizinhança (contexto) deste *pixel*, pode minimizar o problema da relação sinal/ruído, assim como aumentar o desempenho de classificação. A modelagem Markoviana tem sido proposta para incorporar a noção de dependência espacial entre classes e/ou observações (Frery, 1993), e foi utilizada em processamento de imagens, entre outros, por Besag (1986, 1989) e Geman e Geman (1984). O modelo de Potts (que é um caso particular dos campos aleatórios Markovianos) é usado para descrever, de forma estatística, esta dependência espacial. Dentro da formulação Bayesiana, este modelo é empregado para descrever a distribuição *a priori* dos dados no desenvolvimento do classificador contextual. Assim sendo, o modelo de Potts será utilizado como o modelo estatístico para todos os mapas possíveis.

Agora, conhecidos o modelo de degradação, $Pr(x/\omega)$, e a distribuição *a priori*, $Pr(\omega)$, tem-se que procurar um estimador para o mapa, dadas as observações. Segundo Frery (1993), os principais estimadores relacionados às técnicas Markovianas são os de Máximo a Posteriori (MAP – *Maximum A Posteriori*), de Moda da Marginal a Posteriori (MPM – *Marginal Posteriori Mode*) e de Modas Condicionais Iterativas (ICM – *Iterated Conditional Modes*). O algoritmo deste último estimador apresenta várias vantagens com relação aos outros dois, como descrito em Frery (1993), e é o utilizado no classificador contextual aqui apresentado.

O algoritmo ICM é um método de refinamento iterativo de uma classificação inicial, consistindo em substituir a classe atual associada a cada *pixel* por aquela que maximiza a distribuição *a posteriori* da classe, dados o nível de cinza (componente de verossimilhança) e as classes vizinhas (componente de contexto). Quando o modelo de Potts é adotado para modelar a distribuição *a priori*, a maximização da distribuição *a posteriori* equivale a maximizar a seguinte função de verossimilhança:

$$L(\omega) = f_{\omega}(z_s) \exp(\beta \# \{t \in \partial_s : \omega_t = \omega\}),$$

onde $f_{\omega}(z_s)$ representa a distribuição associada à classe ω , com o valor observado z_s na coordenada s , β é um parâmetro real que quantifica a influência das classes vizinhas, sendo estimado iterativamente, $\#$ representa o número de elementos de um conjunto, t denota a coordenada de um pixel e ∂_s é o conjunto

de coordenadas em torno de s . Esta expressão pode ser reduzida ao classificador MaxVer ou ao filtro de Moda, quando $\beta = 0$ ou $\beta \rightarrow \infty$, respectivamente. Para mais detalhes sobre o algoritmo ICM e a estimação do parâmetro β , recomenda-se Frery (1993) e Vieira (1996).

4.3 TESTE DAS CLASSIFICAÇÕES

Nesta seção é comentada a técnica empregada para avaliar diferentes classificações da mesma imagem, processo essencial no contexto desta dissertação. Comparando-se a imagem classificada com amostras de teste específicas ou com imagens verdade que estejam co-registradas, pode-se obter uma matriz de confusão, onde são apresentadas as quantidades e/ou percentagens de pixels classificados correta e incorretamente em cada classe.

Alguns métodos tem sido propostos para a determinação da exatidão da classificação utilizando-se matrizes de confusão (Bishop et al., 1975; Campbell, 1987; Ma e Redmond, 1995). Neste trabalho será utilizado o *Coefficiente de Concordância Kappa*, descrito em Hudson e Ramm (1987), para realizar o teste da classificação, bem como os testes de hipóteses bilaterais, descritos em Vieira (1996), para comparação das matrizes de confusão das classificações obtidas.

