

Análise de métodos limiarização para a detecção de mudanças usando dados ótico e de micro-ondas numa região da Amazônia brasileira

Sidnei João Siqueira Sant'Anna
Mariane Souza Reis

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

Abstract. Change detection can be seen as the process of identifying changes in the state of an object or phenomenon by observing it at different times. There are several change detection techniques that can be applied in remote sensing areas, such as the detection of oil slick, deforestation, burning areas, sources of fire, some kind of disease, disaster monitoring, among others. Governmental programs like PRODES, DETER and DETEX show the great importance of change detection techniques for studies in the Brazilian Amazônia region. Besides its intrinsic complexity, this region is known by presenting a cloud cover problem which, sometimes, could be overcome by using microwave data. Therefore, is fundamental to gain certain knowledge about methods and techniques of digital image processing applied over microwave data from the Brazilian Amazônia. In this context, two thresholding change detection techniques are evaluated in this work for optical and microwave data. Binary classified images are generated using these techniques, that is, images containing only Change and No-Change classes. The classification process is based on two image acquired from the same sensor on different times, one segmented image and thresholds defined using the average values of the pixels inside a segment, in each image. The optical and microwave data achieved high level of overall accuracy in the binary classification, however the former presents an overall accuracy around 96% while for the latter this measure is about 87%. Both data presented very low false alarm rate, approximately 4%.

Palavras-chave: change detection, optical and microwave data, thresholding technique, Brazilian Amazônia detecção de mudanças, dados ótico e de micro-ondas, técnica de limiarização, Amazônia brasileira.

1. Introdução

Detecção de mudanças, segundo Singh (1989), é o processo de identificar diferenças no estado de um objeto ou fenômeno por meio de sua observação em diferentes momentos, pela habilidade de quantificar efeitos temporais nesse objeto ou fenômeno utilizando um conjunto de dados multitemporais. Estudos relacionados à detecção de mudanças contribuem para o entendimento dos ecossistemas ao longo do tempo e da interação entre fenômenos naturais e atividades humanas (LU et al., 2004).

Lu et al. (2014) separam uma análise de detecção de mudanças, utilizando dados provenientes de sensoriamento remoto, em seis passos básicos. São estes:

(a) descrição da natureza dos problemas de detecção de mudanças: tipo de mudança a ser detectado. As três categorias principais são mudança e não mudança (categoria binária); trajetórias detalhadas do tipo "de/para"; e tipos de mudanças específicos, como desmatamento, urbanização ou expansão agrícola, entre outros;

(b) seleção de dados adequados: dados em determinadas épocas do ano ou sensor que possibilitem a detecção de mudanças na categoria desejada;

(c) pré-processamento dos dados: correções geométricas e radiométricas, de forma que pixels ou regiões correspondentes nas imagens sejam diretamente comparáveis;

(d) seleção de variáveis adequadas: intrinsecamente relacionada aos dados selecionados e ao tipo de mudança que se deseja detectar, podendo englobar índices, medidas de textura, variáveis transformadas e as próprias imagens;

(e) seleção do algoritmo de análise: dependente do tipo de mudança a ser detectado e do tipo de dado. Para análises binárias, os mais comuns envolvem a subtração ou razão de uma mesma variável em duas imagens, sendo que se o resultado for maior que um determinado limiar, atribui-se a ocorrência de mudança. Para análises de trajetória ou tipo de mudanças específicos é comum que se classifiquem ambas as imagens e essas classificações sejam

comparadas. Também pode-se realizar esta classificação utilizando-se imagens multitemporais (imagens de mais de uma data agrupadas);

(f) avaliação dos resultados: os métodos mais comuns se baseiam na matriz de confusão, que pode ou não ser adaptada para estudos de mudanças (ver Congalton e Green (1999) para exemplos de matrizes adaptadas).

Quanto à etapa de seleção dos dados adequados, destaca-se que alterações na cobertura da terra devem resultar em mudanças mais significativas no nível de sinal registrado por um dado sensor que aquelas causadas por outros fatores, tais como variações nas condições de geometria de imageamento, iluminação da cena, atmosfera e umidade do solo, para que seja possível detectar mudanças de cobertura da terra (COPPIN et al., 2004). De forma a minimizar alguns desses efeitos indesejáveis, é comum que se utilize imagens de um mesmo sensor e, quando o estudo não está relacionado a mudanças intra-anuais ou sazonais, em uma mesma época do ano. Nesse sentido, ressalta-se que alguns tipos de dados, com essas condições de imageamento, podem não estar disponíveis.

