

Detecção automática de mudanças em áreas de reflorestamento

Matheus Pinheiro Ferreira ¹
Gabriel de Oliveira ¹
Daniel Capella Zanotta ¹
Leila Maria Garcia Fonseca ¹

¹ Instituto Nacional de Pesquisas Espaciais - INPE
Divisão de Sensoriamento Remoto - DSR
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
{mpf, gdo, zanotta}@dsr.inpe.br
leila@dpi.inpe.br

Abstract. Deforestation allied with the conversion of Atlantic Forest by reforestation with exotic species is a common practice in several regions of Brazil. Thus, automatically detection of areas that have experienced changes reduces the time required for their characterization. In this context, the objective of this work is the application of an automatic method for detecting changes in plantation forest areas during 1986 to 2004, in Vale do Ribeira, east of the state of Paraná-Brazil. Specific objectives include: 1) generation of fraction images from Thematic Mapper - TM / Landsat 5 scenes, dated of 1986 and 2004; 2) obtaining difference images for each of the components (vegetation, soil and shade/water); 3) estimation for each pixel of the relevance degrees of the classes change and no-change from a Bayesian approach, with statistical parameters automatically estimated by the *Expectation-Maximization* (EM) algorithm; 4) relevance degrees adjustment by the insertion of spatial context information, implemented in an iterative approach of probabilistic relaxation; 5) production of a base map from visual interpretation of images; 6) Comparison of the results generated by visual interpretation and the automatic method. The results showed that the proposed method was effective regarding to automatic detection of changes in plantation forest areas. Furthermore, the fuzzy approach allowed a more accurate modeling of changes that occur in natural scenes between two different dates, since membership grades for the classes change and no-change were attributed allowing an easement of classification.

Palavras-chave: processamento de imagens, plantações florestais, abordagem *fuzzy*, contexto espacial, image processing, plantation forests, *fuzzy* approach, spatial context.

1. Introdução

O desmatamento aliado à conversão de áreas de floresta atlântica por reflorestamento com espécies exóticas é uma prática freqüente em diversas regiões do Brasil. No Vale do Ribeira, região que abrange o sul do estado de São Paulo e leste do estado do Paraná, esta prática é corriqueira, principalmente com espécies do gênero *Pinus spp.* Esta atividade tomou grande impulso com a promulgação da lei de incentivos fiscais da década de 1970. Com o advento desta lei, observou-se um incremento considerável de áreas reflorestadas, principalmente nas regiões sul e sudeste do país. Assim, alguns pesquisadores têm procurado estabelecer metodologias de avaliação destas áreas, não somente em nível de solo, mas também aéreo e orbital.

A utilização de dados orbitais no monitoramento da cobertura do terreno requer a interpretação e comparação das classes de cobertura em diferentes intervalos temporais. Sendo assim, detectar automaticamente áreas em que tenham ocorrido mudanças reduz o tempo necessário para sua caracterização. Os estudos envolvendo a detecção automática de mudanças de cobertura do terreno a partir de produtos e técnicas de sensoriamento remoto têm como premissa o fato de alvos distintos estarem associados a diferentes comportamentos espectrais (Goltz, 2005).

Vários métodos para detecção automática de mudanças de cobertura e uso do solo têm sido propostos na literatura (Bruzzone e Serpico, 1997; Lorena, 2001; Graça, 2004). Dentre as técnicas utilizadas, a comparação por subtração de duas imagens da mesma área, adquiridas em tempos distintos, prevalece e serve como ponto de partida para a aplicação de outros

métodos. Esta abordagem permite a estimação de mudanças ocorridas em nível de sub-pixel, ou seja, variações dos valores percentuais nas frações (vegetação, solo e sombra) que compõem o pixel. A definição das classes de mudança e não-mudança está associada a um grau de pertinência que atribui um valor de confiabilidade para a classificação dos pixels que sofreram alteração. Com a finalidade de aumentar esta confiabilidade pode-se incluir informações de contexto espacial para levar em conta a correlação espacial presente em cenas naturais (Tso e Mather, 2001).

