

## Efeito da topografia sobre a classificação do uso e cobertura da terra por análise de imagens baseada em objetos

Eder Paulo Moreira<sup>1</sup>  
Márcio de Morisson Valeriano<sup>1</sup>  
Camilo Daleles Rennó<sup>1</sup>  
Helena França<sup>2</sup>

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

<sup>2</sup> Universidade Federal do ABC - UFABC  
Caixa Postal 5001 - 09210-170 - Santo André, SP - Brasil  
helena.franca@ufabc.edu.br

**Abstract.** This study evaluates the influence of topography (topographic effect) on land cover mapping through object-based classification. Tests were applied on Landsat 5 TM reflective bands, which were classified in their original form and after corrected for topography. 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, which was performed using a semi-empirical method. 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 carried out through their accuracies (kappa and overall accuracy), decision trees structure and segments (or regions) size. The results indicate that the topographic effect has influence on all measures of comparison. After topographic correction, classification showed higher accuracy, less complex decision tree (fewer nodes) and larger segments. 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, topographic correction should be applied to reduce topographic effect on the land cover mapping.

**Key words:** topographic correction, topographic effect, Landsat, SRTM, land cover, classification.

### 1. Introdução

Em diversas circunstâncias, efeitos radiométricos restringem a capacidade de imagens óticas orbitais em fornecer informações sobre o uso e cobertura da terra (Teillet, 1986). Entre estes efeitos, pode-se citar a influência da atmosfera (Song et al., 2001), do ângulo zenital/azimutal solar e de visada do sensor (Galvão et al., 2013) e da topografia (Horn, 1981).

O efeito topográfico é causado pela variação da iluminação solar em função da declividade e orientação de vertente em combinação com o ângulo zenital e azimutal solar (Holben e Justice, 1980). Em áreas de topografia irregular, os níveis radiométricos da imagem recebe influência dessa variação, que modifica a característica espectral intrínseca de determinado alvo. Como expressão mais evidente deste efeito, os dados radiométricos normalmente possuem valores mais elevados em vertentes expostas à direção do Sol do que em vertentes com orientação oposta (Riaño et al., 2003).

O efeito topográfico pode prejudicar o desempenho dos classificadores automáticos, comumente utilizados para classificação do uso e cobertura da terra. No entanto, existem vários métodos de correção desse efeito que resultaram em melhorias significativas para a classificação (Meyer et al., 1993; Cuo et al., 2010). 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, do método de correção e da forma como ele é aplicado (Kobayashi e Sanga-Ngoie, 2008; Moreira e Valeriano, 2014). Além disso, os resultados podem variar com a

metodologia de classificação. Espera-se maior sucesso em abordagens que representam as diferentes condições de iluminação em cada classe de uso ou cobertura da terra (Moreira, 2014).

Os estudos que analisam a influência do efeito topográfico sobre a classificação do uso e cobertura da terra foram conduzidos utilizando classificadores locais (“*pixel-a-pixel*”) (Vanonckelen et al., 2013). No presente estudo, buscou-se compreender essa influência sobre a classificação por regiões, particularmente sobre a análise de imagens baseada em objetos (OBIA) (Benz et al., 2004), que recentemente tem sido uma técnica muito utilizada para classificação do uso e cobertura da terra (Blaschke, 2010).

## 2. Material e Métodos

A área de estudo (Figura 1) localiza-se na parte sul do estado de Minas Gerais, entre os municípios de Alfenas e Machado, e equivale a uma quadrícula de 11,5km de lado. Situada na região tropical, 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 o tipo suave ondulado e o 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).

