



ISSN: 2525-815X

# Journal of Environmental Analysis and Progress

Journal homepage: [www.jeap.ufrpe.br/](http://www.jeap.ufrpe.br/)

10.24221/jeap.3.4.2018.2016.379-385



## Mapeamento multicategórico do uso/cobertura da terra em escalas detalhadas usando *Semi-automatic Classification Plugin*

## Multicategorical mapping of land use/cover in detailed scales using *Semi-automatic Classification Plugin*

Luís Flávio Pereira<sup>a</sup>, Ricardo Morato Fiúza Guimarães<sup>b</sup>

<sup>a</sup> Universidade Federal de Viçosa-UFV, Avenida Peter Henry Rolfs, s/n, Viçosa-MG, Brasil. CEP: 36570-900. E-mail: [luis.flavio@ufv.br](mailto:luis.flavio@ufv.br).

<sup>b</sup> Universidade Federal de Ouro Preto-UFOP, Rua Professor Paulo Magalhães Gomes, Ouro Preto-MG, Brasil. CEP: 35400-000. E-mail: [rickmorato369@gmail.com](mailto:rickmorato369@gmail.com).

### ARTICLE INFO

Recebido 22 Jun 2018

Aceito 11 Set 2018

Publicado 24 Set 2018

### ABSTRACT

Land use maps are essential in the analysis of the agrarian, environmental, and social dynamics of a region, but costly resources have constrained their attainment. Therefore, the use of simple and free tools, such as the Semi-automatic Classification Plugin (SCP) for QGIS, has been increased. However, studies on the performance of SCP are still scarce. In this sense, the study aimed to evaluate the performance of SCP to map land uses with high categorical and spatial specificity. The study area consisted of the Melo stream basin (90 km<sup>2</sup>), where 15 land use classes were mapped from the classification of data derived from a Sentinel 2A image, with the three classifiers available in the SCP. The results showed that SCP is suitable for land use mapping with any of the classifiers, but the Maximum Likelihood algorithm presented the best performance, with almost perfect accuracy (Kappa = 0.93). Further studies are suggested to provide concrete guidelines for the use of SCP, improving its efficiency.

**Keywords:** QGIS, Sentinel 2A, remote sensing.

### RESUMO

Mapas de uso da terra são essenciais na análise das dinâmicas agrária, ambiental e social de uma região, mas sua obtenção tem sido limitada por recursos dispendiosos. Por isso, o uso de ferramentas simples e gratuitas, como o *Semi-automatic Classification Plugin* (SCP), para QGIS, tem aumentado. Entretanto, estudos sobre o desempenho do SCP ainda são escassos. Nesse sentido, o estudo objetivou avaliar o desempenho do SCP para mapear usos da terra com alta especificidade categórica e espacial. A área de estudos consistiu na bacia do ribeirão do Melo (90 km<sup>2</sup>), onde foram mapeadas 15 classes de uso da terra, a partir da classificação de dados derivados de uma imagem Sentinel 2A, com os três classificadores disponíveis no SCP. Os resultados mostraram que o SCP é adequado para mapear usos da terra com qualquer um dos classificadores, mas o algoritmo Maximum Likelihood apresentou o melhor desempenho, com acurácia quase perfeita (Kappa = 0,93). Recomenda-se mais estudos que forneçam diretrizes concretas para a utilização do SCP, melhorando sua eficiência.

**Palavras-Chave:** QGIS, Sentinel 2A, sensoriamento remoto.

### Introdução

A conversão de ecossistemas naturais à antrópicos gera impactos ambientais diversos, como distúrbios hidrológicos e climáticos, degradação do solo, e ocorrência de doenças. A severidade desses impactos depende do grau, da

natureza e do histórico do uso da terra (Foley et al., 2005; Eidt et al., 2016; Pereira, Guimarães & Oliveira, 2018).