Neste sentido, o objetivo deste trabalho é detectar de forma automática mudanças ocorridas em áreas de reflorestamento (crescimento e supressão), no período de 1986 a 2004, em uma região do Vale do Ribeira, leste do estado do Paraná.

2. Metodologia

De forma a cumprir o objetivo proposto, o trabalho foi dividido em diferentes etapas, abrangendo os itens abaixo apresentados.

2.1 Dados

Na elaboração do presente estudo, foram utilizadas imagens multiespectrais adquiridas pelo sensor Thematic Mapper – TM/Landsat 5, nas seis bandas do espectro óptico refletido, com resolução espacial de 30 metros, referentes a órbita-ponto 220-077 em duas datas, 14/09/1986 e 30/08/2004. As bandas espectrais foram realçadas pelo método de manipulação de histograma e combinadas na seguinte composição colorida: banda 4 no canal vermelho, banda 5 no canal verde e banda 7 no canal azul (R4G5B7).

Na etapa de georreferenciamento, utilizaram-se cartas na escala 1:50.000 provenientes da Diretoria do Serviço Geográfico do Exército (DSG). Foi utilizado um polinômio de primeira ordem para transformação do sistema de coordenadas e o método do vizinho mais próximo para interpolação dos pixels. As imagens foram georeferenciadas de acordo com a projeção UTM (Transversa Universal de Mercator), e Datum WGS-84. Após o georreferenciamento e definição de parâmetros de projeção, foi feito o recorte da área de estudo, localizada no Vale do Ribeira, leste do estado do Paraná (Figura 1). Este recorte corresponde a uma área de aproximadamente 28.852 hectares.




Figura 1. Recorte da área de estudo, imagens TM/Landsat 5.

2.2 Geração das imagens fração e diferença

O modelo linear de mistura espectral (MLME) adotado neste estudo emprega a abordagem descrita nos trabalhos de Shimabukuro e Smith (1991), Haertel et al. (2004) e Haertel e Shimabukuro (2005). Este modelo estima as frações das componentes de mistura de cada pixel da imagem da seguinte forma (Haertel e Shimabukuro, 2005):

$$r_i = \sum_{j=1}^m a_{i,j}x_j + v_i \quad (2)$$

onde r_i representa a reflectância média na banda espectral i , $a_{i,j}$ é a reflectância espectral do componente j da banda espectral i , x_j é a proporção do componente j dentro do pixel e v_i é o resíduo da banda espectral i .

Usando este modelo, as imagens fração correspondentes a vegetação, solo e sombra foram geradas. As imagens diferença foram obtidas pela subtração pixel a pixel entre as componentes vegetação e solo para cada ano. Estas duas componentes são negativamente correlacionadas, ou seja, o aumento da fração solo resulta na diminuição da fração vegetação e da mesma forma um aumento na fração vegetação (rebrotar) resulta em um decréscimo da componente solo.

2.3 Identificação das classes mudança e não-mudança

As frações vegetação e solo de cada ano, utilizadas para a geração das imagens diferença, apresentam alterações entre si devido a inevitável presença de ruídos e pequenas variações não significativas. Desta maneira, é preciso estimar um limiar de separabilidade entre as classes mudança e não-mudança. Bruzzone e Prieto (2000) propõem uma abordagem estatística baseada no algoritmo *Expectation-Maximization* (EM) (Duda, 2001) para estimar

os parâmetros que melhor caracterizam as classes. Através do algoritmo EM as duas distribuições gaussianas, referentes às classes mudança e não-mudança podem ser identificadas e separadas automaticamente pela estimação dos parâmetros estatísticos que as caracterizam.