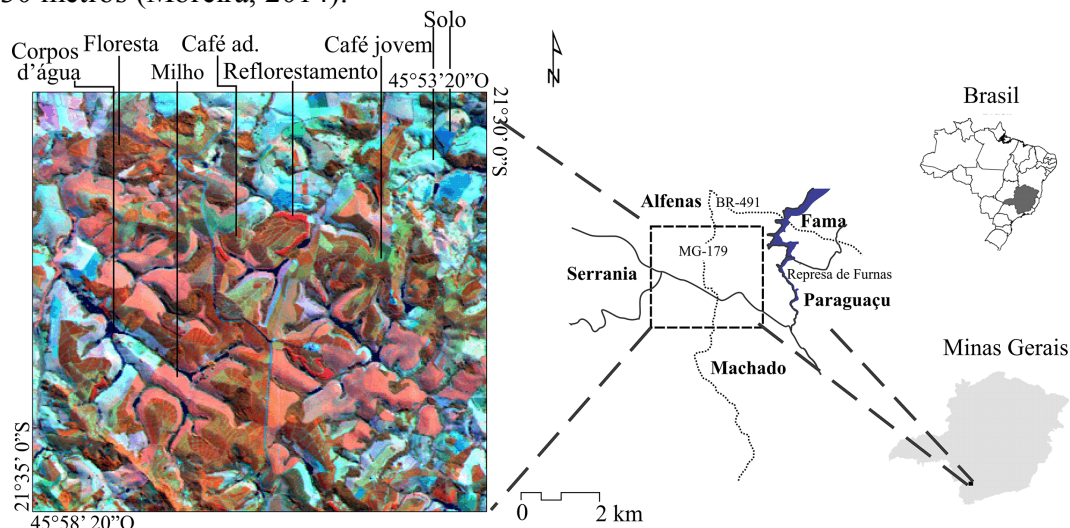


Figura 1. Localização da área de estudo. Imagem Landsat 5 TM, sob composição 453 (RGB), com as classes de uso e cobertura identificadas.

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 outras imagens Landsat 5 TM e imagens de alta resolução do Google Earth, adquiridas no ano de 2011, para verificação dos dados de referência, isto é, todas as amostras descritas a seguir.

O fluxo da geração de resultados para análises, esquematizado na Figura 2, teve suas etapas desenvolvidas na linguagem de programação R, versão 3.0 (R Development Core Team, 2013), com exceção da segmentação, que foi conduzida no *Definiens*, versão 8.0 (Definiens, 2009). A segmentação foi realizada com o algoritmo “multiresolução” (Benz et al., 2004). No R, foi utilizado o algoritmo “CTREE” do pacote “*party*” (Hothorn et al, 2006) para criação da árvore de decisão na etapa de classificação.



Figura 2. Fluxograma das principais etapas desenvolvidas.

O processamento inicial consistiu no registro entre as imagens e o MDE e no cálculo do cosseno do ângulo de incidência solar na superfície,  $\cos i$ , de acordo com a equação (Sellers, 1965):

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

Onde  $\theta_s$  é o ângulo zenital solar,  $\theta_t$  é o ângulo zenital da normal à superfície (declividade),  $\varphi_s$  é o ângulo azimutal solar e  $\varphi_t$  é o ângulo azimutal da normal à superfície (orientação de vertentes). Os dados foram estruturados pelo sistema de coordenadas geográficas (não-projetados), datum WGS 1984.

Por meio de uma avaliação prévia (Moreira e Valeriano, 2014), foi selecionado o método de correção topográfica de Teillet et al. (1982), que 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  $\delta NC_{\lambda ij}$  é o nível de cinza (NC) corrigido da banda  $\lambda$  e *pixel*  $ij$ ,  $NC_{\lambda ij}$  é o NC original;  $b_\lambda$  e  $m_\lambda$  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  $c_\lambda$ , foram utilizadas amostras em locais ocupados por milho ( $n=222$ ), devido à sua maior homogeneidade em termos de cor e textura da imagem (Figura 1) e por sua grande representatividade em termos de área e variação dos níveis de  $\cos i$  na área de estudo (Moreira, 2014).

A correção foi aplicada diretamente sobre os valores digitais de cada banda espectral, sem nenhuma transformação prévia, numa prática observada em alguns estudos (Meyer et al., 1993; Cuo et al., 2010). No entanto, outros trabalhos (Teillet, 1986; Gu and Gillespie, 1998) apontam a correção atmosférica antes da topográfica como recomendável.

Foram coletados três conjuntos de amostras de controle, em forma de pontos. O primeiro conjunto de amostras teve a finalidade de estimar os parâmetros da correção, conforme descrito anteriormente. Essas amostras foram coletadas em diferentes declividades e orientação de vertentes para representar as diferentes condições de iluminação ( $\cos i$ ) da área.

O segundo conjunto de amostras foi utilizado para treinar o classificador. Todas as classes de cobertura da área foram representadas nas amostras de treinamento, com 55 amostras de áreas de café adulto, 63 de milho, 41 de floresta, 59 de solo e 39 das demais (aquelas que ocupam menores extensões territoriais). O terceiro conjunto de amostras foi utilizado para avaliar a classificação, para o que foram coletadas aleatoriamente 50 amostras para cada classe de uso e cobertura da terra. Nesta fase foi decidido dispor numa mesma classe (“outros”) as coberturas de menor expressão territorial na área de estudo, que incluem café jovem, reflorestamento e corpos d’água, totalizando 50 amostras.

