



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-10441-TDI/926

**AVALIAÇÃO DE MEDIDAS TEXTURAIS NA DISCRIMINAÇÃO
DE CLASSES DE USO UTILIZANDO IMAGENS SIR-C/X-SAR DO
PERÍMETRO IRRIGADO DE BEBEDOURO, PETROLINA, PE**

Camilo Daleles Rennó

Dissertação de Mestrado do Curso da Pós-Graduação em Sensoriamento
Remoto, orientada pelo Dr. João Viane Soares, aprovada em
22 dezembro de 1995.

528.711.7 (813)

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/ C.D.Rennó.

- São José dos Campos: INPE, 2003.

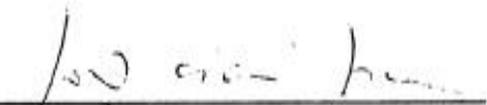
111p. – (INPE-10441-TDI/926).

1.Sensoriamento remoto. 2.Radar de abertura sintética (SAR). 3.Shuttle imaging radar. 4.Seleção de atributos. 5.Textura. 6.Classificação. 7.Petrolina (PE).

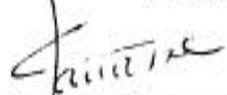
I. Título.

Aprovada pela Banca Examinadora em
cumprimento a requisito exigido para a
obtenção do Título de Mestre em
Sensoriamento Remoto

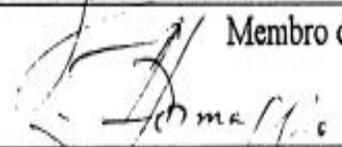
Dr. João Viane Soares


Orientador/Presidente

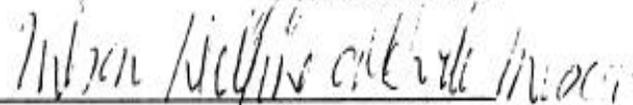
Dra. Corina da Costa Frejtas Yanasse

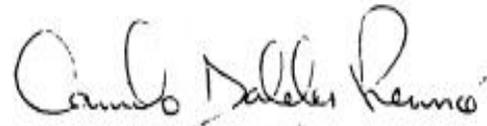

Membro da Banca

Dr. Antonio Roberto Formaggio


Membro da Banca

Dr. Nelson Delfino d'Ávila Mascarenhas


Membro da Banca
- Convidado -


Candidato: Camilo Daleles Rennó

A meus pais

AGRADECIMENTOS

Ao Dr. João Viane Soares, pela orientação, ensinamentos e oportunidades.

Aos meus pais e irmãos, pelo apoio recebido.

À Dra. Corina da Costa Freitas Yanasse, ao Dr. Alejandro César Frery Orgambide e ao Dr. Luciano Vieira Dutra, pelo apoio e sugestões.

Ao Dr. Antônio Roberto Formaggio e ao Msc. Oton Osório de Barros Neto, pela valiosa colaboração durante o trabalho de campo.

Ao Centro de Pesquisa Agropecuária do Trópico Semi-Árido - EMBRAPA e em especial, ao Msc. Iedo Bezerra de Sá e ao Sr. Francisco de Aquino, pelo grande apoio prestado na fase de execução do trabalho de campo.

À Dra. Thelma Krug e ao Dr. João Roberto dos Santos, pelos ensinamentos e apoio.

À Coordenação de Aperfeiçoamento de Pessoal de Estudo Superior (CAPES) pela concessão da bolsa de estudo.

À Sra. Maria Etelvina Rennó Dias Arbex, pela valiosa ajuda.

Às amigas María Silvia Pardi Lacruz e Elaine Cristina Fidalgo, que sempre estiveram presentes durante todo o período do curso, ajudando no que fosse preciso.

A todos aqueles que acreditaram e contribuíram para a conclusão deste trabalho.

RESUMO

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. Na literatura, pode-se encontrar muitas medidas de textura, sendo que a escolha de um conjunto de medidas de textura é quase sempre feita empiricamente. Este trabalho propõe uma metodologia para seleção das medidas texturais que maximize a discriminação entre classes de uso em imagens SAR. Para tanto, foram utilizadas imagens SIR-C/X-SAR, bandas L e C, e polarizações HH, HV e VV. Os resultados mostraram que classificações baseadas apenas na média tonal conseguiram valores de kappa pouco acima de 0,50. O uso de medidas de textura resultou numa melhoria na classificação, obtendo-se valores de kappa superiores a 0,90 quando 15 medidas foram utilizadas simultaneamente. Mesmo quando imagens de apenas uma banda e uma polarização foram empregadas, conseguiram-se, em geral, valores de kappa superiores a 0,85 com a utilização de mais de 20 medidas de textura. Os resultados comprovaram que a informação textural presente em imagens de radar podem ajudar na discriminação de alvos agrícolas e que a metodologia proposta mostrou-se adequada a este propósito.

**AN VALUATION OF THE TEXTURE FEATURES FOR LAND-USE
DISCRIMINATION USING SIR-C/X-SAR DATA IN THE BEBEDOURO
IRRIGATION PROJECT, PETROLINA, PE**

ABSTRACT

The texture is an important characteristic used for visual image interpretation. For this reason, the performance of digital classifiers can be improved with texture measurements, specially for high resolution images. However, the quantification of image texture is very difficult, since there is no consensus in the definition of what texture is, as well as a precise mathematical formulation of it. Several texture measures can be found in the literature. Usually the choice of the best set of these measures is done empirically. This work proposes a methodology for texture measures selection that maximize the discrimination between land use classes in SAR images. The used images were SIR-C/X-SAR, L and C bands, and HH, HV and VV polarizations. The results show that the classification based only on the tonal means achieved kappa values slightly higher than 0.50. The use of texture measures improved the classification, obtaining kappa values higher than 0.90, when 15 measures were used simultaneously. Even when images only one band and one polarization were used, the kappa values obtained were higher than 0.85, making use of more than 20 texture measures. The results confirmed that texture information in radar image may help the discrimination of agriculture crops, and that the proposed methodology is appropriate for this purpose.

SUMÁRIO

Pág.

LISTA DE FIGURAS
LISTA DE TABELAS

CAPÍTULO 1 - INTRODUÇÃO	17
CAPÍTULO 2 - PRINCÍPIOS BÁSICOS DE RADAR	21
2.1 - Sistemas de microondas	21
2.2 - Equação radar.....	26
2.3 – Comportamento de alvos.....	30
2.3.1 - Fatores relacionados ao sensor.....	31
2.3.2 - Fatores relacionados ao dossel.....	35
2.3.3 – Discriminação de culturas	38
2.4 - Evolução dos sistemas de radar	39
2.4.1 - Aspectos históricos	39
2.4.2 - O sistema SIR-C/X-SAR	41
CAPÍTULO 3 - IMAGEM DE RADAR	43
3.1 – Propriedades geométricas da imagem SAR	43
3.2 – Propriedades estatísticas da imagem SAR	46
3.2.1 – Propriedades estatísticas da imagem intensidade.....	48
3.2.1.1 – Regiões homogêneas	49
3.2.1.2 – Regiões não homogêneas	51
3.2.1.3 – Estimadores dos parâmetros da distribuição K intensidade	52
3.2.2 – Propriedades estatísticas da imagem amplitude	53
3.2.2.1 – Regiões homogêneas	53
3.2.2.2 – Regiões não homogêneas	54
3.2.2.3 – Estimadores dos parâmetros da distribuição K amplitude	55
3.3 – Classificação de imagens de radar	57
CAPÍTULO 4 - MEDIDAS DE TEXTURA	59
4.1 - Medidas de textura baseadas em estatísticas de primeira ordem.....	59
4.2 - Medidas de textura baseadas em estatísticas de segunda ordem	61
4.3 - Utilização de medidas de textura na classificação de imagens de radar	65
CAPÍTULO 5 - MATERIAL E MÉTODOS	67
5.1 - Descrição da área de estudo.....	67
5.1.1 - Aspectos climatológicos regionais.....	68
5.1.2 - Aspectos pedológicos.....	69
5.1.3 – Infraestrutura	69
5.1.4 - Uso da Terra.....	70
5.2 – Imagens	71
5.3 - Trabalho de campo.....	72
5.4 - Extração das amostras e cálculo dos parâmetros estatísticos.....	73

5.5 - Avaliação do desempenho das medidas texturais na discriminação de alvos....	74
5.5.1 - Seleção das medidas de textura.....	78
CAPÍTULO 6 - RESULTADOS E DISCUSSÃO	81
CAPÍTULO 7 - CONCLUSÕES	93
REFERÊNCIAS BIBLIOGRÁFICAS	95
APÊNDICE A - MATRIZ DE STOKES	103
APÊNDICE B - DESCOMPACTAÇÃO DAS IMAGENS SIR-C (Bandas L e C)	107

LISTA DE FIGURAS

	Pág.
2.1 - Espectro eletromagnético e bandas da região de microondas	21
2.2 - Transmissão atmosférica para a região de microondas do espectro eletromagnético	22
2.3 - Elementos básicos de um sistema de radar imageador	23
2.4 - Geometria de um radar de visada lateral de abertura real	24
2.5 - Geometria e parâmetros envolvidos na equação de radar	26
2.6 - Contribuições do retroespalhamento de um dossel	30
2.7 - Medida do coeficiente de retroespalhamento de uma cultura de milho como uma função da umidade do solo e do ângulo de incidência	32
2.8 - Sensitividade para umidade do solo como uma função da frequência e do ângulo de incidência	33
2.9 - Resposta angular do coeficiente de retroespalhamento	34
2.10 - Dependência angular da razão de despolarização de uma superfície lisa	35
2.11 - Relação entre o coeficiente de retroespalhamento e a altura <i>RMS</i> e o ângulo de incidência para 1,1 GHz, 4,25 GHz, e 7,25 Ghz	37
3.1 - Comparação entre imagens <i>slant range</i> e <i>ground range</i>	44
5.1 - Localização da área de estudo	67
6.1 - Desempenho da classificação medido pelo kappa como função do número de variáveis selecionadas pelos métodos 1 e 2	86
6.2 - Relação entre a variância entre classes e o kappa de cada variável individual ..	87
6.3 - Kappa e variância entre classes das variáveis selecionadas pelo método 2	88
6.4 - Desempenho da classificação, considerando as 6 imagens separadamente	91
A.1 - Elipse de polarização	105

LISTA DE TABELAS

	Pág.
5.1 - Dados pluviométricos do PIB	68
5.2 - Características dos produtos SAR.....	72
5.3 - Matriz de confusão.....	76
6.1 - Número de amostras por classe de uso	81
6.2 - Abreviaturas das variáveis analisadas.....	82
6.3 - Variáveis rejeitadas num teste de normalidade considerando nível de significância de 0,01	84
6.4 - Variáveis selecionadas pelo método 2	89
6.5 - Desempenho da classificação dos produtos utilizando os três conjuntos de variáveis selecionadas	90
A.1 - Algumas polarizações e seus respectivos ângulos de orientação e elipsidade..	105

CAPÍTULO 1

INTRODUÇÃO

Para que se possa maximizar o uso dos recursos utilizados no sistema produtivo da atividade agrícola é necessário conhecer os fatores ou parâmetros que o afetam.

Técnicas de Sensoriamento Remoto têm sido utilizadas como importantes ferramentas no estudo e caracterização de ambientes agrícolas, por fornecer os meios para estimação de parâmetros relacionados a estes ambientes.

Os primeiros produtos de sensoriamento remoto, tais como as fotografias aéreas, apresentavam altos custos de obtenção e sofriam grande restrição temporal e espacial (o levantamento aerofotográfico era realizado apenas para pequenas regiões e o intervalo de tempo entre levantamentos sobre a mesma região era muito grande). Com o advento dos sensores ópticos orbitais, grandes áreas puderam ser imageadas com uma certa periodicidade, o que possibilitou fazer estudos multitemporais em escala regional a um custo relativamente baixo. Entretanto, a utilização de sensores ópticos orbitais em zonas tropicais tem sofrido grande restrição devido a condições atmosféricas adversas (nuvens, fumaça, etc) que podem prejudicar ou até impedir a aquisição de dados numa base regular, essencial na caracterização de ambientes agrícolas.

Devido às limitações no uso de sensores ópticos, outros sensores foram desenvolvidos operando em diferentes faixas do espectro eletromagnético, entre elas, as microondas. Os sensores de microondas possuem a grande vantagem de serem pouco influenciados pelas condições atmosféricas e poderem adquirir dados independentemente da iluminação solar.

Durante as duas últimas décadas, muitos pesquisadores têm estudado a interação entre o dossel da vegetação e as ondas eletromagnéticas na faixa do microondas. Estes estudos baseiam-se principalmente no coeficiente de retroespalhamento obtido a partir de medidas de escaterômetros e modelos de retroespalhamento.

O coeficiente de retroespalhamento é muito sensível a vários parâmetros do dossel e do sensor, indicando que as imagens de radar apresentam uma grande potencialidade na

discriminação de culturas agrícolas. Esta potencialidade torna-se ainda maior quando se faz uso de sistemas em várias frequências e polarizações. Dentro deste contexto estão os dados fornecidos pela missão SIR-C/X-SAR que são de grande valia, uma vez que estão à disposição, imagens em 3 frequências, 4 polarizações e diferentes épocas, todas referentes a uma mesma área.

Nos dias atuais, as pesquisas são voltadas à determinação da melhor combinação de dados e da metodologia que maximize a discriminação de alvos, ao mesmo tempo em que minimize tempo e custos. Paralelamente, buscam técnicas de processamento digital que tornem o processo de classificação de imagens cada vez mais rápido, preciso e automático. Assim, é indispensável desenvolver classificadores mais “inteligentes”, que levem em consideração não apenas os níveis de cinza de um *pixel* (classificadores pontuais) mas também dos *pixels* vizinhos, o que pode ser feito através de medidas de textura (classificadores contextuais). A natureza estatística própria das imagens de radar também deve ser considerada na construção do classificador digital.

Inúmeros parâmetros estatísticos podem ser utilizados na tentativa de caracterizar um alvo a fim de discriminá-lo dos demais alvos que compõem uma imagem. Entre os mais comuns estão a média e a variância. No entanto, muitos outros podem ser utilizados. Duas culturas agrícolas podem apresentar a mesma tonalidade (ou nível de cinza médio) na imagem, mas no entanto, podem ser distinguíveis pela diferença na textura. Muitos autores têm proposto diferentes parâmetros para expressar a textura, que, basicamente, reflete a variação espacial dos níveis de cinza de um determinado alvo na imagem. No entanto, visto o grande número de medidas de textura encontradas na literatura, torna-se muito difícil selecionar quais utilizar numa análise.

O objetivo geral deste trabalho é a avaliação de medidas de textura na discriminação de alvos agrícolas utilizando-se imagens SAR. Também fará parte deste trabalho, o desenvolvimento de metodologia de seleção de descritores de textura. Espera-se, com este trabalho, mostrar a importância da informação textural para imagens de radar.

O trabalho está organizado em 7 capítulos. No primeiro capítulo são apresentados os objetivos desta pesquisa. O Capítulo 2 apresenta a fundamentação teórica onde são

discutidos temas básicos de radar e como parâmetros do dossel agrícola e do sensor influenciam no coeficiente de retroespalhamento. No Capítulo 3, são discutidas as propriedades geométricas e estatísticas de uma imagem SAR baseando-se no modelo multiplicativo. O Capítulo 4 mostra diferentes parâmetros estatísticos de primeira e segunda ordem que procuram descrever a textura de uma imagem. No Capítulo 5, são descritos a área de estudo, os materiais utilizados, assim como a metodologia adotada. No Capítulo 6, são apresentados e discutidos os resultados. E finalmente, no Capítulo 7, são feitas as considerações finais do trabalho.

Com relação à terminologia utilizada neste trabalho, optou-se por manter alguns termos técnicos na sua forma original, ou seja, em inglês. Isto se deve ao fato de que não há uma padronização na tradução destes termos para a língua portuguesa e estes são normalmente referidos em inglês. Mesmo quando a tradução é feita, o termo original é citado.

CAPÍTULO 2

PRINCÍPIOS BÁSICOS DE RADAR

2.1 - Sistemas de Microondas

O sistema de radar, assim como outros sistemas utilizados no sensoriamento remoto, opera numa faixa restrita do espectro eletromagnético. A Figura 2.1 apresenta as várias regiões do espectro eletromagnético e a designação das bandas espectrais da região de microondas.

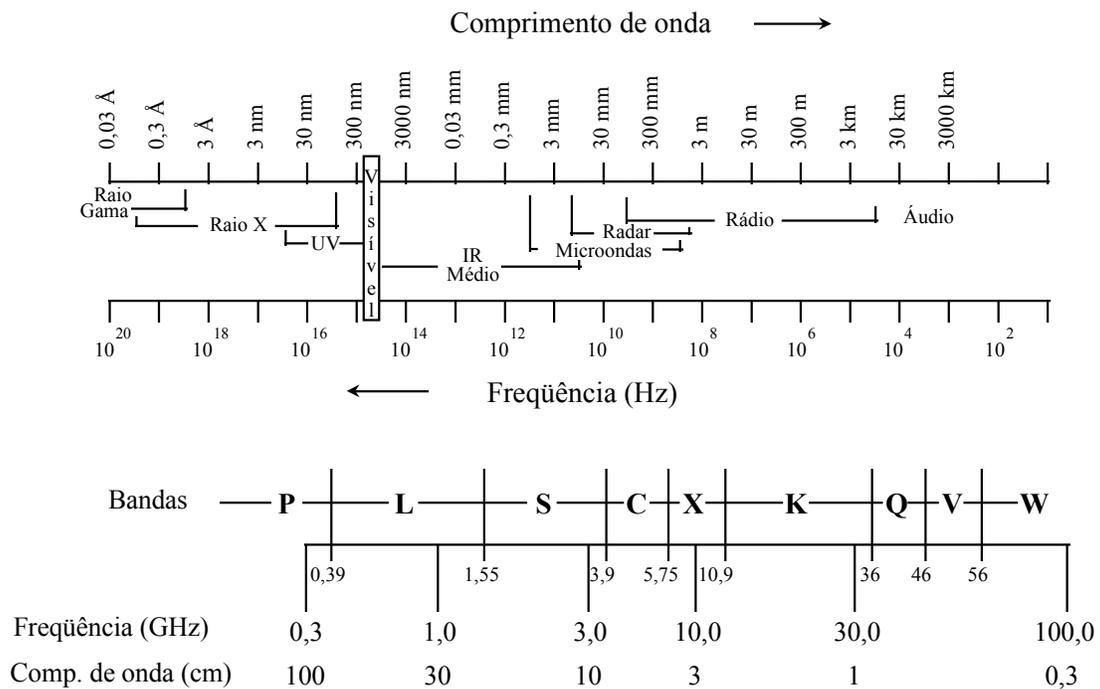


FIGURA 2.1 - Espectro eletromagnético e bandas da região de microondas.

FONTE: Modificada de Dallemand et al. (1993), p. 4.

As ondas eletromagnéticas na faixa do microondas sofrem pequena atenuação atmosférica, apresentando boa penetração nas nuvens. A Figura 2.2 mostra que a transmitância atmosférica é praticamente total na região de 3 a 30 cm (1 a 10 GHz). Esta característica é particularmente interessante para regiões tropicais onde sensores ópticos sofrem grande restrição devido à alta probabilidade de ocorrência de nuvens. Com isso,

ficam prejudicados os estudos multitemporais já que fica impossibilitada a aquisição de imagens numa frequência regular.

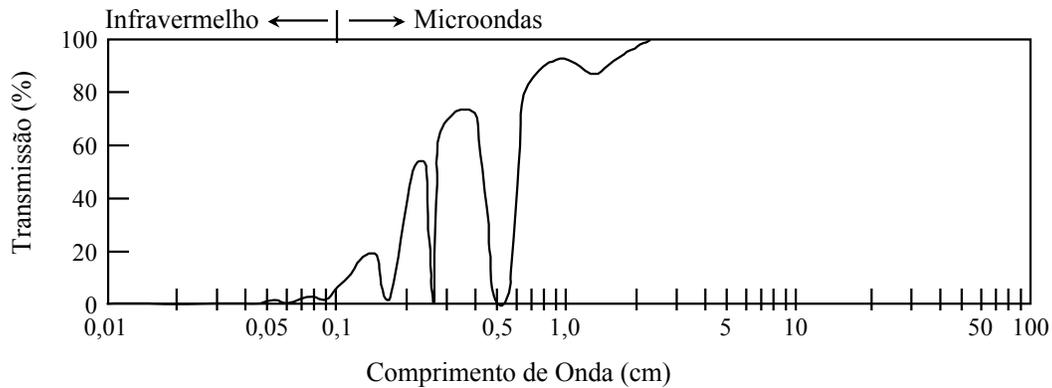


FIGURA 2.2 - Transmissão atmosférica para a região de microondas do espectro eletromagnético.

FONTE: Modificada de Curlander e McDonough (1991), p. 5.

Os sistemas que operam na faixa de microondas podem ser divididos em 2 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 do microondas e portanto a parcela de microondas refletida é desprezível. Caracteristicamente, estes sistemas apresentam baixas resoluções espaciais devido à emissão natural de energia nesta faixa do espectro ser muito pequena. Os radares, por sua vez, possuem sua própria fonte de microondas e portanto captam a energia refletida pelo alvo em estudo. Além disso, os radares apresentam melhores resoluções espaciais.

Os sistemas de radar podem ser agrupados em imageadores e não imageadores (Ulaby et al., 1986a). Os imageadores compreendem os sistemas de antena rotatória, os radares de visada lateral de abertura real (SLAR) e os radares de visada lateral de abertura sintética (SAR). Entre os não imageadores destacam-se os escaterômetros, os espectrômetros e os altímetros.

O princípio de funcionamento dos radares imageadores SLAR e SAR é o mesmo. Um pulso de energia eletromagnética é transmitido por uma antena. Este pulso encontra um

alvo (obstáculo), interage com o mesmo e parte desta energia é retornada ao sensor. A Figura 2.3a apresenta as partes essenciais de um sistema de radar imageador. Num sistema biestático, duas antenas são usadas, uma para transmissão e outra para recepção do sinal refletido pelo alvo, podendo cada antena possuir características distintas de polarização, dimensão, ângulo de visada, etc. Através de um chaveamento é possível utilizar uma mesma antena para transmitir e receber o sinal retroespalhado (Figura 2.3b).

