

Comparação entre classificação contextual e classificação por regiões para mapeamento de uso e cobertura da terra na região da Floresta Nacional de Tapajós - PA (FLONA): utilizando imagens polarimétricas em banda L

Sumaia Resegue Aboud Neta ¹
Luciano Vieira Dutra ¹
Graziela Balda Scofield ¹
Rogerio Galante Negri ¹
Corina da Costa Freitas ¹
Daniel Andrade ¹

¹ Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12245-970 - São José dos Campos - SP, Brasil
{sumaia, dutra, graziela, rogerio, corina}@dpi.inpe.br
andrade@dsr.inpe.br

Abstract. The ALOS PALSAR (Phased Array type L-band Synthetic Aperture Radar) sensor can provide full polarimetric data (HH, HV and VV) for scientific purposes. Dutra et al.(2008) showed that, from the three possible channels, HH-HV channels presented better classification results when the following five classes are used: primary forest, secondary forest, bare soil, agriculture and degraded forest. This study is extending the former work by increasing the number of classes, including now pasture and dirty pasture, and testing if contextual classification can improve the overall accuracy. The results showed that the contextual classification does improve the per point classification results, however not as good as region classification when SEGSAR segmentation is used. Region based classification, particularly the one developed to take in account as much as possible the radar statistical behavior, performed better for VV-HV channels with 98.6% of overall accuracy using gamma filter on image and 92.7% without gamma filter on image. Comparing this study with Dutra et al.(2008), it was possible to observe that the overall accuracy was better and the better channels are different, with only two classes more, which shows that the best channels set is totally dependent on a particular set of classes being considered. So, the best dual polarization depends on the desired land use application, but the HV channels seems to be always chosen. The presence of HV channel in the dual polarization products provide the better combinations for general mapping of the rain forest problem.

Palavras-chave: remote sensing, polarimetric, MAXVER-ICM, Bhattacharyya, ALOS/PALSAR, sensoriamento remoto, polarimétrico.

1. Introdução

As florestas tropicais abrigam grande parte da diversidade natural e cultural do planeta, além de cumprirem um papel importante nos ciclos hidrológicos e climáticos. No Brasil, a região de floresta tropical abriga uma área aproximada de 5.090 milhões de Km², correspondendo cerca de 58,94% do território brasileiro (IBGE, 2008), e, assim como as áreas de floresta tropical de outros países, vem passando por um intenso processo de alteração do uso do solo devido à expansão da fronteira agrícola. Este processo pode contribuir com mudanças no clima, alterações no ciclo hidrológico e aceleração do escoamento superficial, colocando em risco a sua diversidade cultural e biológica.

O uso de dados ambientais, adquiridos por intermédio de satélites, tem permitido estudos com maior profundidade de investigação e, principalmente, com maior confiabilidade. Em vista disso, tem sido realizado um grande esforço, pela comunidade científica mundial, em pesquisas de monitoramento ambiental por sensores ópticos e de microondas.

Os sensores ópticos são de mais fácil interpretação, porém, extremamente vulneráveis à visibilidade atmosférica. Já os sensores de microondas, devido à independência das condições de iluminação solar e a capacidade de obtenção de imagens sob as mais variadas condições meteorológicas, têm se mostrado uma ferramenta útil no processo de caracterização, inventário e monitoramento florestal. Assim, o sensoriamento remoto por microondas tem

vido muito útil no mapeamento e monitoramento de florestas, visto que as imagens de radar não são afetadas com a cobertura de nuvens, sendo eficiente, por exemplo, no mapeamento de áreas de florestas tropicais as quais em geral estão em regiões onde a cobertura de nuvens é deveras crítica.