Devido à essa importância, a avaliação do uso da terra é essencial na análise das dinâmicas agrária, ambiental e social de uma região. Contudo,

mapas com alto detalhamento categórico e espacial podem ser necessários para esse fim (Jensen, 2009; IBGE, 2013). Para mapeamentos desse tipo, frequentemente são demandados recursos dispendiosos e/ou métodos complexos, o que tem elevado a procura por geotecnologias simples e gratuitas (Guimarães, Pimenta & Landau, 2012; Pereira, Guimarães & Oliveira, 2018).

Dentre as geotecnologias em ascensão, encontram-se o QGIS e o *Semi-automatic Classification Plugin* (SCP). O QGIS é um sistema de informações geográficas livre e de código aberto, possui interface amigável e permite grande diversidade de análises geoespaciais, à medida que novos complementos e a integração com outros softwares têm sido implementados (Guimarães, Pimenta & Landau, 2012; Nanni et al., 2017). O SCP, desenvolvido por Luca Congedo, em 2013, é um dos mais importantes complementos do QGIS, pois possibilita a classificação supervisionada de imagens, e é considerado completo, por permitir desde o *download* de dados até à avaliação estatística e correção dos mapas produzidos (Congedo, 2016). Sua utilização tem mostrado bons resultados, mas estudos de caso, especialmente para mapeamentos com alta especificidade categórica, ainda são escassos na literatura (Congedo, 2016; Leroux et al., 2018).

Tendo em vista tais aspectos, este estudo objetivou avaliar o desempenho do SCP para mapear usos/coberturas da terra com alta especificidade categórica em escala detalhada.

## Material e Métodos

### Área de estudo

A área de estudo foi a bacia do ribeirão do Melo (90 km<sup>2</sup>), um importante afluente do rio Piranga, principal formador do rio Doce. A bacia está compreendida dentro dos municípios Rio Espera e Capela Nova, Minas Gerais, e apresenta fisiografia típica dos planaltos altos dissecados (680 – 900 m) da faixa móvel atlântica: solos e regolito profundos, formados do intemperismo de rochas granítico-gnáissicas, o que junto com altas precipitações anuais (1900 mm) e oscilações bioclimáticas, levou à formação de um “mar de morros” florestado (semidescidual estacional) (Schaefer, 2013; Leite et al., 2007). Portanto, a região apresenta grande diversidade de geofomas e geoambientes distribuídos de forma intrincada e irregular. A área foi escolhida por apresentar grande diversidade de usos da terra, além da facilidade de acesso e da disponibilidade de estudos prévios, para comparação de resultados (Leite et al., 2007; Pereira, Guimarães & Oliveira, 2018). A bacia foi delimitada no QGIS, de acordo com os procedimentos adotados por Bruno (2017).




Figura 1. Localização da bacia do ribeirão do Melo, e imagem Sentinel 2A utilizada.

### Mapeamento e validação estatística

Neste estudo foram utilizadas as bandas 2 a 8, 8A, 11 e 12 de uma imagem Sentinel 2A (ID: S2A\_OPER\_MSI\_L1C\_TL\_SGS\_\_20160424T130942\_20160424T181611\_A004382\_T23KPS\_N02\_01\_01; data de aquisição pelo sensor: 24/04/2016). A imagem foi obtida junto ao *United States Geological Survey*, com correções geométrica e radiométrica, bem como ortorretificação e registro espacial (nível 1C), mediante cadastro e solicitação no endereço <https://earthexplorer.usgs.gov>.

