

Detecção de mudanças híbrida: uma associação entre classificação baseada em objetos e baseada em pixels

Rômulo Weckmüller¹
Raúl Sánchez Vicens¹

¹ Universidade Federal Fluminense – UFF
Programa de Pós-Graduação em Geografia (PPGEO)
Av. Litorânea s/n – CEP: 24.210-340 – Niterói – RJ, Brasil
weckmuller@gmail.com
rsvicens@id.uff.br

Abstract. The use of all images at one time, also known as a multi-temporal cube, considerably increases the dimensionality of data, making it difficult to detect changes. Therefore, it is considered a hybrid approach, based on the association between pixels and objects, as a good alternative to reduce the processing time of multi-temporal cubes techniques, maintaining the accuracy of change detection. The building of change images, generated pixel by pixel, was used as input for the segmentation process and also used like descriptors that separate the changes of no changes by object-oriented classification based on a fuzzy logic in eCognition®. As this is a multi-temporal range with three RapidEye® scenes (dated 2009, 2010 and 2011) were used and compared two statistical measures of dispersion: amplitude and standard deviation. The study area represents a very dynamic area of the state of Rio de Janeiro with a lot of changes in land cover recently, due to the installation of a Petrochemical Complex (COMPERJ). The amplitude overestimated the class "change", but showed good results with an overall accuracy of 0.87 and a kappa index of 0.74. But the use of standard deviation as change image showed the best results in this paper, identifying 2791 hectares of changes in the study area with an overall accuracy of 0.94 and a kappa index of 0.88.

Palavras-chave: hibrid change detection, change images, amplitude, standard deviation, detecção de mudanças híbrida, imagens mudança, amplitude, desvio padrão.

1. Introdução

O processamento de imagens multitemporais e detecção de mudanças tem sido um campo de pesquisa ativa em sensoriamento remoto por décadas (Jianya et al., 2008). Detectar mudanças significa identificar alterações na superfície terrestre por meio da análise de imagens da mesma área coletadas em diferentes datas (Singh, 1989). Estes estudos permitem entendermos melhor a relação e interação entre sociedade e natureza, contribuindo para a gestão e utilização dos recursos, de uma maneira mais eficiente e sustentável (Lu et al., 2004). Como as mudanças induzidas pelo homem ocorrem em um ritmo cada vez mais rápido, espera-se que os sistemas de monitoramento baseados em sensoriamento remoto, que imageam o Planeta Terra em tempo integral, tenham papéis cruciais na política ambiental e tomadas de decisão (Chen et al., 2012).

Existem muitas técnicas para a análise multitemporal e cada uma possui uma forma própria de lidar com a extração e com a classificação das mudanças. Não existe um método universalmente aceito. Os parâmetros de escolha dessas técnicas dependem do objetivo da pesquisa e/ou da preferência por parte do pesquisador por determinada ferramenta (Coppin et al., 2004; Jensen, 2009).

Dentre as várias técnicas de detecção de mudanças, há um esforço da literatura em separá-las em grandes grupos. Coppin et al. (2004) classifica-as pelo número de imagens utilizadas. Caso sejam apenas duas, a metodologia é bi-temporal, se forem utilizadas três ou mais delas então a metodologia é de análise da trajetória temporal. Porém Peiman (2011) e Kiel (2008) salientam que a classificação mais usual das técnicas de detecção de mudanças seria em dois grandes grupos: pré-classificação e pós-classificação.

A análise pós-classificação consiste na geração de uma classificação para cada data em separado, para uma posterior detecção de mudanças na comparação destes mapas temáticos,

que pode ser em uma integração entre o sensoriamento remoto e um Sistema de Informações Geográficas (Lu et al., 2004). A análise pré-classificação, também chamada de análise direta, adotada para esta pesquisa, consiste na classificação de todas as imagens de diferentes datas juntas, também chamadas de cubo multitemporal. A premissa básica é a de que todas as alterações na cobertura terrestre deverão resultar em mudanças nos valores de radiância (Singh, 1989).