A classificação dos dados Landsat divide-se em duas partes: segmentação e classificação por árvore de decisão. As bandas sem correções foram utilizadas na 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. Procurou-se otimizar 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. Os mesmos parâmetros foram utilizados para segmentar as bandas com correção. Para classificação dos segmentos, foram calculados vários atributos texturais, espectrais, entre outros, referente a cada segmento (Moreira, 2014).

As amostras (pontos) de treinamento foram sobrepostas a cada uma das segmentações (sem e com correção topográfica) para seleção de segmentos, e de seus respectivos atributos, para treinar o algoritmo de classificação por árvore de decisão. Alguns parâmetros do algoritmo foram ajustados para maior adequação aos dados: o número mínimo de amostras nos nós terminais foi ajustado para 3; o valor do teste estatístico (1 - valor-p), que não deve ser excedido para possibilitar uma divisão, foi ajustado para 0,95; e a soma mínima de amostras para ocorrer uma divisão foi ajustada para 6. Os demais parâmetros do algoritmo não foram alterados.

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 e folhas, 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 matriz de confusão e o índice de concordância kappa calculado a partir dela.

### 3. Resultados e Discussão

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




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

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. Esta variação equivale a



aproximadamente 18% de diferença em relação ao total da classe milho entre as duas classificações (Figura 4a).

O mapeamento e a quantificação das diferenças existentes entre classificação sem e com correção indicam que em 26% da área das duas classificações são diferentes. Portanto, a classificação nas duas condições apresentou um nível de diferença bastante significativo em termos de área, o que demonstra uma forte influência do efeito topográfico (Figura 4b). No processo de segmentação, o tamanho médio dos segmentos aumentou após a correção para todas as classes de uso e cobertura da terra analisadas (Figura 4c).

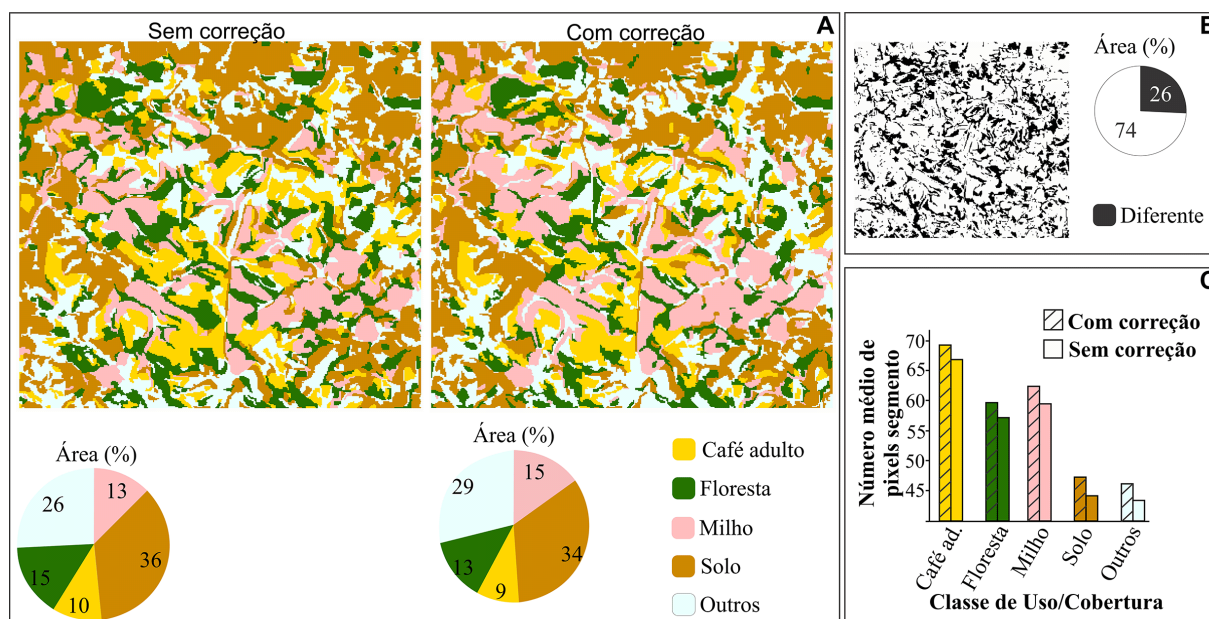


Figura 4. Classificação do uso e cobertura da terra sem/com correção topográfica e suas respectivas áreas em porcentagem (A); área onde as duas classificações (sem/com correção) são diferentes (B) e; tamanho médio dos segmentos de cada classe de uso e cobertura da terra das duas classificações.