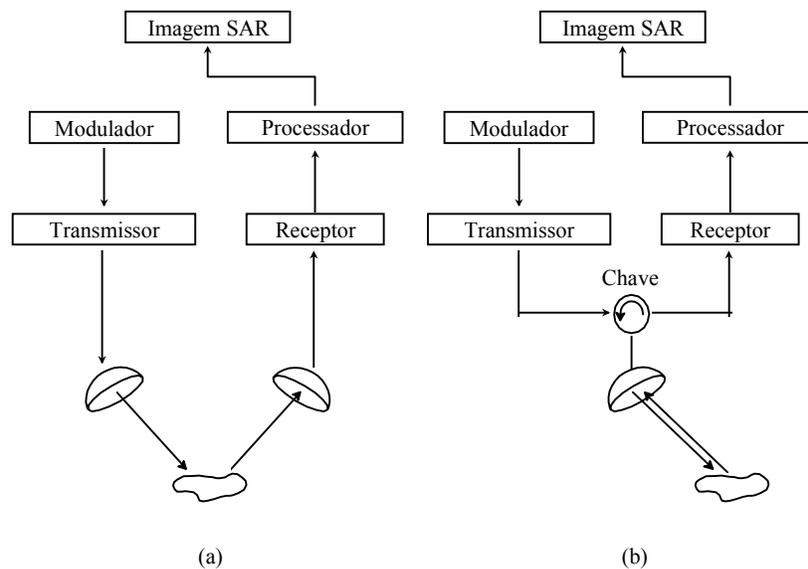


FIGURA 2.3 - Elementos básicos de um sistema de radar imageador.

A diferença entre o SLAR e o SAR está basicamente no processamento do sinal retornado e na resolução azimutal dos dois sistemas. Devido à maior simplicidade, será discutida primeiramente a natureza geométrica de um radar de abertura real e sua resolução. A Figura 2.4 mostra a geometria de imageamento associada a um radar de visada lateral de abertura real.

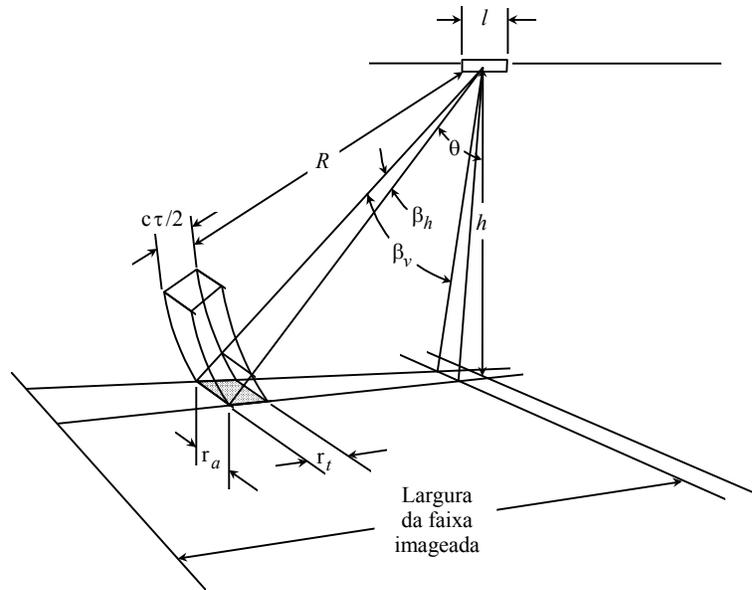


FIGURA 2.4 - Geometria de um radar de visada lateral de abertura real.
 FONTE: Modificada de Ulaby e Dobson (1989), p.18.

O lóbulo da antena, β_h , pode ser definido como

$$\beta_h = \frac{\lambda}{l}, \quad (2.1)$$

onde λ é o comprimento de onda e l é o comprimento real (físico) da antena.

A partir de β_h , pode-se determinar a resolução ao longo da linha de vôo (*along-track*), ou resolução azimutal, de um sistema de abertura real, através da equação

$$r_a = \beta_h R, \quad (2.2)$$

onde R é a distância entre a antena e o alvo imageado. Note que a resolução azimutal é proporcional à R .

A resolução transversal à linha de vôo (*across-track*) num sistema de radar de abertura real pode ser determinada pela duração do pulso transmitido pela antena, ou seja,

$$r_t = \frac{c\tau}{2\text{sen}\theta}, \quad (2.3)$$

onde c é a velocidade da luz, τ é a duração do pulso transmitido e θ é o ângulo de incidência.

Num sistema SAR, aproveitando-se o próprio deslocamento da plataforma, pode-se simular uma antena cujo comprimento é muitas vezes maior que o da antena real. Isto é conseguido através da gravação e combinação dos sinais retornados à antena (Ulaby e Dobson, 1989). O resultado disso é uma melhoria na resolução azimutal do sistema. Teoricamente, a resolução azimutal para um sistema de radar de abertura sintética independe da distância entre a antena e o alvo, sendo definida como a metade do comprimento real da antena, ou seja,

$$r_a \cong \frac{l}{2}. \quad (2.4)$$

A resolução transversal à linha de vôo (resolução em *range*) para sistemas de radar de abertura sintética é a mesma que para os de abertura real. Para se garantir uma resolução em *range* compatível com a azimutal, pulsos de curta duração são modulados em frequência (*chirp*).

As imagens de radar de abertura sintética são geralmente processadas de forma a reduzir um tipo de ruído característico denominado *speckle*. O processamento *multilook* consiste em dividir a abertura sintética da antena em alguns setores (normalmente 4 ou 8), 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 pelo mesmo fator. Assim, por exemplo, a resolução azimutal de um sistema de abertura sintética que utilize um processamento com N *looks* é de

$$r_a \cong \frac{Nl}{2}. \quad (2.5)$$

2.2 - Equação Radar

A equação de radar é uma relação fundamental entre as características do radar, do alvo e do sinal que é transmitido pelo radar, refletido pelo alvo e novamente recebido pelo radar (Ulaby et al., 1986a). A Figura 2.5 apresenta um alvo isolado e os parâmetros envolvidos na equação de radar.

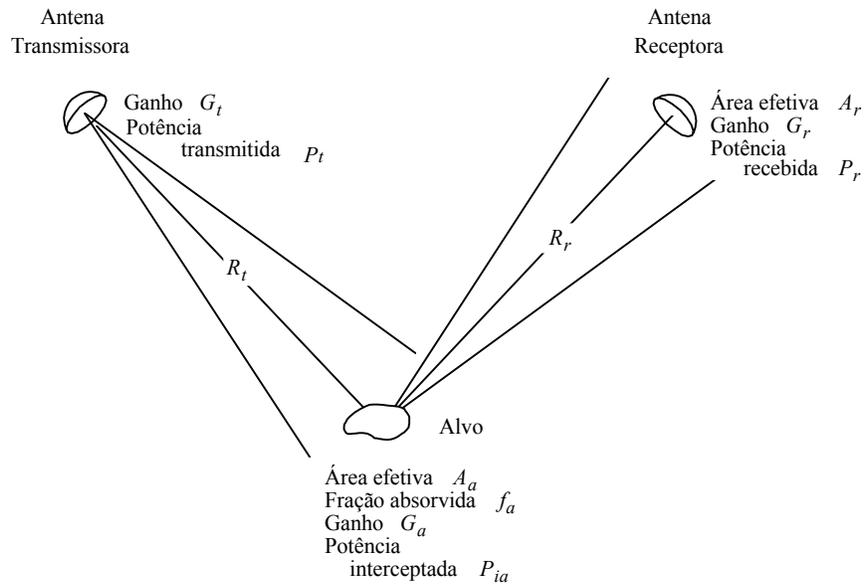


FIGURA 2.5 - Geometria e parâmetros envolvidos na equação de radar

FONTE: Modificada de Ulaby et al. (1986a), p.458.

A densidade do fluxo transmitido pela antena pode ser calculada através da equação:

$$\phi_t = \frac{P_t}{4\pi R^2}, \quad (2.6)$$

onde P_t é a potência transmitida pela antena e R é o raio da esfera ao redor da antena. Nos casos onde a antena não é isotrópica, ou seja, quando possui uma direção preferencial para transmissão, acrescenta-se um fator à equação, G_t , que indica o ganho da antena para uma dada direção. Dessa forma, a equação torna-se

$$\phi_t = \frac{P_t G_t}{4\pi R^2}. \quad (2.7)$$

Considerando que o alvo possui uma área efetiva de A_a e está colocado a uma distância R_t da antena transmissora, tem-se que a potência interceptada pelo alvo é

$$P_{ia} = \frac{P_t G_t A_a}{4\pi R_t^2}. \quad (2.8)$$

Parte da energia interceptada é absorvida pelo alvo. Sendo f_a a fração absorvida, então a potência reirradiada pelo alvo é

$$P_{ia} = P_{ia}(1 - f_a) \quad (2.9)$$

e a potência que atinge a antena receptora é

$$P_r = \frac{P_{ia} G_a A_r}{4\pi R_r^2}, \quad (2.10)$$

onde G_a é o ganho do alvo na direção da antena receptora, A_r é a área efetiva da antena receptora e R_r é a distância entre o alvo e a mesma antena.

A Equação 2.10 pode ser combinada com as anteriores, resultando em

$$P_r = \frac{P_t G_t A_a}{4\pi R_t^2} (1 - f_a) \frac{G_a A_r}{4\pi R_r^2}, \quad (2.11)$$

ou, rearranjando os elementos,

$$P_r = \left(\frac{P_t G_t A_r}{(4\pi)^2 R_t^2 R_r^2} \right) [A_a (1 - f_a) G_a]. \quad (2.12)$$

Os fatores relacionados com o difusor (alvo) estão entre colchetes sendo combinados em um fator denominado seção radar de retroespalhamento:

$$\sigma = A_a (1 - f_a) G_a. \quad (2.13)$$

Assim, a equação de radar torna-se

$$P_r = \frac{P_t G_t A_r \sigma}{(4\pi)^2 R_t^2 R_r^2}. \quad (2.14)$$

Nos casos onde o radar é monoestático, isto é, uma mesma antena é transmissora e receptora, pode-se considerar que $R_t = R_r = R$, $G_t = G_r = G$ e $A_t = A_r = A$.

Sendo a área efetiva de uma antena relacionada ao seu ganho por

$$A = \frac{\lambda^2 G}{4\pi}, \quad (2.15)$$

pode-se reescrever a equação de radar como

$$P_r = \frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 R^4} = \frac{P_t A^2 \sigma}{4\pi \lambda^2 R^4}. \quad (2.16)$$

Esta equação é válida para alvos pontuais (único difusor). Considerando uma superfície, onde N difusores são distribuídos aleatoriamente, tem-se que

$$\bar{P}_r = \sum_{i=1}^N P_{ri}, \quad (2.17)$$

onde \bar{P}_r é a potência recebida pela antena e P_{ri} é a potência refletida por cada um dos difusores e recebida pela antena.

Combinando as Equações 2.16 e 2.17 tem-se

$$\bar{P}_r = \frac{\lambda^2}{(4\pi)^3} \sum_{i=1}^N \frac{P_{ti} G_i^2 \sigma_i}{R_i^4}. \quad (2.18)$$

Definindo-se o coeficiente de retroespalhamento normalizado, σ_i^o , como

$$\sigma_i^o = \frac{\sigma_i}{\Delta A_i} \quad (2.19)$$

e substituindo σ_i por $\sigma_i^o \Delta A_i$ na Equação 2.18 tem-se

$$\bar{P}_r = \frac{\lambda^2}{(4\pi)^3} \sum_{i=1}^N \frac{P_{ti} G_i^2 \sigma_i^o \Delta A_i}{R_i^4}, \quad (2.20)$$

ou, passando ao limite,

$$\bar{P}_r = \frac{\lambda^2}{(4\pi)^3} \int_A \frac{P_t G^2 \sigma^\circ dA}{R^4}. \quad (2.21)$$

Considerando que P_t é constante para cada sistema de radar, que a distância entre a antena e cada um dos difusores é praticamente a mesma e que a variação de σ° é desprezível dentro da área iluminada pelo radar (A), pode-se simplificar a Equação 2.21 para

$$\bar{P}_r = \frac{P_t \lambda^2 \sigma^\circ}{(4\pi)^3 R^4} \int_A G^2 dA. \quad (2.22)$$

Definindo-se uma área ponderada, A_p , de forma que

$$G_0^2 A_p = \int_A G^2 dA. \quad (2.23)$$

onde G_0 representa o ganho máximo da antena, a equação de radar fica simplificada para

$$\bar{P}_r = \frac{P_t \lambda^2 G_0^2 A_p \sigma^\circ}{(4\pi)^3 R^4}. \quad (2.24)$$

Assim, pode-se concluir que a potência recebida pela antena esta diretamente relacionada com o coeficiente de retroespalhamento σ° . Os demais parâmetros da equação podem ser reunidos num só, caracterizando o sistema de radar (Ulaby e Dobson, 1989). É importante notar que a potência que retorna à antena sofre uma atenuação que é proporcional a R^4 , o que significa dizer que dois alvos iguais apresentarão respostas diferentes se colocados a distâncias diferentes em relação à antena. O processo de correção radiométrica visa corrigir este tipo de distorção.

2.3 - Comportamento de Alvos

Na região de microondas, um dossel, representado por uma cultura, pode ser caracterizado por um conjunto de elementos difusores ocupando um certo volume no espaço, colocados sobre uma superfície difusora constituída pelo solo. O coeficiente de retroespalhamento deste dossel, σ_{dos}° , é representado pela soma das contribuições do próprio dossel, do retroespalhamento direto do solo e de múltiplos espalhamentos entre os elementos difusores do dossel e os da superfície do solo (Ulaby et al., 1984). A Figura 2.6 mostra esquematicamente as contribuições do retroespalhamento de um dossel.

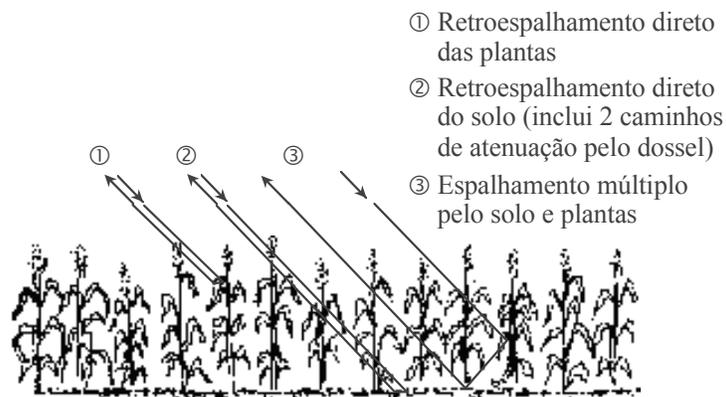


FIGURA 2.6 - Contribuições do retroespalhamento de um dossel.

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

Para melhor entender o comportamento do coeficiente de retroespalhamento de um dossel, 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) a constante dielétrica da vegetação, que é fortemente influenciada pelo seu conteúdo de umidade. 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;
- b) o tamanho, forma e orientação dos elementos difusores do dossel;

- c) a rugosidade e a constante dielétrica do solo sob o dossel; e
- d) a geometria de cobertura do dossel (direção e espaçamento das linhas de cultura, porcentagem de cobertura, altura da planta, etc).

Outros fatores igualmente importantes, segundo os mesmos autores, são os relativos ao sensor:

- a) a frequência da onda incidente;
- b) a direção da onda incidente, definida por (θ, ϕ) , onde θ é o ângulo de incidência relativo à incidência normal e ϕ é o ângulo azimutal relativo à direção de visada paralela às linhas de cultura, por exemplo; e
- c) a direção de polarização das antenas de transmissão e recepção.

2.3.1 - Fatores Relacionados ao Sensor

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

$$h < \frac{\lambda}{8\cos\theta} \text{ ou } h < \frac{c}{8\cos\theta} \frac{1}{f} \quad (2.26)$$

onde h é a altura média das variações da superfície, λ é o comprimento de onda, c é a velocidade da luz, f é a frequência, e θ é o ângulo de incidência.

A penetração da onda incidente num dossel pode ser constatada pela mudança relativa na magnitude do σ_{dos}° em resposta a uma mudança no conteúdo de umidade do solo (Ulaby et al., 1986b). A Figura 2.7 mostra como o σ_{dos}° varia com a umidade do solo para diferentes ângulos de incidência. Para cada ângulo, plotou-se uma linha de

regressão. A inclinação de cada reta, denominada sensibilidade (S), indica a variação do σ_{dos}° relativa a 1% de umidade.

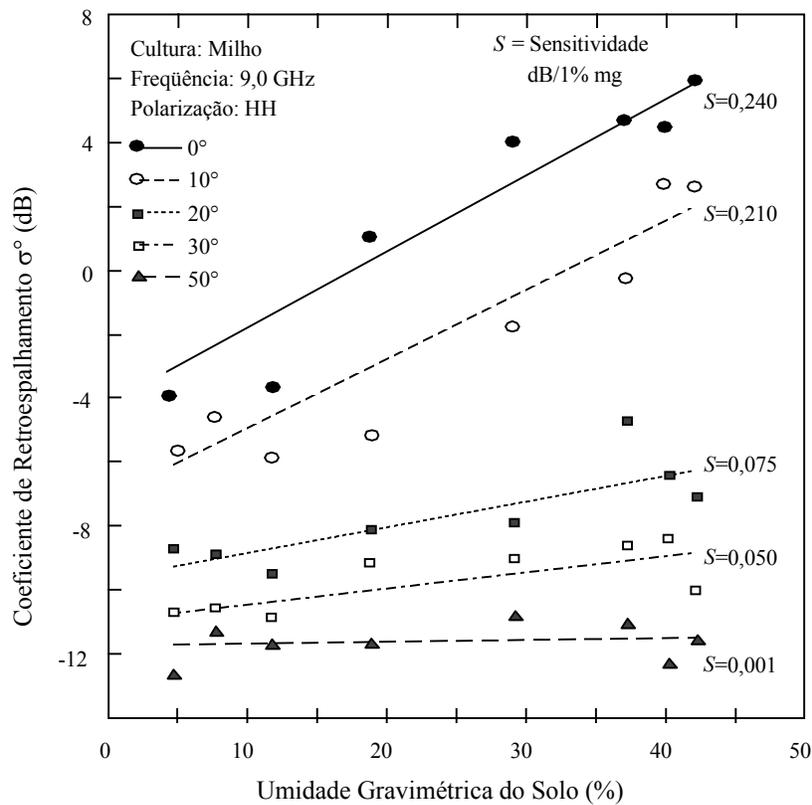


FIGURA 2.7 - Medida do coeficiente de retroespalhamento de uma cultura de milho como uma função da umidade do solo e do ângulo de incidência.

FONTE: Modificada de Ulaby et al. (1975), p. 614.

A fim de avaliar a penetração da onda incidente, Bush e Ulaby (1978) calcularam a sensibilidade S de dosséis de diversas culturas para algumas freqüências e ângulos de incidência. Pode-se notar, pela Figura 2.8, que a maior contribuição do solo (maior penetração da onda incidente) no sinal de retorno do dossel se deu em baixas freqüências (menores que 8 GHz) e pequenos ângulos de incidência (menores que 30°).

A Figura 2.9 apresenta o σ° em função do ângulo de incidência para 5 solos apresentando altos teores de umidade e diferentes rugosidades, em 3 freqüências, 1,1 GHz, 4,25 GHz e 7,25 GHz. Pode-se observar que a maior variação do σ° , para solos

com alto teor de umidade, se dá em baixas frequências e baixos índices de rugosidade (superfícies mais lisas). As maiores variações do σ^0 em relação à umidade e à rugosidade são observadas para ângulos próximos à normal e para ângulos maiores que 30° (Ulaby et al., 1978).

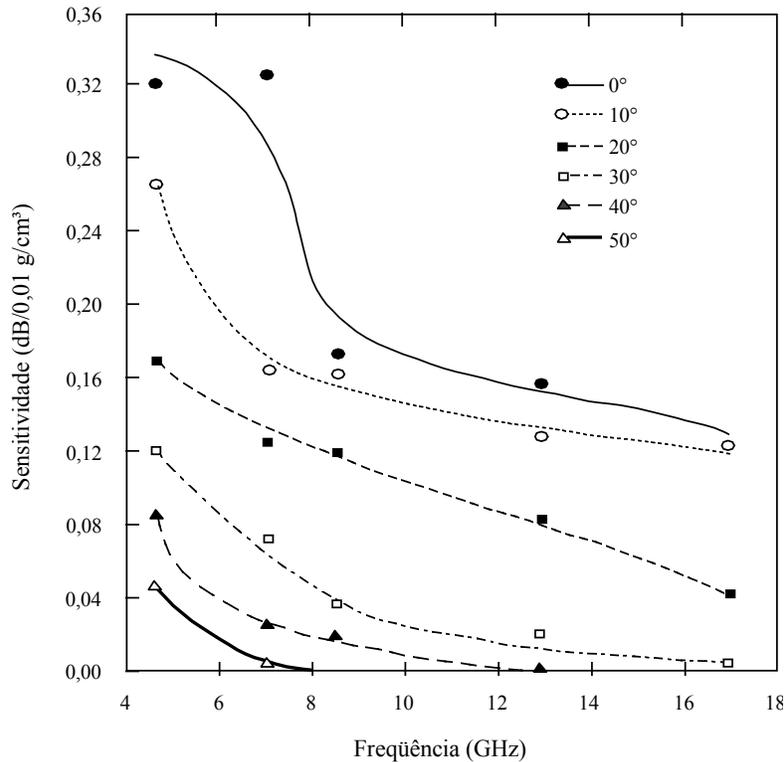


FIGURA 2.8 - Sensitividade para umidade do solo como uma função da frequência e do ângulo de incidência para culturas de milho, soja e alfafa.

FONTE: Modificada de Bush e Ulaby (1978), p. 19.

A polarização descreve a orientação do campo elétrico de uma onda eletromagnética. Comumente, 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).

O grau de penetração da onda num alvo 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 (Allen e Ulaby, 1984; 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 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 pelo ângulo de incidência.

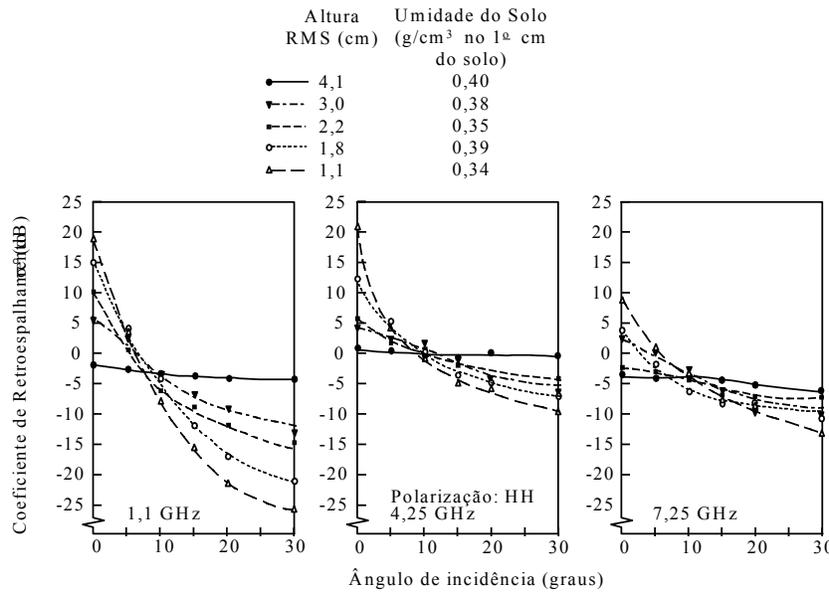


FIGURA 2.9 - Resposta angular do coeficiente de retroespalhamento.
 FONTE: Modificada de Ulaby et al. (1978), p. 289.