Para a eficiente extração de informações de imagens de radar se faz necessária a aplicação de técnicas específicas. Apesar da plataforma orbital SAR ser capaz de integrar diversos produtos polarimétricos, o modo operacional possui algumas limitações, ou seja, o modo com todas as polarizações muitas vezes se torna restrito. Assim, devido ao fato de muitas vezes o modo operacional normal do satélite ser não polarimétrico, este artigo visa estudar o quanto o uso de toda informação polarimétrica dos dados PALSAR (HH, HV e VV, sem informação de fase) podem melhorar ou não a acurácia da classificação em comparação com produtos padrões, como o canal HH (no caso do JERS-1) ou produtos de polarização dual HH-HV. Logo, é verificado se há perda significativa de informação no mapeamento de cobertura terrestre com dados PALSAR utilizando classificação supervisionada com o intuito de se discriminar alterações de uso e cobertura do solo como: floresta primária, secundária, solo nu, agricultura, florestas degradadas, pasto e pasto sujo com perda mínima de informação em função dos canais utilizados.

2. Materiais e Métodos

Devido à grande gama de trabalhos realizados na região pelo INPE, assim como a disponibilidade de imagens complexas SAR do radar ALOS/PALSAR, bem como dados relativos a trabalhos de campo e a diversidade das classes de ocupação do solo existentes como florestas primárias, pastagem e vegetação em diversos estágios de regeneração, a região da Floresta Nacional de Tapajós (FLONA) foi escolhida como área de estudo.

2.1 Área de Estudo

A Floresta Nacional do Tapajós (FLONA), unidade de conservação federal criada pelo Decreto N.º 73.684 – de 19 de fevereiro de 1974, abrange uma área aproximada de 544 mil hectares, localizados em terras de quatro municípios: Aveiro, Belterra, Rurópolis e Placas no oeste do estado do Pará (IBAMA, 2004). Tem como limite norte a área urbana do município de Belterra, a leste a rodovia BR 163- Santarém/Cuiabá, a oeste o Rio Tapajós e ao sul os rios Tinga e Cupari. A área de estudo está localizada no sul da cidade de Santarém no estado do Pará, entre as latitudes Sul 02° 39' 26" a Sul 03° 31' 24" e longitude Oeste 54° 37' 58" a Oeste 55° 14' 22", como ilustrado na Figura 1.




Figura 1. Imagem LANDSAT TM da área de estudo na composição colorida (5)R, (4)G, (3)B

O relevo varia de plano a suavemente ondulado com altitude máxima de 280m. O período de chuvas inicia em Dezembro e termina em Junho, sendo o volume médio anual de precipitação de 1911 mm. A vegetação é composta basicamente por florestas ombrófilas e por algumas áreas de floresta secundária em diferentes estágios de sucessão (Shimabukuro et al., 1997).

A ocupação desta área se dá pela agricultura de subsistência e pecuária e nos últimos anos vem se alastrando o cultivo de soja (Cohenca, 2005).

2.2 Material Utilizado

2.2.1 Dados de microondas

Utilizou-se uma cena multipolarizada em amplitude (PLR nível 1.5) do radar ALOS/PALSAR adquirida em 21 de Outubro de 2006. Também foram utilizados dados de campo obtidos em Outubro de 2005, os quais foram atualizados, com o intuito de refletir mudanças de cobertura e uso do solo após um ano, pela diferença de interpretação visual de cenas LANDSAT-5 TM adquiridas em 21 de Agosto de 2006.

2.2.2 Softwares utilizados

Os aplicativos utilizados para o processamento dos dados foram: ENVI 4.3, SPRING 4.3 e SEGSAR (Sousa Jr., 2005). O software ENVI foi utilizado para o registro das imagens e algumas classificações, o SEGSAR para segmentação das mesmas, as quais posteriormente foram importadas para o software SPRING onde se realizou os demais processamentos digitais de imagens.

2.3 Metodologia

Na metodologia utilizada para segmentação e classificação de uso e cobertura da terra na região da FLONA com dados polarimétricos PALSAR, foram utilizados os seguintes classificadores supervisionados: classificador estatístico de Máxima Verossimilhança Gaussiana (MAXVER) juntamente com o algoritmo iterativo ICM, e classificador por regiões de Distância de Bhattacharyya.

