

Revista Brasileira de Cartografia (2016), Nº 68/3: 505-517
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto
ISSN: 1808-0936

EFEITO DA TOPOGRAFIA SOBRE A CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA POR ANÁLISE DE IMAGENS BASEADA EM OBJETOS

Effect of the Topography on Land Cover Classification Through Object-Based Classification

**Eder Paulo Moreira¹, Márcio de Morisson Valeriano¹,
Camilo Daleles Rennó¹ & Helena França²**

¹Instituto Nacional de Pesquisas Espaciais - INPE
Departamento de Sensoriamento Remoto
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
{eder;valerian}@dsr.inpe.br; camilo@dpi.inpe.br

²Universidade Federal do ABC - UFABC
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas
Caixa Postal 5001 - 09210-170 - Santo André, SP - Brasil
helena.franca@ufabc.edu.br

Recebido em 20 de Outubro, 2014/ Aceito em 10 de Agosto, 2015
Received on October 20, 2014/ Accepted on August 10, 2015

RESUMO

Este estudo avalia a influência do efeito topográfico sobre a classificação de uso e cobertura da terra por análise de imagens baseada em objetos. Para isso, foi realizada a correção topográfica de bandas espectrais Landsat 5 TM e a análise comparativa das classificações dos dados sem e com correção topográfica. A área de estudo está localizada em uma região agrícola de relevo suave ondulado a ondulado localizada no sul do estado de Minas Gerais, Brasil. A imagem Landsat 5 TM foi obtida no catálogo de imagens do Instituto Nacional de Pesquisas Espaciais (INPE) e os dados topográficos para correção topográfica foram obtidos no projeto Topodata, os quais foram elaborados a partir do refinamento dos dados da missão Shuttle Radar Topography Mission (SRTM). A classificação do uso e cobertura da terra foi realizada por análise de imagens baseada em objetos geográficos (GEOBIA), dividida em duas etapas: segmentação e classificação por árvore de decisão. As classificações das imagens sem e com correção topográfica foram comparadas por meio de índice de exatidão global, índice kappa, tamanho das árvores de decisão e tamanho dos segmentos (ou regiões). A classificação da imagem com correção topográfica apresentou árvore de decisão mais simples (menor número de nós) e segmentos maiores. Em 26% da área total as duas classificações apresentaram resultados diferentes em relação às classes de uso ou cobertura da terra. A classificação da imagem com correção apresentou índice kappa e índice de exatidão global em torno de 10% mais elevados. Conclui-se que, em áreas de relevo irregular a correção topográfica deve ser aplicada para reduzir o efeito topográfico na classificação do uso e cobertura da terra utilizando GEOBIA.

Palavras chaves: Correção Topográfica, Efeito Topográfico, OBIA, Landsat TM, SRTM.

ABSTRACT

This study evaluates the influence of topography (topographic effect) on land cover classification through object-based approach. Tests were applied on Landsat 5 TM reflective bands, which were classified in their original form and after topographic correction. The study area is located in an agricultural region of rugged terrain in southeastern Brazil. Slope and aspect data taken from Topodata, a database refined from SRTM, were used to support the topographic correction procedures. Image processing included a co-registration of all data, followed by topographic correction. Original and corrected images were classified using object-based classification, composed by the steps of segmentation and of decision tree classification. Comparisons of classifications were based on accuracy (kappa and overall accuracy), decision tree size and segment size. The results indicate that the topographic effect affected all metrics involved in the comparison. After topographic correction, classification showed simpler decision tree (fewer nodes) and larger segment sizes. Differences between the classification results from original and corrected images occurred on 26% of the total area. The image classification of the corrected data showed kappa and overall accuracy 10% higher. It is recommended that in areas of rugged terrain, where topographic correction should be applied to reduce topographic effect on the land cover mapping.

Keywords: Topographic Correction, Topographic Effect, OBIA, Landsat TM, SRTM.

1. INTRODUÇÃO

A classificação do uso e cobertura da terra a partir de imagens de sensoriamento remoto tem sido empregada em estudos que visam ao mapeamento, ao monitoramento e à caracterização do uso e cobertura da terra. Um fator que tem permitido o avanço da classificação do uso e cobertura da terra nas últimas décadas é a automatização do processo de classificação, que possibilita menor esforço, tempo e custo em relação à classificação manual. Exceto para imagens de áreas planas, o desempenho de classificadores automáticos é prejudicado pelo efeito topográfico (CUO *et al.*, 2010), que altera os níveis radiométricos de cada pixel da imagem em função de sua declividade e orientação de vertente em combinação com o ângulo zenital e azimutal solar vigentes na aquisição da imagem (HOLBEN & JUSTICE, 1980). Essa variação representa uma modificação em relação às características espectrais intrínsecas de cada alvo. Como expressão mais evidente deste efeito, os níveis radiométricos normalmente possuem valores mais elevados em vertentes expostas à direção do Sol do que em vertentes com orientação oposta (RIÑO *et al.*, 2003).

Vários esforços foram realizados para o desenvolvimento de métodos de correção do efeito topográfico, os quais resultaram em melhorias significativas para a classificação (MEYER *et al.*, 1993; COLBY & KEATING, 1998). Os trabalhos que avaliam o impacto da

correção sobre a classificação indicam que o desempenho da correção é variável e depende da área de estudo, dos dados utilizados, do método de correção e da forma como o método é aplicado (KOBAYASHI & SANGANGOIE, 2008; MOREIRA & VALERIANO, 2014). Além disso, os resultados podem variar com a abordagem de classificação, espera-se maior sucesso do classificador em abordagens que representam as diferentes condições de iluminação da cena, como a coleta de amostras de treinamento sob variadas condições de iluminação solar em cada classe de uso ou cobertura da terra (MOREIRA, 2014).