As polarizações cruzadas são geradas por múltiplos espalhamentos e conseqüentemente geram espalhamentos de menor intensidade, particularmente em superfícies levemente rugosas para ângulos de incidência próximos à normal. É comum considerar que $\sigma_{hv}^{\circ} = \sigma_{vh}^{\circ}$ (NASA/JPL, 1986). Segundo Evans et al. (1986), a vegetação normalmente exibe um alto componente de polarização cruzada.

Estudando a razão de despolarização de solos com superfícies lisas, definida como $\sigma_{hv}^{\circ} / \sigma_{hh}^{\circ}$, Ulaby et al. (1978) concluíram que este fator é fracamente dependente do conteúdo de umidade do solo entre 0° e 30°, para freqüências entre 1,1 e 7,25 GHz

(Figura 2.10). Uma grande dependência angular pode ser notada quando se utiliza a frequência de 1,1 GHz. Os mesmos autores verificaram que esta dependência angular desapareceu em solos rugosos.

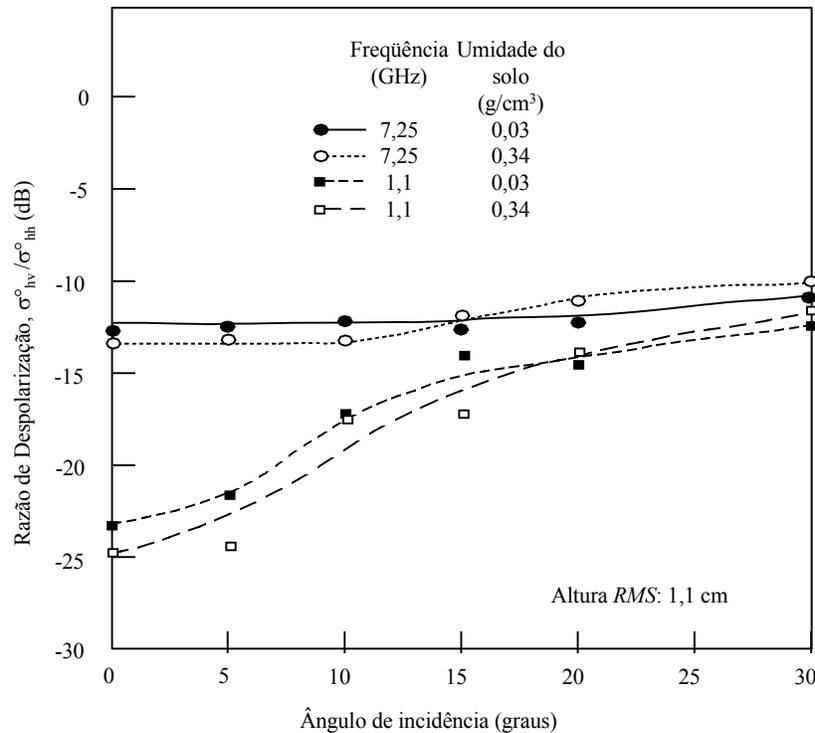


FIGURA 2.10 - Dependência angular da razão de despolarização de uma superfície lisa.

FONTE: Modificada de Ulaby et al.(1978), p. 290.

2.3.2 - Fatores Relacionados ao Dossel

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 dielétricas destes alvos (solo e vegetação) e conseqüentemente do σ^o (Brakke et al., 1981).

Pesquisas têm mostrado que o σ^o aumenta com a umidade do solo, tanto para solos nus (Ulaby et al., 1978) como para solos vegetados (Ulaby et al., 1979). No último caso, a sensibilidade para a umidade do solo decresce com o ângulo de incidência e frequência

devido ao aumento da atenuação causada pela vegetação (Bush e Ulaby, 1978). Ulaby et al. (1978) indicaram que a relação entre o σ° e a umidade do solo nu foi aproximadamente linear, com alta correlação.

Medidas de campo mostraram um incremento do σ° em dosséis com presença de água livre (Allen e Ulaby, 1984; Sofko et al., 1989; Brisco et al., 1989b). 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.

Como pôde ser observada na Figura 2.9, 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*) para descrever a rugosidade de uma superfície. A Figura 2.11 ilustra a dependência do σ° em relação à rugosidade. Pode-se notar que, à nadir ($\theta = 0^{\circ}$), o σ_{hh}° decresce rapidamente com o aumento da rugosidade e este decréscimo é mais acentuado para menores frequências. Para o ângulo de incidência de 10° , o σ° mostra-se pouco dependente com relação à rugosidade, para as 3 frequências analisadas. Já para o ângulo de incidência de 20° , há uma inversão da dependência, ou seja, o aumento da rugosidade resulta no aumento do σ° (Ulaby et al., 1978). Pode-se observar ainda que as maiores variações do σ° ocorrem em superfícies mais lisas.

Segundo Brakke et al.(1981), a vegetação pode atuar sobre o σ° como um fator de incremento da rugosidade da superfície.

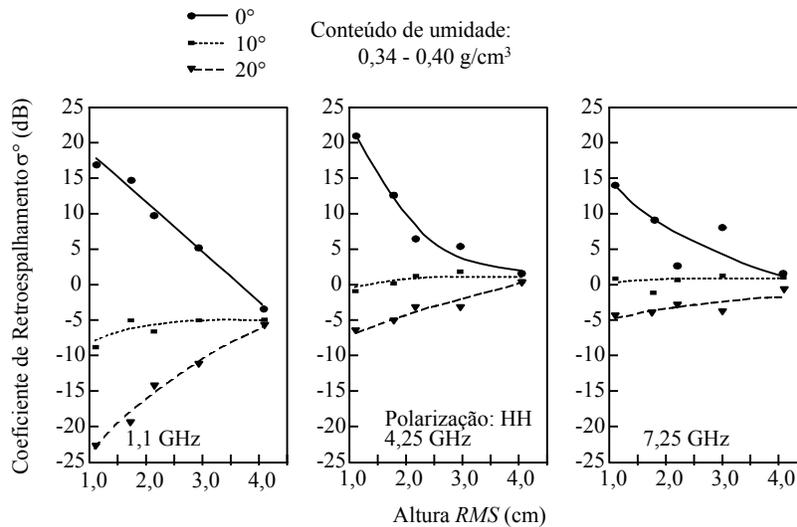


FIGURA 2.11 - Relação entre o coeficiente de retroespalhamento e a altura *RMS* e o ângulo de incidência para 1,1 GHz, 4,25 GHz, e 7,25 GHz.

FONTE: Modificada de Ulaby et al. (1978), p. 290.

Um dossel, pelo seu caráter dinâmico, apresenta variações temporais na morfologia de seus constituintes, podendo influenciar muito a resposta de radar Ulaby et al. (1974).

Ulaby et al. (1986b), trabalhando com milho e trigo, encontraram correlações positivas entre os valores de retroespalhamento 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 de retroespalhamento. Resultados similares foram conseguidos por Fischer e Mussakowski (1989).

Estudando a relação entre o índice de área foliar (IAF) e o σ° , Ulaby et al. (1984) observaram que, para frequência de 13 GHz e ângulo de incidência de 50°, houve um aumento do σ° do dossel, para milho e sorgo, quando incrementou-se o IAF até o valor próximo a 2. A partir deste ponto, a sensibilidade do σ° 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 σ° do dossel foi muito afetado pela umidade do solo. Durante a

fase de desenvolvimento ($IAF > 0,5$), o σ° foi dominado pelas folhas. Já no estágio de pré-colheita ($IAF < 0,5$), o σ° foi dominado pelas contribuições do solo, hastes e espigas. Para Brakke et al. (1981), as maiores correlações entre σ° e o IAF ocorreram para ângulos de incidência de 30° .

A influência da direção da linha da cultura sobre o σ° têm sido verificada por muitos autores (Schwarz e Caspall, 1968; Batlivala e Ulaby, 1976; Batlivala e Ulaby, 1977; Ulaby e Bare, 1979; Ulaby et al., 1979; Paris, 1983; Brisco et al., 1984; Brown et al., 1984).

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 ambas 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.

Ulaby e Bare (1979), estudando culturas de milho, trigo e soja, investigaram a dependência do σ° em relação à direção da linha de cultura, utilizando ângulos de incidência de 0° a 60° , frequências de 1 GHz a 18 GHz e três polarizações lineares (HH, HV e VV). Os resultados indicaram uma forte influência da direção da linha em 1 GHz, diminuindo exponencialmente com a frequência, sendo que esta influência praticamente desapareceu a partir dos 4 GHz. Também neste trabalho foi verificado que não houve efeito da direção da linha sobre o σ_{hv}° .

Paris (1983) observou que, em culturas de milho e soja, o efeito da direção da linha sobre o σ° desapareceu quando ângulos de incidência maiores que 25° foram utilizados.

2.3.3 - Discriminação de Culturas

Já na década de 60, Schwarz e Caspall (1968) demonstraram a influência significativa do tipo de cultura no sinal de radar retornado, com isso demonstrando a potencialidade do sistema de radar em discriminar culturas. A partir daí, muitos outros trabalhos têm demonstrado o grande potencial dos dados de radar na discriminação de culturas agrícolas (Bush e Ulaby, 1978; Brisco e Protz, 1982; Paris, 1983; Brown, 1986).

A variação no sinal de retorno é causada por mudanças nas propriedades dielétricas e geométricas dos constituintes do dossel. Como estas propriedades mudam com o tempo e com o estágio de desenvolvimento fisiológico do dossel, o uso de dados multitemporais pode ser muito útil na discriminação de culturas (Brisco e Protz, 1982; Brisco et al., 1984; Brown et al., 1984). Além disso, alguns autores discutem a importância de se conhecer o calendário agrícola no momento de aquisição dos dados, com isso conseguindo uma melhor discriminação entre culturas (Brisco et al., 1984; Brisco et al., 1989a).

Paris (1983) observou que a discriminação de culturas (milho e soja) foi muito melhor em condições de solo seco. Entretanto, utilizando-se a razão de despolarização, a separabilidade tornou-se muito boa mesmo quando em condições de solo úmido. Segundo o autor, esta discriminação se deu devido a diferenças estruturais básicas entre as culturas estudadas.

Diagramas de dispersão bidimensionais usando diferentes combinações de bandas e polarizações têm sido utilizadas na discriminação de culturas agrícolas (Schwarz e Caspall, 1968; Paris, 1983). Isto sugere que classificadores multidimensionais possam ser usados com sucesso na discriminação de culturas.

Thomson et al. (1990), estudando a correlação entre bandas na faixa do microondas, concluíram que a baixa correlação entre os dados das bandas X e C indicava que a combinação destas duas bandas numa composição colorida forneceria informações adicionais significativas, melhorando a classificação.

Fischer e Mussakowski (1989) sugerem que combinações de diferentes bandas, diferentes polarizações e diferentes datas melhoram a identificação de culturas.

2.4 - Evolução dos Sistemas de Radar

2.4.1 - Aspectos Históricos

Em 1903, a partir de estudos realizados por Hertz sobre geração, recepção e espalhamento de ondas eletromagnéticas, Hulsmeyer demonstrou a possibilidade de utilização de radar na detecção de navios. Em 1922, o primeiro sistema de radar foi demonstrado por Taylor. Mas foi somente em 1937 que Sir Watson-Watt construiu o primeiro sistema de radar operacional (Curlander e McDonough, 1991; Dallemand et al., 1993).

Os primeiros radares imageadores começaram a ser utilizados durante a II Guerra Mundial como auxiliares a bombardeios noturnos. Após a II Guerra Mundial, iniciou-se o desenvolvimento de radares de visada lateral (SLAR - *Side-Looking Airborne Radar*). A principal desvantagem deste radar de abertura real era sua resolução azimutal limitada pelo comprimento da antena, além de ser dependente da distância entre a antena e o alvo imageado. Assim, para se conseguir uma melhor resolução azimutal, necessitava-se diminuir a distância entre o radar e o alvo, ou aumentar o comprimento da antena. Com a utilização de um radar de abertura sintética (SAR - *Synthetic Aperture Radar*), desenvolvido na década de 50, este problema foi solucionado, já que a resolução azimutal neste sistema não dependia da distância entre o radar e o alvo.

Até a metade da década de 60, os radares apresentavam apenas aplicações militares. A utilização de imagens de radar para fins civis iniciou-se na década de 70, quando alguns programas foram realizados, utilizando-se imagens de radar à bordo de aeronaves (Pope et al., 1994). Entre estes programas, destaca-se o projeto RADAM - BRASIL, onde classificações não-supervisionadas de imagens digitais SAR foram muito úteis na caracterização da paisagem, uma vez que não se dispunha de mapas adequados de vegetação para região. As imagens de radar mostraram-se muito úteis principalmente em zonas tropicais, caracterizadas por apresentar muitas áreas permanentemente cobertas por nuvens. A utilização de radar à nível orbital iniciou-se com o lançamento do Seasat em 1978. Com base nos resultados alcançados pelo Seasat, a agência espacial americana, NASA, deu início ao programa SIR (*Shuttle Imaging Radar*), que consistiu numa série de vôos de curta duração. Dentro deste programa foram lançados o SIR-A e o SIR-B em 1981 e 1984 respectivamente. Tanto SIR-A quanto SIR-B foram baseados no Seasat, sendo que todos os três operaram na banda L (1,275 GHz) com polarização

HH. O Seasat e o SIR-A usaram ângulos de incidência fixos, 23° e 50° respectivamente. Já o SIR-B possuiu a capacidade de mover mecanicamente a antena e portanto utilizar múltiplos ângulos de incidência (NASA/JPL, 1986). Missões mais longas iniciaram-se com o lançamento do ALMAZ-1 em 1981, ALMAZ-2 em 1991, ERS-1 em 1991 e JERS-1 em 1992. Tanto o ERS-1 quanto o JERS-1 continuam ainda fornecendo imagens de radar. Como continuação da série SIR, foram programados três lançamentos do SIR-C/X-SAR. Dois outros sistemas SAR foram recentemente lançados, estando em fase de testes: ERS-2 e RADARSAT (NASA, 1987; Curlander e McDonough, 1991; Way e Smith, 1991; Dallemand et al., 1993).

Um histórico bastante detalhado do desenvolvimento dos sistemas de radar pode ser encontrado em Curlander e McDonough (1991). Way e Smith (1991) traçam a evolução dos sistemas de radar de abertura sintética desde o lançamento do Seasat até o desenvolvimento do EOS SAR como parte da série de satélites do *Earth Observing System* (EOS).

2.4.2 - O Sistema SIR-C/X-SAR

O SIR-C/X-SAR é um projeto conjunto da *National Aeronautics and Space Administration* (NASA), da *German Space Agency* (DARA), e da *Italian Space Agency* (ASI). O módulo SIR-C, construído pela JPL/NASA, é um radar que opera em 2 frequências, banda L (23 cm, 1,2 GHz) e banda C (6 cm, 5,6 GHz), e 4 polarizações (HH, HV, VH e VV). O módulo X-SAR, construído pela DARA e ASI, é um radar que opera na banda X (3 cm, 9 GHz), apresentando apenas uma polarização (VV). Ambos módulos foram projetados para trabalhar em sincronismo, apontando sempre para a mesma área.

Este sistema deveria operar pela primeira vez em 1990 (NASA/JPL, 1986) mas, com a explosão do ônibus espacial *Challenger* em 1986, todo o programa SIR foi revisto, e a missão foi sucessivamente adiada para 1991, 1992, 1993 e, finalmente, os dois primeiros vôos ocorreram em abril e outubro de 1994 (SRL-1 e SRL-2). O terceiro vôo da série está previsto para janeiro de 1996.

O SIR-C/X-SAR é, sem dúvida, uma das mais importantes missões de imageamento por radar já realizadas, pois os dados coletados durante os experimentos permitirão conduzir pesquisas nas mais diferentes áreas de estudo: vegetação, oceanografia, geologia, etc; auxiliarão o desenvolvimento de ferramentas para estimação de parâmetros geofísicos; além de auxiliar na definição da melhor configuração para a próxima geração de sistemas SAR multifrequência (NASA/JPL, 1986; Jordan et al., 1991).

CAPÍTULO 3

IMAGEM DE RADAR

Após o processamento digital, o produto de saída de um radar imageador é uma imagem digital composta por uma matriz bidimensional de *pixels*. O nível de cinza de um *pixel*, está relacionado à potência retroespalhada (P_r) pelo correspondente elemento de resolução no terreno por

$$NC = a\sqrt{P_r} + b \quad (3.1)$$

onde a e b são constantes de escala. Neste caso, está subtendido uma detecção linear, cujo produto gerado é uma imagem amplitude, que geralmente é discretizada em 8 *bits* (256 níveis de cinza). Para imagens obtidas a partir de detecção quadrática (imagem intensidade), os níveis de cinza são usualmente quantizados em 16 *bits*.

Pela Equação 2.25, pode-se notar que o nível de cinza de um determinado *pixel* pode ser diretamente relacionado com o σ^0 do elemento de resolução correspondente no terreno. É evidente que esta relação só acontece após todas as correções referentes ao padrão da antena, ângulo de incidência, etc. serem feitas. Entretanto, muitas vezes, não é necessário se fazer uma calibração absoluta dos dados, mas é suficiente uma calibração relativa, fazendo com que dois *pixels* localizados em posições diferentes da imagem mas referentes a um mesmo alvo, apresentem resposta semelhante.

3.1 - Propriedades Geométricas da Imagem SAR

As imagens de radar estão sujeitas a dois tipos de distorções geométricas: um devido a deslocamentos da plataforma e outro devido a características próprias do sistema de radar de visada lateral (SLAR e SAR). O primeiro tipo inclui erros do tipo rotação, guinada e arfagem, que também ocorrem em outros tipos de imagens (para maiores detalhes ver Curlander e McDonough, 1991). Para a correção deste tipo de distorção é necessário o conhecimento preciso da posição da plataforma durante a aquisição da imagem. As distorções do segundo tipo surgem pois os radares avaliam a posição de cada elemento de resolução através de medidas de tempo.

Dois termos são empregados para designar a natureza geométrica da imagem de radar: *slant range* e *ground range*. Os radares, num processamento normal, produzem imagens *slant range*, onde as distâncias são medidas entre a antena e o alvo. Já as imagens *ground range* consideram uma projeção horizontal (paralela à superfície do terreno imageado) e as distâncias são relativas à projeção da antena neste plano. A Figura 3.1 ilustra a relação entre estes dois tipos de imagem. Note que a resolução em *range* numa imagem *slant range* é constante, sendo definida pela duração do pulso de radar transmitido ($c\tau/2$). Nesta figura, cada retângulo representa um *pixel* da imagem e seu elemento de resolução correspondente no terreno. Como pode ser observado, quanto mais próximo o *pixel* está da antena, maior área ele representa em *ground range*. As distorções entre estes dois tipos de imagem se acentuam quando há relevo na área imageada.

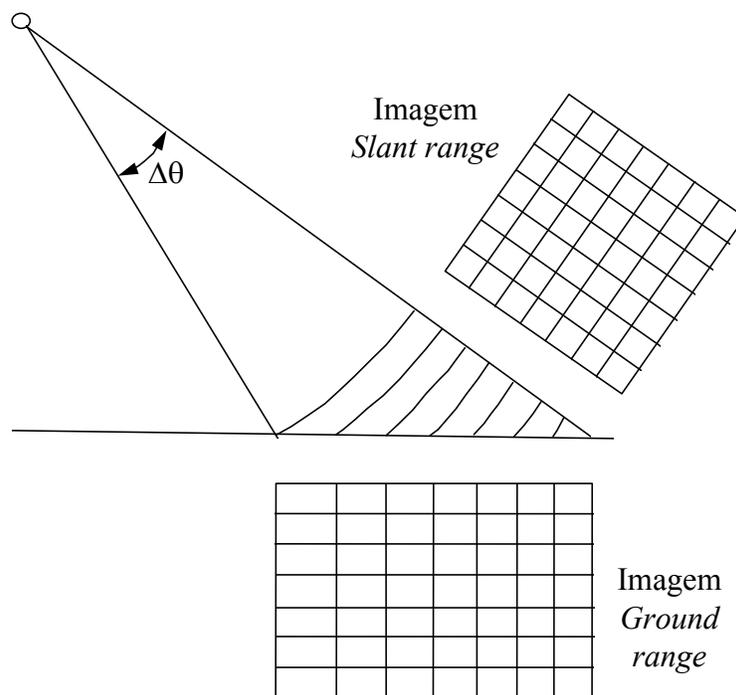


FIGURA 3.1 - Comparação entre imagens *slant range* e *ground range*.

Basicamente, o processo de transformação de uma imagem *slant range* numa imagem *ground range* envolve 2 etapas: uma para correção da posição de cada *pixel* da imagem *slant range* e outra que envolve a reamostragem que visa deixar os *pixels* da imagem

ground range correspondendo a elementos de resolução com dimensões uniformes (geralmente quadrados) no terreno.

A correção da posição de cada *pixel* pode ser conseguida através de uma transformação polinomial que relaciona a posição de cada *pixel* nas duas imagens. O ajuste deste polinômio é conseguido através da localização manual de pontos de controle. O grau do polinômio é determinado de acordo com a distorção existente entre as duas imagens. Devido a geometria de visada lateral dos sensores de radar, a topografia induz a distorções que podem ser parcialmente corrigidas se se adotar um modelo numérico do terreno (MNT) que represente este relevo. Para as áreas que não possuem MNT ou para aquelas onde o relevo é praticamente plano, pode-se promover a correção da imagem considerando a superfície lisa de um elipsóide como representando a superfície terrestre. Neste caso, não é necessária a coleta de pontos de controle, mas, no entanto, um sistema de localização da plataforma é requerido para uma preciso conhecimento da geometria de imageamento (Roth et al, 1993).

No processo de reamostragem, o nível de cinza associado ao *pixel* da imagem corrigida é obtido a partir do *pixel* correspondente na imagem destorcida. Como na maioria dos casos esta correspondência não é exata, o nível de cinza deste *pixel* é estimado a partir de uma vizinhança considerando algum tipo de interpolador. Idealmente, o processo de reamostragem deveria ser feito utilizando janelas de interpolação (*kernel*) do tipo *sinc*¹ o que resultaria, em teoria, em imagens sem perda de informação. No entanto, na prática, é necessário utilizar a função *sinc* truncada o que resulta na modificação das propriedades estatísticas originais (Quegan, 1990, Curlander e McDonough, 1991). Outros interpoladores têm sido utilizados (vizinho mais próximo, bilinear, convolução bicúbica, etc), cada qual com vantagens e desvantagens. De modo geral, todos interpoladores induzem a uma modificação na função de autocorrelação da imagem e, portanto, a textura original é modificada, ou seja, a textura da imagem reamostrada torna-se mais suavizada, ficando com aspecto borrado. Preferivelmente, a reamostragem

¹ $sinc(x) = \frac{\sin x}{x}$

é feita sobre os dados complexos, sendo as partes real e imaginária reamostradas separadamente.

