

## **UTILIZAÇÃO DE IMAGENS DE RADAR DE ABERTURA SINTÉTICA NA CLASSIFICAÇÃO DE USO E OCUPAÇÃO DO SOLO**

Corina da Costa FREITAS, PhD.  
Sidnei João Siqueira SANT'ANNA, MsC  
Camilo Daleles RENNÓ, MsC  
Antonio Henrique CORREIA, MsC  
Instituto Nacional de Pesquisas Espaciais (INPE)  
12227-010  
Av. dos Astronautas, 1758 – São José dos Campos  
e-mail: [corina,sidnei,camilo,correia]@dpi.inpe.br

### **1.1. INTRODUÇÃO**

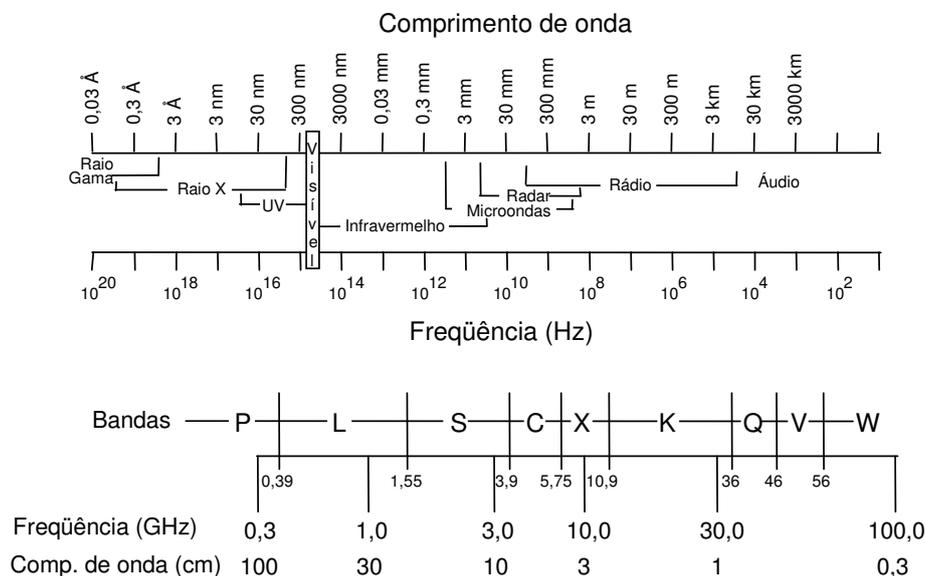
Há décadas que o sensoriamento remoto vem sendo utilizado como ferramenta para o mapeamento da superfície terrestre. Os primeiros produtos de sensoriamento remoto, tais como as fotografias aéreas, apresentam altos custos de obtenção e sofrem grande restrição temporal e espacial. Estas restrições se devem ao fato de que, geralmente, o levantamento aerofotogramétrico é realizado em pequenas regiões e em grandes intervalos de tempo. Com o advento dos sensores orbitais, grandes áreas puderam ser imageadas com uma certa periodicidade, o que possibilitou a realização de estudos multitemporais em extensas regiões a um custo relativamente baixo.

Os sensores podem ser classificados de acordo com a região do espectro eletromagnético em que operam, cujas principais faixas podem ser vistas na Figura 1. Dentro do sensoriamento remoto, os sensores nos quais os especialistas possuem mais experiência são os ópticos. Estes sensores são classificados desta maneira por operarem na faixa óptica do espectro eletromagnético, região esta que compreende comprimentos de onda variando de 0,30 a 15,0 $\mu$ m. Os sensores ópticos podem ser classificados, em função do tipo de energia que detectam, como sensores termais e de energia refletida, cujas regiões de operação são 7,0 a 15,0 $\mu$ m e 0,38 a 3,0 $\mu$ m, respectivamente. Algumas desvantagens associadas ao uso destes sensores são a necessidade de uma fonte externa de iluminação (sensor passivo), excetuando-se os sensores termais, e a grande dependência das condições climáticas.

Devido a limitações na obtenção de imagens de sensores ópticos, outros sensores podem ser utilizados operando em diferentes faixas do espectro eletromagnético, entre elas a faixa de microondas. A faixa de microondas é dividida em bandas, designadas por letras, e está mostrada em detalhes na Figura 1. Os sensores que operam nesta faixa possuem a grande vantagem de poderem adquirir dados independentemente da iluminação solar e de serem pouco influenciados pelas condições atmosféricas, uma vez que a transmitância atmosférica é praticamente total para a faixa de microondas. Esta característica é particularmente interessante para regiões tropicais, onde sensores ópticos sofrem grande restrição devido à alta probabilidade de ocorrência de nuvens.

Os sensores de microondas podem ser divididos em dois grupos básicos: passivos (radiômetros) e ativos (radares). Os radiômetros de microondas detectam a energia emitida pelo alvo analisado, já que o espectro de emissão solar apresenta quantidades praticamente nulas de energia na faixa de microondas e, então, a parcela de microondas refletida é desprezível. Os radares, por sua vez, possuem sua própria fonte de energia na faixa de microondas e captam a energia refletida pelo alvo em estudo nesta faixa do espectro eletromagnético. O termo RADAR, acrônimo de *RA*dio

*Detection And Ranging*, define que o dispositivo é capaz de detectar um objeto (alvo), indicando sua distância (*range*) e posição (Trevett, 1986). Pelo fato de medir distâncias, o radar possui um problema de ambigüidade, uma vez que alvos localizados à mesma distância da antena são indistingüíveis pelo sistema

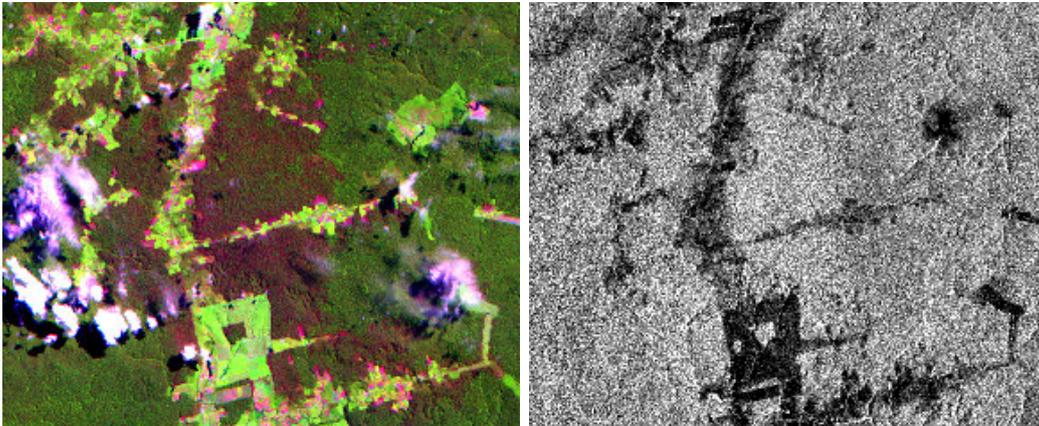


**Figura 1 - Espectro eletromagnético e bandas da região de microondas.**  
**Fonte: Adaptada de Dallemand et al. (1993), p. 4.**

Os sistemas de radar podem ser agrupados em imageadores e não imageadores. Entre os não imageadores destacam-se os escaterômetros e os altímetros. Os radares imageadores compreendem os sistemas de antena rotatória e os de visada lateral (SLAR - *Side Looking Airborne Radar*). A definição de SLAR engloba dois tipos de radar: o de abertura real (RAR - *Real Aperture Radar*) e o de abertura sintética (SAR - *Synthetic Aperture Radar*). O SLAR, por possuir visada lateral, diminui o problema de ambigüidade.

Os processos de formação das imagens ópticas e de radar são muito distintos, assim como as características apresentadas por cada uma delas, uma vez que os sensores detectam informações diferentes. Na Figura 2, é mostrada uma imagem óptica do sensor TM-Landsat (composição colorida, com a banda 5 colocada no canal vermelho, a banda 4 no canal verde e a banda 3 no canal azul - 5R, 4G e 3B) adquirida em 29 de maio de 1993 e uma imagem SAR do satélite JERS-1 (banda L e polarização HH) obtida em 26 de junho de 1993, a fim de se evidenciar as diferenças na formação e entre as características de ambas. Na imagem do TM-Landsat, observa-se a influência das condições atmosféricas (nuvens) acarretando a perda de informação das áreas sob as nuvens e sob suas sombras. Já na imagem do JERS-1, não se nota a influência de nuvens e de suas sombras, porém quando esta imagem é comparada à imagem do TM-Landsat, ela é, de modo geral, visualmente menos rica em informação e detalhes, o que dificulta a interpretação visual deste tipo de imagem. Consideradas as significativas diferenças entre imagens ópticas e de radar, principalmente no que concerne ao comportamento dos dados, muitas das técnicas utilizadas no processamento de imagens ópticas não se adequam perfeitamente às imagens de radar. Portanto, para a extração de informações das imagens de radar se faz necessário o desenvolvimento de ferramentas (técnicas) específicas para a análise dos dados provenientes de radar, tais como filtros, segmentadores, classificadores,

entre outras. É neste contexto que se insere este trabalho, enfatizando aspectos relativos à classificação de imagens de radar de abertura sintética.



**Figura 2 - Imagens óptica (TM-Landsat) e de radar (JERS-1).**

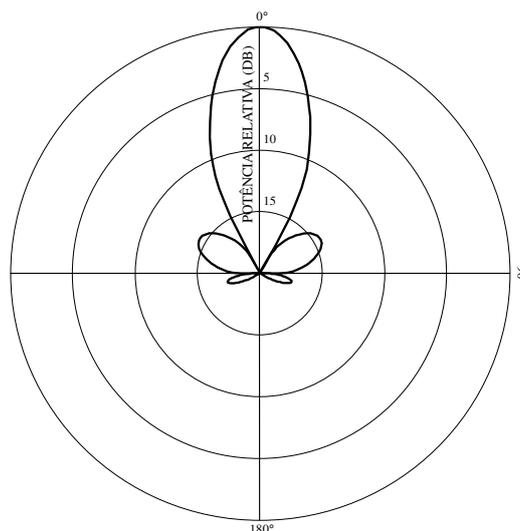
Este trabalho está organizado em seções. Na Seção 1.2, são descritas as principais características dos sistemas de radar, que incluem a geometria de imageamento e alguns parâmetros relacionados ao sensor. A influência de alguns parâmetros do alvo e do sensor sobre o coeficiente de retroespalhamento é discutida na Seção 1.3. A formação e a representação de imagens SAR, bem como os principais problemas encontrados no imageamento da superfície terrestre por este sensor, são apresentados na Seção 1.4. A Seção 1.5 é utilizada para descrever a modelagem dos dados SAR, monoespectrais e polarimétricos. Na Seção 1.6 são apresentadas diferentes abordagens para a descrição de textura em imagens. A classificação de imagens é discutida na Seção 1.7, onde são apresentados três tipos de classificadores: pontual, pontual/contextual e por regiões. Alguns exemplos de classificação de imagens SAR, utilizando estes classificadores, são apresentados na Seção 1.8.

## **1.2. SISTEMA DE RADAR**

Os sistemas de radar são, geralmente, compostos por um transmissor, um receptor, um modulador, um processador e uma antena. As principais características e propriedades da antena de um sistema de radar são: polarização, diagrama de radiação, largura de feixe, lóbulos laterais, diretividade, ganho, impedância de entrada, área de recepção e reciprocidade. Definir-se-á, a seguir, apenas as características encontradas mais freqüentemente na literatura de sensoriamento remoto por radar e a ser utilizadas neste trabalho.

A polarização é definida como a orientação segundo a qual oscila, no tempo, o vetor campo elétrico da onda eletromagnética. Esta orientação pode determinar uma polarização do tipo linear, circular ou elíptica. A polarização é dita linear quando a orientação do campo elétrico varia segundo uma linha reta, que pode ainda ser horizontal ou vertical. A onda eletromagnética é dita horizontalmente polarizada quando o vetor do campo elétrico é perpendicular ao plano de incidência da onda (plano que contém o vetor normal à superfície e o vetor de propagação da onda) ou de maneira geral, quando o vetor do campo elétrico é paralelo à superfície imageada. Usualmente, os sistemas de radar utilizam polarizações lineares paralelas, HH e VV, ou cruzadas, HV e VH (a primeira letra refere-se à polarização da radiação transmitida e a segunda à polarização da radiação recebida pela antena).

A função que descreve o comportamento da potência relativa da radiação de uma antena de sistemas de radar com relação à direção de propagação é chamada diagrama de radiação ou padrão de radiação da antena (Figura 3), a qual define o ganho da antena. Estas antenas são anisotrópicas, isto é, possuem uma direção preferencial para transmissão e recepção da radiação eletromagnética que determina o maior lóbulo (lóbulo principal). A largura do feixe de uma antena é definida como a largura do lóbulo principal nos pontos nos quais a potência é reduzida pela metade. Os lóbulos laterais, mostrados na Figura 3, são denominados lóbulos secundários. Estes últimos são indesejáveis, uma vez que podem interferir na radiação detectada.



**Figura 3 - Diagrama de radiação de uma antena.**

O imageamento por radar consiste da emissão de pulsos de microondas a intervalos regulares sobre a região de interesse e a recuperação dos sinais de retorno (ecos) provenientes desta região, à medida que o sensor se desloca. A recepção do sinal de retorno pode ser feita utilizando-se a mesma antena emissora (sistemas monoestáticos) ou uma segunda antena (sistemas biestáticos). Nos sistemas biestáticos, cada antena pode possuir características distintas de polarização, dimensão, ângulo de visada, etc. (Ulaby et al., 1986a).

A Figura 4 ilustra a geometria de imageamento de um SLAR, onde se destacam os principais parâmetros relacionados ao imageamento, tais como: ângulo de incidência e de visada, resoluções espaciais em *ground range* (direção no solo perpendicular à direção de vôo) e em *slant range* (direção oblíqua perpendicular à direção de vôo), área imageada, largura do feixe, entre outros.

A resolução espacial (definida como a menor distância na qual se pode discriminar dois alvos) nos SLARs de abertura real é diferente para as direções paralela ao vôo (*along track* ou azimutal) e perpendicular ao vôo (*cross track* ou *range*). De acordo com Ulaby (1982) e a Figura 4, as resoluções espaciais no solo em azimute ( $\rho_a$ ) e em *range* ( $\rho_r$ ) são dadas por:

$$\rho_a = \frac{\lambda h}{\ell \cos(\theta)} \text{ e } \rho_r = \frac{c\tau}{2\text{sen}(\theta)},$$

onde  $\lambda$  é o comprimento de onda (que é proporcional ao inverso da frequência  $f$  utilizada,  $\lambda = c/f$ ),  $c$  é a velocidade da luz,  $h$  é a altura de vôo,  $\ell$  é o tamanho



complexo, tanto em termos de sua construção quanto em termos de processamento do sinal (Ulaby, 1982).

As imagens SAR podem receber um processamento específico a fim de se reduzir o seu ruído característico, denominado *speckle* (Seção 1.4). Este processamento, chamado *multi-look*, consiste em dividir a abertura sintética da antena em alguns setores (*looks*), processando-os independentemente e somando-se em seguida cada um destes *looks*. Este processamento reduz o efeito do *speckle* mas causa a diminuição da resolução azimutal por aproximadamente o mesmo fator. Assim, por exemplo, a resolução azimutal de um sistema SAR que utilize um processamento com  $n$  *looks* é de

$$\rho_a \approx \frac{n\ell}{2}.$$

Ao interessado em mais detalhes sobre os princípios básicos associados aos diferentes tipos de radar, recomenda-se a leitura de Di Cenzo (1981), Ulaby (1982), Ulaby et al. (1986a), Trevett (1986), Ulaby e Dobson (1989), e Dallemand et al. (1993).

### 1.3. COMPORTAMENTO DE ALVOS

A relação fundamental entre as características do sistema de radar, do alvo e do sinal que é transmitido pela antena, que interage com o alvo e novamente retorna para a antena, pode ser resumida através da equação de radar, que, para um sistema monoestático, pode ser definida como:

$$\bar{P}_r = \frac{P_t \lambda^2 G_0^2 \sigma^\circ}{(4\pi)^3 R^4},$$

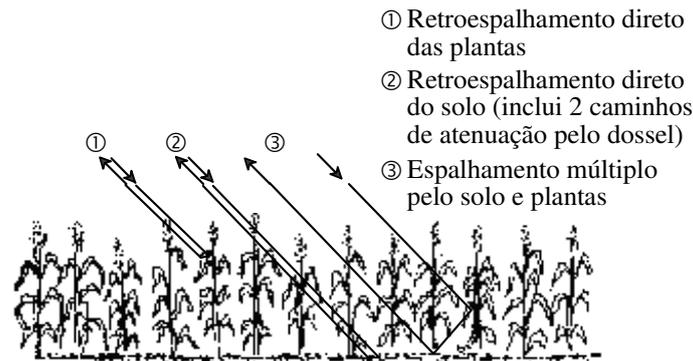
onde  $\bar{P}_r$  é a potência média recebida pela antena,  $P_t$  é a potência transmitida,  $\lambda$  é o comprimento de onda,  $G_0$  é o ganho máximo da antena,  $R$  é a distância entre a antena e o alvo (Figura 4), e  $\sigma^\circ$  é o coeficiente de retroespalhamento (*backscatter*). Pode-se verificar que a potência recebida pela antena é diretamente proporcional ao coeficiente de retroespalhamento, que é o único parâmetro relacionado ao alvo; os demais parâmetros da equação podem ser reunidos, caracterizando o sistema de radar (Ulaby e Dobson, 1989).

Uma célula de resolução, representada na imagem pelo *pixel*, pode ser caracterizada por um conjunto de elementos difusores que, no caso da vegetação, ocupam um certo volume no espaço, distribuídos sobre uma superfície também difusora, representada pelo solo. O sinal de retorno, que chega até a antena proveniente desta célula de resolução, é resultante da soma das contribuições diretas de cada elemento difusor e da superfície, e das reflexões múltiplas entre estes (Ulaby et al., 1984). A Figura 5 mostra esquematicamente as contribuições de um dossel agrícola no retroespalhamento.

Para melhor entender o comportamento do  $\sigma^\circ$  de um alvo, é necessário estudar os fatores relacionados a cada um de seus elementos (ou um conjunto deles). Segundo Ulaby et al. (1986b), estes fatores são:

- a constante dielétrica do alvo, que é fortemente influenciada pelo seu conteúdo de umidade. Para a vegetação, o conteúdo de umidade pode variar significativamente entre os diferentes constituintes do dossel (folhas, troncos e frutos) dependendo do estágio de desenvolvimento, causando, portanto, uma variação da constante dielétrica;

- tamanho, forma e orientação dos elementos difusores do dossel;
- a rugosidade e a constante dielétrica da superfície sob os elementos difusores (o solo, no caso da vegetação); e
- a geometria de distribuição dos elementos difusores (no caso de um dossel agrícola: direção e espaçamento das linhas de plantio da cultura, porcentagem de cobertura, altura da planta, etc.).



**Figura 5 - Contribuições no retroespalhamento de um dossel agrícola.**

Fonte: Ulaby et al. (1984), p. 115.

Outros fatores igualmente importantes são os relativos ao sensor:

- a frequência da onda incidente;
- a direção da onda incidente, definida por  $(\alpha, \phi)$ , onde  $\alpha$  é o ângulo de incidência (Figura 4) e  $\phi$  é o ângulo azimutal relativo à direção de visada; e
- a direção de polarização das antenas de transmissão e recepção.

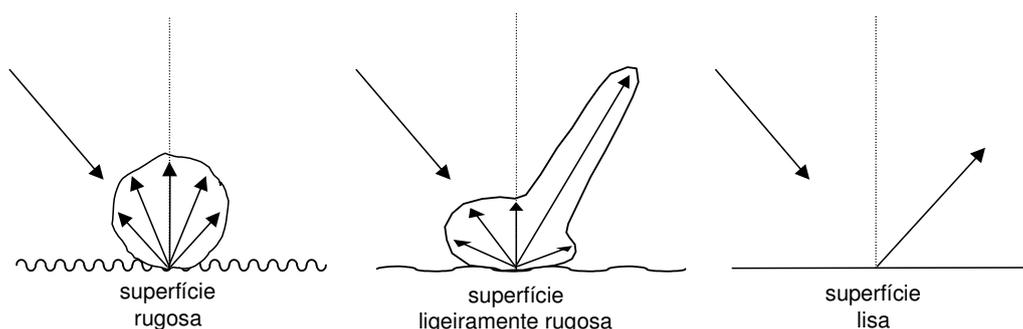
A frequência da onda incidente define a rugosidade relativa do alvo e, juntamente com o ângulo de incidência, determina o grau de penetração da onda no alvo. Segundo Dallemand et al. (1993), uma superfície pode ser considerada lisa, pelo critério de Rayleigh, se

$$r < \frac{\lambda}{8\cos(\alpha)},$$

onde  $r$  é a altura média das variações da superfície,  $\lambda$  é o comprimento de onda e  $\alpha$  é o ângulo de incidência. Desta forma, uma mesma superfície pode ser considerada lisa para um determinado comprimento de onda e rugosa para outros.

Superfícies rugosas refletem a energia emitida pelo sensor de maneira uniforme para todas as direções. Já as superfícies consideradas ligeiramente rugosas possuem uma direção preferencial de reflexão, sendo que as superfícies lisas refletem a energia especularmente (Figura 6).

A maior variação do  $\sigma^{\circ}$ , para solos com alto teor de umidade, se dá em baixas frequências e baixos índices de rugosidade (superfícies mais lisas). As maiores variações do  $\sigma^{\circ}$  em relação à umidade e à rugosidade são observadas para ângulos de incidência próximos à normal ou maiores que  $30^{\circ}$  (Ulaby et al., 1978).