Calculados as estatísticas e as probabilidades *a priori* para as duas classes, é possível usar tais informações como parâmetros de entrada em um classificador paramétrico. Nessa etapa, muitas abordagens se baseiam em critérios rígidos para a classificação, rotulando os pixels em uma ou outra classe pré-definida. A principal desvantagem dessa abordagem reside no fato de que em cenas naturais, as alterações ocorrem de uma forma gradual e contínua, fato este que torna muito difícil a definição objetiva de um limiar separando rigidamente a classe mudança da classe não-mudança.

Sendo assim, de modo a resolver esta dificuldade, optou-se neste estudo por se trabalhar com uma abordagem *fuzzy* ao problema de detecção de mudanças a partir de imagens multitemporais. Isto se deu pelo fato desta abordagem estimar o grau de confiança com que um pixel pode ser rotulado em uma determinada classe, em contraposição a classificação do tipo binária em que cada pixel é integralmente associado a uma classe.

Para validação dos resultados foi gerado um mapa temático de referência por meio da análise visual das imagens, identificando as áreas de reflorestamento que cresceram ou que foram suprimidas. Para esta tarefa foi utilizado o *software* ArcGIS 9.1 em uma escala de mapeamento de 1:25.000.

3. Resultados e Discussão

A Figura 2 apresenta o mapa de referência produzido por interpretação visual onde são mostradas as áreas de supressão (corte raso de reflorestamento) totalizando 939 hectares e as áreas de incremento (crescimento de áreas reflorestadas) que correspondem a 15 hectares.




Figura 2. Mapa de referência gerado por interpretação visual.

A Figura 3 apresenta o mapa de mudanças gerado a partir da metodologia proposta: as áreas em vermelho e azul representam, respectivamente, as áreas de supressão e incremento de reflorestamento. As áreas de supressão correspondem a 2.455 hectares enquanto que as áreas de incremento correspondem a 423 hectares.

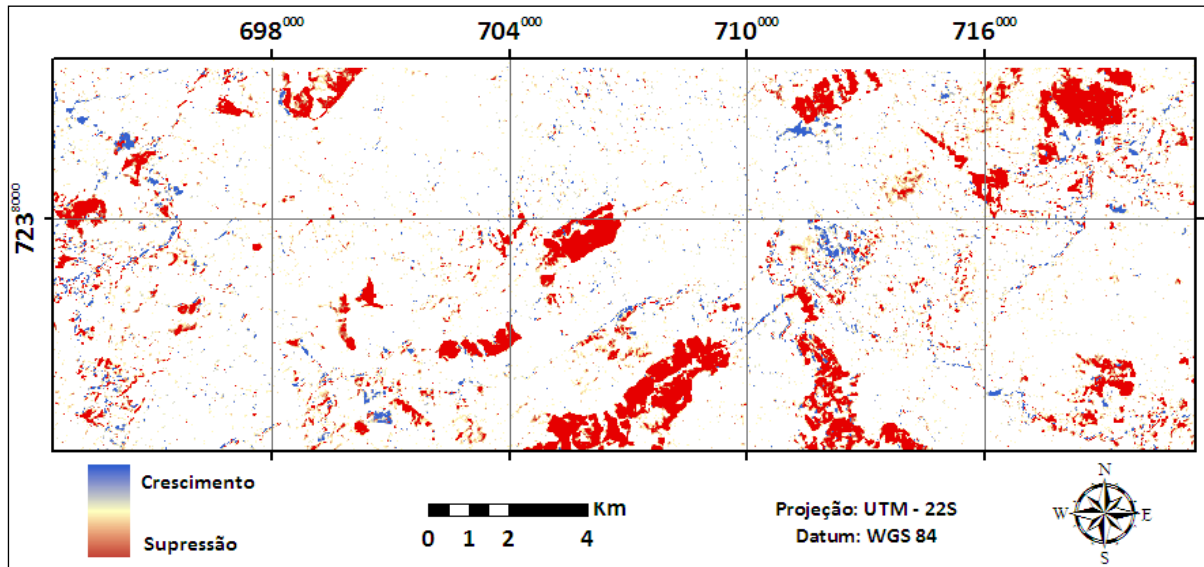


Figura 3. Mapa de mudanças gerado a partir da metodologia proposta.

