

Classificação de cobertura da terra utilizando dados óticos e de radar de abertura sintética em diferentes níveis de detalhamento

Mariane Souza Reis
Sidnei João Siqueira Sant'Anna
Luciano Vieira Dutra

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

Abstract. The use of Synthetic Aperture Radar (SAR) data, sole or fused/combined to optical data, is interesting in regions like the Brazilian Amazon, in which cloud cover is constant. Many works has been done in the region, comparing classifications obtained from SAR, optical or fused data. In general, optical data has shown better results than SAR data. Fused data has either presented better, comparable or worse results. This paper presents land cover classifications for a region in low Tapajós River, in the Brazilian Amazon, using optical, SAR and fused data, using three legends, with different level of detail (number of classes). It was observed that the lower is the number of classes, the higher is the accuracy of the classification. Although optical results were better for all legends level, results obtained from SAR data is comparable to those when using a small number of classes. In addition, some classes where better classified using specific type of data.

Palavras-chave: remote sensing, SAR classification, image fusion, sensoriamento remoto, classificação de imagens SAR, fusão de dados.

1. Introdução

Dados óticos, segundo Bruzzone e Bovolo (2008), tem sido mais estudados e utilizados pela comunidade de sensoriamento remoto. Inclusive, destaca-se que os projetos de monitoramento conduzidos pelo Instituto Nacional de Pesquisa Espaciais, como o Programa de Cálculo do Desflorestamento da Amazônia (PRODES), Detecção de Desmatamentos em Tempo Real (DETER) e DETER-B e Mapeamento da Degradação Florestal na Amazônia Brasileira (DEGRAD) e o Projeto Mapeamento do Uso e Cobertura da Terra nas Áreas Desflorestadas da Amazônia Legal (TerraClass) são todos conduzidos tendo como base dados óticos, de diferentes resoluções. Estes dados, no entanto, sofrem restrição de uso na presença de chuvas, nuvens, bruma e fumaça (PARADELLA et al., 2005).

Radares de Abertura Sintética (SAR) são capazes de prover dados de forma quase que independente das condições da atmosfera (PARADELLA et al., 2005), o que os tornam atrativos para uso em áreas em que a cobertura de nuvens é constante, como é o caso da Amazônia brasileira. Saliencia-se que dados óticos e SAR registram informações distintas sobre os alvos da cobertura da terra. As informações obtidas por dados óticos estão relacionadas à características físicas, químicas e biológicas dos alvos (JENSEN, 2009). Em contrapartida, as informações registradas em dados SAR são afetadas 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). Dessa forma, estes dados são complementares e podem ser utilizados em conjunto, quando disponíveis, para melhorar a análise (PARADELLA et al., 2005).

Os trabalhos de Reis et al. (2015) e Pereira (2012) são exemplos de estudos que comparam resultados de classificação de cobertura entre dados óticos, SAR e fusionados. Reis et al. (2015) apresentaram a comparação entre a classificação de cobertura de uma área da Amazônia brasileira considerando dez classes de cobertura, dados ótico e SAR e atributos extraídos de dados óticos e SAR e dados fusionados, por meio de uma técnica de classificação baseada em regiões e uma proposta Monte Carlo e incerteza da classificação. Neste trabalho, os autores concluíram que em função dos custos envolvidos no processamento dos dados, não foram

observadas melhorias significativas na classificação de imagens de atributos óticos ou de fusão de dados óticos e SAR, sendo que determinadas classes foram melhor classificadas utilizando dados óticos ou SAR, mas não com dados fusionados. Em contrapartida, Pereira (2012), pela classificação de imagens fusionadas por diferentes metodologias e uso de um classificador contextual em uma área de estudo semelhante, concluiu que determinados dados fusionados melhoram a classificação de algumas classes específicas, sendo que algumas imagens fusionadas atingiram valores de exatidão maiores que dados óticos classificados de forma isolada. Ambos os trabalhos, no entanto, apontaram classificações baseadas em dados SAR com exatidão muito inferiores aos de dados óticos.

