

Eficiência de imagens Landsat sintéticas para o mapeamento da cafeicultura

Carolina Gusmão Souza¹
Luis Marcelo Tavares de Carvalho¹
Polyanne Aguiar dos Santos¹
Tássia Borges Arantes¹
Nathália Silva de Carvalho¹

¹ Universidade Federal de Lavras - UFLA
Caixa Postal 3037 - 37200-000 - Lavras - MG, Brasil
{carolinagusmaosouza, pollyaneaguair, tassiabarantes, nathalia.bioufla} @gmail.com;
passarinho@dcf.ufla.br

Abstract. Coffee cropping is a major Brazilian agricultural activity, so monitor these areas is crucial. In tropical regions, the quality of these images is affected mainly because of the big amount of clouds. To solve these problems, an alternative is use an image fusion. The aim of this study was to investigate the potential of using synthetic Landsat images for coffee mapping areas and evaluate the efficacy of different sets of mapping variables in the use of such images. Thus, we intend to answer the questions: (1) Are there significant differences between the classifications using synthetic Landsat images? (2) Use of texture variable, associated with spectral variables is effective to classify the coffee, using synthetic Landsat images? The fusion of images was performed using the algorithm STARFM, it considers the spectral information from MODIS image and spatial information from Landsat image. Therefore, we had six synthetic Landsat bands. Evaluation of the images was made from a linear regression. In classification we use the Random Forest algorithm, using spectral and textural variables. The results showed a high correlation between the synthetic and the original scene. The better results for bands 5, 7 and 3 ($R^2=0.89$; $R^2=0.88$; $R^2=0.77$, respectively). The overall accuracy for both classifications were similar (86.78% original and 84.28% synthetic), showing no significant difference between them. Texture data, combined with spectral data proved effective in the classification process. We conclude that the use of synthetic images for coffee mapping was efficient and can be used as a substitute images with clouds.

Palavras-chave: sensoriamento remoto, fusão de imagens, variáveis espectrais e texturais, STARFM, Landsat TM, MODIS, remote sensing, image fusion, spectral and textural variables,.

1. Introdução

A cafeicultura é umas das principais culturas agrícolas do Brasil e exerce um papel importante no cenário socioeconômico brasileiro e internacional (CONAB, 2014). O estado de Minas Gerais é o maior produtor de café do país, e sua produção corresponde a cerca de 50% da produção nacional (CONAB, 2014). Dessa forma, realizar o monitoramento e mapeamento de forma precisa destas áreas é fundamental. O uso de imagens de satélite como uma fonte de informação no agronegócio é muito comum. Nessas aplicações, é fundamental conhecer o uso e ocupação da terra (SANTOS et al., 2012).

O sensoriamento remoto tem sido bastante usado para este objetivo e atualmente, um grande esforço tem sido feito para criação de mapas temáticos de alta qualidade para estabelecer inventários precisos sobre o uso de cobertura da terra (WILKINSON, 2005). No entanto, a classificação de imagens de satélite para esta cultura muitas vezes é uma tarefa difícil, pois o café apresenta uma resposta espectral muito semelhante a diferentes tipos vegetacionais (MOREIRA et al., 2004).

Muitos trabalhos mapeando café usam imagens provenientes do satélite Landsat (ANDRADE et al., 2013; VIEIRA et al., 2006; MOREIRA et al., 2004). Estas imagens são bastante usadas em estudos de mapeamento, monitoramento e dinâmica do uso e cobertura da terra, devido à alta regularidade dos dados disponíveis.

No entanto, as regiões tropicais, devido às diversas variáveis ambientais, possuem uma alta contaminação por nuvens, o que afeta a qualidade das imagens e dados gerados. Uma alternativa é a utilização de fusão de imagens, que utilizam dados de diferentes sensores com diferentes características espaciais e temporais para suprir esta deficiência.

Neste estudo, foi utilizada uma abordagem de fusão de dados espacial e temporal Adaptive Reflectance Fusão Model – STARFM (GAO et al., 2006). Este método utiliza a informação espectral de imagens MODIS e informação espacial de imagens Landsat. Porém não se sabe a eficiência destas imagens para o mapeamento e monitoramento da cafeicultura.