5 DESCRIÇÃO DO SISTEMA DESENVOLVIDO

Com a finalidade de aproveitar as várias funções auxiliares para a classificação supervisionada de imagens (leitura de imagens, seleção de áreas de treinamento etc.) e as de processamento de dados SAR (filtragem, correções geométricas etc.) oferecidas pelo software ENVI (*ENvironment for Visualizing Images*, ENVI, 1997), foram introduzidas nesse software, todas as rotinas de classificação MaxVer/ICM, para dados polarimétricos, implementadas neste trabalho. Este software permite ao usuário incorporar novas rotinas, utilizando-se a linguagem IDL (*Interactive Data Language*), que é uma poderosa linguagem de programação, estruturada e baseada em vetores que combina processamento integrado de imagens com a capacidade de exibir com facilidade conjuntos de ferramentas para o uso das Interfaces Gráficas *point-and-click* interativas com o usuário (GUI).

O algoritmo ICM, desenvolvido por Vieira (1996) para oito vizinhos, foi incorporado em todos os classificadores MaxVer implementados. Esses classificadores são supervisionados, isto é, requerem a especificação de amostras de treinamento para estimação dos parâmetros. Essas amostras são informadas através de regiões de interesse (*Regions of Interest – ROI*), previamente definidas pelo usuário com as opções do ENVI. O número equivalente de *looks (nel)* também é um parâmetro de entrada, que deve ser estimado previamente, conforme descrito em Vieira (1996). A seguir são descritas todas as cinco rotinas de classificação MaxVer/ICM implementadas para imagens SAR polarimétricas. É importante destacar que todas essas rotinas possuem por trás delas uma modelagem estatística totalmente transparente ao usuário, que necessita apenas conhecer previamente o número de classes existentes na área de estudo.

5.1 PAR DE IMAGENS EM INTENSIDADE MULTI-LOOK

Opção que executa a classificação MaxVer/ICM baseada em duas imagens em intensidade *n-looks* (Z_1 e Z_2). Inicialmente, deverão ser escolhidas duas imagens em intensidade e o arquivo de *ROIs*, além da entrada do *nel*. Em seguida, o sistema ativará para cada classe, a GUI correspondente à Figura 1(a).

Essa interface exibe o histograma e a distribuição bidimensionais do par de imagens em intensidade, ambos em perspectiva e em curvas de nível. Os parâmetros estimados são mostrados abaixo dos gráficos.

Como todas as interfaces mostradas neste trabalho, a da Figura 1 é totalmente interativa com o usuário, que pode especificar o intervalo que os gráficos serão desenhados (*Min x*, *Max x* e *Max z*), qualquer rotação desejada (*Rot x* e *Rot z*) e o número de curvas de nível usadas (*NLevels*). Estas opções estimulam grandemente a interação do usuário com os dados, contribuindo para a sua familiarização com os dados e possibilitando a descoberta de novas informações, estruturas, padrões etc. Os valores de entrada alteram todas as sub-janelas, uma vez que eles são conectados para ajudar a visualização.

Após a visualização da Figura 1(a) para cada classe, o sistema executa a classificação MaxVer, ao final da qual ativa a GUI correspondente à Figura 1(b). O usuário pode, então, escolher interativamente as densidades de cada classes que irão ser visualizadas (em perspectiva e em curvas de nível), bem como o ponto de vista e o número de curvas de nível da densidade. Cada densidade é associada a uma única cor. O classificador MaxVer é baseado na equação (4).




Figura 1 – (a) Interface com o histograma, curvas de nível, densidade do par de imagens em intensidade e as estimativas dos parâmetros de uma dada classe; (b) Interface com as densidades das classes de interesse.

A imagem gerada pelo algoritmo MaxVer é usada como configuração inicial pelo algoritmo ICM. Os critérios de parada dessa técnica iterativa são o percentual de pixels reclassificados de uma iteração para outra ou o número máximo de iterações, ambos definidos pelo usuário.

5.2 IMAGEM DIFERENÇA DE FASE *MULTI-LOOK*

Opção que executa a classificação MaxVer/ICM para uma imagem diferença de fase *n-looks* (Ψ). Inicialmente, deverão ser escolhidas duas imagens em intensidade *n-looks* (Z_1 e Z_2), a imagem complexa correspondente (Z_{12}) e o arquivo de *ROIs*, além da entrada do *nel*, de modo que a imagem diferença de fase será criada a partir da imagem complexa. Após a entrada desses parâmetros, a *GUI* correspondente à Figura 2(a) é mostrada, para cada classe, com o histograma das amostras da classe, a distribuição e os seus respectivos parâmetros.