Seja qual for a análise escolhida, normalmente o pesquisador escolhe um método baseado em pixels ou um baseado em objetos. Jyania et al. (2008) defendem que a associação entre estes métodos melhora a precisão dos resultados. Os autores chamam esta associação de detecção de mudanças híbrida. A ideia deste algoritmo é que a informação preliminar de mudanças deve ser derivada de pixels, com a construção de imagens com informações estatísticas de dispersão (imagens mudança), enquanto que posteriormente o método baseado em objetos é aplicado para melhor extrair os resultados destas mudanças.

Neste trabalho, pretende-se utilizar a detecção de mudanças híbrida, através de uma abordagem pré-classificação, com o uso de um cubo multitemporal de imagens do satélite RapidEye, datadas de 2009, 2010 e 2011. Importante salientar que estas imagens representam uma única cena, localizada na Figura 1, e foram previamente co-registradas e normalizadas radiometricamente, diminuindo as diferenças geométricas e radiométricas entre elas.

A área piloto para aplicação da metodologia corresponde à área do COMPERJ e seu entorno, que compreende parte de cinco municípios do estado do Rio de Janeiro: Cachoeiras de Macacu, Guapimirim, Itaboraí, Rio Bonito e Tanguá. A escolha desta área justifica-se pelo alto dinamismo da mesma nos últimos anos, principalmente nos anos de análise deste trabalho (entre 2009 e 2011). Apenas uma cena foi utilizada, como forma de evitar distorções entre o mesmo ano de análise, visto que poderiam ser de satélites diferentes da constelação RapidEye.

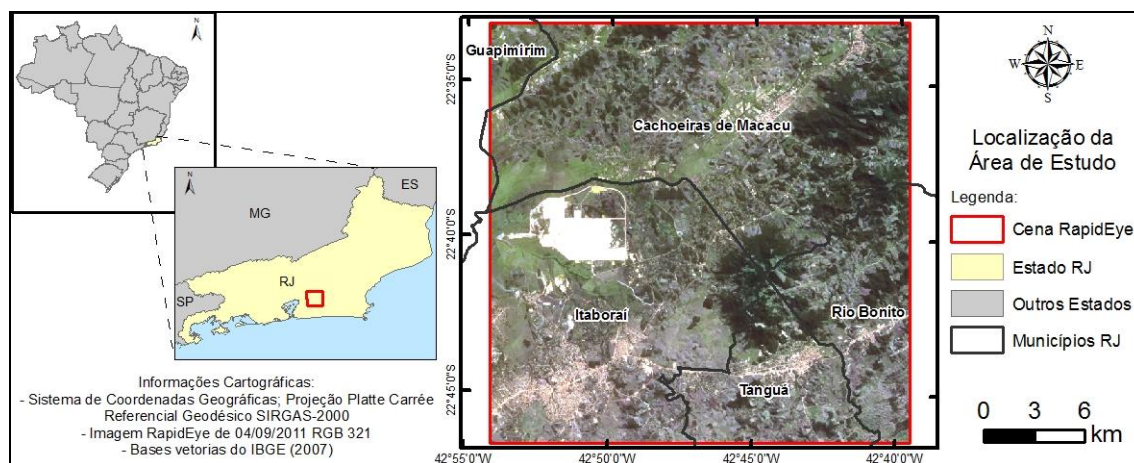


Figura 1. Localização da área de estudo.

2. Metodologia de Trabalho

2.1 Construção das imagens mudança

Como já visto, as imagens mudança são resultantes de técnicas baseadas em pixels. Elas tem este nome porque apresentam informações estatísticas entre as bandas do cubo multitemporal, que por sua vez, podem indicar possíveis áreas de mudanças na paisagem.

É comum encontrarmos na literatura, aplicações de detecção de mudanças que utilizem informações estatísticas inseridas diretamente no processo. As mais comuns são a razão e a subtração de bandas. Porém, esta técnica aplica-se somente às detecções bitemporais. Por se tratar de uma perspectiva multitemporal, com três datas, procurou-se adotar medidas de dispersão, como o desvio-padrão e a amplitude.