Dadas as semelhanças na área de estudo (uma região ao longo da BR-163, no estado do Pará) e dados em ambos os trabalhos, que são imagens LANDSAT5/*Thematic Mapper* e *Advanced Land Observing System (ALOS)/Phase Array L-Band Synthetic Aperture Radar (PALSAR)*, de mesma data, tem-se que as principais diferenças entre os trabalhos são as metodologias de classificação adotadas e as legendas, que diferem em número e tipo de classes. Nesse sentido, tem-se que as amostras rotuladas de cada classe adotada na legenda altera os atributos selecionados para cada dado. Adicionalmente, em trabalhos como Negri (2009), Pereira et al. (2013) e Pantaleão et al. (2012) foram observados aumentos na exatidão após o agrupamento de classes.

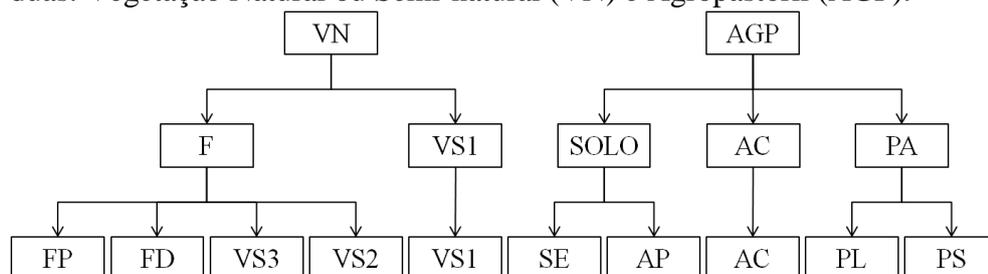
Nesse sentido, o presente trabalho trata-se de uma continuação do trabalho realizado por Reis et al. (2015), com objetivo de comparar classificações de cobertura obtidas por meio de dados SAR, óticos e fusionados, com metodologia similar à adotada pelo trabalho anteriormente citado, mas diferentes agrupamentos de classes. Foram analisados diferentes conjuntos de dados óticos, SAR e um conjunto proveniente da fusão de ambos, em três níveis de detalhamento de legenda classes de cobertura, de forma a buscar melhorias na classificação de dados óticos e SAR pelo uso de atributos extraídos dessas imagens ou pelo agrupamento de classes, bem como avaliar se a fusão de dados representa melhoria significativa na classificação quando consideradas outras legendas.

2. Materiais e Métodos

Como o objetivo deste trabalho é avaliar como a mudança no nível de legenda altera os resultados de classificação de diferentes tipos de dado, classificados tendo como base uma legenda mais detalhada, adotou-se como base de comparação as classificações obtidas por Reis et al. (2015). Foram geradas outras classificações de cobertura, adotando-se mesma metodologia mas legendas distintas.

Acerca do trabalho realizado por Reis et al. (2015), tem-se que a área de estudo se refere à uma região de aproximadamente 412 km², localizada ao longo da BR-163, no município de Belterra, Pará. Os dados de entrada para este trabalho são as imagens utilizadas, as imagens segmentadas e as amostras rotuladas das classes adotadas. As imagens utilizadas correspondem à: bandas 1 a 5 e 7 de uma imagem do sensor TM do satélite LANDSAT5, de 29 de junho de 2010 (das quais o subconjunto formado pelas bandas 2,4 e 5 correspondem ao conjunto denominado “TM”), e uma imagem oriunda do sensor PALSAR, do satélite ALOS, obtida em 21 de junho de 2010 no modo *Fine Beam Dual (FBD)* nível de processamento 1.1. Ambas as imagens foram ortorretificadas. A imagem LANDSAT5/TM foi utilizada na resolução original (30m) e a imagem ALOS/PALSAR foi reamostrada para 15 m, pelo interpelador do vizinho mais próximo, e as polarizações HH e HV foram utilizadas em amplitude (conjunto denominado “PALSAR”). A área de estudo, bem como as imagens utilizadas estão apresentadas na Figura 1.

Em Reis et al. (2015) foram definidas dez classes de cobertura para a região. São essas: 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). Para o presente estudo, essas classes foram hierarquizadas e organizadas em três níveis de detalhes, conforme apresentado na Figura 2. O nível de detalhe intermediário possui cinco classes de cobertura da terra. São estas: Floresta (F), Solo(SOLO), Pasto (PA) e, remanescentes do nível anterior, AC e VS1. No nível de menor detalhe essas cinco classes foram agrupadas outras duas: Vegetação Natural ou Semi-natural (VN) e Agropastoril (AGP).



em que FP=Floresta Primária; FD=Floresta Degradada; VS3=Vegetação Secundária Avançada; VS2=Vegetação Secundária Intermediária; VS1=Vegetação Secundária Inicial; PL=Pasto Limpo; PS=Pasto Sujo; AC=Área Cultivada; AP=Área em Pousio; SE=Solo Exposto; F=Floresta; SOLO=Solo; PA=Pasto; VN=Vegetação Natural e Semi-natural e AGP=Agropastoril.