3.2 - Propriedades Estatísticas da Imagem SAR

As imagens SAR são formadas por uma interferência coerente entre os difusores que formam cada *pixel* da imagem. Como cada elemento de resolução é composto por um grande número de difusores, o sinal de retorno resulta da soma coerente (vetorial) do sinal elementar retornado por cada um dos elementos difusores. Este processo causa flutuações aleatórias que dão um aspecto granuloso característico às imagens SAR. Este tipo de ruído ou interferência denomina-se *speckle*.

O sinal de retorno total de cada elemento de resolução pode ser representado como a soma das contribuições de cada um dos difusores elementares, ou seja,

$$Z(\mathbf{u}) = \sum_{k=-\infty}^{\infty} a_k e^{i\phi_k} h(\mathbf{u}) \quad (3.2)$$

onde a_k , ϕ_k , \mathbf{u} são, respectivamente, a amplitude, a fase e a posição (x em *range*, y em *azimute*) de cada um dos k difusores, $h(\mathbf{u})$ é a função de espalhamento no ponto \mathbf{u} e $i = \sqrt{-1}$.

A Equação 3.2, para o caso quando o elemento de resolução é formado por n difusores, pode ser reescrita como

$$Z(\mathbf{u}) = \sum_{k=1}^n b_k e^{i\Phi_k} \quad (3.3)$$

onde b_k é o produto entre as amplitudes do difusor elementar e da função de espalhamento pontual deste difusor, ou seja,

$$b_k = a_k |h(\mathbf{u})| \quad (3.4)$$

e Φ_k é a soma das fases do difusor elementar e da função de espalhamento, ou seja,

$$\Phi_k = \phi_k + \varphi_k, \quad (3.5)$$

onde $\varphi_k = \angle h(\mathbf{u})^2$.

Quando o alvo apresentar superfície rugosa (relativa ao comprimento de onda e ao ângulo de incidência) ou quando o elemento de resolução possuir dimensões muito maiores que o comprimento de onda, a fase dos difusores será distribuída uniformemente no intervalo de $[-\pi, \pi]$ e será independente da amplitude. Neste caso, os componentes real e imaginário do sinal retornado pelo elemento de resolução são dados por

$$Z_{\Re}(\mathbf{u}) = \sum_{k=-\infty}^{\infty} b_k \cos \Phi_k, \quad (3.6)$$

$$Z_{\Im}(\mathbf{u}) = \sum_{k=-\infty}^{\infty} b_k \sen \Phi_k, \quad (3.7)$$

ambos com média igual a zero³,

$$\langle Z_{\Re}(\mathbf{u}) \rangle = \sum_{k=-\infty}^{\infty} \langle b_k \rangle \langle \cos \Phi_k \rangle = 0, \quad (3.8)$$

$$\langle Z_{\Im}(\mathbf{u}) \rangle = \sum_{k=-\infty}^{\infty} \langle b_k \rangle \langle \sen \Phi_k \rangle = 0, \quad (3.9)$$

e mesma variância,

$$\langle Z_{\Re}(\mathbf{u})^2 \rangle = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} \langle b_j b_k \rangle \langle \cos \Phi_j \cos \Phi_k \rangle = \frac{1}{2} \sum_{k=-\infty}^{\infty} \langle b_k^2 \rangle, \quad (3.10)$$

$$\langle Z_{\Im}(\mathbf{u})^2 \rangle = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} \langle b_j b_k \rangle \langle \sen \Phi_j \sen \Phi_k \rangle = \frac{1}{2} \sum_{k=-\infty}^{\infty} \langle b_k^2 \rangle. \quad (3.11)$$

² \angle denota o argumento de um número complexo.

³ $\langle \cdot \rangle$ é a esperança de uma variável.

É importante notar que os componentes de $Z(\mathbf{u})$ não são correlacionados, uma vez que a covariância entre os dois componentes é nula,

$$\langle Z_{\Re}(\mathbf{u})Z_{\Im}(\mathbf{u}) \rangle = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} \langle b_j b_k \rangle \langle \cos \Phi_j \sin \Phi_k \rangle = 0. \quad (3.12)$$

Se o número de difusores, n , num elemento de resolução for grande e nenhum dos difusores dominar o sinal, então, pelo teorema do limite central, Z_{\Re} e Z_{\Im} possuem distribuição aproximadamente normal, com média zero e mesma variância. Dessa forma, a função densidade de probabilidade (fdp) conjunta é

$$f_z(Z_{\Re}, Z_{\Im}) = \frac{1}{2\pi \text{Var}(Z)} e^{-\frac{(Z_{\Re}^2 + Z_{\Im}^2)}{2\text{Var}(Z)}} \quad (3.13)$$

onde $\text{Var}(Z) = \text{Var}(Z_{\Re}) = \text{Var}(Z_{\Im})$.

3.2.1 - Propriedades Estatísticas da Imagem Intensidade

A intensidade do elemento de resolução definido por

$$I(\mathbf{u}) = |Z(\mathbf{u})|^2 = Z_{\Re}(\mathbf{u})^2 + Z_{\Im}(\mathbf{u})^2 \quad (3.14)$$

possui média, de acordo com as Equações 3.4, 3.10 e 3.11,

$$\mu_I = \langle I(\mathbf{u}) \rangle = \sum_{k=-\infty}^{\infty} \langle a_k^2 \rangle |h(\mathbf{u})|^2. \quad (3.15)$$

Nesta equação, a_k^2 caracteriza cada difusor elementar através da seção de radar (σ).

Considerando $a_k^2 = \sigma_k$, tem-se que

$$\mu_I = \sum_{k=-\infty}^{\infty} \langle \sigma_k \rangle |h(\mathbf{u})|^2, \quad (3.16)$$

o que demonstra que a resposta média em intensidade é diretamente proporcional à seção de radar e portanto do coeficiente de retroespalhamento (σ^0).

Segundo Caves (1993), o momento da intensidade de ordem m pode ser generalizado na forma

$$\langle I(\mathbf{u})^m \rangle = m! \left\langle \left(\sum_{k=-\infty}^{\infty} \sigma_k |h(\mathbf{u})|^2 \right)^m \right\rangle. \quad (3.17)$$

Como $m!$ é o m -ésimo momento de uma variável aleatória exponencial de média unitária, o momento da intensidade pode ser expresso por

$$\langle I(\mathbf{u})^m \rangle = \langle \xi(\mathbf{u})^m \rangle \langle \Upsilon(\mathbf{u})^m \rangle, \quad (3.18)$$

onde ξ é uma variável aleatória exponencial com média unitária e Υ é definido como

$$\Upsilon(\mathbf{u}) = \sum_{k=-\infty}^{\infty} \sigma_k |h(\mathbf{u})|^2. \quad (3.19)$$

Como a Equação 3.18 aplica-se a todos os momentos, pode-se concluir que a intensidade é dada por

$$I(\mathbf{u}) = \xi(\mathbf{u})\Upsilon(\mathbf{u}). \quad (3.20)$$

A variável aleatória exponencial ξ é resultado da interferência coerente, o que causa uma flutuação aleatória da intensidade, causando o aparecimento do *speckle*. Este tipo de representação para a intensidade é referido como o modelo multiplicativo (Lowenthal e Arsenault, 1970; Arsenault e April, 1976; Lee (1981), Frost et al., 1982; Goldfinger, 1982; Ulaby et al., 1986). É importante lembrar que o modelo multiplicativo falha quando o alvo contém detalhes finos que não podem ser resolvidos pelo sistema imageador (Tur et al., 1982; Miller, 1986).

3.2.1.1 - Regiões Homogêneas

Uma região homogênea é definida como aquela que apresenta σ constante, embora desconhecido. Pelas Equações 3.16 e 3.19, pode-se observar que se σ é constante, então $\Upsilon = \mu_I$. Desta forma, a textura encontrada em regiões homogêneas é devido

exclusivamente a variações aleatórias em ξ , ou seja, a intensidade I é exponencialmente distribuída com média μ_I (Caves, 1993). O mesmo resultado pode ser encontrado aplicando-se o teorema do limite central aos componentes complexos Z_{\Re} e Z_{\Im} . Se a fdp conjunta para Z_{\Re} e Z_{\Im} é dada pela Equação 3.13, então, a fdp conjunta para I e Φ é dada por

$$f_Z(I, \Phi) = \frac{1}{4\pi \text{Var}(Z)} e^{\frac{-I}{2\text{Var}(Z)}}. \quad (3.21)$$

Integrando-se esta equação em relação à Φ , tem-se que

$$f_I(I) = \int_{-\pi}^{\pi} f_Z(I, \Phi) d\Phi = \frac{1}{\mu_I} e^{\frac{-I}{\mu_I}}, \quad (3.22)$$

onde $\mu_I = 2 \text{Var}(Z)$, confirmando que I tem distribuição exponencial com média μ_I e variância μ_I^2 . Pode-se também verificar que a fase Φ é uniformemente distribuída,

$$f_{\Phi}(\Phi) = \int_0^{\infty} f_Z(I, \Phi) dI = \frac{1}{2\pi}, \quad (3.23)$$

e que a fase e a intensidade são independentes, uma vez que a distribuição conjunta é a multiplicação de suas marginais,

$$f_Z(I, \Phi) = f_I(I) f_{\Phi}(\Phi). \quad (3.24)$$

A fim de reduzir o *speckle*, uma nova imagem intensidade pode ser formada a partir da média de n imagens intensidade independentes, ou seja,

$$I_{(n)}(\mathbf{u}) = n^{-1} \sum_{k=1}^n I_k(\mathbf{u}), \quad (3.25)$$

onde I_k é uma imagem de 1-look. Se cada I_k é exponencialmente distribuída com média μ_I , então $I_{(n)}$ tem uma distribuição gamma cuja fdp é⁴

$$f_{I_{(n)}}(I) = \frac{n^n I^{n-1}}{\mu_I^n \Gamma(n)} e^{-\frac{nI}{\mu_I}}, \quad (3.26)$$

com média μ_I e variância $Var(I) = \frac{\mu_I^2}{n}$.

3.2.1.2 - Regiões não Homogêneas

Numa região não homogênea, a textura representa não só o *speckle*, mas também as variações em σ . Assim, a distribuição de I depende da distribuição escolhida para Υ . Usualmente, adota-se uma distribuição gamma para Υ (Caves, 1993; Yanasse et al., 1994), cuja fdp é

$$f_{\Upsilon}(\Upsilon) = \frac{\alpha^\alpha \Upsilon^{\alpha-1}}{\mu_I^\alpha \Gamma(\alpha)} e^{-\frac{\alpha \Upsilon}{\mu_I}}, \quad (3.27)$$

onde α é o parâmetro de ordem da distribuição gamma, $\mu_I > 0$, $\alpha > 0$ e $\Upsilon \geq 0$. Quando $\alpha = 1$, esta equação reduz-se a uma exponencial com média μ_I . Se α é muito grande ($\alpha \rightarrow \infty$), Υ torna-se constante ($\Upsilon = \mu_I$), caracterizando áreas homogêneas.

Considerando-se uma imagem de 1-look, ξ é exponencialmente distribuído com média unitária e Υ possui uma distribuição gamma com média μ_I e ordem α . Neste caso, I tem uma distribuição K intensidade, cuja fdp é dada por⁵

$$f_I(I) = \frac{2\alpha}{\mu_I \Gamma(\alpha)} \left(\sqrt{\frac{\alpha I}{\mu_I}} \right)^{\alpha-1} K_{\alpha-1} \left(2 \sqrt{\frac{\alpha I}{\mu_I}} \right), \quad (3.28)$$

⁴ $\Gamma(z)$ é a função gamma, dada por $\Gamma(z) = \int_0^\infty e^{-t} t^{z-1} dt$.

⁵ $K_\nu(z)$ é a função Bessel modificada, dada por $K_\nu(z) = \int_0^\infty e^{-z \cosh t} \cosh(\nu t) dt$.

com média μ_I e variância $\mu_I^2 \left(1 + \frac{2}{\alpha}\right)$, $\mu_I > 0$, $\alpha > 0$ e $I \geq 0$.

Para uma imagem *multilook*, isto é, para uma imagem intensidade formada a partir de n imagens de 1-look independentes, tem-se que I possui distribuição K intensidade n -looks, com fdp

$$f_{I(n)}(I) = \frac{2\alpha n}{\mu_I \Gamma(\alpha) \Gamma(n)} \left(\sqrt{\frac{\alpha n I}{\mu_I}} \right)^{\alpha+n-2} K_{\alpha-n} \left(2 \sqrt{\frac{\alpha n I}{\mu_I}} \right), \quad (3.29)$$

com média μ_I e variância $\frac{\mu_I^2}{n} \left(1 + \frac{n+1}{\alpha}\right)$, $\mu_I > 0$, $\alpha > 0$ e $I \geq 0$.

3.2.1.3 - Estimadores dos Parâmetros da Distribuição K Intensidade

Definindo-se o momento amostral de ordem r de uma amostra de tamanho N de uma imagem intensidade como

$$\hat{m}_{I_r} = N^{-1} \sum_{k=1}^N I_k^r, \quad (3.30)$$

tem-se que os estimadores pelo método dos momentos para μ_I , α e n são, segundo Yanasse et al. (1994),

$$\hat{\mu}_I = \hat{m}_{I_1}, \quad (3.31)$$

$$\hat{\alpha} = \frac{\hat{n} + 1}{\hat{n} \left(\hat{m}_{I_2} / \hat{m}_{I_1}^2 - 1 \right) - 1} = \frac{\hat{n} + 1}{\hat{n} CV_I^2 - 1}, \quad (3.32)$$

$$\hat{n} = \frac{-B \pm \sqrt{C}}{2A}, \quad (3.33)$$

onde

$$A = 2\hat{m}_{I_2}^2 - \hat{m}_{I_1}^2 \hat{m}_{I_2} - \hat{m}_{I_1} \hat{m}_{I_3}, \quad (3.34)$$

$$B = 4\hat{m}_{I_2}^2 - 3\hat{m}_{I_1}^2 \hat{m}_{I_2} - \hat{m}_{I_1} \hat{m}_{I_3}, \quad (3.35)$$

$$C = \hat{m}_{I_1}^4 \hat{m}_{I_2}^2 - 8\hat{m}_{I_1} \hat{m}_{I_2}^3 - 2\hat{m}_{I_1}^3 \hat{m}_{I_2} \hat{m}_{I_3} + 16\hat{m}_{I_2}^4 - 8\hat{m}_{I_1} \hat{m}_{I_2}^2 \hat{m}_{I_3} + \hat{m}_{I_1}^2 \hat{m}_{I_3}^2. \quad (3.36)$$

$$CV_I^2 = \frac{\hat{m}_{I_2} - \hat{m}_{I_1}^2}{\hat{m}_{I_1}^2} \quad (3.37)$$

para $\hat{\alpha} > 0$ e $\hat{n} \geq 1$.

3.2.2 - Propriedades Estatísticas da Imagem Amplitude

A análise de imagens SAR comumente é feita usando-se imagens amplitude, que é a raiz quadrada da intensidade. Assim, caso o modelo multiplicativo para a intensidade possa ser utilizado, a amplitude é dada então pelo produto da raiz quadrada de uma variável aleatória exponencial com média unitária (*speckle*) pela variável relacionada a σ , ou seja,

$$A(\mathbf{u}) = \sqrt{I(\mathbf{u})} = \sqrt{\xi(\mathbf{u})} \sqrt{\Upsilon(\mathbf{u})} = \xi_A(\mathbf{u}) \Upsilon_A(\mathbf{u}). \quad (3.38)$$

Se ξ é exponencialmente distribuído com média unitária, então $\sqrt{\xi} = \xi_A$ tem distribuição Rayleigh com média $\sqrt{\pi/4}$.

3.2.2.1 - Regiões Homogêneas

Se I possui fdp $f_I(I)$, então sua raiz quadrada $A = \sqrt{I}$ tem fdp igual a

$$f_A(A) = f_I(A^2) \frac{dI}{dA} = 2A f_I(A^2). \quad (3.39)$$

Dessa forma, considerando regiões homogêneas, a raiz quadrada A de uma variável aleatória distribuída exponencialmente I com média μ_I (ver Equação 3.22) tem fdp igual a

$$f_A(A) = \frac{2A}{\mu_I} e^{-\frac{A^2}{\mu_I}}, \quad (3.40)$$

ou seja, A tem uma distribuição Rayleigh com média $\mu_A = \sqrt{\frac{\pi\mu_I}{4}}$ e variância $Var(A) = \mu_I \left(1 - \frac{\pi}{4}\right)$, $\mu_I > 0$, e $A \geq 0$.

Considerando uma imagem amplitude *multilook* formada a partir da raiz quadrada da média de n imagens intensidade de 1-look independentes, ou seja,

$$A_{(n)}(\mathbf{u}) = \sqrt{I_{(n)}(\mathbf{u})} = \sqrt{n^{-1} \sum_{k=1}^n I_k(\mathbf{u})}, \quad (3.41)$$

tem-se que $A_{(n)}$ possui uma distribuição raiz da gamma cuja fdp é dada por

$$f_{A_{(n)}}(A) = \frac{2n^n A^{2n-1}}{\mu_I \Gamma(n)} e^{-\frac{nA^2}{\mu_I}}, \quad (3.42)$$

com média $\mu_A = \sqrt{\frac{\pi\mu_I}{4}}$ e variância $Var(A) = \frac{\mu_I}{n} \left(1 - \frac{\pi}{4}\right)$, $\mu_I > 0$, $n > 0$ e $A \geq 0$.

3.2.2.2 - Regiões não Homogêneas

Em regiões não homogêneas, como já discutido na Seção 3.1.2, considera-se que Y possui uma distribuição gamma. Com isso, pode-se concluir que $\sqrt{Y} = Y_A$, Equação 3.38, segue uma distribuição raiz da gamma, cuja fdp é dada por

$$f_{Y_A}(Y_A) = \frac{2\alpha^\alpha Y_A^{2\alpha-1}}{\mu_I^\alpha \Gamma(\alpha)} e^{-\frac{\alpha Y_A^2}{\mu_I}}, \quad (3.43)$$

onde α é o parâmetro de ordem da distribuição gamma de Y , $\alpha > 0$ e $A \geq 0$. Quando $\alpha = 1$, $f_{Y_A}(Y_A)$ torna-se a uma Rayleigh.

Em imagens de 1-look, ξ_A tem distribuição Rayleigh e Y_A possui uma distribuição raiz da gamma. A amplitude A tem, então, uma distribuição K amplitude cuja fdp pode ser facilmente obtida substituindo a Equação 3.28 em 3.39,

$$f_A(A) = \frac{4\sqrt{\alpha}}{\sqrt{\mu_I} \Gamma(\alpha)} \left(A \sqrt{\frac{\alpha}{\mu_I}} \right)^\alpha K_{\alpha-1} \left(2A \sqrt{\frac{\alpha}{\mu_I}} \right), \quad (3.44)$$

com média

$$\mu_A = \sqrt{\frac{\pi \mu_I}{4} \frac{\Gamma(\alpha + \frac{1}{2})^2}{\Gamma(\alpha + 1) \Gamma(\alpha)}} \quad (3.45)$$

e variância

$$Var(A) = \mu_I \left(1 - \frac{\pi}{4} \frac{\Gamma(\alpha + \frac{1}{2})^2}{\Gamma(\alpha + 1) \Gamma(\alpha)} \right). \quad (3.46)$$

Para uma imagem *multilook* formada a partir da raiz quadrada de n imagens intensidade de 1-look independentes, tem-se que A possui distribuição K amplitude n -looks, com fdp

$$f_{A_{(n)}}(A) = \frac{4\sqrt{\alpha n}}{\sqrt{\mu_I} \Gamma(\alpha) \Gamma(n)} \left(A \sqrt{\frac{\alpha n}{\mu_I}} \right)^{\alpha+n-1} K_{\alpha-n} \left(2A \sqrt{\frac{\alpha n}{\mu_I}} \right), \quad (3.47)$$

com média

$$\mu_A = \sqrt{\frac{\mu_I}{\alpha n} \frac{\Gamma(n + \frac{1}{2}) \Gamma(\alpha + \frac{1}{2})}{\Gamma(n) \Gamma(\alpha)}} \quad (3.48)$$

e variância

$$Var(A) = \mu_I \left(1 - \frac{\Gamma(n + \frac{1}{2})^2 \Gamma(\alpha + \frac{1}{2})^2}{\Gamma(n + 1) \Gamma(n) \Gamma(\alpha + 1) \Gamma(\alpha)} \right). \quad (3.49)$$

3.2.2.3 - Estimadores dos Parâmetros da Distribuição K Amplitude

Definindo-se o momento de ordem r de uma amostra de tamanho N de uma imagem amplitude como

$$\hat{m}_{A_r} = N^{-1} \sum_{k=1}^N A_k^r, \quad (3.50)$$

tem-se que o estimador para β é

$$\hat{\beta} = \hat{m}_{A_2}, \quad (3.51)$$

e os estimadores para α e n são obtidos pela solução do sistema de equações:

$$\sqrt{\frac{\hat{m}_{A_2}}{\hat{\alpha}\hat{n}}} \frac{\Gamma(\hat{\alpha} + \frac{1}{2})\Gamma(\hat{n} + \frac{1}{2})}{\Gamma(\hat{\alpha})\Gamma(\hat{n})} - \hat{m}_{A_1} = 0 \quad (3.52a)$$

$$\left(\frac{\hat{m}_{A_2}}{\hat{\alpha}\hat{n}}\right)^{\frac{3}{2}} \frac{\Gamma(\hat{\alpha} + \frac{3}{2})\Gamma(\hat{n} + \frac{3}{2})}{\Gamma(\hat{\alpha})\Gamma(\hat{n})} - \hat{m}_{A_3} = 0. \quad (3.52b)$$

Outro estimador para α pode ser obtido pela Equação 3.32 usando-se o segundo e quarto momentos amostrais da amplitude, ou seja, fazendo-se $\hat{m}_{I_r} = \hat{m}_{A_{r^2}}$.

Na prática, n pode ser estimado a partir de amostras de regiões homogêneas onde, como visto na Seção 3.2.2.1, a amplitude possui distribuição raiz da gamma, com média

$$\mu_A = \sqrt{\frac{\pi\mu_I}{4}} \quad (3.53)$$

e variância

$$Var(A) = \frac{\mu_I}{n} \left(1 - \frac{\pi}{4}\right). \quad (3.54)$$

A partir das Equações 3.53 e 3.54, pode-se verificar que

$$n = \left(\frac{4}{\pi} - 1\right) \frac{\mu_A^2}{Var(A)}. \quad (3.55)$$

Usando-se os momentos amostrais da amplitude de áreas homogêneas para estimar n , tem-se que

$$\hat{n} = \left(\frac{4}{\pi} - 1 \right) \frac{\hat{m}_{A_1}^2}{\hat{m}_{A_2} - \hat{m}_{A_1}^2}. \quad (3.56)$$

Esta estimação é feita para algumas amostras homogêneas, fazendo com que \hat{n} seja a média dos valores encontrados. O estimador \hat{n} é referido como número equivalente de *looks* (Yanasse et al., 1994). Uma vez estimado n , pode-se determinar o estimador de α resolvendo uma das Equações 3.52a ou 3.52b.