Em seguida, o sistema dará início a classificação MaxVer, baseada na equação (5). Terminada a classificação MaxVer o sistema ativará a *GUI* correspondente à Figura 2(b), onde são mostradas as densidades da imagem diferença de fase *n-looks*, de todas as classes, possibilitando visualizar a separabilidade entre as classes. Em seguida, sobre a imagem gerada pelo algoritmo MaxVer, será aplicado o algoritmo ICM.




Figura 2 – (a) Interface com o histograma, densidade da imagem diferença de fase *n-looks* e as estimativas dos parâmetros de uma dada classe; (b) Interface com as densidades associadas as classes de interesse.

5.3 RAZÃO DE IMAGENS EM INTENSIDADE *MULTI-LOOK*

Opção que executa a classificação MaxVer/ICM baseada na razão de imagens em intensidade *n-looks* (W). Inicialmente, deverão ser escolhidas duas imagens em intensidade *n looks* (Z_1 e Z_2), e o arquivo de *ROIs*, além da entrada do *nel*, de modo que a imagem razão criada será da forma $W = Z_1/Z_2$. É

importante mencionar que o sistema verificará se existem pixels da imagem Z_2 iguais a zero, de modo que para esses pixels o resultado da razão será zero.

Os demais passos, desde a entrada dos dados até a geração da imagem classificada pelo algoritmo ICM, são os mesmos descritos na Seção 5.2. A diferença reside em que esta classificação MaxVer é baseada na equação (6).

5.4 PAR DE IMAGENS INTENSIDADE-DIFERENÇA DE FASE *MULTI-LOOK*

Opção que executa a classificação MaxVer/ICM baseada em uma imagem em intensidade *n-looks* (Z_1) e em uma imagem diferença de fase (Ψ). Inicialmente, deverão ser escolhidas duas imagens em intensidade *n-looks* (Z_1 e Z_2), a imagem complexa correspondente (Z_{12}) e o arquivo de *ROIs*, além da entrada do *nel*, sendo que a imagem diferença de fase será criada a partir da imagem complexa. A imagem em intensidade a ser utilizada na classificação será a primeira que foi escolhida.

Os passos seguintes à seleção das imagens até o resultado final (imagem classificada pelo algoritmo ICM), são idênticos aos descritos na Seção 5.1, sendo o classificador MaxVer baseado na equação (7).

5.5 IMAGENS MULTIVARIADAS COMPLEXAS *MULTI-LOOK*

Opção que executa a classificação MaxVer/ICM baseada na distribuição mais ajustada às observações de cada classe, utilizando-se os dados multivariados complexos *n-looks*, conforme a teoria descrita na Seção 3. Inicialmente, deverão ser escolhidas as imagens em intensidade ($Z_{hh}^{(n)}$, $Z_{hv}^{(n)}$ e $Z_{vv}^{(n)}$), as imagens complexas correspondentes ($Z_{hhv}^{(n)}$, $Z_{hvv}^{(n)}$ e $Z_{vvv}^{(n)}$) e o arquivo de *ROIs*, além da entrada do *nel*. Em seguida, o sistema ativará a *GUI* correspondente à Figura 3(a), onde o usuário escolherá as distribuições a serem testadas para as classes, podendo ainda realizar a decorrelação das amostras de cada classe. Essa decorrelação é importante, pois no teste χ^2 , utilizado para verificar o ajuste das amostras de uma classe a uma determinada distribuição, pode-se supor que os dados decorrelacionados são independentes.

Uma vez selecionadas as distribuições, será ativada a *GUI* correspondente à Figura 3(c), onde são mostrados, para as componentes em intensidade HH, HV e VV, os histogramas dos dados, as densidades com as estimativas dos respectivos parâmetros e o resultado do teste χ^2 (*p-valor* e valor da estatística do teste χ^2) para cada distribuição selecionada. O usuário tem a opção de melhorar a visualização de uma janela determinada através das opções que aparecem na parte inferior da Figura 3(c) (*Display for change range, Min x, Max x e Apply*).

