




www.ugb.org.br
ISSN 2236-5664

Revista Brasileira de Geomorfologia

v. 18, nº 4 (2017)

<http://dx.doi.org/10.20502/rbg.v18i4.1249>



CLASSIFICAÇÃO SEMIAUTOMÁTICA DE CICATRIZES DE MOVIMENTOS DE MASSA POR MEIO DE TÉCNICAS DE DETECÇÃO DE MUDANÇAS

MASS MOVEMENT SCARS MAPPING USING CHANGE DETECTION TECHNIQUES

Jéssica Gerente

*Divisão de Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais
Av. dos Astronautas, 1758, São José dos Campos, São Paulo. CEP: 12.245-970. Brasil
Email: jessicagerente@gmail.com*

Mikhaela Aloísia Jéssie Santos Pletsch

*Divisão de Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais
Av. dos Astronautas, 1758, São José dos Campos, São Paulo. CEP: 12.245-970. Brasil
Email: mkmapa@gmail.com*

Camile Sothe

*Divisão de Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais
Av. dos Astronautas, 1758, São José dos Campos, São Paulo. CEP: 12.245-970. Brasil
Email: camilesothe@yahoo.com.br*

Cristiane Nunes Francisco

*Departamento de Análise Geoambiental, Universidade Federal Fluminense
Av. Gal. Milton Tavares de Souza, s/nº, Niterói, Rio de Janeiro. CEP: 24.210-346. Brasil
Email: crisnff@vm.uff.br*

Informações sobre o Artigo

Recebido (Received):

30/03/2017

Aceito (Accepted):

24/07/2017

Palavras-chave:

Movimentos de Massa; Classificação de Imagens; *Random Forest*.

Keywords:

Mass Movements; Image Classification; Random Forest.

Resumo:

Movimentos de massa são fenômenos naturais que muitas vezes causam perdas e danos à sociedade. Inventários de cicatrizes podem auxiliar no entendimento da suscetibilidade de um local frente a esses processos. Nessa vertente, o uso de ferramentas de sensoriamento remoto para a detecção e o mapeamento de cicatrizes de movimentos de massa pode ser vantajoso, principalmente em escalas regionais e em áreas de difícil acesso. No entanto, mapeamentos semiautomáticos ainda se mostram incipientes no âmbito nacional. Nesse contexto, o objetivo deste trabalho foi avaliar múltiplas técnicas de detecção de mudanças para o mapeamento semiautomático de cicatrizes de movimentos de massa. Como estudo de caso, foram analisados os movimentos deflagrados em janeiro de 2011 em uma porção do município de Nova Friburgo (RJ). Para isso, foram geradas imagens de detecção de mudanças por meio das técnicas PCA, ICA, MNF, SA, OSAVI e subtração de bandas espectrais. Os produtos que melhor destacaram os movimentos de massa foram selecionados como dados de entrada para a classificação por meio do algoritmo *Random*

Forest. A diferença entre o índice de vegetação OSAVI pré e pós-evento foi considerada a técnica de maior importância para o classificador. Já na análise visual, verificou-se que a 3ª e 4ª componentes ICA, MNF e PCA também destacaram bem as cicatrizes. O desempenho da classificação foi considerado satisfatório, uma vez que detectou mais de 80% das cicatrizes de movimento de massa na área de estudo. Esse trabalho permitiu verificar ainda, que o uso de métodos semiautomatizados pode ser uma abordagem em potencial para a detecção de cicatrizes de movimento de massa, sobretudo aplicado a mapeamentos preliminares e emergenciais.

Abstract:

Mass movement is a natural phenomenon frequently associated with damages to the society. Its inventories assist the comprehension of mass movement spatial distribution and susceptibility. Thus remote sensing techniques enable detection and mapping of mass movement scars worldwide in large scales and in areas of difficult access. However, its use is still incipient in a national level. In this context, the aim of this paper is to assess multiple techniques that may support mass movement mapping automation. The research was carried out in a specific case study located in the municipality of Nova Friburgo (RJ-Brazil). A total of six change detection techniques were evaluated: PCA, ICA, MNF, SA, OSAVI and multi-band spectral subtraction. The techniques that best highlighted the mass movements were then selected as input data for the final classification through Random Forest algorithm. As a result, the difference between OSAVI pre and post mass movements event image was considered by the classifier the most important change detection technique. Visual analysis also showed that the 3rd and 4th components ICA, MNF and PCA efficiently highlighted the scars. The classification was satisfactory, once its accuracy was higher than 80%, according to the reference inventory. This work allowed to verify also that the use of semiautomated methods can be a suitable approach for mass movement scars detection, mainly in preliminary and emergency mapping.

1. Introdução

Movimentos de massa são processos que podem provocar grandes transformações no relevo, sendo caracterizados pela transferência de materiais (rocha, regolito e/ou solo) encosta abaixo sob ação da força da gravidade (CROZIER, 1986; SELBY, 1993). Quando deflagrado em porções habitadas do território, esse fenômeno pode causar graves consequências à sociedade. Por esta razão, o mapeamento das zonas mais suscetíveis à ocorrência destes processos se mostra como um relevante instrumento de planejamento e gestão pública.

Dentre outras informações, para a elaboração de um mapa de suscetibilidade a movimentos de massa é importante que se conheçam os locais de ocorrências pretéritas destes processos (FERNANDES e AMARAL, 2003). Desta forma, a investigação de metodologias que visem à melhoria do mapeamento de cicatrizes de movimentos de massa pode contribuir para o aumento do conhecimento das características de suscetibilidade dos terrenos.