Estudos que analisam a influência do efeito topográfico sobre a classificação foram conduzidos com classificadores “pixel-a-pixel” (VANONCKELEN *et al.*, 2013), que consideram a informação espectral de cada pixel dissociado de qualquer informação de sua vizinhança. No presente estudo, buscou-se compreender esse efeito sobre o desempenho da classificação por regiões, particularmente sobre a análise de imagens baseada em objetos geográficos (Geographic Object Image Analysis - GEOBIA, dado que tal abordagem vem se tornando mais utilizada (BENZ *et al.*, 2004; HAY & CASTILLA, 2008; BLASCHKE, 2010).

Em geral, GEOBIA requer uma etapa inicial de segmentação da imagem, depois a geração de atributos para cada segmento e, por fim, a classificação dos segmentos com base em

seus atributos. Estes são elaborados de forma a representarem os objetos do meio físico, como sua forma, textura e cor. Uma vantagem em relação à classificação “pixel-a-pixel” é a redução da fragmentação de classes decorrente da variabilidade espectral interna das classes de uso e cobertura da terra, que prejudica o aspecto visual e a exatidão da classificação. Esse efeito é mais evidente sobre imagens de alta resolução espacial (PINHO *et al.*, 2005), mas também é comum em classificação de imagens de média resolução espacial, como nas Landsat TM (DORREN *et al.*, 2003; BLASCHKE *et al.*, 2000).

A classificação dos segmentos comumente é realizada pelo método de classificação por árvore de decisão, que é um classificador supervisionado e não-paramétrico (MATHER & TSO, 2009). Este método permite a visualização, nos nós e ramos da árvore, dos atributos e dos limiares que contribuíram para a discriminação de cada classe de uso e cobertura da terra. Assim, é possível interpretar toda a árvore de decisão e, eventualmente, manipular os dados de treinamento ou o algoritmo para melhorar o processo de classificação. Uma descrição detalhada da classificação por árvore de decisão encontra-se em STROBL *et al.* (2009).

Os algoritmos de árvore de decisão determinam, com base em estatísticas das amostras de treinamento, os melhores atributos e limiares para discriminação das classes de uso e cobertura. Uma característica desses algoritmos é que as amostras de treinamento de determinada classe pode ser particionada e seguir mais de um trajeto (“ramo” ou “galho”) dentro da árvore (HOTHORN *et al.*, 2006). Espera-se que esta seja uma característica que minimize o efeito topográfico sobre a classificação final, alocando uma mesma classe em distintas “folhas”, quando ela se encontra sob condições distintas de iluminação solar. Em contraposição, espera-se uma árvore de decisão com maior número de nós e folhas em classificação de imagens sem correção topográfica.

Este estudo faz uma análise mais detalhada da influência do efeito topográfico sobre GEOBIA em uma região agrícola de terreno suave ondulado a ondulado (EMBRAPA, 2006)

no sul de Minas Gerais. A presente pesquisa complementa um estudo precursor (MOREIRA & VALERIANO, 2014), cujo objetivo principal foi avaliar 10 métodos de correção topográfica com a análise geral de seus impactos em GEOBIA. Aqui são abordadas a influência do efeito topográfico sobre o tamanho dos segmentos e sobre os erros de classificação em classes específicas de uso e cobertura da terra e uma análise detalhada do efeito topográfico sobre a estrutura da árvore de decisão.

2. MATERIAL E MÉTODOS

Nesta seção estão elencadas informações referentes à área de estudo, aos dados e recursos para processamento e a metodologia utilizada para atingir os objetivos propostos.

2.1 Área de estudo

A área de estudo (Figura 1) localiza-se no Sul do Estado de Minas Gerais nos municípios de Alfenas e Machado, correspondendo a uma área de 13.225 hectares. A área tem uso predominantemente agrícola, com culturas anuais e perenes e pequenos fragmentos florestais de Mata Atlântica. Existem também pequenas áreas de silvicultura, principalmente, de eucalipto. As principais culturas agrícolas na região são café, milho e feijão (IBGE, 2014). O relevo da área varia entre os tipos suave ondulado e ondulado (EMBRAPA, 2006). A declividade média é de 7,5° e a máxima de 35°. A altitude varia de 765 a 1.030 metros (MOREIRA, 2014).

2.2 Dados e recursos para processamento

Foram usadas as seis bandas não-termais Landsat 5 TM da área de estudo, obtidas do catálogo de imagens do INPE (<http://www.dgi.inpe.br/CDSR/>), cena 219/75 (path/row), com data de imageamento de 8 de junho de 2011. A iluminação solar no momento da aquisição da imagem provém do ângulo zenital de 54,32° e azimutal de 37,01°. Os dados topográficos, representados principalmente pela declividade e orientação de vertentes, foram obtidos do Topodata (BRASIL, 2008).

Também foram usadas as imagens Landsat 5 TM de 21/04/2011 e 28/09/2011, obtidas no catálogo do INPE, e uma imagem de




Fig. 1 - Localização da área de estudo nos Municípios de Alfenas e Paraguaçu, Estado de Minas Gerais, Brasil. Imagem Landsat 5 TM, sob composição 453 (RGB), com a identificação das classes de uso e cobertura da terra.

alta resolução do Google Earth de 23/06/2011, para ajudarem na identificação das classes do uso e cobertura da terra da imagem principal.