Sendo assim, o objetivo do estudo foi investigar o potencial do uso de imagens Landsat sintéticas no mapeamento de áreas cafeeiras, bem como avaliar a eficácia do uso de diferentes conjuntos de variáveis no mapeamento, usando este tipo de imagens. Neste sentido, pretendemos responder as seguintes questões: (1) Há diferença significativa entre as classificações utilizando imagens Landsat sintéticas? (2) O uso de variáveis de textura, associadas a variáveis espectrais são eficientes para classificar o café, usando imagens Landsat sintéticas?

2. Metodologia

2.1 Área de estudo

A área de estudo está localizada na região sul do estado de Minas Gerais, no município de Carmo da Cachoeira (Figura 1). Está entre as coordenadas 21°29'55" Sul e 45°12'47" Oeste (SILVA et al., 2014). O clima da região, de acordo com a classificação de Koppen, é classificado como Cwb, clima mesotérmico ou tropical de altitude, com inverno seco e verão chuvoso, com temperaturas amenas. Tem a uma altitude média de 987 metros. O município está inserido no bioma Mata Atlântica e sua vegetação é caracterizada por Florestas Estacionais Semidecíduais (SILVA et al., 2014). O município se destaca na produção de café e é uma região muito importante no cenário da cafeicultura mineira.

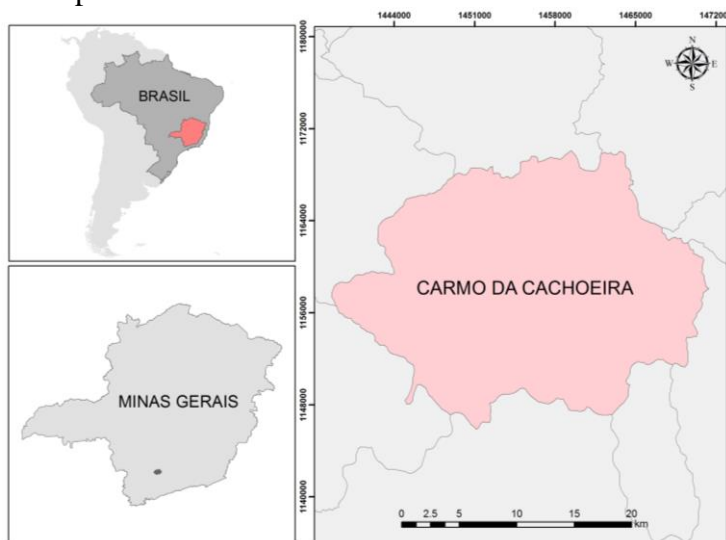


Figura 1: Localização da área de estudo

2.2 Aquisição dos dados e pré-processamento

Para este estudo foram utilizadas duas imagens do satélite Landsat, sensor TM (órbita/ponto 218/075), com datas de 2010245 e 2010213. As imagens Landsat TM possuem dados de reflectância em 7 bandas, possuem resolução espacial de 30 metros (exceto para banda termal, que apresenta resolução de 120 metros). Foi utilizado o produto CDR

(*Reflectance Climate Data Record Landsat Surface*) disponível no portal United States Geological Survey (USGS) (<http://earthexplorer.usgs.gov/>). Este produto é gerado a partir do software especializado chamado LEDAPS (*Landsat Ecosystem Disturbance Adaptive Processing System*). O LEDAPS gera dados sobre refletância e temperatura de superfície, localização de nuvens e sombras de nuvens, solo e água, a partir de informações como vapor de água, ozônio, altura geopotencial, espessura óptica de aerossóis, e elevação do terreno. Esse conjunto de dados serve de entrada para o algoritmo 6S (*Satellite Signal in the Solar Spectrum*), que resultam em produtos CDR (MASEK, 2009), além disso, o produto é ortorretificado. Estas imagens foram usadas para a classificação do uso da terra e como input no processo de fusão.

Foram usadas também duas imagens do sensor MODIS (produto MOD09), nas datas 2010209 e 2010241, como input para o processo de predição. As imagens foram adquiridas pelo portal USGS (<https://mrtweb.cr.usgs.gov/>), cena h13v11. Esse produto fornece dados de refletância de várias bandas, inclusive as que estão contidas no satélite Landsat TM. O MOD09 apresenta uma resolução espacial de 500 metros.