Em geral, a elaboração de mapeamentos de cicatrizes de movimentos de massa é baseada na interpretação visual de imagens aliada ou não a pesquisas de campo e consultas a dados complementares. Contudo,

a análise visual de imagens pode ser uma tarefa custosa e subjetiva (dependente da experiência do intérprete). Ainda, para muitos casos, pesquisas em campo podem ser impraticáveis e informações suplementares podem ser inexistentes, inacessíveis ou incompletas (ESCAPE *et al.*, 2014). Nesse contexto, o sensoriamento remoto aliado às técnicas de processamento digital de imagens (PDI) se mostra uma alternativa eficaz de fonte de dados, viabilizando análises espaço-temporais de diferentes fenômenos como, por exemplo, movimentos de massa.

Em âmbito internacional, é possível observar esforços para o desenvolvimento de metodologias que buscam subsidiar e automatizar o mapeamento de cicatrizes de movimentos de massa (MOINE *et al.*, 2009; MONDINI *et al.*, 2011; GUZZETTI *et al.*, 2012; BLASCHKE e FEIZIZADEH, 2014; HÖLBLING *et al.*, 2015). Dentre estes, o uso de técnicas de detecção de mudanças e algoritmos de classificação de imagens tem se mostrado eficiente para a detecção de cicatrizes (GONG *et al.*, 2008; MONDINI *et al.*, 2011; HÖLBLING *et al.*, 2015), embora ainda seja incipiente no país.

Nesse contexto, o objetivo deste trabalho foi avaliar o uso de múltiplas técnicas de detecção de mudanças na classificação semiautomática de cicatrizes

de movimentos de massa deflagradas em janeiro de 2011 em uma porção do município de Nova Friburgo (RJ). Para isso, foram geradas imagens de detecção de mudanças por meio das técnicas de componentes principais (*Principal Component Analysis - PCA*), análise de componentes independentes (*Independent Component Analysis - ICA*), fração de ruído mínimo (*Minimum Noise Fraction - MNF*), diferença entre o índice de vegetação corrigido para o solo pré e pós-evento (*Optimized Soil Adjusted Vegetation Index - OSAVI*), o mapeador de ângulo espectral (*Spectral Angle - SA*) e subtração de bandas espectrais pré e pós-evento. Os produtos que melhor destacaram os movimentos de massa foram então selecionados como os dados de entrada para a classificação semiautomática por meio do algoritmo *Random Forest (RF)*.

2. Área de Estudo

A área de estudo possui cerca de 40 km² e localiza-se na bacia do rio Roncador, no noroeste do municí-

pio de Nova Friburgo – Rio de Janeiro (Figura 01). Este município, por sua vez, está situado na unidade geomorfológica denominada Planalto Reverso da Região Serrana e possui relevo montanhoso a escarpado (DANTAS, 2001).

Os terrenos são compostos basicamente por gnaisse e granitóides gerados por diferentes episódios geológicos. Além disso, a área estudada passou por um intenso processo de tectonismo colisional, gerando uma série de fraturas e foliações (AVELAR *et al.*, 2016). Estas características geológicas podem contribuir para a formação de descontinuidades hidráulicas nas encostas, o que pode ser um condicionante para a ocorrência de movimentos de massa.

Em um evento excepcional de chuvas ocorrido entre os dias 11 e 12 de janeiro de 2011, esta região foi gravemente afetada por cerca de 4.000 ocorrências de movimentos de massa, os quais ocasionaram em mais de 1.500 óbitos, milhares de desalojados e desabrigados, além de diversos prejuízos econômicos (COELHO NETO *et al.*, 2011; AVELAR *et al.*, 2016).



Figura 1 - Mapa de localização da área de estudo, situada na região noroeste do município de Nova Friburgo/RJ.

3. Materiais e Métodos

A metodologia empregada neste trabalho baseia-se nas abordagens propostas por Mondini *et al.* (2011). Como fonte de dados pré-evento, foi utilizada uma cena fusionada do sensor ALOS/AVNIR-2 com o sensor ALOS/PRISM, ambas obtidas em 2010. O ALOS/AVNIR-2 possui quatro bandas multiespectrais, correspondendo às três bandas do visível (VIS) e uma no infravermelho próximo (IVP), e resolução espacial de 10m. O sensor ALOS/PRISM é pancromático e possui resolução espacial de 2,5m.

Como imagem pós-evento, foi utilizada uma cena da constelação de satélites RapidEye obtida em agosto de 2011. O sensor desses satélites possui três bandas espectrais na região do VIS, uma banda correspondendo à região espectral do IVP e, ainda, uma banda localizada entre as regiões do vermelho e IVP, denominada *Red-Edge* ou vermelho limítrofe (não utilizada neste estudo). As imagens RapidEye possuem 5m de resolução espacial. A esquematização das etapas metodológicas realizadas pode ser encontrada na figura 2.

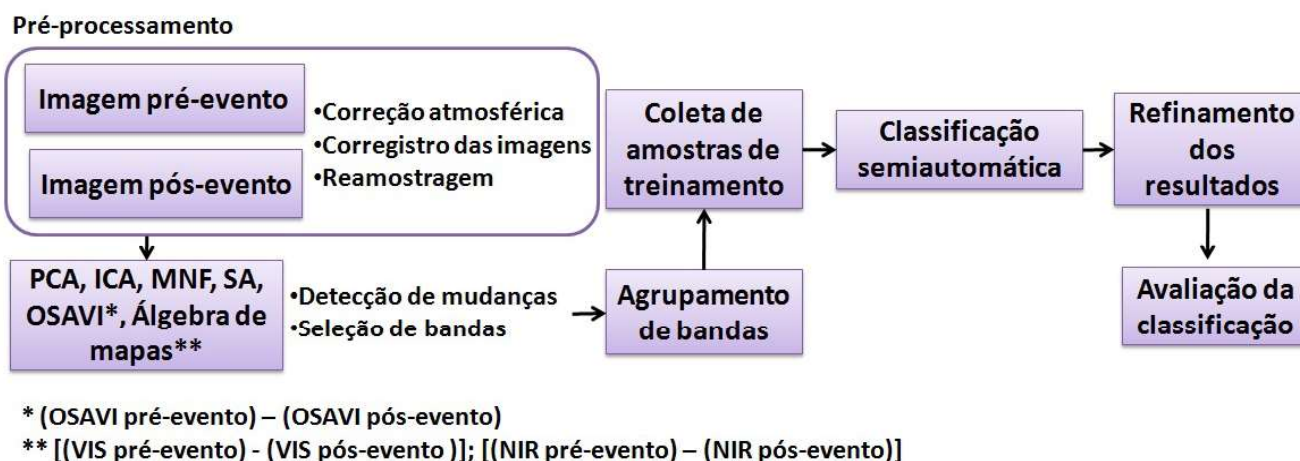


Figura 2 - Esquematização da metodologia empregada.

