

Análise de imagens orientada a objetos para integração de imagens SAR e ópticas no mapeamento de áreas periurbanas

Haron Abraham Magalhães Xaud^{1,2}
Leila Maria da Fonseca²
João Roberto dos Santos²
Gustavo Augusto Mascarenhas Goltz²
Maristela Ramalho Xaud^{1,2}

¹ Empresa Brasileira de Pesquisas Espaciais – Embrapa Roraima
BR- 174, km 8, Distrito Industrial, 69.301-970 – Boa Vista – RR, Brasil
{haron, maris}@cpafrr.embrapa.br

² Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
{haron, jroberto, mramalho}@dsr.inpe.br; leila@dpi.inpe.br; gustavo_goltz@yahoo.com.br

Abstract. This study analyze the contribution of SAR and optical images for mapping the land use and land cover in a periurban site using an oriented-based image analysis (OBIA) approach. We have chosen a site in the municipality of São José dos Campos, country region in the state of São Paulo, Brazil. The SAR images are from the sensor SAR-R99B (L-band in HH, HV and VV polarizations) with 3.0m of spatial resolution, in amplitude; the optical images are from QuickBird-2 with 2.44m of resolution, in VIS and IR bands, orthorectified. Using original SAR data we generate 12 textures based on occurrence and co-occurrence matrix for each polarization. Using an OBIA software, it was conducted the selection among bands and attributes to promote the better classification of LULC for the study area, given the conjunct of data and classes (trees; shrubs; grassland; agriculture; water; bare soil; pavement soil; houses; buildings). Through a data mining tool (Feature Space Optimization), based on Nearest Neighbor classifier, we optimize the bands and its attributes to improve the separability among classes. The results reveal: 1) the importance of R99-B images and mainly co-occurrence textures used in complement of QuickBird-2 images to improve the LULC classification; 2) the high potential of OBIA to: a) integrate different data (SAR and Optical), b) select attributes of images and c) structure models to obtain an adequate classification, even when the contextual features weren't explored yet.

Palavras-chave: synthetic aperture radar, oriented based OBIA, texture, radar de abertura sintética, classificação orientada o objetos, textura.

1. Introdução

Na classificação de imagens aplicada aos estudos de uso do solo para áreas urbanas, tem havido crescente evolução de sensores ópticos de alta resolução espacial, próximas a 1m² ou ainda menores (e.g. satélites IKONOS, QuickBird etc.). Porém, de acordo com Pinho et al. (2005), existem potencialidades e limitações para o tratamento destas imagens que dizem respeito ao nível de resolução espacial, abaixo do tamanho médio dos objetos urbanos.

Pode-se supor que tal problema de alta resolução espacial venha a afetar as imagens SAR de forma semelhante, pelo mesmo princípio de super divisão de um determinado objeto, que passa a conter uma variabilidade bem maior de respostas de retro-espalhamento. Superar esta característica inerente aos dados de alta resolução é um desafio.

Por outro lado, a importância das imagens texturas na área de Radar vem sendo abordada como uma alternativa de aumento do poder de extração de informação a partir das imagens originais, tendo sido empregada em diversos tipos de aplicações do sensoriamento remoto (Schmidt et al. 1997; Rennó et al., 1998; Kuplich e Curran, 2003). Utilizando imagens HH, HV e VV do GlobeSAR, Pingxiang e Shenghui (2003), abordaram 4 tipos de textura de co-ocorrência para classificar uma área com as classes distrito residencial, plantios de arroz, solos secos, áreas montanhosas e corpos d'água, indicando significativa melhora na

classificação de algumas classes e no resultado global, quando foram utilizadas imagens texturais.

Neste contexto, abre-se uma boa oportunidade de investigação a partir do aproveitamento de imagens ópticas e de RADAR do sensor SAR R99-B de alta resolução, visando complementaridade de informação dentro de uma abordagem de classificação orientada a objetos (OBIA). Como passo natural, uma das linhas de investigação principais a serem contempladas na construção científica para melhoria das classificações em áreas urbanas e periurbanas, diz respeito ao universo de dados de imagens que deverá ou não ser mais efetivo na extração de atributos que levem a uma adequada classificação.

