

Classificação de cobertura da terra utilizando dados óticos e de radares de abertura sintética

Mariane Souza Reis¹

Eliana Pantaleão²

Sidnei João Siqueira Sant'Anna¹

Luciano Vieira Dutra¹

¹Instituto Nacional de Pesquisas Espaciais – INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
{reis, sidnei, dutra}@dpi.inpe.br

²Universidade Federal de Uberlândia
epantaleao@ufu.br

Abstract. The availability of optical data is subject to weather conditions and lighting of the scene. Images from Synthetic Aperture Radar (SAR) can be obtained almost independently from weather conditions, what renders this data a strong candidate to be used in cover classification studies. Also, since these two different data are complementary, their combination can improve the results obtained with each separately. This work compares classification results from optical data, SAR data and optical-SAR fusion data and evaluates their performance for land cover identification. The study area is located in Belterra, state of Pará, in the Legal Amazon region. Different sets of data were used, including the original data and other texture attributes extracted from them. The aim of the study is to evaluate the use of optical, SAR data and the fusion of both for the assessment of the classifications and also the sensibility of the results to the variations induced by the selection of the training data. Results show that the use of SAR data together with optical data does not improve classification results when compared to the use of only optical data and the use of texture attributes of optical data may be interesting for only some cover classes. In the absence of optical data, texture attributes derived from filtered SAR data may be used instead, with less accurate results in general, although the classification of fallow agriculture areas is improved in comparison to that obtained from optical data.

Palavras-chave: region based classification, optical data, SAR data, data fusion, classificação baseada em regiões, dados óticos, dados SAR, fusão de dados.

1. Introdução

Segundo Bruzzone e Bovolo (2008), dados provenientes de sensores imageadores óticos têm recebido maior atenção pela comunidade de sensoriamento remoto. O sinal medido por esses sensores pode ser descrito por meio de um modelo de ruído gaussiano aditivo, o que possibilita um processamento relativamente simples dos dados para a aplicação de técnicas de processamento de imagens (BRUZZONE; BOVOLO, 2008). Além disso, esses dados são de fácil interpretação visual quando comparados a outros tipos de dados, além de possibilitar a caracterização espectral dos alvos, com informações que se relacionam com as características químicas, físicas e biológicas dos mesmos (JENSEN, 2009). No entanto, a coleta desses dados sofre restrições na presença de chuvas, nuvens, bruma e fumaça (PARADELLA et al., 2005). São também afetados pela presença de material particulado e variações na intensidade solar (PARADELLA et al., 2005).

Radares de Abertura Sintética (*Synthetic Aperture Radar* - SAR) são capazes de prover dados de forma quase que independente das condições da atmosfera e de forma independente da fonte solar (PARADELLA et al., 2005). A partir de dados SAR é possível extrair informações que se relacionam às variações texturais, dielétricas e estruturais do terreno. Nesses dados, o sinal registrado é fortemente afetado pela rugosidade e propriedades dielétricas dos alvos, ângulo de incidência local, tipo de espalhamento, reflexão de canto e polarização da onda eletromagnética (JENSEN, 2009; LEWIS; HENDERSON, 1998). No geral, observa-se maior dificuldade em se trabalhar com esses dados, seja por sua difícil interpretação visual, ou pela necessidade de técnicas mais eficientes de processamento e classificação. Um dos principais problemas ao se trabalhar com esses dados se relaciona à natureza coerente do sinal, que resulta

em um ruído multiplicativo conhecido como *speckle*. O *speckle* propicia a formação de áreas claras e escuras na imagem, dificultando a análise e contribuindo para uma definição menos nítida de formas e bordas se comparada com imagens óticas de resolução espacial comparável (ORSOMANDO et al., 2007). Dados SAR podem, ainda, possuir distorções geométricas induzidas pela topografia e o ângulo de imageamento, tais como a inversão do relevo, o encurtamento de rampa e o sombreamento (JENSEN, 2009), esse último também observado em imagens óticas.

Não obstante, observa-se um crescente interesse na utilização de dados SAR, principalmente em áreas como a Amazônia, onde a cobertura de nuvens é frequente durante grande parte do ano. Nessa região, em alguns anos, pode-se não obter imagens óticas com cobertura de nuvens aceitável para análise, enquanto em outros, há apenas uma ou duas imagens, geralmente da mesma época, que podem não ser suficientes ou adequadas para a análise. Além desse fator, esses dois tipos de dados citados possuem naturezas diferentes e registram propriedades dos distintas, sendo então, complementares e podendo ser utilizados em conjunto (PARADELLA et al., 2005).