Todas as classificações foram realizadas com a imagem ALOS/PALSAR original e filtrada através de um filtro Gamma 5x5, com o intuito de se comparar os resultados das classificações. Como o método de classificação utilizado é supervisionado, utilizaram-se regiões de interesse como pontos de treinamento para a classificação, sendo que esses dados foram coletados em campo.

O classificador de máxima verossimilhança é um método de classificação *pixel a pixel* no qual dado uma imagem com N *pixels*, cada *pixel* (descrito pelo seu vetor de atributos x) será classificado como sendo da classe ω_j se

$$g_j(x) > g_k(x) \text{ para todo } j \neq k, \quad (1)$$

onde g_j é denominada função discriminante para a classe ω_j e j, k varia de 1 até o número total de classes da imagem.

Para o classificador MAXVER, onde os dados seguem uma distribuição gaussiana multivariada, a função discriminante pode ser definida como:

$$g_j(x) = -\frac{1}{2}(x - m_j)^t \Sigma_j^{-1}(x - m_j) - \frac{1}{2} \ln |\Sigma_j| + \ln P(\omega_j), \quad (2)$$

onde m_j e Σ_j correspondem ao vetor de média e a matriz de covariância e $P(\omega_j)$ é a probabilidade a priori da classe j . As médias e matrizes de covariância das classes de interesse são estimadas a partir de amostras conhecidas. As probabilidades a priori são geralmente consideradas iguais e desprezadas no cálculo da função de comparação (Dutra e Huber, 1999).

No entanto, para melhorar o resultado da classificação é necessário um classificador que além de considerar o vetor de observações do *pixel*, incorpore a informação da vizinhança deste *pixel*. Um desses classificadores é o ICM (Correia et al., 1998), o qual se baseia na

teoria de campos markovianos. Assim, considerando iguais as probabilidades a priori de cada classe, a função discriminante pode ser definida por:

$$g_j(x) = -\frac{1}{2}(x - m_j)^t \Sigma_j^{-1}(x - m_j) - \frac{1}{2} \ln |\Sigma_j| + \beta \#\{t \in \delta_x : \omega_t = \omega_x\}, \quad (3)$$

onde β é um parâmetro real que quantifica a influência das classes vizinhas, sendo estimado iterativamente, $\#$ representa o número de elementos de um conjunto, t denota a coordenada de um *pixel* e δ_x é o conjunto de coordenadas em torno da posição de x .

Já o classificador supervisionado por regiões da medida de distância de Bhattacharyya, classifica a imagem segmentada e tem por intuito medir a separabilidade estatística entre um par de classes espectrais, sendo assim através desta tem-se a distância média entre as distribuições de probabilidades de classes espectrais. Essa distância média é calculada da seguinte maneira (Richards, 1995):

$$BD(m_i, m_j) = \frac{1}{8}(m_i - m_j)^t \left\{ \frac{\Sigma_i + \Sigma_j}{2} \right\}^{-1} (m_i - m_j) + \frac{1}{2} \ln \left\{ \frac{|\Sigma_i + \Sigma_j|}{2 \left[|\Sigma_i|^{1/2} + |\Sigma_j|^{1/2} \right]} \right\}^{-1}, \quad (4)$$

onde as classes i e j são assumidas por terem distribuição normalmente distribuída com média e covariâncias de m_i e m_j , Σ_i e Σ_j respectivamente. Porém este classificador por ser de regiões requer como parâmetro uma imagem segmentada, sendo utilizados dois métodos de segmentações: um pelo SPRING (Câmara et al., 1996) e outro através do segmentador multiníveis SEGSAR (Souza Jr., 2005). Os métodos foram utilizados com o intuito de se avaliar os possíveis resultados da classificação final e conseqüentemente a existência ou não de perda de informações devido aos canais polarimétricos utilizados.