As imagens mudança foram calculadas no *software* ArcGis, através da ferramenta *Raster Calculator*. As mesmas foram adicionadas ao cubo multitemporal, tornando-se bandas desta imagem. Visualmente, a amplitude e o desvio-padrão das bandas 4 e 5 (borda do vermelho e vermelho, respectivamente) apresentam áreas com cores mais acentuadas (valores digitais altos), que podem representam áreas de mudança (Figura 2).

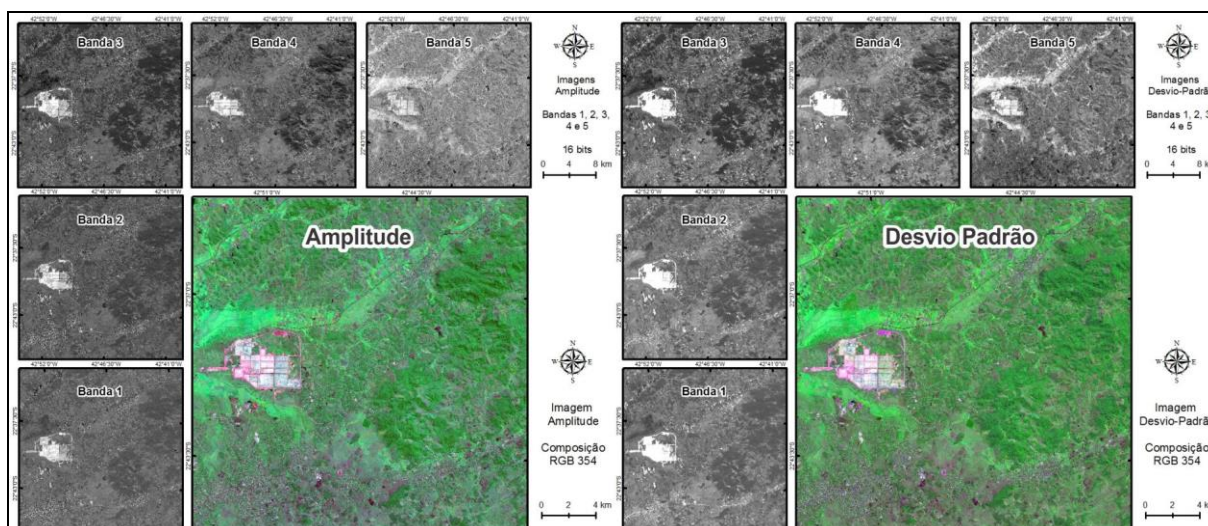


Figura 2. Bandas de imagens mudança geradas, com uma composição RGB 352.

2.2 Segmentação do cubo multitemporal

Ao todo dois projetos foram criados, um para cada imagem mudança (amplitude e desvio-padrão). O objetivo era verificar qual banda estatística tem maior precisão em separar as mudanças das não- mudanças, em imagens multitemporais.

A segmentação foi realizada no *software* eCognition 8.8. Somente as bandas das imagens mudança foram usadas para a segmentação da cena, evitando utilizar todo o cubo multitemporal, o que aumentaria o tempo de processamento e talvez não tivesse o resultado esperado. Após o teste de vários parâmetros de segmentação, uma combinação destes foi escolhida como satisfatória a todos os projetos: 200 de escala, 0.8 de forma e 0.5 de compacidade. Apesar de as imagens mudanças se distinguirem pela cor (valor dos pixels), um fator de forma mais alto resultou em melhores segmentações.

Vale ressaltar que quanto menor o fator de forma, maior será o peso da informação espectral (“cor”) no processo de segmentação. A forma, considerada no processo de segmentação, é composta pela compacidade e suavidade que agem da seguinte maneira: a suavidade procura separar objetos que possuem as bordas lineares e bem definidas, enquanto a compacidade extrai objetos compactos, mas que se distinguem de outros por um pequeno contraste (Araújo, 2006).



2.3 Classificação das mudanças

A classificação foi realizada no *software* eCognition, com ênfase na modelagem *fuzzy* e análise orientada a objetos. De acordo com Cruz et al. (2009), a análise *Fuzzy* fornece o grau de pertinência de um objeto para todas as classes definidas na legenda, numa lógica de probabilidades, cujos valores podem ser inseridos em novos contextos de classificação. Cruz et al. (2007) apontam que a classificação orientada a objeto busca simular técnicas de interpretação visual através da modelagem do conhecimento para identificação de feições, baseada na descrição de padrões identificadores, tais como textura, cor, métrica, contexto.