Devido ao fato que o produto diferença entre as frações vegetação e solo pode apresentar ruídos e/ou pequenas variações não significativas que podem comprometer a acurácia do produto, foi utilizado o método de relaxação para refinar as estimativas atualizando os graus de pertinência dos pixels da imagem para as classes em questão, conforme descrito em Zanotta (2010). O mapa gerado após dez iterações foi considerado o melhor resultado, pois eliminou grande parte dos pixels referentes a ruídos e preservou a transição gradativa entre as duas classes, como pode ser visto em detalhe na Figura 4 (pixels com tons variando de vermelho para azul).

A Figura 4 mostra o mapa de referência (contornos) sobreposto ao mapa de mudanças gerado pelo algoritmo EM e classificação Bayesiana.

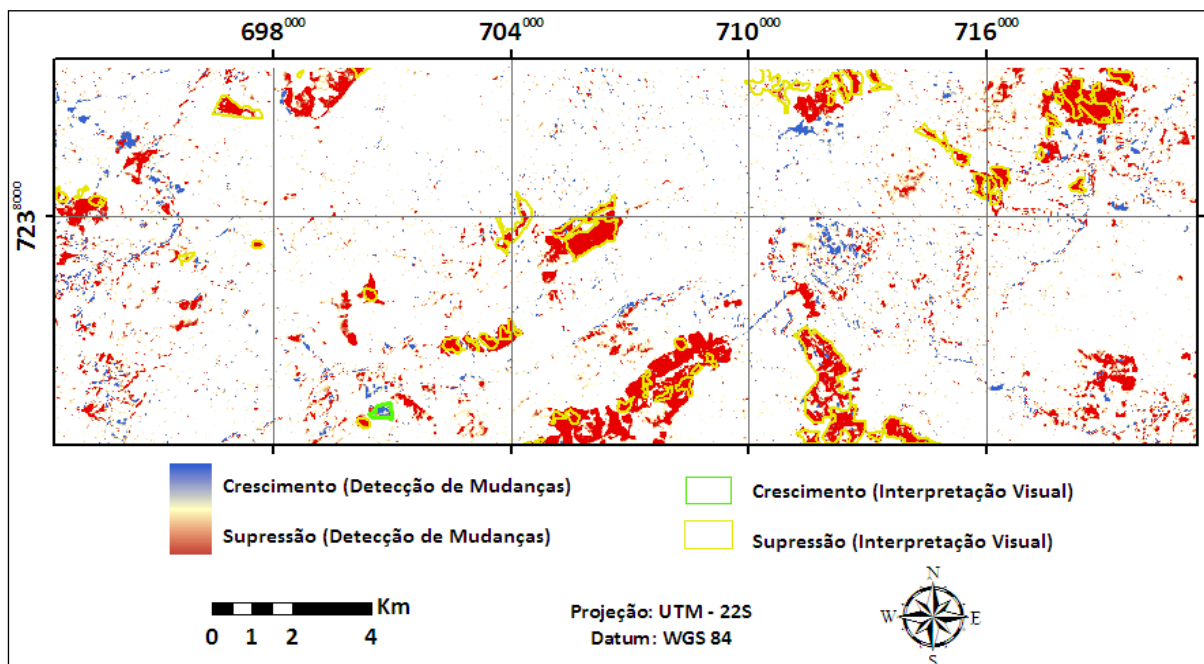


Figura 4. Limites dos polígonos do mapa de referência sobreposto ao mapa de mudanças.