3.3 - Classificação de Imagens de Radar

Desde que as primeiras imagens de sensores ópticos foram obtidas, muitos autores têm procurado desenvolver técnicas de classificação que permitam a distinção de alvos na imagem. Entre os classificadores mais populares destacam-se os de máxima verossimilhança e os que se baseiam em funções discriminantes que procuram separar os dados segundo algum critério de similaridade. Cada tipo de classificador pode utilizar informações no domínio espectral, espacial e/ou temporal para treinar e testar seu desempenho.

A aplicação de técnicas de classificação em imagens de radar é relativamente recente (a partir de imagens do SEASAT em 1978). Devido à presença do *speckle*, os classificadores pontuais, ou seja, aqueles que classificam cada *pixel* separadamente, apresentam baixo desempenho (por exemplo, ver Lim et al, 1989, e Thomson, 1990), o que pode ser observado pelo grande número de *pixels* isolados ou não classificados.

Como visto na Seção 3.2, a suposição de normalidade dos dados, requerida por muitos classificadores, não pode ser adotada para imagens de radar, com exceção às imagens formadas a partir de um grande número de *looks*. Dessa forma, classificadores que utilizam regras de decisão bayesianas, de modo geral, não conseguem bons resultados.

Na maioria dos casos, não se conhece previamente a verdade terrestre e com isso não se estabelece probabilidades diferentes para cada classe investigada *a priori*. Dessa forma, mesmo que uma determinada classe tenha maior frequência na área de estudo, um *pixel* tem, *a priori*, a mesma chance de ser atribuído a esta classe ou a outra qualquer, mesmo

que esta última tenha pouca representatividade. A fim de minimizar este tipo de problema, van Zyl e Burnette (1992) desenvolveram uma metodologia onde uma imagem classificada é utilizada para estimar a probabilidade *a priori* e a mesma imagem é reclassificada. Os mesmos autores observaram que praticamente nenhum *pixel* foi reclassificado após a 4ª iteração e a precisão total chegou próximo dos 100%, quando testada sobre as amostras de treinamento.

Definitivamente, o maior problema da imagem SAR para os classificadores pontuais é a presença do *speckle* que causa uma grande variação tonal. A fim de minimizar este problema, foram desenvolvidos alguns filtros que levam em consideração a natureza estatística do *speckle*. Estes filtros, teoricamente, atenuam o efeito deste ruído sem, no entanto, eliminar a informação textural das imagens e as descontinuidades devido a mudanças de alvos. Os mais utilizados são os filtros adaptativos baseados em estatísticas locais: Frost, Lee e Kuan. Uma análise de cada um destes filtros pode ser encontrada em Lopes et al. (1990). Na prática, estes filtros podem amenizar a textura e com isso eliminar informação. Dois alvos na imagem com médias tonais semelhantes mas com texturas diferentes podem, após a filtragem, tornar-se muito semelhantes e com isso não serem mais distinguíveis. O número de *pixels* de uma determinada classe pode influir no desempenho destes filtros. Áreas menores tendem a apresentar maiores problemas em suas descontinuidades. De modo geral, a filtragem causa uma transformação dos níveis de cinza, fazendo com que sua distribuição se aproxime mais da normal e com isso, conseguem aumentar o desempenho de classificadores pontuais de máxima verossimilhança (Dobson et al, 1995).

Ao contrário dos classificadores pontuais, os contextuais promovem a classificação baseando-se não somente na informação de um *pixel* mas também a de seus vizinhos na imagem. Dentre estes classificadores estão os que utilizam estatísticas de 2ª ordem que trazem informação sobre a variação do nível de cinza dentro de uma região da imagem, ou seja, da textura. O uso da informação textural no processo de classificação será abordado na Seção 4.3.

CAPÍTULO 4

MEDIDAS DE 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., 1986; Marceau et al., 1989).

Apesar das dificuldades, muitos autores têm tentado quantificar a textura. Métodos de análise de textura têm sido desenvolvidos usando-se padrões de frequência (Chen, 1990), estatísticas de primeira ordem (Hsu, 1978; Irons e Petersen, 1981) e estatísticas de segunda ordem (Haralick et al., 1973; Welch et al., 1990).

4.1 - Medidas de Textura Baseadas em Estatísticas de Primeira Ordem

Alguns métodos utilizados para caracterizar a textura de imagens baseiam-se em parâmetros estatísticos de primeira ordem, ou seja, que não levam em consideração a distribuição espacial dos níveis de cinza de uma região da imagem.

As medidas mais comumente utilizadas são:

a) variância

$$V = \sum_i [i - M]^2 P(i), \quad (4.1)$$

onde $P(i)$ é a frequência com que o nível de cinza i ocorre na imagem e M é a média dos níveis de cinza da imagem, ou seja,

$$M = \sum_i iP(i) \quad (4.2)$$

b) coeficiente de variação

$$CV = \frac{\sqrt{V}}{M} \quad (4.3)$$

c) assimetria

$$AS = \frac{\sum (i - M)^3 P(i)}{V^{\frac{3}{2}}} \quad (4.4)$$

d) assimetria da média em relação à mediana

$$ASM = \frac{|M - MED|}{\sqrt{V}} \quad (4.5)$$

onde MED é a mediana dos níveis de cinza da imagem.

e) curtose

$$CUR = \frac{\sum (i - M)^4 P(i)}{V^2} \quad (4.6)$$

Estas medidas de textura, assim como as baseadas em estatísticas de segunda ordem, não são específicas para imagens de radar, uma vez que não consideram nenhum modelo matemático que explique a variação encontrada na imagem. Yanasse et al. (1993), estudando as propriedades estatísticas de imagens SAR, testaram diversas distribuições (K amplitude *multilook*, gamma, raiz da gamma, log-normal, entre outras) para determinar aquelas para as quais seus dados mostraram melhor ajuste. Analisando as estimativas dos parâmetros de algumas distribuições, concluíram que estas poderiam ser utilizadas para discriminar áreas de floresta e não floresta. Particularmente, o parâmetro α da distribuição K amplitude *multilook* parece expressar a variação de textura entre estas duas classes e desta forma pode também ser usado como uma medida de textura. Altos valores de α são indicativos de homogeneidade. Um estimador para o parâmetro α pode ser encontrado nas seções 3.2.1.3 e 3.2.2.3.

4.2 - Medidas de Textura Baseadas em Estatísticas de Segunda Ordem

O método mais comumente utilizado, proposto por Haralick et al. (1973), baseia-se no uso de estatísticas derivadas a partir da matriz de co-ocorrência dos níveis de cinza de uma imagem. Cada elemento $P(i, j)_{\Delta x, \Delta y}$ da matriz de co-ocorrência representa a frequência com que dois *pixels* vizinhos (separados por uma distância de Δx colunas e Δy linhas) ocorrem na imagem, um com o nível de cinza i e o outro com o nível de cinza j .

A principal desvantagem no uso de medidas texturais baseadas na matriz de co-ocorrência é a grande exigência em memória e tempo computacional. Por exemplo, numa imagem de 8 *bits* (256 níveis de cinza), a matriz de co-ocorrência é composta por 65536 elementos, muitos deles com valor nulo. Como alternativa, pode-se trabalhar com vetores soma e diferença de níveis de cinza (Weszka et al., 1976; Unser, 1986; Welch et al., 1990). Cada elemento do vetor soma é definido como

$$P^S(k)_{\Delta x, \Delta y} = \sum_i \sum_j P(i, j)_{\Delta x, \Delta y} \quad \forall \quad i + j = k, \quad (4.7)$$

enquanto que o elemento do vetor diferença é definido como

$$P^D(k)_{\Delta x, \Delta y} = \sum_i \sum_j P(i, j)_{\Delta x, \Delta y} \quad \forall \quad |i - j| = k. \quad (4.8)$$

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 e nos vetores soma e diferença de níveis de cinza.

a) uniformidade (energia)

$$UNI_{\Delta x, \Delta y} = \sum_i \sum_j P(i, j)_{\Delta x, \Delta y}^2 \quad (4.9)$$

b) entropia

$$ENT_{\Delta x, \Delta y} = - \sum_i \sum_j P(i, j)_{\Delta x, \Delta y} \log P(i, j)_{\Delta x, \Delta y} \quad (4.10)$$

c) contraste

$$CON_{\Delta x, \Delta y} = \sum_i \sum_j (i - j)^2 P(i, j)_{\Delta x, \Delta y} \quad (4.11)$$

d) homogeneidade

$$HOM_{\Delta x, \Delta y} = \sum_i \sum_j \frac{P(i, j)_{\Delta x, \Delta y}}{1 + (i - j)^2} \quad (4.12)$$

e) correlação

$$COR_{\Delta x, \Delta y} = \frac{\sum_i \sum_j ij P(i, j)_{\Delta x, \Delta y} - \mu_l \mu_c}{\sigma_l \sigma_c} \quad (4.13)$$

onde

$$\mu_l = \sum_i iP(i, *)_{\Delta x, \Delta y}, \quad (4.14)$$

$$\mu_c = \sum_j jP(*, j)_{\Delta x, \Delta y}, \quad (4.15)$$

$$\sigma_l = \sqrt{\sum_i (i - \mu_l)^2 P(i, *)_{\Delta x, \Delta y}}, \quad (4.16)$$

$$\sigma_c = \sqrt{\sum_j (j - \mu_c)^2 P(*, j)_{\Delta x, \Delta y}}, \quad (4.17)$$

$$P(i, *)_{\Delta x, \Delta y} = \sum_j P(i, j)_{\Delta x, \Delta y} \quad (4.18)$$

e

$$P(*, j)_{\Delta x, \Delta y} = \sum_i P(i, j)_{\Delta x, \Delta y} \quad (4.19)$$

f) chi-quadrado

$$CHI_{\Delta x, \Delta y} = \sum_i \sum_j \frac{P(i, j)_{\Delta x, \Delta y}^2}{P(i, *)_{\Delta x, \Delta y} P(*, j)_{\Delta x, \Delta y}} \quad (4.20)$$

g) média do vetor soma

$$MS_{\Delta x, \Delta y} = \sum_k k P^S(k)_{\Delta x, \Delta y} \quad (4.21)$$

h) variância do vetor soma

$$VS_{\Delta x, \Delta y} = \sum_k (k - MS_{\Delta x, \Delta y})^2 P^S(k)_{\Delta x, \Delta y} \quad (4.22)$$

i) uniformidade do vetor soma

$$UNIS_{\Delta x, \Delta y} = \sum_k P^S(k)_{\Delta x, \Delta y}^2 \quad (4.23)$$

j) entropia do vetor soma

$$ENTS_{\Delta x, \Delta y} = - \sum_k P^S(k)_{\Delta x, \Delta y} \log P^S(k)_{\Delta x, \Delta y} \quad (4.24)$$

l) média do vetor diferença

$$MD_{\Delta x, \Delta y} = \sum_k k P^D(k)_{\Delta x, \Delta y} \quad (4.25)$$

m) variância do vetor diferença

$$VD_{\Delta x, \Delta y} = \sum_k (k - MD_{\Delta x, \Delta y})^2 P^D(k)_{\Delta x, \Delta y} \quad (4.26)$$

n) uniformidade do vetor diferença

$$UNID_{\Delta x, \Delta y} = \sum_k P^D(k)_{\Delta x, \Delta y}^2 \quad (4.27)$$

o) entropia do vetor diferença

$$ENTD_{\Delta x, \Delta y} = - \sum_k P^D(k)_{\Delta x, \Delta y} \log P^D(k)_{\Delta x, \Delta y} \quad (4.28)$$

Outra medida de 2ª ordem que reflete, de certo modo, a textura de uma imagem é a autocorrelação espacial que indica a relação espacial existente entre os *pixels* desta imagem. Há um valor de autocorrelação para cada relação de vizinhança, sendo definida por uma distância em linhas e outra em colunas. Usualmente, estas distâncias são referidas como *lags*, ou seja, cada autocorrelação espacial é definida considerando um determinado *lag*. Por exemplo, a autocorrelação de *lag* 2,-1 é calculada através da correlação existente entre cada *pixel* da imagem e o seu vizinho localizado 2 *pixels* à direita e 1 *pixel* acima. A autocorrelação espacial é definida como

$$AUT_{li,lj} = \frac{\sum_{i=1}^{ni-li} \sum_{j=1}^{nj-lj} (x_{i,j} - \bar{x})(x_{i+li,j+lj} - \bar{x})}{\sum_{i=1}^{ni} \sum_{j=1}^{nj} (x_{i,j} - \bar{x})^2} \quad (4.29)$$

onde li e lj são os *lags* em coluna e linha respectivamente; n_i e n_j são o número de colunas e linhas, $x_{i,j}$ é o nível de cinza do *pixel* localizado na i -ésima coluna e j -ésima linha e \bar{x} é o nível de cinza médio.

4.3 - Utilização de Medidas de Textura na Classificação de Imagens de Radar

Devido a ausência de uma definição matemática precisa da textura, e a existência de um grande número de medidas que procuram, de certa forma, descrever as propriedades texturais de um alvo, grande parte destes trabalhos buscam a melhor combinação destas medidas a fim de maximizar o resultado da classificação. Dentro deste contexto, Ulaby et al. (1986), utilizando imagens Seasat (banda L) de 16 *looks*, selecionaram duas medidas de Haralick, contraste e homogeneidade, que melhor separaram as classes de uso estudadas. Em seguida, amostras de cinco classes de uso foram classificadas usando-se algoritmo de máxima verossimilhança. Os melhores resultados foram conseguidos com o uso simultâneo dos parâmetros contraste e homogeneidade. Os mesmos autores, procurando discriminar 5 tipos de florestas a partir de imagens SIR-A de 24 *looks*, conseguiram classificações com precisão total superior a 90% quando a média e o contraste foram utilizados. Neste trabalho, eles observaram que uma das classes de floresta (mata de galeria) apresentou melhor taxa de acerto quando a informação textural foi utilizada, sendo que pela média tonal, esta classe se confundia muito com as demais.

Briand e Gray (1989) mostraram que medidas de textura de primeira ordem podem ser utilizadas para melhorar a identificação de classes de uso em imagens SAR. Quando somente a informação tonal foi utilizada, a precisão total foi de 60%, subindo para 85% quando se utilizou também a informação textural.

Luckman et al. (1994), utilizando imagens SAR na banda C, verificaram que o sinal retroespalhado (em intensidade) era praticamente o mesmo para floresta virgem e para diferentes classes de regeneração, havendo, no entanto, uma diferença significativa na textura entre estas classes.

CAPÍTULO 5

MATERIAL E MÉTODOS

5.1 - Descrição da Área de Estudo

A área de estudo (Figura 5.1) compreende o Projeto de Irrigação de Bebedouro (PIB) localizado na região do Sub-médio São Francisco (9°07'S, 40°18'WGr), a aproximadamente 40 km à nordeste do município de Petrolina, estado de Pernambuco.

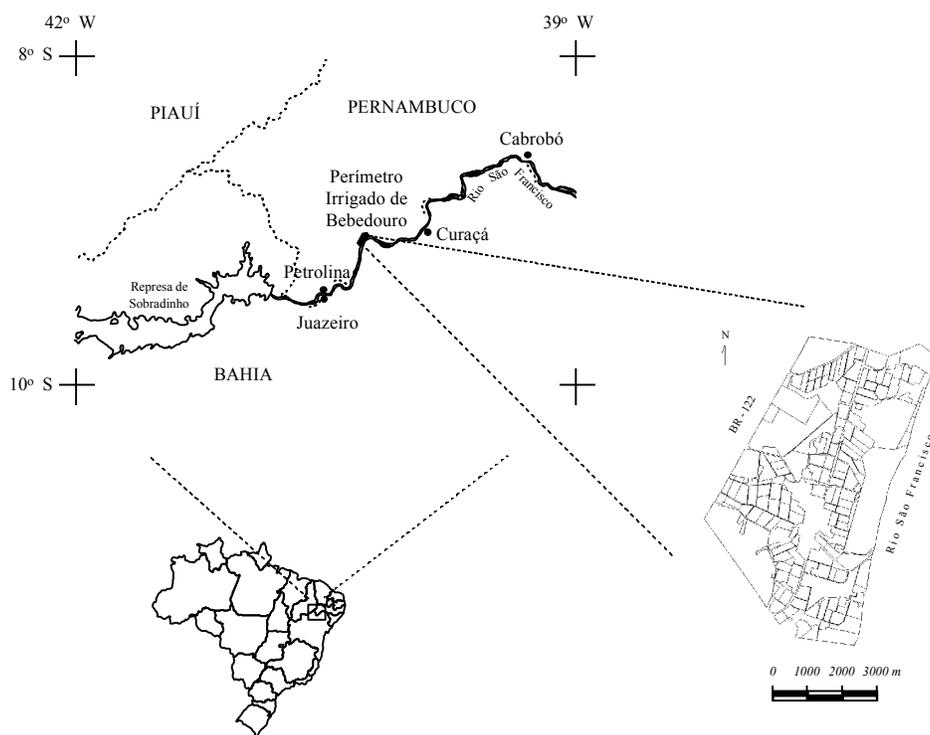


FIGURA 5.1 - Localização da área de estudo.

O PIB está dividido em 2 partes, denominadas PIB I e PIB II, com área total aproximada de 3500 ha e 2000 ha, respectivamente. O PIB I é formado por pequenas propriedades de 5 a 12 ha, áreas maiores destinadas a pequenas empresas privadas, áreas de reserva de vegetação natural e pequenos núcleos habitacionais. O PIB II possui uma área destinada a empresas privadas e outra destinada ao Serviço de Produção de Sementes Básicas (SPSB) da EMBRAPA.

O PIB constitui um mosaico de culturas agrícolas anuais e perenes particularmente interessante para o estudo de discriminação agrícola. Conta com uma assistência técnica fornecida pela EMBRAPA que mantém um campo experimental dentro do PIB. Além disso, a EMBRAPA possui um centro de pesquisa (CPATSA - Centro de Pesquisa Agropecuária do Trópico Semi-Árido) próximo ao PIB.

5.1.1 - Aspectos Climatológicos Regionais

O clima da região, pela classificação de Köppen, é denominado Bswb. O clima é semi-árido com precipitação total anual de 350 a 950 mm. O regime pluviométrico caracteriza-se por precipitações irregulares tanto no decorrer dos anos quanto durante o ano (Tabela 5.1). A temperatura média mensal varia de 25,4° a 28,1° (Projeto RADAMBRASIL, 1983; Amorim Neto, 1989).

TABELA 5.1 - Dados pluviométricos do PIB.

Coordenadas geográficas: 09°09'S, 40°22'WGr.

Altitude: 365,5 m.

Dados médios referentes aos anos de 1963 a 1984.

	Jan	Fev	Mar	Abr	Mai	Jun	
Média	65,0	96,5	140,4	100,4	18,6	9,7	
Máxima	188,4	315,8	340,3	270,7	103,9	47,4	
Mínima	10,4	4,6	8,5	0,8	0,0	0,0	
	Jul	Ago	Set	Out	Nov	Dez	Total
Média	7,5	6,7	8,4	10,7	50,6	72,3	578,1
Máxima	58,2	27,2	29,0	50,5	128,0	257,2	951,4
Mínima	1,0	0,0	0,0	0,0	0,0	0,4	341,0

FONTE: Amorim Neto (1989), p. 25.

O período chuvoso corresponde aos meses de verão, entre novembro e abril quando são registradas chuvas que dificilmente ultrapassam os 150 mm mensais. O período de seca quase sempre ultrapassa os 6 meses (maio a outubro).

5.1.2 - Aspectos Pedológicos

Às margens do rio São Francisco, encontram-se solos aluviais geralmente mal drenados, argilosos ou argilo-arenosos. O solo predominante na parte mais elevada do terreno é do tipo Latossolo Vermelho Amarelo com fertilidade natural baixa, possuindo a camada sub-superficial muito ácida (FAO, 1966; Pereira e Souza, 1967).

Sobre o embasamento metamórfico sobrepõe-se um depósito ferralítico constituído de seixos rolados e sub-angulares e concreções ferruginosas. A espessura desta camada varia de alguns centímetros até vários metros. Em algumas áreas há o afloramento deste depósito, que, por serem impróprias à exploração agrícolas, são destinadas às reservas de vegetação natural do tipo caatinga arbórea-arbustiva (FAO, 1966; Pereira e Souza, 1967).

O relevo regional varia de plano a suave ondulado, com declives de 2% a 5%.

5.1.3 - Infraestrutura

O principal sistema de irrigação utilizado no PIB I é a irrigação por gravidade (sulcos de infiltração). Através de uma estação de bombeamento situada às margens do rio São Francisco, a água é captada e lançada na rede de distribuição formada por canais revestidos de concreto. Também conta com um sistema de drenos abertos responsáveis pelo escoamento do excesso de água das propriedades. O PIB I possui uma área irrigada de 1750 ha (CODEVASF, 1991).

Devido a problemas com o uso excessivo e manejo inadequado da irrigação, iniciou-se um processo de salinização dos solos de algumas propriedades (Valdivieco-Salazar e Cordeiro, 1985), inviabilizando a agricultura em algumas áreas. A fim de reverter o problema, alguns proprietários implantaram uma rede de drenos abertos e subterrâneos.

A adução de água ao PIB II é feita por meio de um aqueduto que se liga ao canal principal do sistema de irrigação do PIB I (CODEVASF, 1982). Parte desta água é destinada para irrigação de dois pivôs centrais do SPSB. Outros dois pivôs centrais

encontrados no SPSB possuem adutoras próprias. A área irrigada pelo sistema de pivô central totaliza 360 ha.

5.1.4 - Uso da Terra

As principais culturas (em termos de área cultivada) exploradas no PIB I são a uva, a melancia, o melão, o tomate industrial e o feijão. Outras culturas podem ser encontradas: manga, goiaba, acerola, coco, cebola, mandioca, sorgo, etc.

Nas áreas não irrigadas (áreas de sequeiro), predomina a exploração pecuária (bovinos, caprinos e ovinos). Também as áreas de pousio são utilizadas como pastagem.

Dentre as culturas, a que mais se destaca é a uva. O sistema de cultivo mais utilizado é o tipo latada: moirões sustentam uma malha de arame a cerca de 1,80 m de altura, onde são conduzidos os ramos da videira. As cultivares mais difundidas na região são a “Itália” e a “Piratininga”, que destinam-se ao consumo *in natura* (Albuquerque e Albuquerque, 1987). A videira, em clima tropical semi-árido, apresenta um comportamento totalmente distinto daquele apresentado nas regiões tradicionais de cultivo, tendo seu ciclo fenológico condicionado ao controle da irrigação e época de poda, possibilitando a produção de uvas em qualquer época do ano (Albuquerque e Albuquerque, 1981). Com a poda seletiva do parreiral, quando apenas algumas linhas são podadas, o colono pode planejar colheitas com intervalo de até uma semana.