Utilizando a comparação das respostas espectrais disponibilizada pelo eCognition, com base nas amostras de treinamento, os descritores e seus respectivos limiares foram escolhidos

para a classificação entre mudanças e não-mudanças, utilizando somente as bandas das imagens mudança (Tabela 1). A fase de coleta de amostras das classes é considerada fundamental para o conjunto de respostas espectrais para cada classe no eCognition. Uma alternativa utilizada para esta coleta foi a geração de composições coloridas multitemporais no próprio software, ou seja, o uso de bandas de diferentes datas no canal RGB. Este tipo de composição evidencia visualmente áreas de mudanças, pois onde as mesmas acontecem, a cor fica mais vibrante, facilitando o processo de seleção das amostras (Figura 3). As imagens mudanças também são utilizadas no processo de amostragem, onde se observa a ocorrência dos maiores valores nas áreas de mudanças.

Tabela 1: Descritores utilizados por projeto na separação de mudança e não-mudança.

<i>Imagem mudança</i>	<i>Descritores (bandas)</i>	<i>Limiar</i>	<i>Modelo</i>
Amplitude	2 (Verde), 3 (Vermelho), 4 (Borda do Vermelho) e 5 (Infravermelho)	Fuzzy	
Desvio Padrão	2 (Verde), 3 (Vermelho), 4 (Borda do Vermelho) e 5 (Infravermelho)	Fuzzy	

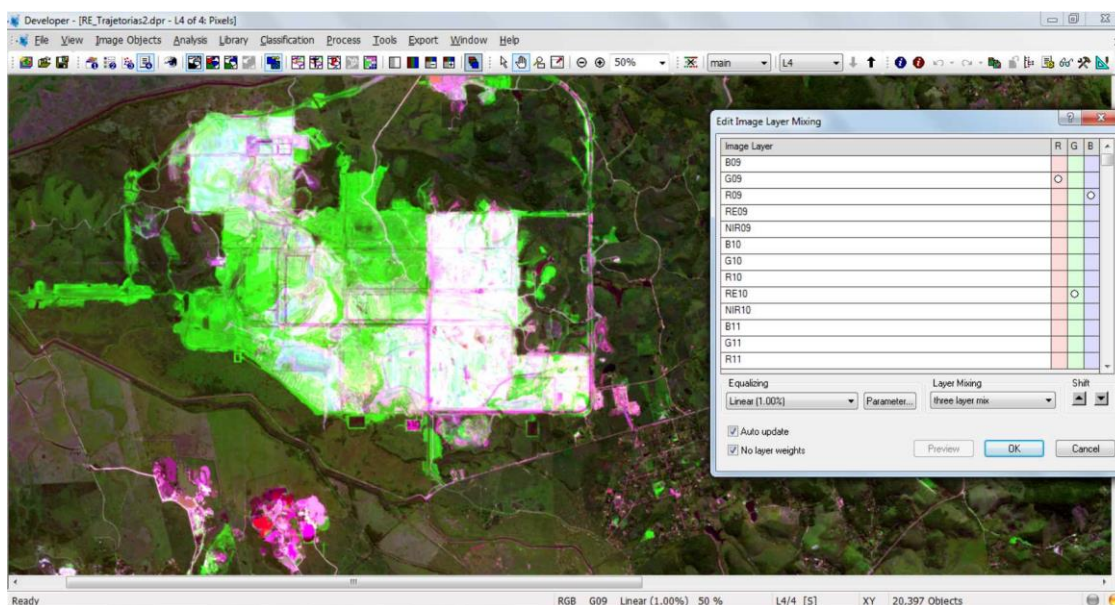


Figura 3: Composição R(G09)G(RE10)B(R09) no eCognition, usada como auxiliar na coleta das amostras de mudanças e não-mudança. (G) Verde, (R) Vermelho, (RE) Borda Vermelho.

Importante ressaltar que nenhuma edição manual foi aplicada na classificação das mudanças nos dois projetos, pois objetiva-se avaliar qual imagem mudança tem melhores resultados numa detecção de mudanças híbrida.