A técnica utilizada pelo SPRING foi o “crescimento de regiões”, onde através da segmentação particiona-se a imagem em regiões que correspondem às áreas de interesse da aplicação. Assim ocorre o agrupamento de dados, no qual somente as regiões espacialmente adjacentes podem ser agrupadas. Cada *pixel* é inicialmente rotulado como uma região distinta e um critério de similaridade baseado em um teste estatístico de hipótese entre as médias das regiões é calculado para cada par de regiões. Os limiares de similaridade e de área mínima foram definidos em 1 e 40m² respectivamente.

Já o segmentador hierárquico e multi-nível SEGSAR é um segmentador híbrido que também utiliza técnicas de “crescimento de regiões”. Este segmentador é multi-banda e realiza teste de bordas, teste de homogeneidade para regiões e entre regiões, utilizando o método de compressão de imagem por pirâmide gaussiana (Souza Jr., 2005). Na segmentação realizada utilizou-se o modelo Cartoon (com nível de compressão 4), número equivalente de looks 4 e 5 (para imagem filtrada), similaridade de 1dB e área mínima de 40m². Assim, foram geradas classificações univariadas e bivariadas, onde os resultados foram avaliados a partir de amostras de teste pelo coeficiente kappa, acurácia global e testes de hipóteses.

3. Resultados

De posse dos pontos de treinamento para a classificação coletados em campo, utilizou-se as seguintes classes para classificação de uso e cobertura do solo na área de estudo: floresta primária, floresta secundária, solo nu, agricultura, florestas degradadas, pasto e pasto sujo, conforme evidenciado na Figura 2. As regiões sólidas representam amostras de treinamento, enquanto que as regiões hachuradas representam amostras de teste.

Na Tabela 1, encontra-se o desempenho do canal HH para as classificações MAXVER-ICM e Bhattacharyya (com segmentações SPRING e SEGSAR) nas imagens com filtro (S) e

sem filtro (N). Os valores presentes referem-se à acurácia da classificação e foram obtidos estatisticamente por meio da acurácia global e valor kappa.

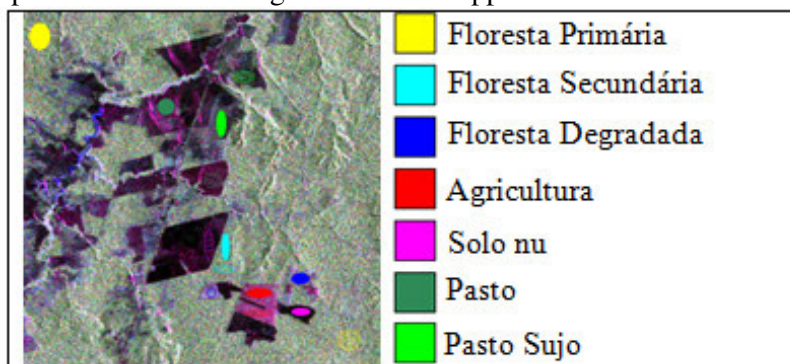


Figura 2. Imagem ALOS/PALSAR PLR 1.5 (obtida em 21 de Outubro 2006) com as classes utilizadas no estudo - Composição colorida (HH)R, (HV)G, (VV)B

Tabela 1. Acurácia da classificação da cobertura da terra PALSAR para o canal HH

Tipo de Classificador	Filtrada (S/N)	Acurácia (%)	Kappa
MAXVER	N	35.4	0.292
	S	50.1	0.424
ICM	N	42.2	0.370
	S	49.6	0.421
Bhattacharyya - SEGSAR	N	73.6	0.660
	S	58.3	0.500
Bhattacharyya - SPRING	N	36.3	0.271
	S	49.6	0.426

Pelos valores da tabela, verifica-se que o maior valor de índice kappa para o canal HH, foi obtido quando se utilizou a classificação Bhattacharyya – SEGSAR na imagem sem filtragem.