As bandas foram importadas para o SCP, e a correção atmosférica foi realizada pelo método do DOS1, conforme Leroux et al. (2018). Em seguida, foram gerados índices de vegetação (NDVI, EVI, VDVI), umidade (Gao, 1996) e água (McFeeters, 1996), e obtido um mosaico de empilhamento de bandas, que agregou 15 planos de informação. O conjunto de dados foi classificado

por cada um dos três classificadores disponíveis no SCP: *Maximum Likelihood* (ML), *Minimum Distance* (MD), e *Spectral Angle Mapper* (SAM). Foram delimitadas 15 classes: Milho (lavouras maduras), Cana (lavouras maduras), Talhões Agrícolas Indiferenciados, Café, Eucalipto, Brejos, Pastagem Sem Degradação, Pastagem Moderadamente Degradada, Pastagem Severamente Degradada, Mata, Regeneração Natural (capoeiras), Rochedos e Cidades, Água, Nuvem e Sombra. Todas as classificações foram realizadas utilizando as configurações padrão do SCP.

Para a classificação, um grande número de pequenas amostras de treinamento foi coletado em polígonos shapefile, por vetorização em tela via interpretação da composição RGB cor natural da imagem Sentinel, bem como de modelos tridimensionais e séries temporais de imagens do Google Earth, segundo o método de Pereira, Guimarães & Oliveira (2018). Em seguida, as amostras foram importadas para o SCP e dissolvidas em única macro amostra, utilizada para as três classificações. Essa estratégia foi adotada para diminuir o tempo de processamento gasto durante a classificação. Números diferentes de pixels foram amostrados para cada classe mapeada, mas sempre em número maior que 480, pois Faria (2015) mostrou que, acima de 80 pixels, a amostra de treinamento não exerce influência sobre o desempenho de diversos classificadores supervisionados. As amostras foram coletadas dentro e ao redor da área de estudo, conforme a disponibilidade.

As amostras de validação foram coletadas da mesma forma que as de treinamento, também em número desbalanceado, conforme o critério de frequência relativa explicitado por Pereira, Guimarães & Oliveira (2018). Para não enviesar a validação, as amostras foram coletadas antes de se realizar a classificação, e a frequência de cada classe na área foi estimada de acordo com os resultados de Pereira, Guimarães & Oliveira (2018), Faria (2015) e Leite et al. (2007), obtidos para a região em diferentes períodos e em escala detalhada.

Os polígonos de validação foram fornecidos ao SCP para a obtenção das matrizes de confusão entre os dados classificados e os dados de referência, e cálculo do coeficiente Kappa, conforme Congalton & Green (2008). O Kappa mede a acurácia de mapeamento, e seu valor

máximo é 1, quando a classificação apresenta concordância total entre dados classificados e uma amostra referência. Quando a concordância é igual ou menor à esperada pelo acaso, os valores de Kappa equivalem estatisticamente a zero. Congalton & Green (2008) também apresentam testes Z para avaliar a significância de cada Kappa e se há diferença estatística entre cada um deles. Os testes Z foram realizados em planilha eletrônica, utilizando-se os dados gerados pelo SCP.

## Resultados

A Figura 2 apresenta os mapas gerados pela classificação da imagem Sentinel 2<sup>a</sup>, por cada um dos classificadores disponíveis no SCP, e os respectivos Kappas obtidos. Os mapas obtidos possuem resolução de 10 m, o que equivale a escalas detalhadas (> 1:25.000), segundo IBGE (2013). Os desempenhos de todos os três classificadores diferiram significativamente ( $p \leq 0,05$ ). O ML apresentou o melhor desempenho de classificação com Kappa, que sugere acurácia quase perfeita, segundo Landis & Koch (1977) (Figura 1C). O MD apresentou maior acurácia que o SAM, mas ambos os valores de Kappa foram enquadrados na faixa considerada adequada (concordância substancial) por Landis & Koch (1977). Para melhorar o aspecto visual do mapa de melhor acurácia, foi utilizado o filtro *Majority* com raio de atuação de 3 pixels, eliminando pixels isolados, que davam aspecto fragmentado ao mapa. A filtragem melhorou o aspecto visual sem interferir significativamente na acurácia do mapeamento ( $p > 0,05$ ) e, por isso, o mapa obtido (Figura 2D) foi adotado como o mapa final do presente estudo.