A fim de aumentar o aproveitamento do solo, da água e do fertilizante, alguns agricultores utilizam o consorciamento, principalmente em áreas onde se cultivam frutíferas perenes ainda novas. Os consorciamentos mais comuns são: manga/melão, manga/melancia, uva/feijão, uva/cebola, acerola/feijão e acerola/melancia.

Os quatro pivôs centrais do SPSB, localizados no PIB II, são destinados à produção de sementes, entre elas, de milho, soja, sorgo e gramíneas forrageiras.

5.2 - Imagens

Neste trabalho estão sendo analisadas as imagens referentes a 2 passagens do SIR-C obtidas durante o primeiro experimento (abril de 1994). Os produtos GR1 e GR2 são compostos por imagens *ground range* e o produto SR é composto por imagens *slant range*. É importante observar que as imagens GR2 e SR possuem características muito semelhantes sendo o GR2 obtido a partir do SR, após processamento *multilook* e transformação para o formato *ground range*. A utilização destes 3 conjuntos de imagens permite fazer um estudo comparativo do desempenho de cada um destes com relação à discriminação de classes de uso, podendo-se, talvez, indicar aquele que mais se adequa a este tipo de estudo.

O processamento das imagens foi realizado pelo JPL. Todas as imagens foram calibradas radiometricamente para compensar desvios ou mudanças na potência transmitida, ganho do receptor, apontamento da antena, etc. As imagens foram recebidas num formato compactado em fitas *exabyte*.

Após a leitura das fitas, através de um programa específico (“CEOS Tape Reader”), procedeu-se o processamento *multilook* da imagem SR de forma a reduzir o *speckle* e obter elementos de resolução correspondentes a cada *pixel* da imagem mais ou menos quadrados. Com o uso do programa “byte_image” fez-se a descompactação produzindo imagens amplitude discretizadas em 256 níveis de cinza (8 *bits*) nas polarizações HH, HV e VV. É importante ressaltar que, devido ao processamento dos dados, não houveram diferenças entre as polarizações HV e VH, e portanto apenas uma destas foi analisada. Para maiores detalhes sobre a descompactação das imagens SIR-C veja o Apêndice B. A Tabela 5.2 resume as principais características dos produtos analisados nesta pesquisa.

TABELA 5.2 - Características dos produtos SAR.

	GR1	GR2	SR
Data de aquisição	09/04/94	13/04/94	13/04/94
Banda	L (1,254 Ghz) C (5,304 GHz)	L (1,254 Ghz) C (5,304 GHz)	L (1,254 Ghz) C (5,304 GHz)
Tipo do produto	<i>Multilook Complex</i>	<i>Multilook Complex</i>	<i>Single-Look Complex</i>
Número de <i>looks</i> *	4,14	4,06	1,81
Projeção	<i>Ground Range</i>	<i>Ground Range</i>	<i>Slant Range</i>
Âng. de incid. (centro)	47,77°	37,97°	37,98°
Espaçamento na linha	12,5 m	12,5 m	12,6 m
Espaçamento na coluna	12,5 m	12,5 m	13,3 m
Polarizações	HH, HV e VV	HH, HV e VV	HH, HV e VV
Altitude da plataforma	220,4 km	219,4 km	219,4 km
Direção da órbita	descendente	descendente	descendente

* valores estimados a partir da Equação 3.56

5.3 - Trabalho de Campo

Simultaneamente ao imageamento feito pelo SIR-C/X-SAR em abril de 1994, foi realizado um trabalho de campo visando o levantamento do uso da terra, utilizado como verdade terrestre.

Neste trabalho de campo, realizado no período de 6 a 16/04/94, fez-se a caracterização agrônômica em pelo menos 70% da área das propriedades do PIB.

Uma legenda foi definida levando-se em consideração a área, a distribuição e a importância de cada classe de uso. Dessa forma, foram definidas 7 classes de uso: uva, melão/melancia, tomate, solo preparado, pasto limpo, pasto sujo/pousio e manga.

Para cada propriedade, foi obtido um *overlay* (tendo o mapa topográfico do PIB como base). Cada classe de uso existente foi delimitada e descrita segundo os itens: altura de planta, espaçamento, orientação das linhas de cultura, estágio fenológico e tipo de substrato.

Dados meteorológicos de rotina (temperatura do ar, precipitação pluviométrica, umidade do ar, etc.), referentes à época do experimento, foram adquiridos na estação meteorológica localizada no próprio PIB.

5.4 - Extração das Amostras e Cálculo dos Parâmetros Estatísticos

Os *overlays* de campo foram digitalizados e registrados às imagens de radar. Note que, neste trabalho, os vetores que descrevem cada polígono de cada classe de uso é que foram registrados à imagem e não o contrário, como o usual. Este procedimento foi adotado a fim de manter as características originais da imagem, uma vez que, no processo de registro, a imagem sofre uma reamostragem, o que resultaria na mudança dos níveis de cinza originais da imagem.

Diversas rotinas foram desenvolvidas em “IDL⁶” para realizar a extração dos níveis de cinza e cálculo dos parâmetros estatísticos das amostras. Cada imagem foi lida e os polígonos que representam as amostras de cada uma das classes de uso foram extraídos. Para cada polígono, calculou-se a matriz de co-ocorrência e os vetores soma e diferença (ver seção 4.2), considerando uma vizinhança de 1 *pixel*, ou seja, o nível de cinza de um determinado *pixel* foi comparado com os níveis de cinza dos 8 *pixels* vizinhos mais próximos. Em seguida, foram calculadas as medidas de textura de primeira e segunda ordem encontradas nas seções 4.1 e 4.2. A autocorrelação espacial foi calculada considerando-se 3 *lags* (0,1; 1,0 e 1,1). O parâmetro α foi estimado por dois métodos: um utilizando o primeiro e segundo momentos amostrais da amplitude (equação (3.52a)), e outro utilizando o segundo e quarto momentos amostrais da amplitude (equação (3.32)). Foi calculada também a média dos níveis de cinza de cada polígono. Dessa forma, foram extraídas 25 medidas para cada imagem (14 medidas de Haralick, 3 autocorrelações espaciais, 5 medidas baseadas em estatísticas de 1^a ordem, 2 estimadores de α , e a média), totalizando 150 medidas por produto (25 medidas, 2 bandas, 3 polarizações).

⁶IDL, *Interactive Data Language*, software de análise interativa de dados com funções matemáticas e estatísticas.

5.5 - Avaliação do Desempenho das Medidas Texturais na Discriminação de Alvos

A utilização de todas as medidas texturais na caracterização de um alvo é impraticável e desnecessária uma vez que a demanda computacional para a extração destas informações seria extremamente elevada e, devido à alta correlação existente entre várias destas medidas, haveria muita informação redundante que poderia ser descartada.

Assim, faz-se necessário a adoção de um critério para a seleção das melhores medidas texturais, ou seja, aquelas que melhor discriminem os alvos de interesse. Esta seleção deve basear-se em estimativas tomadas a partir de amostras. Dessa forma, os estimadores das medidas texturais passam a comportar-se como variáveis com uma determinada distribuição, quase sempre desconhecida. As estimativas de cada medida podem então ser agrupadas de acordo com o alvo que representam. Algumas destas variáveis podem apresentar maior variação entre classes do que dentro das classes e portanto a seleção destas variáveis deve promover uma melhor discriminação entre as classes consideradas. No entanto, o descarte de variáveis torna-se muito complexo quando existe uma alta correlação entre as mesmas, de forma que a inclusão ou exclusão de uma variável determina o poder de discriminação de uma outra variável (Fatti et al., 1982). Esta complexidade pode ser ainda maior se o descarte de variáveis envolver a discriminação de muitas classes ou populações, uma vez que há um conjunto de variáveis que maximiza a discriminação entre cada par de grupos.

O desempenho de um conjunto de variáveis pode ser avaliado, por exemplo, através da classificação de amostras. Um conjunto ótimo de variáveis seria aquele que classificasse todas as amostras corretamente. Quando a forma da distribuição das variáveis é conhecida e seus parâmetros estimados, regras baseadas na teoria Bayesiana podem ser empregadas na classificação das amostras e conseqüente avaliação do desempenho das variáveis envolvidas. De uma maneira geral, a regra de decisão de um classificador baseia-se na probabilidade de uma dada amostra pertencer a uma determinada classe: a amostra será atribuída à classe cuja probabilidade de acerto é maior ou a probabilidade de erro é menor. Quando a forma da distribuição das variáveis é desconhecida, ainda assim, é possível proceder à classificação considerando algum critério de similaridade.

Comumente empregam-se medidas de divergência (distâncias) ou de similaridade no processo de separação das amostras em grupos (*clusters*).

Entre as diversas medidas de distância encontradas na literatura, a de uso mais geral (por não considerar qualquer forma específica para a distribuição das variáveis) é a distância euclidiana, que avalia as diferenças quadráticas entre dois pontos. Considerando K variáveis, a distância euclidiana entre os pontos \mathbf{x}_i e $\bar{\mathbf{x}}$ é dada por

$$d_i^2 = (\mathbf{x}_i - \bar{\mathbf{x}})'(\mathbf{x}_i - \bar{\mathbf{x}}). \quad (5.1)$$

Note que \mathbf{x}_i e $\bar{\mathbf{x}}$ representam grandezas vetoriais com dimensão K .

Conhecendo-se apenas as médias de cada classe, procede-se a classificação das amostras, atribuindo a amostra à classe (ou grupo) cuja média mais se aproxima do ponto avaliado, ou seja, a que possui a menor distância euclidiana. O sucesso da classificação depende, é claro, do conjunto de variáveis escolhidas. Assim, o problema resume-se em encontrar o conjunto de variáveis que resulte numa melhor classificação. Se de um conjunto inicial de K variáveis deseja-se escolher um subconjunto de K' variáveis ($K' \leq K$), pode-se avaliar o desempenho de cada possível combinação e escolher aquela cuja classificação resulte no maior número de pontos corretamente classificados.

Quando as variáveis distribuição gaussiana, pode-se utilizar a distância de Mahalanobis ao invés da euclidiana. A distância de Mahalanobis entre os pontos \mathbf{x}_i e $\bar{\mathbf{x}}$ é dada por

$$D_i^2 = (\mathbf{x}_i - \bar{\mathbf{x}})' \mathbf{S}^{-1} (\mathbf{x}_i - \bar{\mathbf{x}}), \quad (5.2)$$

onde \mathbf{S} é a matriz de covariância de \mathbf{x} ,

$$\mathbf{S} = (\mathbf{x} - \bar{\mathbf{x}})(\mathbf{x} - \bar{\mathbf{x}})'. \quad (5.3)$$

O uso da distância de Mahalanobis na classificação normalmente traz melhores resultados pois esta avalia não somente a média, como a distância euclidiana, mas também a variância e a covariância entre as variáveis envolvidas.

Caso se conheça a verdadeira classe a que pertence cada amostra, pode-se construir uma matriz que relaciona as classes às quais foram atribuídas as amostras com a verdadeira classe a que pertence cada amostra. Esta matriz é conhecida como matriz de confusão ou matriz de erro. A Tabela 5.3 mostra, esquematicamente, uma matriz de confusão. Cada elemento x_{ij} representa o número de amostras que sendo verdadeiramente da classe i foram, após a classificação, atribuídas à classe j . O total marginal x_{i+} indica o número de amostras da classe i , e x_{+j} o número total de amostras que foram atribuídas à classe j . Os elementos da diagonal representam as amostras corretamente classificadas.

TABELA 5.3 - Matriz de confusão

		Classificação				
		1	2	...	c	Total
V e r d a d e	1	x_{11}	x_{12}	...	x_{1c}	x_{1+}
	2	x_{21}	x_{22}			x_{2+}
	⋮	⋮		⋱		⋮
	c	x_{c1}			x_{cc}	x_{c+}
	Total	x_{+1}	x_{+2}	...	x_{+c}	N

Usualmente, uma classificação é avaliada pela proporção de amostras corretamente classificadas, denominada precisão total, que corresponde à razão entre a soma da diagonal da matriz de confusão (amostras corretamente classificadas) e a soma de todos os elementos desta matriz (número total de amostras). Como alternativa, pode-se avaliar uma classificação através do coeficiente kappa (Rosenfield e Fitzpatrick-Lins, 1986; Hudson e Ramm, 1987; Foody, 1992). Este coeficiente tem a vantagem de levar em consideração todos os elementos da matriz de confusão e não somente os elementos da diagonal. Este coeficiente supõe que parte do acerto total poderia ser devido ao acaso e portanto o coeficiente kappa estima a proporção de acerto que efetivamente ocorre. Um estimador para o kappa é dado a seguir:

$$\hat{\kappa} = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad (5.4)$$

onde

$$\theta_1 = \sum_{i=1}^c x_{ii} / N \quad (5.5)$$

e

$$\theta_2 = \sum_{i=1}^c x_{i+} x_{+i} / N^2. \quad (5.6)$$

O kappa assume valores menores ou iguais a 1, podendo inclusive assumir valores negativos. Quando todas as amostras são corretamente classificadas, ou seja, todos os elementos da matriz de confusão fora da diagonal possuem valor nulo, o coeficiente kappa possui valor 1. Valores de kappa pequenos indicam que a classificação não obteve bons resultados (Landis e Koch, 1977).

A variância do kappa pode ser estimada por

$$VAR_{\hat{\kappa}} = \frac{1}{N} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (5.7)$$

onde

$$\theta_3 = \sum_{i=1}^c x_{ii}(x_{i+} + x_{+i}) / N^2 \quad (5.8)$$

e

$$\theta_4 = \sum_{i=1}^c \sum_{j=1}^c x_{ij}(x_{j+} + x_{+i}) / N^3. \quad (5.9)$$

O conhecimento da variância do kappa e a suposição de normalidade permitem que comparações entre diferentes coeficientes kappa possam ser feitas.

5.5.1 - Seleção das Medidas de Textura

Devido os produtos GR1, GR2 e SR não serem co-registrados, fez-se uma análise e seleção de medidas para cada um destes produtos separadamente. Dessa forma, o procedimento é descrito apenas uma vez mas é válido para qualquer um dos 3 produtos utilizados.

Cada produto é composto por 6 imagens: 2 bandas e 3 polarizações. Para cada imagem, foram determinadas 25 medidas (14 medidas de Haralick, 3 autocorrelações espaciais, 5 medidas baseadas em estatísticas de 1ª ordem, 2 estimadores de α , e a média), resultando em 150 variáveis para cada conjunto de imagens analisado. Como as variáveis apresentam diferentes grandezas, procedeu-se à padronização das mesmas, ou seja, para cada valor foi subtraída a média e o resultado dividido pelo desvio padrão. Desta forma, todas as variáveis passaram a possuir média nula e variância unitária.

Considerando um número fixo de variáveis a ser selecionado, o método ideal de seleção deveria testar todas as possíveis combinações entre as 150 variáveis analisadas. Por exemplo, para se selecionar o melhor conjunto de 10 variáveis, deveriam ser testadas mais de 1×10^{15} combinações, o que seria totalmente inviável e ainda assim, não garantiria que a combinação selecionada tivesse um valor de kappa mínimo aceitável. Dessa forma, buscou-se métodos alternativos que testassem um menor número de combinações.

No primeiro método, o poder discriminante de cada variável foi inicialmente determinado adotando-se o coeficiente kappa obtido a partir da classificação das amostras de acordo com cada variável. A variável com maior kappa individual foi a primeira a ser selecionada. Em seguida, buscou-se, entre as 149 restantes, a variável que juntamente com a primeira selecionada apresentou maior kappa. Selecionadas as duas variáveis, procurou-se entre as demais, a que, juntamente com as duas primeiras, apresentou maior kappa. Este processo foi repetido até que um coeficiente kappa igual ou superior a 0,90 foi encontrado. É importante salientar que após a introdução de uma nova variável, combinações entre as já selecionadas eram testadas a fim de verificar se

alguma destas variáveis poderia ser eliminada sem, no entanto, diminuir o valor do kappa.

Pode-se observar que, ainda assim, um grande número de combinações deve ser testado até que se selecione o melhor conjunto de variáveis, sem a garantia de que esta combinação seja a melhor a utilizar.

Como o poder discriminante de uma variável depende do modo como os seus valores se distribuem nas diferentes classes analisadas, é possível supor que variáveis com alta variância entre classes possuam maiores taxas de acerto e portanto maiores valores de kappa. A variância entre classes é definida por

$$VAR_{entre} = \frac{\sum_i n_i (\bar{x}_i - \bar{x})^2}{N}, \quad (5.10)$$

onde \bar{x}_i é a média da variável para a classe i , n_i é o número de amostras que compoem a classe i , \bar{x} é a média geral da variável e N é o número total de amostras. Como todas as variáveis foram padronizadas, a média \bar{x} é nula e portanto a equação (5.10) reduz-se a

$$VAR_{entre} = \frac{\sum_i n_i \bar{x}_i^2}{N}. \quad (5.11)$$

No segundo método, pôde-se promover uma pré-seleção com base na variância entre classes de modo a reduzir o número de variáveis testadas. Numa primeira etapa, ordenaram-se as variáveis de acordo com a variância entre classes apresentada por cada uma delas. A seleção iniciou-se pela variável com maior variância entre classes. A cada variável selecionada, foram reclassificadas as amostras e determinado o coeficiente kappa. A seleção foi encerrada quando um kappa igual a 1 foi obtido. Em seguida, procedeu-se à seleção das variáveis do mesmo modo que para o primeiro método, com a vantagem de não ser necessário testar todas as 150 variáveis.

CAPÍTULO 6

RESULTADOS E DISCUSSÃO

Este capítulo, para uma melhor compreensão, está dividido em duas partes. Na primeira parte, discute-se a relação entre o número de variáveis selecionadas e o desempenho da classificação. Numa segunda etapa, comparam-se os resultados obtidos para os diferentes conjuntos de imagens, procurando destacar as medidas comuns aos 3 produtos. Finalmente, uma análise do desempenho de discriminação das medidas de textura é feita utilizando-se cada imagem separadamente (imagem com 1 frequência e 1 polarização).

Cada produto analisado (GR1, GR2 e SR) é composto por 6 imagens (2 bandas e 3 polarizações). Para cada um dos conjuntos de imagens, foram obtidas 225 amostras (Tabela 6.1) com um mínimo de 20 *pixels* e foram calculadas 25 medidas (14 medidas de Haralick, 3 de autocorrelação espacial, 5 medidas baseadas em estatísticas de 1ª ordem, 2 estimadores de α , e a média), totalizando 150 medidas para cada amostra.

TABELA 6.1 - Número de amostras por classe de uso.

Classe de uso	Nº de amostras
manga	7
melancia	10
tomate	13
pasto limpo	22
solo exposto	34
pasto sujo	48
uva	91
Total	225

Para identificar cada uma das medidas foi adotada a seguinte nomenclatura: uma a cinco letras minúsculas indicam o parâmetro estimado, seguido por uma letra maiúscula identificando a banda (L ou C) e finalmente duas letras maiúsculas que identificam a

polarização da imagem (HH, HV ou VV). Por exemplo, *conLHV* refere-se ao parâmetro contraste calculado a partir de uma imagem na banda L polarização HV. A Tabela 6.2 apresenta a abreviatura adotada para cada medida estudada.

TABELA 6.2 - Abreviaturas das variáveis analisadas.

Abreviatura	Nome da variável
<i>con</i>	contraste
<i>cor</i>	correlação
<i>chi</i>	chiquadrado
<i>ent</i>	entropia
<i>hom</i>	homogeneidade
<i>uni</i>	uniformidade
<i>mvs</i>	média do vetor soma
<i>vvs</i>	variância do vetor soma
<i>univs</i>	uniformidade do vetor soma
<i>entvs</i>	entropia do vetor soma
<i>mvd</i>	média do vetor diferença
<i>vvd</i>	variância do vetor diferença
<i>univd</i>	uniformidade do vetor diferença
<i>entvd</i>	entropia do vetor diferença
<i>aut01</i>	autocorrelação espacial <i>lag</i> 0,1
<i>aut10</i>	autocorrelação espacial <i>lag</i> 1,0
<i>aut11</i>	autocorrelação espacial <i>lag</i> 1,1
<i>v</i>	variância
<i>cv</i>	coeficiente de variação
<i>ass</i>	assimetria
<i>assm</i>	assimetria da média em relação à mediana
<i>cur</i>	curtose
<i>alfaa</i>	alfa estimado pela Equação 3.52a
<i>alfai</i>	alfa estimado pela Equação 3.32
<i>m</i>	média

De todas as medidas, as duas únicas que apresentaram problemas foram os estimadores do parâmetro α (*alfaa* e *alfai*). A medida *alfaa* foi obtida por um processo iterativo que buscava a solução da Equação 3.52a. Primeiramente, foi necessário estimar o número equivalente de *looks* para cada conjunto de imagens, a partir de 30 amostras de áreas homogêneas, usando-se a Equação 3.56. A busca pela solução da Equação 3.52a foi realizada para o intervalo de $0,0001 < \alpha < 1000$. Para várias amostras, não se conseguiu achar esta solução. Isto ocorreu principalmente nos casos em que o coeficiente de

variação era pequeno (áreas homogêneas) e neste caso o parâmetro α assumiria valores muito altos (tendendo a infinito). Dessa forma, adotou-se como solução o valor 150, para o qual observou-se que uma distribuição K amplitude *multilook* tenderia para uma raiz da gamma (distribuição característica de áreas homogêneas de uma imagem amplitude *multilook*). Também alguns valores muito altos foram obtidos (acima de 500), causando uma elevação da variância desta variável. Assim, os valores acima de 150 foram também contabilizados como 150. Já a medida *alfai*, obtida pela Equação 3.32, apresentou, em alguns casos, valores negativos, o que seria, em teoria, impossível, uma vez que o parâmetro α só é definido para valores maiores que zero. Observando a Equação 3.32, pode-se verificar que valores negativos poderiam ser obtidos se fossem observados valores de coeficiente de variação em intensidade menores que $\hat{n}^{-1/2}$. Neste caso, este coeficiente de variação pequeno seria indicativo de áreas homogêneas e portanto esses valores, assim como para a medida *alfaa*, foram redefinidos para 150. Igualmente, valores de *alfai* maiores que 150 foram computados com esse valor.

Em seguida, as variáveis foram padronizadas (média nula e variância unitária) para que se pudesse promover uma análise conjunta das mesmas.

A fim de testar a possibilidade do uso da distância de Mahalanobis na classificação das amostras, foi realizado um teste de normalidade (teste χ^2) para todas as variáveis analisadas. Neste teste, consideraram-se apenas as amostras referentes a 3 classes de uso de maior ocorrência: pasto sujo, solo exposto e uva. A Tabela 6.3 apresenta a relação das variáveis que foram rejeitadas no teste de normalidade em pelo menos duas classes de uso, quando um nível de significância de 0,01 foi considerado. De modo geral, as variáveis *con*, *cor*, *alfaa* e *alfai* foram as que mais se distanciaram de uma distribuição normal e portanto, teoricamente, a distância de Mahalanobis não poderia ser utilizada na classificação destas variáveis.