De acordo com Bruzzone e Bovolo (2008), dos dados de sensoriamento remoto, os óticos são os mais utilizados nas análises de detecção de mudanças. No entanto, este tipo de dado possui restrições de coleta na presença de chuvas, nuvens, bruma e fumaça (PARADELLA et al., 2005). Radares de Abertura Sintética (*Synthetic Aperture Radar* - SAR) provêm dados de forma quase que independente das condições da atmosfera e independente da fonte solar (PARADELLA et al., 2005), sendo possível adquirir imagens em qualquer época do ano, mesmo em regiões como a Amazônia, onde a cobertura de nuvens é frequente.

Dada a importância crescente em se detectar mudanças na região amazônica, esse trabalho objetiva avaliar resultados de processos de detecção de mudanças binários. Neste estudo utilizam-se dados provenientes de um sensor ótico e de um sensor SAR, e uma técnica baseada em limiares definidos a partir dos valores médios dos pixels de uma dada região em imagens obtidas em datas diferentes. São geradas classificações binárias onde as regiões são rotuladas como áreas que mudaram de uma imagem para outra (classe mudança) e áreas que não mudaram de uma imagem para outra (classe não-mudança). Estas imagens classificadas também são avaliadas de acordo com a sua Exatidão Global e a Probabilidade de Falso Alarme.

2. Materiais e Métodos

A área de estudo deste trabalho corresponde a uma parcela da Floresta Nacional (FLONA) do Tapajós e arredores. Essa área, de aproximadamente 4120 km² se localiza no município de Belterra, no estado do Pará. Na Figura 1 está ilustrada a localização da área de estudo, em relação a seus limites geográficos e políticos.

Para a elaboração deste trabalho foram utilizadas quatro imagens, provenientes de dois sensores distintos, sendo um ótico e um SAR. As duas imagens óticas são provenientes do sensor *Thematic Mapper* (TM), a bordo do satélite LANDSAT5. Essas imagens datam, respectivamente, de 23 de junho de 2008 e de 29 de junho de 2010. As duas imagens SAR foram adquiridas pelo sensor *Phase Array L-Band Synthetic Aperture Radar* (PALSAR) do satélite *Advanced Land Observing System* (ALOS) e datam de 15 de junho de 2008 e de 21 de junho de 2010, respectivamente.

As imagens LANDSAT5/TM foram obtidas com 8 bits, 30 m de resolução espacial, correção radiométrica e correção geométrica de sistema, sendo que foram utilizadas para este trabalho as bandas 1 a 5 e 7. Essas imagens foram ortorretificadas e normalizadas. As imagens ALOS/PALSAR foram adquiridas no modo *Fine Beam Dual* (FBD) 1.1, com ângulo de incidência de 38,7°, 32 bits, resolução espacial de aproximadamente 10 m em range e 4,5 m em azimute, nas polarizações HH e HV e com comprimento de onda de aproximadamente 23 cm (banda L) (ver JAXA (2009) e ESA (2007) para demais detalhes). Essas imagens foram geometricamente corrigidas, filtradas pelo filtro de *speckle* denominado *Stochastic Distances*

Nonlocal Means (SDNLM) desenvolvido por Torres et al. (2014), foram convertidas para amplitude e também normalizadas. Para a filtragem, foram utilizados os seguintes parâmetros: tamanho de janela de filtragem de 5x5 pixels, tamanho do *patch* de 3x3 pixels e o nível de confiança dos testes estatísticos de 90%. Essas quatro imagens estão ilustradas na Figura 2, de onde pode-se identificar visualmente a existência de algumas regiões de mudanças perceptíveis tanto nas imagens óticas quanto nas imagens SAR.