Dada a importância em avaliar o potencial do uso de dados óticos, SAR ou da combinação desses, para estudos de uso e cobertura da terra, este trabalho tem como objetivo avaliar o potencial dados óticos, SAR e da fusão de ambos para a classificação da cobertura da terra na região do baixo Tapajós, considerando metodologia específica. Foram analisados diferentes conjuntos de dados óticos, SAR e um conjunto proveniente da fusão de ambos de forma a buscar melhorias na classificação de dados óticos e SAR pelo uso de atributos extraídos dessas imagens e avaliar se a fusão de dados representa melhoria significativa na classificação, quando comparada às demais.

2. Materiais e Métodos

A área de estudo desse trabalho corresponde aos arredores de um trecho da BR-163 (Rodovia Cuiabá-Santarém), que abrange parte da Floresta Nacional (FLONA) do Tapajós. Essa área de aproximadamente 412 km² se localiza na Amazônia Legal brasileira, no município de Belterra, no estado do Pará.

Foram utilizadas duas imagens para este trabalho: uma imagem do sensor *Thematic Mapper* (TM) do satélite LANDSAT5, datada de 29 de junho de 2010, e uma imagem oriunda do sensor *Phase Array L-Band Synthetic Aperture Radar* (PALSAR) do satélite *Advanced Land Observing System* (ALOS), de 21 de junho de 2010. A imagem LANDSAT5/TM foi disponibilizada pelo Instituto Nacional de Pesquisas Espaciais (INPE, 2013a), com 8 bits, 30 m de resolução espacial, correção radiométrica e correção geométrica de sistema, no sistema de projeção UTM (*Universal Transverse Mercator*) e datum WGS84 (*World Geodetic System 1984*). A imagem ALOS/PALSAR foi adquirida no modo *Fine Beam Dual* (FBD), ângulo de incidência de 38,7°, 32 bits, resolução espacial de aproximadamente 10 m em *range* e 4,5 m em azimute, com nível de processamento 1.1 (complexo e em *slant range*), nas polarizações HH e HV e com comprimento de onda de aproximadamente 23 cm (banda L) (JAXA, 2009; ESA, 2007).

Ambas as imagens foram ortorretificadas no *software* PCI 13.0, utilizando o modelo *rational function* (*Rational Function Model* - RFM), os dados do *Shuttle Radar Topography Mission* versão 4 (SRTM 4) como Modelo Digital de Elevação e pontos de controle obtidos em uma imagem ALOS/PALSAR FBD 1.5 de 30 de abril de 2008, disponível em IBGE (s.d). Em uma etapa prévia à ortorretificação, a imagem ALOS/PALSAR de 2010 foi geocodificada utilizando o *software* ASF MapReady versão 3.0, etapa na qual a imagem foi projetada para UTM WGS84, zona 21 sul e os pixels foram reamostrados para 15 por 15 m. Com esse processo, as imagens, originalmente em valores complexos, foram convertidas para amplitude.

A Figura 1 ilustra a localização da área de estudo, juntamente com os limites políticos e

geográficos da região. Nessa figura, também estão demonstrados os recortes das duas imagens, ortorretificadas, utilizadas para este trabalho.