Quanto às classes mapeadas, é possível verificar na Tabela 1 e na Figura 2 que SAM e MD superestimaram as áreas de cana e brejos, e subestimaram as áreas de matas, pastagens moderadamente degradadas e pastagens sem degradação, em relação ao ML. SAM e MD apresentaram estimativas muito parecidas, sendo as únicas diferenças substanciais observadas nas classes cana (superestimativa do SAM em relação ao MD) e café, em que houve superestimativa do MD em relação aos demais classificadores. Para o mapa de melhor acurácia, os usos mais abundantes foram matas, pastagens moderadamente degradadas e regenerações naturais, e os menos abundantes foram água, milho e cidades/rochedos, respectivamente.

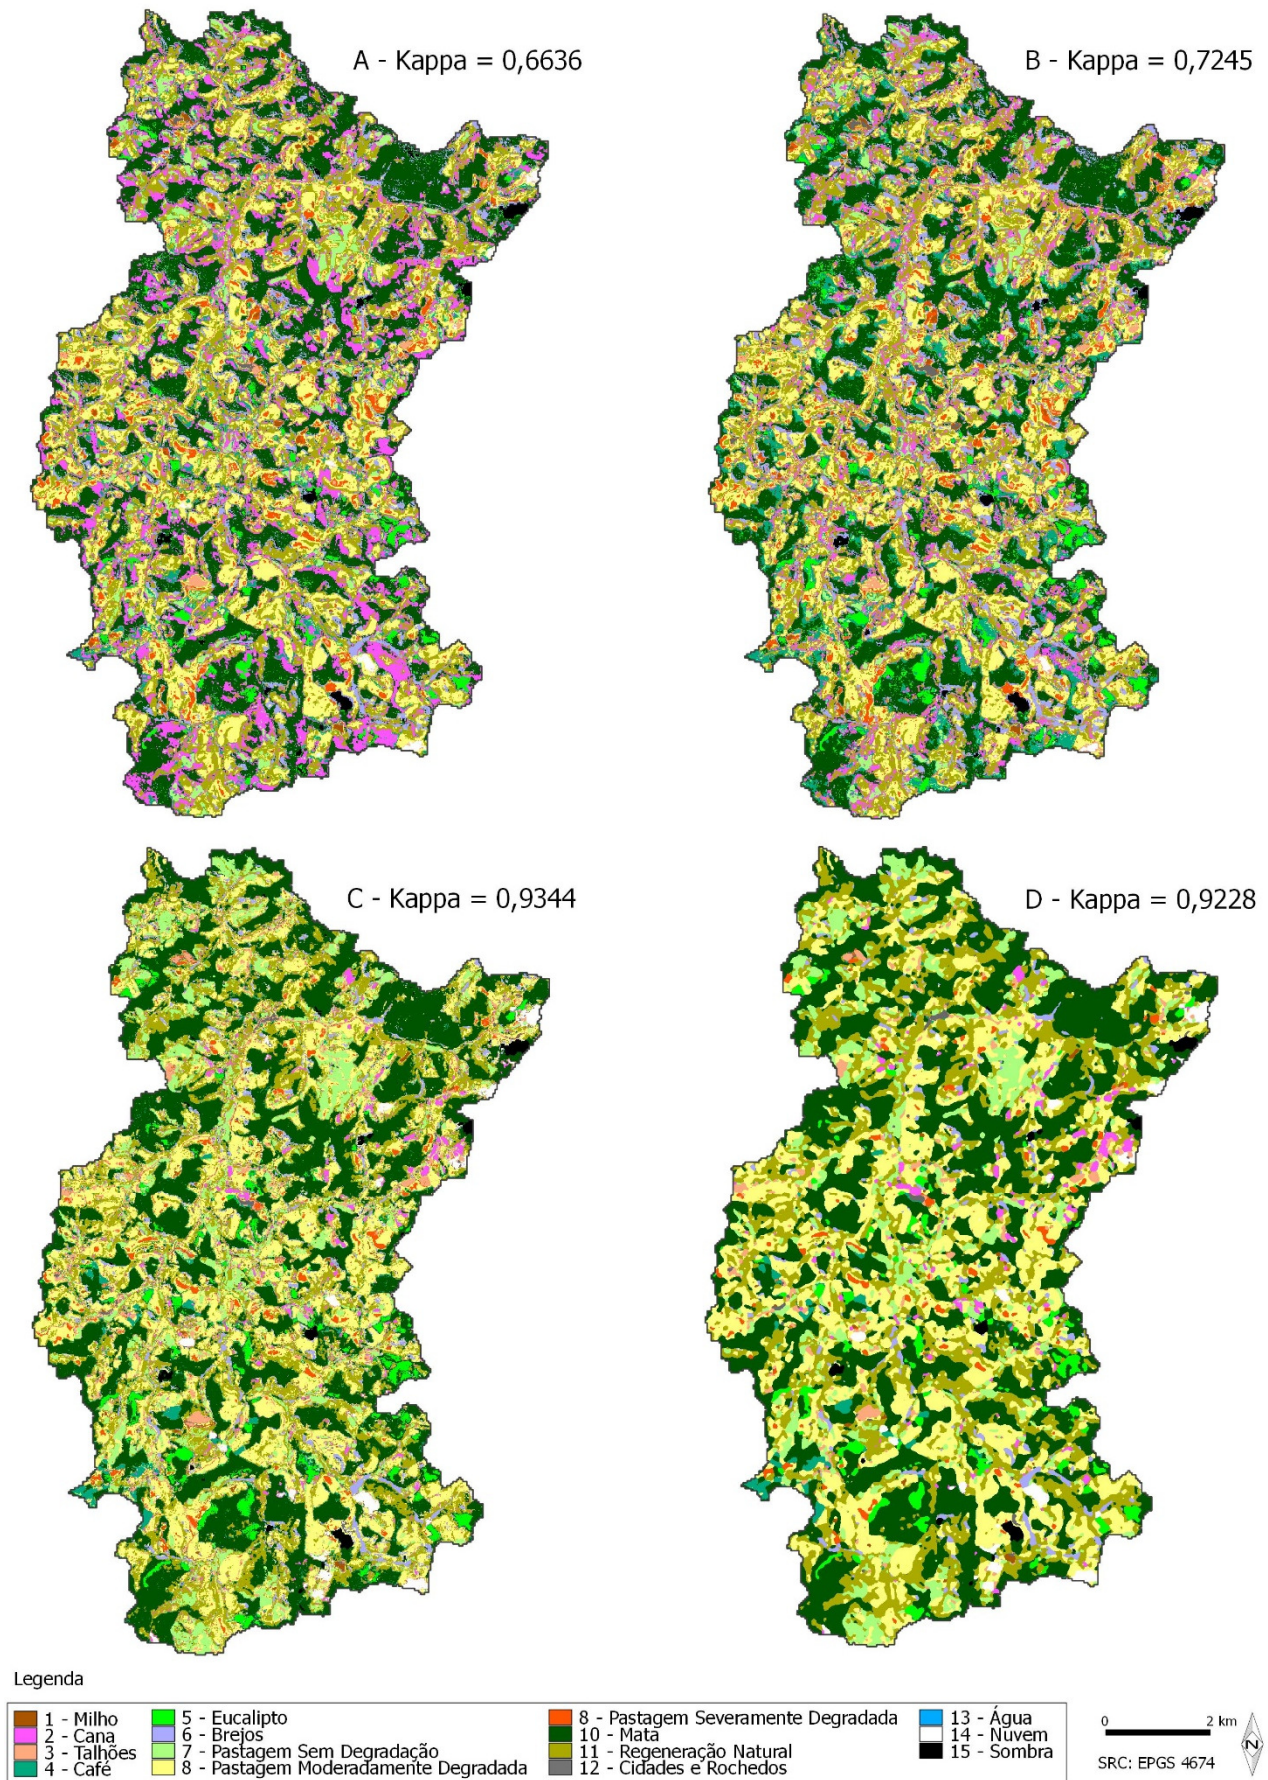


Figura 2. Mapas de uso da terra gerados por cada classificador. (A) *Spectral Angle Mapper* (B) *Minimum Distance* (C) *Maximum Likelihood* e (D) *Maximum Likelihood* após aplicação do filtro *Majority*.

Tabela 1. Estimativa da frequência (%) de cada classe mapeada na área de estudo, de acordo com cada classificador, bem como diferenças de estimativas entre classificadores.

Classe	SAM	MD	ML	SAM – ML	MD - ML	SAM - MD
1 - Milho	0,42	0,38	0,46	-0,04	-0,08	0,04