TABELA 6.3 - Variáveis rejeitadas num teste de normalidade considerando nível de significância de 0,01.

GR1	GR2	GR3
<i>conLHH</i>	<i>conLHH</i>	<i>conLHH</i>
<i>varvsLHH</i>	<i>varvdLHH</i>	<i>alfaaLHH</i>
<i>varvdLHH</i>	<i>alfaaLHH</i>	<i>alfaiLHH</i>
<i>alfaaLHH</i>	<i>alfaiLHH</i>	<i>alfaaLHV</i>
<i>alfaiLHH</i>	<i>alfaaLHV</i>	<i>alfaiLHV</i>
<i>varvdLHV</i>	<i>alfaiLHV</i>	<i>cvLVV</i>
<i>alfaaLHV</i>	<i>corLVV</i>	<i>alfaaLVV</i>
<i>alfaiLHV</i>	<i>alfaaLVV</i>	<i>alfaiLVV</i>
<i>corLVV</i>	<i>alfaiLVV</i>	<i>univsCHH</i>
<i>varvdLVV</i>	<i>alfaaCHH</i>	<i>alfaaCHH</i>
<i>curLVV</i>	<i>alfaiCHH</i>	<i>alfaiCHH</i>
<i>alfaaLVV</i>	<i>corCHV</i>	<i>corCHV</i>
<i>alfaiLVV</i>	<i>curCHV</i>	<i>alfaaCHV</i>
<i>corCHH</i>	<i>alfaaCHV</i>	<i>alfaiCHV</i>
<i>univsCHH</i>	<i>alfaiCHV</i>	<i>univdCVV</i>
<i>alfaaCHH</i>	<i>alfaaCVV</i>	<i>alfaaCVV</i>
<i>alfaiCHH</i>	<i>alfaiCVV</i>	<i>alfaiCVV</i>
<i>corCHV</i>		
<i>alfaaCHV</i>		
<i>alfaiCHV</i>		
<i>corCVV</i>		
<i>alfaaCVV</i>		
<i>alfaiCVV</i>		

Apesar de algumas variáveis não poderem ser consideradas como sendo normalmente distribuídas, adotou-se a distância de Mahalanobis como regra de decisão no processo de classificação, uma vez que testes preliminares indicaram que o uso da distância euclidiana apresentava resultados muito inferiores aos da distância de Mahalanobis.

O próximo passo foi realizar a seleção das variáveis que melhor discriminaram as classes de uso estudadas. Dois métodos foram então testados. O primeiro método selecionou as variáveis de acordo com o coeficiente kappa obtido a partir da classificação das amostras. O segundo método fez uma pré-seleção das variáveis, selecionando aquelas que apresentaram alta variância entre classes. Esta pré-seleção reduziu para cerca de um terço o número de variáveis analisadas (64 para GR1, 55 para

GR2 e 54 para SR). A classificação, considerando todas estas variáveis pré-selecionadas, apresentou kappa igual a 1, o que significa, que todas as amostras foram corretamente classificadas, não havendo confusão entre as classes. A seleção propriamente dita foi feita do mesmo modo que para o primeiro método.

A Figura 6.1 apresenta uma comparação entre os métodos adotados para seleção das variáveis. O desempenho de cada conjunto de variáveis selecionado é avaliado pelo kappa correspondente à classificação das amostras segundo estas variáveis. Ambos os métodos são comparados com o desempenho de classificação quando somente as médias tonais são consideradas. Pode-se notar que, quando um pequeno número de variáveis é selecionado, as médias apresentam bom desempenho. No entanto, como cada conjunto de imagens é composto por apenas 6 imagens, tem-se, no máximo, 6 médias selecionadas (1 média para cada amostra de cada imagem) resultando num kappa máximo de pouco mais que 0,5. Este kappa indica uma classificação cuja precisão pode ser considerada apenas moderada (Landis e Koch, 1977). Quando medidas de textura são avaliadas, pode-se chegar a valores de kappa superiores a 0,90 para os casos em que se consideram mais do que 15 medidas simultaneamente.

Os dois métodos de seleção apresentaram desempenho muito semelhante, com ligeira vantagem para o segundo método nas imagens *slant range* (SR). É importante salientar que as variáveis selecionadas por cada um dos métodos não são necessariamente as mesmas. De acordo com estes resultados, pode-se eleger o segundo método como o melhor uma vez que este compara um número menor de variáveis, sendo cerca de três vezes mais rápido que o primeiro método. A partir daqui, os comentários serão feitos considerando apenas os resultados obtidos pelo método 2.

A Figura 6.2 mostra a relação existente entre a variância entre classes e o kappa de cada uma das variáveis. As linhas verticais indicam o valor mínimo de variância entre classes apresentado pelas variáveis pré-selecionadas. A classificação resultante da utilização de todas as variáveis pré-selecionadas apresenta um kappa igual a 1, o que significa dizer, que todas as amostras foram corretamente classificadas. As variáveis localizadas a esquerda das linhas verticais foram rejeitadas no processo de pré-seleção. Note que

cerca de 2/3 das variáveis foram descartadas. Os maiores valores de kappa e variância entre classes são provenientes de imagens da banda L, mostrando o potencial discriminante desta frequência.

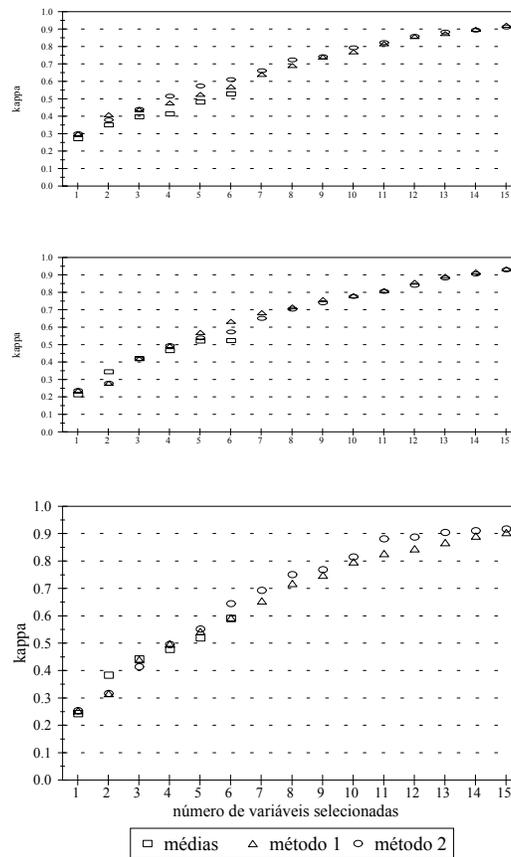


FIGURA 6.1 - Desempenho da classificação medido pelo kappa como função do número de variáveis selecionadas pelos métodos 1 e 2.

Quando apenas as variáveis selecionadas são mostradas (Figura 6.3), pode-se observar que o melhor conjunto de variáveis selecionado pelo método 2 não corresponde às variáveis com maior kappa individual e/ou maior variância entre classes, daí o motivo pelo qual, na fase de pré-seleção, não se deve reduzir muito o número de variáveis.

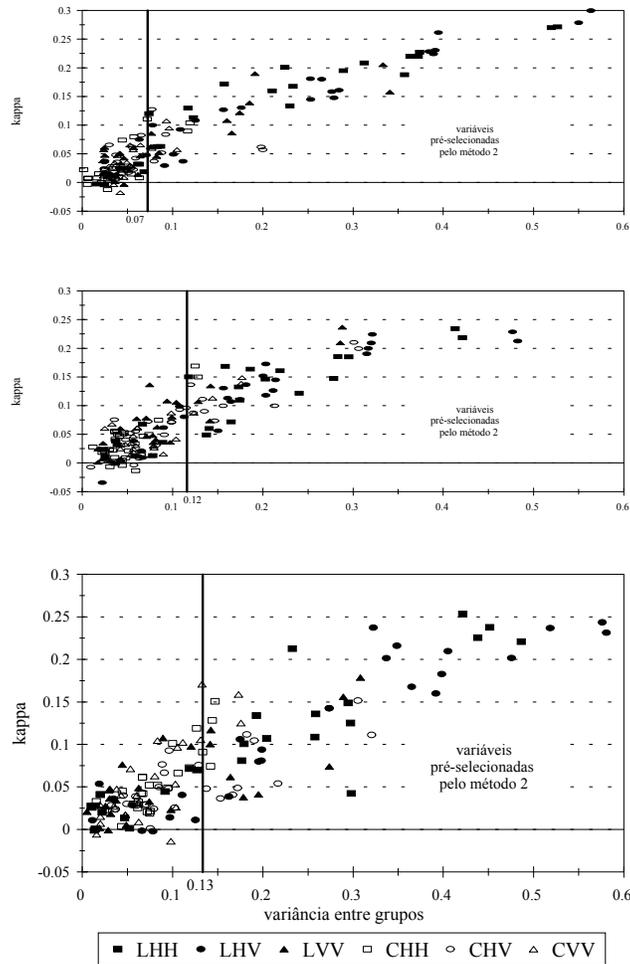


FIGURA 6.2 - Relação entre a variância entre classes e o kappa de cada variável individual.

A Tabela 6.4 apresenta a relação das variáveis selecionadas por produto. Todas as imagens contribuíram com pelo menos 1 variável (com exceção da imagem CVV do produto GR2), sendo que o maior número de variáveis selecionadas corresponderam às imagens da banda L. Para o produto GR1, a maior contribuição textural foi dada pela polarização VV, o mesmo não ocorrendo para os demais produtos, para os quais esta polarização apresentou menor importância. Pode-se observar ainda que, para as classes de uso analisadas, a média tonal foi uma importante medida discriminante uma vez que grande parte das imagens está representada pela média ou por outra medida altamente correlacionada com esta.

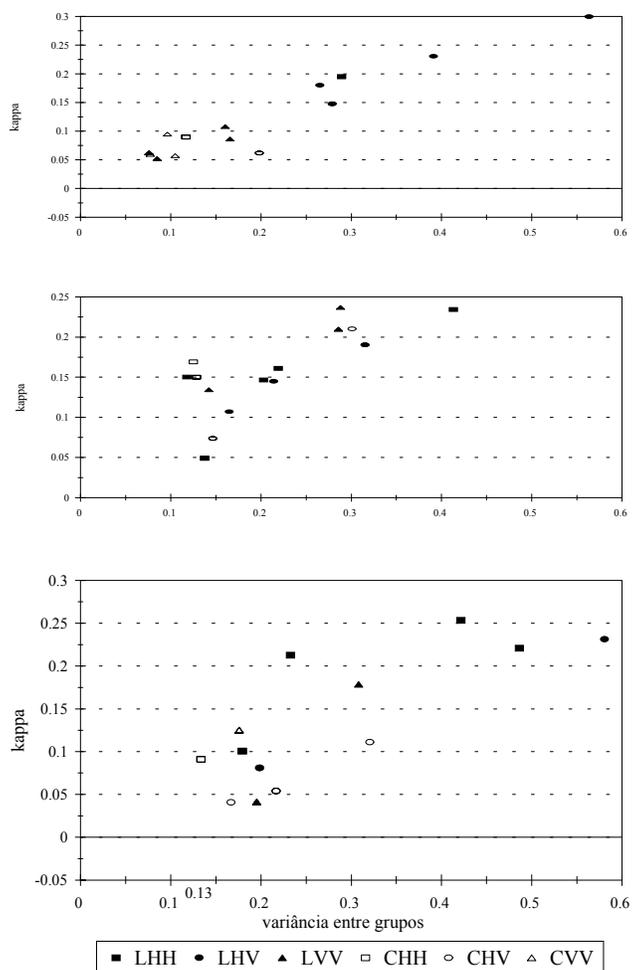


FIGURA 6.3 - Kappa e variância entre classes das variáveis selecionadas pelo método 2.

Cada produto (GR1, GR2 e SR) tem um conjunto distinto de variáveis selecionadas, mas, no entanto, algumas delas altamente correlacionadas (maior que 0,90): *m* e *mvs*, *entvd* e *mvd*, *univd* e *chi*, *con* e *m*, *vvs* e *v*, entre outras. Pode-se observar que algumas variáveis foram selecionadas para diferentes produtos: *chiLHH* em GR1 e GR2, *mCHH* em GR1 e GR2, *mvsCHV* em GR1 e GR2, *mvsCVV* em GR1 e SR, *curLHH* em GR2 e SR, e *mvsLVV* em GR2 e SR. Algumas variáveis, apesar de não terem sido selecionadas em outro produto, possuem alta correlação com outras variáveis: *entvdLHV* com *mvdLHV* em GR1 e GR2, *mLHV* com *conLHV* em GR1 e GR2, *vLHV* com *vvsLHV* de GR1 e GR2, *conLVV* com *mLVV* de GR1 e GR2, *mLHH* com *mvsLHH* de GR2 e SR, *mvsCHV* com *mCHV* de GR2 e SR, entre outras.

TABELA 6.4 - Variáveis selecionadas pelo método 2.

GR1	GR2	SR
<i>chiLHH</i>	<i>corLHH</i>	<i>conLHH</i>
<i>entvsLHV</i>	<i>chiLHH</i>	<i>homLHH</i>
<i>entvdLHV</i>	<i>mLHH</i>	<i>mvsLHH</i>
<i>mLHV</i>	<i>assmLHH</i>	<i>curLHH</i>
<i>vLHV</i>	<i>curLHH</i>	<i>mvsLHV</i>
<i>conLVV</i>	<i>conLHV</i>	<i>assLHV</i>
<i>chiLVV</i>	<i>vvsLHV</i>	<i>mvsLVV</i>
<i>homLVV</i>	<i>mvdLHV</i>	<i>vvdLVV</i>
<i>cvLVV</i>	<i>mvsLVV</i>	<i>vvdCHH</i>
<i>mCHH</i>	<i>univdLVV</i>	<i>univdCHV</i>
<i>mvsCHV</i>	<i>mLVV</i>	<i>mCHV</i>
<i>mvsCVV</i>	<i>mvsCHH</i>	<i>cvCHV</i>
<i>univdCVV</i>	<i>mCHH</i>	<i>mvsCVV</i>
<i>entvdCVV</i>	<i>mvsCHV</i>	
<i>cvCVV</i>	<i>assmCHV</i>	

A fim de verificar se os diferentes conjuntos de variáveis selecionados possuem uma relação implícita, procedeu-se à classificação de cada produto utilizando-se todos os 3 conjuntos de variáveis. É importante salientar que a classificação foi feita com base nas mesmas amostras utilizadas na seleção das variáveis, resultando na superestimação da exatidão da classificação. Por outro lado, quando o conjunto de variáveis selecionado para um produto é utilizado para classificar as amostras de outro produto, fica garantido a independência entre a fase de seleção e a de classificação, e conseqüentemente, as exatidões de classificação tornam-se mais realistas. O resultado desta classificação, apresentado na Tabela 6.5, mostra que, de modo geral, um conjunto de variáveis selecionado a partir de um dos produtos pode ser utilizado para classificar outro produto com características distintas e, ainda assim, conseguir um bom resultado. Segundo Landis e Koch (1977), valores de kappa entre 0,61 e 0,80 correspondem a uma boa precisão na classificação.

TABELA 6.5 - Desempenho da classificação dos produtos utilizando os três conjuntos de variáveis selecionadas.

	kappa		
	GR1	GR2	SR
variáveis de GR1	0,91	0,81	0,80
variáveis de GR2	0,82	0,91	0,85
variáveis de SR	0,75	0,82	0,90

Até aqui, considerou-se uma análise conjunta de imagens em várias frequências e polarizações. No entanto, comercialmente, estão disponíveis apenas imagens em uma única frequência e polarização: ERS-1, JERS-1, e recentemente RADARSAT. Dessa forma, dever-se-ia testar as medidas de textura para cada imagem separadamente a fim de verificar, se também neste caso, as medidas de textura poderiam melhorar a discriminação entre as classes de uso estudadas. É importante observar que, agora, há no máximo 25 medidas para cada imagem (24 medidas de textura e a média). A Figura 6.4 mostra o desempenho apresentado por cada imagem quando um determinado número de variáveis é selecionado. Os resultados mostram que mesmo utilizando-se uma imagem em uma frequência e polarização, as medidas de textura conseguem discriminar as classes de uso estudadas, chegando a valores de kappa superiores a 0,85, independentemente da frequência e polarização utilizada. Esse resultado comprova que a informação textural em imagens SAR é muito importante e deveria, portanto, ser utilizada na classificação.

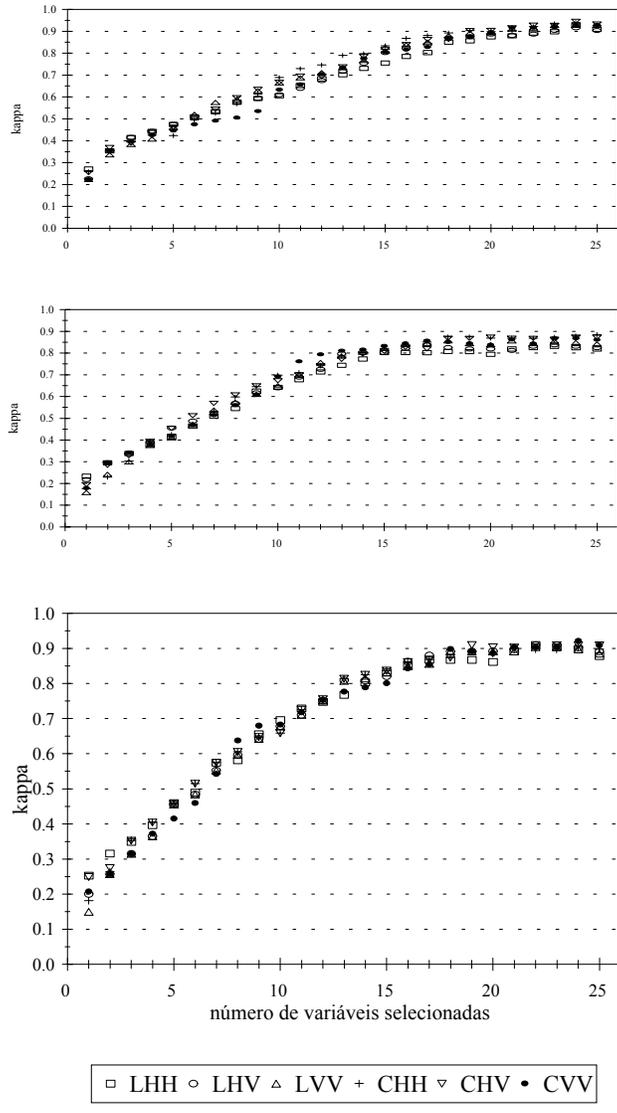


FIGURA 6.4 - Desempenho da classificação, considerando as 6 imagens separadamente.

CAPÍTULO 7

CONCLUSÕES

Os resultados deste trabalho comprovaram que as medidas de textura melhoram significativamente a precisão da classificação de imagens SAR. No entanto, não há um conjunto destas medidas que se possa generalizar como sendo ideal para estudos de discriminação de alvos agrícolas. Foi mostrado que, pelo menos para o caso estudado, as características próprias de cada produto testado (projeção e ângulo de incidência) pouco influenciaram na seleção das medidas de texturas, uma vez que um conjunto selecionado para um determinado produto pode ser aplicado, com resultados muito bons, nos demais produtos.

A metodologia para seleção das medidas de textura mostrou-se adequada, já que, valores muito altos de kappa foram obtidos quando se realizou a classificação baseando-se nestas medidas selecionadas. É importante observar que a distância de Mahalanobis mostrou-se eficiente no processo de classificação, mesmo que algumas das medidas de textura não possuam distribuição normal.

A utilização de medidas de textura em imagens adquiridas em uma frequência e polarização trouxe resultados surpreendentes. Este tipo de imagem, que caracteristicamente apresenta baixos índices de acerto quando são utilizados classificadores baseados apenas na informação tonal, consegue, em alguns casos, valores de kappa superiores a 0,90.

Ficou evidente que também a informação tonal foi muito importante para a discriminação das classes de uso, visto que, praticamente para todos os produtos, houve a seleção das médias tonais (ou outras variáveis altamente correlacionadas a estas) de todas as imagens testadas.

Este trabalho procurou discutir, ainda que não por completo, sobre o aproveitamento da informação textural em imagens SAR para fins de classificação. Muito ainda se tem por fazer até torná-lo prático e utilizável, uma vez que esta metodologia pressupõe que a

imagem esteja segmentada e que a verdade terrestre esteja estabelecida para a seleção das medidas.

Alguns pontos devem ser elucidados através de outras pesquisas, podendo-se citar entre eles:

- a) definição do número de *pixels* de um segmento para extração da informação textural;
- b) desenvolvimento de algoritmos de extração da informação textural mais eficientes e rápidos;
- c) teste da metodologia apresentada neste trabalho em outras áreas com diferentes classes de uso; e
- d) busca de melhores estimadores para o parâmetro α da distribuição K amplitude *multilook*.

Espera-se que este trabalho tenha conseguido mostrar a importância e a necessidade de maiores estudos sobre a classificação de imagens SAR e o aproveitamento da informação textural existente nestas imagens. O autor coloca a disposição dos interessados todas as rotinas desenvolvidas para o cálculo e seleção das medidas de textura.

REFERÊNCIAS BIBLIOGRÁFICAS

- Albuquerque, J.A.S.; Albuquerque, T.C.S. **Cultivo da videira na região do sub-médio São Francisco**. Petrolina: EMBRAPA/CPATSA, 1987. (EMBRAPA-CPATSA. Circular Técnico, 15).
- Albuquerque, T.C.S.; Albuquerque, J.A.S. **Comportamento de dez cultivares de videira na região do sub-médio São Francisco**. Petrolina: EMBRAPA/CPATSA, 1981. (EMBRAPA/CPATSA. Documentos, 12).
- Allen, C.T.; Ulaby, F.T. Modelling the polarization dependence of the attenuation in vegetation canopies. In: IGARSS'84 - International Geoscience and Remote Sensing Symposium. Strasbourg: 27-30 Aug. 1984. **Proceedings**. Paris: ESA, 1984, v. 1, p. 119-124. (ESA SP-215)
- Amorim Neto, M. S. **Informações meteorológicas dos campos experimentais de Bebedouro e Mandacaru**. Petrolina: EMBRAPA/CPATSA, 1989. (EMBRAPA/CPATSA. Documentos, 57).
- Arsenault, H.H.; April, G. Properties of speckle integrated with a finite aperture and logarithmically transformed. **Journal of the Optical Society of America**, v.66, n.11, p.1160-1163, Nov. 1976.
- 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).
- Batlivala, P.P.; Ulaby, F.T. Radar look direction and row crops. **Photogrammetric Engineering Remote Sensing**, v.42, n.2, p. 233-238, Feb. 1976.
- Brakke, T.W. et al. Microwave radar response to canopy moisture leaf-area index, and dry weight of wheat, corn, and sorghum. **Remote Sensing of Environment**, v.11, n.3, p.207-220, July 1981.
- Briand, P.; Gray, J.T. Classification de l'utilisation du territoire sur une image radar SIR-B, à partir de l'information texturale dérivée des statistiques de premier ordre. In: IGARSS'89 - **Canadian Symposium on Remote Sensing** 2., Vancouver. July 10-14, 1989. Proceedings. New York: IEEE, 1989, v. 5, p. 2777-2780.
- Brisco, B.; Brown, R.J.; Manore, M.J. Early season crop discrimination with combined SAR and TM data. **Canadian Journal Remote Sensing**, v.15, n.1, p.44-54, May 1989a.
- Brisco, B.; Brown, R.J.; Pultz, T.J. The effects of free canopy water on SAR crop separability. In: IGARSS'89 - Canadian Symposium on Remote Sensing, 12., Vancouver. July 10-14, 1989. Proceedings. New York: IEEE, 1989, v. 2, p. 424-429.

