



**Mapeamento de Áreas Agrícolas com Máquina de
Vetor de Suporte no Noroeste de Minas Gerais, Brasil**
Mapping of Agricultural Areas with Support
Vector Machine in the Northwest of Minas Gerais, Brazil

Danila Mendes Durães¹; Carlos Magno Moreira de Oliveira¹;
Rafael Coll Delgado²; Vitor Marques Vidal³ & Inácio Barbosa Borges¹

¹ Instituto Federal do Norte de Minas Gerais –
Campus Arinos. Rodovia MG 202, Km 407, s/n Zona Rural, 38680-000, Arinos – MG - Brasil

² Universidade Federal Rural do Rio de Janeiro, Instituto de Florestas,
Departamento de Ciências Ambientais. BR 465, km 7, 23890-000, Seropédica – RJ – Brasil

³ Instituto Federal Goiano – Campus Rio Verde. Rua Sul Goiãna, Km 01, Zona Rural, 75901-970, Rio Verde – Go – Brasil

E-mails: ddanilamendes@gmail.com; carlos.moreira@ifnmg.edu.br;
rafaelcolldelgado32@gmail.com; vmarquesvidal@gmail.com; inacio.borges@ifnmg.edu.br

Recebido em: 18/08/2019 Aprovado em: 12/11/2019

DOI: http://dx.doi.org/10.11137/2020_1_33_41

Resumo

A agricultura é um dos setores que mais se destaca na economia do Brasil, sendo necessário muitas vezes o emprego do sensoriamento remoto, para identificação da expansão das áreas agrícolas e estimativas da sua produção. Esse trabalho tem por objetivo mapear as áreas agrícolas do noroeste de Minas Gerais por meio de máquina de vetor de suporte e comparar os resultados obtidos com o censo estatístico do Instituto Brasileiro de Geografia e Estatística. Para identificação das áreas agrícolas foi utilizado o algoritmo *Service Vector Machine* e imagens dos satélites e sensores Landsat 8 / OLI e Terra / MODIS. As amostras de treinamento do algoritmo foram obtidas por meio de imagem de alta resolução espacial, disponível no programa *Google Earth Pro*, nas classes rios, floresta, agricultura, pastagem e silvicultura. O mapeamento utilizando imagem do sensor OLI apresentou melhor Acurácia Global (0,81) e Kappa (0,66). A classificação com imagem OLI e MODIS apresentaram maior precisão na classe agricultura quando comparada as demais classes, apresentando confusão com pastagem, em decorrência da alta fitomassa da pastagem na época de aquisição das imagens (verão). O cálculo das áreas agrícolas demonstra superestimativa do *Service Vector Machine (SVM)* na classificação das imagens OLI e MODIS, com forte relação dos dados MODIS com o censo do IBGE ($R^2=0,83$). Apenas municípios com áreas agrícolas superiores a 50.000 ha apresentaram menor erro na estimativa das áreas agrícolas. A aplicação do algoritmo mostra-se potencial para mapeamento da agricultura por meio de imagens dos sensores MODIS e OLI, porém deve-se avaliar a época de aquisição das imagens orbitais e variações nos parâmetros do algoritmo para melhorar a acurácia da classificação.

Palavras-chave: agricultura; classificação supervisionada; aprendizado de máquina

Abstract

Agriculture is one of the sectors that stands out most in the Brazilian economy, often requiring the use of remote sensing to identify the expansion of agricultural areas and estimates of their production. This work aims to map the agricultural areas of the northwest of Minas Gerais by means of a support vector machine and compare the results obtained with the statistical census of the Brazilian Institute of Geography and Statistics. For the identification of the agricultural areas, the Service Vector Machine algorithm and images of the Landsat 8 / OLI and Terra / MODIS satellites and sensors were used. The training samples of the algorithm were obtained by high resolution spatial image, available in Google Earth Pro software, in the categories rivers, forest, agriculture, pasture and forestry. The OLI image mapping showed better Global Accuracy (0.81) and Kappa (0.66). The classification with OLI and MODIS images showed greater precision in the agriculture class when compared to the other classes, presenting confusion with pasture, due to the high phytomass of the pasture at the time of acquisition of the images (summer). The calculation of the agricultural areas shows an overestimation of the Service Vector Machine in the classification of the OLI and MODIS images, with a strong ratio of the MODIS data to the IBGE census ($R^2=0.83$). Only municipalities with agricultural areas greater than 50,000 ha presented less error in the estimation of agricultural areas. The application of the algorithm shows the potential for mapping agriculture through images of the MODIS and OLI sensors, but it is necessary to evaluate the time of acquisition of the orbital images and variations in the parameters of the algorithm to improve the accuracy of the classification.