Assim, um ambiente de classificação OBIA deve permitir o acesso a mais parâmetros provenientes de imagens, como por exemplo: a) brilho total de imagens (brightness); b) elementos texturais; c) tamanho, forma e localização de objetos; e d) lógica de pertinência de objetos e hierarquização de classes. Tal flexibilidade pode permitir: i) a criação de regras de classificação independentes para as diferentes classes; ii) acesso a diferentes atributos das diferentes imagens; e iii) acesso a objetos em diferentes níveis de detalhamento (tamanho).

A hipótese desenvolvida para a elaboração deste trabalho é de que existe uma complementaridade entre as imagens SAR (R99-B, HH, HV e VV) e ópticas (QuickBird-2 multiespectrais) que tende a melhorar os mapeamentos de uso e cobertura do solo (LULC) e que pode ser potencializada em ambientes de classificação de imagens orientado a objetos (OBIA). Numa etapa futura não só os atributos radiométricos, mas também a forma e o posicionamento dos objetos no espaço poderão ser incorporados na análise.

Com base no exposto, o objetivo do trabalho consistiu em realizar o mapeamento da cobertura e uso do solo em área urbana e periurbana, analisando as contribuições advindas das diferentes imagens (ópticas e SAR) e o potencial de extração e integração de informações a partir da aplicação de uma abordagem com base em classificação orientada a objetos (OBIA).

2. Metodologia de Trabalho

2.1 Área de Estudo

A área de estudo está localizada em uma região que integra uma parte urbana e a franja urbana da cidade de São José dos Campos - SP (Figura 1). A região selecionada possui suficiente variedade de alvos, tais como: áreas residenciais diversificadas, corpos d'água, solo exposto, áreas rurais de pequenas e grandes propriedades, diversos tipos de vegetação, pavimentação etc., distribuídos num relevo local variando de plano a ondulado.



Figura 1 – Localização da área de estudo em São José dos Campos - SP.

2.2 Imagens utilizadas

As imagens ópticas de junho de 2006 foram provenientes do satélite QuickBird-2, nas 4 bandas multiespectrais (QB-1, QB-2, Q-3, QB-4), com 2,44 m de resolução espacial. Já as imagens de RADAR de julho de 2006 foram provenientes do sensor R99-B (SIPAM). O R99-B é um SAR (Síntetic Aperture Radar) polarimétrico aerotransportado que pode operar em

diferentes modos. Para as imagens aqui utilizadas, sua operação foi realizada na banda L, modo multipolarizado gerando imagens amplitude HH, HV, VH e VV, com 3,0 m de resolução espacial.

2.3 Pré-processamento de imagens QuickBird-2

As imagens foram ortorretificadas usando pontos de controle (GCPs-Ground Control Points) obtidos a partir de levantamento com GPS (Global Positioning System) realizado pelo Centro Técnico Aeroespacial (CTA) e o Instituto Nacional de Pesquisas Espaciais (INPE). A ortorretificação foi realizada no software PCI Geomatica v.10.0, utilizando a ferramenta OrthoEngine, que se baseia numa modelagem matemática rigorosa. Este modelo usa os coeficientes polinomiais racionais (RPC-Rational Polynomial Coefficient), contidos nos metadados das imagens, além de um Modelo Digital de Elevação (DEM), com resolução de 5 metros, gerado a partir de cartas planialtimétricas 1:10.000. No total, foram utilizados doze GCPs, identificados sobre as imagens pancromáticas. Para cada GCP coletado considerou-se uma razão de 4 para 1 na sua posição de linha e coluna, para posteriormente transferir os pontos GCPs para as imagens multiespectrais. O Erro Médio Quadrático obtido foi de 0,81 metros em x (longitude) e 0,64 metros em y (latitude). Uma vez que a imagem foi retificada usando-se a banda pancromática, todos os pixels das imagens multiespectrais automaticamente foram reamostrados ficando com um valor nominal de 0,60m.

2.4 Pré-processamento, Registro e Pré-seleção de imagens SAR-R99-B

As imagens SAR R99-B (HH, HV, VH e VV) foram registradas no software ENVI (v.4.2) utilizando como base a imagem QuickBird-2 ortorretificada. Foram utilizados 8 pontos de controle, bem distribuídos ao longo da imagem e polinômio de 1º. Grau, ficando o erro médio quadrático em torno de 1,1 pixel. O algoritmo de reamostragem utilizado foi o do Vizinho Mais Próximo visando à manutenção dos valores digitais originais. Adicionalmente foi feita uma verificação visual ao longo de toda a imagem registrada, através da operação de acoplamento de telas, constatando adequada geometria. A verificação da correlação entre as imagens ou bandas polarizadas HV e VH foi realizada através de uma plotagem de histograma 2D das mesmas. Confirmada a correlação completa entre as duas, optou-se por descartar a polarização VH e trabalhar apenas com a polarização cruzada HV. Assim, somente as polarizações HH, HV e VV do SAR R99-B foram utilizadas para os demais processamentos.