Para a correção atmosférica entre as imagens pré e pós-evento, o algoritmo *Quick Atmospheric Correction* (*software* ENVI 5.0) foi utilizado. Apesar não haver deslocamentos significativos entre as duas imagens, foi efetuado um corregistro com 15 pontos de controle inseridos manualmente, obtendo um erro (*Root Mean Square Error*) menor que 0,35m. Posteriormente, a imagem RapidEye foi reescalada para 8 bits e a imagem do sensor ALOS foi reamostrada para 5m pelo algoritmo de interpolação vizinho mais próximo. Por fim, ambas as imagens passaram por uma normalização radiométrica por meio da função *Histogram Match* do ENVI 5.0.

Após a etapa de pré-processamento, foram aplicados distintos métodos de detecção de mudanças sobre as imagens pré e pós-evento: PCA, ICA, MNF, diferença entre OSAVI pré e pós-evento e SA. Além disso, foram realizadas subtrações entre bandas correspondentes às imagens de pré e pós-evento. Tais métodos foram selecionados considerando o seu amplo uso na literatura (RONDEAUX *et al.*; 1996; ROBILA, 2005; MONDINI

et al., 2011).

Conforme aponta Jolliffe (2002), a análise PCA é provavelmente uma das mais antigas e difundidas técnicas de análise multivariada. O principal objetivo da PCA é reduzir a dimensionalidade de um conjunto de dados, os quais podem estar interrelacionados a algumas variáveis, preservando ao máximo as variações presentes no conjunto de dados.

Semelhante a PCA, a ICA também objetiva separar atributos redundantes por meio de transformações geométricas (ROBILA, 2005; MONDINI *et al.*, 2011). A ICA consiste em definir uma transformação linear dos valores do espaço de atributos da imagem de modo que a dependência estatística entre as componentes seja minimizada (COMON, 1994), ressaltando, assim, possíveis variações entre imagens.

Segundo Mondini *et al.* (2011), tanto as componentes principais quanto as componentes independentes são combinações lineares das variáveis originais proje-

tadas em novos eixos ortogonais. Através da projeção nestes novos eixos, as informações comuns presentes nas imagens originais são separadas e, ao mesmo tempo, feições de mudanças são redistribuídas em diferentes componentes. Apesar de suas vantagens, as componentes principais nem sempre produzem imagens de boa qualidade. Assim, foi proposto por Green *et al.* (1988) o método MNF, o qual remove ruídos das transformações lineares. Este método é baseado em duas rotações, sendo que a primeira utiliza as componentes principais da matriz de covariância do ruído para reescalonar e descorrelacionar os valores. Em seguida, a segunda rotação utiliza as componentes principais derivadas da primeira rotação, empregando assim somente as porções coerentes, e separando o ruído da imagem (ENVI, 2004).

O índice OSAVI (Equação 1) foi proposto por Rondeaux *et al.* (1996) e corresponde a uma modificação do Índice de Vegetação Ajustado ao Solo (*Soil Adjusted Vegetation Index* - SAVI), o qual por sua vez deriva do Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI). O OSAVI possui o valor de 0,16 para o fator de ajuste de fundo do dossel. Rondeaux (1996) identificou que este valor fornece maior variação do solo do que o SAVI para cobertura vegetal baixa, demonstrando maior sensibilidade à cobertura vegetal superior a 50%. Este índice é mais comumente utilizado em áreas com vegetação relativamente escassa, onde o solo é visível através do dossel. Assim, ele pode ser considerado vantajoso por ser simples e por não requerer informações prévias sobre parâmetros do solo. Neste trabalho, realizou-se uma diferença entre a imagem OSAVI pré e pós-evento a fim de se destacarem as mudanças entre as duas cenas (Equação 2).

$$OSAVI = (\rho_{IVP} - \rho_{red}) / (\rho_{IVP} + \rho_{red} + 0,16) \quad (1)$$

$$Dif_OSAVI = OSAVI_{(pré-evento)} - OSAVI_{(pós-evento)} \quad (2)$$

onde: ρ_{IVP} = reflectância no Infravermelho Próximo;
 ρ_{red} = reflectância no Vermelho.

O SA é um método automático para a comparação direta do formato de curvas espectrais. Quando aplicado para a detecção de mudança, esse índice expressa a

diferença do padrão de forma espectral dos alvos em uma mesma localização geográfica entre as datas pré e pós-evento (SOHN e REBELLO, 2002; MASEK e SUN, 2004). Se não houver mudança, ou apenas mudança linear, devido à iluminação ou efeito topográfico, o índice SA será próximo de zero. Em caso de mudança causada por um agente externo, como por exemplo, um movimento de massa, o SA será maior do que zero. Portanto, o SA pode ser utilizado como um fator para alterações que não estão diretamente relacionadas com a perda de vegetação. O índice pode ser calculado por meio da Equação 3.

$$SA = \arccos\left(\frac{\mathbf{u} \cdot \mathbf{v}}{|\mathbf{u}| \cdot |\mathbf{v}|}\right) \quad (3)$$

Sendo:

$$\mathbf{u} = [B_{azul}, B_{verde}, B_{vermelho}, B_{IVP}]_{pré}$$

$$\mathbf{v} = [B_{azul}, B_{verde}, B_{vermelho}, B_{IVP}]_{pós}$$

onde: B = bandas utilizadas.