Para cada componente polarimétrica é selecionada a distribuição que ofereça o melhor ajuste ao teste χ^2 (menor valor da estatística do teste χ^2), sendo a mesma destacada com um quadro branco no seu respectivo gráfico. A melhor distribuição de uma dada classe será aquela que possuir melhor ajuste na maioria (2 ou 3) das componentes polarimétricas. No caso em que cada distribuição seja a melhor em uma componente, ou seja, não aconteça a maioria, será escolhida aquela que apresentar a menor média entre os valores da estatística do teste χ^2 das componentes polarimétricas.




Figura 3 – (a) Interface para escolha das distribuições; (b) Interface com as distribuições mais ajustadas para cada classe; (c) Interface com os ajustes das distribuições selecionadas para uma dada classe, com os dados de cada componente em intensidade (HH, HV e VV).

Após a análise para todas as classes ou, caso o botão *Cancel* (Figura 3(a)) seja pressionado, é ativada a GUI correspondente à Figura 3(b), onde são mostradas as distribuições que melhor se ajustaram às observações de cada classe, tendo o usuário a opção de escolha da distribuição que lhe seja mais conveniente. Realizada a seleção das distribuições de cada uma das classes, o sistema dará início a classificação MaxVer, baseada nas equações (3), (8) e (9), de acordo com as distribuições selecionadas. Em seguida, sobre a imagem MaxVer é aplicado o algoritmo ICM segundo a metodologia já mencionada.

6 RESULTADOS

Com objetivo de apresentar a operacionalidade do sistema desenvolvido, bem como de avaliar o conteúdo de informação presente nos diversos formatos polarimétricos, são apresentados aqui os resultados obtidos com as imagens da missão *Space Shuttle SIR-C/X-SAR* (Soares, 1996), bandas L e C, tipo MLC (*Multi-Look Complexo*), com número nominal de *looks* igual à 4.7854018. O espaçamento de pixels é de 12.5 x 12.5 metros. Essas imagens foram obtidas em 14/04/1994, sobre o Projeto de Irrigação de Bebedouro, com pivôs contendo diferentes cultivos de milho e soja, situado na

região do Sub-médio São Francisco ($09^{\circ}07' S$, $40^{\circ}18' W$), cerca de 40 Km ao nordeste do município de Petrolina, estado de Pernambuco, Brasil. Na Figura 4, pode-se observar cada uma das componentes polarimétricas (HH, HV e VV) em amplitude, para as bandas C e L, que fornecem informações diferentes da cena imageada.




Figura 4 - Imagem SIR-C de Bebedouro, com as componentes: (a) C-HH, (b) C-HV, (c) C-VV, (d) L-HH, (e) L-HV e (f) L-VV.

Como pode-se observar na Figura 4, existem quatro pivôs centrais (irrigação por aspersão) na área de estudo, dentro dos quais encontram-se diferentes estágios de cultivo de soja e milho. Desta forma, foram utilizadas as classes apresentadas na Figura 5, identificadas através das amostras de treinamento (Figura 5(a)) e teste (Figura 5(b)), onde foram considerados como classes distintas três estágios de soja e dois de milho, conforme descrito em Correia (1998), além de outras classes de interesse existentes na área de estudo.

Como mostrado em Correia (1998), de posse das amostras de treinamento das classes foram realizadas todas as combinações possíveis entre as componentes polarimétricas, para as bandas C e L, para cada um dos classificadores MaxVer/ICM baseados nas distribuições univariadas (razão de imagens em intensidade e diferença de fase), bivariadas (par de imagens em intensidade e par de imagens intensidade-diferença de fase) e multivariadas complexas.