2.5 Geração de imagens-textura

Com base nas e imagens amplitude SAR R99-B multipolarizadas (HH, HV e VV) foram geradas imagens texturas, a partir de rotinas desenvolvidas no software RAT (Radar Tools, 2008), baseadas em estudos propostos por Haralick (1979). Para cada polarização foram geradas 01 textura baseada em matriz de ocorrência, denominada Coeficiente de Variação (CV) e 11 texturas baseadas em matrizes de co-ocorrência, assim denominadas: CO_1- Segundo Momento Angular; CO_2- Contraste; CO_3- Entropia; CO_4- Momento da Diferença Inversa; CO_5- Correlação; CO_6- Dissimilaridade; CO_7- Probabilidade Máxima; CO_8- Média; CO_9- Variância; CO_10- “Cluster Shade”; CO_11- “Cluster Proeminence”. Ao todo foram geradas 36 imagens-textura no RAT.

2.6 Montagem de banco de dados e classificação no Definiens (OBIA)

O Definiens (5.0) foi o software de classificação orientada a objetos escolhido para a realização deste trabalho. Todas as imagens ópticas (4), SAR R99-B (3) e suas imagens-textura (36) foram importadas para a formação de um projeto único no Definiens, totalizando 43 imagens. Os principais procedimentos realizados no Definiens foram:

2.6.1 Criação das classes de interesse

Criação das classes de interesse com base em interpretação visual preliminar e conhecimento sobre a área de estudos. As classes foram assim divididas: Água; Solo exposto; Solo pavimentado; Casas; Edifícios; Vegetação arbórea; Vegetação arbustiva; Vegetação gramínea e Agricultura. Para a classificação apenas das imagens ópticas ou quando da análise integrada (ópticas + SAR), duas classes adicionais tiveram ainda que ser consideradas: nuvens e sombras de nuvens. Para análise apenas das imagens SAR as mesmas não foram consideradas por serem inexistentes.

2.6.2 Segmentação (criação de objetos)

A segmentação de maior detalhe foi realizada utilizando-se as imagens com maior qualidade aparente, que neste trabalho consistiram nas imagens ópticas do QuickBird-2. Existem diversos algoritmos para a realização da segmentação no Definiens, tendo sido utilizado o algoritmo baseado em multiresolução, o qual é considerado um processamento mais demorado, mas que produz uma segmentação mais detalhada. A segmentação forma polígonos irregulares, onde cada um deles passa a ser reconhecido e identificado como um objeto único que é utilizado no armazenamento e na extração de atributos das imagens.

2.6.3 Seleção de amostras

Em seguida foi procedida a seleção de amostras de treinamento, escolhendo-se muitas amostras a partir dos objetos derivados da operação de segmentação. A partir destas amostras são criadas as regras para a realização da classificação das imagens. Esta seleção pode ser refinada através da substituição parcial ou total das amostras escolhidas. Para tanto se pode lançar mão da visualização das amostras e de seus histogramas, podendo-se verificar visualmente a separabilidade entre histogramas de diferentes amostras. Buscou-se um número mínimo de 15 amostras para cada tipo de classe.

2.6.4 Otimização do espaço de atributos (Feature Space Optimization) e classificação

Nesta etapa foram avaliadas a composição de bandas e atributos a serem utilizados para descrever o universo de dados a serem selecionados para obter a desejada separabilidade das classes de interesse. O cuidado na escolha das bandas e seus atributos (média, desvio padrão, brilho, máxima diferença etc.) visa à produção de um mapa de uso do solo e cobertura vegetal com a menor confusão possível entre suas classes.

Por trás da ferramenta de otimização do espaço de atributos funciona o algoritmo do vizinho mais próximo, utilizado como critério para que o espaço de atributos de n-dimensões seja subdividido, baseado nas amostras de treinamento selecionadas anteriormente e que a menor distância entre o objeto a ser classificado e as amostras de cada classe possa ser avaliado. Para efeito de comparação foram realizados 12 testes de composição do espaço de atributos. Desde testes bastante simples, onde as imagens ópticas e SAR foram tratadas de forma isolada (e.g T07 e T09, na Tabela 2) levando-se em consideração apenas o valor médio de nível de cinza de cada objeto, até composições bem mais complexas, onde foram avaliadas conjuntamente todas as bandas ópticas, todas as bandas SAR, suas respectivas texturas e ainda o desvio padrão das imagens básicas (ópticas e SAR).