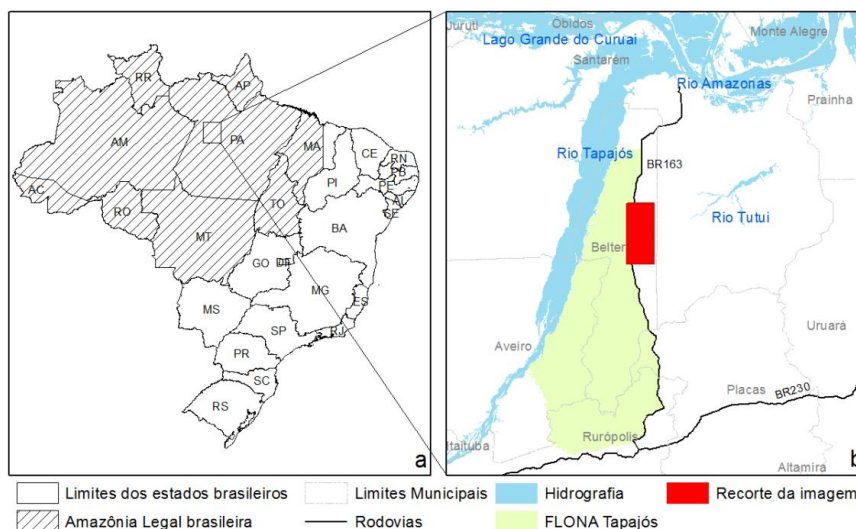


Figura 1. Localização da área de estudo: a) em relação à Amazônia Legal brasileira; b) em relação a limites políticos e geográficos.




Figura 2. Imagens utilizadas: a) ótica de 2008 em composição colorida 5(R)4(G)3(B); b) ótica de 2010 em composição colorida 5(R)4(G)3(B); c) SAR de 2008 em composição colorida HH(R)HV(G)HH(B) e d) SAR de 2010 em composição colorida HH(R)HV(G)HH(B).

Na Figura 3 é apresentado o fluxograma metodológico simplificado, cujas etapas estão explicadas a seguir. As análises que seguem foram realizadas apenas considerando pares de imagens provenientes de um mesmo sensor. Primeiramente, cada imagem de cada data foi segmentada de forma individual. Na seleção do segmentador mais adequado para cada tipo de dado (ótico ou SAR) foram analisados quatro segmentadores com diferentes parametrizações. São estes: crescimento de regiões (TerraPixel 1.04), *Multiresolution Segmentation* (eCognition 8), MultiSeg (SOUSA JR, 2005) e o disponível no *software* Idrisi Selva. As imagens do ano de 2010

de ambos dados foram usadas como referência para a seleção dos segmentadores e seus respectivos parâmetros. Isto é, cada tipo de dado do ano de 2008 foi segmentado utilizando o mesmo algoritmo e parametrização que foi selecionado como melhor para os dados de 2010. Para os dados óticos, tendo com base o Índice Ponderado para Avaliação de Segmentação (*Weighted Index for Segmentation Evaluation - WISE*) (REIS et al.; 2014), optou-se pela segmentação obtida pelo *Multiresolution Segmentation* com forma e compacidade 0,3 e parâmetro de escala 30. Para os dados SAR, por análise visual, optou-se pela segmentação obtida pelo Idrisi, com tolerância de similaridade 40, tamanho de janela 3; peso do fator médio 0,5 e peso do fator de variância 0,5.

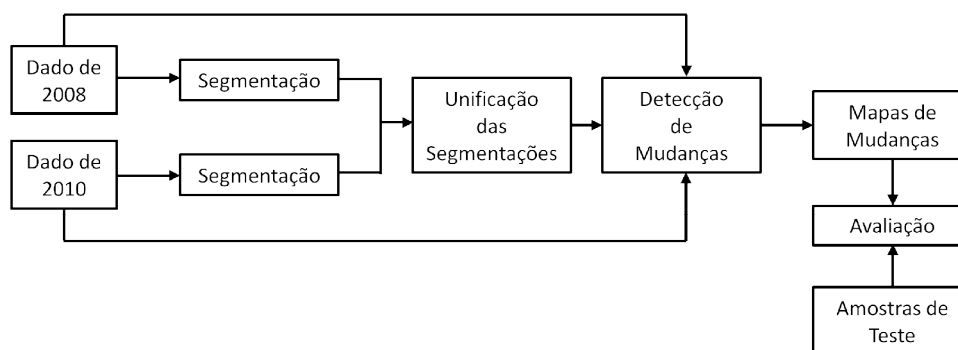


Figura 3. Fluxograma metodológico.