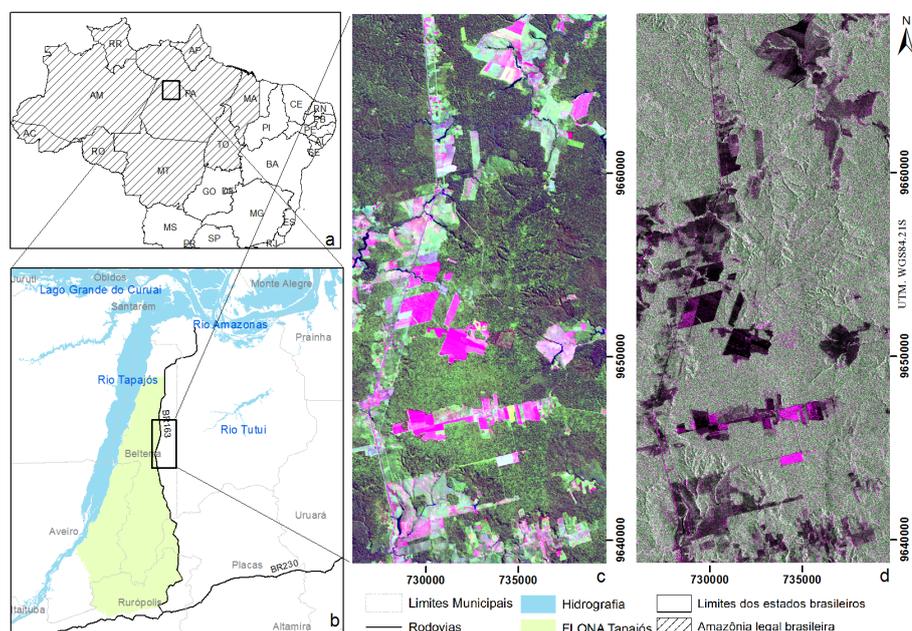


Figura 1. Localização da área de estudo: a) localização em relação à Amazônia Legal brasileira; b) localização em relação a limites políticos e geográficos; c) Imagem LANDSAT5/TM de 29 de junho de 2010, composição colorida 5(R)4(G)3(B); d) Imagem ALOS/PALSAR de 21 de junho de 2010, em amplitude, composição colorida HH(R)HV(G)HH(B).

As classes de cobertura foram definidas utilizando dados provenientes de trabalhos de campo realizados em setembro de 2009 e setembro de 2010, fotografias de 2008 presentes na biblioteca digital de fotos de campo da OBTE (Coordenação-Geral de Observação da Terra) (INPE, 2013b), as imagens citadas e dados do Projeto Mapeamento do Uso e Cobertura da Terra nas Áreas Deflorestadas da Amazônia Legal (TerraClass) (COUTINHO et al., 2013). Foram definidas 10 classes de cobertura da terra. São estas: Floresta Primária (FP), Floresta Degradada (FD), Vegetação Secundária Avançada (VS3), Vegetação Secundária Intermediária (VS2), Vegetação Secundária Inicial (VS1), Pasto Limpo (PL), Pasto Sujo (PS), Área Cultivada (AC), Área em Pousio (AP) e Solo Exposto (SE).

Tendo como base as dez classes de cobertura definidas e as imagens LANDSAT5/TM e ALOS/PALSAR do ano de 2010, foram gerados seis tipos de dados para classificação. Esses dados foram classificados utilizando o classificador baseado em regiões de mínima distância de Bhattacharyya e uma metodologia baseada em Monte Carlo. Ressalta-se que trabalhos como Aboud Neta (2009), Silva et al. (2011) e Scofield et al. (2010) demonstraram classificações de imagens SAR realizadas por meio desse classificador com altos valores de acurácia. Essas classificações foram então avaliadas, também com uma metodologia baseada em Monte Carlo e na análise da sensibilidade dessas classificações à variação do conjunto de treinamento (incerteza da classificação). Essas etapas estão ilustradas no fluxograma metodológico da Figura 2 e explicadas a seguir.

Dos seis dados utilizados para classificação, três foram definidos de forma independente das classes utilizadas. São estes os dados:

- (a) PALSAR: imagem ALOS/PALSAR após uma etapa de reescalonamento (divisão por 39,8107, de forma a possuir um *range* de valores similar à uma imagem FBD 1.5, para

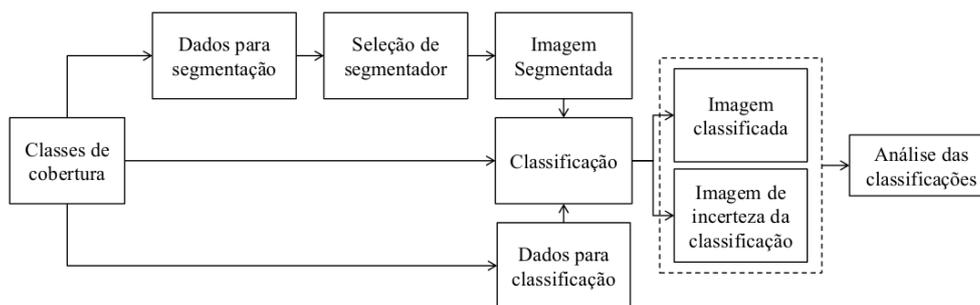


Figura 2. Fluxograma metodológico.