As etapas de processamento de dados foram desenvolvidas na linguagem de programação R, versão 3.0 (R DEVELOPMENT CORE TEAM, 2013), com exceção da segmentação, que foi conduzida no programa Definiens, versão 8.0 (DEFINIENS, 2009). A segmentação foi realizada com o algoritmo multiresolução (BENZ *et al.*, 2004). Na fase de classificação dos segmentos, o algoritmo utilizado para elaboração automática da árvore de decisão foi o “CTREE”, do pacote party (HOTHORN *et al.*, 2006).

2.3 Metodologia

O fluxo geral de dados e de processamentos está esquematizado na Figura 2. O processamento inicial consistiu no registro dos dados multiespectrais e dos dados topográficos, e no cálculo do cosseno do ângulo de incidência solar na superfície, $\cos i$, usado na correção topográfica (TEILLET *et al.*, 1982):

$$\cos i = \cos \theta_s \cos \theta_t + \sin \theta_s \sin \theta_t \cos(\varphi_s - \varphi_t) \quad (1)$$

onde θ_s é o ângulo zenital solar, θ_t é o ângulo zenital da normal à superfície (declividade), φ_s é o ângulo azimutal solar e φ_t é o ângulo azimutal da normal à superfície (orientação de vertentes).

Os dados multiespectrais e topográficos mostraram-se deslocados lateralmente, apesar de originalmente estarem georreferenciados. Para registro dos mesmos, foi realizado um deslocamento linear daqueles em relação a estes. Esse deslocamento foi feito de acordo com a observação de pontos de controle evidentes em ambas fontes de dados, geralmente confluências de drenagem e de linhas de divisores de águas. Posteriormente, os dados multiespectrais foram reposicionados pelo método do vizinho mais próximo, para o completo alinhamento de seus pixels com os dos dados topográficos, quando sobrepostos. Os dados foram processados em coordenadas geográficas do Sistema Geodésico WGS84.

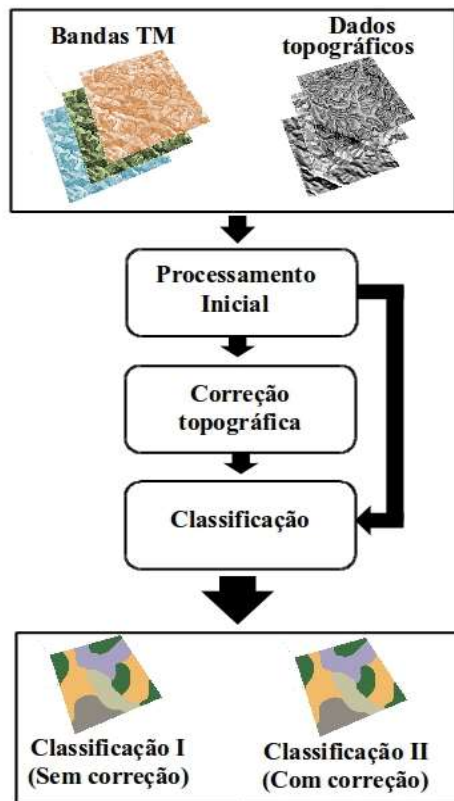


Fig. 2 - Fluxo geral de dados e das principais etapas de processamento.

Pelos resultados de uma avaliação anterior (MOREIRA & VALERIANO, 2014), foi selecionado o método de correção topográfica de TEILLET *et al.* (1982) (correção C), por ser um método que resultou em melhorias gerais na classificação por GEOBIA, considerando o tamanho dos segmentos, a estrutura da árvore de decisão e o índice de concordância kappa. Naquela avaliação, a correção C foi o método que resultou no maior tamanho médio dos segmentos. O aumento do tamanho médio dos segmentos após a aplicação da correção topográfica é um indicativo de que a correção diminui a heterogeneidade causada pela topografia nos dados de uma mesma classe (MOREIRA & VALERIANO, 2014).

O método de correção C baseia-se nas seguintes equações:

$$\delta NC_{\lambda ij} = NC_{\lambda ij} \left(\frac{\cos \theta_s + c_\lambda}{\cos i + c_\lambda} \right) \quad (2)$$

$$c_\lambda = \left(\frac{b_\lambda}{m_\lambda} \right) \quad (3)$$

onde δ é o nível de cinza (NC) corrigido da banda e pixel, $NC_{\lambda ij}$ é o NC original; e b_λ e m_λ são parâmetros obtidos da reta da regressão linear representada pela equação:

$$NC_{\lambda ij} = b_\lambda + m_\lambda \cos i \quad (4)$$

Para estimação do parâmetro, foram utilizadas amostras em locais ocupados por milho, devido à sua maior homogeneidade em termos de cor e textura da imagem (Fig. 1), por sua grande representatividade em termos de área e pela respectiva variação dos níveis de $\cos i$ na área de estudo (MOREIRA, 2014). As amostras foram coletadas em diferentes declividades e orientação de vertentes com o objetivo de representar as diferentes condições de iluminação ($\cos i$) da área, num total de 222 amostras.

A correção C foi aplicada diretamente sobre os valores digitais de cada banda espectral, sem transformação prévia para radiância ou reflectância e sem correção atmosférica (MEYER *et al.*, 1993; CUO *et al.*, 2010). No entanto, outros trabalhos (TEILLET, 1986; GU & GILLESPIE, 1998) apontam a correção atmosférica antes da correção topográfica como recomendável.