**Figura 6 - Reflexão da energia emitida pelo sensor para diferentes graus de rugosidade da superfície.**

O grau de penetração da onda num alvo também é influenciado pela polarização utilizada pelo sistema (Dallemand et al., 1993). Numa vegetação que possua estrutura predominantemente vertical, como as gramíneas, a atenuação pode ser mais significativa para a polarização VV do que para polarização HH, o que significa maior penetração de ondas horizontalmente polarizadas (Le Toan et al., 1984). Entretanto, Fischer e Mussakowski (1989), estudando dosséis de milho, encontraram maiores valores de retorno para a polarização HH. Isto pode ser explicado pela diferença entre a estrutura desta cultura e a de outras gramíneas. Os mesmos autores levantaram a hipótese de que, talvez, a porção foliar do dossel de milho, que é mais horizontal que vertical, afete o sinal de retorno mais que a porção de hastes que é verticalmente orientada. É evidente que esta resposta também é influenciada por outros parâmetros do sensor, tais como o ângulo de incidência, o comprimento de onda, etc.

As polarizações cruzadas são geradas por múltiplos espalhamentos e conseqüentemente geram espalhamento de menor intensidade, particularmente em superfícies levemente rugosas para ângulos de incidência próximos à normal. Para sistemas monoestáticos, considera-se  $\sigma_{hv}^{\circ} = \sigma_{vh}^{\circ}$  (NASA/JPL, 1986). Segundo Evans et al. (1986), a vegetação normalmente exibe uma alta componente de polarização cruzada.

Para a faixa de microondas, a constante dielétrica da água possui uma ordem de magnitude maior do que a do solo e a da vegetação secos. Dessa forma, pequenas mudanças na umidade podem causar significantes mudanças nas propriedades dieléticas destes alvos (solo e vegetação) e conseqüentemente do  $\sigma^{\circ}$  (Brakke et al., 1981).

Pesquisas têm mostrado que o  $\sigma^{\circ}$  aumenta com o acréscimo da umidade do solo, tanto para solos nus (Ulaby et al., 1978) como para solos vegetados (Ulaby et al., 1979). No último caso, a sensibilidade do  $\sigma^{\circ}$  em relação à umidade do solo decresce com o aumento do ângulo de incidência e/ou da freqüência, devido ao acréscimo da atenuação causada pela vegetação (Bush e Ulaby, 1978). Ulaby et al. (1978) indicaram que a relação entre o  $\sigma^{\circ}$  e a umidade do solo nu foi aproximadamente linear, com alta correlação.

Medidas de campo mostraram um incremento do  $\sigma^{\circ}$  em dosséis com presença de água livre (Brisco et al., 1989). Um exame destes resultados indica que este tipo de dado pode melhorar a separabilidade em culturas como as gramíneas, cuja estrutura do dossel permite armazenar água após precipitação ou irrigação.

A rugosidade é outro importante fator que influencia na resposta do alvo. A descrição completa da rugosidade de uma superfície é muito difícil de ser conseguida. Muitos autores têm utilizado o desvio padrão da variação da altura (ou altura RMS, *Root Mean Square*) para descrever a rugosidade de uma superfície. À nadir ( $\alpha = 0^\circ$ ), o  $\sigma_{hh}^\circ$  decresce rapidamente com o aumento da rugosidade e este decréscimo é mais acentuado para menores freqüências. Para o ângulo de incidência de  $10^\circ$ , o  $\sigma^\circ$  mostra-se pouco dependente com relação à rugosidade. Já para o ângulo de incidência de  $20^\circ$ , há uma inversão da dependência, ou seja, o aumento da rugosidade resulta no aumento do  $\sigma^\circ$  (Ulaby et al., 1978). Segundo Brakke et al. (1981), a vegetação pode atuar sobre o  $\sigma^\circ$  como um fator de incremento da rugosidade da superfície.

Ulaby et al. (1986b), trabalhando com milho e trigo, encontraram correlações positivas entre os valores do  $\sigma^\circ$  e a porcentagem de cobertura até o ponto quando a cultura atingiu a maturação. A partir deste momento, a correlação passou a ser negativa, ou seja, o aumento da porcentagem de cobertura provocou diminuição dos valores do coeficiente de retroespalhamento. Resultados similares foram conseguidos por Fischer e Mussakowski (1989).

Estudando a relação entre o índice de área foliar (IAF) e o  $\sigma^\circ$ , Ulaby et al. (1984) observaram que, para freqüência de 13 Ghz (banda K) e ângulo de incidência de  $50^\circ$ , houve um aumento linear do  $\sigma^\circ$  do dossel, para milho e sorgo, quando incrementou-se o IAF até o valor próximo a 2. A partir deste ponto, a sensibilidade do  $\sigma^\circ$  para o IAF foi praticamente nula. Já para o trigo, esta sensibilidade foi mantida até altos valores de IAF (próximo de 9). Os mesmos autores observaram que, na fase inicial de desenvolvimento (plantas pequenas e IAF < 0,5), o  $\sigma^\circ$  do dossel foi muito afetado pela umidade do solo. Durante a fase de desenvolvimento (IAF > 0,5), o  $\sigma^\circ$  foi dominado pelas folhas. Já no estágio de pré-colheita (IAF < 0,5), o  $\sigma^\circ$  foi dominado pelas contribuições do solo, hastes e espigas. Brakke et al. (1981), analisando a relação entre o IAF e  $\sigma^\circ$ , para as culturas de milho, trigo e sorgo utilizando quatro freqüências (8,6; 13; 17 e 35,6 GHz) nas polarizações HH, HV e VV e com três ângulos de incidência ( $30^\circ$ ,  $50^\circ$  e  $70^\circ$ ), observaram que as maiores correlações entre IAF e  $\sigma^\circ$  ocorreram para a freqüência de 13 GHz, polarização VV e ângulo de incidência de  $30^\circ$ .

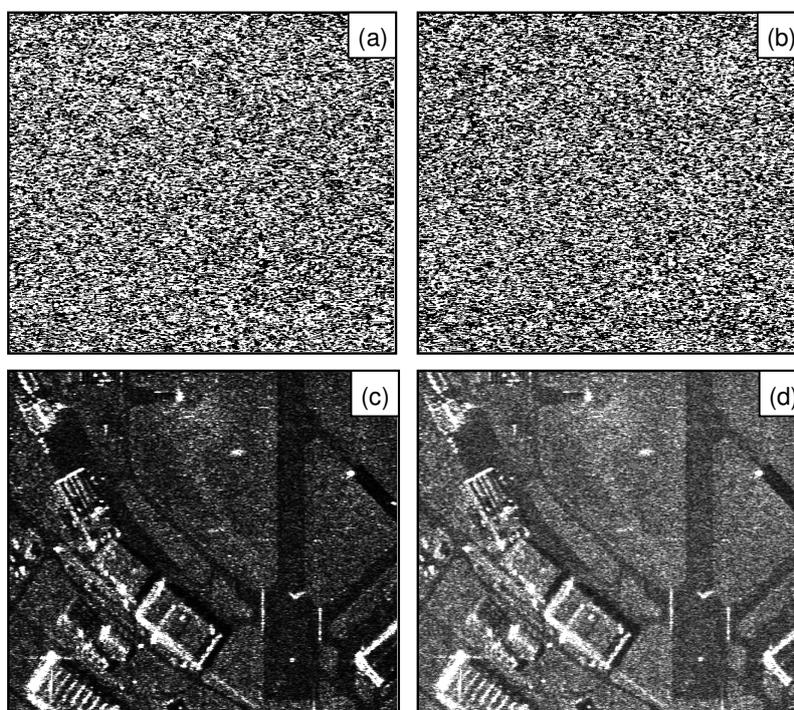
A influência da direção da linha de plantio da cultura sobre o  $\sigma^\circ$  tem sido analisada por muitos autores (Batlivala e Ulaby, 1977; Ulaby et al., 1979; Paris, 1983). Batlivala e Ulaby (1977), comparando as bandas L e C em culturas de sorgo e trigo, notaram um grande efeito da direção da linha para as polarizações HH e VV da banda L. Por outro lado, os efeitos da direção da linha não foram evidenciados para a polarização cruzada da banda L e para qualquer uma das polarizações da banda C. Paris (1983) observou que, em culturas de milho e soja, o efeito da direção da linha sobre o  $\sigma^\circ$  desapareceu quando ângulos de incidência maiores que  $25^\circ$  foram utilizados.

#### 1.4. IMAGENS DE RADAR

A formação de uma imagem SAR requer o processamento coerente do sinal de retorno recebido após a emissão dos pulsos. O processamento do sinal é, geralmente, dividido em duas etapas: o processamento em *range* e o processamento em azimute. O sinal recebido (complexo) de cada pulso emitido é demodulado em fase (*I*) e quadratura (*Q*), amostrado (dada uma função de referência) e convertido para o

formato digital (para formar uma seqüência de dados). A seqüência de dados formada é denominada *range bin* ou *range gate* e irá formar uma linha da imagem, com número de *pixels* dependente da taxa de amostragem empregada no sinal. Esta taxa de amostragem define o espaçamento entre centros de *pixels* (*pixel spacing*). À medida que o sensor se desloca (na direção azimutal), o processamento dos pulsos emitidos irá compor as colunas da imagem (processamento em azimute). Em Mura (1990, 1991) e Fernandes (1993), o processamento SAR para a formação de uma imagem é descrito detalhadamente.

As imagens SAR complexas obtidas pelo processo de demodulação coerente podem ser representadas pelas suas componentes em fase ( $I$ ) e quadratura ( $Q$ ), como dito anteriormente. Contudo, estas imagens ainda podem ser representadas em intensidade ou amplitude, dependendo apenas do tipo de detecção realizada, quadrática ( $I^2 + Q^2$ ) ou linear ( $\sqrt{I^2 + Q^2}$ ), respectivamente. As diferenças existentes entre estas formas de se representar as imagens SAR podem ser observadas na Figura 7, de onde nota-se a impossibilidade de se visualizar qualquer tipo de feição (alvos) nas componentes complexas.



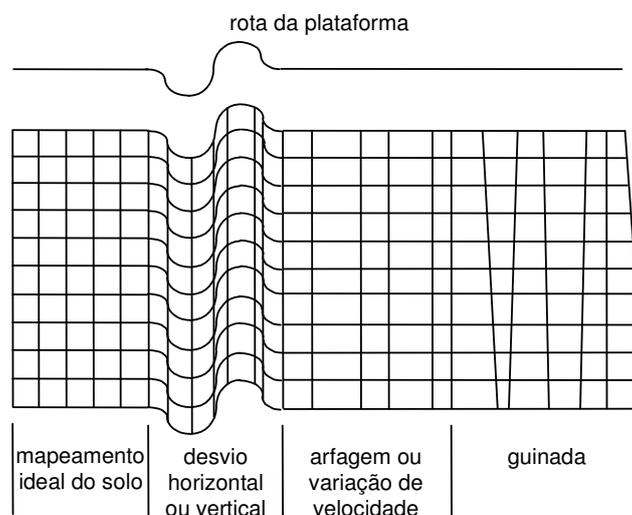
**Figura 7 - Exemplo de uma imagem de radar do sensor aerotransportado AeS-1 (AeroSensing), na banda X, da região de Oberpfaffenhofen, Alemanha, nos formatos: complexo, (a) parte real e (b) parte imaginária; (c) intensidade; e (d) amplitude.**

As imagens em amplitude ou em intensidade resultantes podem ser armazenadas no formato original em 32 *bits*, onde o valor de cada *pixel* é representado por um número real, positivo e de simples precisão. Muitas vezes, este valor pode ser quantizado (discretizado) para 8 ou 16 *bits*, resultando em imagens com 256 ou 65536 níveis de cinza (valores inteiros e positivos), respectivamente. Com o processo de discretização, em geral, procura-se manter a proporcionalidade entre o nível de cinza e o sinal de retorno. É importante lembrar que as propriedades estatísticas da imagem podem ser alteradas com o processo de discretização da imagem, assim como a discriminação de feições.

Os SLARs, dada a sua geometria de imageamento e por medirem distâncias, podem gerar imagens com certas degradações. As principais degradações encontradas nas imagens de radar são as distorções geométrica e radiométrica.

Dentre as distorções geométricas, pode-se citar as relativas às variações nos movimentos da plataforma, a intrínseca à geometria de imageamento e à formação das imagens, e as três principais referentes às dimensões dos alvos imageados: *foreshortening* (encurtamento), *layover* (superposição) e *shadowing* (sombreamento).

Na Figura 8, é mostrado o efeito causado nos *pixels* de uma imagem de radar quando ocorrem algumas variações de movimento da plataforma (sensor): o desvio horizontal e o vertical, a arfagem (*pitch*) e a guinada (*yaw*). Além destes pode ocorrer também a rolagem (*roll*).



**Figura 8 - Distorções causadas pelo movimento da plataforma.**

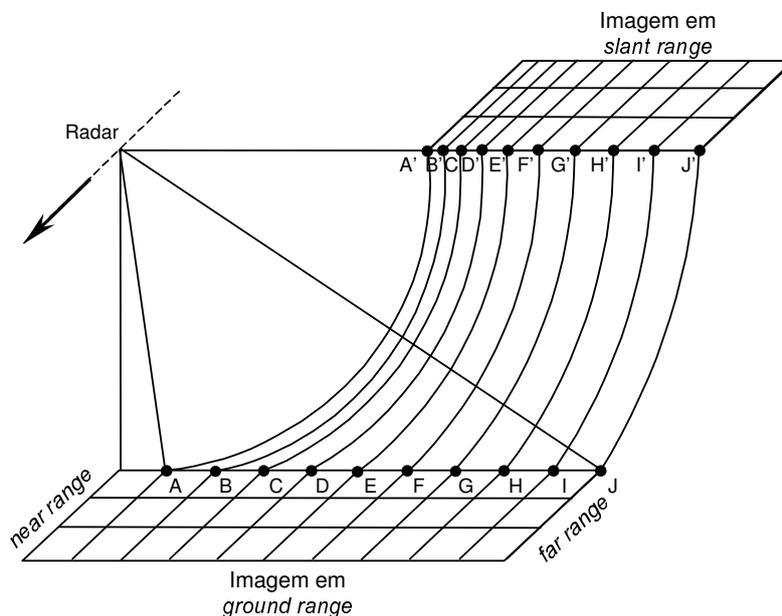
**Fonte: Adaptada de Ulaby et al. (1982), p. 618.**

Dado que as medidas de distâncias feitas pelos SLARs são realizadas em *slant range*, a área imageada no solo para a formação dos *pixels* do *near range* é maior do que aquela para a formação dos *pixels* do *far range*, provocando com isso a compressão das áreas do *near range*. A Figura 9 ilustra a diferença de imagens obtidas em *slant* e em *ground range*.

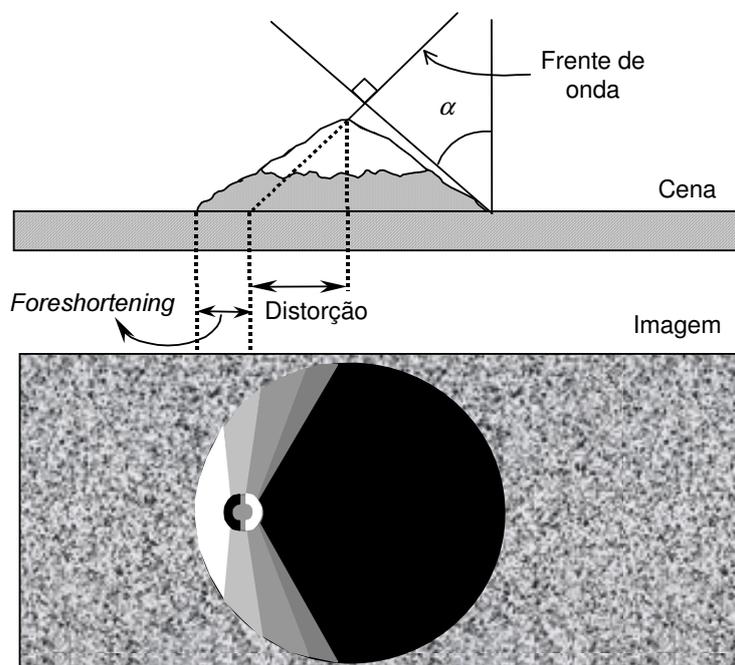
Para regiões com qualquer tipo de elevação, todas as vertentes (rampas) voltadas para o radar apresentam a distorção conhecida como *foreshortening* (Figura 10). Esta distorção é maior para aquelas vertentes com maior ângulo de inclinação. O *layover* (superposição), que é um caso extremo do *foreshortening*, acontece quando a onda eletromagnética refletida de elementos da parte superior de um alvo imageado retorna ao radar antes da refletida pelos elementos da parte inferior, causando na imagem uma inversão do alvo. Para pequenas distâncias alvo-sensor e pequenos ângulos de incidência, o efeito da superposição é mais intenso (Figura 11).

O *shadowing* (sombreamento) ocorre devido à ausência de resposta (sinal de retorno) das partes não iluminadas do alvo imageado (partes não atingidas pelas ondas eletromagnéticas), ocasionando o aparecimento de áreas escuras na imagem. O efeito do sombreamento, para alvos de mesma altura, é mais intenso para aqueles que

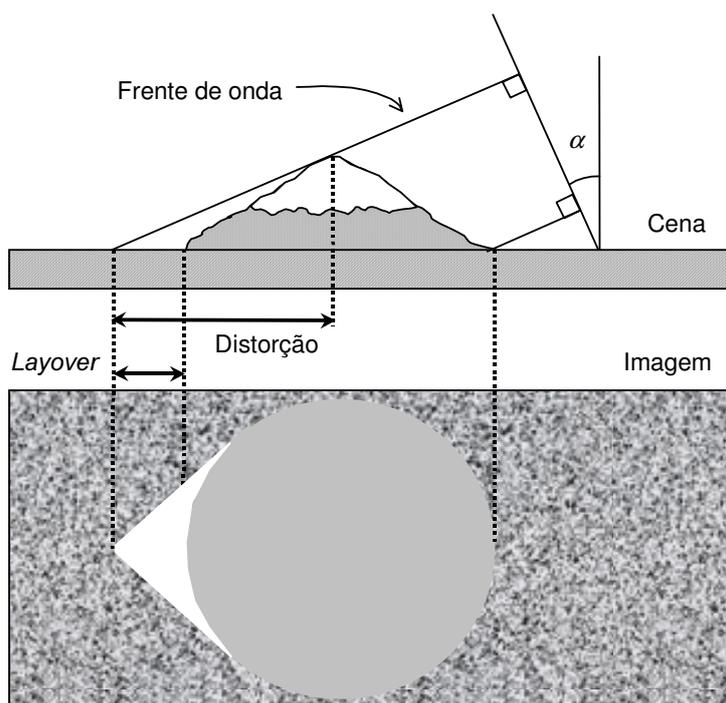
estão mais afastados do sensor e para menores ângulos de depressão, como mostrado na Figura 12, onde  $v_1$  e  $v_2$  são os ângulos de depressão.



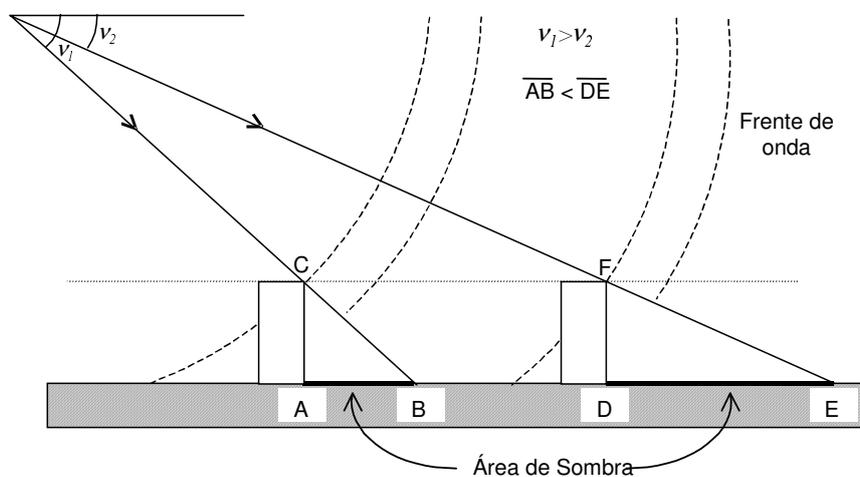
**Figura 9 - Imagens em *slant* e *ground range*.**  
 Fonte: Adaptada de Ahern (1994), p. 27.



**Figura 10 - Caracterização do *foreshortening* nas imagens de radar.**  
 Fonte: Adaptada de Ahern (1994), p. sn.

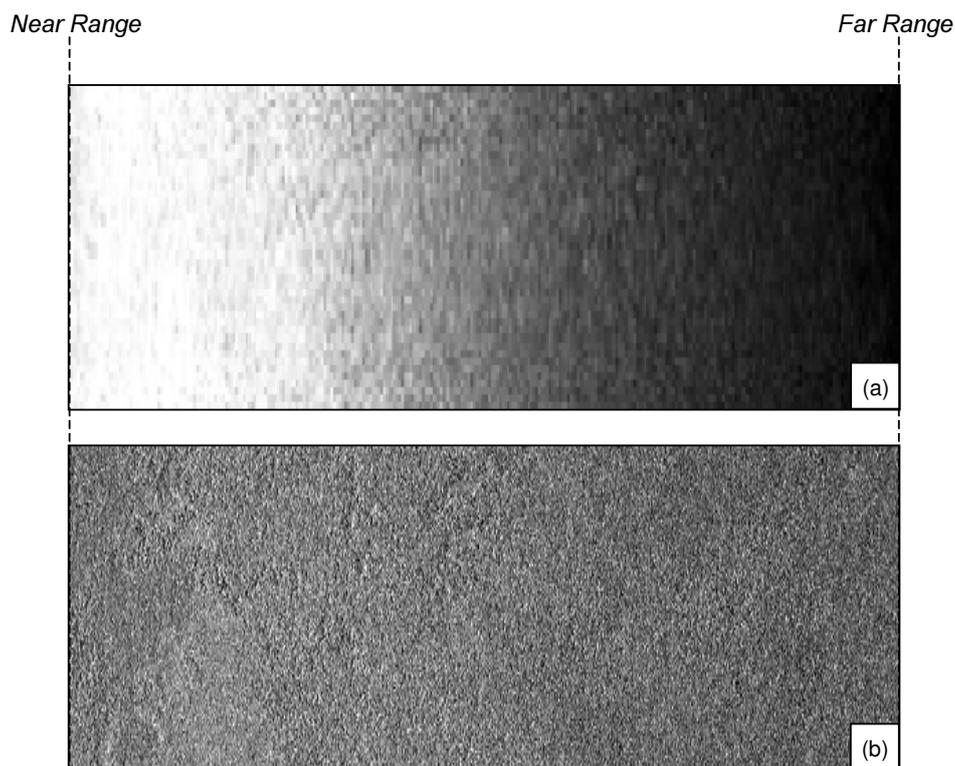


**Figura 11 - Caracterização do *layover* nas imagens de radar.**  
**Fonte: Adaptada de Ahern (1994), p. sn.**



**Figura 12 - Caracterização do *shadowing* nas imagens de radar.**

Os dois tipos de distorções radiométricas mais comumente encontradas em imagens de radar são aquelas causadas pelo padrão de radiação da antena e pelo ruído *speckle*, que é inerente a sistemas que operam com iluminação coerente. O padrão de radiação da antena e a geometria de imageamento podem causar uma variação gradual do sinal de retorno na direção perpendicular ao vôo, podendo ser observada na imagem como valores de níveis de cinza mais altos próximos ao *near range* e mais baixos próximos ao *far range* (Figura 13a). Esta variação pode ser amenizada com a correção do padrão da antena (Figura 13b).