2.4 Validação dos resultados

Tema recorrente sobre detecção de mudanças, a avaliação da precisão da técnica é fundamental. Muitas são as possibilidades de avaliação. Neste trabalho optou-se por uma das mais comuns e efetivas, muito utilizadas na literatura: o índice kappa, associado à análise da matriz de confusão. Considera-se que a análise da matriz de confusão é tão importante quanto o índice kappa, pois permite identificar a principal fonte de erros da classificação, se é proveniente do algoritmo e/ou do pesquisador.

A seleção dos pontos amostrais para avaliação foi aleatória. No caso da análise de diferentes métodos numa mesma área de estudo, os pontos devem ser diferentes, evitando um efeito conhecido como pontos treinados, onde a localização dos mesmos pode superestimar os resultados. Além disso, Congalton (1991) destaca que um número representativo de amostras coletadas para uma avaliação seria de cinquenta, número este coletado para este trabalho, o que segundo o autor garante a relevância estatística dos dados.

A Figura 4 resume todas as etapas metodológicas supracitadas, destacando os softwares e ferramentas utilizadas para a detecção e validação das mudanças.

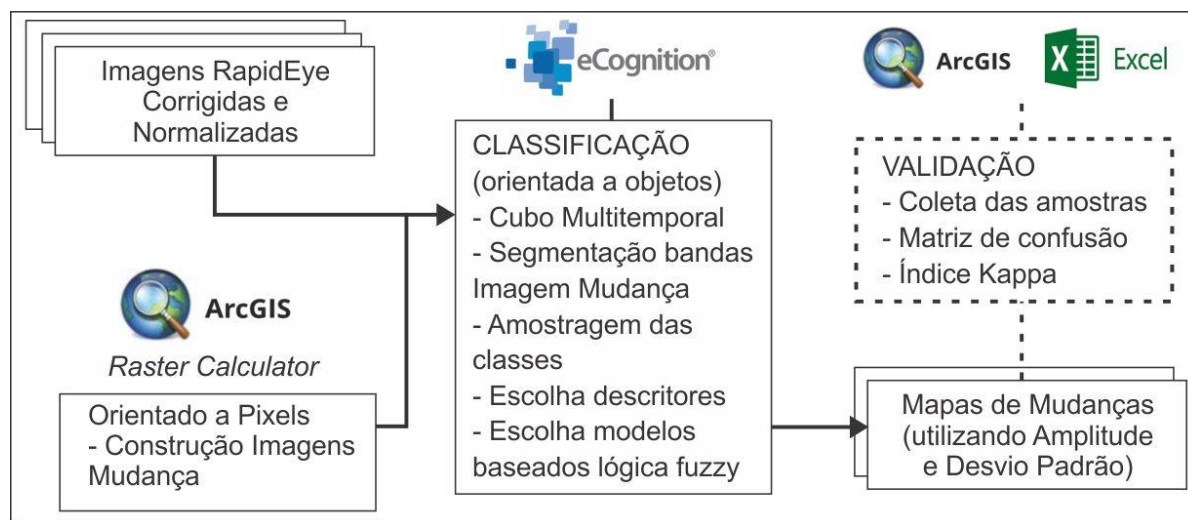


Figura 4. Fluxograma metodológico das correções nas imagens.

3. Resultados e Discussão

3.1) Amplitude

Esta imagem mudança foi importante na detecção de mudanças na paisagem, principalmente a amplitude das bandas potenciais aos estudos de vegetação (bandas 4 e 5) e a banda potencial em estudos antrópicos (banda 3). Na área de estudo, mudanças fenológicas nos vales dos grandes rios e algumas rotações de cultura foram detectadas. A área referente ao COMPERJ foi totalmente classificada como mudança, pois mesmo parte dela já sendo considerada uma área antrópica, ocorreu uma intensificação desta antropização, modificando a resposta espectral dos pixels, caracterizando-os como mudança (Figura 5).