A classificação dos dados Landsat divide-se em duas etapas: segmentação e classificação por árvore de decisão. As bandas sem correções foram utilizadas para definição dos parâmetros de segmentação do algoritmo. Os parâmetros foram definidos pelo método de tentativa e erro utilizando as bandas 3, 4, 5 e 7 com mesmo peso. Nessa etapa, procurou-se estabelecer os parâmetros de segmentação de forma a evitar mistura de duas classes espectrais distintas dentro de um segmento. Os parâmetros de segmentação foram: escala=6, forma=0,2 e compacidade=0,3. Estes parâmetros como mesmo valores foram aplicados para segmentar a imagem com correção.

Para classificação dos segmentos, foram calculados para cada segmento alguns atributos utilizados para discriminação de alvos agrícolas: a média e o desvio padrão das 6 bandas espectrais; 7 atributos de textura propostos por Haralick (1979); 15 razão de bandas;

o Normalized Difference Vegetation Index (NDVI); 3 transformações Tasseled cap: Brightness, Greenness e Wetness (KAUTH & THOMAS, 1976); e o coeficiente de variação das seis bandas espectrais (Tabela 1).

Para treinar o classificador foram coletadas amostras de treinamento em cada classe de uso e cobertura da terra, em forma de pontos. Foram coletadas 55 amostras de café adulto, 63 de milho, 41 de floresta, 59 de solo e 39 das demais classes, que ocupam menores extensões territoriais, que incluem café jovem, reflorestamento e corpos d'água. Os "pontos" de treinamento foram sobrepostos a cada uma das segmentações (sem e com correção topográfica) para seleção de segmentos e de seus atributos.

Na etapa de classificação por árvore de decisão, foram realizados ajustes no algoritmo para sua adequação às amostras de treinamento e para melhorar sua capacidade discriminação

das classes. Esses ajustes foram realizados com base na visualização da árvore de decisão e da matriz de confusão, geradas com as amostras de treinamento sem correção topográfica. O número mínimo de amostras nos nós terminais (minbucket) foi ajustado de 7 para 3. O valor do teste estatístico (1 - valor-p), que não deve ser excedido para possibilitar uma divisão (mincriterion), foi mantido em 0,95. O valor-p está ligado à capacidade das amostras serem particionadas em dois grupos (nós), onde valor-p alto (próximo a 0,05) indica maior confusão (erro) entre os dois grupos. A soma mínima de amostras nos nós para ocorrer uma divisão (minsplit) foi ajustada de 20 para 6. Para uma visão detalhada do algoritmo e de seus parâmetros, recomenda-se a descrição do pacote party (HOTHORN et al, 2006). Os parâmetros com mesmos valores foram usados para a geração da árvore de decisão da classificação com correção topográfica.

Tabela 1: Atributos gerados para cada segmento (região) a partir das 6 bandas não termais (B1, B2, B3, B4, B5 e B7) Landsat 5 TM

Tipo	Nomes	Simbologia	Nº ributos
Espectral	Média	MediaB1: 2, 3, 4, 5 e 7	6
	Desvio padrão (DP)	DPB1: 2, 3, 4, 5 e 7	6
Textura ^a	GLCM Média ^b	GmB1: 2, 3, 4, 5 e 7	6
	GLCM Contraste	ConB1: 2, 3, 4, 5 e 7	6
	GLCM Dissimilaridade	DisB1: 2, 3, 4, 5 e 7	6
	GLCM Homogeneidade	HomogB1: 2, 3, 4, 5 e 7	6
	GLCM Entropia	EntB1: 2, 3, 4, 5 e 7	6
	GLCM Desvio padrão	GdpB1: 2, 3, 4, 5 e 7	6
	GLCM Ang. 2 momento	MomB1: 2, 3, 4, 5 e 7	6
	NDVI ^c	NDVI	1
Customizado	<i>Tasseled cap: Brightness, Greenness e Wetness</i> ^d	Brightness, Greenness e Wetness	3
	Razão de bandas:	B2/B1; B3/B2; B3/B1; B4/B3; B4/B2; B4/B1; B5/B4; B5/B3; B5/B2; B5/B1; B7/B5; B7/B4; B7/B3; B7/B2; B7/B1	15
	Coeficiente de variação (CV)	CVB1: 2, 3, 4, 5 e 7	6
TOTAL			79

a: Métodos propostos por HARALICK (1979).

b: GLCM: *Gray Level Co-occurrence Matrix*.

c: NDVI: *Normalized Difference Vegetation Index*.

d: Transformação espectral *Tasseled cap* (KAUTH & THOMAS, 1976).

A avaliação do efeito topográfico sobre a classificação incluiu a análise da estrutura da árvore de decisão, em que se considerou o número de nós, os atributos presentes nos nós, o valor-p do teste estatístico usado como critério de divisão em cada nó e o tamanho dos segmentos. Além da árvore de decisão, a avaliação levou em conta a análise da matriz de confusão (por exemplo, os erros de omissão e comissão), o índice de exatidão global e o índice de concordância kappa (CONGALTON & GREEN, 2009). Para essa avaliação da classificação por meio da matriz de confusão, do índice de exatidão global e do índice de concordância kappa, foi coletado, de maneira aleatória, 50 amostras de cada classe de uso e cobertura da terra. Nessa fase também foi definido dispor numa mesma classe (rotulada de “outros”) as coberturas de menor expressão territorial na área de estudo. No total foram coletados 250 amostras para as classes café adulto, floresta, milho, solo e outros.