adequação de uso em alguns dos *softwares* utilizados);

- (b) PALSAR_SDNLM: dado PALSAR filtrado utilizando o filtro de *speckle* SDNLM (*Stochastic Distances Nonlocal Means*) desenvolvido por Torres et al. (2014), com tamanho de janela de filtragem de 5x5 pixels, tamanho do *patch* de 3x3 pixels e o nível de confiança dos testes estatísticos de 90%;
- (c) Fusão: fusão das bandas 1 a 5 e 7 da imagem LANDSAT5/TM e da primeira componente principal (calculada no *software* ENVI 4.8 utilizando matriz de correlação) do dados PALSAR_SDNLM (reamostrados para tamanho de pixel de 30 m) pela análise de componentes principais seletivos (*Selective Principal Component Analysis - SPC-SAR*), conforme demonstrado em Pereira (2012).

Os outros três dados utilizados para classificação foram definidos a partir das dez classes do nível mais detalhado. São estes:

- (a) TM: bandas 2,4 e 5 da imagem LANDSAT5/TM;
- (b) Atributos TM: atributos de textura calculados sobre o dado TM, utilizando o *software* ENVI 4.8, matriz de coocorrência e janelas de 5x5 pixels. São esses atributos: Média da banda 2, Média da banda 4 e Variância da banda 5;
- (c) Atributos PALSAR_SDNLM: atributos de textura calculados sobre o dado PALSAR_SDNLM, utilizando o *software* ENVI 4.8, e matriz de coocorrência. São esses atributos: Média da amplitude HH (janela de 13x13 pixels), Média da amplitude HV (janela de 13x13 pixels), Entropia da amplitude HH (janela de 15x15 pixels) e Segundo Momento da amplitude HH (janela de 15x15 pixels).

Como o objetivo desse trabalho é o de avaliar o potencial de dados óticos, SAR e da fusão de ambos para tarefas de classificação de cobertura da terra, optou-se por classificar cada tipo de dado de forma independente. Assim, de forma a buscar a segmentação ótima para cada dado, foram testados segmentadores com diferentes parametrizações.

Segmentou-se então o dado PALSAR utilizando o algoritmo MultiSeg (SOUSA JR, 2005) com diferentes parametrizações. De forma visual, escolheu-se a segmentação proveniente da parametrização com modelo de manchas, com similaridade de 1,0 db, área mínima de 20 pixels, nível de confiabilidade de 95% e nível de compressão igual a 5. Para os dados TM, Fusão e PALSAR_SDNLM, foram testados os segmentadores crescimento de regiões (TerraPixel 1.04), MultiSeg, o do *software* Idrisi Selva e o *Multiresolution Segmentation* (eCognition 8.0); todos com diferentes parametrizações. A segmentação adequada para o dado PALSAR_SDNLM foi escolhida de forma visual e trata-se da proveniente do Idrisi com tolerância de similaridade 40, tamanho de janela 3; peso do fator médio 0,5 e peso do fator de variância 0,5. As segmentações para os dados TM e Fusão foram escolhidas tendo com base o Índice Ponderado para Avaliação de Segmentação (*Weighted Index for Segmentation Evaluation - WISE*) proposto por REIS et al. (2014), sendo que o parâmetro de ponderação foi ajustado para o valor “1”. Para

os dados TM, a segmentação escolhida foi a proveniente do *Multiresolution Segmentation* com forma e compacidade 0,3 e parâmetro de escala 30. Para dados Fusão, a segmentação selecionada foi a obtida utilizando o *Multiresolution Segmentation* com forma e compacidade 0,3 e parâmetro de escala 35.