Com a finalidade de avaliar os resultados obtidos com os classificadores MaxVer/ICM implementados, para os dados polarimétricos, utilizou-se como uma das bases de comparação os resultados obtidos através do sistema desenvolvido por Vieira (1996) e incorporado ao software ENVI, que utiliza na classificação MaxVer, as distribuições oriundas do modelo multiplicativo (Yanasse, 1993; Frery et al.,

1997), mais apropriadas para imagens SAR monoespectrais em amplitude (baseada nas áreas com diferentes graus de homogeneidade), além do algoritmo ICM para vizinhança oito. A outra base de comparação foi a opção também incorporada por Vieira (1996) ao software ENVI, que utiliza na classificação MaxVer, a distribuição Normal Multivariada para todas as classes de interesse provenientes das imagens SAR multivariadas em amplitude, além do algoritmo ICM. O motivo dessa comparação se deve ao fato que os resultados obtidos em Vieira (1996), através das distribuições mais ajustadas juntamente com o algoritmo ICM, foram bastante significativos e demonstraram um grande avanço no campo das classificações digitais de imagens SAR.




Figura 5 - Composição colorida (R-HH, G-HV e B-VV) da imagem de Bebedouro com as amostras de: (a) treinamento e (b) teste, das classes de interesse.

De posse das classificações MaxVer e ICM, para cada tipo de dado SAR *multi-look*: univariados em amplitude (utilizando-se as distribuições mais apropriadas), polarimétricos uni/bivariados, multivariados em amplitude (utilizando-se a distribuição Normal multivariada) e multivariados complexos, para as bandas L e C, foram geradas as respectivas matrizes de confusão dessas classificações, utilizando-se as amostras de testes (Figura 5(b)).

Devido à grande quantidade de classificações geradas no decorrer do trabalho, são mostrados na Tabela 1 apenas os valores de Kappa ($\hat{\kappa}$) e das respectivas variâncias ($s_{\hat{\kappa}}^2$) das melhores classificações ICM para cada tipo de dado SAR utilizado: Monoespectral C-VV, Par-Intensidade L-HV VV, Multivariado em Amplitude na banda L, Multivariado Complexo na banda L. Além desses valores, são mostradas as classificações dos dados polarimétricos uni/bivariados: Razão L-HHVV, Intensidade-Fase L-HHVV, Par-Intensidade C-HV VV e Par-Intensidade L-HV VV, que melhor discriminaram cada classe de interesse. Na Figura 6, todas essas classificações podem ser vistas.

Os valores das classificações MaxVer que levaram às melhores ICM foram colocadas na Tabela 1 para mostrar a melhora que ocorre quando o algoritmo ICM é aplicado sobre uma imagem classificada pelo algoritmo MaxVer. Essa melhora pode ser comprovada visualmente na Figura 6(a) e (b), que são as classificações MaxVer e ICM, respectivamente, da imagem monoespectral em amplitude C-VV, onde a classificação ICM apresenta um aspecto mais suave do que a MaxVer. Essa suavidade da classificação ICM em relação à respectiva classificação MaxVer foi constatada em todas as situações estudadas neste

trabalho, e está em acordo com as propriedades teóricas do algoritmo ICM (Frery, 1993; Besag, 1986, 1989).

Tabela 1 – Estimativas do coeficiente de concordância Kappa ($\hat{\kappa}$) e de suas variâncias ($s_{\hat{\kappa}}^2$).

CLASSIFICAÇÃO	$\hat{\kappa}$		$s_{\hat{\kappa}}^2 (\times 10^{-5})$	
	MaxVer	ICM	MaxVer	ICM
Monoespectral C-VV	0,3879	0,5737	2,022	2,007
Razão L-HHV	0,2565	0,3572	1,399	1,507
Intensidade-Fase L-HHV	0,4431	0,6062	2,165	1,998
Par-Intensidade C-HVV	0,5506	0,5824	2,032	1,987
Par-Intensidade L-HHV	0,5116	0,6498	2,080	1,904
Par-Intensidade L-HVV	0,5295	0,6824	2,028	1,714
Multivariado Amplitude na banda L	0,6003	0,7726	1,921	1,433
Multivariado Complexo na banda L	0,6747	0,8254	1,786	1,191

Com base na Tabela 1, foram realizados os testes de hipóteses para verificação da igualdade dos coeficientes de concordância $\hat{\kappa}$, entre as melhores classificações MaxVer e ICM para cada tipo de dado SAR, sendo todas as classificações estatisticamente diferentes aos níveis de significância de ordem prática. Com isso pode-se afirmar que:

1. A classificação MaxVer das imagens Multivariadas complexas na banda L, por possuir um valor de $\hat{\kappa}$ superior, apresenta um resultado 73,93%, 27,42% e 12,39% melhor, quando comparada com as classificações MaxVer das imagens Par-Intensidade L-HVV, Monoespectral C-VV e Multivariado em Amplitude da banda L, respectivamente;
2. A classificação MaxVer das imagens Multivariadas complexas na banda L, por possuir um valor de $\hat{\kappa}$ superior, apresenta um resultado 43,88%, 20,95% e 6,84% melhor, quando comparada com as classificações ICM das imagens Par-Intensidade L-HVV, Monoespectral C-VV e Multivariado em Amplitude da banda L, respectivamente;
3. As classificações ICM foram, em média, 31,94% melhores que as classificações MaxVer.

Destes resultados observa-se que o aumento da informação utilizada nas classificações de imagens SAR produziu diferenças cada vez menores entre os resultados dessas classificações. Entretanto, analisando-se a Figura 6(b), (g), (h) e (i), verifica-se que as classificações Monoespectral C-VV, Par-Intensidade L-HVV, Multivariado em Amplitude na banda L, Multivariado Complexo na banda L, foram capazes de discriminar, respectivamente, três, seis, oito e nove classes. Desta forma, conclui-se que, através de uma modelagem contextual mais adequada para os dados complexos, conseguiu-se um melhor resultado no valor de $\hat{\kappa}$ e a discriminação de todas as classes de interesse, o que não foi possível com as demais classificações.




Figura 6 - Classificações: (a) MaxVer C-VV (b) ICM C-VV; (c) Par-Intensidade ICM L-HHV; (d) Razão L-HHV; (e) Par Intensidade-Fase ICM L-HHV; (f) Par-Intensidade ICM C-HHV; (g) Par-Intensidade L-HHV; Multivariado na banda L (h) em Amplitude e (i) Complexo.

Dos resultados apresentados, é importante destacar que, no caso dos dados multivariados complexos não estiverem disponíveis, a utilização dos dados polarimétricos uni/bivariados pode produzir bons resultados. Este fato é observado na Figura 6(c), (d), (e), (f) e (g), onde cada uma dessas classificações forneceu uma melhor discriminação de certas classe. Pode-se concluir, a partir dessas classificações, que as classes Rio e Solo Preparado são melhor classificadas com a banda C, enquanto que as demais são melhor classificadas com a banda L. Além disso, é importante notar que existe uma grande confusão entre as classes Soja2 e Milho2.

Estes resultados mostram que a utilização dos dados polarimétricos uni/bivariados não permite separar a classe Soja2 da classe Milho2. Além disso, não foi possível discriminar, em uma mesma classificação

da imagem considerada, mais do que três classes com a banda C, nem mais do que seis classes com a banda L. Entretanto, dependendo do tipo de aplicação desejada, a utilização dos dados polarimétricos uni/bivariados pode produzir bons resultados, principalmente, se a informação de fase estiver disponível, indicando o aspecto complementar desse tipo de dado SAR (Correia, 1998).

7 CONCLUSÕES

A investigação, implementação e teste de classificadores MaxVer e ICM para imagens SAR polarimétricas *multi-look* foram os objetivos deste trabalho. Pode-se considerar que as rotinas de classificação MaxVer/ICM implementadas conseguiram atender aos seguintes requisitos:

1. Operacionalidade: todas as rotinas de classificação estão totalmente operacionais.
2. Uso da informação contextual: o algoritmo ICM, desenvolvido por Vieira (1996) foi incorporado dentro das rotinas de Classificação MaxVer, proporcionando melhores resultados.
3. Iteratividade com usuário: o sistema implementado funciona através de interfaces gráficas e toda a modelagem estatística utilizada é totalmente transparente ao usuário; a sequência de passos requerida para a obtenção de uma classificação é um conhecimento modelado e incorporado ao sistema. Caso o usuário não execute todos os passos necessários, o sistema o faz por ele (caso as informações estejam disponíveis) ou solicita que sejam realizados.
4. Integração ao software ENVI: todas as rotinas implementadas encontram-se disponíveis dentro do software ENVI, de tal forma que todas as funções originais desse software podem ser aproveitadas nas imagens de interesse.
5. Potencialidade: os resultados demonstram o grande potencial de aplicações das rotinas implementadas, para a classificação de imagens SAR polarimétricas.
6. Contribuição estatística: a distribuição G_C^0 multivariada é um modelo interessante que permite explicar dados que não são bem descritos pelos modelos clássicos, e produziu excelentes classificações.

A versão do sistema aqui apresentado somente permite que dados multivariados complexos de uma mesma banda possam ser classificados conjuntamente. Entretanto, este sistema será aperfeiçoado, incluindo a possibilidade do usuário utilizar em uma mesma classificação, os dados multivariados complexos de diferentes bandas, por exemplo, banda C com a banda L, utilizando-se para tal, a mesma modelagem descrita neste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abramowitz, M; Stegun, I. **Handbook of mathematical functions**: with formulas, graphs, and mathematical tables. New York: Dover, 1964.
- Besag, J. On the statistical analysis of dirty pictures (with discussion). *Journal of the Royal Statistical Society B*, **48**(3):259-302, 1986.
- Besag, J. Towards Bayesian image analysis. *Journal Applied on Statistic*, **16**(3):395-407, 1989.

- Bishop, Y. M.; Feinberg, S. E.; Holland, P. W. **Discrete multivariate analysis: theory and practice**. Cambridge: MIT Press, 1975. 575p.
- Campbell, J.B. **Introduction to remote sensing**. New York: Guilford Press, 1987. 551p.
- Correia, A.H. *Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas*. Dissertação de Mestrado em Sensoriamento Remoto, Instituto de Nacional de Pesquisas Espaciais, São José dos Campos, SP, 1998.
- Du, L. J.; Lee, J. S. Polarimetric SAR image classification based on target decomposition theorem and complex Wishart distribution. In: IGARSS'96 International Geoscience and Remote Sensing Symposium, Lincoln, May 27–31, 1996. **Remote sensing for a sustainable future**, Piscataway: IEEE, 1996. v.1, p.439–441.
- ENVI 3.0 user's guide: the environment for visualizing images. version 3.0, December 1997 edition. Lafayette: Better Solutions Consulting, 1993–1997. Under contract of Research Systems Inc.
- Frery, A. C. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética**. São José dos Campos. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, 1993.
- Frery, A. C.; Müller, H. J.; Yanasse, C. C. F; Sant'Anna, S.J.S. A Model for extremely heterogeneous clutter. **IEEE Transactions on Geoscience and Remote Sensing**, v.35,n.3,p.1–12, May, 1997.
- Geman, D; Geman, S. Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images. **IEEE Transactions on Pattern Analysis Machine Intelligence**, PAMI-6(6):721–741, 1984.
- Goodman, N. R. Statistical analysis based on a certain multivariate complex gaussian distribution. **Annals of Mathematical Statistics**, v.34,n.1,p.152–177, 1963.
- Gradshteyn, I. S.; Ryzhik, I. M. **Table of integrals, series, and products**. New York: Academic Press, 1980. 1160 p.
- Hudson, W. D.; Ramm, C. W. Correct formulation of the kappa coefficient of agreement. **Photogrammetric Engineering and Remote Sensing**, v.53,n.4,p.421–422, 1987.
- Jakeman, E. On the statistics of K-distributed noise. **Journal of Physics A: Mathematical and General**, v.13, n.1,p.31–48, 1980.
- Jakeman, E.; Pusey, P. N. A model for non-Rayleigh sea echo. **IEEE Transactions on Antennas and Propagation**, v.AP-24,n.6,p.806–814, 1976.
- Kong, J. A. Identification of terrain cover using the optimal polarimetric classifier. **Journal of Electromagnetic Waves and Applications**, v.2,n.2,p.:171–194, 1988.
- Lee, J. S.; Grunes, M. R. Feature classification using multi-look polarimetric SAR imagery. In: IGARSS'92 International Geoscience and Remote Sensing Symposium, Houston, May 26–29, 1992. **International space year: space remote sensing**. Piscataway: IEEE, 1992. v.1,p.77–79.
- Lee, J. S.; Schuler, D. L.; Lang, R. H.; Ranson, K. J. K-distribution for multi-look processed polarimetric SAR imagery. In: IGARSS'94 International Geoscience and Remote Sensing Symposium, Pasadena, Aug. 8–12, 1994. **Surface and atmospheric remote sensing: technologies, data analysis and interpretation**. Piscataway: IEEE, 1994a. v.4,p.2179–2181.