Para avaliar se os índices kappa das duas classificações, imagem original e corrigida, são estatisticamente diferentes, utilizou-se a seguinte abordagem com o método Monte Carlo: a partir de dados de referência e resultados das classificações fez-se (a) uma amostragem de n amostras aleatórias sem reposição, onde em cada amostra se observam a classe da referência e as classes resultantes das duas classificações; (b) a partir das n amostras calculou-se o índice kappa de cada classificação, resultando em k_{11} e k_{21} ; (c) fez-se a reposição das n amostras. Repetiu-se (a), (b) e (c) m vezes. Como resultado disso, obtiveram-se m vezes k_{1i} e k_{2i} , calculados de forma pareada, ou seja, calculados em cada reamostragem com o mesmo conjunto de amostras. Por último, subtraiu-se k_{1i} de k_{2i} para obter m diferenças e, a partir delas, calculou-se o intervalo de credibilidade (por exemplo, de 95%), desprezando os valores das extremidades (5%). Caso o valor zero pertença ao intervalo, as classificações não serão significativamente diferentes e, caso contrário, serão (MOREIRA, 2014). Como não há um mapa de referência, foram utilizadas como referência as amostras da avaliação das classificações. Das 50 amostras de cada classe de uso e cobertura foram selecionadas aleatoriamente 25, totalizando 125 amostras (n) para as 5 classes de uso e cobertura da

terra. O número de simulações (m) foi de 10.000. O intervalo de credibilidade adotado foi de 95%.

3. RESULTADOS E DISCUSSÕES

As feições topográficas da área são mais evidentes na imagem sem correção do que na imagem com correção topográfica, numa indicação visual da remoção do efeito topográfico com a correção. Aparentemente, não há evidência de perda de informação espectral para distinção das classes de cobertura com a correção, uma vez que as matizes da composição colorida se mantiveram inalteradas (Figura 3).

A classe solo representa a maior fração de área, com cerca de 30 e 29% nas classificações sem e com correção, respectivamente. A definição desta classe inclui solo arado, solo com palha seca e áreas de pastagens. A área de milho, que ocupa 16% da área na classificação sem correção, representa 19% na classificação com correção. A variação equivale a aproximadamente 18% de diferença em relação ao total da classe milho entre as duas classificações (Fig. 4 A e B). As áreas das classes de café adulto, floresta e outros, mudaram de 10 para 9%, 15 para 13% e 26 para 29%, respectivamente, da classificação sem correção topográfica (Figura 4A) para a classificação com correção topográfica (Figura 4B).

O mapeamento e a quantificação das diferenças advindas da correção indicaram que as classes de uso e cobertura foram alteradas em 26% da área (Figura 4C). Diante do relevo local, de suave a suave-ondulado, considera-se que uma fração expressiva da área total está sujeita a um nível de efeito topográfico suficiente para que sua correção resulte em uma classificação distinta de uso e cobertura.

No processo de segmentação, o tamanho médio dos segmentos aumentou após a correção em todas as classes de uso e cobertura da terra analisadas (Figura 5). Esse aumento correspondeu a 4,3, 3,4, 5,0, 7,1 e 6,0% para as classes de café adulto, floresta, milho, solo e outros, respectivamente. Esses resultados são um indicativo de que a correção topográfica diminuiu a heterogeneidade intra classe de uso e cobertura da terra, causada pelo efeito topográfico.




Fig. 3 - Imagem Landsat 5 TM, composição 453 (RGB), sem correção (A) e com correção topográfica (B).

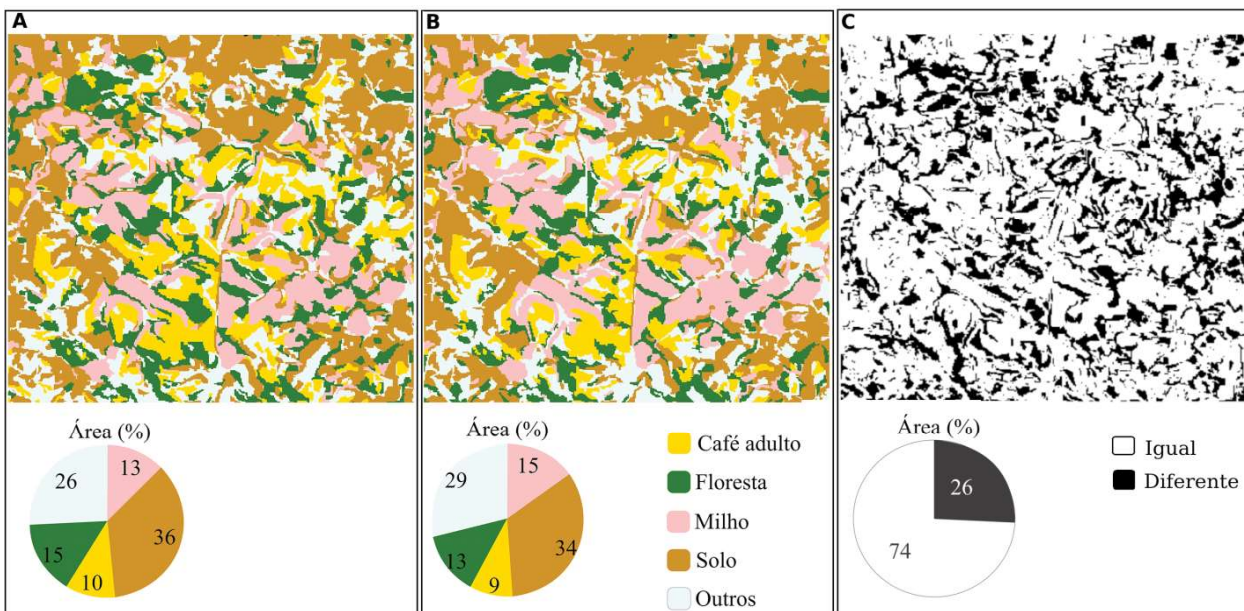


Fig. 4 - Classificação do uso e cobertura da terra sem (A) e com correção topográfica (B) e suas respectivas áreas em porcentagem; área onde as duas classificações (sem/com correção) são diferentes (C).