Figura 2. Classificação hierárquica das classes de interesse para definição das legendas com diferentes níveis de detalhe.

As amostras de treinamento e teste utilizadas por Reis et al. (2015) foram agrupadas de forma a corresponderem às novas duas legendas propostas (com cinco e duas classes) e utilizadas juntamente com os dados e as respectivas imagens segmentadas para gerar classificações de cobertura. Os dados foram classificados utilizando o *Stochastic Minimum Distance Classifier - Bathacharyya* (Classificador de Mínima Distância Estocástica - Bhattacharyya), do aplicativo *Region Based Classification Methods* (NEGRI et al. 2012) 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 com pixel de 30 m (TM, Atributos TM e Fusão) e 1200 pixels por classe para dados com pixels de 15 m (PALSAR, PALSAR_SDNLN e Atributos PALSAR_SDNLN). Cada região recebe o rótulo mais frequente nas 100 classificações daquele dado para compor a classificação final de cada dado.

As classificações finais de cobertura foram avaliadas por uma Monte Carlo, em que são 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 os dados PALSAR, PALSAR_SDNLN e Atributos PALSAR_SDNLN. Matrizes de confusão e o índice Kappa (Global e condicional por classe) foram calculados a partir dessas amostras. Este processo foi repetido 1000 vezes por classificação, com variação no sorteio das amostras de teste. Os índices de exatidão foram analisados em função de sua mediana, quartis e desvio padrão.

3. Resultados

Os valores de Kappa Global para cada conjunto de dados obtidas por Reis et al. (2015) (nível de detalhe com dez classes) e os dois níveis propostos estão demonstrados na Figura 3. Como é possível verificar nessa figura, para todos os níveis de detalhes, as classificações dos dados TM apresentaram resultados melhores ou similares às dos dados Atributos TM e Fusão, sendo que esses três dados (que possuem componentes óticos) apresentam valores de Kappa Global melhores que os dos dados que apresentam apenas componentes SAR. Ao se considerar apenas os dados com componentes SAR, têm-se que Atributos PALSAR_SDNLN

apresentou os melhores resultados na classificação de dez classes (maior nível de detalhe) e que PALSAR_SDNLM e Atributos PALSAR_SDNLM apresentaram resultados similares nas classificações com cinco e duas classes de cobertura. De forma geral, observa-se também que os valores de Kappa Global são maiores a medida em que decresce o número de classes utilizadas.