Foram realizados testes Z para igualdade dos coeficientes de concordância kappa sobre as imagens classificadas com o intuito de verificar se os valores obtidos eram estatisticamente iguais ao nível de significância de 5%. Constatou-se que a classificação de Bhattacharyya – SEGSAR é estatisticamente diferente de todas as outras classificações. Entretanto, o resultado da classificação MAXVER sobre a imagem filtrada é estatisticamente igual à classificação ICM com imagem filtrada ao nível de significância de 5%, assim como a classificação da imagem ICM com filtro e classificação Bhattacharyya – SPRING na imagem com filtro.

Na Figura 3 são apresentados os resultados dos melhores valores kappa do classificador pontual, contextual e por regiões, os quais foram respectivamente MAXVER com imagem filtrada, ICM com imagem filtrada e classificação Bhattacharyya – SEGSAR.




Figura 3. Resultados das melhores classificações utilizando o canal HH: (a) MAXVER com filtro Gamma (b) ICM com filtro Gamma, (c) Bhattacharyya - SEGSAR sem filtro

Analisando os resultados acima, classes da Figura 2 e matriz de confusão, verificamos que na classificação MAXVER houve uma considerável confusão de floresta primária com agricultura e floresta secundária, no entanto, o solo nu foi bem classificado assim como áreas de agricultura. Na classificação ICM na imagem filtrada, verifica-se que as classes de solo nu, pasto e pasto sujo foram bem classificadas, enquanto que houve uma considerável confusão na classificação de floresta primária com pasto, floresta degradada e floresta secundária. Já na classificação através de Bhattacharyya – SEGSAR na imagem sem filtro, a agricultura, solo nu e pasto foram bem classificados, enquanto houve uma considerável confusão das outras classes presentes em relação à agricultura e floresta primária.

Na Tabela 2 encontram-se os desempenhos dos canais de polarização dual HH-HV e VV-HV para as classificações MAXVER-ICM e Bhattacharyya (com segmentações SPRING e SEGSAR).

Tabela 2. Acurácia da classificação da cobertura da terra PALSAR para os canais de polarização dual HH-HV e VV-HV

Tipo de Classificador	Filtrada (S/N)	HH-HV		VV-HV	
		Acurácia(%)	Kappa	Acurácia (%)	Kappa
MAXVER	N	62.9	0.563	62.9	0.561
	S	67.7	0.633	86.3	0.831
ICM	N	79.3	0.752	74.8	0.800
	S	68.9	0.648	88.4	0.857
Bhattacharyya - SEGSAR	N	86.1	0.829	92.7	0.911
	S	88.4	0.859	98.6	0.983
Bhattacharyya (SPRING)	N	81.0	0.773	81.9	0.784
	S	88.0	0.854	86.2	0.835

Comparando todos os valores de kappa da Tabela 2, verificamos que para os canais HH-HV a melhor classificação ocorreu quando se utilizou Bhattacharyya – SEGSAR na imagem filtrada. Do mesmo modo, o maior valor de kappa para VV-HV também foi obtido utilizando-se Bhattacharyya – SEGSAR na imagem filtrada. Entretanto, as duas classificações são consideradas estatisticamente diferentes a um nível de significância de 5%.

Na Tabela 3 encontra-se a matriz de confusão do melhor resultado encontrado (Bhattacharyya – SEGSAR com filtro) utilizando os canais de polarização dual, para as classes floresta secundária(FS), pasto(P), floresta degradada(FD), pasto sujo(PS), floresta primária(FP), solo nu(SN) e agricultura(AG).

Tabela 3. Matriz de confusão do melhor valor kappa encontrado para os canais de polarização dual (utilizando classificação por regiões na imagem filtrada e segmentação SEGSAR)

Classes	HH-HV (88.4% de acurácia global)								VV-HV (98.6% de acurácia global)							
	FS	P	FD	PS	FP	SN	AG	Total	FS	P	FD	PS	FP	SN	AG	Total
FS	207	0	0	0	270	0	0	477	468	0	30	0	0	0	0	498
P	0	812	0	0	0	0	0	812	0	812	0	0	0	0	0	812
FD	0	0	288	47	0	0	0	335	0	0	258	0	0	0	0	258
PS	0	0	0	729	0	0	0	729	0	0	0	776	0	0	0	776
FP	305	0	0	0	1264	0	0	1569	44	0	0	0	1534	0	0	1578
SN	0	0	0	0	0	886	0	886	0	0	0	0	0	886	0	886
AG	0	0	0	0	0	0	552	552	0	0	0	0	0	0	552	552
Total	512	812	288	776	1534	886	552	5360	512	812	288	776	1534	886	552	5360