Outra técnica de detecção de mudanças que, apesar de simples, pode gerar bons resultados é a diferença entre bandas multiespectrais. Por este método, imagens corregistradas e normalizadas radiométricamente adquiridas em diferentes momentos são subtraídas uma da outra e, a partir desta operação, valores diferentes de zero indicam ocorrência de mudança nos alvos (Equação 4).

$$Dif_Bx = Bx_{(pré-evento)} - Bx_{(pós-evento)} \quad (4)$$

onde: Bx = Banda espectral de determinada região espectral x .

Por meio de inspeção visual dos resultados, as técnicas que melhor discriminaram as cicatrizes de movimentos de massa foram selecionadas para serem utilizadas na etapa da classificação. Os seguintes produtos foram escolhidos: 1) 3ª e 4ª componentes das técnicas PCA, ICA e MNF; 2) SA; 3) diferença entre os OSAVI pré e pós-evento; e 4) diferença entre cada banda espectral da imagem pré-evento e a respectiva banda correspondente na imagem pós-evento. Foram escolhidas apenas as 3ª e 4ª componentes da PCA, ICA e MNF pelo fato de terem

sido as que melhor destacaram visualmente as cicatrizes movimentos de massa, considerando-se, desta forma, desnecessário o uso das outras componentes.

A partir disso, procedeu-se a coleta das amostras de treinamento. Nesta etapa, foram definidas apenas duas classes, uma abrangendo as mudanças relacionadas aos movimentos de massa, para a qual foram coletados 15.744 *pixels* de treinamento, e a classe “outras”, para a qual foram coletados 84.022 *pixels* de treinamento compreendendo os locais da imagem em que não ocorreram mudanças relacionadas aos movimentos de massa entre as duas datas avaliadas.

A classificação da imagem composta pelos *layers* de detecção de mudança foi realizada com o algoritmo não paramétrico *Random Forest* (RF) implementado plataforma EnMAP-BOX (VAN DER LINDEN, 2015). O RF é uma técnica desenvolvida por Breiman (2001) como forma de melhorar a árvore de classificação e regressão através da combinação de um grande número de conjuntos de árvores de decisão. Cada árvore contribui com um único voto, e a classificação final é determinada pela maioria dos votos de todas as árvores da floresta. As amostras que não são utilizadas no sorteio inicial são chamadas de *Out-Of-Bag* (OOB) e podem ser utilizadas para estimar erros de classificação e obter a importância das variáveis (ADAM *et al.*, 2014). O algoritmo RF possui dois parâmetros a serem determinados: número de variáveis (*ntry*) e de árvores (*nree*). Rodriguez-Galiano *et al.* (2012) realizaram uma avaliação empírica do parâmetro número de árvores e verificaram que as diferenças na precisão de classificação após 100 árvores eram pequenas. Desta forma, optou-se por utilizar 100 árvores, enquanto que para o parâmetro *ntry* foi mantida a configuração padrão, que corresponde à raiz quadrada do número total de bandas espectrais usadas em cada experimento (BREIMAN, 2001).

Este algoritmo também foi utilizado para verificar a importância das variáveis na classificação. Para isso, as amostras OOB são permutadas na respectiva variável e suprimidas de cada árvore. A partir disto, as precisões são computadas. Em seguida, as precisões das amostras permutadas OOB são subtraídas das precisões das amostras originais. A média das diferenças das precisões de uma variável é a importância bruta para essas variáveis. A divisão da importância da variável bruta pelo respectivo desvio padrão resulta na importância normalizada da variável. Um valor elevado significa que a variável tem uma grande importância para todo o RF e vice-versa (JAKIMOW *et al.*, 2014).

Após a classificação, foi feito um refinamento dos resultados com o objetivo de excluir áreas erroneamente classificadas como movimentos de massa, pelo fato de ter ocorrido alguma outra mudança na cobertura da terra no período estudado. Para este refinamento, dois procedimentos foram realizados: 1) exclusão dos polígonos menores ou iguais a 400 m², de modo a diminuir ruídos, e 2) exclusão dos polígonos localizados em uma máscara de uso urbano e de uso agrícola, uma vez que estas classes são mais sujeitas a alterações ao longo do tempo e, por isso, possuem maior probabilidade de gerar erros de comissão.

Por fim, como produto de referência para a validação da classificação, foi realizado um mapeamento das cicatrizes de movimentos de massa presentes na área de estudo, por meio de interpretação visual da imagem multiespectral do sensor RapidEye e com o auxílio de imagens históricas e de alta resolução espacial disponíveis no aplicativo *Google Earth*. Vale ressaltar que a coleta de amostras para a classificação e o mapeamento por interpretação visual foram realizados por intérpretes diferentes.

Como os movimentos de massa no episódio estudado foram deflagrados devido ao grande volume de chuva, estes fenômenos acabaram modificando uma extensa área nas encostas e fundos de vale. Muitos dos materiais mobilizados sofreram liquefação completa ou parcial devido ao acúmulo de água e, portanto, transformaram-se em fluxos que modificaram também os canais fluviais. Desta forma, na elaboração do mapa de referência, foram consideradas tanto as feições erodidas presentes nas encostas quanto as presentes nas margens de canais fluviais, situados muitas vezes nos fundos de vale, os quais sofreram impactos diretos em razão do transporte e deposição de materiais advindos das rupturas e/ou deformações das encostas.