Referente à estrutura da árvore de decisão, a maioria dos atributos utilizados na discriminação das classes de uso e cobertura da terra são razão de bandas, presentes em 5 nós de ambas as classificações (figuras 6 e 7). As árvores diferenciaram-se entre si em relação a alguns atributos presentes nos nós. O atributo CVB4 (coeficiente de variação da banda 4), MediaB4 e B7/B3 estão presentes somente na árvore da classificação da imagem sem correção, e Wetness e B5/B4 somente na árvore da classificação da

imagem corrigida. A árvore da classificação da imagem com correção topográfica, de 8 nós e 9 folhas, é menor do que aquela obtida sem correção, que possui 9 nós e 10 folhas. O nó e a folha removidos pela correção distingue café adulto, floresta e “outros”, que demandavam um atributo a mais para sua distinção.

Nos resultados obtidos sobre imagens sem correção, ocorreram valores-p nos nós das árvores de decisão que se aproximam do valor máximo para a partição (0,05) em dois nós ou

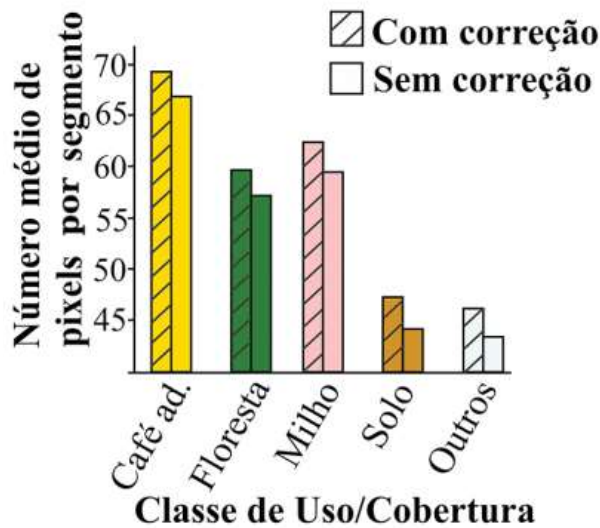


Fig. 5 - Tamanho médio dos segmentos de cada classe de uso e cobertura da terra das duas classificações, sem e com correção topográfica.

folhas na árvore de decisão da classificação. São quatro nós que possuem valor-p maiores que 0,01. Na classificação da imagem com correção, todos os valor-p foram menores ou iguais a 0,01. Portanto, pode-se considerar que existe menor capacidade de discriminação das amostras de treinamento sem correção em relação àquelas com correção. Reforçado pelas análises anteriores, isso confirma o maior grau de confusão entre classes de cobertura da terra devido à heterogeneidade decorrente do efeito

topográfico na classificação de imagens sem correção.

A exatidão total e o índice de concordância kappa demonstram as diferenças gerais entre as classificações, sem correção e com correção, que podem ser vistos na última linha das matrizes de confusão (Tabela 2). Pela comparação de valores, esses dois índices da classificação com correção foram superiores aos daquela sem correção. Pelo resultado da análise de comparação dos índices kappa das classificações pelo método de Monte Carlo, pode-se afirmar que o índice kappa da classificação com a imagem corrigida foi significativamente diferente daquele obtido com a classificação da imagem sem correção, com intervalo de credibilidade de 95%. Com 10.000 simulações, nesse intervalo de credibilidade, a menor diferença entre os dois índices kappa foi de 0,06, e a maior de 0,17. Há um aumento mediano de 0,1 (~10%) do valor do kappa da classificação com correção.

Pela análise dos erros de comissão e dos erros de omissão das matrizes de confusão das duas classificações, observa-se que ocorreu maior confusão entre classes na classificação da imagem sem correção. Nota-se que há maior quantidade de acertos para todas as classes da classificação com correção, com exceção da classe solo, cuja classificação teve maior erro de comissão na classificação com correção (Tabela 2).