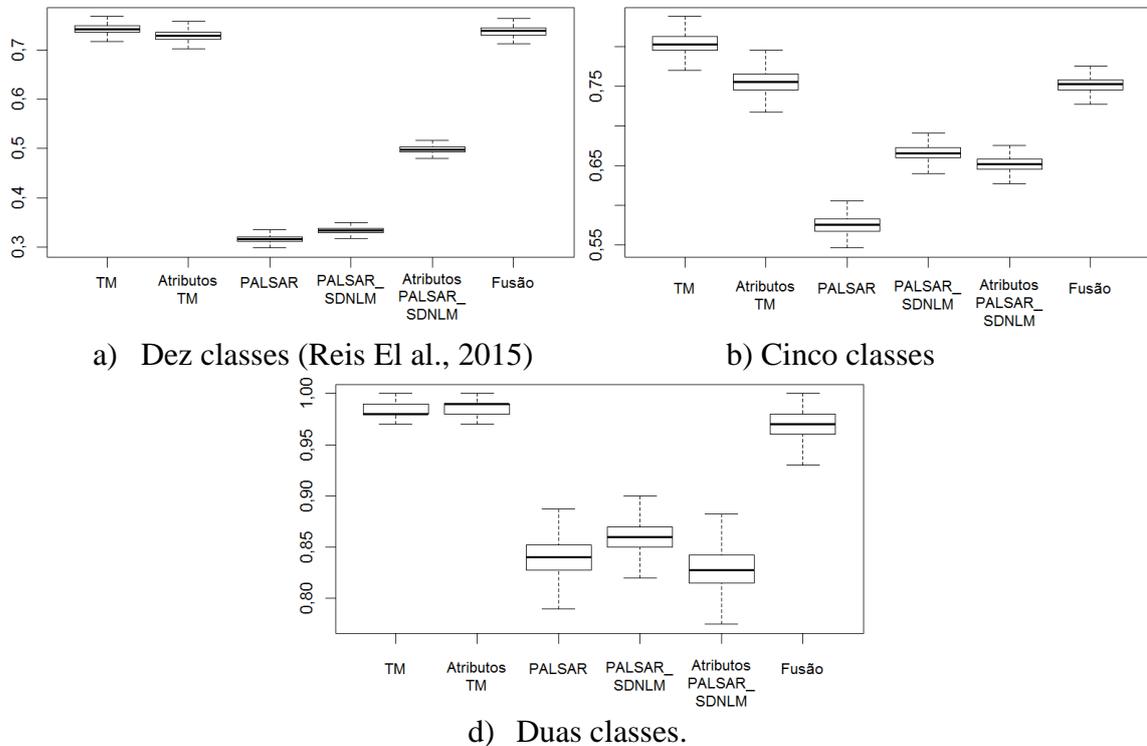


Figura 3. Boxplot dos valores de Kappa Global calculados para cada classificação de cobertura, com possíveis *outliers* omitidos.

Dos resultados obtidos para Kappa Condicional (por classe), considerando os dados originais de Reis et al (2015), tem-se que:

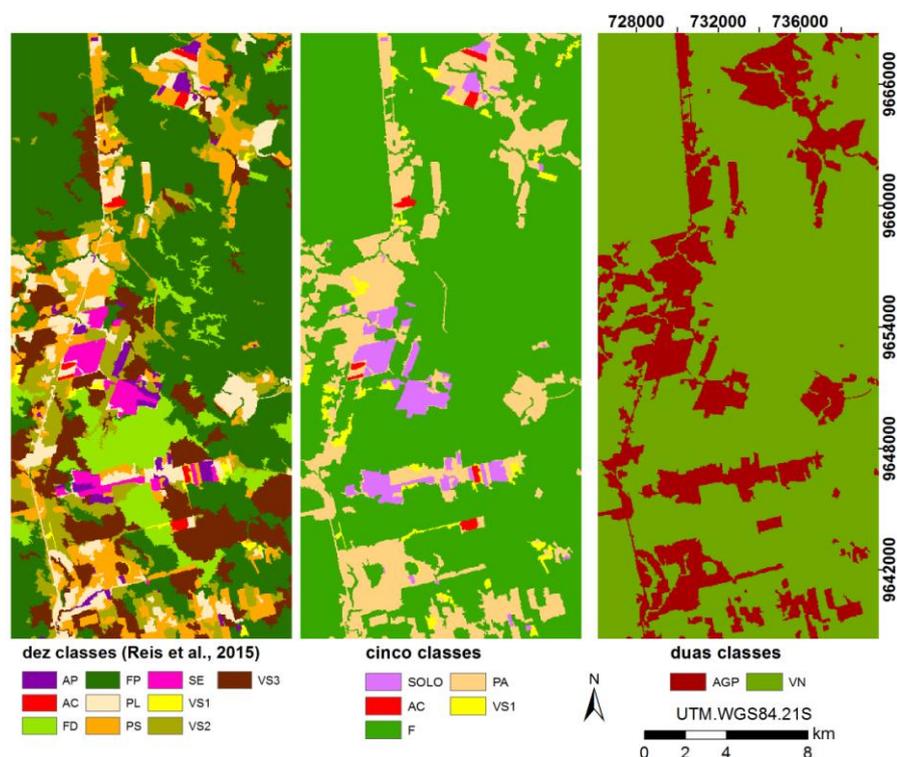
- para a classes AC, FP, PS e VS1 o dado Fusão apresentou resultados melhores que TM;
- para as classes FP, PL, PS e VS1 o dado Atributos TM apresentou resultados melhores que TM;
- das classes melhor classificadas com os dados Fusão e Atributos TM em relação à do dado TM (FP, PS e VS1), Atributos TM apresentaram resultados melhores ou similares aos do dado Fusão;
- o Kappa Condicional para a classe VS1 na classificação do dado TM foi negativo, uma vez que nessa classificação nenhuma amostra dessa classe foi corretamente classificada. Isso provavelmente ocorreu em função da segmentação, em que áreas de PS e VS1 ou FD e VS1 foram agrupadas em um mesmo segmento;
- a classificação do dado Atributos PALSAR_SDNLM apresentou os melhores resultados para a classe AP, resultados comparáveis com TM e Fusão para FD e resultados melhores que os demais dados SAR para as classes AC, PL, SE, VS2 e VS3;
- a classificação do dado PALSAR apresentou resultados melhores que PALSAR_SDNLM e Atributos PALSAR_SDNLM apenas para a classe FP;
- a classificação de PALSAR_SDNLM apresentou resultados melhores que a de Atributos PALSAR_SDNLM apenas para a classe PS.