Para avaliar os resultados, a classe considerada “mudança” devido à existência de cicatrizes de movimentos de massa entre as imagens pré e pós-evento (2010 e 2011), foi comparada com o mapa de referência por meio de uma tabulação cruzada. Deste cruzamento, calcularam-se os seguintes parâmetros: verdadeiros positivos - VP (acertos), falsos negativos - FN (omissão), falsos positivos - FP (comissão), porcentagem de detecção - PD (Equação 5), porcentagem de qualidade - PQ (Equação 6), erros de omissão - EO (Equação 7) e erros de comissão - EC (Equação 8).

$$\text{Porcentagem de Detecção (PD)} = 100 \times \frac{VP}{VP+FN} \quad (1)$$

$$\text{Porcentagem de Qualidade (PQ)} = 100 \times \frac{VP}{VP+FN+FP} \quad (2)$$

$$\text{Porcentagem de Erros de Omissão (EO)} = 100 - PD \quad (3)$$

$$\text{Porcentagem de Erros de Comissão (EC)} = 100 \times \frac{FP}{VP+FP} \quad (4)$$

Os acertos compreendem aos movimentos de massa corretamente detectados. Os erros de omissão correspondem aos movimentos de massa que existem na referência, porém não foram detectados pela abordagem de classificação. Os erros de comissão correspondem às áreas classificadas como movimentos de massa, mas que não são consideradas movimentos de massa no mapa de referência. A porcentagem de detecção corresponde ao percentual de movimentos de massa que foi corretamente identificado pelo classificador. Por fim, a porcentagem de qualidade representa um indicador que relaciona os alvos corretamente mapeados com os possíveis erros de identificação, indicando a probabilidade de uma cicatriz

de movimento de massa ser corretamente classificada (BEHLING *et al.*, 2014).

4. Resultados e Discussão

Entre os primeiros resultados destacam-se os produtos derivados das técnicas de detecção de mudanças relacionados com a ocorrência dos movimentos de massa. Na Figura 3, observam-se as imagens resultantes de algumas das técnicas de detecção de mudanças utilizadas como dados de entrada no classificador RF. De modo geral, percebe-se que essas técnicas conseguiram, em diferentes níveis de intensidade, destacar as mudanças na paisagem relacionadas à ocorrência de movimentos de massa. Nos quadros da Figura 3, as cicatrizes se destacam por apresentarem cores diferentes das áreas não afetadas. Os quadros “a” e “d” da Figura 3 representam as técnicas ICA e MNF, respectivamente, ambas em uma composição “R4-B3-G4”, já que as componentes 3 e 4 de ambas as técnicas foram as que melhor destacaram as mudanças do uso da terra relativas à ocorrência dos movimentos de massa.




Figura 3 - Resultado de quatro técnicas de detecção de mudanças: a) ICA (R4-B3-G4); b) SA; c) OSAVI; d) MNF (R4-B3-G4).

Mondini *et al.* (2011), ao testarem técnicas de detecção de mudanças para identificar áreas atingidas por movimentos de massa em Taiwan, indicaram que a 4ª componente do MNF e PCA foi a de maior relação com a ocorrência de movimentos de massa mais recentes no terreno. No presente trabalho, a 4ª componente das técnicas ICA e MNF também gerou bom destaque visual das mudanças. Porém, na PCA, foi a 3ª componente que demonstrou melhor destaque das ocorrências de movimentos de massa.

Os quadros “b” e “c” da Figura 3 representam as técnicas de OSAVI e SA, respectivamente. Em comparação ao SA, o OSAVI se mostrou mais satisfatório para identificar visualmente as áreas afetadas. Além da interpretação visual, pode-se perceber pelo gráfico da Figura 4 que o OSAVI teve um valor de importância

maior que o SA para classificação digital das áreas atingidas pelo algoritmo RF.

A Figura 4 apresenta o peso de cada técnica de detecção de mudança para a classificação das áreas afetadas por movimentos de massa a partir do uso do algoritmo RF. O método OSAVI obteve maior peso dentre as demais técnicas para a classificação, tal superioridade pode ser observada também em relação à avaliação visual deste índice (Figura 3). Em geral, valores altos de OSAVI indicam maior atividade fotossintética e maior cobertura de vegetação. Desta forma, os valores negativos obtidos na diferença entre os pares de imagens OSAVI pré e pós-evento podem servir como indicativo de potenciais áreas de ocorrência de movimentos de massa, já que identificam áreas com perda de vegetação entre as datas.