2 - Cana	14,86	9,72	2,7	12,16	7,02	5,14
3 - Talhões	0,80	0,84	2,59	-1,79	-1,75	-0,04
4 - Café	3,28	6,98	2,27	1,01	4,71	-3,70
5 - Eucalipto	1,85	2,33	2,16	-0,31	0,17	-0,48
6 - Brejos	6,27	6,46	3,09	3,18	3,37	-0,19
7 – Pastagens Sem Degradação	3,61	3,22	8,01	-4,40	-4,79	0,39
8 – Pastagens Moderadamente Degradadas	17,46	17,87	22,74	-5,28	-4,87	-0,41
9 – Pastagens Severamente Degradadas	2,91	3,15	1,61	1,30	1,54	-0,24
10 – Mata	25,53	25,65	30,91	-5,38	-5,26	-0,12
11 – Regeneração Natural	21,96	22,53	21,27	0,69	1,26	-0,57
12 – Cidades e Rochedos	0,10	0,25	0,86	-0,76	-0,61	-0,15
13* – Água	0,00	0,00	0,00	0,00	0,00	0,00
14 – Nuvem	0,27	0,14	0,83	-0,56	-0,69	0,13
15 – Sombra	0,68	0,48	0,5	0,18	-0,02	0,20
Soma	100,00	100,00	100,00	0,00	0,00	0,00

\*participação muito pequena, área média de 0,14 ha.

## Discussão

Os resultados sugerem que o SCP é adequado para mapear usos da terra com alta especificidade categórica e em escalas detalhadas, pois todos os classificadores apresentam desempenho satisfatório, com coeficientes Kappa dentro da faixa considerada adequada por Landis & Koch (1977). O algoritmo com melhor desempenho para mapear usos da terra na região de estudo foi o ML, com valores de Kappa que indicam concordância quase perfeita entre os dados classificados e os de referência (Figura 2). Os resultados estão em conformidade com a literatura, pois diversos autores apontam que o ML apresenta melhor acurácia do que o SAM e o MD (Castillejo-González et al., 2009; Sameen et al., 2016). Entretanto, os resultados contradizem o argumento de Leroux et al. (2018), que adotaram o SAM para mapear usos da terra em região com relevo movimentado e grande diversidade de geoformas, porque seu desempenho seria melhor para esse tipo de terreno. A filtragem dos mapas é recomendável, pois possibilitou grande melhora no aspecto visual do mapa, sem alterar a acurácia do mapeamento.

Dessa forma, o ML parece ser o melhor classificador para mapeamentos de uso da terra, mas estudos futuros que avaliem o desempenho dos classificadores em condições diversas são recomendáveis. Recomenda-se, especialmente, considerar maior diversidade de dados utilizados para a classificação, níveis categóricos, substratos litopedogeomorfológicos, tipos de filtragem dos mapas e formas de amostragem de treinamento. Esses estudos comparativos poderiam fornecer subsídio à tomada de decisão no mapeamento,

funcionando como diretrizes para melhorar a eficiência do SCP.