De posse das imagens segmentadas de cada ano de um mesmo tipo de dado, estas imagens foram unificadas originando uma única imagem segmentada para cada tipo de dado. A unificação das imagens segmentadas foi realizada de forma que cada segmento representasse uma região homogênea tanto na imagem de 2008 quanto na de 2010. Regiões com menos de 10 pixels, resultantes dessa unificação, foram agrupadas àquelas com as quais compartilhavam maior fronteira.

Na etapa de detecção de mudanças propriamente dita, considerando dados de um mesmo sensor e a segmentação unificada, os valores de pixels de uma dada região da imagem de 2010 foram comparados com os valores dos pixels na mesma região na imagem de 2008, tanto banda a banda quanto de forma global (considerando todos os pixels de uma determinada região em todas as bandas conjuntamente). A partir desta comparação foram gerados vários mapas binários de mudanças, que são representados por imagens onde os pixels são rotuladas pelas classes *Mudança* e *Não-Mudança*. A comparação foi realizada através de limiares baseados nos valores das médias dos pixels da região denominados Limiar de Porcentagem e Limiar de Desvio Padrão.

No Limiar de Porcentagem associa-se a classe *Mudança* ao segmento (região) em que a diferença, em módulo, da média do segmento na imagem de 2010 com a de 2008 for maior ou igual a um limiar pré-estabelecido. Caso contrário, associa-se a classe *Não-Mudança* a este segmento. Nesta comparação foram testados limiares entre 0 e 25%, em passos de 5%. Já no Limiar de Desvio Padrão foram usados dois intervalos de valores em torno da média de cada região (um para a região na imagem de 2008 e outro na de 2010). Os limites inferior e superior de cada intervalo são definidos em função do desvio padrão dos pixels da região. Os intervalos $C_1 = [m_1 - f \cdot s_1; m_1 + f \cdot s_1]$ e $C_2 = [m_2 - f \cdot s_2; m_2 + f \cdot s_2]$ são, então, construído para cada região da imagem segmentada, onde m_1 e m_2 são, respectivamente, as médias dos pixels da região nas imagens de 2008 e 2010, s_1 e s_2 os respectivos desvios padrões e f um fator constante. Neste caso a classe *Mudança* é associada somente às regiões para as quais não há interseção entre os valores de C_1 e C_2 . Testaram-se valores de f variando de 0 a 1, em passos de 0,2 unidades.

Para a avaliação dos mapas de mudanças resultantes, primeiramente foram definidas dez classes de cobertura da terra, identificadas na área de estudo (REIS, 2014). São elas: floresta primária, floresta degradada, vegetação secundária em três estágios de desenvolvimento (inicial,

intermediária e avançada), pasto com e sem presença de arbustos, áreas cultivadas, áreas em pousio e solo exposto. Considerando essas classes de cobertura, foram identificadas áreas de **Mudança** (coberturas diferentes nas duas datas) e **Não-Mudança** (mesma cobertura em ambas as datas) e coletadas amostras de teste. As classificações de mudança então foram avaliadas por uma estratégia Monte Carlo, onde sortearam-se, sem repetição, 100 amostras de teste para cada classe de mudança (200 amostras no total), construída a matriz de confusão e calculada a Exatidão Global. Esse processo foi repetido 1000 vezes, sendo que os resultados foram avaliados em função da média e desvio padrão dos valores de Exatidão Global obtidos. Calculou-se também a probabilidade de falso alarme (PFA) das classificações com maior valor de Exatidão Global para cada dado (banda, polarização e global), tendo como base as matrizes de confusão calculadas. A PFA simboliza a probabilidade de uma área de **Não-Mudança** ser classificada como **Mudança** e é dada por:

$$PFA = \frac{E}{T} \quad (1)$$

em que E equivale ao número de amostras de **Não-Mudança** erroneamente classificadas como **Mudança** e T é o total de amostras. Esses valores também foram avaliados em função de média e desvio padrão.

3. Resultados

Na Figura 4 são apresentados os valores de Exatidão Global obtidos com a utilização dos dados óticos, utilizando os métodos de limiar de porcentagem e de limiar em função do desvio padrão. Na Figura 5 são mostrados os resultados obtidos com os dados SAR, usando os mesmos métodos de detecção de mudanças.