Analisando a matriz de confusão na Figura 5, observa-se uma pequena confusão entre as classes, onde o algoritmo deixou de classificar algumas áreas de mudança, classificando-as como não-mudança. Com uma exatidão global de 87% e um índice kappa de 0,74 a amplitude foi a segunda melhor imagem mudança utilizada. Do total da cena, 4042 ha de mudança foram encontrados, o que corresponde a 6,46% (Tabela 2).

Tabela 2: Áreas das classes de mudança e não-mudança (utilizando a amplitude).

Classes	Área (hectares)	Área (%)
Mudança	4042	6,46
Não mudança	58508	93,54

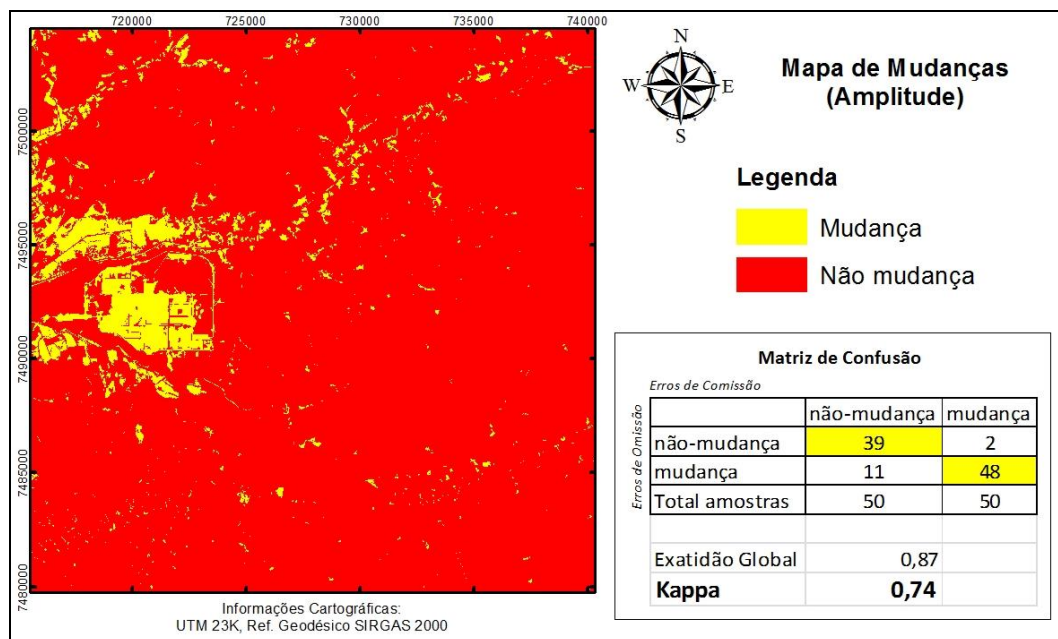


Figura 5: Mapa de mudanças, utilizando a amplitude como imagem mudança.

3.2) Desvio-Padrão

Assim como na amplitude, as bandas 3, 4 e 5 foram muito úteis no processo de detecção de mudanças utilizando o desvio-padrão, pois possibilitou detectar processos de intensificação de áreas antrópicas. As mudanças permanentes foram predominantes no processo de detecção, em detrimento das mudanças fenológicas, contribuindo com a proposta deste trabalho. Algumas rotações de cultura, na beira dos grandes rios, também foram detectadas.

Analisando a matriz de confusão na Figura 6 observam-se bons resultados, com erro de apenas uma amostra na classe de mudança. Com uma exatidão global de 94% e um índice kappa de 0,88 o desvio-padrão foi obtive uma ótima precisão em detectar as mudanças. Do total da cena, 2791 ha de mudança foram encontrados, o que corresponde a 4,46% (Tabela 3). Esta diminuição em relação à amplitude deve-se, provavelmente, a menor presença de mudanças fenológicas neste mapeamento.