Quanto à ocorrência e distribuição geoespacial dos usos da terra, o mapa final (Figura 2D) foi comparado com os estudos de Leite et al. (2007), Faria (2015) e Pereira, Guimarães & Oliveira (2018). A comparação mostrou que os usos da terra na região apresentam estabilidade no tempo, pois a percentagem de áreas ocupadas pelos usos da terra foi bastante similar entre os estudos, para todas as classes comparáveis. A avaliação do mapa final sobre modelos tridimensionais do Google Earth Pro, conforme Pereira, Guimarães & Oliveira (2018), revelou que, para toda a bacia, são observados os mesmos padrões de distribuição espacial dos usos da terra previamente descritos por esses autores, em um dos afluentes do ribeirão do Melo. Os padrões de ocupação da terra são advindos da regulação por interações pedogeomorfológicas (Pereira, Guimarães & Oliveira, 2018), o que sugere que tal padronização se repita em maior ou menor grau por toda a faixa móvel atlântica brasileira, onde dominarem os planaltos soerguidos, florestados, dissecados e de solos pobres (Schaefer, 2013). Esse tipo de padronização dá indícios de que a utilização de variáveis de terreno, como elevação, declividade, e distância dos cursos d'água, poderia melhorar ainda mais o desempenho dos classificadores, o que reforça a recomendação de que sejam feitos mais estudos sobre o tema.

## Conclusão

O *Semi-automatic Classification Plugin* apresenta desempenho adequado para mapear usos

da terra, mesmo em escala detalhada e com alta especificidade categórica

O algoritmo *Maximum Likelihood* apresentou o melhor desempenho na classificação, alcançando acurácia quase perfeita ( $Kappa = 0,93$ ).

Em estudos futuros recomenda-se a avaliação do desempenho do SCP, utilizando diferentes bases de dados, níveis categóricos, formas de amostragem e filtrações das classificações obtidas, além do estudo em áreas fisiograficamente distintas.

### Referências

BRUNO, L. O. 2017. GRASS: A free and open source solution for hydrographic body analysis. *Nativa*, v. 5, n. 1, p. 24-30.

CASTILLEJO-GONZÁLEZ, I. L.; LÓPEZ-GRANADOS, F.; GARCÍA-FERRER, A.; PEÑA-BARRAGÁN, J. M.; JURADO-EXPÓSITO, M.; DE LA ORDEN, M. S.; GONZÁLEZ-AUDICANA, M. 2009. Object-and pixel-based analysis for mapping crops and their agro-environmental associated measures using QuickBird imagery. *Computers and Electronics in Agriculture*, v. 68, n. 2, p. 207-215.

CONGALTON, R. G.; GREEN, K. 2008. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. 2.ed. New York: CRC Press. 183p.

CONGEDO, L. Semi-Automatic Classification Plugin Documentation. Release 5.0.0.1. 3 set. 2016. Disponível em: [https://www.researchgate.net/publication/265031337\\_SemiAutomatic\\_Classification\\_Plugin\\_User\\_Manual](https://www.researchgate.net/publication/265031337_SemiAutomatic_Classification_Plugin_User_Manual). Acesso em: 17 abr. 2017.

EIDT, J. I.; ANDRIETTI, G.; DE FIGUEIREDO, L. F.; DEMARQUI, E.; DE ANDRADE, R. L. T.; DO AMARAL, A. G.; SCHNEIDER, R. M.; DE ALMEIDA, F. T. 2016. Monitoring metals in surface water of a small watershed in amazon region. *Nativa*, v. 4, n. 4, p. 187-194.

FARIA, M. M. 2015. Distribuição espacial do café na região das matas de Minas. Tese (Doutorado em Solos e Nutrição de Plantas), Universidade Federal de Viçosa, Viçosa, MG, Brasil. 89p.