Keywords: agriculture; supervised classification; machine learning

1 Introdução

A agricultura é o setor que mais se destaca na economia brasileira, com forte potencial na exportação de grãos, cereais e frutas, o que tem aumentando a participação desse setor no Produto Interno Bruto (PIB) do país. Devido à grande contribuição da agricultura na balança comercial, torna-se necessário o desenvolvimento de ferramentas de baixo custo e eficientes, que viabilizem o monitoramento continuado da expansão de áreas agrícolas (Adami *et al.*, 2007).

A estimativa de áreas agrícolas torna-se uma informação potencial para a criação de políticas econômicas, visto a influência desse setor no que tange as importações e exportações, manutenção de estoques, uso de insumos agrícolas, distribuição de crédito, além de avaliar os possíveis impactos da expansão da agricultura sobre ambientes naturais e áreas urbanas (Epiphanyo *et al.*, 2002). Esse processo pode ser realizado de forma indireta, como realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), por meio de informações relativas a quantidade de insumos consumidos, investimento agrícola, variabilidade sobre as condições meteorológicas, tendência de mercado e histórico da região (Adami *et al.*, 2007; Luiz *et al.*, 2012). Porém, com o avanço de ferramentas de informática e a disponibilização de imagens de satélite gratuitas, esse processo torna-se menos oneroso e mais preciso (Adami *et al.*, 2007; Delgado *et al.*, 2012; Vaeza *et al.*, 2012; Shiratsuchi *et al.*, 2014).

A dinâmica de áreas agrícolas pode ser realizada por meio de classificação supervisionada, a qual o usuário define as amostras espectrais dos alvos, e não supervisionada, em que o algoritmo define as classes de agrupamentos das respostas espectrais (Oliveira *et al.*, 2014; Gonçalves, 2009). Nos últimos anos, sofisticados algoritmos tem sido desenvolvidos como redes neurais, árvore de decisão, máquina de vetor de suporte e algoritmos baseados em objetos, bem como o uso de dados provenientes de diferentes sensores com variadas resoluções espaciais, espectrais, radiométricas e temporais, afim de melhorar o mapeamento por meio do comportamento espectral dos alvos (Lu *et al.*, 2012; Delgado *et al.*, 2012; Garofalo *et al.*, 2015; Souza *et al.*, 2016).

Diante do exposto, esse trabalho tem por objetivo mapear as áreas agrícolas do noroeste de Mi-

nas Gerais, por meio de técnicas de Sensoriamento Remoto e validar os resultados do mapeamento com o censo estatístico do Instituto Brasileiro de Geografia e Estatística (IBGE).

2 Material e Métodos

O noroeste do estado de Minas Gerais é formado por dezenove municípios (Figura 1). A região tem como clima predominante semi-úmido, com período de seca longo e período chuvoso de 4 a 5 meses no ano, sua vegetação típica é o Cerrado (Alvares *et al.*, 2013). Segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE), em 2010, esta região apresentou população de 366.418 habitantes, desse total 286.618 (78,22%) vivem em zona urbana e 79.800 (21,78%) vivem em zona rural, apresentando a quarta maior proporção de população rural das mesorregiões do estado de Minas Gerais (IBGE, 2019).

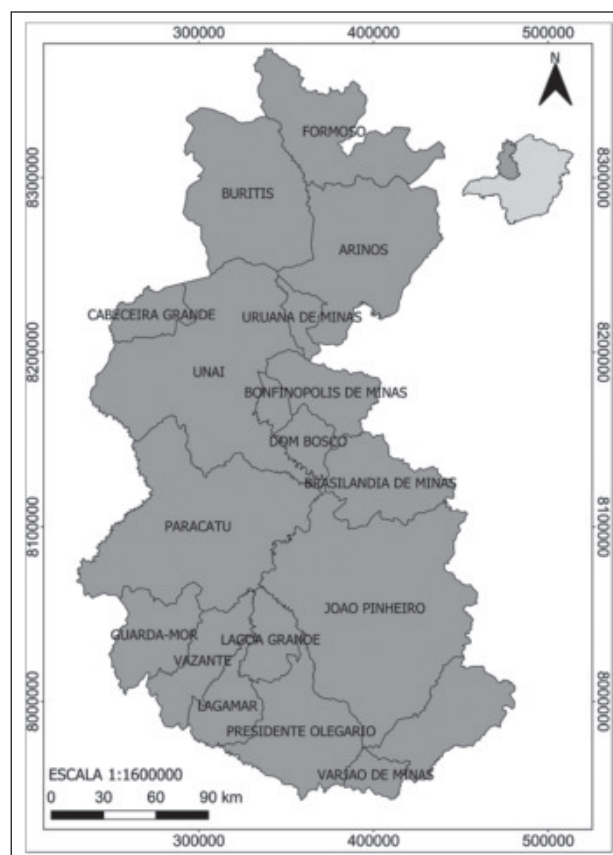


Figura 1 Municípios que compõe a região noroeste do estado de Minas Gerais.