Analisando as classificações MAXVER na imagem sem filtro dos canais HH-HV, verificou-se que esses resultados são estatisticamente iguais a classificação MAXVER na

imagem sem filtro dos canais VV-HV e ICM com imagem filtrada dos canais HH-HV ao nível de significância de 5%. O mesmo ocorrendo para classificação Bhattacharyya – SEGSAR nos canais HH-HV, MAXVER com filtro nos canais VV-HV e classificação Bhattacharyya – SPRING nas imagens com filtro dos canais VV-HV.

Comparando as classificações do canal HH com as classificações de polarização dual, os valores de kappa das classificações Bhattacharyya – SEGSAR podem ser considerados estatisticamente iguais à classificação ICM com imagem filtrada nos canais HH-HV, ao nível de significância de 5%. Analisando as Tabelas 1 e 2, verifica-se que os resultados da classificação de polarização dual HH-HV e VV-HV mostraram ter uma melhor acurácia na classificação em relação ao resultado dos canais HH. Além disso, em geral as classificações com imagens filtradas mostraram ter um maior valor de kappa.

A classificação Bhattacharyya – SEGSAR mostrou ser a melhor classificação para as imagens filtradas utilizando os canais HH-HV e VV-HV e imagem sem filtro utilizando o canal HH.

No geral, os classificadores na polarização dual VV-HV apresentaram melhores valores kappa e acurácia global. Estudos de Dutra et al. (2008) mostraram que os canais HH-HV foram os responsáveis pelos melhores resultados de classificação quando foram utilizadas as mesmas classes deste trabalho, porém sem a presença de pasto e pasto sujo.

Na Figura 4 são apresentados os melhores resultados do melhor canal dual, no caso VV-HV, de acordo com os valores kappa para o classificador pontual, contextual e por regiões, os quais foram respectivamente MAXVER com imagem filtrada, ICM com imagem filtrada e classificação Bhattacharyya – SEGSAR com filtro.




Figura 4. Resultado das melhores classificações de polarização dual (obtidas através do canal VV-HV): (a) MAXVER com filtro Gamma (b) ICM com filtro Gamma, (c) Bhattacharyya - SEGSAR com filtro Gamma

Observando os resultados acima, classes da Figura 2 e matriz de confusão, verificamos que para os classificadores MAXVER e ICM sobre a imagem com filtro as classes de agricultura, solo nu, pasto, pasto sujo e floresta degradada foram bem classificadas, entretanto a classe de floresta primária e secundária apresentou uma pequena confusão. A classificação Bhattacharyya – SEGSAR na imagem filtrada no geral mostrou uma boa classificação para todas as classes envolvidas (acurácia de 98.6%), o que pode ser evidenciado pela matriz de confusão da Tabela 3, onde somente as classes floresta secundária e degradada não obtiveram 100% de acerto. Já para os canais HH-HV (acurácia de 88.4%) existiu uma ligeira confusão na classificação de floresta secundária com primária e pasto sujo com floresta degradada.

4. Conclusões

Utilizando polarização dual foi possível obter uma melhoria na classificação de uso e cobertura da terra em comparação com polarização de apenas um canal (como o HH do JERS-1). A combinação dos dois canais formando a polarização dual HH-HV e VV-HV fez com que as regiões de interesse fossem melhores classificadas e o erro de classificação menor

possível. Os resultados evidenciaram que a classificação contextual (ICM) melhora a classificação pontual (MAXVER), no entanto a acurácia do resultado não foi melhor do que a classificação por regiões (Bhattacharyya) quando a segmentação pelo SEGSAR foi utilizada.