Os dados foram classificados utilizando o *Stochastic Minimum Distance Classifier - Bhattacharyya* (Classificador de Mínima Distância Estocástica - Bhattacharyya), do aplicativo em IDL *Region Based Classification Methods* (RBC), implementado por Negri et al. (2012), utilizando apenas suas respectivas segmentações, com exceção do dado Atributos TM, classificado com a segmentação de TM, e Atributos PALSAR_SDNLM, classificado com a segmentação de PALSAR_SDNLM. Cada dado foi classificado 100 vezes, com variação do sorteio das amostras de treinamento. Para cada variação dessas amostras, foram sorteados 300 pixels por classe das amostras de treinamento para os dados TM, Atributos TM e Fusão (imagens com resolução de pixel de 30 m) e 1200 pixels por classe para dados PALSAR, PALSAR_SDNLM e Atributos PALSAR_SDNLM (imagens com resolução de pixel de 15 m). Esses valores foram escolhidos em função do número de amostras disponíveis por classe. Na classificação final de cada dado, as regiões recebem o rótulo da classe mais frequente nas 100 classificações. Esse rótulo é denominado classe majoritária. Dessa etapa também são geradas as imagens de incerteza da classificação (IC), dada por $IC = 1 - n/t$, em que n é o número de vezes que a classe majoritária foi classificada e t é o número total de classificações.

Todas as classificações foram avaliadas por uma estratégia Monte Carlo. Foram sorteados, sem repetição, 100 pixels por classe das amostras de teste para os dados TM, Fusão e Atributos TM e 400 pixels por classe para PALSAR, PALSAR_SDNLM e Atributos PALSAR_SDNLM. Em seguida, foram calculados a matriz de confusão e o índice Kappa (global e por classe). Esse procedimento foi repetido 1000 vezes por classificação e os resultados analisados em função da média e desvio padrão desses valores. A avaliação da incerteza se deu por meio da média da imagem de incerteza.

3. Resultados

Os valores de Kappa Global e de Kappa Condicional (por classe) para cada tipo de dado estão apresentados na Tabela 1. Nessa tabela, os dados estão apresentados no formato $\mu \pm \sigma$, em que μ é a média dos 1000 valores calculados para o índice e σ o desvio padrão desses valores. Os maiores valores para cada índice estão destacados em negrito e valores negativos (classificações piores que se fossem feitas de forma aleatória) estão destacados em vermelho.

Como é possível verificar na Tabela 1, a classificação do dado TM apresentou valor de Kappa Global similar aos dos dados Atributos TM e Fusão, sendo que esses três dados que possuem componentes óticos apresentam valores de Kappa Global maiores que as dos dados que apresentam apenas componentes SAR. Ao se considerar apenas as classificações obtidas a partir de dados SAR, têm-se que a que possui maior Kappa Global é a obtida usando Atributos PALSAR_SDNLM. Quanto aos valores de Kappa Condicional, observa-se que a maioria dos melhores valores foram obtidos utilizando dados com componentes óticos. No entanto, com a utilização do dado Atributos PALSAR_SDNLM, obteve-se a melhor classificação no que se refere às classe AP e FD, essa última sendo similar às obtidas utilizando os dados Fusão e TM. Os valores negativos de Kappa Condicional para a classe VS1 com a utilização do dado TM se deve ao fato de as poucas amostras de teste dessa classe estarem localizadas em áreas de transição, que foram classificadas como PS ou VS2. Demais áreas de VS1, incluindo as regiões onde foram coletadas amostras de treinamento, estão corretamente classificadas.

Os valores de incerteza médio por classificação e por área classificada como determinada classe estão apresentados na Tabela 2. Observa-se que as classificações com menores valores de incerteza são as obtidas utilizando dados TM, Atributos TM e Atributos PALSAR_SDNLM.

Tabela 1. Valores médios de Kappa Global e Condicional e desvio padrão.

Kappa	TM	Atributos TM	PALSAR	PALSAR_ SDNLM	Atributos PALSAR_SDNLM	Fusão
Global	0,74 ± 0,01	0,73 ± 0,01	0,32 ± 0,01	0,33 ± 0,01	0,50 ± 0,01	0,74 ± 0,01
da classe SE	1,00 ± 0,00	1,00 ± 0,00	0,45 ± 0,01	0,54 ± 0,01	0,82 ± 0,02	1,00 ± 0,00
da classe AP	0,80 ± 0,03	0,79 ± 0,03	0,80 ± 0,03	0,77 ± 0,02	1,00 ± 0,00	0,75 ± 0,03
da classe AC	0,81 ± 0,03	0,76 ± 0,03	0,26 ± 0,04	-0,11 ± 0,00	0,67 ± 0,02	0,99 ± 0,01
da classe PL	0,86 ± 0,04	0,97 ± 0,02	0,11 ± 0,02	0,20 ± 0,01	0,33 ± 0,02	0,68 ± 0,04
da classe PS	0,45 ± 0,01	0,70 ± 0,02	0,46 ± 0,01	0,55 ± 0,01	0,44 ± 0,01	0,58 ± 0,02
da classe VS1	-0,11 ± 0,00	0,96 ± 0,03	0,38 ± 0,02	0,15 ± 0,05	0,38 ± 0,03	1,00 ± 0,00
da classe VS2	0,64 ± 0,03	0,37 ± 0,02	0,09 ± 0,01	0,07 ± 0,01	0,35 ± 0,01	0,49 ± 0,03
da classe VS3	0,94 ± 0,03	0,84 ± 0,04	0,15 ± 0,02	0,16 ± 0,01	0,22 ± 0,02	0,53 ± 0,04
da classe FD	0,74 ± 0,02	0,50 ± 0,05	0,29 ± 0,03	0,41 ± 0,02	0,74 ± 0,02	0,73 ± 0,02
da classe FP	0,91 ± 0,02	0,99 ± 0,01	0,85 ± 0,03	0,35 ± 0,03	0,48 ± 0,01	0,99 ± 0,01