2.6.5 Validação

Escolhidos os atributos e realizada a classificação, as imagens temáticas passaram por uma validação para cálculo do coeficiente Kappa e a Acurácia Global. Tal etapa foi realizada a partir da utilização de amostras independentes daquelas que foram utilizadas para o treinamento da classificação.

3. Resultados e Discussão

Após testes empíricos para a definição da segmentação, foram definidos os fatores Escala 50, Forma 0,1 e Compacidade 0,5, como adequados; sendo gerados cerca de 47.000 segmentos ou objetos. Uma vez que o foco deste trabalho foi a escolha comparativa de bandas e atributos que fornecessem a melhor separabilidade das classes, foi utilizado apenas um nível de resolução na extração dos segmentos ou objetos. Observou-se que as áreas onde a segmentação gerou os menores polígonos foram exatamente as regiões ocupadas por casas e edifícios. Isto fez com que na seleção de amostras, fosse coletado um numero bem maior das mesmas visando captar a variabilidade destas classes.

Baseado no nível de segmentação acima citado, considerando as classes de interesse: Água, Solo exposto, Solo pavimentado, Casas, Edifícios, Vegetação arbórea, Vegetação arbustiva, Vegetação graminosa e Agricultura, Nuvens e Sombra de nuvens, os resultados da utilização do algoritmo de seleção baseado na otimização do espaço de atributos, mostrou-se como uma importante etapa para a realização de classificações com maior grau de acurácia. Os resultados obtidos no espaço de otimização de atributos puderam ser observados em gráficos, números e matrizes de confusão (Figura 2).




Figura 2 – Gráfico de saída no ambiente do Definiens para verificação da otimização do espaço de atributos.

A partir dos mesmos, foram observadas claramente as classes mais difíceis de serem separadas, dada a utilização de um conjunto de atributos. A seleção de feições trata-se de uma etapa que deve ser realizada em tentativas sucessivas, até que se chegue num equilíbrio entre o número de parâmetros a serem utilizadas e o grau de acurácia desejado.

Um excessivo número de parâmetros pode causar demora no processamento das classificações subseqüentes. Na realidade, como em toda busca de modelos quantitativos, deseja-se uma aproximação da realidade, que neste caso é representado pelos acertos na classificação, utilizando-se o princípio da parcimônia: quanto menor o número de parâmetros utilizados, melhor.

Neste mesmo exemplo é interessante observar como houve uma forte complementaridade entre as imagens ópticas e de SAR, principalmente relacionado às imagens textura. Dentre as 5 primeiras imagens de maior peso para a separabilidade entre classes, estão duas texturas de radar, o Segundo Momento Angular produzido da polarização HH e a Dissimilaridade produzida da polarização HH. Considerando-se a sequência de imagens ainda neste exemplo, observa-se que nas 10 primeiras bandas ou feições que permitem a maior separabilidade entre

as classes estarão 7 bandas-texturas provenientes das imagens de radar. Os resultados de todos os testes realizados para a seleção de atributos estão sintetizados na Tabela 2 a seguir.

Tabela 2 – Resumo das classificações, principais bandas e parâmetros utilizados, mostrando o resultado da validação através do cálculo do Coef. Kappa e da Acurácia Global.