FOLEY, J. A.; DEFRIES, R.; ASNER, G.P.; BARFORD, C.; BONAN, G.; CARPENTER, S.T.; CHAPIN, F. S.; COE, M. T.; DAILY, G. C.; GIBBS, H. K.; HELKOWSKI, J. H.; HOLLOWAY, T.; HOWARD, E. A.; KUCHARIK, C. J.; MONFREDA, C.; PATZ, J.

A.; PRENTICE, I. CO.; RAMAKUTTY, N.; SNYDER, P. K. 2005. Global consequences of land use. *Science*, v. 309, n. 5734, p. 570-574.

GAO, B. C. ANO. NDWI – A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, v. 58, n. 3, p. 257-266.

GUIMARÃES, D. P.; PIMENTA, F. M.; LANDAU, E. C. 2012. Integração Google Earth-SIG-Servidor de Mapas e o Monitoramento Ambiental. *Circular Técnica. Embrapa Milho e Sorgo, Sete Lagoas*, n. 183, p. 1-20.

IBGE. 2013. *Manual Técnico de Uso da Terra*. IBGE, Terceira Edição, Rio de Janeiro. 278p.

JENSEN, J. R. 2009. *Remote sensing of the environment: An earth resource perspective*. Pearson Education India, Second Edition. 204p.

LANDIS, J. R.; KOCH, G. G. 1977. The measurement of observer agreement for categorical data. *Biometrics*, pp. 159-174.

LEITE, M. G. P.; FUJACO, M. A. G.; BARCELOS, E. A. S.; GONÇALVES, G. H. T.; IGREJA, F. F. 2007. Environmental analysis of small rural catchments case study: Melo Creek-MG/Brazil. *Management of Environmental Quality: An International Journal*, v. 18, n. 6, p. 711-722.

LEROUX, L.; CONGEDO, L.; BELLÓN, B.; GAETANO, R.; BÉGUÉ, A. 2018. Land Cover Mapping Using Sentinel-2 Images and the Semi-Automatic Classification Plugin: A Northern Burkina Faso Case Study. In: BAGHDADI, N.; MALLET, C.; ZRIBI, M. *QGIS and Applications in Agriculture and Forest*, v. 2, p. 119-151.

MCFEETERS, S. K. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, v. 17, n. 7, p. 1425-1432.

PEREIRA, L. F.; GUIMARÃES, R. M. F.; OLIVEIRA, R. R. O. 2018. Integrando geotecnologias simples e gratuitas para avaliar usos/coberturas da terra: QGIS e Google Earth Pro. *Journal of Environmental Analysis and Progress*, v. 3, n. 3, p. 250-264.

NANNI, A.; BARROS, S. D.; DESCOVI FILHO, L.; SOUZA, M. S.; PEREIRA FILHO, N. S.;

GOVEIA, S. S. 2017. QGIS User Guide, Versão 2.18. 473 p. Disponível em: [https://docs.qgis.org/2.18/pdf/pt\\_BR/QGIS-2.18-UserGuide-pt\\_BR.pdf](https://docs.qgis.org/2.18/pdf/pt_BR/QGIS-2.18-UserGuide-pt_BR.pdf). Acesso em: 15 dez. 2017.

SAMEEN, M. I.; NAHHAS, F. H.; BURAIHI, F. H.; PRADHAN, B.; SHARIFF, A. R. B. M. 2016. A refined classification approach by integrating Landsat Operational Land Imager (OLI) and

RADARSAT-2 imagery for land-use and land-cover mapping in a tropical area. *International Journal of Remote Sensing*, v. 37, n. 10, p. 2358-2375.

SCHAEFER, C. E. G. R. 2013. Bases físicas da paisagem brasileira: estrutura geológica, relevo e solos. *Tópicos em ciência do solo*. Sociedade Brasileira de Ciência do Solo, v. 8, n. 1, p. 1-69.