Todas as bandas, referentes às bandas da imagem Landsat TM, foram reprojatadas para a projeção Universal Transversa de Mercator (UTM), para isso, utilizou-se o software MODIS Re-projection Tools (MRT). Além disso, estas bandas foram reamostradas para 30 m de resolução espacial utilizando uma abordagem do vizinho mais próximo. Estes procedimentos foram realizados utilizando o software ENVI 4.8. Em todas as imagens foram feitos subsets na extensão do polígono correspondente à imagem Landsat TM.

2.3 Predição de imagem sintética

Para a fusão das imagens, Landsat TM e MODIS, foi utilizado o algoritmo STARFM, desenvolvido por Gao et al.(2006). Este algoritmo utiliza uma janela móvel que incorpora informações adicionais dos pixels vizinhos das imagens Landsat e MODIS, empregando uma função ponderada definida como a combinação espacial, temporal e espectral das imagens (GAO et al., 2006). O algoritmo é expresso pela fórmula:

$$L\left(\frac{x_w}{2}, \frac{y_w}{2}, t_0\right) = \sum_{i=1}^w \sum_{j=1}^w \sum_{k=1}^n W_{ijk} * (M(x_i, y_j, t_0) + L(x_i, y_j, t_0) - M(x_i, y_j, t_k))$$

Onde w é o tamanho da janela de busca e $\left(\frac{x_w}{2}, \frac{y_w}{2}\right)$ é o pixel central dessa janela móvel. O peso W_{ijk} é calculado a partir de três medidas: diferença espectral entre MODIS e Landsat TM, diferença temporal entre MODIS T_1 e MODIS T_2 e a distância entre o pixel central predito e o pixel vizinho candidato espectralmente semelhante, dessa forma determinando o quanto cada pixel vizinho irá contribuir para estimar o valor de refletância do pixel central (Gao et al. 2006). Neste estudo, foi utilizada uma área de 750 m X 750 m como *moving window*.

Com o intuito de comparar a eficiência destas imagens, nós utilizamos uma imagem Landsat TM, data de 2010245 para ser predita. Esta imagem estava completamente livre de nuvens. As imagens TM livres de nuvens foram pareadas com imagens MODIS, levando em consideração a diferença mínima entre as datas de imageamento dos sensores (Tabela 1).

Tabela 1: Pares de imagens MODIS e Landsat (sem nuvens) correspondentes utilizadas na predição de imagens Landsat sintéticas.

MODIS T1	Landsat TM T1	MODIS T2	Landsat Sintética
2010209	2010213	2010241	2010245

2.4 Avaliação da imagem sintética

A avaliação das imagens Landsat TM sintéticas foi feita por meio de uma regressão linear entre os valores de refletância das imagens Landsat TM originais e preditas.

Foi usada uma abordagem baseada em objeto, pois a classificação foi feita utilizando esta mesma abordagem. Foram utilizados os mesmos parâmetros da segmentação para classificação. As regressões lineares simples foram realizadas para avaliarmos o coeficiente de determinação (R^2), de todas as bandas, exceto a banda 6.

2.5 Classificação do uso da terra

A classificação foi realizada para a área do município de Carmo da Cachoeira. Foi utilizada uma abordagem baseada em objeto, sendo assim, a imagem Landsat TM foi segmentada, usando o algoritmo *multi-resolution segmentation*, do software Ecognition (citação). Os parâmetros usados foram: 250 para escala, e 0.5 para forma e compacidade. A classificação de uso da terra foi feita para separar os principais tipos de cobertura existentes, mas principalmente vegetação, café e pastagem. Assim, foram utilizadas 5 classes de uso: Vegetação natural, Café, Pastagem, Outros usos e Corpos D'água.

A classificação foi realizada usando o algoritmo de aprendizado de máquina *Random Forest* (RF). O algoritmo de classificação Random Forest é descrito em detalhes em Breiman, 2001. Resumidamente, o Random Forest se baseia em um conjunto de árvores de classificação e possui muitas qualidades, como alta precisão, lida bem com grande base de dados e possui medidas integradas de importância das variáveis envolvidas no modelo (DIAZ-URIARTE e ALVAREZ DE ANDRES, 2006). A classificação foi realizada no software RStudio.