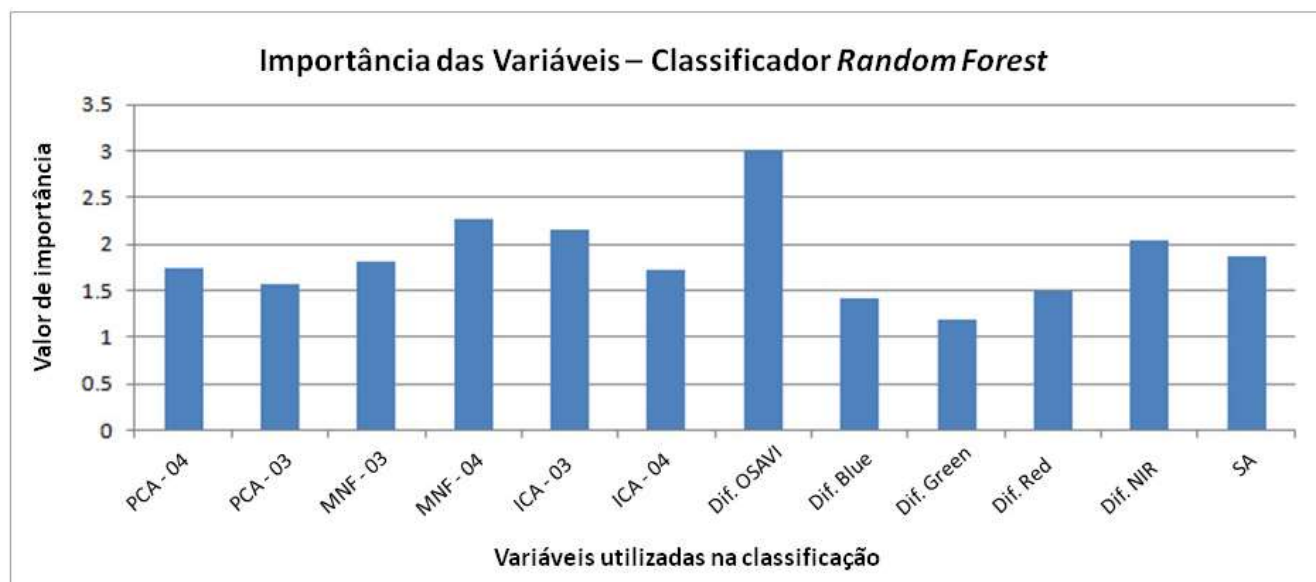


Figura 4 - Valor de importância de cada variável na classificação com o algoritmo Random Forest.

Percebe-se que as bandas que tiveram menor valor de importância para a classificação foram as subtrações entre imagens pré e pós-evento relativas à faixa espectral do verde, azul e vermelho, respectivamente (Figura 4), enquanto que a subtração entre as bandas da região do IVP teve maior importância. Isso pode ser atribuído ao fato de que o solo exposto reflete com maior intensidade nesta faixa espectral. Porém, apesar de alguns valores de importância das variáveis escolhidas pelo classificador assemelharem-se ao que seria considerado pela interpretação visual, diferentemente de uma classificação por árvore de decisão, o RF não explicita o conjunto de regras de decisão utilizado para

classificar a imagem. Isto limita a interação do usuário no processo da classificação e a replicação do resultado para outras áreas.

A Figura 5 apresenta uma porção da área de estudo. A parte superior desta figura mostra, à esquerda, a imagem de antes da ocorrência dos movimentos de massa e à direita a imagem pós-evento. A parte inferior da figura apresenta, à esquerda, o resultado do mapeamento realizado por interpretação visual, o qual foi considerado como referência para a avaliação da classificação digital e à direita apresenta o resultado do mapeamento gerado por meio do classificador RF, utilizando como dados as múltiplas técnicas de detecção de mudanças.




Figura 5 - Comparação entre imagens pré e pós-evento, mapa de referência e a classificação Random Forest.

Percebe-se, a partir da amostra mais detalhada dos resultados presentes na Figura 5, que a metodologia para a classificação semiautomática adotada neste trabalho apresentou bons resultados em relação à precisão e exatidão do mapeamento das cicatrizes de movimentos de massa. Nota-se que o uso de imagens bitemporais intensifica as mudanças na paisagem e, portanto, pode melhorar o desempenho da classificação supervisionada. A classificação semiautomática possibilitou maior precisão na delimitação das bordas das cicatrizes de movimentos de massa do que o inventário elaborado por interpretação visual, o qual está sujeito a variações de acordo com a escala de mapeamento e percepção do intérprete.

A Tabela 1 mostra os resultados da classificação se-

miautomática. A área total das cicatrizes de movimentos de massa presentes no mapa de referência foi de 391,17 ha, enquanto que a área classificada foi de aproximadamente 330 ha. Percebe-se que a classificação detectou 84,3% dos movimentos de massa da área de estudo.

Resultados semelhantes foram encontrados por Rau *et al.* (2014), que, ao classificarem movimentos de massa utilizando imagens ópticas de alta resolução espacial e MDE, alcançaram índices de detecção variando entre 64,8% e 92,7%. Behling *et al.* (2014) utilizaram uma abordagem semelhante a este trabalho, definindo mudanças através de limiares da trajetória de NDVI para o mapeamento de movimentos de massa, em uma série temporal de imagens RapidEye no sul de Quirguistão, e alcançaram 90% de detecção.

Tabela 1: Resultados da classificação semiautomática com o algoritmo RF.

Avaliação	Classificação
Acertos (ha)	329,6
Omissão (ha)	61,5
Comissão (ha)	76,7
Porcentagem de Detecção (%)	84,3
Porcentagem de Qualidade (%)	70,5
Erro de Omissão (%)	15,7
Erro de Comissão (%)	18,9

A Figura 6 apresenta o resultado da classificação semiautomática sobreposta ao mapa de referência.

No primeiro zoom da Figura 6 encontra-se uma área com erro de comissão, ou seja, um alvo classificado erroneamente como sendo cicatriz de movimento de massa. A feição em questão corresponde a uma área de aterramento/corte em encosta, que já estava presente na imagem anterior ao desastre. Apesar disso, à montante dos cortes, ocorreram deslizamentos, que foram corre-

tamente classificados como movimentos de massa. No segundo quadro de detalhe da Figura 6, percebem-se locais em que o mapa classificado teve bom acerto na detecção das cicatrizes. Por fim, o terceiro quadro da Figura 6 mostra dois casos de erros de omissão: o primeiro, situado a noroeste, a cicatriz de movimento de massa não foi classificada e no segundo, situado na porção sudeste do quadro, apenas uma parte da cicatriz foi classificada, ou seja, criou-se um polígono menor que o alvo.

