

# UTILIZAÇÃO DE MEDIDAS TEXTURAS NA DISCRIMINAÇÃO DE CLASSES DE USO DO SOLO DO PERÍMETRO IRRIGADO DE BEBEDOURO, PERNAMBUCO, BRASIL, UTILIZANDO-SE IMAGENS SAR.

Camilo Daleles Rennó  
João Viane Soares

INPE - Instituto Nacional de Pesquisas Espaciais  
Caixa Postal 515, 12201-970 São José dos Campos, SP, Brasil  
{camilo, viane} @ltid.inpe.br

## RESUMO

A textura é uma importante característica utilizada na interpretação visual de imagens. Dessa forma, sua utilização pode melhorar o desempenho de classificadores digitais, principalmente em imagens com alta resolução espacial. Muitas medidas de textura podem ser encontradas na literatura mas, no entanto, não há um consenso na definição deste termo, nem tampouco uma formulação matemática única e precisa. A escolha das medidas de textura a serem utilizadas numa determinada análise é feita quase sempre de forma empírica. Este trabalho vem apresentar uma metodologia de seleção de medidas de textura baseada na maximização da discriminação de classes de uso em imagens SAR. Foram utilizadas imagens provenientes da missão SIR-C/X-SAR, bandas L e C, polarizações HH, HV e VV, de abril de 1994 sobre o Perímetro Irrigado de Bebedouro, Petrolina - PE, Brasil. Foram analisadas um total de 24 medidas de textura de primeira e segunda ordem. Os resultados mostraram que classificações baseadas apenas na média tonal obtiveram valores de kappa pouco acima de 0,50. O uso de medidas de textura resultaram numa melhoria da classificação, obtendo-se valores de kappa superiores a 0,90 quando 15 medidas foram utilizadas simultaneamente, considerando uma análise conjunta de todas as bandas e polarizações. Mesmo quando apenas uma imagem (uma banda, uma polarização) foi utilizada, conseguiu-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 classes de uso de solo.

## 1. INTRODUÇÃO

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).

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).

O objetivo geral deste trabalho é avaliar o desempenho de medidas de textura na discriminação de alvos agrícolas utilizando-se imagens de radar. Para tanto, serão utilizados dois métodos de seleção que maximizam a discriminação obtidas a partir da missão SIR-C/X-SAR.

## 2. MEDIDAS DE TEXTURA

Entre as medidas mais utilizadas, destacam-se aquelas baseadas na matriz de co-ocorrência (Haralick et al., 1973). 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  $\Delta x$  colunas e  $\Delta y$  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. Como alternativa, pode-se trabalhar com vetores soma e diferença de níveis de cinza (Weszka et al., 1976; Unser, 1986; Welch et al., 1990). Neste trabalho estão sendo avaliadas as seguintes medidas de Haralick: uniformidade (energia), entropia, contraste, homogeneidade, correlação, chi-quadrado, média do vetor soma, variância do vetor soma, uniformidade do vetor soma, entropia do vetor soma, média do vetor diferença, variância do vetor diferença, uniformidade do vetor diferença e entropia do vetor diferença.

Além das medidas baseadas na matriz de co-ocorrência, outra medida de segunda 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. Neste trabalho, estão sendo testadas as autocorrelações de *lag* (0,1), (1,0) e (1,1).

Outros 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 de primeira ordem analisadas neste estudo são: variância, coeficiente de variação, assimetria, assimetria da média em relação à mediana e curtose.

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  $\alpha$  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  $\alpha$  são indicativos de homogeneidade. Duas estimativas estão sendo avaliadas, uma baseada na distribuição K amplitude *multilook* e outra na distribuição K intensidade *multilook*.

### 3. MATERIAL E MÉTODOS

A área de estudo compreende o Projeto de Irrigação de Bebedouro (PIB) localizado na região do Sub-médio São Francisco (9°07'S, 40°18'WGr), Petrolina, Pernambuco, Brasil. O PIB constitui um mosaico de culturas anuais e perenes com propriedades de 5 a 12 ha (Soares et al., 1988).

Neste trabalho, foram analisadas as imagens referentes a 2 passagens do SIR-C obtidas durante o primeiro experimento (abril de 1994). A Tabela 1 resume as principais características destas imagens. GR1 e GR2 são imagens *ground range* e SR *slant range*.

Inicialmente, as imagens SR sofreram um processamento *multilook* a fim de reduzir o speckle e obter elementos de resolução correspondentes a cada *pixel* da imagem mais ou menos quadrados (12,57 x 13,32 m). Cada conjunto é composto por 6 imagens

amplitude discretizadas em 256 níveis de cinza (bandas L e C, polarizações HH, HV e VV).