**Figura 13 - Imagem SAR do sensor AeS-1, da Floresta Amazônica Venezuelana: (a) bruta e (b) com o efeito do padrão da antena corrigido.**

O *speckle* gera na imagem uma aparência granular (mudanças bruscas de níveis de cinza de um *pixel* para outro). Este ruído é causado pela característica coerente do sensor, pois a amplitude e fase do sinal de retorno são resultantes de uma soma vetorial (coerente) dos sinais de retorno de vários difusores contidos em cada célula de resolução. A fase de cada difusor está relacionada à distância entre o difusor e o sensor. Se o sensor se move, as fases dos difusores mudarão, acarretando uma alteração na amplitude total. Então, observações sucessivas da mesma área quando o sensor se move resultarão em diferentes valores de amplitude. Descrições mais detalhadas sobre a caracterização, formação e redução do ruído *speckle* podem ser encontradas em Ulaby et al. (1982, 1986a), Trevett (1986), Ulaby e Dobson (1989), Sant'Anna (1995) e as referências nelas contidas. Vale ainda ressaltar que os efeitos causados pelas distorções geométrica e radiométrica são mais acentuados para os sensores aerotransportados que para os sensores orbitais.

Para muitos tipos de aplicações em sensoriamento remoto utilizando imagens ópticas ou de radar é necessário que sejam realizadas correções (geométricas e/ou radiométricas). Quando se objetiva comparar imagens adquiridas por diferentes sensores ou em datas distintas, é de fundamental importância que se realize a calibração destas imagens. A calibração efetuada para imagens de radar consiste da recuperação dos valores de coeficiente de retroespalhamento do alvo a partir da radiometria dos seus níveis de cinza, denominada calibração absoluta. A forma de calibração das imagens de radar varia de acordo como o sensor e os parâmetros utilizados no imageamento. Como exemplo de calibração absoluta, para imagens RADARSAT e JERS-1 utilizam-se respectivamente as seguintes expressões (Amaral e Shimabukuro, 1997; Rosenqvist, 1996):

$$\sigma^\circ = 10 \log_{10} \left[ \text{sen}(\alpha) \left( \frac{NC^2 + A_0}{A_R} \right) \right] \text{ e } \sigma^\circ = 10 \log_{10}(NC^2) + FC,$$

onde  $\sigma^\circ$  é o coeficiente de retroespalhamento (em decibéis, dB),  $\alpha$  é o ângulo de incidência que varia ao longo do *range*,  $NC$  é o nível de cinza em amplitude,  $A_0$  e  $A_R$  são constantes do sistema, e  $FC$  é a fator de calibração (para imagens JERS-1 de 1993, este fator é aproximadamente igual a -68,5 dB).

### 1.5. MODELAGEM DOS DADOS SAR

O desenvolvimento de técnicas automáticas de processamento de imagens SAR pode ser realizado heurísticamente ou através da modelagem dos dados. No primeiro caso, não se adota nenhum modelo para os dados. Neste trabalho, será feita uma abordagem estatística para a modelagem dos dados. Logo, é fundamental que se conheçam as propriedades estatísticas dos dados SAR. Estas propriedades podem ser utilizadas para o desenvolvimento de ferramentas específicas para as imagens SAR (filtros, classificadores, etc.), assim como para a discriminação de classes de uso e ocupação do solo, por exemplo.

Muitos trabalhos têm sido realizados na tentativa de se modelar os dados SAR, entre eles pode-se citar, Jakeman e Pursey (1973 e 1976), Jao (1984), Lopes et al. (1990), Lee e Grunes (1994), Lee et al. (1994a e c), Frery et al. (1995a e b), Lee et al. (1995), Du e Lee (1996) e Frery et al. (1997a e b). Para boa parte dos pesquisadores desta área, o modelo multiplicativo é o que melhor se adequa a esse tipo de dado, e portanto é o mais utilizado e aceito atualmente. Já para dados ópticos, o modelo mais adotado é o aditivo, onde o sinal recebido pode ser decomposto como uma soma de duas variáveis aleatórias (o sinal da cena somado a um ruído) Gaussianas independentes e identicamente distribuídas.

No modelo multiplicativo, é considerado que o valor observado em cada *pixel* da imagem é uma variável aleatória ( $Z$ ), resultante da multiplicação de outras duas variáveis aleatórias. Estas duas últimas variáveis são independentes, uma relacionada ao retroespalhamento do alvo ( $X$ ) e outra representando o ruído *speckle* ( $Y$ ) que corrompe o sinal recebido da cena. A variável  $X$  representa a raiz quadrada da refletividade do alvo que por sua vez é proporcional ao coeficiente de retroespalhamento e será denominada simplesmente como retroespalhamento. Desta forma, matematicamente tem-se  $Z = X \cdot Y$ , onde a variável aleatória  $X$  é sempre considerada real e positiva, enquanto que a variável aleatória  $Y$  pode ser complexa ou real e positiva, dependendo apenas do formato de representação dos dados. Este formato pode ser complexo, de intensidade ou de amplitude e as variáveis aleatórias denotando cada um deles serão indexadas com as letras " $C$ ", " $I$ " e " $A$ ", respectivamente. Assim,  $Z_C$  representa o sinal de retorno complexo recebido,  $Z_I$  a intensidade (potência) e  $Z_A$  a amplitude deste sinal. De modo geral, denominar-se-á de retorno a variável  $Z$ .

Na Seção 1.5.1, serão apresentados os modelos para os dados monoespectrais (uma banda e uma polarização) onde são considerados modelos para o *speckle*, para o retroespalhamento do alvo, e para o retorno em amplitude. Quando o retorno é dado em amplitude ou intensidade, a informação de fase do sinal recebido é perdida, o que não acontece quando dados polarimétricos complexos são utilizados. A modelagem para dados polarimétricos (uma banda e várias polarizações) é apresentada na Seção 1.5.2.

## 1.5.1. Dados Monoespectrais

### 1.5.1.1. Ruído Speckle

No formato complexo, geralmente, é considerado que o ruído *speckle*  $Y_C$  possui distribuição Gaussiana bivariada e suas componentes real ( $Y_{\Re}$ ) e imaginária ( $Y_{\Im}$ ) são independentes e identicamente distribuídas com média nula e variância  $1/2$ . A relação existente entre o *speckle* no formato complexo e o *speckle* nos formatos intensidade e amplitude é dada, respectivamente, por  $Y_I = |Y_C|^2$  e  $Y_A = |Y_C| = \sqrt{Y_{\Re}^2 + Y_{\Im}^2}$ <sup>1</sup>. Deste modo, para imagens de *1-look*, pode-se provar que  $Y_I$  possui uma distribuição exponencial e  $Y_A$  uma distribuição Rayleigh (Ulaby et al., 1986a).

Para a formação de uma imagem em intensidade com  $n$  *looks* (processamento *multi-look*), calcula-se a média de  $n$  amostras independentes de  $Y_I$ , conduzindo a uma distribuição Gama para essa variável aleatória, denotada por  $Y_I^{(n)} \sim \Gamma(n, n)$  e descrita por:

$$f_{Y_I^{(n)}}(y) = \frac{n^n}{\Gamma(n)} y^{n-1} \exp(-ny) \quad n, y > 0, \quad (1)$$

onde  $\Gamma(\cdot)$  denota a função gama de Euler.

A amplitude, no caso *multi-look*, é obtida extraindo-se a raiz quadrada dos dados em intensidade *multi-look*, isto é,  $Y_A^{(n)} = \sqrt{Y_I^{(n)}}$ , onde  $Y_I^{(n)}$  tem a distribuição dada pela Equação (1). Desta forma, a variável aleatória  $Y_A^{(n)}$  possuirá uma distribuição Raiz Quadrada da Gama, denotada por  $Y_A^{(n)} \sim \Gamma^{1/2}(n, n)$  e caracterizada por:

$$f_{Y_A^{(n)}}(y) = \frac{2n^n}{\Gamma(n)} y^{2n-1} \exp(-ny^2) \quad n, y > 0.$$

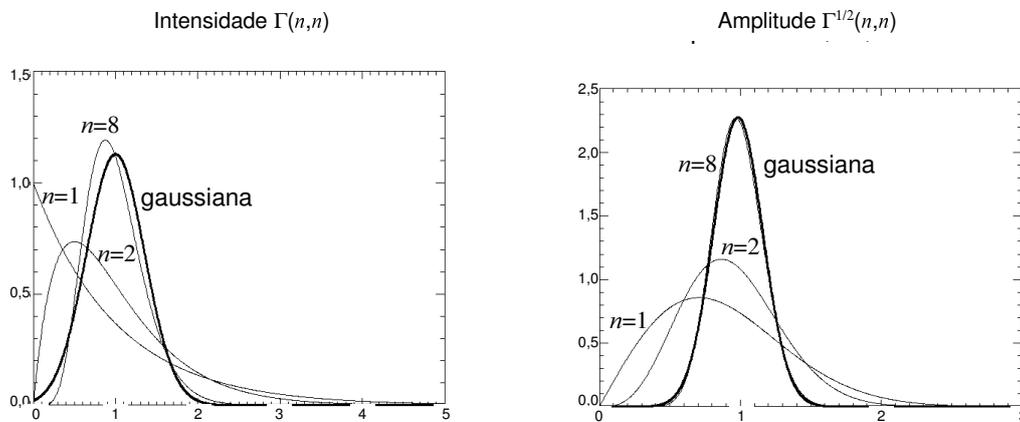
O número de *looks*  $n$ , quando estimado sobre dados reais, raramente é um número inteiro. Isto se deve ao fato de que, entre outras razões, a média de intensidade é calculada sobre observações correlacionadas. Portanto,  $n$  é, em geral, denominado número equivalente de *looks*. Para grandes valores de  $n$  e sob certas condições, as distribuições  $\Gamma(n, n)$  e  $\Gamma^{1/2}(n, n)$  tendem para uma distribuição Gaussiana (como mostrado na Figura 14), podendo ser explicado através do teorema central do limite.

### 1.5.1.2. Retroespalhamento

A modelagem do retroespalhamento, geralmente, é associada à homogeneidade das áreas imageadas, a qual também depende dos parâmetros do sensor (frequência, polarização, ângulo de incidência, etc.). Neste trabalho, seguindo a modelagem proposta por Frery et al. (1997a), é considerado um modelo geral para o retroespalhamento, e a partir dele pode-se obter modelos mais simples para áreas com diferentes graus de homogeneidade, aqui denominadas, de maneira geral, homogêneas, heterogêneas e extremamente heterogêneas. O uso destes modelos

<sup>1</sup> Tanto o módulo de um número complexo quanto o determinante de uma matriz serão denotadas por  $|\cdot|$ , estando as matrizes representadas em negrito.

mais simples é vantajoso devido à menor quantidade de parâmetros a serem estimados e também à menor complexidade computacional.



**Figura 14 - Distribuições  $\Gamma(n,n)$  e  $\Gamma^{1/2}(n,n)$  para diferentes valores de  $n$ .**

O retroespalhamento, no modelo geral, possui uma distribuição Raiz Quadrada da Gaussiana Inversa Generalizada, com parâmetros<sup>2</sup>  $\alpha$ ,  $\gamma$  e  $\lambda$ , denotada por  $X \sim N^{-1/2}(\alpha, \gamma, \lambda)$ , e caracterizada por:

$$f_X(x) = \frac{(\lambda/\gamma)^{\alpha/2}}{K_\alpha(2\sqrt{\lambda\gamma})} x^{2\alpha-1} \exp\left(-\frac{\gamma}{x^2} - \lambda x^2\right) \quad x > 0$$

onde  $K_\alpha(\cdot)$  denota a função de Bessel modificada de terceiro tipo e ordem  $\alpha$ , e o domínio dos parâmetros é dado por:

$$\begin{cases} \gamma > 0, \lambda \geq 0, & \text{se } \alpha < 0 \\ \gamma > 0, \lambda > 0, & \text{se } \alpha = 0 \\ \gamma \geq 0, \lambda > 0, & \text{se } \alpha > 0 \end{cases} \quad (2)$$

Os momentos, assim como referências a respeito desta distribuição, podem ser encontrados em Frery et al. (1997a).

Esta distribuição possui, como casos particulares (modelos mais simples), algumas das distribuições que são amplamente utilizadas na modelagem de dados de radar:

- a constante  $(\beta^{1/2})$ , utilizada para a modelagem de áreas homogêneas, levando os dados de retorno em amplitude à distribuição Raiz Quadrada da Gama.
- a Raiz Quadrada da Gama, usualmente utilizada na modelagem de áreas heterogêneas, a qual leva os dados de retorno à família de distribuições K. A distribuição Raiz Quadrada da Gama, denotada por  $\Gamma^{1/2}(\alpha, \lambda)$ , é caracterizada por:

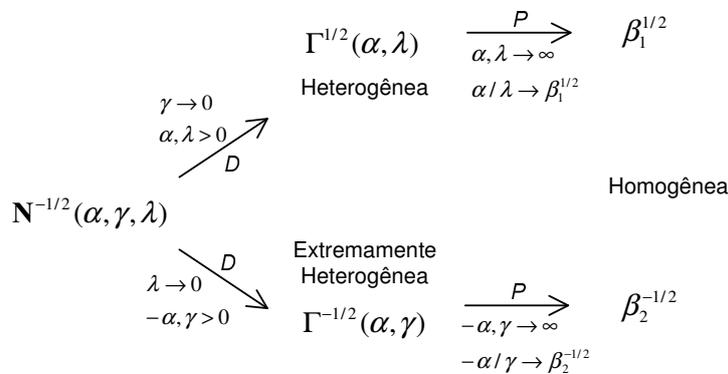
<sup>2</sup> Os parâmetros  $\alpha$ ,  $\lambda$ ,  $\tau$  e  $\rho$  das distribuições descritas a partir desta Seção não representam os parâmetros do imageamento definidos na Seção 1.2.

$$f_X(x) = \frac{2\lambda^\alpha}{\Gamma(\alpha)} x^{2\alpha-1} \exp(-\lambda x^2) \quad \alpha, \lambda, x > 0;$$

- a Recíproca da Raiz Quadrada da Gama, utilizada para a modelagem de áreas extremamente heterogêneas, a qual leva os dados de retorno à família de distribuições G Zero ( $G^0$ ). A distribuição Recíproca da Raiz Quadrada da Gama, denotada por  $\Gamma^{-1/2}(\alpha, \gamma)$ , é caracterizada por:

$$f_X(x) = \frac{2}{\gamma^\alpha \Gamma(-\alpha)} x^{2\alpha-1} \exp\left(-\frac{\gamma}{x^2}\right) \quad -\alpha, \gamma, x > 0.$$

Estes casos particulares têm suas relações com a distribuição  $N^{-1/2}(\alpha, \gamma, \lambda)$  explicitada no diagrama a seguir:



onde  $D$  e  $P$  indicam respectivamente convergência em distribuição e probabilidade.

### 1.5.1.3. Retorno Observado em Amplitude

A distribuição do retorno em amplitude para dados *multi-look*, obtida através do produto  $Z_A^{(n)} = X \cdot Y_A^{(n)}$ , onde  $X \sim N^{-1/2}(\alpha, \gamma, \lambda)$  e  $Y_A^{(n)} \sim \Gamma^{1/2}(n, n)$ , é denotada por  $G_A(\alpha, \gamma, \lambda, n)$  e caracterizada pela distribuição

$$f_{Z_A^{(n)}}(z) = \frac{2n^n \sqrt{(\lambda/\gamma)^\alpha}}{\Gamma(n) K_\alpha(2\sqrt{\lambda\gamma})} z^{2n-1} \left(\frac{\gamma + nz^2}{\lambda}\right)^{\frac{(\alpha-n)}{2}} K_{\alpha-n}\left(2\sqrt{\lambda(\gamma + nz^2)}\right) \quad z \in R, \quad (3)$$

onde o domínio dos parâmetros é dado na Equação (2).

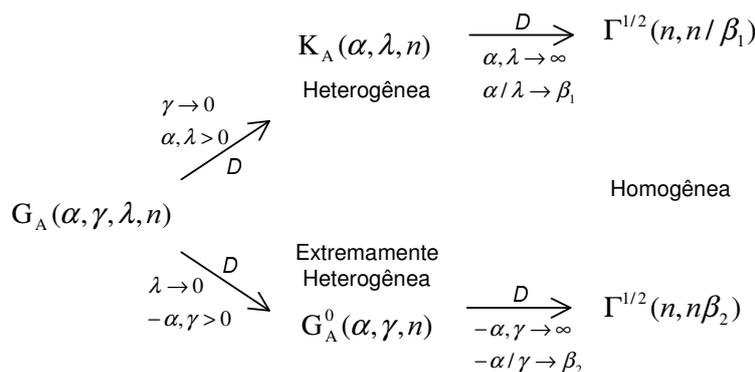
Analogamente ao discutido na Seção 1.5.1.2, esta distribuição tem como casos particulares a distribuição Raiz Quadrada da Gama (utilizada para regiões homogêneas), a distribuição K-Amplitude (utilizada para regiões heterogêneas), e a distribuição G-Amplitude Zero ( $G_A^0$ , utilizadas para regiões extremamente heterogêneas), cujas distribuições são dadas respectivamente pelas equações a seguir:

$$f_{Z_A^{(n)}}(z) = \frac{2n^n}{\beta^n \Gamma(\alpha)} z^{2n-1} \exp(-nz^2 / \beta) \quad n, \beta, z > 0, \quad (4)$$

$$f_{Z_A^{(n)}}(z) = \frac{4\lambda n z}{\Gamma(\alpha)\Gamma(n)} (\lambda n z^2)^{(\alpha+n-2)/2} K_{\alpha-n}(2z\sqrt{\lambda n}) \quad \alpha, \lambda, n, z > 0, \quad (5)$$

$$f_{Z_A^{(n)}}(z) = \frac{2n^n \Gamma(n-\alpha) z^{2n-1}}{\gamma^\alpha \Gamma(n)\Gamma(-\alpha)(\gamma+nz^2)^{n-\alpha}} \quad -\alpha, \gamma, n, z > 0. \quad (6)$$

O esquema a seguir mostra a relação existente entre estas distribuições:



onde  $D$  indica convergência em distribuição.

Mais detalhes sobre as distribuições citadas acima, tais como propriedades, aplicações e estimadores dos parâmetros, podem ser encontradas em Yanasse et al. (1995), Vieira (1996), Frery et. al. (1997a) e Correia (1998).

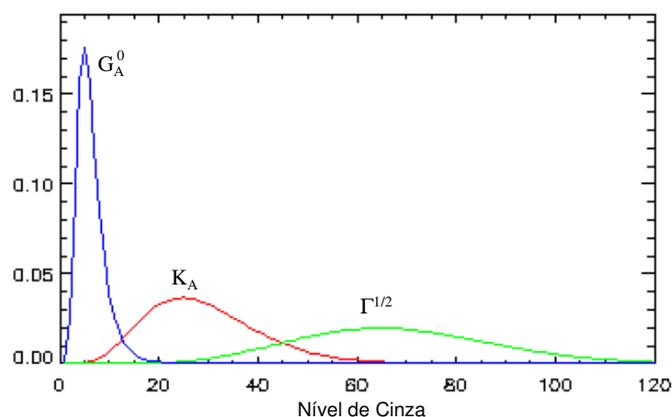
Na Tabela 1, pode-se observar, de forma simplificada, as distribuições utilizadas na modelagem dos dados *multi-look* em amplitude (*speckle*, retroespalhamento e retorno observado) para áreas com diferentes graus de homogeneidade. Na Figura 15, são mostradas as distribuições do retorno em amplitude *multi-look* (com número de *looks* igual a 3) para os três graus de homogeneidade considerados.

**Tabela 1 - Modelagem dos dados *multi-look* em amplitude.**

Áreas	Retroespalhamento ( $X$ )	<i>Speckle</i> ( $Y_A^{(n)}$ )	Retorno Observado ( $Z_A^{(n)}$ )
Homogêneas	$\beta^{1/2}$	$\Gamma^{1/2}(n, n)$	$\Gamma^{1/2}(n, n/\beta)$
Heterogêneas	$\Gamma^{1/2}(\alpha, \lambda)$		$K_A(\alpha, \lambda, n)$
Extr. Heterogêneas	$\Gamma^{1/2}(\alpha, \gamma)$		$G_A^0(\alpha, \gamma, n)$
Geral	$N^{-1/2}(\alpha, \gamma, \lambda)$		$G_A(\alpha, \gamma, \lambda, n)$

As distribuições para o retorno em intensidade podem ser obtidas das distribuições do retorno em amplitude, através da transformação  $f_{Z_I^{(n)}}(z) = f_{Z_A^{(n)}}(\sqrt{z})/(2\sqrt{z})$ , levando as distribuições descritas nas Equações (3), (4), (5) e (6) às distribuições G-Intensidade ( $G_I$ ), Gama ( $\Gamma$ ), K-Intensidade ( $K_I$ ) e G-Intensidade Zero ( $G_I^0$ ), respectivamente (Frery et al. 1997a).