O desempenho do método de detecção de mudanças em áreas de reflorestamento foi medido através da matriz de contingência que resultou nos valores apresentados na Tabela 1.

Tabela 1. Comparação em porcentagem das classes mapeadas por interpretação visual (linhas) com as classes mapeadas pela metodologia proposta (colunas).

	Não-mudança	Supressão	Incremento
Incremento	2,21	6,5	53,00
Supressão	41,12	82,78	24,1

Analisando a Tabela 1, pode-se observar que para aquelas áreas onde ocorreu o corte raso de reflorestamento (supressão no mapa de referência) a metodologia proposta foi capaz de reconhecer 82,78% das mesmas, demonstrando assim a conformidade dos polígonos do mapa de referência com as áreas de supressão detectadas. Porém, pode-se observar que o algoritmo detectou não apenas às alterações ocorridas nas áreas de reflorestamento, mas também na cobertura vegetal de um modo geral. Isto é explicado pelo fato da utilização de imagens fração vegetação, como dado de entrada do algoritmo, que realça as áreas de cobertura vegetal. A discordância corresponde aos 41,12% dos pixels classificados como supressão e 2,21 % dos pixels classificados como incremento.

A Figura 5 mostra um pequeno recorte na porção nordeste da área de estudo para as duas datas (1986 e 2004) e a sobreposição entre os polígonos do mapa de referência e o mapa de mudanças. A Figura 5c mostra a imagem *fuzzy*, onde os tons de vermelho mais escuro representam as áreas de supressão mais acentuada e os tons de azul mais escuro representam as áreas de incremento mais intenso na cobertura vegetal.

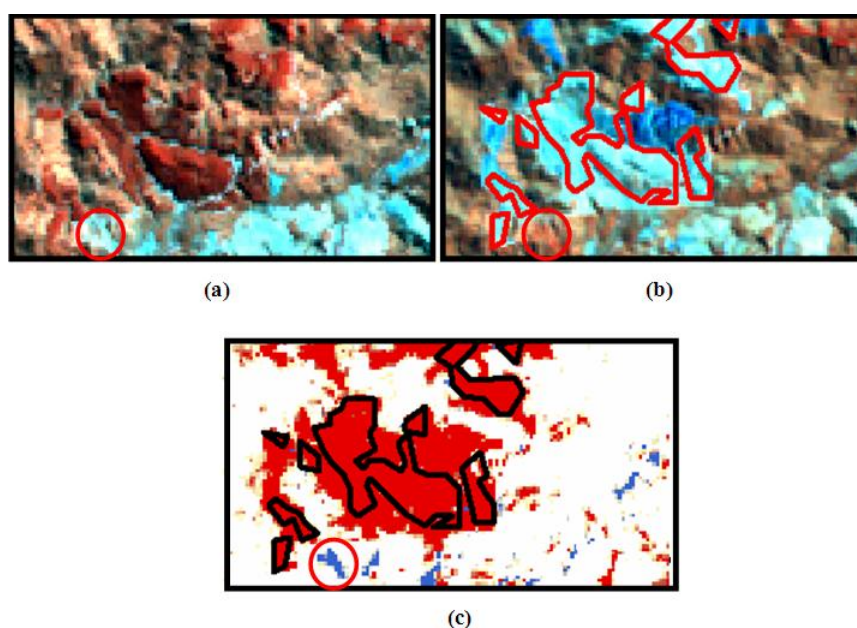


Figura 5. Detalhe de um pequeno recorte na porção nordeste da área de estudo (a) 1986 e (b) 2004; (c) sobreposição entre os polígonos do mapa de referência (polígonos pretos) e o mapa de mudanças.

Os círculos vermelhos ilustrados na Figura 5 destacam a área onde ocorreu crescimento da cobertura vegetal identificada pelo método. Pode-se observar, ainda nas figuras 5a e 5b, as áreas de supressão identificadas em áreas fora da área de reflorestamento.