Tabela 1 - Características das imagens SAR

|                | GR1                 | GR2                 | SR                 |
|----------------|---------------------|---------------------|--------------------|
| Data           | 09/04/94            | 13/04/94            | 13/04/94           |
| Bandas         | L e C               | L e C               | L e C              |
| Polarizações   | HH, HV e VV         | HH, HV e VV         | HH, HV e VV        |
| Projeção       | <i>Ground Range</i> | <i>Ground Range</i> | <i>Slant Range</i> |
| Âng. de incid. | 47,77°              | 37,97°              | 37,97°             |
| Esp. na linha  | 12,5 m              | 12,5 m              | 4,19 m             |
| Esp. na coluna | 12,5 m              | 12,5 m              | 13,32 m            |
| Altitude       | 220,37 km           | 219,38 km           | 219,38 km          |

Simultaneamente ao imageamento feito pelo SIR-C/X-SAR, foi realizado o trabalho de campo visando o levantamento do uso da terra, utilizado como verdade terrestre. 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), que posteriormente, foi digitalizado e registrado às imagens. Este procedimento garantiu que nenhuma distorção nos níveis de cinza fosse gerada, conservando as imagens em seu formato original.

Em seguida, para cada amostra de cada imagem foram determinadas 25 medidas (14 medidas de Haralick; 3 autocorrelações espaciais; 5 medidas baseadas em estatísticas de primeira ordem; 2 estimadores de  $\alpha$ ; e a média), totalizando 150 medidas para cada conjunto de imagens analisadas. A Tabela 2 apresenta a relação de todas as medidas testadas, assim como a abreviatura adotada para cada uma destas medidas.

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.

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. Comumente empregam-se medidas de divergência (distâncias) ou de similaridade no processo de classificação.

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.

Quando as variáveis são normalmente distribuídas, pode-se utilizar a distância de Mahalanobis ao invés da euclidiana. O uso da distância de Mahalanobis na classificação normalmente traz melhores resultados pois esta avalia não somente a média, mas também a variância e a covariância entre as variáveis envolvidas.

Tabela 2 - 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 lag 0,1                       |
| <i>aut10</i> | autocorrelação espacial lag 1,0                       |
| <i>aut11</i> | autocorrelação espacial lag 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> | $\alpha$ estimado pela K amplitude <i>multilook</i>   |
| <i>alfai</i> | $\alpha$ estimado pela K intensidade <i>multilook</i> |
| <i>m</i>     | média   |

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. Os elementos da diagonal desta matriz representam as amostras corretamente classificadas.

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 de amostras classificadas). 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.

O kappa assume valores menores ou iguais a 1, podendo inclusive assumir valores negativos. Quando todas as amostras são corretamente classificadas, o coeficiente kappa possui valor 1. Valores de kappa pequenos indicam que a classificação não obteve bons resultados (Landis e Koch, 1977).

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

Cada conjunto 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 primeira ordem, 2 estimadores de  $\alpha$ , 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.

Primeiramente, o poder discriminante de cada variável foi 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, por esta metodologia, 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 seleção 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 grupos possuam maiores taxas de acerto e portanto maiores valores de kappa. A variância entre grupos é definida por

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

onde  $\bar{x}_i$  é a média da variável para a classe  $i$ ,  $n_i$  é o número de amostras que compõem 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 variância entre grupos reduz-se a

$$VAR_{entre} = \frac{\sum n_i \bar{x}_i^2}{N}$$

Com base na variância entre grupos, pôde-se promover uma pré-seleção de modo a reduzir o número de variáveis testadas. Numa primeira etapa, ordenaram-se as variáveis de acordo com a variância entre grupos apresentada por cada uma delas. A seleção iniciou-se pela variável com maior variância entre grupos. 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 já havia sido proposto, com a vantagem de não ser necessário testar todas as 150 variáveis.

#### 4. RESULTADOS E DISCUSSÃO

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. Os 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 grupos. 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. A seleção propriamente dita foi feita do mesmo modo que para o primeiro método.

A Figura 1 apresenta uma comparação entre os métodos adotados para seleção das variáveis. O desempenho de cada conjunto de variáveis selecionadas 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, em alguns casos, quando um pequeno número de variáveis é selecionado,

as médias apresentam melhor 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.




Fig. 1 - Desempenho da classificação.

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 3 vezes mais rápido que o primeiro método. A

partir daqui, os comentários serão feitos considerando apenas os resultados obtidos pelo método 2.

A Figura 2 mostra a relação existente entre a variância entre grupos e o kappa de cada uma das variáveis. Também é indicado, nestas figuras, o valor mínimo de variância entre grupos apresentado pelas variáveis pré-selecionadas. A classificação feita utilizando-se todas estas variáveis pré-selecionadas apresentou kappa igual a 1. Note que grande parte das variáveis é descartada nesta fase. Os maiores valores de kappa e variância entre grupos individuais são provenientes de imagens da banda L. Isto demonstra que pela textura (e também a média) desta banda consegue-se separar melhor as classes de uso estudadas.




Fig. 2 - Relação entre variância entre grupos e o kappa individual.

Por outro lado, quando apenas as variáveis selecionadas são mostradas (Figura 3), pode-se observar que o melhor conjunto de variáveis selecionado não corresponde às variáveis com maior kappa

individual, daí o motivo pelo qual, na fase de pré-seleção, não se deve fazer o descarte de um grande número de variáveis.