Existem outras distribuições que são usadas para modelar os dados SAR, mas que não são oriundas do modelo multiplicativo. Dentre estas distribuições pode-se citar a Beta, Lognormal e Weibull.



**Figura 15 - Distribuições do retorno em amplitude *multi-look*:  $\Gamma^{1/2}(3, 0,0006)$ ,  $K_A(4, 1000, 3)$  e  $G_A^0(-3, 100, 3)$ .**

### 1.5.2. Dados Polarimétricos

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 todas as células de resolução de uma cena (Ulaby e Elachi, 1990). Desta forma, para obter essas configurações para cada célula de resolução, é medida a matriz de espalhamento complexa (*complex scattering matrix*):

$$S = \begin{pmatrix} S_{vv} & S_{vh} \\ S_{hv} & S_{hh} \end{pmatrix}.$$

Os termos  $S_{pq}$  (onde  $p, q = h$  ou  $v$ ) são conhecidos como amplitude de espalhamento complexa (*complex scattering amplitude*), e como mostra Sarabandi (1992), tem-se:

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

onde  $N$  é o número de difusores de uma célula de resolução, cada um possuindo uma amplitude  $|s_{pq}^n|$  e uma fase  $\phi_{pq}^n$ . O vetor resultante da soma vetorial de todos os difusores terá amplitude  $|S_{pq}|$  e fase  $\phi_{pq}$ .

Considerando-se que as antenas, de um modo geral, são monoestáticas, 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:

$$\mathbf{Z}_C = \begin{bmatrix} S_{hh} \\ S_{hv} \\ S_{vv} \end{bmatrix},$$

onde  $\mathbf{Z}_C$  representa um vetor complexo.

O modelo multiplicativo também pode ser aplicado aos dados polarimétricos, considerando-se modelos distintos para áreas com diferentes graus de

homogeneidade. Neste caso, por se tratar de dados em diferentes polarizações, o *speckle* ( $Y_C$ ) é modelado por uma distribuição Gaussiana complexa multivariada. Assim, o retorno  $Z_C$  (aqui representado pelo vetor  $\mathbf{Z}_C$ ) terá também uma distribuição Gaussiana complexa multivariada quando o retroespalhamento ( $X$ ) é modelado através de uma constante (regiões homogêneas).

O vetor  $\mathbf{Z}_C$  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 *speckle*, os dados SAR polarimétricos são freqüentemente processados com o aumento do número de *looks* (*multi-look*). Sendo assim, a partir do vetor  $\mathbf{Z}_C(k)$ , que representa a  $k$ -ésima amostra de *1-look*, pode-se obter a matriz de covariância para  $n$ -*looks* (*multi-look*), dada por (Lee et al., 1995):

$$\mathbf{Z}_C^{(n)} = \frac{1}{n} \sum_{k=1}^n \mathbf{Z}_C(k) \mathbf{Z}_C^{*T}(k), \quad (7)$$

onde  $\mathbf{Z}_C^{*T}(k)$  denota o conjugado transposto do vetor  $\mathbf{Z}_C(k)$ .

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  $\mathbf{A}_C = n\mathbf{Z}_C^{(n)}$  apresenta uma distribuição de Wishart complexa multivariada, conforme Srivastava (1963). Sendo assim, a distribuição da variável aleatória  $\mathbf{Z}_C^{(n)}$ , associada à matriz  $\mathbf{Z}_C^{(n)}$ , é dada por:

$$f_{\mathbf{Z}_C^{(n)}}(\mathbf{z}) = \frac{n^{qn} |\mathbf{z}|^{(n-q)} \exp[-n \text{Tr}(\mathbf{C}_C^{-1} \mathbf{z})]}{K(n, q) |\mathbf{C}_C|^n} \quad n, q > 0, \quad (8)$$

onde  $q$  denota o número de componentes,  $K(n, q) = \pi^{(1/2)q(q-1)} \Gamma(n) \cdots \Gamma(n-q+1)$ ,  $\text{Tr}(\cdot)$  denota o traço de uma matriz,  $\mathbf{C}_C = E[\mathbf{Z}_C \mathbf{Z}_C^{*T}]$  e  $E(\cdot)$  denota a esperança matemática.

Para áreas heterogêneas, o retroespalhamento pode ser modelado pela distribuição Gama, como no caso de dados monoespectrais em intensidade. Baseado nesta modelagem, Lee et al. (1994c) desenvolveram, a partir da Equação (7), a distribuição de  $\mathbf{Z}_C^{(n)}$ , denominada  $K_C$  multivariada *multi-look*, que é caracterizada por:

$$f_{\mathbf{Z}_C^{(n)}}(\mathbf{z}) = \frac{2|\mathbf{z}|^{(n-q)} (n\alpha)^{(\alpha+qn)/2} K_{\alpha-qn} \left( 2\sqrt{n\alpha \text{Tr}(\mathbf{C}_C^{-1} \mathbf{z})} \right)}{K(n, q) |\mathbf{C}_C|^n \Gamma(\alpha) \text{Tr}(\mathbf{C}_C^{-1} \mathbf{z})^{(qn-\alpha)/2}} \quad \alpha, n, q > 0. \quad (9)$$

Seguindo a mesma abordagem, foi desenvolvida em Correia (1998), para áreas extremamente heterogêneas, a distribuição de  $\mathbf{Z}_C^{(n)}$  denominada  $G_C^0$  multivariada *multi-look*. Para tanto, considerou-se que o retroespalhamento é modelado pela distribuição Inversa da Gama (a mesma para dados monoespectrais em intensidade). A distribuição  $G_C^0$  multivariada *multi-look* é caracterizada por:

$$f_{Z_C^{(n)}}(\mathbf{z}) = \frac{n^{qn} |\mathbf{z}|^{(n-q)} \Gamma(qn - \alpha)}{(-\alpha)^\alpha \Gamma(-\alpha) K(n, q) |\mathbf{C}_C|^n (n \text{Tr}(\mathbf{C}_C^{-1} \mathbf{z}) - \alpha)^{qn - \alpha}} \quad -\alpha, n, q > 0. \quad (10)$$

As distribuições descritas pelas Equações (8), (9) e (10), reduzem-se respectivamente às distribuições  $\Gamma$ ,  $K_I$  e  $G_I^0$  quando  $q = 1$  (caso mono-espectral). As distribuições multivariadas complexas podem modelar adequadamente o retorno proveniente de regiões com diferentes graus de homogeneidade, porém é exigido um grande esforço computacional. Dessa forma, Lee et al. (1994a e c) e Lee et al. (1995) derivaram a partir da Equação (8) (considerando o retroespalhamento constante, isto é, áreas homogêneas), distribuições bivariadas (par de imagens em intensidade e par de imagens intensidade-diferença de fase) e univariadas (razão de imagens em intensidade e imagem diferença de fase), descritas a seguir.

- **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, de acordo com as equações:

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

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

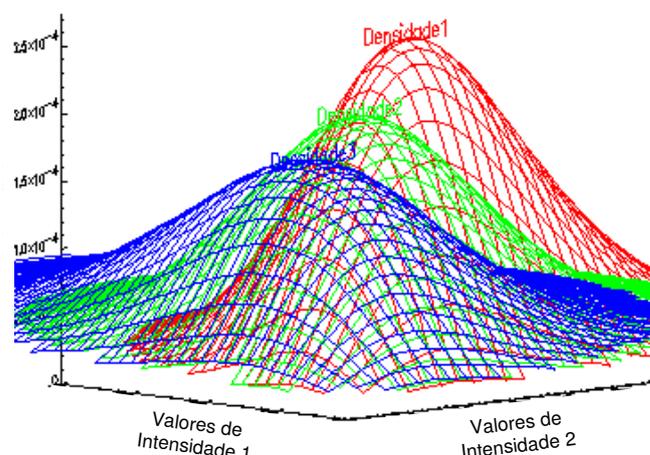
$$f_{(Z_1, Z_2)}(z_1, z_2) = \frac{n^{n+1} (z_1 z_2)^{\frac{(n-1)}{2}} \exp\left(-\frac{n(z_1/h_{11} + z_2/h_{22})}{1 - |\rho_c|^2}\right)}{(h_{11} h_{22})^{\frac{(n+1)}{2}} \Gamma(n) (1 - |\rho_c|^2) |\rho_c|^{n-1}} I_{n-1}\left(\frac{2n|\rho_c|}{1 - |\rho_c|^2} \sqrt{\frac{z_1 z_2}{h_{11} h_{22}}}\right),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

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  $\xi$  a fase do coeficiente de correlação complexo *multi-look*,  $i = \sqrt{-1}$  e  $I_{n-1}$  representa a função modificada de Bessel de ordem  $n-1$ .

Na Figura 16, pode-se observar como se comporta a distribuição do par de imagens em intensidade, ao se variar um dos parâmetros ( $h_{22} = 60, 80$  e  $100$ ) e mantendo-se os demais fixos.



**Figura 16 - Distribuição do par de imagens em intensidade para  $h_{22} = 60, 80$  e  $100$ ,  $n = 4$ ,  $|\rho_c| = 0,5$  e  $h_{11} = 60$ .**

**Fonte: Adaptada de Correia (1998), p. 63.**

- **Distribuição da Imagem Diferença de Fase *multi-look***

Seja uma imagem diferença de fase *multi-look* representada pela variável aleatória  $\Psi$ , obtida a partir de duas componentes  $S_r$  e  $S_s$  da matriz de espalhamento, de acordo com a equação (Lee et al., 1994a):

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

onde  $\text{Arg}(\cdot)$  denota o argumento de um número complexo. A distribuição de  $\Psi$ , derivada em Lee et al. (1994b), é dada por:

$$f_{\Psi}(\psi) = \frac{\Gamma(n+1/2)(1-|\rho_c|^2)^n \delta}{2\sqrt{\pi} \Gamma(n)(1-\delta^2)^{n+1/2}} + \frac{(1-|\rho_c|^2)^n}{2\pi} {}_2F_1(n, 1; 1/2; \delta^2) \quad (-\pi < \psi \leq \pi), \quad (12)$$

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

Na Figura 17, pode-se observar o comportamento da distribuição da imagem diferença de fase, quando um dos parâmetros ( $\xi = -1,5, 0,0$  e  $1,5$ ) é alterado e os demais são mantidos constantes.

- **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:

$$f_W(w) = \frac{\tau^n \Gamma(2n)(1-|\rho_c|^2)^n (\tau+w)w^{n-1}}{\Gamma^2(n)[(\tau+w)^2 - 4\tau|\rho_c|^2 w]^{(2n+1)/2}}, \quad (13)$$

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

Na Figura 18, pode-se observar como se comporta a distribuição da razão de imagens em intensidade, ao se variar um dos parâmetros ( $\tau = 0,15, 0,25$  e  $0,35$ ), enquanto os demais são mantidos constantes.

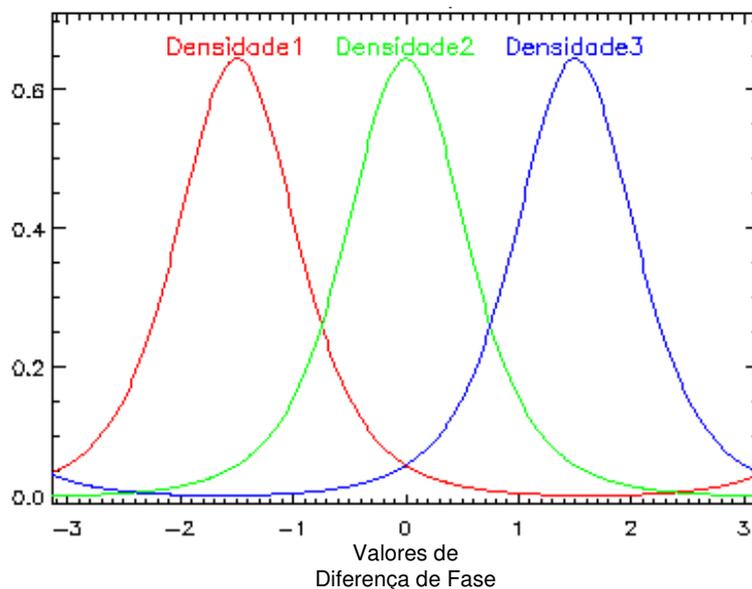


Figura 17 - Distribuições da imagem diferença de fase para  $\xi = -1,5, 0,0$  e  $1,5$ ,  $n = 4$  e  $|\rho_c| = 0,5$ .

Fonte: Adaptada de Correia (1998), p. 66.

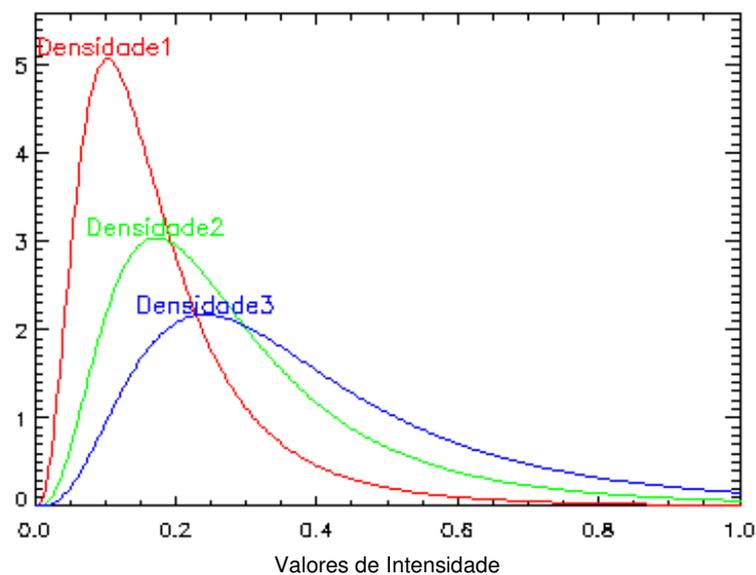


Figura 18 - Distribuições da razão de imagens em intensidade para  $\tau = 0,15, 0,25$  e  $0,35$ ,  $n = 4$  e  $|\rho_c| = 0,5$ .

Fonte: Adaptada de Correia (1998), p. 69.

- **Distribuição do Par de imagens Intensidade-Diferença de Fase *multi-looks***

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

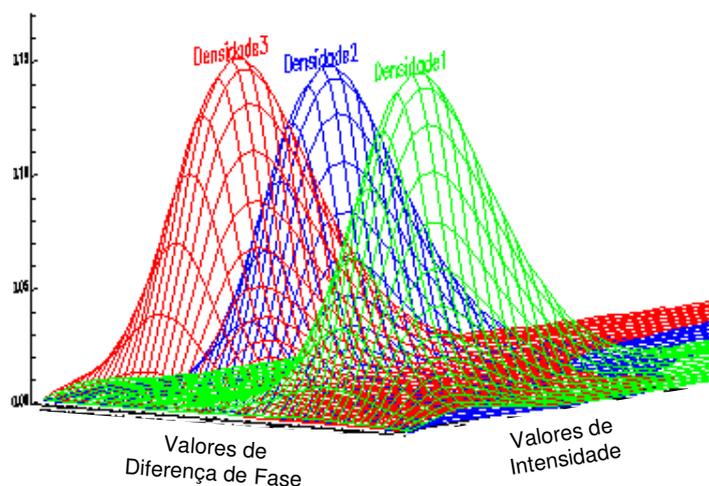
$$B_1 = \frac{nZ_1}{h_{11}} = \frac{\sum_{k=1}^n |S_r(k)|^2}{h_{11}}.$$

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

$$f_{(B_1, \Psi)}(b_1, \psi) = \frac{b_1^{n-1} \exp\left(-\frac{b_1}{d}\right)}{2\pi \Gamma(n)} {}_1F_1\left[1; \frac{1}{2}; \frac{\delta^2 b_1}{d}\right] + \frac{\delta b_1^{n-\frac{1}{2}} \exp\left(-\frac{b_1(1-\delta^2)}{d}\right)}{2\sqrt{\pi} \Gamma(n) \sqrt{d}}, \quad (14)$$

onde  $d = 1 - |\rho_c|^2$ , o parâmetro  $\delta$  vem da Equação (12) e  ${}_1F_1(\cdot)$  denota a função hipergeométrica degenerada ou confluenta (Abramowitz e Stegun, 1965).

Na Figura 19, pode-se observar o comportamento da distribuição do par de imagens intensidade-diferença de fase, onde um dos parâmetros ( $\xi = -1,5, 0,0$  e  $1,5$ ) é alterado, enquanto os demais são mantidos constantes.



**Figura 19 - Distribuição do par de imagens intensidade-diferença de fase para  $\xi = -1,5, 0,0$  e  $1,5$ ,  $n = 4$ ,  $|\rho_c| = 0,6$  e  $h_{11} = 50$ .**

**Fonte: Adaptada de Correia (1998), p. 71.**

Estimadores dos parâmetros das distribuições dadas pelas Equações (11) a (14) podem ser encontrados em Correia (1998).

## 1.6. TEXTURA

A textura é uma importante característica utilizada na interpretação visual de imagens e por esta razão, o uso de medidas de textura pode aumentar o desempenho de classificadores digitais, principalmente em imagens com alta resolução espacial. No entanto, a textura de uma imagem é muito difícil de ser quantificada, uma vez que não há um consenso na definição deste termo, nem tampouco uma formulação matemática precisa. Ao contrário da informação espectral, que descreve a variação do nível de cinza de um *pixel*, a textura contém informações sobre a distribuição espacial dos níveis de cinza de uma região da imagem (Ulaby et al., 1986b; Marceau et al., 1989).

As técnicas de discriminação de alvos que incorporam a informação textural são em sua grande maioria *ad hoc*. As primeiras técnicas desenvolvidas para se descrever a textura de uma imagem, procuravam entender as relações de contraste, direcionalidade, rugosidade e regularidade dos níveis de cinza de regiões consideradas homogêneas texturalmente. Dentro desta linha, destacam-se as técnicas que utilizam funções de autocorrelação, matrizes de co-ocorrência e morfologia matemática. Outras abordagens consideram que a textura presente numa imagem podem ser explicadas através da adoção de modelos. Assim, dado um modelo e conhecido seus parâmetros, pode-se sintetizar áreas com texturas homogêneas. Dessa forma, a análise textural consiste da verificação da adequabilidade de um modelo e estimação de seus parâmetros. Como exemplos de modelos pode-se citar os autorregressivos de média móvel (que podem ser estendidos para o caso bidimensional) e campos aleatórios Markovianos.

A textura não pode ser analisada sem se considerar a escala. Para qualquer superfície textural, existe uma escala na qual esta apresenta uma aparência lisa ou praticamente sem textura. A medida que a escala aumenta, esta superfície pode apresentar uma textura fina chegando até a uma textura bastante grosseira, e para uma análise multi-escala, este ciclo lisa/textura fina/textura grosseira pode se repetir.

Recomenda-se a consulta de Haralick and Shapiro (1992), para informações sobre aplicações do uso da informação textural na discriminação de alvos nas mais diversas áreas do conhecimento, tais como uso do solo, geologia, medicina, etc. A seguir são descritas algumas maneiras de se descrever a textura.

### 1.6.1. Co-ocorrência dos níveis de cinza

A dependência espacial de uma região pode ser caracterizada através da co-ocorrência dos níveis de cinza presentes nesta região. Texturas grosseiras são aquelas cujos níveis de cinza mudam suavemente com a distância. Por outro lado, texturas mais finas são aquelas cujas mudanças do nível de cinza ocorrem mais rapidamente com relação a distância.

A co-ocorrência dos níveis de cinza pode ser especificada numa matriz de frequências relativas,  $P(i,j)$ , com que dois *pixels* vizinhos, separados por uma certa distância em uma dada direção, ocorrem na imagem, um com nível de cinza  $i$  e o outro com o nível de cinza  $j$ . Em geral, a matriz de co-ocorrência é simétrica, ou seja, considera-se  $P(i,j) = P(j,i)$  (Haralick et al., 1973).

Dependendo do nível de quantização da imagem analisada, a matriz de co-ocorrência torna-se extremamente grande e ao mesmo tempo, é quase sempre uma matriz esparsa (grande parte da matriz é constituída de "zeros"). Por exemplo, para uma imagem de 8 *bits* (256 níveis de cinza), a matriz de co-ocorrência é composta por 65536 elementos ( $256^2$ ). Como alternativa, pode-se trabalhar com vetores de co-

ocorrência da soma e da diferença de níveis de cinza (Weszka et al., 1976; Unser, 1986; Welch et al., 1990). Cada elemento do vetor soma é definido como

$$P^S(k) = \sum_i \sum_j P(i, j) \quad \forall (i+j) = k,$$

enquanto que o elemento do vetor diferença é definido como

$$P^D(k) = \sum_i \sum_j P(i, j) \quad \forall |i-j| = k.$$

Dessa forma, utilizando-se a mesma imagem de 8 *bits*, o vetor soma terá 511 elementos e o vetor diferença 256 elementos.

A seguir apresentam-se algumas medidas de textura baseadas na matriz de co-ocorrência:

- uniformidade (energia)

$$UNI = \sum_i \sum_j P(i, j)^2$$

- entropia

$$ENT = -\sum_i \sum_j P(i, j) \log P(i, j)$$

- contraste

$$CON = \sum_i \sum_j (i-j)^2 P(i, j)$$

- homogeneidade

$$HOM = \sum_i \sum_j \frac{P(i, j)}{1 + (i-j)^2}$$

- correlação

$$COR = \frac{\sum_i \sum_j ijP(i, j) - \mu_i \mu_c}{\sigma_i \sigma_c}$$

onde

$$\mu_i = \sum_i iP(i, *), \quad \mu_c = \sum_j jP(*, j), \quad \sigma_i = \sqrt{\sum_i (i - \mu_i)^2 P(i, *)}, \quad \sigma_c = \sqrt{\sum_j (j - \mu_c)^2 P(*, j)},$$

$$P(i, *) = \sum_j P(i, j) \quad \text{e} \quad P(*, j) = \sum_i P(i, j)$$

- chi-quadrado

$$CHI = \sum_i \sum_j \frac{P(i, j)^2}{P(i, *)P(*, j)}$$

Estas e outras medidas foram utilizadas por Rennó (1995) e Soares et al. (1997) como descritores texturais para a discriminação de culturas agrícolas. As medidas baseadas na matriz de ocorrência são, de modo geral, denominadas medidas de Haralick.