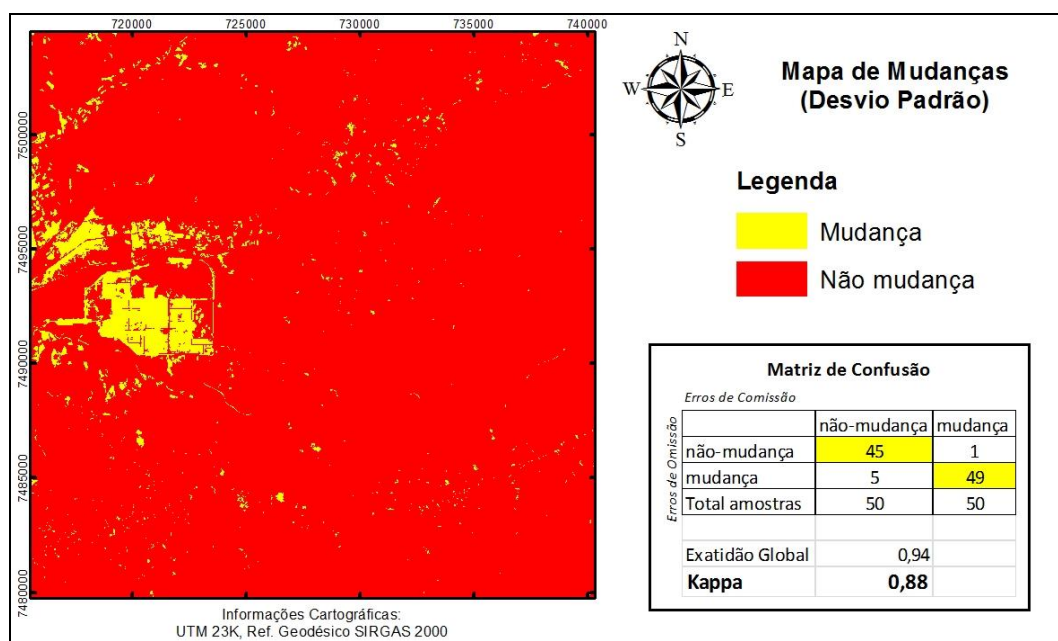


Figura 6: Mapa de mudanças, utilizando o desvio padrão como imagem mudança.

Tabela 3: Áreas das classes de mudança e não-mudança (utilizando o desvio padrão).

Classes	Área (hectares)	Área (%)
Mudança	2791	4,46
Não mudança	59784	95,54

Observa-se que o desvio padrão, em comparação com a amplitude, foi o que obteve os melhores resultados (Figura 7). Desta maneira seu uso para uma continuação do estudo dessas mudanças, especificando-as para obter as trajetórias evolutivas da cobertura da terra, por exemplo, é o mais indicado.

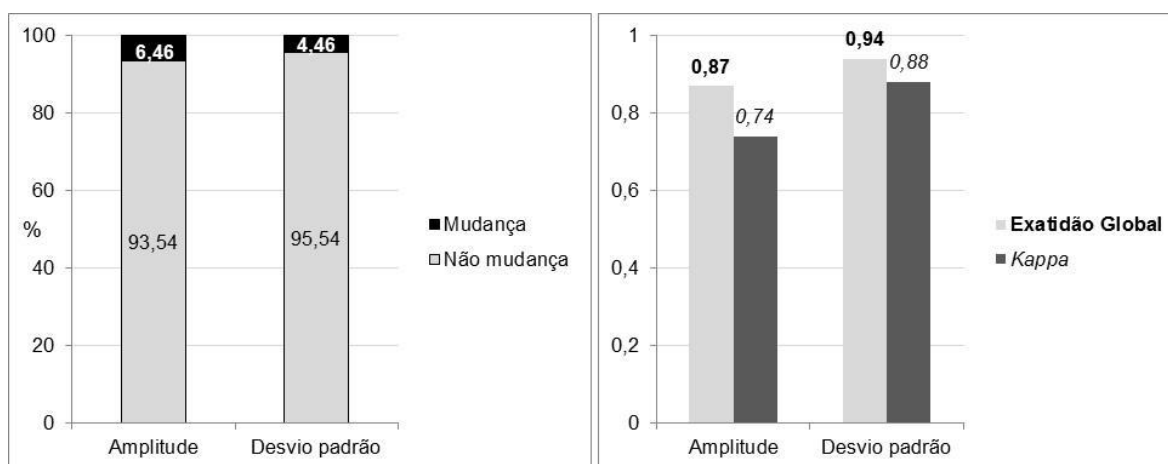


Figura 7. Áreas (em %) das classes mudanças e não-mudança utilizando amplitude e desvio-padrão como imagens mudança (à esq.) e seus respectivos resultados de validação (à dir.).