Considerando cinco classes de cobertura, para os resultados obtidos para Kappa Condicional, tem-se que:

- (a) apenas para a classe SOLO há uma melhora no Kappa Condicional que justifique o uso do dado Fusão ao invés do dado TM;
- (b) a classificação dos dados Atributos TM não apresentou melhores resultado que a de TM para nenhuma classe de cobertura;
- (c) a classificação de Atributos PALSAR_SDNLM apresenta melhores resultados que PALSAR_SDNLM apenas para a classe SOLO, sendo que para as demais classes, PALSAR_SDNLM apresenta resultados melhores ou comparáveis aos dos demais dados SAR. Para as classes AC, SOLO e VS1 os resultados são comparáveis aos obtidos por TM;
- (d) para a classe SOLO, a classificação do dado Atributos PALSAR_SDNLM é similar à de Fusão.

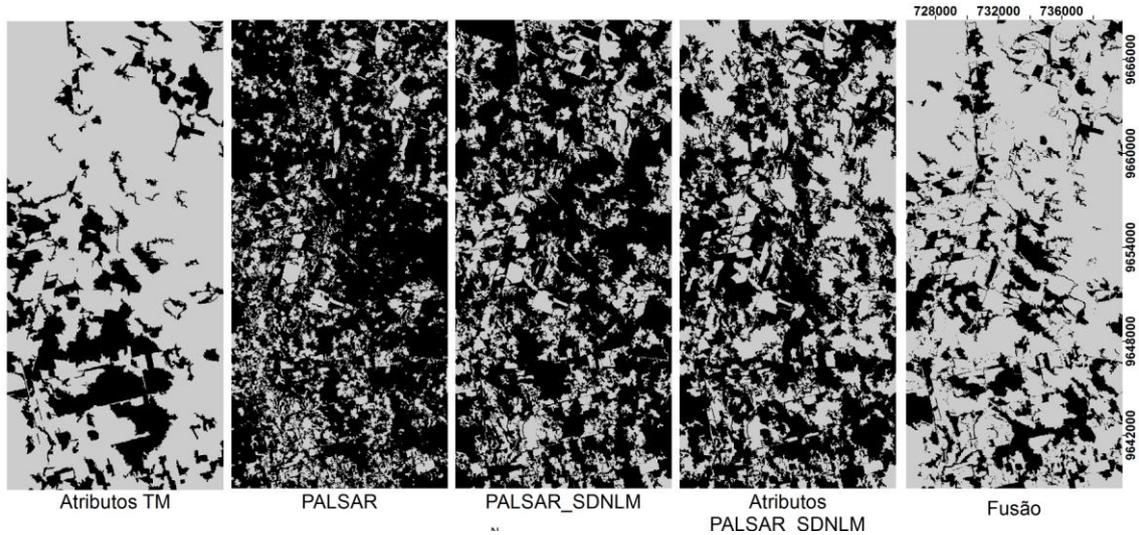
Para as classificações com menor nível de detalhe, ou seja, duas classes, todos os dados obtiveram resultados comparáveis e maiores que 0,85 para a classe AGP. Para a classe VN, os melhores resultados foram obtidos pelos dados TM, Atributos TM (ambos com Kappas Condicionais maiores que 0,94) e Fusão (Kappas Condicionais variam entre 0,86 e 1,00). Os resultados obtidos pelos dados SAR para essa classe são comparáveis e maiores que 0,60.