Em que SE=Solo Exposto; AP=Área em Pousio; AC=Área Cultivada; PL=Pasto Limpo; PS=Pasto Sujo; VS1=Vegetação Secundária Inicial; VS2=Vegetação Secundária Intermediária; VS3=Vegetação Secundária Avançada; FD=Floresta Degradada e FP=Floresta Primária.

Esses valores ocorrem principalmente em função dos altos valores de incerteza para áreas classificadas como vegetação secundária (VS1, VS2 e VS3) ou floresta (FP e FD) para os dados PALSAR e PALSAR_SDNLM. Nesse sentido, observa-se que a aplicação de filtro de *speckle* e posteriormente de janelas para cálculo de textura (ambos processos que homogenizam os valores entre pixels vizinhos) resultam em valores de incerteza progressivamente menores para essas classes, ou seja, esses a classificação desses dados são menos sensíveis à variação das amostras de treinamento. Os valores de incerteza para as classes VS1, VS2, VS3, FP e FD também são maiores para a classificação do dado Fusão que as dos dados TM e Atributos TM.

Tabela 2. Valores médios de incerteza, em porcentagem, por tipo de dado e área classificada como cada classe.

Dado	TM	Atributos TM	PALSAR	PALSAR_ SDNLM	Atributos PALSAR_SDNLM	Fusão
Imagem	2,8	2,5	13,7	8,2	2,9	4,4
classe SE	4,8	1,4	0,8	0,0	0,8	2,4
classe AP	6,8	4,5	4,6	0,5	1,7	2,5
classe AC	0,0	0,1	0,5	0,0	0,0	11,4
classe PL	3,6	6,6	2,0	1,8	5,9	1,9
classe PS	1,3	4,5	1,9	0,9	1,7	3,5
classe VS1	1,7	6,2	15,7	11,7	5,6	8,3
classe VS2	5,5	1,7	18,1	7,8	2,6	7,2
classe VS3	7,1	3,6	9,3	4,9	3,1	8,3
classe FD	4,1	4,2	25,6	14,8	6,2	10,4
classe FP	0,8	1,4	32,6	20,6	1,8	1,9

Em que SE=Solo Exposto; AP=Área em Pousio; AC=Área Cultivada; PL=Pasto Limpo; PS=Pasto Sujo; VS1=Vegetação Secundária Inicial; VS2=Vegetação Secundária Intermediária; VS3=Vegetação Secundária Avançada; FD=Floresta Degradada e FP=Floresta Primária.

Considerando os valores de Kappa Condicional apresentados na Tabela 1 em conjunto com os valores de incerteza (Tabela 2), tem-se que com a utilização do dado PALSAR_SDNLM, as classes SE, AP, AC, PL e PS apresentam os menores valores de incerteza. Essas classes apresentaram, também baixos valores de Kappa Condicional. Ou seja, independentemente da variação das amostras de treinamento, polígonos pertencentes a essas classes foram classificados erroneamente com grande frequência. Ao utilizar a incerteza da classificação como critério de desempate, a melhor classificação de SE corresponde àquela do dado Atributos TM, da classe

FD à classificação do dado TM. Valores de Kappa Condicional e de incerteza da classe FP são apenas pouco melhores para a classificação do dado Atributos TM que a do dado Fusão.