### 1.6.2. Função de autocorrelação

Sendo  $g(x,y)$  o valor digital da região  $g$  na posição  $(x,y)$ , pode-se definir o valor de autocorrelação considerando-se um deslocamento ( $lag$ ) de  $(u,v)$  como:

$$\rho(u,v) = \frac{\frac{1}{(n_x - |u|)(n_y - |v|)} \sum_{x=1}^{n_x - |u|} \sum_{y=1}^{n_y - |v|} g(x,y)g(x+u, y+v)}{\frac{1}{n_x n_y} \sum_{x=1}^{n_x} \sum_{y=1}^{n_y} g^2(x,y)} \quad |u| < n_x \text{ e } |v| < n_y,$$

onde  $n_x$  e  $n_y$  representam respectivamente o número de colunas e linhas da região  $g$ .

Uma vez que o padrão textural numa imagem é geralmente periódico, a função de autocorrelação também obedece essa periodicidade. A função de autocorrelação para regiões com textura mais fina decresce rapidamente com a distância. Já em regiões com textura mais grosseira, esse decréscimo é menos acentuado.

A adoção da função de autocorrelação para caracterizar a textura de uma região pressupõe que a organização espacial é definida pela dependência linear que um *pixel* tem com outro.

### 1.6.3. Morfologia matemática

A abordagem morfológica para a análise textural de imagens requer a definição de um elemento estrutural (conjuntos de *pixels* que constituem uma forma específica como, por exemplo, linhas, círculos ou retângulos) e a geração de imagens binárias que resultam da erosão da imagem pelo elemento estrutural por um processo de translação deste elemento sobre a imagem. As medidas texturais podem ser obtidas pela contagem do número de *pixels* que possuem o valor "um" nestas novas imagens.

A operação de dilatação pode ser utilizada em conjunto com a erosão, resultando em operações de abertura (erosão seguida de dilatação) e fechamento (dilatação seguida de erosão).

O número de *pixels* que possuem valor "um" em uma imagem resultante de um processo de abertura, como função do tamanho do elemento estrutural, pode determinar a distribuição do tamanho dos grânulos (elementos texturais primitivos) na imagem.

Um exemplo do uso de morfologia matemática para análise textural pode ser encontrado em Chen e Dougherty (1994).

### 1.6.4. Modelos autorregressivos

Com a adoção de um modelo autorregressivo (caso particular do modelo autorregressivo de média móvel), pode-se estimar o nível de cinza de um *pixel* a partir dos níveis de cinza de seus *pixels* vizinhos, ou seja, a estimação é feita através da ponderação linear dos níveis de cinza da vizinhança de um *pixel*. Para texturas mais grosseiras, os coeficientes utilizados na ponderação serão muito similares. Por outro lado, para texturas mais finas, estes coeficientes poderão ser muito distintos. A

estimação destes coeficientes pressupõe uma dependência linear entre os *pixels* da imagem que pode ser avaliada através da função de autocorrelação (ver Seção 1.6.2).

A formação da textura, utilizando-se um modelo autorregressivo, se dá através do seguinte procedimento: a partir de uma imagem ruído gerada aleatoriamente e uma seqüência qualquer de valores, o próximo valor desta seqüência pode ser calculado como uma combinação linear dos valores previamente existentes somado à combinação linear dos valores de ruídos previamente gerados. Os coeficientes dessas combinações lineares são os parâmetros desse modelo.

A utilização de modelos autorregressivos como descritores texturais pode ser encontrada em Sant'Anna e Dutra (1995), que avaliaram filtros redutores de *speckle*, e em Soares (1998), que discriminou tipos de florestas através de classificação digital.

### 1.6.5. Parâmetros estatísticos de primeira ordem

A textura pode também ser caracterizada através de parâmetros estatísticos de primeira ordem, ou seja, que não levam em consideração a distribuição espacial dos níveis de cinza de uma região da imagem. Os parâmetros que se relacionam com a textura, em geral, descrevem a variação ou forma da distribuição dos níveis de cinza. Assim pode-se utilizar como descritores de textura a variância (ou o desvio padrão), o coeficiente de variação, assimetria, curtose, etc.

Muitas distribuições podem ser empregadas para descrever a variação dos níveis de cinza de imagens de radar (para maiores detalhes ver Seção 1.5). Particularmente, o parâmetro  $\alpha$  da distribuição K tem se mostrado um importante descritor da textura de uma região. Pode-se verificar que a distribuição Raiz Quadrada da Gama é um caso particular da K-Amplitude quando  $\alpha$  tende a infinito e, que a primeira está associada a regiões mais homogêneas e a segunda a regiões mais heterogêneas em imagens amplitude. Dessa forma, uma estimativa do parâmetro  $\alpha$  pode ser utilizado como medida da homogeneidade (textura) de uma região.

Sant'Anna et al. (1997) utilizaram o coeficiente de variação e o parâmetro  $\alpha$  da distribuição K-Amplitude para descrever a textura de uma imagem do RADARSAT, na discriminação de três classes de uso do solo: floresta primária, sucessão secundária e atividades recentes (solo exposto, pastagem e culturas agrícolas). Foi mostrado que esses parâmetros texturais são muito úteis para a discriminação de floresta primária e sucessão secundária (ver Seção 1.8.1.3).

## 1.7. CLASSIFICAÇÃO DE IMAGENS

Em sensoriamento remoto, uma das técnicas de processamento de imagens mais importantes e utilizadas é a classificação digital. No processo de classificação, parte-se de uma imagem de entrada e gera-se uma imagem rotulada, onde cada *pixel* recebe um rótulo que identifica a classe a qual ele foi atribuído, segundo uma regra de decisão. O classificador pode ser denominado pontual quando a classificação é feita *pixel a pixel* ou por região quando a classificação é realizada num conjunto de *pixels* (região).

Os métodos de classificação podem ser divididos em dois grupos: supervisionados (semi-automático) ou não supervisionados (automático). No primeiro, supondo-se o número de classes presente na imagem conhecido, define-se um conjunto de amostras como pertencentes a cada uma das classes (amostras de treinamento), extrai-se algum tipo de informação destas amostras para cada classe (etapa de aprendizado ou treinamento), a partir da qual constroem-se critérios que permitirão agrupar os *pixels* ou regiões com características similares (classificação propriamente

dita). No segundo, é desconhecido o número de classes existente na imagem, e assim procura-se verificar a existência de grupos naturais de *pixels* ou regiões, de modo que elementos de um mesmo conjunto (classe) tenham características semelhantes, ao mesmo tempo que elementos de conjuntos diferentes possuam as características mais distintas possíveis. Desta forma, ao final da classificação, considera-se que os conjuntos encontrados pertençam a classes distintas.

A classificação digital de uma imagem pode ser realizada usando-se várias técnicas, tais como heurísticas, estatísticas, redes neurais, morfologia matemática, *clustering* (agrupamento), entre outras. Ao leitor interessado em mais detalhes sobre métodos e técnicas de classificação digital pode-se recomendar a consulta de Richards (1993), Mascarenhas e Velasco (1989), e Dutra et al. (1993).

A seguir, serão apresentados três métodos de classificação supervisionada, sendo os dois primeiros classificadores estatísticos pontuais e o último um classificador por região. O segundo método incorpora a informação contextual com o objetivo de melhorar a classificação pontual.

Sistemas para classificação e análise estatística de imagens SAR para dados mono-espectrais e polarimétricos, incorporando os três classificadores descritos a seguir, foram desenvolvidos e implementados no Instituto Nacional de Pesquisas Espaciais (INPE). Estes sistemas foram implementados em linguagem de programação IDL (*Interactive Data Language*), baseados na plataforma ENVI (*ENvironment for Visualizing Images*), são amigáveis (não requerendo treinamento específico do operador), possuem uma seqüência de passos natural e guiada (*goal-driven*) e permitem a incorporação de novos módulos, como por exemplo, outras distribuições para se modelar os dados.

### 1.7.1. 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  $\omega$  dada a ocorrência de um *pixel* com valor  $x$ . Isto é equivalente, após algumas simplificações, à maximização da seguinte função de verossimilhança:

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

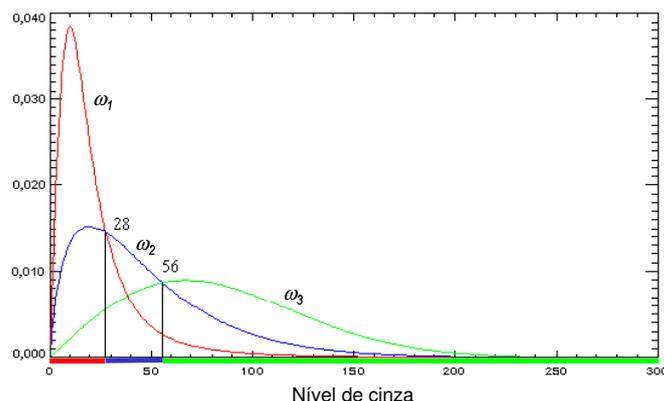
Dada a hipótese de equiprobabilidade das classes (isto é,  $Pr(\omega)$  é igual para todas as classes), a expressão anterior se reduz ao modelo de degradação adotado para o sinal ( $Pr(x/\omega)$ ). A maximização de  $L(\omega)$  é conhecida como a regra decisão por máxima verossimilhança, a qual dá o nome ao classificador. Para imagens ópticas, geralmente, adota-se a distribuição Gaussiana para modelar a  $Pr(x/\omega)$ .

O processo de maximização (classificação) é ilustrado graficamente na Figura 20, para o caso da classificação MaxVer utilizando dados mono-espectrais, considerando-se três classes  $\omega_1$ ,  $\omega_2$  e  $\omega_3$  (cujas distribuições são representadas nas cores vermelho, azul e verde, respectivamente). Para encontrar a classe que maximiza  $Pr(x/\omega)$ , procura-se aquela que possui os valores de sua distribuição superiores aos das outras

distribuições. Portanto, as regras de decisão para a atribuição de cada *pixel* a uma das classes  $\omega_1$ ,  $\omega_2$  ou  $\omega_3$ , do exemplo da Figura 20, são dadas por:

$$\begin{cases} x \leq 28 & \Rightarrow \text{o pixel pertence à classe } \omega_1 \\ 28 < x \leq 56 & \Rightarrow \text{o pixel pertence à classe } \omega_2 \\ x > 56 & \Rightarrow \text{o pixel pertence à classe } \omega_3 \end{cases}$$

e representadas na Figura 20 pelas faixas nas suas respectivas cores.

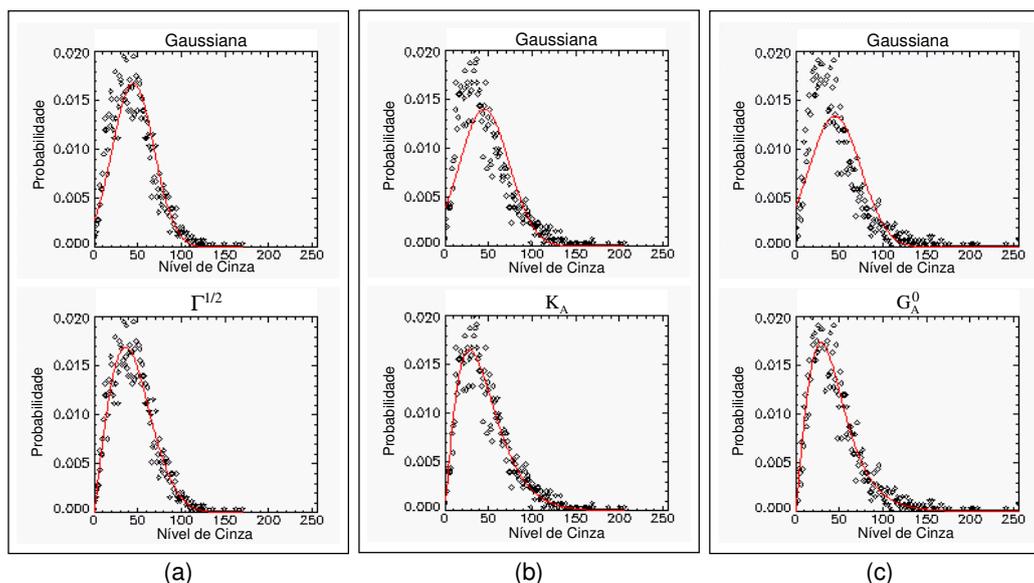


**Figura 20 - Distribuições associadas às classes  $\omega_1$ ,  $\omega_2$  e  $\omega_3$ , e as faixas de níveis de cinza utilizadas na classificação.**

Neste trabalho, o classificador pontual considerado como específico para imagens SAR é o MaxVer (ou seja, maximização de  $Pr(x/\omega)$  com  $Pr(\omega)$  igual para todas as classes), porém supondo a hipótese de que os dados SAR são melhores descritos pelas distribuições oriundas do modelo multiplicativo (vide Seção 1.5). Para ilustrar a relevância de se considerar diferentes distribuições para diferentes classes, ajustou-se aos dados de três classes distintas, as distribuições Gaussianas e as oriundas do modelo multiplicativo. Na Figura 21, são mostradas as distribuições  $\Gamma^{1/2}$  (Figura 21a),  $K_A$  (Figura 21b) e  $G_A^0$  (Figura 21c) que foram as melhores ajustadas a estes dados e as respectivas distribuições Gaussianas que seriam ajustadas aos dados destas classes, caso o modelo Gaussiano fosse adotado (a hipótese de que os dados proviessem de uma distribuição Gaussiana foi rejeitada em todos os casos, utilizando o teste de aderência de  $\chi^2$ ). Nesta figura, pode-se observar diferenças entre os ajustes das distribuições Gaussianas e as provindas do modelo multiplicativo, sendo estas diferenças mais significativas para as classes mais heterogêneas.

Em Vieira (1996), é reportado (para dois tipos de imagens) uma melhora média de aproximadamente 6% no desempenho do classificador MaxVer com as distribuições melhores ajustadas, quando comparado com o obtido pelo classificador MaxVer sob a hipótese de Gaussianidade. Esta melhoria relativamente pequena é devida ao fato de o classificador MaxVer só levar em conta a informação radiométrica pontual e também pela baixa relação sinal-ruído destas imagens.

O classificador MaxVer implementado no sistema desenvolvido no INPE, possibilita a classificação de dados monoespectrais em amplitude (utilizando as distribuições  $\Gamma^{1/2}$ ,  $K_A$  e  $G_A^0$  descritas na Seção 1.5.1.3, Weibull, Lognormal e Gaussiana), de dados polarimétricos completos (utilizando as distribuições dadas pelas Equações (8), (9) e (10)), e para dados provenientes dos polarimétricos (utilizando as distribuições dadas pelas Equações (11), (12), (13) e (14)).



**Figura 21 - Ajuste das distribuições Gaussianas e das mais apropriadas a dados de três classes com diferentes graus de homogeneidade: (a) Raiz Quadrada da Gama (homogênea), (b) K-Amplitude (heterogênea) e (c)  $G^0$ -Amplitude (extremamente heterogênea).**

### 1.7.2. 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, dadas as classes (Frery, 1993), e foi utilizada em processamento de imagens, entre outros, por Besag (1986 e 1989) e Geman e Geman (1984). O modelo de Potts-Strauss (que é um caso particular dos campos aleatórios Markovianos) é usado para descrever, de forma estatística, esta dependência espacial, e dentro da formulação Bayesiana, é empregado na modelagem da distribuição *a priori* no desenvolvimento do classificador contextual.

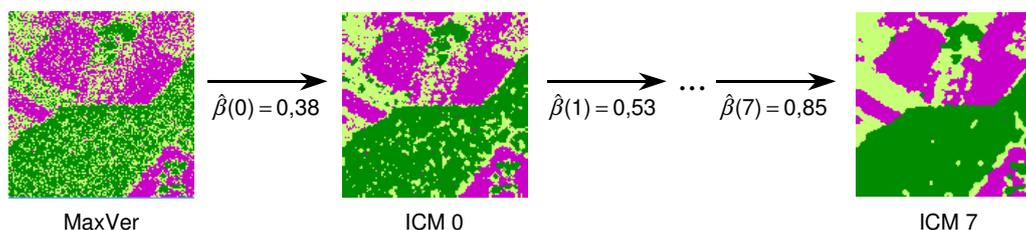
Agora, conhecidos o modelo de degradação,  $Pr(x/\omega)$ , e a distribuição *a priori*,  $Pr(\omega)$ , tem-se que procurar um estimador para a distribuição *a posteriori*, como no caso MaxVer. Segundo Frery (1993), os principais estimadores relacionados à técnicas Markovianas são os de Máximo a Posteriori (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 certas 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 MaxVer) e as classes vizinhas (componente contexto). Quando o modelo de Potts-Strauss 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  $\omega$ , com o nível de cinza  $z_s$  na coordenada  $s$ ,  $\beta$  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  $\partial_s$  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  $\beta$ , recomenda-se Frery (1993), Vieira (1996) e Frery et al. (1997c). A Figura 22 ilustra o processo iterativo de refinamento do algoritmo ICM na classificação de uma imagem SAR, partindo-se inicialmente de uma classificação MaxVer. Nesta figura, pode-se observar que para cada iteração (imagem ICM-0 até a imagem ICM-7) o parâmetro  $\beta$  estimado ( $\hat{\beta}$ ) possui um valor diferente, e que há uma melhoria na classificação em cada passo.



**Figura 22 - Processo iterativo de refinamento da classificação ICM.**

Em Vieira et al. (1997), é relatado que o uso da informação contextual (através do algoritmo ICM), juntamente com o uso das melhores distribuições ajustadas aos dados, permite a obtenção de resultados de classificação, em média, 94% melhores quando comparados aqueles obtidos com a classificação MaxVer. Entretanto, esta melhora no desempenho de classificação ICM é conseguida a um custo e complexidade computacional maiores que os do classificador MaxVer. Outros resultados da classificação ICM usando dados SAR podem ser encontrados em Sant'Anna et al. (1997), Frery et al. (1997c), Sant'Anna et al. (1998).

Vale ressaltar que os classificadores MaxVer e ICM apresentados anteriormente para imagens SAR foram descritos para dados monoespectrais (ou seja, dados com apenas uma banda espectral e uma única polarização). Porém, os mesmos conceitos podem ser aplicados a dados polarimétricos *multi-look*. Neste caso,  $Pr(x/\omega)$  tem sido modelada utilizando-se as distribuições definidas pelas Equações (8) a (14). Os exemplos de aplicação apresentados neste trabalho (Seção 1.8.2), utilizam as distribuições para os dados polarimétricos (par de intensidades, diferença de fase, razão de intensidades e par intensidade-diferença de fase), definidas pelas Equações (11) a (14). O classificador contextual ICM irá refinar a classificação MaxVer obtida por um dos diferentes tipos de dados polarimétricos. Exemplos do uso do

MaxVer/ICM para a classificação de dados polarimétricos podem ser encontrados em Correia (1998) e Freitas et al. (1998).

O classificador ICM implementado no sistema desenvolvido no INPE utiliza as mesmas distribuições usadas no classificador MaxVer descrito na seção anterior. O contexto, neste classificador, é incorporado considerando-se os oito vizinhos mais próximos ao *pixel* a ser classificado.

### 1.7.3. Classificador por Regiões

Os classificadores por regiões podem utilizar, além da informação espectral (nível de cinza) de cada *pixel*, a informação espacial que descreve a relação entre um *pixel* e seus vizinhos. Cada região ou segmento representa uma área da imagem que é homogênea sob algum aspecto.

O processo de segmentação de uma imagem, de modo simplificado, consiste da sua partição em regiões disjuntas (regiões sem interseção), seja observando uma característica que se mantenha uniforme ao longo desta região ou através da detecção de descontinuidades (bordas) presentes nesta imagem. Dois métodos clássicos de segmentação são o de crescimento de regiões e o de detecção de bordas. No primeiro método, os *pixels* são agrupados de acordo com a similaridade existente entre esses *pixels*. O processo é realizado iterativamente, considerando inicialmente cada *pixel* como uma região distinta. A cada iteração é feito um teste de igualdade de médias de um atributo entre regiões vizinhas, que serão agrupadas caso este teste indique que estas regiões sejam similares (neste caso, adotando-se um limiar de aceitação para a hipótese de igualdade de médias). No segundo método, procura-se determinar os limites (bordas) de cada região, identificando-se e perseguindo-se as bordas encontradas na imagem na qual se realizou estas feições utilizando-se, por exemplo, o filtro de Sobel (Jain, 1989).

Pode-se verificar que esses métodos de segmentação são muito sensíveis à presença de ruídos e dessa forma, não apresentam em geral bom desempenho quando utilizados sobre imagens de radar, resultando numa excessiva segmentação da imagem (um número extremamente grande de regiões). Especificamente para imagens de radar, foram desenvolvidos métodos de segmentação que utilizam as distribuições mais apropriadas para esse tipo de dado para decidir sobre a similaridade entre duas regiões. Entre estes métodos, pode-se citar: *Annealing* (Oliver e Quegan, 1998), *Merge Using Moments* (Cook et al., 1994) e *RWSEG* (White, 1986).

Cada região (segmento) pode ser considerada como um elemento único (objeto) ou como um conjunto de *pixels* da imagem que compõem esta região. No primeiro caso, a região possui um ou mais atributos que podem descrever a natureza estatística dos dados, a forma geométrica da região, a textura ou a relação espacial existentes entre os diferentes *pixels* que compõem esta região. Dessa forma, cada região pode ser interpretada de forma similar a um *pixel* e as técnicas desenvolvidas para classificação pontual podem ser então perfeitamente aplicáveis. No caso de se considerar os valores de todos os *pixels* de uma região, pode-se proceder à classificação, de uma maneira bastante simplificada, através da comparação entre a distribuição dos valores dos *pixels* desta região e a distribuição dos valores de cada classe, usando alguma medida de similaridade.