Com a correção topográfica, a árvore de decisão foi simplificada, de 9 nós e 10 folhas para 8 nós e 9 folhas. O nó e a folha que a árvore sem correção possui a mais é responsável pela distinção de café adulto, floresta e “outros”. Em outras palavras, foi necessário um atributo a mais para classificá-los. Além disso, as árvores diferenciaram-se 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 obtida na classificação da imagem sem correção, e *Wetness* e B5/B4 somente com a imagem corrigida (Figura 5 e 6).

Em relação ao valor-p presente nos nós das árvores de decisão, nota-se que existem na árvore de decisão da imagem sem correção valores que se aproximam de 0,05, que é o valor máximo estabelecido para que ocorra a partição que resulte em dois nós ou folhas. Existem quatro nós que possuem valor-p maiores que 0,01. Após a correção, todos os valores-p foram menores ou iguais a 0,01. Portanto, pode-se considerar que existe maior nível de impureza em alguns nós da árvore obtida sem correção em relação àquela obtida com imagem corrigida, o que indica maior grau de confusão entre classes de cobertura da terra.

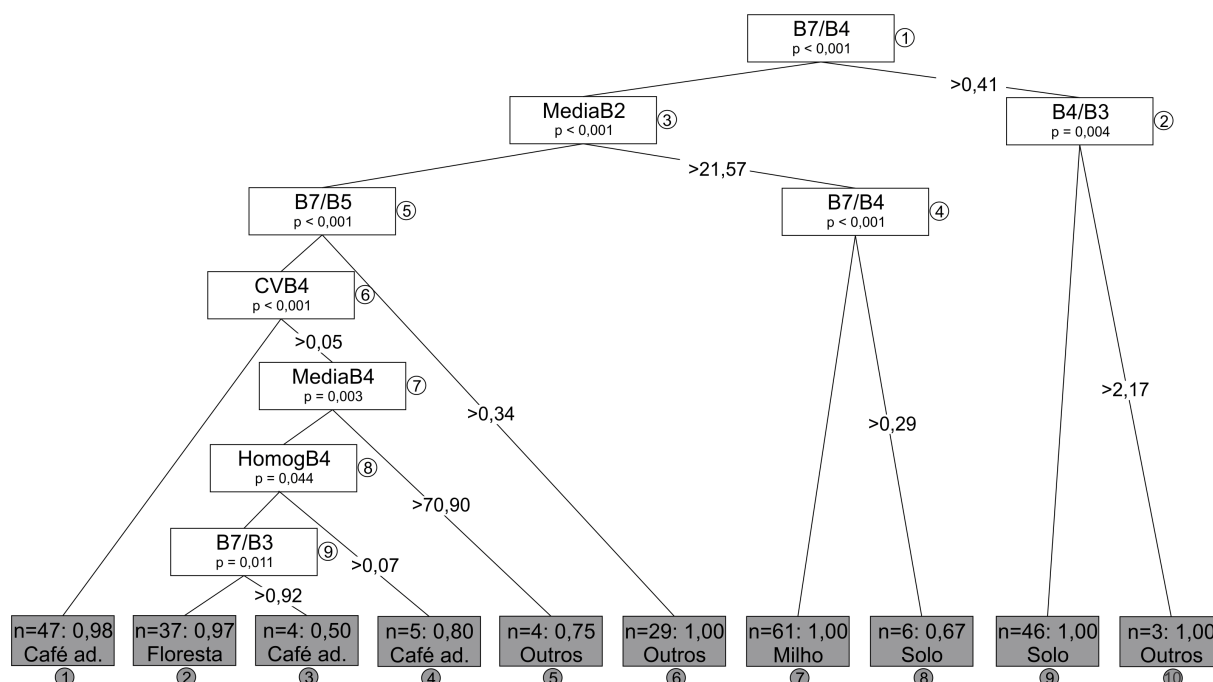


Figura 5. Árvore de decisão da classificação sem correção topográfica. A letra B e os números representam as bandas espectrais Landsat TM 5; CV é o coeficiente de variação; e Homog é homogeneidade.