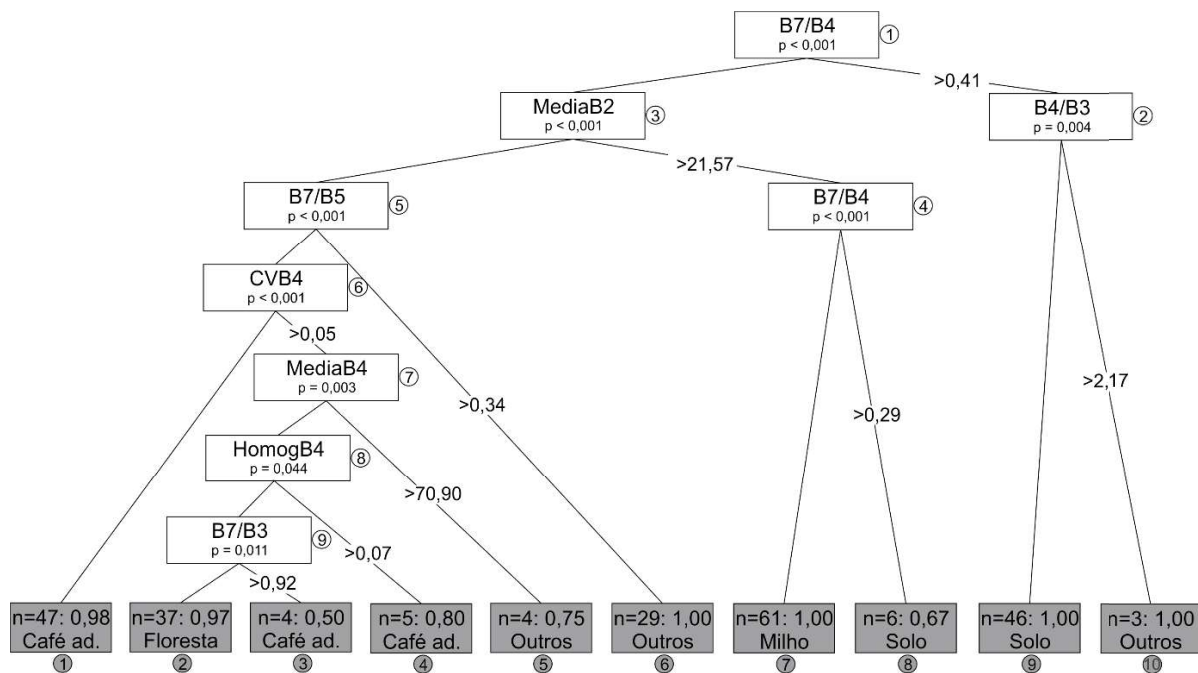


Fig. 6 - Árvore de decisão da classificação sem correção topográfica. A simbologia é detalhada na Tabela 1.




Fig. 7 - Árvore de decisão da classificação com correção topográfica. A simbologia é detalhada na Tabela 1.

Tabela 2: Matrizes de confusão da classificação da imagem sem e da com correção topográfica, para um total de 250 amostras

Classificação	Referência					Erro de comissão
	Milho	Solo	Café ad.	Floresta	Outros	
Classificação sem correção						
Milho	44	0	0	0	0	0,0
Solo	0	48	0	0	1	2,0
Café ad.	3	0	37	6	1	21,3
Floresta	3	0	9	41	4	28,1
Outros	0	2	4	3	44	17,0
Erro de omissão (%)	12,0	4,0	26,0	18,0	12,0	
Exatidão Global: 86%					Índice Kappa: 0,82	
Classificação com correção						
Milho	50	0	0	0	0	0,0
Solo	0	48	0	0	2	4,0
Café ad.	0	0	41	1	2	6,8
Floresta	0	0	6	47	1	13,0
Outros	0	2	3	2	45	13,5
Erro de omissão (%)	0,0	4,0	18,0	6,0	10,0	
Exatidão Global: 92%					Índice Kappa: 0,91	

Observa-se, nas duas classificações, que a maior confusão ocorreu para a classe de café adulto. Essa classe foi confundida principalmente com a classe floresta. Apesar de essa confusão ter sido reduzida após correção topográfica, ela permaneceu relativamente alta se comparada às demais classes. Isto pode ser explicado pela relativa similaridade espectral existente entre café e floresta, que não pôde ser minimizada com a correção do efeito topográfico.

Semelhantemente a outros estudos realizados com classificadores pixel-pixel (MEYER *et al.*, 1993; CUO *et al.*, 2010), a classificação por regiões é afetada pelo efeito topográfico. Em geral, os estudos indicam melhorias na exatidão da classificação após a correção topográfica (VANONCKELEN *et al.*, 2013). Este estudo mostrou que, além da exatidão, a topografia afeta a estrutura da árvore de decisão e o tamanho dos segmentos ou objetos da classificação. Recomenda-se que, em outros estudos se analise o efeito topográfico em diferentes latitudes, datas de aquisição de dados espectrais e tipos de relevo para sua maior compreensão em diversas condições ambientais.

4. CONCLUSÕES

Com base nos resultados deste trabalho, pode-se fazer as seguintes conclusões gerais:

1 – O efeito topográfico teve influência sobre a classificação do uso e cobertura da terra utilizando GEOBIA.

2 – A correção topográfica causou mudança nos resultados da classificação em 26% da área total em comparação com a classificação sem correção.

3 – O índice de exatidão e o índice de concordância kappa da classificação com correção topográfica foram mais elevados (em ~10%) que os da sem correção.

4 – A classificação com correção topográfica apresentou árvore de decisão mais simplificada (menor número de nós) e segmentos com áreas maiores que a classificação sem correção.

AGRADECIMENTOS

Os autores agradecem aos professores Dr. João Marcos Caixeta Franco (UNIFAL-MG), Dr. João Luiz Lani (UFV-MG) e Dra. Dilce de Fátima Rossetti (DSR/INPE), pelas diversas contribuições para realização deste

estudo. Agradecem também à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), e o CNPq pelo apoio financeiro, e aos quatro revisores anônimos por suas diversas considerações que foram importantes para a melhoria deste estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

BENZ, U.C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, p. 239-258, 2004. doi: 10.1016/j.isprsjprs.2003.10.002.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, p. 2-16, 2010. doi: 10.1016/j.isprsjprs.2009.06.004.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. **Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications**. In: CREMERS, A.; GREVE, K. (Org.), *Environmental Information for Planning, Politics and the Public*. Marburg: Metropolis Verlag, 2000, p. 555-570.

BRASIL. Instituto Nacional de Pesquisas Espaciais (INPE). **Topodata: banco de dados geomorfométricos do Brasil**. Variáveis geomorfométricas locais. São José dos Campos, 2008. Disponível em: <<http://www.dsr.inpe.br/topodata/>>. Acesso em: 10 set. 2014.

COLBY, J.D.; KEATING, P.L. Land cover classification using Landsat TM imagery in the tropical highlands: the influence of anisotropic reflectance. **International Journal of Remote Sensing**, v. 19, n. 8, p. 1479-1500, 1998.

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data: Principles and Practices**. 2. ed. Boca Raton: CRC Press, 2009. 183p.