No. Teste; No. Total Parâm.; Sensor	Melhor número de parâm.	Maior Separa- bilidade	Observações e as bandas/atributos mais importantes na classificação.	Coef. Kappa	Acurácia Global (%)
T01 ; 39; R99	5	0.158	Aqui foram desconsideradas nuvens e sombras de nuvem, devido ao tipo de imagem. Mean: hv_CO_1; hh_CO_5; vv_CO_4; hv_CO_6; hh_CO_6	0.5087	61.63
T02 ; 3; R99	3	0.014	Aqui foram desconsideradas das classes nuvens e sombras de nuvem, devido ao tipo de imagem. Mean: R99_hv, vv, hh	0.519	62.72
T03 ; 39; R99	10	0.215	Aqui foram desconsideradas nuvens e sombras de nuvem, devido ao tipo de imagem. Mean: hv_CO_1; hh_CO_5; vv_CO_4; hv_CO_6; hh_CO_6	0.5608	65.36
T04 ; 39; R99	31	0.302	Aqui foram desconsideradas nuvens e sombras de nuvem, devido ao tipo de imagem. Mean: hv_CO_1; hh_CO_5; vv_CO_4; hv_CO_6; hh_CO_6	0.6623	74.87
T05 ; 4; QB	2	0.067	Mean: QB-4; QB-3 (todas as classes)	0.6759	75.59
T06 ; 10; QB	4	0.375	Mean QB-4; Stdv QB-4; Mean QB-3; Máx.Dif.	0.7168	78.56
T07 ; 43QB + R99	5	0.749	Só médias: Mean: hv_CO_1; QB-4; hh_CO_6; QB-2; vv_CO-5	0.7536	81.81
T08 ; 43; QB + R99	10	1.115	Só médias: Mean: hv_CO_1; QB-4; hh_CO_6; QB-2; vv_CO-5	0.7626	82.41
T09 ; 43; QB + R99	21	1.314	Só médias: Mean: hv_CO_1; QB-4; hh_CO_6; QB-2; vv_CO-5	0.7851	84.05
T10 ; 50; QB + R99	5	0.869	Médias + stdev das bandas originais: Mean: hv_CO_1; QB-4; hh_CO_6; QB-2; Stdev: QB-4; seguida de mais 5 bandas de textura do R99	0.7919	84.5
T11 ; 50; QB + R99	10	1.258	Médias + stdev das bandas originais: Mean: hv_CO_1; QB-4; hh_CO_6; QB-2; Stdev: QB-4; seguida de mais 5 bandas de textura do R99	0.8186	86.52
T12 ; 50; QB + R99	22	1.566	Médias + stdev das bandas originais: Mean: hv_CO_1; QB-4; hh_CO_6; QB-2; Stdev: QB-4; seguida de mais 5 bandas de textura do R99	0.822	86.77

Onde: **QB** – imagens do sensor QuickBird-2; **R99** – imagens do sensor R99-B; **Mean**: média; **Stdev**: desvio padrão; **Brightness**: Somatório do brilho de n-bandas escolhidas; **Máx. Dif.**: Máxima diferença; **hh, hv, vv**: diferentes polarizações das imagens SAR-R99-B; **CV**: textura baseada em matriz de ocorrência – Coeficiente de Variação; **CO**: texturas baseadas em matrizes de co-ocorrência; **CO_1**- Segundo Momento Angular; **CO_2**- Contraste ; **CO_3**- Entropia; **CO_4**- Momento da Diferença Inversa; **CO_5**- Correlação; **CO_6**- Dissimilaridade; **CO_7**- Probabilidade Máxima ; **CO_8**- Média; **CO_9**- Variância ; **CO_10**- “Cluster Shade” ; **CO_11**- “Cluster Proeminence”.

Pela interpretação da Tabela 2, verifica-se que no Teste 12 foram usadas todas as médias individuais das bandas originais QuickBird-2 (QB) e SAR (R99B) e das bandas texturas (36) e ainda o desvio padrão das 7 bandas originais, totalizando a avaliação de 50 feições ao mesmo tempo. Os resultados da seleção de atributos indicaram que a máxima separabilidade seria obtida com 22 feições, gerando um valor total de separabilidade de 1,566.

É interessante ressaltar que para os testes realizados apenas com os 10 e 5 parâmetros (respectivamente, T11 e T10) mais importantes revelados na otimização pelo FSO, os resultados foram bastante próximos, podendo ser uma alternativa de baixo custo computacional para se chegar a resultados classificatórios semelhantes, já que o Kappa do T12 (22 parâmetros) ficou em 0,822 e o Kappa do T11 (10 parâmetros) ficou em 0,8186, ou seja, muito próximos. O terceiro Kappa mais alto de todas as classificações testadas foi o obtido no Teste 10 com apenas 5 parâmetros. Estes testes revelaram que a importância relativa das imagens texturas de co-ocorrência é alta para que se obtenha o aumento da separabilidade entre as classes.

A Figura 3 mostra algumas das diferentes imagens empregadas e a classificação gerada ao centro.




Figura 3 – Algumas imagens utilizadas e produto obtido através da classificação no Definiens.