Para fins de ilustração, a Figura 4 apresenta as classificações de cobertura obtidas utilizando-se dados TM, para os três níveis de legenda. Na Figura 5 estão apresentadas as áreas em que houve ou não concordância na classificação dos demais dados com o dado TM, para os três níveis de legenda. Como pode ser observado na Figura 5, quanto menor o número de classes na legenda adotada, não apenas maior a exatidão, mas mais parecidas as classificações se aproximam da classificação dos dados TM.

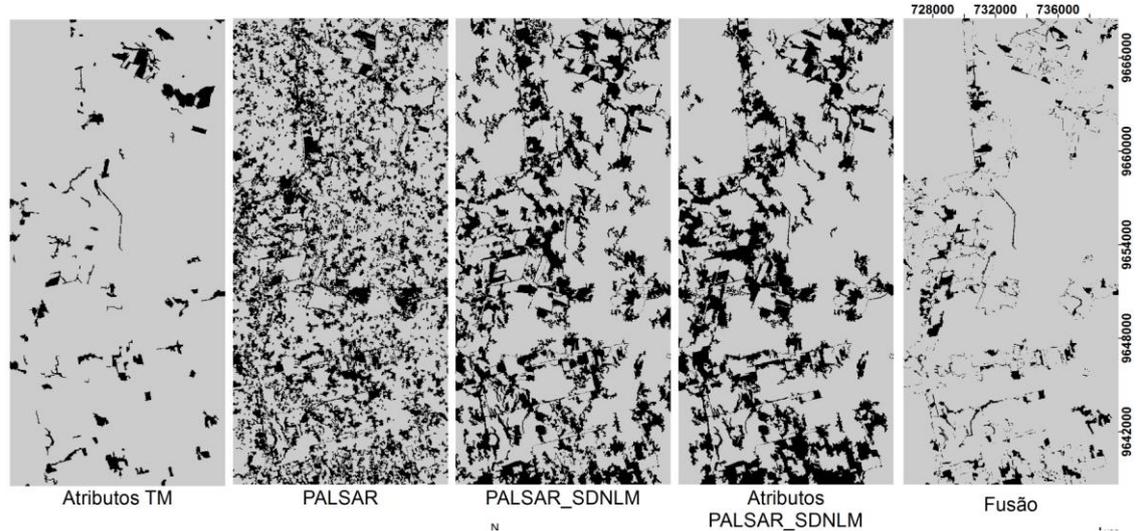


em que FP=Floresta Primária; FD=Floresta Degradada; VS3=Vegetação Secundária Avançada; VS2=Vegetação Secundária Intermediária; VS1=Vegetação Secundária Inicial; PL=Pasto Limpo; PS=Pasto Sujo; AC=Área Cultivada; AP=Área em Pousio; SE=Solo Exposto; F=Floresta; SOLO=Solo; PA=Pasto; VN=Vegetação Natural e Semi-natural e AGP=Agropastoril.

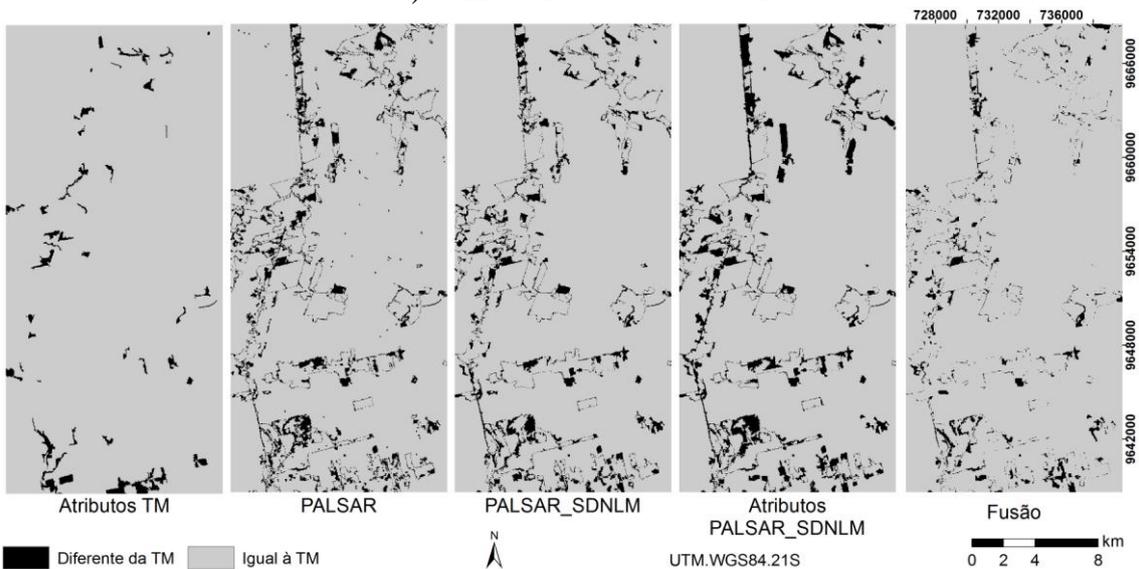
Figura 4. Classificações de cobertura obtida utilizando-se dados TM, para os três níveis de legenda.