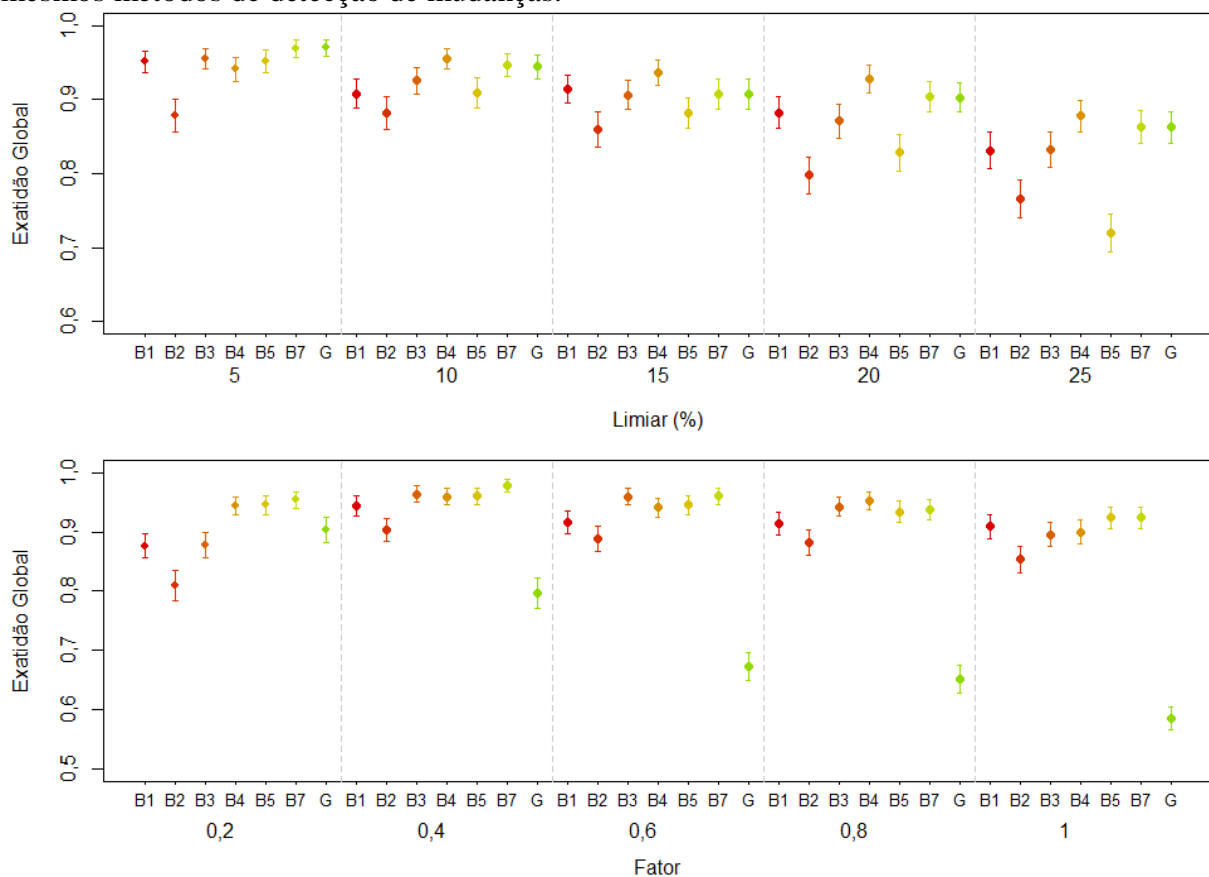


Figura 4. Exatidão Global média e desvio padrão da Exatidão Global das classificações obtidas a partir dos dados óticos, utilizando os métodos de limiar de porcentagem e de limiar em função de fator e desvio padrão. As cores são indicativas de banda analisada ou G=global.