Cabe salientar que em estudos desta natureza, os mapas de mudança apresentam o efeito *salt and pepper* gerado por ruídos aleatórios e mudanças sem interesse prático. Esta última foi

ampliada pela grande defasagem temporal entre as duas imagens, o que ocasiona o aparecimento de pequenas alterações distribuídas de maneira uniforme na cobertura do solo. Embora informações de contexto espacial tenham sido aplicadas para a obtenção do mapa final de mudanças, este tipo de problema ainda persistiu. A total eliminação destes pixels ruidosos pode comprometer a exatidão da classificação, uma vez que as áreas em que realmente houveram mudanças são subestimadas. Para tanto, o número de iterações aplicadas à imagem deve ser controlado a fim de obter um resultado razoável.

4. Conclusões

A metodologia proposta foi eficaz na detecção automática de mudanças em áreas de reflorestamento. Porém, a mesma foi sensível às mudanças na cobertura vegetal de modo geral, não se restringindo às regiões de reflorestamento. Para aumentar a eficiência desta metodologia é necessário identificar atributos na imagem que diferenciem as áreas de reflorestamento das demais classes de uso do solo ou delimitar a área de interesse no processamento, assim a análise das mudanças ocorreria restritamente nestas áreas. A abordagem *fuzzy* adotada neste trabalho permitiu uma modelagem mais acurada das alterações que ocorrem em cenas naturais entre duas datas distintas, uma vez que graus de pertinência para as classes mudança e não-mudança foram atribuídos permitindo uma flexibilização da classificação.

Referências bibliográficas

- Bruzzone, L.; Prieto, D. F. Automatic Analysis of the Difference Image for Unsupervised Change Detection. **IEEE Transactions on Geoscience and Remote Sensing**, v. 38, n. 3, p. 1171-1182, 2000.
- Bruzzone, L.; Serpico, S.B. An iterative technique for the detection of land-cover transitions in multitemporal remote-sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 4, p. 858-867, 1997.
- Duda, R. O.; Hart, P. E.; Stork, D. G. **Pattern Classification**, 2nd edition, New York: John Wiley & Sons, 2001. 680 p.
- Goltz, E. **Avaliação do produto MOD09 (reflectância da superfície) fornecido pelo sensor MODIS/Terra através de radiometria de campo em uma área de soja**. 2005. 133 p. (INPE 14219 TDI/1120). Dissertação de Mestrado - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2005.
- Graça, P. M. L. A. **Monitoramento e caracterização de áreas submetidas à exploração florestal na Amazônia por técnicas de detecção de mudanças**. 2004. 275 p. (INPE-13644-TDI/1046). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2004.
- Haertel, V.; Shimabukuro, Y. E. Spectral Linear Mixing Model in Low Spatial Resolution Image Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 11, p. 2555-2562, 2005.
- Haertel, V.; Shimabukuro, Y. E.; Almeida Filho, R. Fraction Images in Multitemporal Change Detection. **International Journal of Remote Sensing**, v. 10, n. 23, p. 5473-5489, 2004.
- Lorena, R. B. **Evolução do uso da terra em porção da Amazônia ocidental (Acre), com uso de técnicas de detecção de mudanças**. 2001. 116 p. (INPE-9650-TDI/846). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2001.
- Shimabukuro, Y.E.; Smith, J.A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p.16-20, 1991.

Tso, B.; Mather, P. M. **Classification Methods for Remotely Sensed Data**. London and New York: Taylor & Francis, 2001.332 p.

Wang, F. Fuzzy Supervised Classification of Remote Sensing Images. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 28, no. 2, pp. 194 – 201, 1990.

Zanotta, D. C. **Uma abordagem *fuzzy* na detecção automática de mudanças do uso do solo usando imagens de fração e informações de contexto espacial**. 2010. 79 p. Dissertação (Mestrado em Sensoriamento Remoto) – Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Porto Alegre, 2010.