Foram usadas variáveis espectrais e texturais no processo de classificação (Tabela 2), a fim de verificar como estas variáveis influenciam na acurácia da classificação.

Tabela 2: Relação das variáveis usadas neste estudo. Variáveis relacionadas às informações espectrais, texturais e geométricas.

Informação espectral	Bandas espectrais*
	Razão de Bandas (NDVI e SAVI)
	Brilho*
	Média*
Textura GLCM todas as direções	Desvio Padrão*
	Entropia
	Homogeneidade
	Média
	Desvio Padrão
	Correlação

* Selecionado para cada banda.

Foram selecionados cerca de 10% do total de objetos gerados pela segmentação como amostras de treinamento. As amostras foram coletadas de maneira uniforme por toda imagem. A escolha dos objetos foi feita usando interpretação visual e de forma criteriosa, sendo que objetos com mais de um tipo de cobertura da terra não foram utilizados.

2.6 Amostras de acurácia e análise estatística

Com a finalidade de verificar a acurácia das classificações, foram coletados 280 pontos como dados de teste. Esses pontos foram obtidos através de uma amostragem estratificada aleatória, em que cada estrato foi representado por uma categoria de classificação

(MARTÍNEZ-VERDUZCO et al., 2012). Foi utilizado o coeficiente Kappa e acurácia global como critério de avaliação.

Para comparar os resultados das acurácias foi usado o teste de McNemar's (FOODY, 2004; MAS et al., 2010) (Tabela 3).

Tabela 3: Matriz de confusão usada no teste de McNemar's.

Classificação 2	Classificação 1	
	Correto	Incorreto
Correto	f_{11}	f_{12}
Incorreto	f_{21}	f_{22}

A avaliação do teste é baseada na distribuição chi-quadrado (Z^2). Assim, o valor de chi-quadrado calculado é comparado com o valor de chi-quadrado tabelado indicando sua significância estatística (FOODY, 2004; MAS; GAO; PACHECO, 2010). O quadrado de Z segue uma distribuição chi-quadrado com um grau de liberdade. A equação do teste pode ser expressa por:

$$Z^2 = \frac{(f_{12} - f_{21})^2}{f_{12} + f_{21}}$$

3. Resultados e Discussão

Neste trabalho avaliou-se a efetividade do uso de uma imagem Landsat sintética para o mapeamento de áreas cafeeiras, bem como o uso de diferentes variáveis para a classificação destas áreas.

Os resultados da regressão linear mostraram que a imagem sintética possui uma alta correlação com a imagem Landsat original (Figura 2). Os melhores resultados foram encontrados para as bandas 5, 7 e 3, com R^2 de 0.89, 0.88 e 0.84, respectivamente. A banda 2 e 4 apresentaram índices um pouco menores, com R^2 de 0.73 para a banda 2 e 0.77 para banda 4. Somente a banda 1 apresentou um R^2 mais baixo de 0.54. Resultados similares foram encontrados por Souza et al. (2014) em um estudo realizado na região sul de Minas Gerais, usando imagens sintéticas para mapeamento de vegetação natural, onde a imagem sintética apresentou alta correlação com original.