De modo geral, assim como a classificação pontual, a classificação por região pode utilizar critérios probabilísticos (através da maximização de funções de verossimilhança, por exemplo) para decidir a classe para qual será atribuída cada uma das regiões analisadas. Para tanto, faz-se necessário o conhecimento prévio da distribuição associada aos dados de cada classe considerada. Como alternativa, pode-

se adotar medidas de separabilidade como critério no processo de classificação. Entre estas medidas, destacam-se a distância quarteirão, euclidiana, a de Mahalanobis, a de Bhattacharyya e a de Jeffries-Matusita. Para maiores detalhes sobre medidas de separabilidade recomenda-se Richards (1993).

Em Rennó et al. (1998), é apresentado o sistema desenvolvido no INPE, o qual envolve a extração e seleção de medidas texturais, e a classificação por região de uma imagem. As medidas utilizadas são divididas em quatro grupos:

- Medidas de Haralick:: contraste, entropia, energia, homogeneidade, correlação, dissimilaridade, chi-quadrado, *cluster shade*, *cluster prominence*, e média, variância, entropia e energia dos vetores soma e diferença, e contraste do vetor diferença.
- Medidas distribucionais: estimadores da média, variância e desvio padrão das distribuições Gaussiana e Lognormal, e estimadores do parâmetro  $\alpha$  baseados nos momentos das distribuições K-Intensidade e K-Amplitude;
- Medidas de primeira ordem: desvio médio absoluto, assimetria, curtose, coeficiente de variação, mediana, entropia e energia; e
- Autocorrelações espaciais e razões entre elas: considerando *lags* de -4 a 4.

A seleção de medidas que melhor discriminam as classes de interesse é obtida, considerando um par de classes  $A$  e  $B$ , pelo fator discriminante definido por:

$$FD_{AB} = \frac{n_A \cdot \sum_{i=1}^{n_A} (X_{Ai} - \bar{X}_A)^2 + n_B \cdot \sum_{i=1}^{n_B} (X_{Bi} - \bar{X}_B)^2}{n_A \cdot \sum_{i=1}^{n_A} (X_{Ai} - \bar{X}_B)^2 + n_B \cdot \sum_{i=1}^{n_B} (X_{Bi} - \bar{X}_A)^2}, \quad (15)$$

onde  $X_\omega$  ( $\omega = A$  ou  $B$ ) é o valor da medida para a  $i$ -ésima amostra,  $\bar{X}_\omega$  é o valor médio da medida e  $n_\omega$  é o número de amostras da classe  $\omega$ . Quanto maior a separabilidade entre as classes, maior será este fator. Portanto, para cada par de classes, é escolhida a medida que apresenta o maior valor do fator discriminante. A classificação propriamente dita é efetuada extraíndo-se as medidas selecionadas para cada região da imagem e atribuindo-a à classe que minimiza a distância de Mahalanobis.

## 1.8. EXEMPLOS DE APLICAÇÕES

Alguns resultados obtidos com o uso dos classificadores/sistemas acima citados serão apresentados a seguir. Objetiva-se exemplificar o uso de imagens SAR no mapeamento de diferentes usos e ocupações do solo, com ênfase em vegetação, utilizando a classificação digital. Esses exemplos fazem uso de imagens adquiridas pelos seguintes sistemas:

- **SAR-580** - SAR aerotransportado, banda L (1,2 GHz), polarização HH, resolução azimutal e em *range* de 3m, *pixel spacing* de 1,5m, imagem amplitude (8 bits/pixel), 1-look;
- **JERS-1** - SAR orbital, banda L (1,275 GHz), polarização HH, resolução azimutal e em *range* de aproximadamente de 18m, *pixel spacing* de 12,5m, imagem amplitude (16 bits/pixel), 3-looks, ângulo de incidência de 38°;

- **RADARSAT** - SAR orbital, banda C (5,3 GHz), polarização HH, resolução azimutal de 8,4m e em *range* de 7,8m (*Fine Mode*), *pixel spacing* de 3,125m, imagem amplitude (16 *bits/pixel*), 1-look, ângulo de incidência de 45° a 48°; e
- **SIRC-C** - SAR orbital, bandas C (5,304 GHz) e L (1,254 GHz), polarizações HH, HV e VV, resolução azimutal e em *range* de 25m, *pixel spacing* de 12,5m, imagem *multi-look* complexa (64 *bits/pixel*), 4,785 *looks*, ângulo de incidência de aproximadamente 49°.

### 1.8.1. Uso de classificador pontual/contextual em dados monoespectrais

Nesta seção, serão apresentados exemplos do uso do classificador MaxVer/ICM em imagens adquiridas pelos sistemas SAR-580, JERS-1 e RADARSAT.

Os resultados obtidos da classificação MaxVer/ICM de imagens adquiridas pelos sensores SAR-580 e JERS-1 são apresentados em Vieira (1996) e em Vieira et al. (1997). Em Sant'Anna et al. (1997), apresentam-se os resultados obtidos da classificação MaxVer/ICM da imagem adquirida pelo RADARSAT. É apresentado aqui, um resumo destes resultados.

#### 1.8.1.1. Resultados para imagem do SAR-580

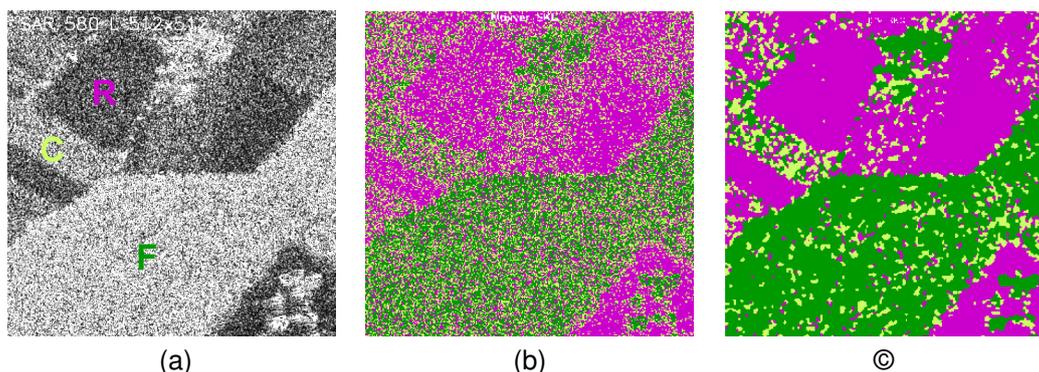
A imagem do SAR-580 da região de Freiburg, Alemanha é mostrada na Figura 23a. Foram definidas três classes de interesse: Floresta, Cultura e Restolho, identificadas na Figura 23a pelas letras F, C e R, respectivamente. Destas áreas foram retiradas amostras para a seleção das distribuições que melhor se ajustaram a cada uma das classes, através do teste de aderência de  $\chi^2$ . A distribuição que mais se ajustou à classe Floresta foi a  $G_A^0$ ; para a classe Cultura foi a  $K_A$  e para a classe Restolho foi a Raiz Quadrada da Gama (ou, neste caso, como o número de *looks* é igual a um, a distribuição Rayleigh). Portanto, considerando-se as distribuições ajustadas, o grau de homogeneidade é maior para a classe Restolho e menor para classe Floresta.

Foram obtidas as classificações MaxVer e ICM, tanto para a hipótese de Gaussianidade das classes, quanto para a hipótese da distribuição mais ajustada para as observações de cada classe. As Figuras 23b e c apresentam os resultados das classificações MaxVer e ICM, respectivamente, com o uso das distribuições mais ajustadas para as observações de cada classe. As classificações ICM foram iniciadas com as classificações MaxVer. As classes Floresta, Cultura e Restolho estão representadas respectivamente pelas cores verde escuro, verde claro e magenta. A Tabela 2 apresenta, para cada classificação, os valores estimados do coeficiente de concordância Kappa ( $\hat{\kappa}$ ) (Richards, 1993), e das suas respectivas variâncias ( $s_{\hat{\kappa}}^2$ ) obtidos através de amostras de teste.

**Tabela 2 - Valores estimados do coeficiente de concordância Kappa ( $\hat{\kappa}$ ), e de suas variâncias ( $s_{\hat{\kappa}}^2$ ).**

Classificação	$\hat{\kappa}$	$s_{\hat{\kappa}}^2$
MaxVer Gaussianas	0,3859	$7,296 \times 10^{-5}$
MaxVer Ajustadas	0,4060	$6,206 \times 10^{-5}$
ICM Gaussianas	0,7222	$3,321 \times 10^{-5}$
ICM Ajustadas	0,7688	$2,895 \times 10^{-5}$

Fonte: Adaptada de Vieira et al. (1997), p. 183.



**Figura 23 - Imagens: (a) SAR-580 original, (b) classificada pelo método MaxVer e (c) classificada pelo método ICM.**

**Fonte: Adaptada de Vieira et al. (1997), p. 183.**

Os testes para a igualdade dos coeficientes de concordância Kappa foram efetuados para todos os pares de classificações. Estes testes foram todos estatisticamente significativos para níveis de significância acima de 10%.

Dessa forma, pode-se afirmar que, para a imagem do SAR-580:

- a classificação MaxVer com o uso das distribuições mais ajustadas às classes apresenta um resultado de melhor qualidade, quando comparada à MaxVer com o uso de distribuições Gaussianas. Pelos resultados apresentados na Tabela 2, é possível verificar que houve uma melhora de 5,2% para o  $\hat{\kappa}$  da classificação MaxVer ao se utilizar as distribuições mais ajustadas;
- a classificação ICM com o uso das distribuições mais ajustadas às classes apresenta um resultado de melhor qualidade, quando comparada à ICM com o uso de distribuições Gaussianas. Através da Tabela 2, é possível verificar que houve uma melhora de 6,5% para o  $\hat{\kappa}$  da classificação ICM ao se utilizar as distribuições mais ajustadas; e
- a classificação ICM é sempre superior à classificação MaxVer. Pelos resultados apresentados na Tabela 2, pode-se verificar que houve uma melhora média de 88,3% para o  $\hat{\kappa}$  ao se utilizar a classificação ICM em substituição à MaxVer.

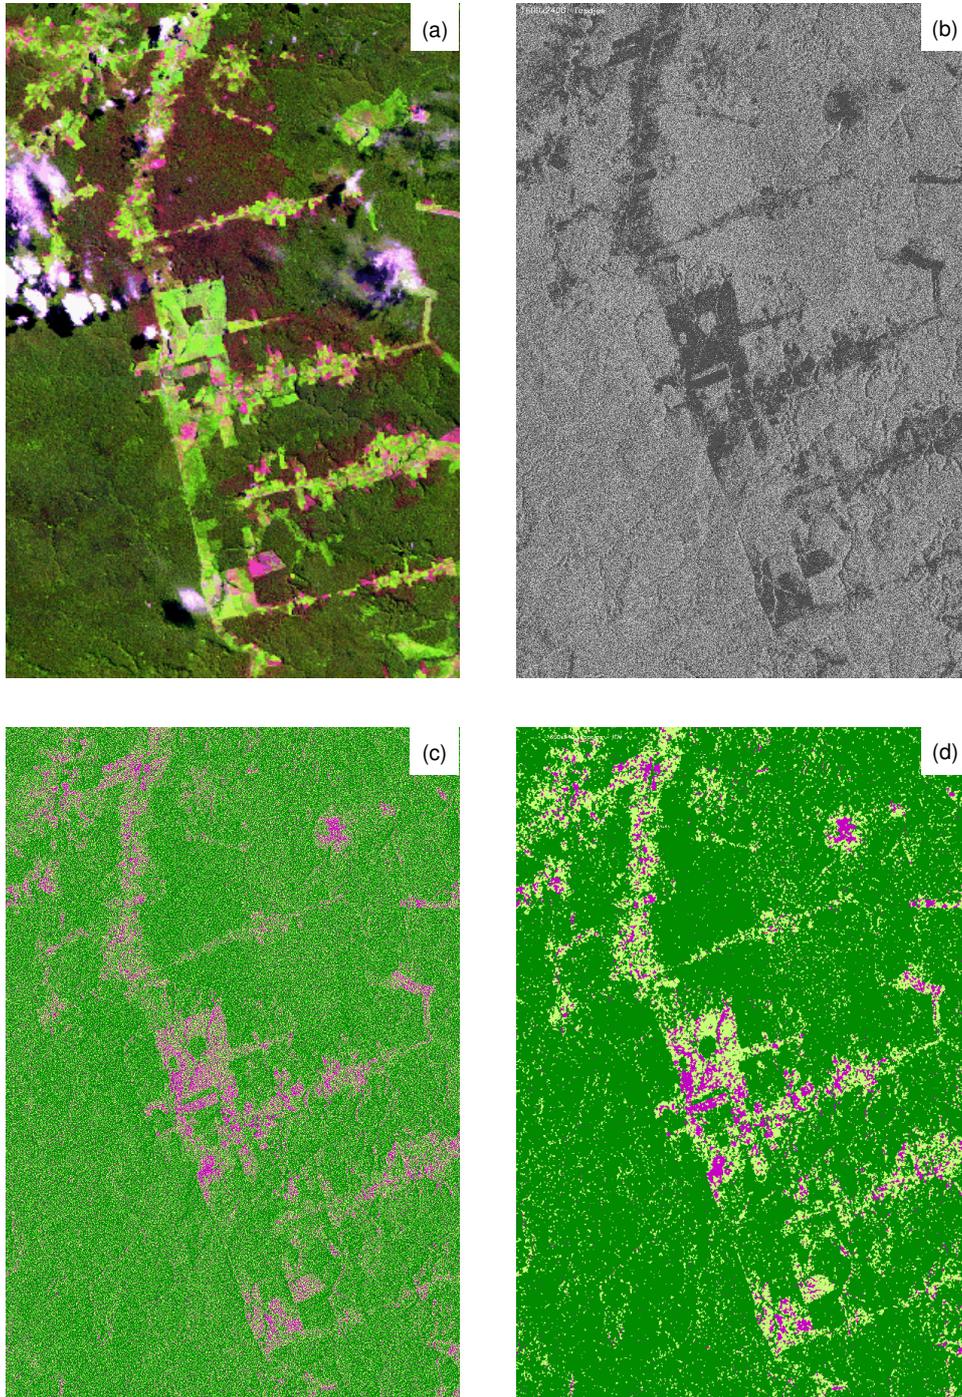
### 1.8.1.2. Resultados para a imagem do JERS-1

A imagem do JERS-1, da região da Floresta Nacional de Tapajós, Pará, Brasil, é apresentada na Figura 24b. As classes de uso do solo de interesse são Solo Exposto/Pastagem, Regeneração (Floresta Secundária) e Floresta Primária, que podem ser identificadas na Figura 24a (imagem do TM-Landsat, utilizada somente como referência) pelas cores: magenta/amarelo claro, verde claro e verde escuro, respectivamente. As classes Solo Exposto e Pastagem foram agrupadas em uma única classe.

A distribuição que mais se ajustou aos dados foi a  $G_A^0$ , para todas as três classes de interesse.

As classificações MaxVer e ICM foram obtidas, tanto sob a suposição de normalidade dos dados, quanto sob a suposição da distribuição mais ajustada à cada classe. Os coeficientes de concordância Kappa foram estimados para cada classificação, através das respectivas matrizes de confusão obtidas das amostras de teste. A Tabela 3

apresenta os valores estimados do coeficiente de concordância Kappa ( $\hat{\kappa}$ ), e de suas respectivas variâncias ( $s_{\hat{\kappa}}^2$ ).



**Figura 24 - Imagens: (a) TM-Landsat na composição colorida, bandas 5, 4 e 3 (RGB); (b) JERS-1 original; (c) classificada pelo método MaxVer e (d) classificada pelo método ICM.**

**Fonte: Adaptada de Vieira et al. (1997), p.184.**

**Tabela 3 - Valores estimados do coeficiente de concordância Kappa ( $\hat{\kappa}$ ), e de suas variâncias ( $s_{\hat{\kappa}}^2$ ).**

Classificação	$\hat{\kappa}$	$s_{\hat{\kappa}}^2$
MaxVer Gaussianas	0,3283	$10,300 \times 10^{-5}$
MaxVer Ajustadas	0,3728	$9,789 \times 10^{-5}$
ICM Gaussianas	0,6559	$8,717 \times 10^{-5}$
ICM Ajustadas	0,7388	$6,779 \times 10^{-5}$

**Fonte: Adaptada de Vieira et al. (1997), p. 184.**

Os testes para a igualdade dos coeficientes de concordância Kappa foram efetuados para todos os pares de classificações, indicando que os coeficientes de concordância Kappa são estatisticamente diferentes para todos esses pares, para níveis de significância de ordem prática.

Portanto, pode-se afirmar que para a imagem do JERS-1 utilizada:

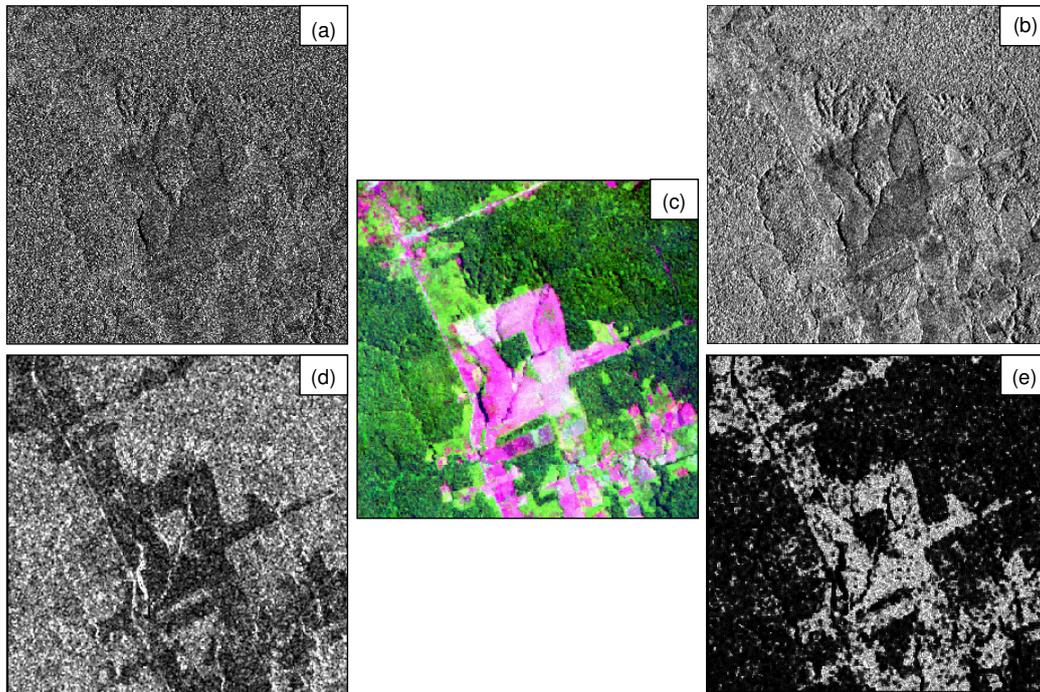
- a classificação MaxVer, com o uso das distribuições mais ajustadas às classes, apresenta um resultado de melhor qualidade quando comparada à MaxVer obtida com o uso de distribuições Gaussianas. Pelos resultados apresentados na Tabela 3, pode-se verificar que houve uma melhora de 13,6% para o  $\hat{\kappa}$  da classificação MaxVer ao se utilizar as distribuições mais ajustadas aos dados SAR;
- a classificação ICM, com o uso das distribuições mais ajustadas às classes, é de melhor qualidade quando comparada à classificação ICM com o uso de distribuições Gaussianas, havendo uma melhora de 12,6% para o valor  $\hat{\kappa}$ ; e
- a classificação ICM é superior à classificação MaxVer, havendo uma melhora média de 99% para o valor  $\hat{\kappa}$  ao se utilizar a classificação ICM em substituição à MaxVer.

As Figuras 24c e d apresentam os resultados da classificações MaxVer e ICM, respectivamente, da imagem do JERS-1 com o uso das distribuições mais ajustadas para as classes. As classes estão representadas pelas cores magenta (Solo Exposto e Pastagem), verde claro (Regeneração) e verde escuro (Floresta). Estas figuras evidenciam a superioridade da classificação ICM quando comparada à classificação MaxVer.

### 1.8.1.3. Resultados para a imagem do RADARSAT

A imagem do RADARSAT, datada de 3 de maio de 1996, da região de Tapajós é utilizada para mostrar outro exemplo das classificações MaxVer/ICM em imagens SAR. A resolução espacial desta imagem foi degradada computando-se a raiz quadrada da média de 9 *pixels* em intensidade. Isto é, a cada conjunto de  $3 \times 3$  *pixels* calculou-se a média gerando um novo valor de nível de cinza, aumentando-se assim o número de visadas nominal. A partir desta imagem degradada (Figura 25a) gerou-se, através do processo de filtragem, três outras imagens: uma com aplicação do filtro de Frost (Figura 25b) e as demais usando-se estimadores do coeficiente de variação (CV) e do parâmetro  $\alpha$  da distribuição K-Amplitude (Figuras 25d e e, respectivamente). No processo de filtragem destas imagens, empregou-se respectivamente os tamanhos de  $5 \times 5$ ,  $7 \times 7$  e  $11 \times 11$  *pixels* para a janela de processamento. A imagem gerada pela filtragem com o algoritmo de Frost apresenta um contraste geral maior que o da

imagem degradada. A imagem do TM-Landsat é utilizada como referência e é mostrada na Figura 25c.



**Figura 25 – Imagens: (a) do RADARSAT degradada; (b) filtrada pelo algoritmo de Frost; (c) TM-Landsat na composição colorida, bandas 5, 4 e 3 (RGB); (d) do coeficiente de variação; e (e) do parâmetro  $\alpha$  da K-Amplitude.**

**Fonte: Adaptada de Sant'Anna et al. (1997), p. 189.**

Para efeito de classificação considerou-se apenas as classes dominantes na imagem, que são:

- Atividade Recente (Solo Nu e Pastagem): que aparece na Figura 25c na cor magenta e apresenta uma textura mais lisa na Figura 25b;
- Regeneração ou Sucessão Secundária: que aparece na Figura 25c na cor verde mais clara e apresenta uma textura moderada na Figura 25b; e
- Floresta Primária: que aparece na Figura 25c na cor verde escuro e apresenta uma textura rugosa na Figura 25b.