Para exemplificação, a Figura 3 apresenta as classificações de cobertura dos dados TM e Atributos PALSAR_SDNLM, bem como as respectivas imagens de incerteza das classificações. Nota-se que na classificação de cobertura do dado Atributos PALSAR_SDNLM há manchas de vários tipos de vegetação secundária e floresta degradada onde na classificação do dado TM há áreas corretamente classificadas como pastagens ou floresta primária. Além disso, na imagem de incerteza da classificação do dado TM, os polígonos de maiores valores estão concentrados na região sul da imagem (área de concentração de FD), enquanto que na de Atributos PALSAR_SDNLM os polígonos com maiores valores de incerteza estão espalhados pela imagem.

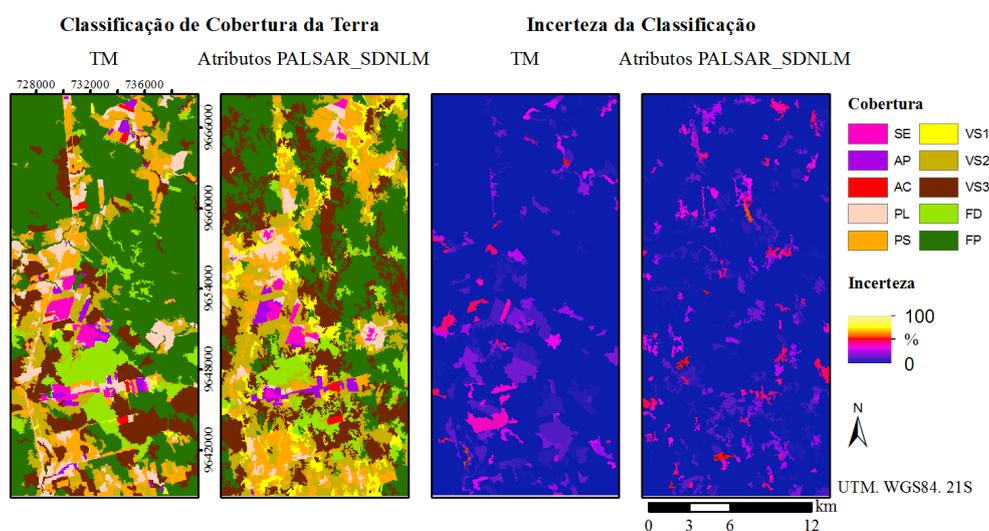


Figura 3. Classificações de cobertura e incerteza das classificações dos dados TM e Atributos PALSAR_SDNLM.

4. Conclusões

De forma global e considerando a metodologia proposta e dados os custos envolvidos no processamento necessário para se obter classificações de cobertura da terra utilizando atributos de textura extraídos de imagens óticas ou de fusão de imagens óticas e SAR, não observou-se melhoras na exatidão que justifiquem o uso de algum desses dados em substituição às bandas selecionadas da imagem LANDSAT5/TM original. Em casos em que dados óticos estejam indisponíveis, recomenda-se a utilização de atributos de textura extraídos a partir de dados ALOS/PALSAR FBD 1.1 filtrados. Considerando as classes de cobertura individualmente e os custos envolvidos, recomenda-se a utilização do dado TM para a classificação de SE, VS2, VS3, FD e FP; do dado Atributos TM para PL, PS, AP e VS1 e do dado Atributos PALSAR_SDNLM para AP.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, pela concessão de bolsas pelos processos número 130890/2012-0, 150439/2014-8 e 307666/2011-5; ao Instituto Chico Mendes de Conservação da Biodiversidade - ICMBio (MMA) por meio da Autorização SISBIO de número 38157-2 e ao Programa de Grande Escala da Biosfera-Atmosfera na Amazônia (*Large-Scale Biosphere Atmosphere Experiment in Amazonia*- LBA).