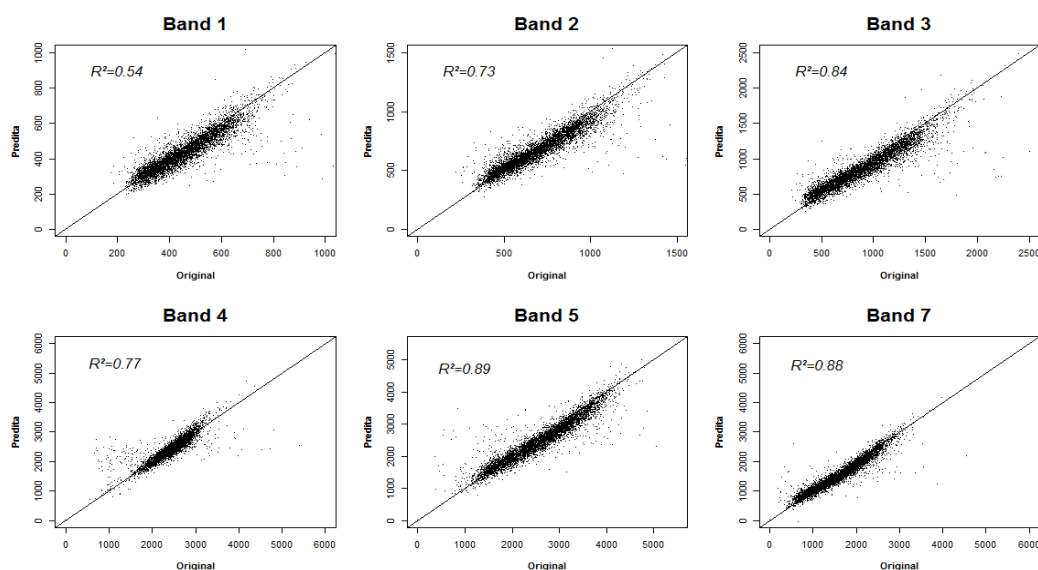


Figura 2: Gráficos de dispersão para todas as bandas Landsat.

Foram feitas duas classificações, uma para imagem original e outra para imagem sintética. A Tabela 4 mostra o resultado das classificações para as duas imagens.

Tabela 4: Valores de índice kappa, acurácia global e porcentagem de acerto para cada classe de uso.

Imagem Landsat	Acurácia						
	Global (%)	Kappa	Vegetação natural (%)	Pastagem (%)	Café (%)	Outros usos (%)	Corpos d'água (%)
Original	86.78	0.82	93.75	85.56	89.23	74.29	70.00
Sintética	84.28	0.78	91.25	90.00	81.54	62.86	70.00

Os resultados mostram que os índices de acerto foram bem parecidos para as duas classificações, com índices de acertos de 86.78% para a imagem original e 84.28% para a imagem sintética.

Quando comparado os índices de acerto por classes foi possível observar que para a classe vegetação natural a diferença de acerto foi bem pequena com 2.50%, entre as duas classificações. Para a classe café a diferença foi um pouco menor com 7.59%. A classe que apresentou a maior variação foi Outros usos com 11.43%. É importante salientar que para a classe pastagem o índice de acerto foi maior na classificação da imagem sintética (90.00%).

As classes café e vegetação natural obtiveram bons índices de separabilidade, tanto para a imagem original quanto para sintética. Isso mostra que imagens geradas a partir de dados fusionados podem ser eficientes para o mapeamento de áreas cafeeiras.

A análise estatística mostra que não houve diferença significativa entre as classificações (Tabela 5), porém é importante salientar mesmo não apresentando diferença significativa, as classificações possuem diferenças entre si, como é possível observar na Figura 3. Estes resultados mostram que mesmo possuindo índices de acerto parecidos as classificações são diferentes. Portanto, além das análises estatísticas e de acurácia é fundamental uma interpretação visual das classificações, para selecionar a que melhor separou as classes de uso.

Tabela 5: Comparações de classificações realizadas utilizando o teste de McNemar com $X^2=3.81$ tabulado.