4. Considerações Finais

A detecção de mudanças híbrida representa uma possibilidade interessante e eficiente nesta temática. A construção das imagens mudança, através de técnica baseada em pixels, foi fundamental para a detecção de mudanças, baseada em objetos. Seu uso no processo de segmentação possibilitou extrair os objetos que mudaram de uma forma mais precisa e rápida, visto o que o tempo de processamento foi bem menor na comparação com o uso de todo o cubo multitemporal neste processo.

O mapeamento de mudanças realizado com auxílio das imagens desvio padrão apresentou os melhores resultados. Acredita-se que a vantagem deste em relação aos outros talvez seja sua capacidade de trabalhar com dados multitemporais, ao invés de bitemporais, gerando medidas de dispersão com um menor intervalo que a amplitude, logo um limiar mais baixo de separação entre as classes de mudanças e não-mudança.

Contudo, fica a necessidade de aprofundar os estudos em relação ao comportamento desta medida de dispersão, utilizando séries temporais maiores e imagens de satélite com menor resolução radiométrica.

Agradecimentos

Os autores agradecem ao Laboratório de Geografia Física (LAGEF), da Universidade Federal Fluminense (UFF); à Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes), pelo apoio a esta pesquisa.

Referências Bibliográficas

- Araújo, E.H.G. Análise Multi-Temporal de cenas do satélite Quickbird usando um novo paradigma de classificação de Imagens e inferências espaciais: estudo de caso em Belo Horizonte, MG. 2006. 175 p. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP. 2006.
- Chen, G.; Hay, G.J.; Carvalho, L.M.T.; Wulder, M.A. Object based change detection. **International Journal of Remote Sensing**, v. 33, n. 14, p. 4434-4457, 2012.
- Congalton, R.G. (1991) A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, p. 35-76, 1991.
- 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. 09, n° 05, p. 1565-1596, 2004.
- Cruz, C.B.M.; Vicens, R.S.; Seabra, V.S.; Reis R.B.; Faber, O.A.; Richter, M.; Arnaut, P.K.E.; Araújo, M. Classificação orientada a objetos no mapeamento dos remanescentes da cobertura vegetal do bioma Mata Atlântica, na escala 1:250.000. **Anais do XIII Simpósio Brasileiro de Sensoriamento Remoto**. Florianópolis, SC, Brasil. INPE, p. 5691-5698, 2007.
- Cruz, C.B.M.; Vicens, R.S.; Rosário, L.S.; Abreu, M.B.; Almeida, P.M.M.; Cronemberger, F.M. Classificação orientada a objetos na geração do mapa de uso e cobertura do estado do Rio de Janeiro. **Anais do XIV Simpósio Brasileiro de Sensoriamento Remoto**. Natal, RN, Brasil. INPE, p. 7789-7796, 2009.
- Jensen, J.R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 604 p.
- Jianya, G.; Haigang, S.; Guorui, M.; Qiming, Z. A Review of Multi-Temporal Remote Sensing Data Change Detection Algorithms. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B7. Beijing, China. 2008.
- Kiel, R. Detecção de mudanças no uso e na cobertura do solo em uma série temporal de imagens da região da Campanha do Rio Grande do Sul. Dissertação (Mestrado em Sensoriamento Remoto). 2008. 203 p. Universidade Federal do Rio Grande do Sul, Porto Alegre, RS. 2008.
- Lu D.; Mausel, P.; Brondizio, E.; Moran, E. Change detection techniques. **International Journal of Remote Sensing**, v. 25, n° 12, p. 2365-2407, 2004.
- Peiman, R. Pre-classification and post-classification change-detection techniques to monitor land-cover and land-use change using multi-temporal Landsat imagery: a case study on Pisa Province in Italy. **International Journal of Remote Sensing**, v. 32 n. 15, p. 4365-4381, 2011.
- Singh, A. Digital Change Detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10 n. 06, p. 989-1003, 1989.