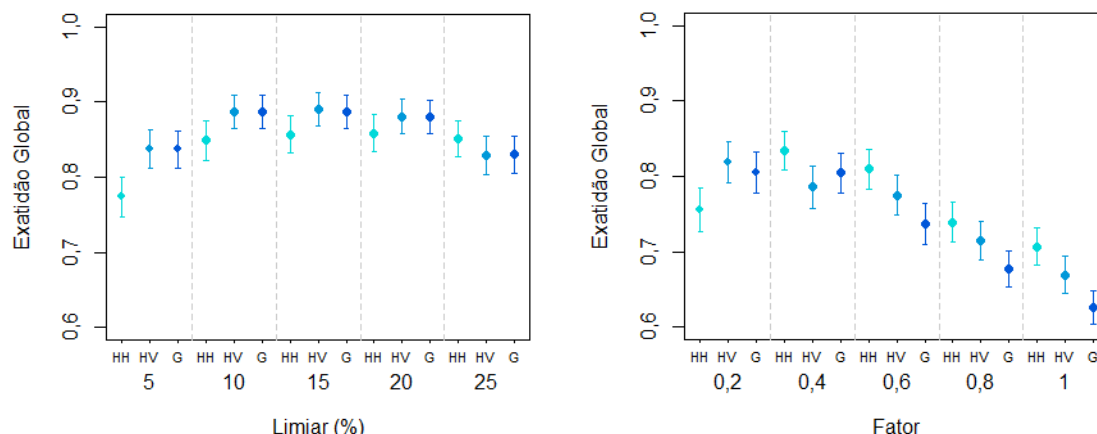


Figura 5. Exatidão Global média e desvio padrão da Exatidão Global das classificações obtidas a partir dos dados SAR, utilizando os métodos de limiar de porcentagem e de limiar em função de fator e desvio padrão. As cores são indicativas polarização analisada ou G=Global.

Como é possível observar nas Figuras 4 e 5, há diferenças significativas nos valores de Exatidão Global com a utilização de diferentes métodos, parâmetros e variável analisada (bandas ou polarização e de forma individual ou global). Para as bandas 2, 3, 4, 5 e 7 da imagem LANDSAT5/TM normalizada, os melhores resultados foram obtidos pelo método que estabelece o limiar em função do desvio padrão, com fator 0,4. Para a banda 1 e para os dados de forma global da mesma imagem, os melhores resultados foram obtidos com o método que adota o limiar de porcentagem, com limiar de porcentagem de 5%. Para os dados SAR, os melhores resultados utilizando cada polarização ou os dados de forma global foram obtidos pelo método que adota o limiar de porcentagem, sendo que para a polarização HH esse limiar foi de 20%, para a HV e os dados de forma global o limiar foi de 15%.

Na Tabela 1 são ilustrados os valores médios de Exatidão Global e PFA para as melhores classificações obtidas para cada variável analisada, com os respectivos desvios padrões. De forma geral, observam-se altos valores de exatidão (superiores a 0,85) com baixos valores de PFA (menores que 4,5%). Além disso, as classificações utilizando dados óticos obtiveram valores médios de Exatidão Global maiores que as que utilizam dados SAR.

Tabela 1. Valores médios de Exatidão Global e Probabilidade de Falso Alarme (PFA) para as melhores classificações obtidas para cada variável analisada, com os respectivos desvios padrão.

Variável	Limiar	Exatidão Global	PFA (%)
LANDSAT5/TM banda 1	5%	0,951 ± 0,014	4,35 ± 1,36
LANDSAT5/TM banda 2	0,4*s	0,930 ± 0,020	1,96 ± 0,94
LANDSAT5/TM banda 3	0,4*s	0,964 ± 0,013	3,02 ± 1,24
LANDSAT5/TM banda 4	0,4*s	0,959 ± 0,014	2,29 ± 1,04
LANDSAT5/TM banda 5	0,4*s	0,960 ± 0,014	1,74 ± 0,94
LANDSAT5/TM banda 7	0,4*s	0,978 ± 0,010	1,79 ± 0,94
LANDSAT5/TM global	5%	0,970 ± 0,012	2,63 ± 1,08
ALOS/PALSAR HH	20%	0,858 ± 0,025	3,72 ± 1,37
ALOS/PALSAR HV	15%	0,890 ± 0,022	4,06 ± 1,38
ALOS/PALSAR global	15%	0,887 ± 0,022	4,22 ± 1,34

em que dp= desvio padrão do segmento.