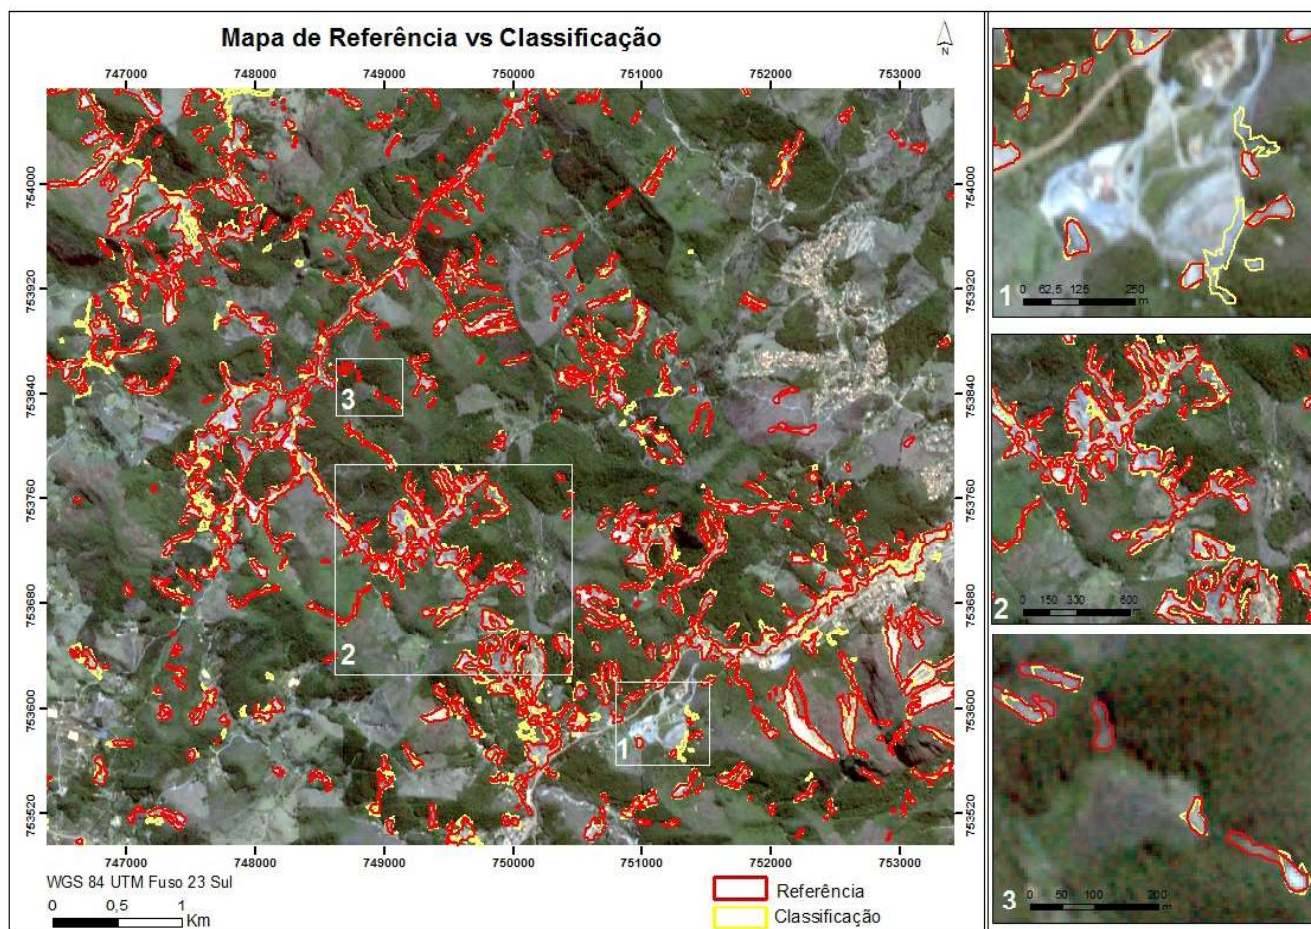


Figura 6 - Resultado da classificação com o algoritmo Random Forest utilizando diferentes técnicas de detecção de mudanças.

5. Considerações Finais

Este trabalho buscou contribuir com a temática de classificação de cicatrizes de movimentos de massa por meio de técnicas de detecção de mudanças. A análise visual dos resultados mostrou que a 3ª e 4ª componente do ICA, PCA e MNF, além da diferença pré e pós-evento do OSAVI, estão entre as técnicas que melhor destacaram as cicatrizes de movimento de massa. Tal resultado corroborou com o valor de importância dado para essas variáveis pelo classificador RF, o qual elencou a diferença OSAVI entre as imagens pré e pós-evento como o produto mais importante para classificar os movimentos de massa.

O desempenho da classificação foi considerado satisfatório, uma vez que detectou mais de 80% das cicatrizes de movimentos de massa. Percebeu-se ainda, uma melhor delimitação das bordas das cicatrizes em relação ao mapa utilizado como referência, que foi elaborado por vetorização manual. Além disso, o processamento semiautomático se mostrou mais rápido frente ao método de interpretação visual. Nesse sentido, a utilização de métodos automatizados se mostra como uma ferramenta em potencial, permitindo agilizar mapeamentos preliminares e emergenciais.

No entanto, apesar das vantagens da utilização de técnicas de detecção de mudanças e algoritmos de classificação de imagens para automatização de mapeamentos, a interferência de um intérprete, a realização de trabalhos de campo, bem como a utilização de dados complementares não devem ser descartadas para obtenção de mapeamentos mais robustos.

Agradecimentos

As autoras agradecem ao CNPq e CAPES pela concessão de bolsas de mestrado e doutorado.

Referências Bibliográficas

AVELAR, A.; VINAGRE, R.; BORGES, G.; SILVA, A. C.; ALMEIDA, G. P. Interações geomorfológico-geológico-geotécnicas nos movimentos de massa da bacia do Córrego Dantas, Nova Friburgo (RJ). Anais do XI Simpósio Nacional de Geomorfologia. Maringá. 2016.

ADAM, E.; MUTANGA, O.; ODINDI, J.; ABDEL-RAHMAN, E. M. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance

of random forest and support vector machines classifiers. **International Journal of Remote Sensing**, v. 35, n. 10, p. 3440-3458, 2014.

BEHLING, R.; ROESSNER, S.; KAUFMANN, H.; KLEINSCHMIT, B. Automated Spatiotemporal Landslide Mapping over Large Areas Using RapidEye Time Series Data. **Remote Sensing**, v. 6, p. 8026-8055, 2014.