Classificação 1	Classificação 2	X^2	Significante?
Original	Sintética	0.35	Não

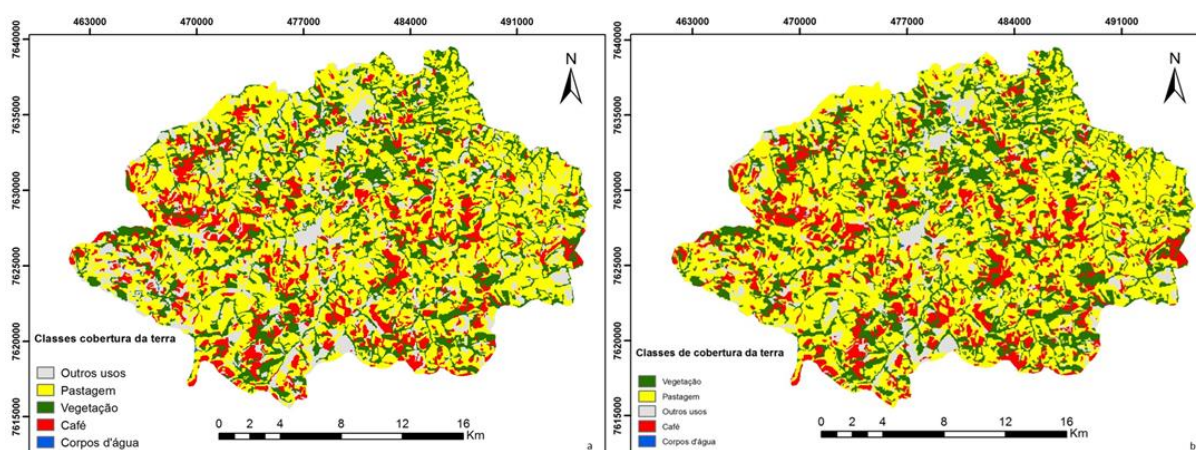


Figura 3: Mapa de uso da terra. a) Imagem original e b) Imagem predita.

É importante salientar que os dados de textura, aliados a dados espectrais se mostraram eficazes no processo de classificação, como pode ser observado na Figura 4, uma vez que as classificações obtiveram excelentes índices de acurácia, segundo (Landis and Koch, 1977), usando estes parâmetros para classificação. Muitas variáveis oriundas de dados de textura

mostraram valores maiores, sendo mais usadas do que algumas variáveis espectrais, obtendo bons resultados no processo de separação das classes para duas imagens.




Figura 4: Pontuação das variáveis usadas no processo de classificação, obtidas com o algoritmo RF. a) Imagem original; b) Imagem sintética. Variáveis: (1) NDVI; (2) SAVI; (3) Média b1; (4) Média b2; (5) Média b3; (6) Média b4; (7) Média b5; (8) Média b7; (9) Desvio padrão b1; (10) Desvio padrão b2; (11) Desvio padrão b3; (12) Desvio padrão b4; (13) Desvio padrão b5; (14) Desvio padrão b7; (15) Brilho; (16) Máxima diferença; (17) GLCM Contraste b1; (18) GLCM Contraste b2; (19) GLCM Contraste b3; (20) GLCM Contraste b4; (21) GLCM Contraste b5; (22) GLCM Contraste b7; (23) GLCM Entropia b1; (24) GLCM Entropia b2; (25) GLCM Entropia b3; (26) GLCM Entropia b4; (27) GLCM Entropia b5; (28) GLCM Entropia b7; (29) GLCM Homogeneidade b1; (30) GLCM Homogeneidade b2; (31) GLCM Homogeneidade b3; (32) GLCM Homogeneidade b4; (33) GLCM Homogeneidade b5; (34) GLCM Homogeneidade b7; (35) GLCM Média b1; (36) GLCM Média b2; (37) GLCM Média b3; (38) GLCM Média b4; (39) GLCM Média b5; (40) GLCM Média b7; (41) GLCM Desvio padrão b1; (42) GLCM Desvio padrão b2; (43) GLCM Desvio padrão b3; (44) GLCM Desvio padrão b4; (45) GLCM Desvio padrão b5; (46) GLCM Desvio padrão b7.

Estes resultados mostram que a imagem sintética é bastante eficiente no processo de classificação do uso e cobertura da terra, indicando bons resultados no processo de classificação e separabilidade de áreas cafejeiras.

4. Conclusão

O algoritmo STARFM se mostrou bastante promissor na predição das imagens Landsat TM, com alto índice de correlação entre as imagens. As imagens sintéticas foram eficazes na realização do mapeamento de áreas cafejeiras, bem como no mapeamento de uso da terra, podendo ser usadas como alternativa quando os dados originais não estiverem disponíveis.

O uso de variáveis texturais, tanto na imagem original, como na imagem predita, foram eficazes para aumentar a acurácia na classificação.

Mais estudos são necessários em outras áreas, para verificar a eficiência destas imagens em áreas com características ambientais distintas, além disso, testar em escalas maiores.