Recortes de detalhes dessas classificações estão apresentadas na Figura 6 para análise visual, com algumas feições em destaque por setas pretas. Na Figura 6, é possível observar que, em classificações resultantes de dados SAR (Figuras 6l, 6m e 6n), há um maior número

de pequenas regiões classificadas como *Mudança* e espalhadas na imagem que nas que utilizam dados óticos. De forma geral, também observa-se que algumas feições não foram identificadas com o uso de alguns dados, ou identificadas de formas distintas com uso de variáveis diferentes. Por exemplo, na Figura 6e a feição destacada é formada por segmentos distintos que nas demais classificações. Além disso, apenas com o uso da banda 1 e dos dados globais da imagem ótica, a feição identificada na Figura 6k foi classificada como *Mudança* (trata-se de uma área de solo exposto em 2008 e pousio em 2010). Nas Figuras 6h, 6i e 6j, observa-se uma feição que aparece com formatos diferentes com o uso das bandas 4 e 7, mas não é identificada com o uso da banda 5 da imagem ótica. Também destaca-se o aparecimento de uma feição linear (ao longo de uma estrada) nas classificações de imagens óticas (com exceção da banda 4), que não ocorrem na imagem SAR. Não foram identificadas, pela comparação entre as imagens, quais diferenças podem ter causado essa classificação.

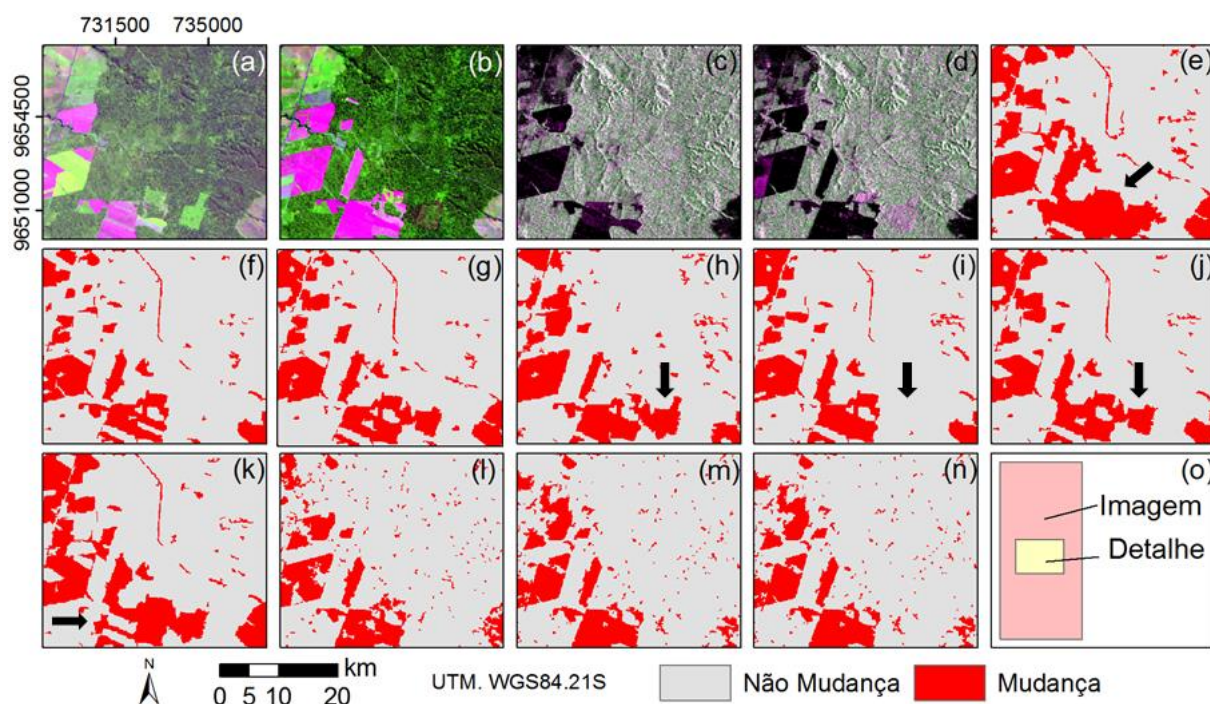


Figura 6. Detalhe da imagem e melhores resultados por variável: a) LANDSAT5/TM de 2008, composição colorida 5(R)4(G)3(B); b) LANDSAT5/TM de 2010, composição colorida 5(R)4(G)3(B); c) ALOS/PALSAR de 2008, composição colorida HH(R)HV(G)HH(B); d) ALOS/PALSAR de 2010, composição colorida HH(R)HV(G)HH(B); e) classificação da banda 1 da imagem ótica; f) classificação da banda 2 da imagem ótica; g) classificação da banda 3 da imagem ótica; h) classificação da banda 4 da imagem ótica; i) classificação da banda 5 da imagem ótica; j) classificação da banda 7 da imagem ótica; k) classificação global da imagem ótica; l) classificação da polarização HH da imagem SAR; m) classificação da polarização HV da imagem SAR; n) classificação global da imagem SAR; e o) localização do detalhe em comparação às imagens.