Fig. 3 - Kappa e variância entre grupos das variáveis selecionadas.

Todas as imagens contribuíram com pelo menos 1 variável (com exceção da imagem CVV do produto GR2), sendo que as imagens da banda L, de modo geral, foram as que tiveram o maior número de variáveis selecionadas. Para o produto GR1, a maior contribuição textural foi dada pela polarização VV, enquanto que esta mesma polarização para os produtos GR2 e SR foi a que menos contribuiu.

A Tabela 3 apresenta a relação das variáveis selecionadas por produto. Pode-se observar que, para as classes de uso analisadas, a média foi uma medida muito importante na discriminação, sendo que quase todas as imagens estão representadas pela sua média. Cada produto tem um conjunto distinto de variáveis

selecionadas, mas, no entanto, há algumas variáveis altamente correlacionadas: *m* e *mvs*, *entvd* e *mvd*, *univd* e *chi*, *con* e *m*, *vvs* e *v*, entre outras.

Tabela 3 - variáveis selecionadas

| 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 selecionadas possuem uma relação implícita, procedeu-se à classificação de cada produto utilizando-se todos os 3 conjuntos de variáveis selecionadas. O resultado desta classificação, apresentado na Tabela 4, 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 Kock (1977), valores de kappa entre 0,61 e 0,80 correspondem a uma boa precisão na classificação.

Tabela 4 - 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 de 2 bandas e 3 polarizações. No entanto, na prática raramente se dispõe de dados SAR multipolarimétricos e em mais que uma banda. Dessa forma, procedeu-se a uma análise de cada imagem separadamente. É importante observar que, agora, há no máximo 25 medidas de textura para cada imagem. A Figura 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 de uma banda e polarização, as medidas de textura conseguem discriminar as classes de uso estudadas, conseguindo valores de kappa

superiores a 0,85, independentemente da frequência e polarização utilizada.




Fig. 4 - Desempenho da classificação, considerando as imagens separadamente.

## 5. CONCLUSÃO

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 utilização de medidas de textura em imagens adquiridas em uma frequência e polarização trouxe resultados surpreendentes. Neste tipo de imagem, que caracteristicamente apresenta baixos índices de acerto quando são utilizados classificadores baseados apenas na informação tonal, pode-se observar, 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 em todos os casos, houve a seleção das médias (ou outras variáveis altamente correlacionadas a estas) de todas as imagens testadas.

#### AGRADECIMENTOS

Os autores agradecem o apoio do CNPq através do projeto PROTEM-CC GEOTEC (Processo 682.061-94-0)

#### REFERÊNCIAS

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

Foody, G.M. On the compensation for chance agreement in image classification accuracy assessment. **Photogram. Eng. & Rem. Sen.**, 58(10):1459-1460, Oct. 1992.

Haralick, R.M.; Shanmugan, K.; Dinstein, I. Texture features for image classification. **IEEE Trans. Systems, Man and Cybernetics**, SMC-3(6):610-621, Nov. 1973.

Hsu, S.Y. Texture-tone analysis for automated land-use mapping. **Photogram. Eng. & Rem. Sen.**, 44(11):1393-1404, Nov. 1978.

Hudson, W.D.; Ramm, C.W. Correct formulation of the kappa coefficient of agreement. **Photogram. Eng. & Rem. Sen.**, 53(4):421-422, Apr. 1987.

Irons, J.R.; Petersen, G.W. Texture transforms of remote sensing data. **Rem. Sen. Env.**, 11(5):359-370, Nov. 1981.

Landis, J.R.; Koch, G.G. The measurements of observer agreement for categorical data. **Biometrics.**, 33:159-174, Mar. 1977.

Marceau, D.; Howarth, P.J.; Dubois, J.M. Automated texture extraction from high spatial resolution satellite imagery for land-cover classification: concepts and application. In: IGARSS'89 - Canadian Symposium on Remote Sensing, 12., Vancouver, July 10-14, 1989. **Proceedings. IEEE**, 1989, v. 5, p. 2765-2768.

Rosenfield, G.H.; Fitzpatrick-Lins, K. A coefficient of agreement as a measure of thematic classification accuracy. **Photogram. Eng. & Rem. Sen.**, 52(2):223-227, Feb. 1986.

Soares, J.V. et al. **Microwave remote sensing from a spaceborne platform as a tool to monitor the hydrologic cycle of a floodplain area (várzea) at northeast Brazil.** São José dos Campos, INPE, 1988. (INPE-4741-RPE/579)

Ulaby, F.T.; Kouyate, F.; Brisco, B.; Lee Williams, T.H. Textural Information in SAR Images. **IEEE Trans. on Geosc. and Remote Sensing**, 24(2):235-245, Mar. 1986.

Unser, M. Sum and difference histograms for texture classification. **IEEE Trans. Pattern Anal. Mach. Intell.**, PAMI-8(1):118-125, Jan. 1986.

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

Weszka, J.S.; Dyer, C.R.; Rosenfeld, A. A comparative study of texture measures for terrain classification. **IEEE Trans. Syst. Man. Cybern.**, SMC-6(4):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.