Pode-se verificar que a distinção destas três classes não é evidente na imagem original do RADARSAT, onde os níveis de cinza médio das classes Floresta Primária e Regeneração são muito próximos e maiores que o da classe Atividade Recente. Nota-se, através das Figuras 25d e e, que os estimadores do coeficiente de variação e do parâmetro  $\alpha$  da distribuição K-Amplitude permitem discriminar a classe Floresta Primária das demais classes. As classes Atividade Recente e Regeneração podem ser consideradas mais homogêneas que a Floresta Primária por possuírem valores de  $\alpha$  maiores.

O teste de aderência do  $\chi^2$  foi usado para selecionar as distribuições que melhor se ajustaram aos dados. As distribuições selecionadas foram utilizadas na classificação MaxVer e ICM e são apresentadas na Tabela 4. A distribuição Gaussiana foi utilizada

para modelar as observações das três classes da imagem filtrada pelo parâmetro  $\alpha$ , muito embora estas observações não tenham sido bem ajustadas a nenhuma das distribuições.

**Tabela 4 - Distribuições utilizadas para as classificações MaxVer/ICM.**

Imagem	Classes		
	Ativ. Recente	Regeneração	Floresta
Degradada	Lognormal	Lognormal	$G_A^0$
Frost	$K_A$	Lognormal	$K_A$
Coef. de Variação	Lognormal	Lognormal	Lognormal
$\alpha$ da K-Amplitude	Gaussiana	Gaussiana	Gaussiana

**Fonte: Adaptada de Sant'Anna et al. (1997), p. 190.**

As imagens classificadas usando apenas a informação tonal (imagens degradada ou filtrada pelo algoritmo de Frost) apresentaram muita confusão entre as classes Floresta e Regeneração. Já as imagens classificadas usando a informação textural (imagens filtradas pelo coeficiente de variação ou pelo parâmetro  $\alpha$ ) apresentaram muita confusão entre Atividade Recente e Regeneração. Contudo, com a informação textural, é possível separar as classes Floresta e não Floresta (Regeneração e Atividade Recente). Para se obter melhores resultados de classificação, utilizando-se os atributos tonal e textural, efetuou-se o cruzamento das classificações através de operações Booleanas (classificação cruzada). Estas operações foram aplicadas em pares de imagens classificadas, uma gerada a partir da classificação da imagem degradada ou filtrada pelo filtro de Frost e a outra a partir da classificação da imagem do coeficiente de variação ou do parâmetro  $\alpha$ .

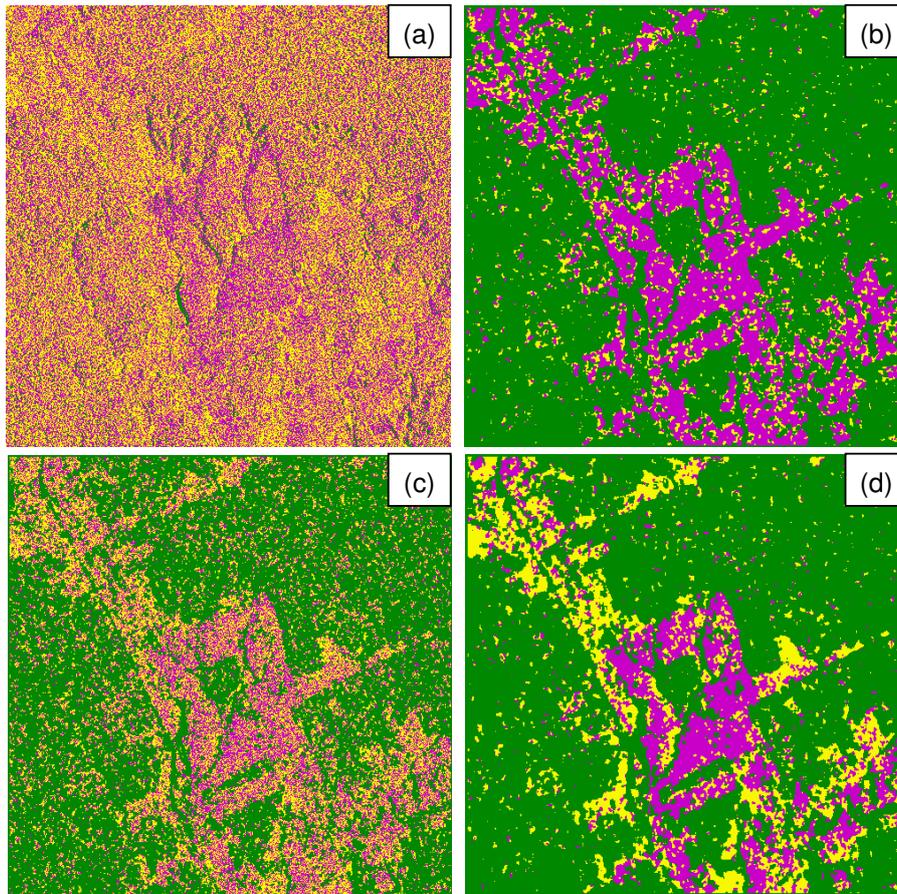
A avaliação dos resultados das classificações foi efetuada através da análise visual das classificações, das matrizes de confusão, e dos respectivos valores estimados do coeficiente de concordância Kappa ( $\hat{\kappa}$ ). Na Tabela 5, são apresentados os valores estimados do coeficiente de concordância Kappa ( $\hat{\kappa}$ ) para cada uma das imagens classificadas.

**Tabela 5 - Valores estimados do coeficiente de concordância Kappa ( $\hat{\kappa}$ ).**

		Classificação	MaxVer	ICM
Individuais	Degradada		0,0514	0,1150
	Frost		0,0952	0,1300
	Coeficiente Variação		0,4635	0,5430
	$\alpha$ da K Amplitude		0,6304	0,7072
Cruzadas	Degradada e CV		0,4385	0,6141
	Frost e CV		0,5136	0,6408
	Degradada e $\alpha$		0,5673	0,6912
	Frost e $\alpha$		0,6454	0,7176

**Fonte: Adaptada de Sant'Anna et al. (1997)**

Na Figura 26, são mostradas as imagens classificadas que obtiveram os piores e os melhores resultados das classificações individuais e cruzadas (menores e maiores valores de  $\hat{\kappa}$ ).



**Figura 26 - Imagens das classificações: (a) MaxVer da imagem degradada; (b) ICM da imagem  $\alpha$ ; (c) resultante do cruzamento da MaxVer da imagem degradada e da MaxVer da imagem CV; e (d) resultante do cruzamento da ICM da imagem Frost e da ICM da imagem  $\alpha$ .**

**Fonte: Adaptada de Sant'Anna et al. (1997).**

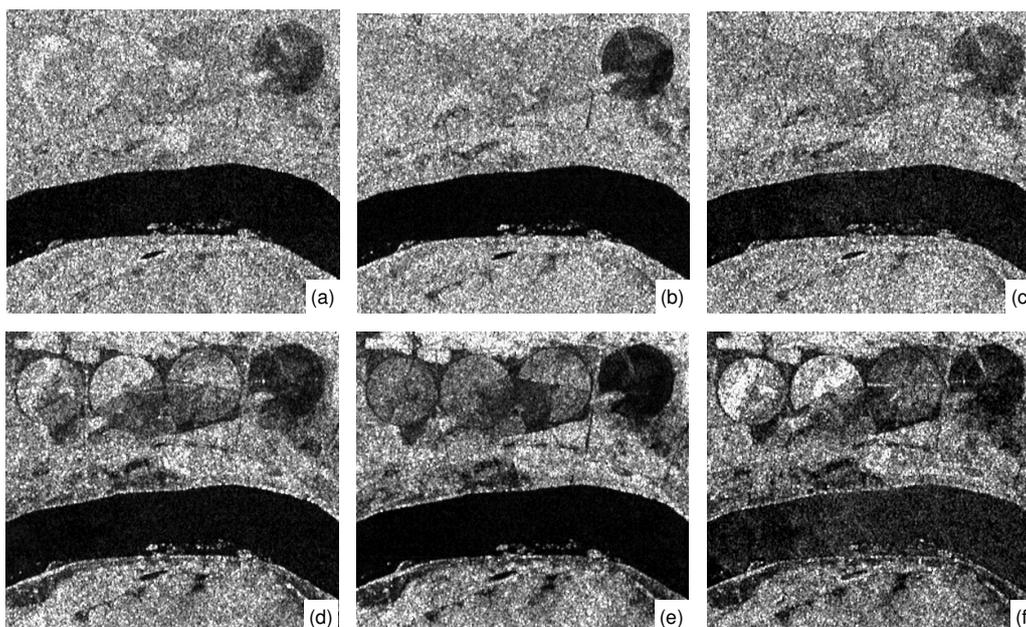
Através da análise, pode-se concluir que:

- as classificações em que foi utilizada a imagem classificada baseada no parâmetro  $\alpha$  apresentaram melhores resultados do que as baseadas no coeficiente de variação, evidenciando a relevância do uso deste parâmetro em classificadores;
- as classificações em que foi utilizada a imagem classificada baseada no filtro de Frost apresentaram melhores resultados do que as baseadas na imagem original degradada, evidenciando a importância de filtros redutores de *speckle* nas classificações;
- o melhor resultado de classificação foi obtido utilizando-se as imagens classificadas baseadas no filtro de Frost e no parâmetro  $\alpha$ , na classificação ICM;
- verificou-se que todas as estimativas encontradas para o coeficiente de concordância  $\hat{\kappa}$  foram estatisticamente diferentes entre si;

- pode-se observar que os resultados da classificação ICM é sempre superior aos da classificação MaxVer, mostrando a relevância do contexto quando se classifica imagens de radar;
- para as três classes utilizadas nas classificações destas imagens notou-se a fundamental importância da informação textural;
- o melhor resultado de classificação foi obtido cruzando-se as classificações ICM das imagens filtradas pelo algoritmo de Frost e pelo estimador do parâmetro  $\alpha$ ; e
- o resultado da classificação cruzada ICM (Frost x  $\alpha$ ) proporcionou um incremento de apenas 1,5% em relação a classificação ICM obtida com a imagem do parâmetro  $\alpha$ , evidenciando que a informação textural é a maior responsável pelo alto desempenho da classificação.

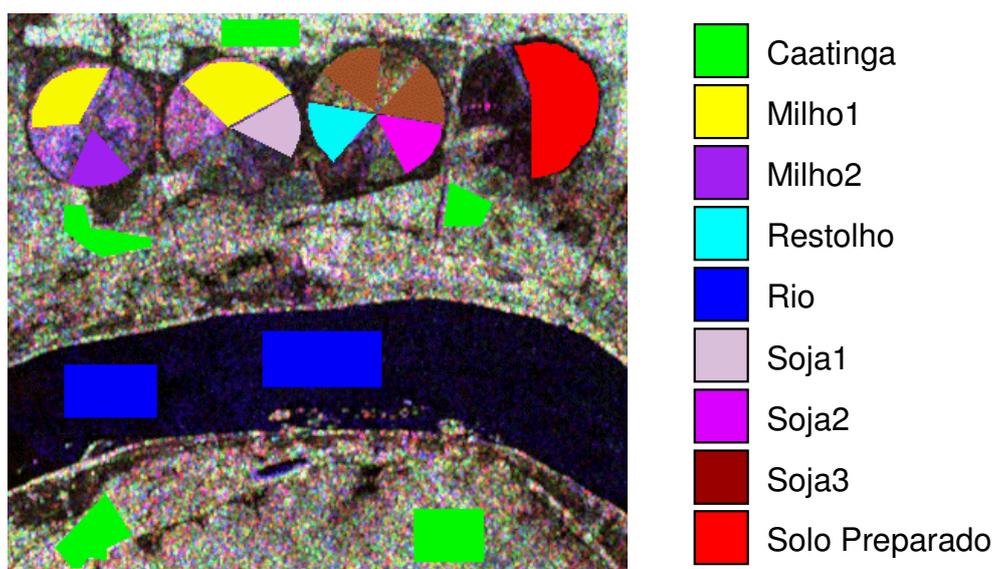
### 1.8.2. Uso de classificador pontual/contextual em dados polarimétricas

Os resultados aqui apresentados foram extraídos de Correia (1998), obtidos a partir das imagens polarimétricas da missão SIR-C/X-SAR de 14/04/1994, nas bandas L e C, do Projeto de Irrigação de Bebedouro, próximo a cidade de Petrolina-PE. Na Figura 27, pode-se observar cada uma das componentes polarimétricas (HH, HV e VV) em amplitude, para as bandas C e L.



**Figura 27 - 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 27, 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 28, identificadas através das amostras de treinamento, 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.



**Figura 28 - Composição colorida (R-HH, G-HV e B-VV) da imagem de Bebedouro com as amostras de treinamento das classes de interesse.**

**Fonte: Adaptada de Correia (1998), p.129.**

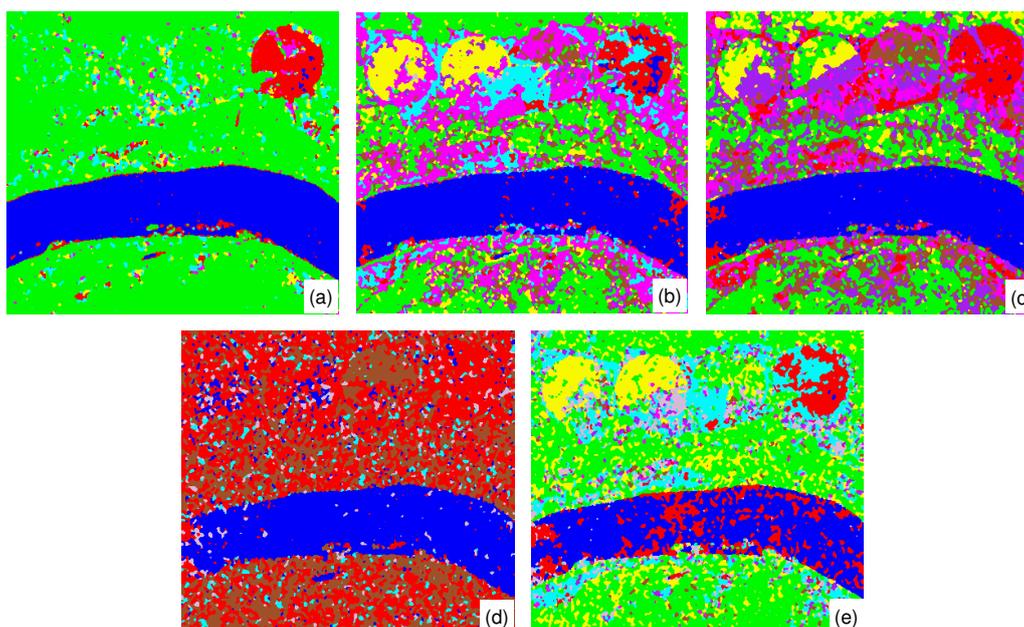
Como mostrado em Correia (1998), de posse das amostras de treinamento das classes foram realizadas todas as combinações possíveis entre as componentes polarimétricas, para as bandas C e L, para cada um dos classificadores MaxVer/ICM baseados nas distribuições univariadas (razão de imagens em intensidade e diferença de fase) e bivariadas (par de imagens em intensidade e par de imagens intensidade-diferença de fase), conforme descritas na Seção 1.5.2.

De posse das classificações MaxVer e ICM, para cada tipo de dado uni/bivariado polarimétrico, para as bandas L e C, foram geradas as respectivas matrizes de confusão dessas classificações, utilizando-se as amostras de testes (diferentes das amostras de treinamento). Devida à grande quantidade de classificações geradas, são mostrados na Tabela 6 apenas os valores de Kappa ( $\hat{\kappa}$ ) e das respectivas variâncias ( $s_{\hat{\kappa}}^2$ ) das classificações que melhor discriminaram cada classe de interesse. Essas classificações podem ser vistas na Figura 29.

**Tabela 6 – Valores estimados do coeficiente de concordância Kappa ( $\hat{\kappa}$ ), e de suas variâncias ( $s_{\hat{\kappa}}^2$ ).**

Classificação	$\hat{\kappa}$	$s_{\hat{\kappa}}^2$
ICM Intensidade-Fase L-HHV	0,6062	$1,998 \times 10^{-5}$
ICM Razão L-HHV	0,3572	$1,507 \times 10^{-5}$
ICM Par-Intensidade C-HVV	0,5824	$1,987 \times 10^{-5}$
ICM Par-Intensidade L-HVV	0,6824	$1,714 \times 10^{-5}$
ICM Par-Intensidade L-HHV	0,6498	$1,904 \times 10^{-5}$

**Fonte: Adaptada de Correia (1998).**



**Figura 29 - Classificações: Par de imagens em intensidade (a) ICM C-HVVV, (b) ICM L-HVVV, (c) ICM L-HHVV, (d) ICM da razão de imagens em intensidade L-HHVV, (e) ICM do par de imagens intensidade-diferença de fase L-HHVV.**

**Fonte: Adaptada de Correia (1998).**

Com base na Tabela 6, foram realizados os testes de hipóteses para verificação da igualdade dos coeficientes de concordância  $\hat{\kappa}$ , sendo todas as classificações estatisticamente diferentes aos níveis de significância de ordem prática. Com isso pode-se afirmar que a classificação ICM Par-intensidade L-HVVV, por apresentar um coeficiente de concordância  $\hat{\kappa}$  superior as demais, foi a que apresentou melhor resultado, em média, 31,44% melhor que as demais classificações.

É importante notar que, a classificação ICM Par-Intensidade L-HVVV, apesar de ter sido a melhor segundo o valor de  $\hat{\kappa}$ , não forneceu a melhor classificação para todas as classes de interesse. Este fato pode ser visto na Tabela 7 onde são mostradas as classificações que melhor discriminaram cada uma das classes de interesse.

Pode-se concluir, a partir da Tabela 7, 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 as observações da Tabela 7 indicam que existe uma grande confusão entre as classes Soja2 e Milho2, de forma que, quando a classe Soja2 foi bem classificada a classe Milho2 foi totalmente confundida com Soja2, e vice-versa.

Estes resultados mostram que a utilização dos dados polarimétricos uni/bivariados não permitem 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, e 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).

**Tabela 7 – Melhores classificações dos dados polarimétricos uni/bivariados para cada classe.**

Classe	Classificação	Observações
Restolho	ICM Intensidade-Fase L-HHVV	
Caatinga		
Soja1		
Soja3	ICM Razão L-HHVV	
Rio	ICM Par-Intensidade C-HVVV	
Solo Preparado		
Milho1	ICM Par-Intensidade L-HVVV	Milho2, Soja1 e Soja3 foram confundidas com Soja2
Soja2		
Milho2	ICM Par-Intensidade L-HHVV	Soja1 e Soja2 foram confundidas com Milho2

Fonte: Correia (1998), p. 184.

### 1.8.3. Uso de classificador textural por regiões

A fim de avaliar a potencialidade do uso da informação textural em imagens SAR, Rennó et al. (1998) utilizaram uma imagem JERS-1 de 26 de junho de 1993 da região próxima à Floresta Nacional de Tapajós (FLONA), Estado do Pará (Figura 30a). A Figura 30b apresenta o mapa de uso e ocupação do solo com quatro classes: Floresta Primária (FP - verde escuro), Regeneração Antiga (RA - verde claro), Regeneração Nova (RN - amarelo) e Atividades Recentes (AR - magenta). Para geração deste mapa, foi realizado um agrupamento de classes do mapa de uso e ocupação do solo obtido a partir de uma seqüência temporal de imagens do TM-Landsat (de 1984 a 1993). A metodologia para a obtenção do mapa de uso e ocupação completo (original) é descrita em Sant'Anna et al. (1995).

Amostras de cada classe foram escolhidas com base no mapa de uso do solo, sendo extraídas, para cada amostra, um total de 35 medidas a partir da imagem do JERS-1, apresentadas na Seção 1.7.3. Todas as medidas de Haralick foram calculadas sobre uma matriz de co-ocorrência considerando oito vizinhos mais próximos de um *pixel*. Todas as medidas de primeira ordem e distribucionais foram utilizadas, exceto o estimador do parâmetro  $\alpha$  da K-Intensidade. Foram calculadas as autocorrelações espaciais para os *lags* (1,0) e (1,1), e a razão entre elas.

Dado este grande número de medidas, procedeu-se à seleção das medidas que melhor discriminaram as classes de interesse, segundo o fator discriminante descrito na Equação (15).

A Tabela 8 mostra as três melhores medidas de acordo com o fator discriminante para cada par de classes. Pode-se observar que a maior discriminação ocorreu entre as classes Floresta Primária e Regeneração Antiga quando foi utilizado a medida entropia de Haralick. Este resultado é muito importante pois estas classes não eram separáveis quando somente o valor médio de nível de cinza foi utilizado (Yanasse et al., 1993; Yanasse et al., 1997). As classes Floresta Primária e Atividades Recentes foram também bem discriminadas, uma vez que apresentaram alto valor discriminante. Os

menores valores do fator discriminante foram encontrados para o par de classes Regeneração Antiga/Regeneração Nova e Regeneração Nova/Atividades Recentes.

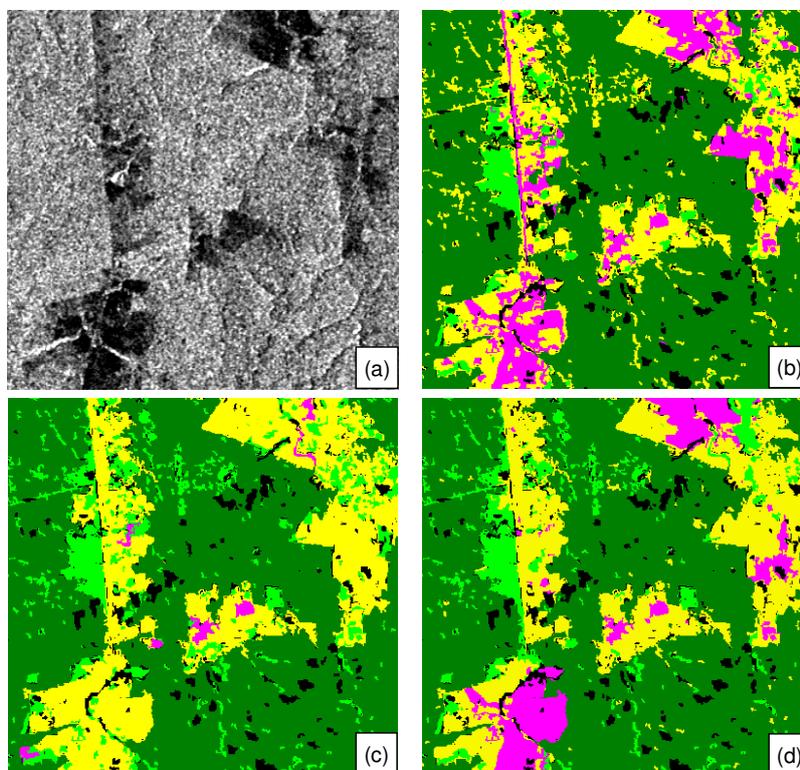


Figura 30 - (a) imagem do JERS-1; (b) Mapa de uso de ocupação do solo; (c) Resultado da classificação baseada em três medidas texturais (mediana, entropia de Haralick e correlação de Haralick); (d) Resultado da classificação baseada em duas medidas textural (mediana e entropia de Haralick) realizada em dois passos.