Agradecimentos

Gostaríamos de agradecer o Laboratório de Estudos e Projetos em Manejo Florestal – LEMAF pelo apoio na realização dos trabalhos. A Universidade Federal de Lavras e o Programa de Pós-graduação em Engenharia Florestal. A CAPES, FAPEMIG e CNPq pelas bolsas concedidas.

Referências

- ANDRADE, L. N.; VIEIRA, T. G. C. ; LACERDA, W. S.; VOLPATO, M. M. L.; DAVIS JUNIOR, C. A. Aplicação de redes neurais artificiais classificação de áreas cafeeiras da região de Machado (MG). *Coffee Science*, v. 8, p. 78-90, 2013.
- BREIMAN, L. E. O. Random Forests. p. 5–32, 2001.
- CONAB. Acompanhamento de Safra Brasileira. 2014.
- DIAZ-URIARTE, R.; ALVAREZ DE ANDRES, S. Gene selection and classification of microarray data using random forest. *BMC Bioinformatics*, v. 7, n. 3, p. 1-13, 2006.
- FOODY, G. M. Thematic Map Comparison : Evaluating the Statistical Significance of Differences in Classification Accuracy. n. May, p. 627–633, 2004.
- GAO, F.; MASEK, J. G.; SCHWALLER, M.; HALL, F. G. On the Blending of the Landsat and MODIS Surface Reflectance: Predicting Daily Landsat Surface Reflectance. *IEEE Tran. Geosci. Remote Sensing*, v. 44, n. 8, p. 3287–3319, 2006.
- LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data Data for Categorical of Observer Agreement The Measurement. *Biometrics*, v. 33, n. 1, p. 159–174, 1977.
- MARTÍNEZ-VERDUZCO, G. C.; GALEANA-PIZANA, J. M.; CRUZ-BELLO, G. M. Coupling Community Mapping and supervised classification to discriminate Shade coffee from Natural vegetation. *Applied Geography*, v. 34, p. 1–9, 2012.
- MAS, J.-F.; GAO, Y.; PACHECO, J. A. N. Sensitivity of landscape pattern metrics to classification approaches. *Forest Ecology and Management*, v. 259, n. 7, p. 1215–1224, 2010.
- MASEK, J. Automated registration and orthorectification package for Landsat and Landsat-like data processing. *Journal of Applied Remote Sensing*, v.3, n. 1, p. ,2009.
- MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. Análise espectral e temporal da cultura do café em imagens Landsat. *Pesq. agropec. bras.*, v. 39, n. 3, p. 223-231, 2004.
- SANTOS, J. A.; GOSSELIN, P. H.; PHILIPP-FOLIGUET, S.; TORRES, R. S.; FALCÃO, A. X. Multiscale Classification of Remote Sensing Images. *IEEE Trans. Geosci. Remote Sensing*, v. 50, n. 10, p. 3764–3775, 2012.
- SILVA, F. O. R.; RAMOS, J. D.; OLIVEIRA, M. C.; RUFINI, J. C. M.; RAMOS, P. S. Fenologia reprodutiva e caracterização físico-química de abacateiros em Carmo da Cachoeira, Minas Gerais. *Rev. Ceres*, v. 61, n.1, p. 105-111, 2014.
- SOUZA, C. G.; Carvalho, L. M. T.; Aguiar, P.; Arantes, T. B.; Pereira, A. M.; Cardoso, Q.; Corrêa, I. A. Evaluating Land Cover Maps Derived from Synthetic Landsat Images. In: *ForestSAT2014 Conference*. Proceedings of the ForestSAT2014, 2014.
- VIEIRA, T. G. C.; ALVES, H. M. R.; LACERDA, M. P. C.; VEIGA, R. D.; EPIPHANIO, J. C. N. Crop Parameters for the evaluation of the Spectral Response of Coffee (*Coffea Arabica* L.) areas within the State of Minas Gerais, Brazil. *Coffee Science*, v. 1, p. 111-118, 2006.
- WILKINSON, G. Results and implications of a study of fifteen years of satellite image classification experiments. *IEEE Trans. Geosci. Remote Sensing*, v. 43, n. 3, p. 433–440. 2005.