O produto da polarização dual VV-HV obteve a melhor combinação para o mapeamento florestal da área de estudo mediante as classes: floresta primária, secundária, solo nu, agricultura, florestas degradadas, pasto e pasto sujo, diferentemente do estudo de Dutra et al.(2008) onde a melhor combinação foi obtida nos canais HH-HV e o valor da acurácia global foi menor em relação ao encontrado neste trabalho. No entanto, o conjunto de classes não levava em consideração as classes pasto e pasto sujo além de classificações contextuais.

Mediante os estudos realizados, conclui-se que sem considerar a informação de fase, a presença do canal HV nos produtos de polarização dual providencia melhores resultados no mapeamento de florestas tropicais. Porém, a melhor polarização dual depende da aplicação que se deseja evidenciar no uso e cobertura do solo. Logo, novos estudos que considerem a informação polarimétrica da fase tornam-se relevantes no sentido de se obter mais comparações com os resultados encontrados.

Agradecimentos

Os autores agradecem o suporte financeiro do CNPq (3284469/2006-0, 304274/2005-4 e 305546/2003-1), CAPES, FAPESP (2007/02139-5), e JAXA (JAXA-PI 108).

5. Referências Bibliográficas

Câmara, G., Souza, R. C. M., Freitas, U. M., Garrido, "SPRING: Integrating remote sensing and GIS by object-oriented data modelling" **Journal of Computers & Graphics**, v. 20, n. 3, p. 395-403, May-Jun 1996.

Cohenca, D. **A expansão da fronteira agrícola e sua relação com o desmatamento detectado em imagens Landsat TM e ETM+ na região norte da BR-163, Pará entre os anos de 1999 a 2004**. Lavras, MG, 2005. 59 f. Monografia (Pós-Graduação Lato Sensu em Gestão e Manejo Ambiental em Sistemas Florestais) - FAEPE, UFLA. Disponível em: <http://www.ibama.gov.br/flona_tapajos/download.php?id_download=136>. Acesso em: 28 jan. 2008.

Correia, A. H., Freitas, C. C., Frery, A. C., Sant'Anna, S. J. S. "A user friendly statistical system for polarimetric SAR image classification". **Revista de Teledetección**, v. 1, n. 3, p.79-93, 1998.

Dutra, L. V., Huber, R. Feature Extraction and Selection for ERS-1/2 InSAR Classification. **International Journal of Remote Sensing**, v. 20, n.5, p. 993-1016. May 1999.

Dutra, L. V., Scofield, G. B., Aboud Neta, S. R, Negri, R. G., Freitas, C. C., Silva, D. L. A. Alos PALSAR polarimetric data for land use/land cover classification in Amazon. Submitted In: **XIV Brazilian Remote Sensing Symposium**, Natal, Rio Grande do Norte, Brasil, 2008.

IBAMA (Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis). **Decreto nº 73.684**: Decreto de criação da FLONA do Tapajós, 2004. Disponível em: <http://www.ibama.gov.br/flona_tapajos/index>. Acesso em: 12 ago. 2006.

Instituto Brasileiro de Geografia e Estatística (IBGE). Área Territorial Oficial. Disponível em: <<http://www.ibge.gov.br/home/geociencias/areaterritorial/principal.shtm?c=5>>. 2008. Acesso em: 20 fev 2008.

Richards, J. A., **Remote Sensing Digital Image Analysis: a introduction**, 2 ed., Springer-Verlag, Germany, 1995

Shimabukuro, Y. E., Mello, E. M. K.; Moreira, J. C., Duarte, V. **Segmentação e classificação da imagem sombra no modelo de mistura para mapear desflorestamento na Amazônia**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 1997 16p. (INPE – 6147-PUD/029)

Souza, Jr., **Segmentação multi-níveis e multi-modelos para imagens de radar e ópticas**. Tese Doutorado em Computação Aplicada, Instituto Nacional de Pesquisas Espaciais, 2005.