Fonte: Adaptada de Rennó et al. (1998), p.163.

Tabela 8 - Fator discriminante para cada par de classes de interesse.

Medidas	Par de classes de interesse*					
	FP/RA	FP/RN	FP/AR	RA/RN	RA/AR	RN/AR
Mediana	7,09	14,66	<b>33,19</b>	2,29	<b>7,20</b>	<b>3,13</b>
Entropia (Haralick)	<b>35,53</b>	<b>19,99</b>	23,44	2,28	1,59	1,17
Correlação (Haralick)	1,12	4,40	4,14	<b>2,69</b>	2,31	1,04

\*Os valores em negrito indicam a medida selecionada para o par de classes.

Fonte: Adaptada de Rennó et al. (1998), p.162.

O resultado da classificação usando as três melhores medidas selecionadas é mostrado na Figura 30c. Pode-se notar que muitas regiões da classe Atividades Recentes foram erroneamente classificadas como Regeneração Recente, e que

grande parte das pequenas regiões foram classificadas como Regeneração Antiga, quando, de fato, deveriam ser classificadas como Regeneração Nova.

Para melhorar este resultado, a seleção e classificação foi feita em dois passos. Inicialmente, definiu-se dois grupos: o primeiro formado pelas classes Floresta Primária e Regeneração Antiga, e o segundo formado pelas classes Regeneração Nova e Atividades Recentes. O processo de seleção foi refeito e a mediana foi escolhida como a melhor medida para discriminar estes dois grupos, com fator discriminante igual a 10,10. A classificação foi feita a fim de separar esses 2 grupos. Numa segunda etapa, as regiões de cada grupo separadamente foram classificadas em uma das classes que compunham o grupo usando-se a medida selecionada para aquele par de classes (entropia de Haralick para o par Floresta Primária/Regeneração Antiga e mediana para o par Regeneração Nova/Atividades Recentes). O resultado desta classificação é mostrado na Figura 30d. Visualmente, pode-se verificar uma melhora na classificação quando comparado ao procedimento anterior (classificação em um passo).

## 1.9. CONSIDERAÇÕES FINAIS

Este capítulo teve como objetivo mostrar uma visão geral de diversos aspectos relativos à utilização de imagens de radar, apresentando as principais características que envolvem a geometria de imageamento de sistema de radar, comportamento dos alvos na região de microondas, modelagem estatística utilizada para dados SAR, descritores de textura e classificadores pontuais, contextuais e por regiões. Para ilustrar o uso de classificadores, utilizando-se diversas imagens SAR, foram apresentados exemplos de aplicações especificamente para discriminação de diferentes tipos de uso e ocupação do solo.

Apesar da utilização de imagens de radar em aplicações civis ser um campo de pesquisa relativamente novo, a bibliografia sobre ela é extensa, e muitas técnicas para a análise de imagens de radar têm surgido nos últimos anos. Muitas destas técnicas, tais como filtragem do ruído *speckle*, segmentação de imagens, orto-retificação, correção de distorções geométricas, fusão de dados, interferometria, geração de modelos digitais de terreno, etc., não foram abordadas neste capítulo, uma vez que o enfoque principal foi a classificação de imagens SAR, mas seu conhecimento é de extrema relevância para usuários deste tipo de sensor.

Grande parte das técnicas para a análise de imagens de radar ainda se encontram em desenvolvimento, as quais deverão ser aprimoradas a fim de melhorar a confiabilidade dos produtos obtidos a partir deste tipo de imagem. A utilização das técnicas mais adequadas dependerá do tipo de aplicação, das características do sensor, etc. Estas técnicas, quando estiverem bem fundamentadas e integradas em um único sistema, serão de grande valia para a construção de um sistema de informações geográficas capaz de agregar diferentes tipos de informações.

## AGRADECIMENTOS

Os autores gostariam de agradecer o apoio financeiro recebido do CNPq (Proc. 300927/92-4) e do PPG-7 (0808/95 e 0816/95), Convênio FINEP (6.6.96.0473.00 e 6.6.96.0474.00). Um agradecimento especial é feito à AeroSensing Radar-Systeme por permitir a utilização das imagens obtidas pelo AeS-1, mostradas nas Figuras 7 e 13. Os autores agradecem também ao Instituto Nacional de Pesquisas Espaciais e à Diretoria de Serviço Geográfico do Exército Brasileiro pela oportunidade da realização deste trabalho.

---

## REFERÊNCIAS BIBLIOGRÁFICAS

- Abramowitz, M; Stegun, I. *Handbook of mathematical functions: with formulas, graphs, and mathematical tables*. New York: Dover, 1965. 1046p.
- Ahern, F.J. *Basic concepts of imaging radar: a intensive course*. Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, out. 1994 (Notas de curso).
- Amaral, S.; Shimabukuro, Y.E. Sensoriamento remoto por radar (SAR): pré-processamento de imagens RADARSAT ("Fine Mode") na região da Floresta Nacional de Tapajós. In: *Primeras Jornadas Latinoamericanas de Percepción Remota por Radar*. Técnicas de Procesamiento de Imágenes, Buenos Aires, dec. 1996. Paris, ESA, 1997, p. 37-42. (ESA SP 407).
- Batlivala, P.P.; Ulaby, F.T. *Feasibility of monitoring soil moisture using active microwave remote sensing*. Lawrence, KS, University of Kansas Center for Research, 1977. (RSL Technical Report 264-12).
- 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.
- Brakke, T.W.; Kanemasu, E.T.; Steiner, J.L.; Ulaby, F.T.; Wilson, E. Microwave radar response to canopy moisture leaf-area index, and dry weight of wheat, corn, and sorghum. *Remote Sensing of Environment*, 11(3):207-220, July 1981.
- Brisco, B.; Brown, R.J.; Pultz, T.J. The effects of free canopy water on SAR crop separability. In: *Remote sensing: an economic tool for the nineties*. Canada, IEEE, 1989. v. 2, p. 424-429. IGARSS'89, Canadian Symposium on Remote Sensing, 12., Vancouver, July 10-14, 1989.
- Bush, T.F.; Ulaby, F.T. An evaluation of radar as a crop classifier. *Remote Sensing of Environment*, 7(1):15-36, 1978.
- Chen, Y.; Dougherty, E.R. Gray-scale morphological granulometric texture classification. *Optical Engineering*, 33(8):2713-2722, 1994.
- Cook, R.; McConnell, I.; Oliver, C.J. MUM (Merge Using Moments) segmentation for SAR images. In: *Proceedings of SPIE*, 2316, 92-103, 1994.
- Correia, A. H. *Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas*. Dissertação de Mestrado em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1998.
- Dallemand, J.F.; Lichtenegger, J.; Raney, R.K.; Schumann, R. *Radar imagery: theory and interpretation: lecture notes*. Rome, FAO/ESA, 1993. (RSC Series 67).
- Di Cenzo, A. *Synthetic aperture radar and digital processing: an introduction*. Pasadena, CA, JPL, Feb. 1981 (JPL Publication).
- Du, L.J.; Lee, J.S. Polarimetric SAR image classification based on target decomposition theorem and complex Wishart distribution. In: 1996 International Geoscience and Remote Sensing Symposium, Lincoln, May 27-31 1996. *Remote sensing for a sustainable future*. Piscataway, IEEE, v. 1, p. 439-441.
- Dutra, L.V.; Frery, A.C.; Krug, T.; Mascarenhas, N.D.A.; Sant'Anna, S.J.S.; Yanasse, C.C.F. *Alguns aspectos de modelagem estatística de dados de*

---

*sensoriamento remoto*. Curitiba, INPE/SBC, maio 1993. Notas de curso do Simpósio Brasileiro de Sensoriamento Remoto, 7. 25p.

Evans, D.L.; Farr, T.G.; Ford, J.P.; Thompson, T.W.; Werner, C.L. Multipolarization radar images for geologic mapping and vegetation discrimination. *IEEE Transactions on Geoscience and Remote Sensing*, GE-24(2):246-256, Mar. 1986.

Fernandes, D. *Formação de imagens de radar de abertura sintética e modelos da relação "speckle"-textura*. Tese de Doutorado, Instituto Tecnológico da Aeronáutica, São José dos Campos, 1993.

Fischer, J.A.; Mussakowski, R.S. Preliminary evaluation of multi-date SAR data for identification of agricultural crops in Southern Ontario. In: *Remote sensing: an economic tool for the nineties*. Canada, IEEE, 1989. v. 2, p. 430-433. IGARSS'89; Canadian Symposium on Remote Sensing, 12., Vancouver, July 10-14, 1989.

Freitas, C.C., Correia, A.H.; Frery, A.C.; Sant'Anna, S.J.S. A system for multilook polarimetric SAR image statistical classification. In: *Second Latino-American Seminar on Radar Remote Sensing: Image Processing Techniques*, Santos, sep. 1998. Noordwijk, ESA, 1998, p. 141-148. (ESA SP 434).

Frery, A.C. *Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética*. Tese de Doutorado em Computação Aplicada, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1993. (INPE-5548-TDI/534).

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*, 35(3):648-659, 1997a.

Frery, A.C.; Yanasse, C.C.F.; Sant'Anna, S.J.S. Statistical characterization of SAR data: the multiplicative model and extensions. In: Simposio Latinoamericano de Percepción Remota (SELPER), 7, México, nov. 1995. *Latinoamérica evaluada desde el espacio*. México, s.e., 1995a, p. 502-515.

Frery, A.C.; Yanasse, C.C.F.; Sant'Anna, S.J.S. Alternative distributions for the multiplicative model in SAR images. In: 1995 International Geoscience and Remote Sensing Symposium, Italy, Jul. 10-14 1995b. *Quantitative remote sensing for science and applications*. Florence, Italy, IEEE, v. 1, p. 169-171.

Frery, A.C.; Yanasse, C.C.F., Sant'Anna, S.J.S. El modelo multiplicativo para el análisis de imágenes SAR. In: *Primeras Jornadas Latinoamericanas de Percepción Remota por Radar: Técnicas de Procesamiento de Imágenes*, Buenos Aires, dec. 1996. Paris, ESA, 1997b, p. 63-70. (ESA SP 407).

Frery, A.C.; Yanasse, C.C.F.; Vieira, P.R.; Sant'Anna, S.J.S.; Rennó, C.D. A user-friendly system for synthetic aperture radar image classification based on grayscale distributional properties and context. In: *Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens*, 10., 1997. Los Alamitos, CA, USA, IEEE Computer Society, p. 211-218, 1997c.

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.

Gradshteyn, I.S.; Ryzhik, I.M. *Table of integrals, series, and products*. New York Academic Press, 1980. 1160 p.

- 
- Haralick, R.M.; Shanmugan, K.; Dinstein, I. Texture features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3(6):610-621, Nov. 1973.
- Haralick, R.M.; Shapiro, L.G. *Computer and robot vision*. New York, Addison-Wesley, 1992. 672p.
- Jain, A.K. *Fundamentals of digital image processing*. Englewood Cliffs, NJ, Prentice-Hall International Editions, 1989. 569p.
- Jakeman, E.; Pusey, P.N. The statistics of light scattered by a random phase screen. *Journal of Physics A: Mathematical and General*, 6(L):89-92, 1973.
- Jakeman, E.; Pusey, P.N. A model for non-Rayleigh sea echo. *IEEE Transactions on Antennas and Propagation*, AP-24(6):806-814, 1976.
- Jao, J.K. Amplitude distribution of composite terrain radar clutter and the K distribution. *IEEE Transactions on Antennas and Propagation*, AP-32:1049-1061, 1984.
- 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.
- Lee, J.S.; Grunes, M.R. Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution. *International Journal of Remote Sensing*, 15(11):2299-2311, Sept, 1994.
- Lee, J.S.; Hoppel, K.W.; Mango, S.A.; Miller, A.R. Intensity and phase statistics of multi-look polarimetric and interferometric SAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 32(5):1017-1028, Sept, 1994a.
- Lee, J.S.; Miller, A.R.; Hoppel, K.W. Statistics of phase difference and product magnitude of multi-look processed Gaussian signals. *Waves in Random Media*, 4:307-319, 1994b.
- 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, 1994c, v.4, p.2179-2181.
- Le Toan, T.; Lopes, A.; Huet, M. On the relationships between radar backscattering coefficient and vegetation canopy characteristics. In: Remote sensing: from research towards operational use. Noordwijk, ESA/ESTEC, 1984. v. 1, p. 155-160. (ESA SP-215). *Proceedings of IGARSS'84*, Strasbourg, Aug. 27-30, 1984.
- Lopes, A.; Laur, H.; Nezry, E. Statistical distribution and texture in multilook and complex SAR images. In: IGARSS'90 International Geoscience and Remote Sensing Symposium, Washington DC, 1990. Remote Sensing Sciences for the Nineties. New York: IEEE, 1990. v.3, p.2427-2430.
- Marceau, D.; Howarth, P.J.; Dubois, J.M. Automated texture extraction from high spatial resolution satellite imagery for land-cover classification: concepts and application. In: IGARSS'89 - Canadian Symposium on Remote Sensing, 12., Vancouver, July 10-14, 1989. *Proceedings*, IEEE, 1989. v. 5, p. 2765-2768.
- Mascarenhas, N.D.A.; Velasco, F.R.D. *Processamento digital de imagens*. São Paulo, IME, 1989, Quarta Escola de Computação. 2ª ed. 373p.

Mura, J.C. Algoritmos e metodologia de processamento para síntese de imagens de radar de abertura sintética (SAR). In: Simpósio Brasileiro de Sensoriamento Remoto, 6, Manaus, 24–29 jun. 1990. *Anais*. São José dos Campos, INPE, 1990, v.1, p. 188-196.

Mura, J.C. Um sistema de processamento de imagens de radar de abertura sintética (SAR) aerotransportado. In: Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, 4, São Paulo, 14–17 jul. 1991. *Anais*. p. 95-98.

NASA/JPL, ed. *Shuttle imaging radar-C science plan*. Pasadena, CA, 1986. (JPL Publication 86-29).

Oliver, C.; Quegan, S. *Understanding synthetic aperture radar images*. Norwood, MA, Artech House, 1998. 479p.

Paris, J.F. Radar backscattering properties of corn and soybeans at frequencies of 1.6, 4.75, and 13.3 GHz. *IEEE Transactions on Geoscience and Remote Sensing*, GE-21(3):392-400, July 1983.

Rennó, C.D. *Avaliação de medidas texturais na discriminação de classes de uso utilizando imagens SIR-C/X-SAR do Perímetro Irrigado de Bebedouro, Petrolina, PE*. Dissertação de Mestrado em Sensoriamento Remoto, Instituto de Nacional de Pesquisas Espaciais, 1995.

Richards, J.A. *Remote sensing digital image analysis: an introduction*. Berlin, Springer-Verlag, 1993. 2ª ed. 340p.

Rosenqvist, Å. Evaluation of JERS-1, ERS-1 and Almaz SAR backscatter for rubber and oil palm stands in West Malaysia. *International Journal of Remote Sensing*, 17(16):3219-3231, 1996.

Sant'Anna, S.J.S. *Avaliação de filtros redutores de speckle em imagens de radar de abertura sintética*. Dissertação de Mestrado em Sensoriamento Remoto, Instituto de Nacional de Pesquisas Espaciais, São José dos Campos, 1995. (INPE-6125-TDI/586).

Sant'Anna, S.J.S.; Dutra, L.V. SAR texture discrimination using AR-2D models for Amazonian land use classification. In: Simposio de Especialistas Latinoamericanos en Percepción Remota (SELPER), 7, México, nov. 1995. *Latinoamérica evaluada desde el espacio*. México, s.e., 1995, p. 516-523.

Sant'Anna, S.J.S.; Freitas, C.C.; Rennó, C.D. The use of textural features on the polarimetric SAR image classification. In: *Segunda Jornada Latinoamericana de Sensoriamento Remoto por Radar: Técnicas de Processamento de Imagens*, Santos, set. 1998. Paris, ESA, 1998, p. 99-106. (ESA SP 434)

Sant'Anna, S.J.S.; Yanasse, C.C.F.; Frery, A.C. Estudo comparativo de alguns classificadores utilizando-se imagens RADARSAT da região de Tapajós. In: *Primeras Jornadas Latinoamericanas de Percepción Remota por Radar: Técnicas de Procesamiento de Imágenes*, Buenos Aires, dez. 1996. Paris, ESA, 1997, p. 187–194. (ESA SP 407)

Sant'Anna, S.J.S.; Yanasse, C.C.F.; Hernandez Filho, P.; Kuplich, T.M.; Dutra, L.V.; Frery, A.C.; Santos, P.P. Secondary forest age mapping in Amazônia using multi-temporal Landsat/TM imagery. In: IGARSS, Italy, July 10-14 1995, *Quantitative remote sensing for science and applications*. v.1, pages 323-325, Florence, Italy. IEEE

Sarabandi, K. Derivations of phase statistics from the Mueller matrix. *Radio Science*, 27(5):553–560, 1992.

Soares, J.V.; Rennó, C.D.; Formaggio, A.R.; Yanasse, C.C.F.; Frery, A.C. Evaluation of texture features for crops discrimination using SAR. *Remote Sensing of Environment*, 59(2): 234–247, 1997.

Soares, S.M. *Classificação textural de imagens de radar por modelagem estatística autorregressiva*. Dissertação de Mestrado em Sensoriamento Remoto, Instituto de Nacional de Pesquisas Espaciais, São José dos Campos, 1998.

Srivastava, M.S. On the complex Wishart distribution. *Annals of Mathematical Statistics*, 36(1):313–315, 1963.

Trevett, J.W. *Imaging radar for resources surveys*. New York, NY, Chapman and Hall, 1986. 313 p.

Ulaby, F.T. Radar signature of terrain: useful monitors of renewable resources. *Proceedings of IEEE*, 70(12):1410-1428, Dec.1982.

Ulaby, F.T.; Allen, C.T.; Eger, G.; Kanemasu, E. Relating the microwave backscattering coefficient to leaf area index. *Remote Sensing of Environment*, 14(1-3):113-133, Jan. 1984.

Ulaby, F.T.; Batlivala, P.P.; Dobson, M.C. Microwave backscatter dependence on surface roughness, soil moisture, and soil texture, part I: bare soil. *IEEE Transactions Geoscience and Electronics*, GE-16(4):286-295, Oct. 1978.

Ulaby, F.T.; Bradley, G.A.; Dobson, M.C. Microwave backscatter dependence on surface roughness, soil moisture, and soil texture, part II: vegetation-covered soil. *IEEE Transactions Geoscience and Electronics*, GE-17(2):33-40, Apr. 1979.

Ulaby, F.T.; Dobson, M.C. *Handbook of radar scattering statistics for terrain*. Norwood, MA, Artech House, 1989. 357p.

Ulaby, F.T.; Elachi, C. *Radar polarimetry for geoscience applications*. Norwood: Artech House, 1990. 364p.

Ulaby, F.T.; Moore, R.K.; Fung, A.K. *Microwave remote sensing - radar remote sensing and surface scattering and emission theory*. v.2. Reading, Addison-Wesley, 1982.

Ulaby, F.T.; Moore, R.K.; Fung, A.K. *Microwave remote sensing: active and passive: radar remote sensing and surface scattering and emission theory*. 2<sup>a</sup>.ed. v.2. Norwood, MA, Artech House, 1986a.

Ulaby, F.T.; Moore, R.K.; Fung, A.K. *Microwave remote sensing: active and passive: from theory to applications*. v.3. Dedham, MA, Artech House, 1986b.

Unser, M. Sum and difference histograms for texture classification. *IEEE Transactions on Pattern Analysis Machine Intelligence*, PAMI-8(1):118-125. Jan. 1986.

Vieira, P.R. *Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR*. São José dos Campos. Dissertação de Mestrado em Sensoriamento Remoto, Instituto de Nacional de Pesquisas Espaciais, 1996. (INPE–6124–TDI/585).

Vieira, P.R.; Yanasse, C.C.F.; Frery, A.C.; Sant'Anna, S.J.S. Um sistema de análise e classificação estatísticas para imagens SAR. In: *Primeras Jornadas Latinoamericanas de Percepción Remota por Radar: Técnicas de Procesamiento de Imágenes*, Buenos Aires, dec. 1996. Paris, ESA, 1997, p. 170–185. (ESA SP 407)

Welch, R.M.; Kuo, K.S.; Sengupta, S.K. Cloud and surface textural features in polar regions. *IEEE Transactions on Geoscience and Remote Sensing*, 28(4):520-528. July 1990.

Weszka, J.S.; Dyer, C.R.; Rosenfeld, A. A comparative study of texture measures for terrain classification. *IEEE Transactions on Systems and Man Cybernetics*, SMC-6(4):269-285. Apr. 1976.

White, R.G. *Low-Level segmentation of noise imagery*. Memorandum 3900, DRA, Royal Signal and Radar Establishment, Works, 1986.

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. 31p. (INPE-5630-NTC/318).

Yanasse, C.C.F.; Sant'Anna, S.J.S.; Frery, A.C.; Rennó, C.D.; Soares, J.V.; Luckman, A.J. Exploratory study of the relationship between tropical forest regeneration stages and SIR-C L and C data. *Remote Sensing of Environment*, 59(2):180–190, 1997.