- Lee, J. S.; et al. Intensity and phase statistics of multi-look polarimetric and interferometric SAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*, v.32,n.5,p.1017–1028, Sept, 1994b.
- Lee, J. S.; Miller, A.; Hoppel, K. Statistics of phase difference and product magnitude of multi-look processed Gaussian signals. *Waves in Random Media*, v.4,p.307–319, 1994c.
- Lee, J. S.; Grunes, M. R. Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution. *International Journal of Remote Sensing*, v.15,n.11,p.2299–2311, Sept, 1994.
- Lee, J. S.; Du, L.; Schuler, D. L.; Grunes, M. R. Statistical analysis and segmentation of multi-look SAR imagery using partial polarimetric data. In: *IGARSS'95 International Geoscience and Remote Sensing Symposium*, Firenze, July 10–14, 1995. **Quantitative remote sensing for science and applications**. Piscataway: IEEE, 1995. v.3, p.1422–1424.
- Lim, H. H.; et al. Classifications of Earth terrain using polarimetric SAR images. *Journal of Geophysical Research*, v.94,n.B6,p.7049–7057, June, 1989.
- Ma, Z.; Redmond, R. L. Tau coefficient for accuracy assessment of classification of remote sensing data. *Photogrammetric Engineering and Remote Sensing*, v.61,n.4,p.453–459, 1995.
- Nezry, E.; Lopés, A.; Ducrot-Gambart, D.; Nezry, C.; Lee, J.S. Supervised classification of K-distributed SAR images of natural targets and probability of error estimation. *IEEE Transactions on Geoscience and Remote Sensing*, v.34,n.5,p.1233–1242, Sept. 1996.
- Quegan, S.; Rhodes, I. Statistical models for polarimetric data: consequences, testing and validity. *International Journal of Remote Sensing*, v.16,n.7,p.1183–1210, Sept. 1995.
- Srivastava, M. S. On the complex Wishart distribution. *Annals of Mathematical Statistics*, 36(1):313–315, 1963.
- Tur, M.; Chin, K.C.; Goodman, J.W. When is speckle noise multiplicative? *Applied Optics*, v.21,p.1157–1159, 1982.
- Ulaby, F. T.; Moore, R. K.; Fung, A. K. **Microwave remote sensing: active and passive**. Norwood: Artech House, 1986. 1097p. v. 3.
- Ulaby, F. T.; Elachi, C. **Radar polarimetry for geoscience applications**. Norwood: Artech House, 1990. 364p.
- Vieira, P. R. **Desenvolvimento de classificadores de maxima verossimilhança e ICM para imagens SAR**. São José dos Campos. 251p. (INPE-6124-TDI/585). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto de Nacional de Pesquisas Espaciais, 1996.
- Yanasse, C. C. F; Frery, A.C.; Sant'Anna, S.J.S.; Hernandes, P. F.; Dutra, L. V. Statistical analysis of SAREX data over Tapajós-Brazil. In: *South American Radar Experiment for SAREX'92*, Paris, 1993, p. 25–40 (ESAWPP-76).
- Yanasse, C. C. F; Frery, A.C.; Sant'Anna, S.J.S. Stochastic distributions and the multiplicative model; relations, properties, estimators and applications to SAR image analysis. INPE, São José dos Campos, 1995. (INPE-5630-NTC/318).