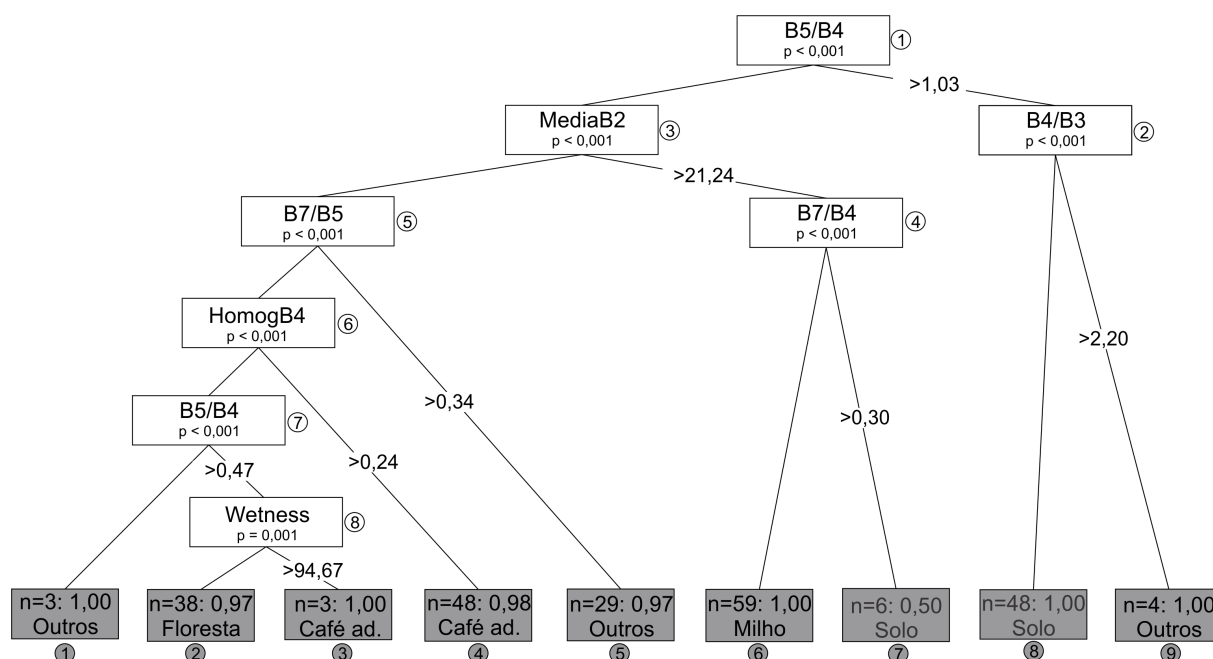


Figura 6. Árvore de decisão da classificação com correção topográfica. A letra B e os números representam as bandas espectrais Landsat TM 5 e Homog é homogeneidade.

Pela observação das diagonais das matrizes de confusão da classificação, observa-se que ocorreu maior confusão entre classes de uso e cobertura da terra para a imagem sem correção. Houve maior quantidade de acertos para todas as classes da classificação com correção, com exceção da classe solo, cuja classificação teve desempenho igual sob as duas condições (Tabela 2).

Tabela 2. Matrizes de confusão da classificação da imagem sem e da com correção topográfica

Classificação	Referência					
	Milho	Solo	Café ad.	Floresta	Outros	TOTAL
<b>Classificação sem correção</b>						
Milho	<b>44</b>	0	0	0	0	44
Solo	0	<b>48</b>	0	0	1	49
Café ad.	3	0	<b>37</b>	6	1	47
Floresta	3	0	9	<b>41</b>	4	57
Outros	0	2	4	3	<b>44</b>	53
Exatidão Global: 86%					Índice Kappa: 0,82	
<b>Classificação com correção</b>						
Milho	<b>50</b>	0	0	0	0	50
Solo	0	<b>48</b>	0	0	2	50
Café ad.	0	0	<b>41</b>	1	2	44
Floresta	0	0	6	<b>47</b>	1	54
Outros	0	2	3	2	<b>45</b>	52
Exatidão Global: 92%					Índice Kappa: 0,91	

Observa-se 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. 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).

#### 4. Conclusões

Com base nos resultados apresentados, pode-se concluir com esta metodologia que:

1 – O efeito topográfico teve influência sobre a classificação do uso e cobertura da terra utilizando análise de imagem baseada em objetos.

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

3 – A 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.

#### Referências

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.

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

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.

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).

Galvão, L.S.; Breunig, F.M.; Santos, J.R.; Moura, Y.M. View-illumination effects on hyperspectral vegetation indices in the Amazonian tropical forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 291–300, 2013.

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.

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.

Horn, B.K.P. Hill shading and the reflectance map. *Proceedings of the IEEE*, v. 69, n. 1, p. 14-47, 1981.

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.

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.

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.

Sellers, W.D. **Physical climatology**. Chicago: University of Chicago Press, 1965. 272p. ISBN: (978-0226746999).

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.2013.02.003.