CUO, L.; VOGLER, J.B.; FOX, J.M. Topographic normalization for improving vegetation classification in a mountainous watershed in Northern Thailand. **International Journal of Remote Sensing**, v. 31, n. 11, p. 3037-3050, 2010. doi: 10.1080/01431160903154333.

- DEFINIENS. **eCognition developer 8 user guide**. Munich: Definiens, 2009. 236p.
- DORREN, L.K.A.; MAIER, B.; SEIJMONSBERGEN, A.C. Improved Landsat-based forest mapping in steep mountainous terrain using object-based classification. **Forest Ecology and Management**, v. 183, p. 31-46, 2003. doi:10.1016/S0378-1127(03)00113-0.
- EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema brasileiro de classificação de solos**. 2. ed. Rio de Janeiro: Embrapa Solos, 2006. 306p. ISBN: (978-85-7035-198-2).
- EMBRAPA; INPE. **TerraClass: Levantamento de dados de uso e cobertura da terra na Amazônia - 2010**. 2012. Disponível em: <http://www.inpe.br/cra/projetos_pesquisas/terraclass2010.php>. Acesso em: 20 Ago. 2015.
- HAY, G.J.; CASTILLA, G. **Geographic Object-Based Image Analysis (GEOBIA): a new name for a new discipline**. In: BLASCHKE, T.; LANG, S.; HAY, G.J. (Org.), **Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications**, Berlin: Springer-Verlag, 2008, p. 75-89.
- HOLBEN, B.N.; JUSTICE, C.O. The topographic effect on spectral response from nadir-pointing sensors. **Photogrammetric Engineering and Remote Sensing**, v. 46, n. 9, p. 1191-1200, 1980.
- HORN, B.K.P. Hill shading and the reflectance map. *Proceedings of the IEEE*, v. 69, n. 1, p. 14-47, 1981.
- HOTHORN, T.; HORNIK, K.; ZEILEIS, A. Unbiased recursive partitioning: a conditional inference framework. **Journal of Computational and Graphical Statistics**, v. 15, n. 3, p. 651-674, 2006.
- INPE. Monitoramento de Queimadas e Incêndios. Disponível em: <<http://www.inpe.br/queimadas/apresentacao.php>>. Acesso em: 21 Ago. 2015.
- Instituto Brasileiro de Geografia e Estatística (IBGE). **Produção agrícola municipal, Tabela 1612** - área plantada, área colhida, quantidade produzida e valor da produção da lavoura temporária. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em: 10 set. 2014.
- KOBAYASHI, S.; SANGA-NGOIE, K. A comparative study of radiometric correction methods for optical remote sensing imagery: the IRC vs. other image-based C-correction methods. **International Journal of Remote Sensing**, v. 30, n. 2, p. 285-314, 2009. doi: 10.1080/01431160802356781.
- MATHER, P.; TSO, B. **Classification Methods for Remotely Sensed Data**. London CRC Press, 2009. 376p.
- MEYER, P.; ITTEN, K.L.; KELLENBERGER, T.; SANDMEIER, S.; SANDMEIER, R. Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 48, p. 17-28, 1993.
- MOREIRA, E.P. **Correção radiométrica do efeito de iluminação solar induzido pela topografia**. 2014. 86 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos. 2014. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3FHCR62>>. Acesso em 23 set. 2014.
- MOREIRA, E.P.; VALERIANO, M.M. Application and evaluation of topographic correction methods to improve land cover mapping using object-based classification. **International Journal of Applied Earth Observations and Geoinformation**, v. 32, p. 208-217, 2014. doi: 10.1016/j.jag.2014.04.006.
- PINHO, C.M.D.; FEITOSA, F.F.; KUX, H. Classificação automática de cobertura do solo urbano em imagem IKONOS: Comparação entre a abordagem pixel-a-pixel e orientada a objetos. In: XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 2005. **Anais**. p. 4217-4224, 2005.
- PRODES. **Monitoramento da Floresta Amazônica Brasileira por Satélite**. Disponível em: <<http://www.obt.inpe.br/prodes>>. Acesso em: 07 Ago. 2015.
- R CORE TEAM, 2013. **R: A language and environment for statistical computing**. Vienna, Austria: R Foundation for Statistical Computing. ISBN (3-900051-07-0).
- RIAÑO, D.; CHUVIECO, E.; SALAS,

- J.; AGUADO, I. Assessment of Different Topographic Corrections in Landsat-TM Data for Mapping Vegetation Types. **IEEE Transactions on Geoscience and Remote Sensing**, v. 64, n. 5, p. 1056-1061, 2003. doi: 10.1109/TGRS.2003.811693.
- STROBL, C.; MALLEY, J.; TUTZ, G. An introduction to recursive partitioning: rationale, application and characteristics of classification and regression trees, bagging and random forests. **Psychol Methods**, v. 14, n. 4, p. 323-348, 2009. doi: 10.1037/a0016973.
- TEILLET, P.M.; GUINDON, B.; GOODENOUGH, D.G. On the slope-aspect correction of multispectral scanner data. **Canadian Journal of Remote Sensing**, v. 8, p. 84-106, 1982.
- TEILLET, P.M. IMAGE correction for radiometric effects in remote sensing. **International Journal of Remote Sensing**, v. 7, n. 12. p. 1637-1651, 1986.
- VANONCKELEN, S.; LHERMITTE, S.; ROMPAEY, A.V. The effect of atmospheric and topographic correction methods on land cover classification accuracy. **International Journal of Applied Earth Observation and Geoinformation**, v. 24, p. 9-21, 2013. doi: 10.1016/j.jag.2013.02