Referências

- ABOUD NETA, S. **Uso de imagens ALOS/PALSAR multipolarizadas para detecção de incremento de desflorestamento na Amazônia**. 264 p. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009-09-30 2009.
- BRUZZONE, L.; BOVOLO, F. Unsupervised change detection in multi-temporal SAR images. In: C.H, C. (Ed.). **Image processing for remote sensing**. Londres: Taylor and Francis, 2008. 380p.
- COUTINHO, A.; ALMEIDA, C.; VENTURIERI, A.; ESQUERDO, J.; SILVA, M. **Uso e cobertura da terra nas áreas desflorestadas da Amazônia Legal**: TerraClass, 2008. Brasília, Belém, 2013. 116p.
- EUROPEAN SPACE AGENCY (ESA). **Information on ALOS PALSAR products for ADEN users**. Paris: EESA, 2007. 15 p.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **IBGE downloads**. s.d. Disponível em: <http://downloads.ibge.gov.br/downloads_geociencias.htm>. Acesso em: 15 maio 2013.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Catálogo LANDSAT5**. 2013a. Disponível em: <<http://www.dgi.inpe.br>>. Acesso em: 12 jan. 2013.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Biblioteca digital de fotos de campo da OBT**. 2013b. Disponível em: <<http://www.obt.inpe.br/fototeca/>>. Acesso em: 9 out. 2013.
- JAPAN AEROSPACE EXPLORATION AGENCY (JAXA). **ALOS/PALSAR level 1.1/1.5 product format description (English Version)**. 2009. 158 p. (NEB-070062B).
- JENSEN, J. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 598 p.
- LEWIS, A.; HENDERSON, F. Radar fundamentals: the geosciences perspective. In: HENDERSON, F.; LEWIS, A. (Ed.). **Manual of remote sensing: principles and applications of imaging radar**. 3. ed. New York: Wiley, 1998. v. 3. 896 p.
- NEGRI, R. G.; DUTRA, L. V.; SANT'ANNA, S. J. S. Stochastic approaches of minimum distance method for region based classification. **Lecture Notes in Computer Science**, v. 7441, n. 2012, p. 797–804, 2012. ISSN 0302-9743.
- ORSOMANDO, F.; LOMBARDO, P.; ZAVAGLI, M.; CONSTANTINI, M. SAR and optical data fusion for change detection. In: Urban Remote Sensing Joint Event, 2007, Paris, França. **Proceedings...** Paris, 2007.
- PARADELLA, W.; SANTOS, A.; VENEZIANI, P.; CUNHA, E. Radars imageadores nas geociências: estado da arte e perspectivas. **Revista Brasileira de Cartografia**, v. 1, n. 57, p. 56–62, 2005.
- PEREIRA, L. O. **Avaliação de métodos de integração de imagens ópticas e de radar para a classificação do uso e cobertura da terra na região amazônica**. 2012. 242 p. CDU 528.8.044.2(811.5). Dissertação (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012.
- REIS, M. S.; PANTALEÃO, E.; SANT'ANNA, S. J. S.; DUTRA, L. V. Proposal of a weighted index for segmentation evaluation. In: IEEE INTERNATIONAL GEOSCIENCE & REMOTE SENSING SYMPOSIUM (IGARSS 2014) AND 35TH CANADIAN SYMPOSIUM ON REMOTE SENSING (35TH CSRS) SYMPOSIUM, 2014, Québec, Canada. **Proceedings...** Québec: IEEE, 2014. p. 3742–3745.
- SCOFIELD, G. B.; DUTRA, L. V.; FREITAS, C. C.; SANT'ANNA, S. J. S.; SILVA, D. L. A. Evaluation of two region based classifications in Tapajós national forest using the ALOS/PALSAR polarimetric and interferometric coherences. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2010, 1997, Honolulu, HI. **Proceedings...** Honolulu: IEEE, 2010. p. 3426 – 3429. ISBN 978-1-4244-9564-1.
- SILVA, W. B.; PEREIRA, L. O.; SANT'ANNA, S. J. S.; FREITAS, C. C.; GUIMARÃES, R. J. P. S.; FRERY, A. C. Land cover discrimination at Brazilian Amazon using region based classifier and stochastic distance. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2011, Vancouver, BC. **Proceedings...** Vancouver: IEEE, 2011. p. 2900 – 2903. ISBN 978-1-4577-1003-2.
- SOUSA JR, M. **Segmentação multi-níveis e multi-modelos para imagens radar e ópticas**. 2005. 131 p. INPE - 14466-TDI/1147. Dissertação (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2005.
- TORRES, L.; SANT'ANNA, S. J. S.; FREITAS, C. C.; FRERY, A. C. Speckle reduction in polarimetric SAR imagery with stochastic distances and nonlocal means. **Pattern Recognition**, v. 47, n. 1, SI, p. 141–157, Jan. 2014. ISSN 0031-3203.