a) Dez classes de cobertura.



b) Cinco classes de cobertura.



c) Duas classes de cobertura.

Figura 5. Comparação das classificações de cobertura com aquela obtida pelos dados TM.

4. Considerações finais

Como pode ser observado pela análise dos resultados, de forma geral, a diminuição do número de classes melhorou a exatidão das classificações. Para todos os níveis de legenda, a classificação dos dados TM ou alcançou os valores de Kappa Global mais altos ou comparáveis a esses, sendo que não importando o nível de legenda, não se observou melhorias globais na classificação que justifiquem o uso de atributos de textura extraídos da imagem LANDSAT5/TM ou a fusão dos dados óticos e SAR. Melhorias ao se utilizar estes dados foram observadas apenas na classificação de algumas classes específicas. Apesar das diferenças nos valores de Kappa Global em todos os níveis de legenda, ressalta-se que para o nível de menor detalhe (duas classes), os valores medianos de Kappa Global são superiores a 0,85. Nesse sentido, dada a impossibilidade de se utilizar dados óticos (devido à cobertura de nuvens, por exemplo) pode-se utilizar dados SAR para classificar a cobertura da terra, com atenção às classes utilizadas.

Agradecimentos

Os autores agradecem ao CNPq pela bolsa de número 312753/2015-2.

Referências

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. **Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia**. 2009. 170 p. (INPE-16220-TDI/1541). Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP8W/35AKRR5>>. Acesso em: 16 nov. 2016

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.

PARADELLA, W., SANTOS, A., VENEZIANI, P., CUNHA, E. Radares imageadores nas geociências. **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**. 242 p. Dissertação (Mestrado) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012.

PEREIRA, L. O.; FREITAS, C. C.; SANT'ANNA, S. J. S.; LU, D.; MORAN, E. F. Optical and radar data integration for land use and land cover mapping in the Brazilian Amazon. **GIScience & Remote Sensing**, v. 50, n. 3, p. 301-321, 2013. doi: <10.1080/15481603.2013.805589>. PANTALEÃO, E.; DUTRA, L. V.; SANDRI, S. A. Scenario analysis for image classification using multi-objective optimization. **InfoComp**, v. 11, n. 3, p. 15-22, set.-dez. 2012. Disponível em: <http://www.dcc.ufla.br/infocomp/index.php?option=com_content&view=article&id=530&Itemid=216>. Acesso em: 16 nov. 2016.

REIS, M. S.; PANTALEÃO, E.; SANT'ANNA, S. J. S.; DUTRA, L. V. Classificação de cobertura da terra utilizando dados óticos e de radares de abertura sintética. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 4612-4619. Internet. ISBN 978-85-17-0076-8. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3JM4D2H>>. Acesso em: 16 nov. 2016.

SOUSA JÚNIOR, M. A. **Segmentação multi-níveis e multi-modelos para imagens de radar e ópticas**. 2005. 131 p. (INPE-14466-TDI/1147). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. Disponível em: <<http://urlib.net/sid.inpe.br/jeferson/2005/06.01.18.47>>. Acesso em: 16 nov. 2016.

TORRES, L., SANT'ANNA, S. J., FREITAS, C. C., FRERY, A. C., 2014. Speckle reduction in polarimetric SAR imagery with stochastic distances and nonlocal means. **Pattern Recognition**, v. 47, n. 1, p. 141–157.