Brisco, B.; Protz, R. Manual and automatic crop identification with airborne radar imagery. **Photogrammetric Engineering and Remote Sensing**, v.48, n.1, p.101-109, Jan. 1982.

Brisco, B.; Ulaby, F.T.; Protz, R. Improving crop classification through attention to the timing of airborne radar acquisitions. **Photogrammetric Engineering and Remote Sensing**, v.50, n.6, p.739-745, June 1984.

Brown, R.J. An overview of remote sensing agricultural application in North America. In: IGARSS'86 - International Geoscience and Remote Sensing Symposium, Zürich. 8-11 Sept. 1986. **Remote sensing today's solutions for tomorrow's information needs**. Paris: ESA, 1986, v. 2, p. 733-737. (ESA SP-254)

Brown, R.J.; Guindon, B.; Teillet, P.M.; Goodenough, D.G. Crop type determination from multitemporal SAR imagery. In: Canadian Symposium on Remote Sensing, 9., St. John's, Aug. 14-17, 1984. **Proceedings**. Ottawa: Canadian Aeronautics and Space Institute, 1984, p. 683-692.

Bush, T.F.; Ulaby, F.T. An evaluation of radar as a crop classifier. **Remote Sensing Environment**, v.7, n.1, p.15-36, 1978.

Caves, R.G. **Automatic matching of features in Synthetic Aperture Radar data to digital map data**. Sheffield: University of Sheffield, 1993. (Tese submetida para a obtenção do grau de Doutor em Filosofia).

Chen, C.H. Texture unit, texture spectrum, and texture analysis **IEEE Transactions on Geoscience and Remote Sensing**, v.28, n.4, p.509-512, July 1990.

CODEVASF. **Inventário dos projetos de irrigação**. 2.ed. Brasília: codevasf, 1991.

CODEVASF. **Inventário dos projetos de irrigação**. Brasília: codevasf, 1982.

Curlander, J.C.; McDonough, R.N. **Synthetic aperture radar: systems and signal processing**. New York: NY, John Wiley & Sons, 1991.

Dallemand, J.F.; Lichtenegger, J.; Raney, R.K.; Schumann, R. **Radar imagery: theory and interpretation: lecture notes**. Rome: FAO/ESA, 1993. (RSC Series 67).

Dobson, M.C.; Ulaby, F.T.; Pierce, L.E. Land-cover classification and estimation of terrain attributes using synthetic aperture radar. **Remote Sensing Environment**, v.51, n.1, p.199-214. Jan. 1995.

Evans, D.L. et al. Multipolarization radar images for geologic mapping and vegetation discrimination. **IEEE Transactions on Geoscience and Remote Sensing**, v.24, n.2, p.246-257, Mar. 1986.

FAO. **Survey of the São Francisco river basin Brazil**: semidetained soil survey. Rome: FAO, v. 2, 1966. (FAO/UNDP/SF: 22/BRA).

Fatti, L.P.; Hawkins, D.M.; Raath, E.L. Discriminant analysis. In: Hawkins, D.M., ed. **Topics in applied multivariate analysis**. Cambridge: Cambridge University Press, 1982. cap. 1, p. 1-71.

Fischer, J.A.; Mussakowski, R.S. Preliminary evaluation of multi-date SAR data for identification of agricultural crops in Southern Ontario. In: IGARSS'89 - Canadian Symposium on Remote Sensing, 12., Vancouver. July 10-14, 1989. **Proceedings**. [New York], IEEE, 1989, v. 2, p. 430-433.

Foody, G.M. On the compensation for change agreement in image classification accuracy assessment. **Photogrammetric Engineering Remote Sensing**, v.58, n.10, p.1459-1460, Oct. 1992.

Frost, V.S.; Stiles, J.A.; Shanmugan, K.S.; Holtzmann, J.C. A model for radar images and its application to adaptive filtering of multiplicative noise. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.4, n.2, p.157-166, Mar. 1982.

Goldfinger, A.D. Estimation of spectra from speckled images. **IEEE Transactions on Aerospace and Electronic System**, v.18, n.5, p.675-681, Sept. 1982.

Haralick, R.M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v.67, n.5, p.786-804, May 1979.

Haralick, R.M.; Shanmugan, K.; Dinstein, I. Texture features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v.3, n.6, p. 610-621, Nov. 1973.

Hsu, S.Y. Texture-tone analysis for automated land-use mapping. **Photogrammetric Engineering and Remote Sensing**, v.44, n.11, p.1393-1404, Nov. 1978.

Hudson, W.D.; Ramm, C.W. Correct formulation of the kappa coefficient of agreement. **Photogrammetric Engineering Remote Sensing**, v.53, n.4, p.421-422, Apr. 1987.

Irons, J.R.; Petersen, G.W. Texture transforms of remote sensing data. **Remote Sensing Environment**, v.11, n.5, p.359-370, Nov. 1981.

Jordan, R.L.; Huneycutt, B.L.; Werner, M. The SIR-C/X-SAR synthetic aperture radar system. **Proceedings of the IEEE**, v.79, n.6, p. 827-838, June 1991.

Landis, J.R.; Koch, G.G. The measurements of observer agreement for categorical data. **Biometrics**, v.33, n.3, p.159-179. Mar, 1977.

Le Toam, T.; Lopes, A.; Huet, M. On the relationships between radar backscattering coefficient and vegetation canopy characteristics. In: IGARSS'84 - International Geoscience and Remote Sensing Symposium. Strasbourg. 27-30 Aug. 1984. **Proceedings**. Paris: ESA, 1984, v. 1, p. 155-160. (ESA SP-215)

Lee, J.S. Speckle analysis and smoothing of synthetic aperture radar images. **Computer Graphics and Image Processing**, v.17, n.1, p. 24-32, Sept. 1981.

Lim, H.H.; Swartz, A.A.; Yueh, H.A.; Kong, J.A.; Shin, R.T.; van Zyl, J.J. Classification of earth terrain using polarimetric synthetic aperture radar images. **Journal of Geophysical Research**, v.94, n.B6, p. 7049-7057, June 1989.

Lopes, A.; Touzi, R.; Nezry, E. Adaptive speckle filters and scene heterogeneity. **IEEE Transactions Geoscience Remote Sensing**, v.28, n.6, p.992-1000. Nov. 1990.

Lowenthal, S.; Arsenault, H.H. Image formation for coherent diffuse objects: statistical properties. **Journal of the Optical Society of America**, v.60, n.11, p. 478-1483, Nov. 1970.

Luckman, A.; Groom, G.; Baker, J. Forest age discrimination from texture measures of SAR imagery. In: IGARSS'94, 1994. **Proceedings**. Pasadena CA: IEEE, 1994, v. 1, p. 104.

Mao, J.; Jain, A.K. Artificial neural networks for feature extraction and multivariate data projection. **IEEE Transactions Neural Networks**, v.6, n.2, p. 296-317, Mar. 1995.

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**. New York: IEEE, 1989, v. 5, p. 2765-2768.

NASA. **Synthetic Aperture Radar. SAR**. Washington DC: NASA, 1987. (Earth Observing System Reports, v. 2f).

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

Paris, J.F. Radar backscattering properties of corn and soybeans at frequencies of 1.6, 4.75, and 13.3 GHz. **IEEE Transactions Geoscience Remote Sensing**, v.21, n.3, p. 392-400, July 1983.

Pereira, J.M.A.; Souza, R.A. **Mapeamento detalhado da área de Bebedouro, Petrolina, PE**. Recife: MINTER/SUDENE, 1967. (relatório).

- Pope, K.O.; Rey-Benayas, J.M.; Paris, J.F. Radar remote sensing of forest and wetland ecosystems in the Central American tropics. **Remote Sensing of Environment**, v.48, n.3, p. 205-219, June 1994.
- Projeto RADAMBRASIL. **Folhas SC. 24/25 Aracaju/Recife**; geologia, geomorfologia, pedologia, vegetação e uso potencial da terra. Rio de Janeiro: 1983. (Levantamento de Recursos Naturais, 30).
- Quegan, S. Interpolation and sampling in SAR images. **IEEE Transactions Geoscience Remote Sensing**, v.28, n.4, p.641-646. July, 1990.
- Rosenfield, G.H.; Fitzpatrick-Lins, K. A coefficient of agreement as a measure of thematic classification accuracy. **Photogrammetric Engineering Remote Sensing**, v.52, n. 2, p.223-227, Feb. 1986.
- Roth, A.; Craubner, A.; Hügel T. Standard geocoded ellipsoid corrected images. In: Schreier, G., ed. **SAR geocoding: data and systems**. Karlsruhe: Präzis Druck, 1993. cap. 6, p. 159-172.
- Schwarz, D.E.; Caspall, F. The use of radar in the discrimination and identification of agricultural land use. In: Symposium on Remote Sensing of Environment, 5., Ann Arbor, MI, April 16-18, 1968. **Proceedings**. Ann Arbor MI: University of Michigan, 1968, p. 233-247.
- Sofko, G. et al. Variation of microwave radar cross-section of wheat during the initial hours of a rainfall. In: IGARSS'89 - Canadian Symposium on Remote Sensing, 12., Vancouver. July 10-14, 1989. **Quantitative remote sensing: an economic tool for the nineties**. [New York], IEEE, 1989, v. 3, p. 1191-1194.
- Thomson, K.P.B.; Edwards, G.; Landry, R.; Jatou, A., Cadieux, S.P.; Gwyn, Q.H.J. SAR applications in agriculture: multiband correlation and segmentation. **Canadian Journal of Remote Sensing**, v.16, n.3, p. 47-54. Oct. 1990.
- Tur, M.; Chin, K.C.; Goodman, J.W. When is speckle noise multiplicative? **Applied Optics**, v.21, n.7, p.1157-1159, Apr. 1982.
- Ulaby, F.T.; Allen, C.T.; Eger, G.; Kanemasu, E. Relating the microwave backscattering coefficient to leaf area index. **Remote Sensing Environment**, v.14, n.1-3, p. 113-133, Jan. 1984.
- Ulaby, F.T.; Bare, J.E. Look direction modulation function of the radar backscattering coefficient of agricultural fields. **Photogrammetric Engineering Remote Sensing**, v.45, n.11, p.1495-1506, Nov. 1979.
- 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 on Geoscience Electronics**, v.16, n.4, p. 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 Trans. Geoscience Electronics.**, v.17, n.2, p.33-40, Apr. 1979.
- Ulaby, F.T.; Bush, T.F.; Batlivala, P.P. Radar response to vegetation II: 8-18 GHz band. **IEEE Transactions Antennas and Propagation**, v.23, n.5, p.608-618, Sept. 1975.
- Ulaby, F.T.; Bush, T.F.; Batlivala, P.P.; Cihlar, J. **The effects of soil moisture and plant morphology on the radar backscatter from vegetation**. Lawrence: KS, University of Kansas Center of Research, 1974. (RSL Technical Report 177-51).
- Ulaby, F.T.; Dobson, M.C. **Handbook of radar scattering statistics for terrain**. Norwood: MA, Artech House, 1989.
- Ulaby, F.T.; Kouyate, F.; Brisco, B.; Lee Williams, T.H. Textural Information in SAR Images. **IEEE Transactions on Geoscience and Remote Sensing**, v.24, n.2, p.235-245, Mar. 1986.
- 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.ed. Norwood MA: Artech House, 1986a. v. 2.
- Ulaby, F.T.; Moore, R.K.; Fung, A.K. **Microwave remote sensing: active and passive: from theory to applications**. Dedham MA: Artech House, 1986b. v. III.
- Unser, M. Sum and difference histograms for texture classification. **IEEE Transactions Pattern Analysis Machine Intelligence**, v.8, n.1, p.118-125. Jan. 1986.
- Valdivieso-Salazar, C.R.; Cordeiro, G.G. **Avaliação do manejo de águas no perímetro irrigado de Bebedouro, Petrolina, PE**. Petrolina: EMBRAPA/CPATSA, 1985. (EMBRAPA/CPATSA. Boletim de Pesquisa, 25).
- van Zyl, J.J.; Burnette, C.F. Bayesian classification of polarimetric SAR images using adaptive "a priori" probabilities. **International Journal Remote Sensing**, v.13, n.5, p.835-838, 1992.
- van Zyl, J.J.; Zebker, H.A.; Elachi, C. Imaging radar polarization signatures: theory and observation. **Radio Science**, v.22, n.4, p. 529-543, July/Aug. 1987.
- Way, J.; Smith, E.A. The evolution of synthetic aperture radar systems and their progression to the EOS SAR. **IEEE Transactions Geoscience Remote Sensing**, v.29, n.6, p.962-985, Nov. 1991.
- Welch, R.M.; Kuo, K-S; Sengupta, S.K. Cloud and surface textural features in polar regions. **IEEE Transactions Geoscience Remote Sensing**, v.28, n.4, p.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 Man and Cybernetics**, v.6, n.4, p.269-285. Apr. 1976.

Yanasse, C.C.F.; Frery, A.C.; Sant'Anna, S.J.S.; Hernandes, P.F.; Dutra, L.V. Statistical analysis of SAREX data over Tapajós - Brazil. In: SAREX-92: South American Radar Experiment, ESA, Paris, Dec. 6-8, 1993. **Workshop Proceedings**. Paris: ESA, 1993, p. 25-40.

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).

APÊNDICE A

MATRIZ DE STOKES

Um difusor pode ser caracterizado em termos da matriz de Stokes, $[\mathbf{M}]$. Os elementos de $[\mathbf{M}]$ são funções dos elementos da matriz de espalhamento e podem ser expressos como

$$[\mathbf{M}] = ([\mathbf{R}]^t)^{-1} [\mathbf{W}] [\mathbf{R}]^{-1} \quad (\text{A.1})$$

onde

$$[\mathbf{W}] = \begin{bmatrix} M_{hh}M_{hh}^* & M_{hv}M_{hv}^* & M_{hh}M_{hv}^* & M_{hv}M_{hh}^* \\ M_{vh}M_{vh}^* & M_{vv}M_{vv}^* & M_{vh}M_{vv}^* & M_{vv}M_{vh}^* \\ M_{hh}M_{vh}^* & M_{hv}M_{vv}^* & M_{hh}M_{vv}^* & M_{hv}M_{vh}^* \\ M_{vh}M_{hh}^* & M_{vv}M_{hv}^* & M_{vh}M_{hv}^* & M_{vv}M_{hh}^* \end{bmatrix} \quad (\text{A.2})$$

e

$$[\mathbf{R}] = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & -i & i \end{bmatrix}. \quad (\text{A.3})$$

Cada elemento $M_{mn}M_{kl}^*$ representa a multiplicação do elemento complexo da matriz de espalhamento M_{mn} pelo complexo conjugado de M_{kl} , para todos $n, m, k, l = \{h, v\}$.

Desta forma, a matriz de Stokes é uma matriz 4x 4, definida como

$$[\mathbf{M}] = \begin{bmatrix} M_{1,1} & M_{1,2} & M_{1,3} & M_{1,4} \\ M_{2,1} & M_{2,2} & M_{2,3} & M_{2,4} \\ M_{3,1} & M_{3,2} & M_{3,3} & M_{3,4} \\ M_{4,1} & M_{4,2} & M_{4,3} & M_{4,4} \end{bmatrix}, \quad (\text{A.4})$$

onde

$$M_{1,1} = (M_{hh}M_{hh}^* + M_{vv}M_{vv}^* + M_{hv}M_{hv}^* + M_{vh}M_{vh}^*)/4, \quad (\text{A.5})$$

$$M_{1,2} = (M_{hh}M_{hh}^* - M_{vv}M_{vv}^* - M_{hv}M_{hv}^* + M_{vh}M_{vh}^*)/4, \quad (\text{A.6})$$

$$M_{1,3} = \left(\text{real}(M_{hh}M_{hv}^*) + \text{real}(M_{vh}M_{vv}^*) \right) / 2, \quad (\text{A.7})$$

$$M_{1,4} = \left(-\text{imag}(M_{hh}M_{hv}^*) - \text{imag}(M_{vh}M_{vv}^*) \right) / 2, \quad (\text{A.8})$$

$$M_{2,1} = \left(M_{hh}M_{hh}^* - M_{vv}M_{vv}^* + M_{hv}M_{hv}^* - M_{vh}M_{vh}^* \right) / 4, \quad (\text{A.9})$$

$$M_{2,2} = \left(M_{hh}M_{hh}^* + M_{vv}M_{vv}^* - M_{hv}M_{hv}^* - M_{vh}M_{vh}^* \right) / 4, \quad (\text{A.10})$$

$$M_{2,3} = \left(\text{real}(M_{hh}M_{hv}^*) - \text{real}(M_{vh}M_{vv}^*) \right) / 2, \quad (\text{A.11})$$

$$M_{2,4} = \left(-\text{imag}(M_{hh}M_{hv}^*) + \text{imag}(M_{vh}M_{vv}^*) \right) / 2, \quad (\text{A.12})$$

$$M_{3,1} = \left(\text{real}(M_{hh}M_{vh}^*) + \text{real}(M_{hv}M_{vv}^*) \right) / 2, \quad (\text{A.13})$$

$$M_{3,2} = \left(\text{real}(M_{hh}M_{vh}^*) - \text{real}(M_{hv}M_{vv}^*) \right) / 2, \quad (\text{A.14})$$

$$M_{3,3} = \left(M_{hv}M_{hv}^* + \text{real}(M_{hh}M_{vv}^*) \right) / 2, \quad (\text{A.15})$$

$$M_{3,4} = \left(-\text{imag}(M_{hh}M_{vv}^*) + \text{imag}(M_{hv}M_{vh}^*) \right) / 2, \quad (\text{A.16})$$

$$M_{4,1} = \left(-\text{imag}(M_{hh}M_{vh}^*) - \text{imag}(M_{hv}M_{vv}^*) \right) / 2, \quad (\text{A.17})$$

$$M_{4,2} = \left(-\text{imag}(M_{hh}M_{vh}^*) + \text{imag}(M_{hv}M_{vv}^*) \right) / 2, \quad (\text{A.18})$$

$$M_{4,3} = \left(-\text{imag}(M_{hh}M_{vv}^*) - \text{imag}(M_{hv}M_{vh}^*) \right) / 2, \quad (\text{A.19})$$

e

$$M_{4,4} = \left(\text{real}(M_{hv}M_{vh}^*) - \text{real}(M_{hh}M_{vv}^*) \right) / 2. \quad (\text{A.20})$$

Através da matriz de Stokes, pode-se calcular a potência ou intensidade do sinal:

$$P = [\mathcal{S}_r]^t [\mathbf{M}] [\mathcal{S}_t] \quad (\text{A.21})$$

onde $[\mathcal{S}_r]$ é o vetor de Stokes referente a onda refletida pelo difusor e $[\mathcal{S}_t]$ é o vetor de Stokes referente a onda transmitida pela antena.

Cada vetor de Stokes é

$$[\mathcal{S}] = \begin{bmatrix} 1 \\ \cos(2\psi) \cos(2\xi) \\ \sin(2\psi) \cos(2\xi) \\ \sin(2\xi) \end{bmatrix}, \quad (\text{A.22})$$

onde ψ é o ângulo de orientação e ξ é o ângulo de elipsidade (Figura A.1).

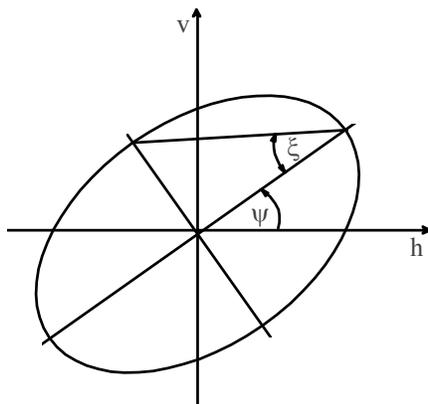


FIGURA A.1 - Elipse de polarização.

A Tabela A.1 lista as polarizações mais comuns e seus respectivos ângulos de orientação e elipsidade.

TABELA A.1 – Algumas polarizações e seus respectivos ângulos de orientação e elipsidade (em graus).

polarização	ψ_t	ξ_t	ψ_r	ξ_r
HH	0	0	0	0
HV	0	0	0	90
VH	0	90	0	0
VV	0	90	0	90
LL	45	135	45	135
RR	45	45	45	45

FONTE: NASA/JPL (1994), p. 19.

APÊNDICE B

DESCOMPACTAÇÃO DAS IMAGENS SIR-C

(Bandas L e C)

As imagens SIR-C são fornecidas num formato compactado onde cada *pixel* é composto por 10 *bytes* que podem ser descomprimidos para valores em pontos flutuantes, a partir dos quais calcula-se a matriz de Stokes.

O programa “byte_image” faz a descompactação, produzindo uma imagem amplitude discretizada em 256 níveis de cinza (8 *bits*). O nível de cinza associado a cada *pixel* da imagem provém da seguinte transformação:

$$NC = nint(a.b.\sqrt{P}) \quad (B.1)$$

onde a representa um fator de escala relativa (fornecido pelo usuário), $b = 128/\bar{A}$, \bar{A} é a amplitude média ($\sqrt{\bar{P}}$) obtida através de uma amostragem da imagem, P é a potência ou intensidade do *pixel* obtida através da matriz de Stokes e $nint()$ indica que o valor do inteiro mais próximo é calculado para seu argumento.

É importante observar que para polarizações lineares (HH, HV, VH e VV) apenas os elementos $M_{1,1}$, $M_{1,2}$, $M_{2,1}$ e $M_{2,2}$ da matriz de Stokes são considerados e cálculo da potência resume-se em isolar o elemento de $[W]$ correspondente à potência naquela polarização, assim

$$P_{hh} = M_{hh}M_{hh}^* = real(M_{hh})^2 + imag(M_{hh})^2, \quad (B.2)$$

$$P_{hv} = M_{hv}M_{hv}^* = real(M_{hv})^2 + imag(M_{hv})^2, \quad (B.3)$$

$$P_{vh} = M_{vh}M_{vh}^* = real(M_{vh})^2 + imag(M_{vh})^2 \quad (B.4)$$

e

$$P_{vv} = M_{vv}M_{vv}^* = real(M_{vv})^2 + imag(M_{vv})^2. \quad (B.5)$$