Outro resultado que se sobressai das análises apresentadas resumidamente na Tabela 2 diz respeito ao comportamento isolado das bandas óticas e SAR. As primeiras quando utilizadas isoladamente, mantêm-se com coeficiente Kappa e Acurácia Global, ainda razoáveis. Já as imagens SAR, principalmente em se tratando das originais, caem bastante em acurácia quando utilizadas isoladamente.

Porém o que se deseja em sensoriamento remoto muitas vezes é exatamente a complementação de dados entre diferentes sensores. Tal complementação quando se torna

possível, revela-se útil para melhorar os mapas de uso e cobertura vegetal em ambientes afins, como o que demonstram os resultados aqui apresentados.

Ainda que neste trabalho não se tenha feito uma comparação direta em relação aos resultados obtidos através desta abordagem orientada a objetos e outros tipos de classificação convencionais, vale mencionar que o Definiens mostrou-se bastante flexível para trabalhar com diferentes formatos de imagem e com uma quantidade expressiva de dados.

4. Conclusões

Com base no exposto pode-se afirmar que as imagens SAR R99-B, ao serem utilizadas em conjunto às imagens ópticas, adicionaram informação valiosa melhorando a classificação final obtida através da abordagem orientada a objetos utilizada neste trabalho.

A abordagem de classificação orientada a objetos (OBIA) mostrou-se capaz de integrar as diferentes fontes de dados, quer sejam as imagens de diferentes sensores e ainda proporcionou uma análise exploratória dos melhores atributos para serem utilizados na obtenção de classificações de qualidade “Muito Boa” e “Excelente”, com coeficientes Kappa próximos ou acima de 0,8.

Agradecimentos

Os autores agradecem à Empresa Imagem por ter cedido gentilmente as imagens QuickBird-2 utilizadas; ao IEAV por ter cedido as imagens SAR R99-B; ao Cleber Gonzáles de Oliveira e à Bárbara Maria Giacom Ribeiro pelo procedimento de ortoretificação; à Embrapa e ao INPE pelos recursos de suporte à pesquisa.

Referências Bibliográficas

- HARALICK, R.M. Statistical and structural approaches to texture. **Proceedings** of the IEEE. v. 67, n. 5, p. 786-804. May 1979.
- KUPLICH, T.M.; CURRAN, P.J., Estimating texture independently of tone in simulated images of forest canopies. 2003. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 11, 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. Artigos, p. 2209-2216. CD-ROM, On-line. ISBN 85-17-00017-X. Disponível em: <http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2002/11.19.09.53/doc/16_473.pdf>. Acesso em: 03.out.2010.
- PINGXIANG, L.; SHENGHUI, F. SAR image classification based on its texture features. **Journal Geo-Spatial Information Science**. Publisher Wuhan University of Technology. On-line. ISSN 1993-5153. v.6, n.3, September, 2003. DOI 10.1007/BF02826887. p.16-19.
- PINHO, C.M.D; FEITOSA, F.F.; KUX, H.J.H. Classificação automática de cobertura do solo urbano em imagem IKONOS: comparação entre a abordagem pixel-a-pixel e orientada a objetos. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12, 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 4217-4224. CD-ROM, On-line. ISBN 85-17-00018-8. Disponível em: <<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.19.17.58/doc/4217.pdf>>. Acesso em: 01.jun.2010.
- RAT. **Radar Tools**. v.0.20. Software. 2008.
- RENNÓ, C.D.; FREITAS, C.C.; SANT'ANNA, S.J.S. A system for region image classification based on textural measures. In: In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 9, 1998, Santos. **Anais...** São José dos Campos: INPE, 1998. Artigos, p. 1195-1202. CD-ROM. On-line. ISBN 85-17-00015-3. Disponível em: <http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.11.14.26/doc/10_211o.pdf>. Acesso em: 01.jun.2010.
- SCHMIDT, M., KEIL, M., SCALES, D.R., DOS SANTOS, J.R., & KUX, H. Investigation of deforestation dynamics and land use changes by ERS-1 SAR data in Rondonia, Brazil. The Use and Applications of ERS in Latin America, **Proceedings** of an International seminar held in Vina del Mar, Chile, 25-29 November 1996. Ed. T.D. Guyenne. ESA SP-405. Paris: ESA, 1997. p.45-52. Disponível em: <http://articles.adsabs.harvard.edu>. Acesso em: 20.jun.2009.