4. Conclusão

A detecção de mudanças com a utilização de dados LANDSAT5/TM normalizados, pelas metodologias discutidas, apresenta resultados melhores que a utilizando dados ALOS/PALSAR FBD 1.1 normalizados. No entanto, as classificações binárias (*Mudança* e *Não-Mudança*) obtidas por meio de dados SAR (polarizações HH e HV ou de forma global), apresentaram valores de Exatidão Global superiores a 0,85, com baixa Probabilidade de Falso Alarme (menor que 5%). Assim, na indisponibilidade de dados óticos, é possível detectar mudanças de cobertura da terra utilizando dados SAR na banda L. O uso de variáveis diferentes (bandas ou polarização, de forma individual ou global) de uma mesma imagem resulta em classificações de mudança distintas.

Para dados óticos, o melhor resultado foi obtido com a utilização da banda 7 da imagem LANDSAT5/TM. Para dados SAR, o melhor resultado foi obtido utilizando a polarização HV da imagem ALOS/PALSAR.

Paralelamente a este trabalho, realizaram-se análises de detecção de mudanças com os mesmos dados aqui utilizados, analisando os segmentos por meio do teste T (pareado e não-pareado). Nesses testes, foi avaliada a igualdade da média do segmento na imagem de 2008 com o da imagem de 2010. Rejeitada a igualdade, o segmento era classificado como Mudança. Esta análise, realizada com diferentes níveis de confiança, não apresentou resultados coerentes, uma vez que a análise se mostrou muito sensível a pequenas alterações nos valores das amostras, ocasionando uma grande quantidade de falsos alarmes. Trabalhos futuros incluem testes utilizando outras variáveis das imagens SAR, como textura, e outros métodos de análise, como o uso de distâncias estocásticas e testes de hipótese mais sofisticados.

Referências

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.

CONGALTON, R.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 160 p.

COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. Digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, v. 25, n. 9, p. 1565-1596, 2004.

EUROPEAN SPACE AGENCY (ESA). Information on ALOS PALSAR products for ADEN users. Paris: EESA, 2007. 15 p.

JAPAN AEROSPACE EXPLORATION AGENCY (JAXA). **ALOS/PALSAR level 1.1/1.5 product format description <English Version>**. 2009. 158 p. (NEB-070062B).

LU, D.; LI, G.; MORAN, E. Current situation and needs of change detection techniques. **International Journal of Image and Data Fusion**, v. 5, n. 1, p. 13638, 2014. Disponível em: <<http://dx.doi.org/10.1080/19479832.2013.868372>>. Acesso em: 5 jul. 2014.

LU, D.; MAUSEL, P.; BRONDIZIO, E.; MORAN, E. Change detection techniques. **International Journal of Remote Sensing**, v. 25, n. 12, p. 2365-2401, 2004.
PARADELLA, W.; SANTOS, A.; VENEZIANI, P.; CUNHA, E. Radares imageadores nas geociências: estado da arte e perspectivas. **Revista Brasileira de Cartografia**, v. 1, n. 57, p. 566-62, 2005.

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.

REIS, M.S. **Detecção de Mudanças de Uso e Cobertura da Terra Utilizando Dados Óticos e de Micro-ondas em uma Região da Amazônia Brasileira**. 2014. 290 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014. Disponível em <<http://urlib.net/8JMKD3MGP5W34M/3GJ7LFB>>. Acesso em: 6 nov. 2014.

SINGH, A. Digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, p. 376-41, 1989.

SOUSA JR, M. **Segmentação multi-níveis e multi-modelos para imagens radar e óticas**. 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, p. 141-157, Jan. 2014. ISSN0031-3203. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m19/2013/06.09.02.13.18>>. Acesso em: 20 jun. 2014.