BLASCHKE, T.; FEIZIZADEH, B. Object-Based Image Analysis and Digital Terrain Analysis for Locating Landslides in the Urmia Lake Basin, Iran. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 12, p. 4806 – 4817, 2014.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.

COELHO NETTO, A. L.; AVELAR, A. S.; D'ORSI, R. N. Vulnerabilidades dos sistemas naturais: monitoramento dos problemas de encosta na cidade do rio de janeiro frente às mudanças climáticas em curso e futuras, 2011. In: **Megacidades, vulnerabilidades e mudanças climáticas: Região metropolitana do Rio de Janeiro**. Disponível em: <https://s3.amazonaws.com/tapajos/Megacidades/12_Encostas.pdf>. Acesso em nov. de 2016.

COMON, P. Independent component analysis, a new concept?. **Signal Processing**, v. 36, p. 287-314, 1994.

CROZIER, M. J. **Landslide: causes, consequences & environment**. London: Crom Hel Tld., 252p, 1986.

DANTAS, M. E. Geomorfologia do estado do Rio de Janeiro. In: SILVA, L. C.; CUNHA, H. V. S. **Geologia do Estado do Rio de Janeiro: texto explicativo do mapa geológico do Estado do Rio de Janeiro**. Brasília: CPRM, 2001.

ENVI. **ENVI User's Guide**. Washington: RSI – Research System Inc., 1057p, 2004.

ESCAPE, C. M.; ALEMANIA, K. M.; LUZON, P. K.; FELIX, R.; SALVOSA, S.; AQUINO, D.; ECO, R. N.; LAGMAY, A. M. F. Comparison of various remote sensing classification methods for landslide detection using ArcGIS. **Geophysical Research Abstracts**, v. 16, 2014.

FERNANDES, N. F.; AMARAL, C. P. Movimentos de massa: uma abordagem geológico-geomorfológica. In: GUERRA, A. J. T.; CUNHA, S. B. **Geomorfologia e meio ambiente**. (Eds). 4.ed. Rio de Janeiro: Bertrand Brasil, p. 123-194, 2003.

GONG, J.; SUI, H.; MA, G.; ZHOU, Q. A review of multi-temporal remote sensing data change detection algorithms. The International Archives of the Photogrammetry, **Remote**

- Sensing and Spatial Information Sciences**, v. 37 (B7), p. 757–762, 2008.
- GREEN, A. A.; BERMAN, M.; SWITZER, P.; CRAIG, M. D. A. Transform for Ordering Multispectral Data in terms of Image Quality with Implications for Noise Removal. **IEEE Transactions on Geoscience and Remote Sensing**, v. 26, n. 1, p. 65-74, 1988.
- GUZZETTI, F.; MONDINI, A. C.; CARDINALI, M.; FIORUCCI, F.; SANTANGELO, M.; CHANG, K. T. Landslide inventory maps: new tools for and old problem. *Earth-Science Reviews*, v. 112, p. 42-66, 2012.
- HÖLBLING, D.; FRIEDL, B.; EISANK, C. An object-based approach for semi-automated landslide change detection and attribution of changes to landslide classes in northern Taiwan. *Earth Science Informatics*, v. 8, 327p, 2015.
- JAKIMOW, B.; OLDENBURG, C.; RABE, A.; WASKE, B.; VAN DER LINDEN, S.; HOSTERT, P. **ImageRF Classification**, Manual for Application: imageRF version 1.1. Humboldt-Universität zu Berlin, Germany, 2014.
- JOLLIFFE, I. T. **Principal Component Analysis**. Second ed. Springer Series in Statistics. New York: Springer-Verlag New York, 2002.
- MASEK, J. G.; SUN, G. Technical note: A spectral-angle methodology for mapping net forest cover change in northeastern China. **International Journal of Remote Sensing**, v. 25, n. 24, p. 5629-5636, 2004.
- MOINE, M.; PUISSANT, A.; MALET, J.-P. Detection of landslides from aerial and satellite images with a semi-automatic method. Application to the Barcelonnette basin (Alpes-de-Haute-Provence, France). In: MALET, J.P; REMAITRE, A.; BOGAARD, T. **Landslide Processes: from geomorphological mapping to dynamic modelling**. (Eds). CERG, Strasbourg, France, p. 63-68, 2009.
- MONDINI, A. C.; CHANG, K.-T.; YIN, H.-Y. Combining multiple change detection indices for mapping landslides triggered by typhoons. **Geomorphology**, v. 134, n. 3, p. 440-451, 2011.
- RAU, J.-Y.; JHAN, J.-P.; RAU, R.-J. Semiautomatic object-oriented landslide recognition scheme from multisensor optical imagery and DEM. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, p. 1336–1349, 2014.
- ROBILA, S. A. Using spectral distances for speedup in hyperspectral image processing. **International Journal of Remote Sensing**, v. 26, p. 5629–5650, 2005.
- RODRIGUEZ-GALIANO, V. F.; GHIMIRE, B.; ROGAN, J.; CHICA-OLMO, M.; RIGOL-SANCHEZ, J. P. An assessment of the effectiveness of a random forest classifier for landcover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 67, p. 93–104, 2012.
- RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, p. 95-107, 1996.
- SELBY, M. J. **Hillslope materials & processes**. New York: Oxford University Press, 451p, 1993.
- SOHN, Y.; REBELLO, N. S. Supervised and Unsupervised Spectral Angle Classifiers. **Photogrammetric Engineering & Remote Sensing**, v. 68, n. 12, p. 1271-1280, 2002.
- VAN DER LINDEN, S.; RABE, A.; HELD, M.; JAKIMOW, B.; LEITÃO, P. J.; OKUJENI, A.; SCHWIEDER, S. S.; HOSTERT, P. The EnMAP-Box — A Toolbox and Application Programming Interface for EnMAP Data Processing, **Remote Sensing**, v. 7, p. 11249-11266, 2015.