Para realizar mapeamento de áreas agrícolas foram utilizadas imagens provenientes do satélite Landsat 8 e sensor *Operational Land Imager* (OLI) e do satélite Terra e sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS). As imagens do sensor OLI foram adquiridas nos pontos e orbitas 219/072 (19/06/2015), 219/073 (05/07/2015), 220/070 (28/07/2015), 220/071 (25/05/2015), 220/072 (25/05/2015) e 220/073 (12/07/2015) de forma a recobrir o noroeste do estado de Minas Gerais. Esses produtos foram obtidos do repositório de imagens *Earth Explorer*, gerenciado pelo *United States Geological Survey* (USGS), no nível de processamento 2, ou seja, com correção geométrica e com correção dos efeitos atmosféricos (USGS, 2018). Foram utilizadas as bandas *Green* (banda 3), *Red* (banda 4) e *Near infrared* (NIR) (banda 5) para composição 5R4G3B e o mosaico das seis composições de bandas.

Também foi obtido o produto MOD09A1, versão 006, proveniente do sensor MODIS, referente ao dia 25/05/2015. Esse produto tem periodicidade de 16 dias e resolução espacial de 500 m, disponível na extensão .HDF. O MOD09A1 disponibiliza imagens de reflectância que compreendem as bandas 1 a 7 e resolução radiométrica de 16 bits. Para o mapeamento foram utilizadas as bandas *Red* (banda 1), *Near infrared* (NIR) (banda 2) e *Green* (banda 4), com comprimentos de onda 620-670 nm, 841-876 nm, 545-565 nm, respectivamente. As imagens do sensor MODIS foram, inicialmente, processadas no software *Modis Reproject Tools* (MRT), versão 4.1, afim de converter as imagens da projeção Sinusoidal para o Datum *World Geodetic System 1984* (WGS84) e projeção *Universal Transversa de Mercator* (UTM). Posteriormente, as imagens foram sobrepostas, formando composição de imagem R (banda 2) G (banda 1) B (banda 4).

Para a classificação supervisionada foram necessários pontos georreferenciados para construir a biblioteca espectral das classes rios, pastagem, agricultura, floresta e eucalipto. Os pontos georreferenciados foram adquiridos por meio de imagens de alta resolução espacial disponíveis no software *Google Earth Pro*, referente ao ano de 2015. Para as classes agricultura, eucalipto, floresta, pastagem

e rios foram coletados aleatoriamente 138, 20, 20, 20 e 20, respectivamente, observando apenas o limite na região noroeste do estado de Minas Gerais. Cada ponto amostral abrangeu área de raio de 30 m, correspondendo a aproximadamente 3 pixels por amostra na imagem Landsat, ou seja, cada amostra de treinamento representa a média da reflectância de 3 pixels, e para imagem MODIS cada unidade amostral correspondeu ao valor de um pixel. Posteriormente os pontos foram exportados para a extensão .KML, inseridos em ambiente Sistema de Informação Geográfico (SIG), agrupados e exportados para formato *shapefile* (Figura 1).

De posse dos mosaicos de imagens e dos pontos referentes as classes de uso e cobertura do solo, a identificação das classes foi realizada no software R versão (R 3.5.1) utilizando o algoritmo não paramétrico *Service Vector Machine* (SVM), por meio dos pacotes *e1071*, *rgdal*, *raster*, *caret*, *Rcpp* e *SDMTools* presente no repositório do software. Esse algoritmo necessita que o usuário defina o *kernel* utilizado no processo de treinamento do algoritmo e na previsão dos dados, valor de *cost* que ajusta a margem de decisão dos vetores de suporte e *gamma* que define a largura da função de kernel, sendo ajustado os seguintes parâmetros linear, 10 e 0,3333 (*default*), respectivamente. Esses valores foram obtidos a partir de avaliações realizados por meio de sucessivas interações de parâmetros e escolhidos por meio do menor erro no ajuste dos modelos.

A classificação de imagem foi avaliada por meio da estatística da Acurácia Global (AG) e índice Kappa (K), sendo este último por meio de intervalos que caracterizam qualitativamente a precisão, sendo de $K < 0$ (péssimo), $0,00 < K \leq 0,2$ (ruim), $0,2 < k \leq 0,4$ (razoável), $0,4 < k \leq 0,6$ (bom), $0,6 < k \leq 0,8$ (muito bom) e $0,8 < k \leq 1,0$ (excelente). Além disso foram avaliados os erros de omissão, que demonstram o quanto que deveria ser classificado como determinada classe, mas foi inserido em outra classe, e o erro de comissão, que determina o quanto foi inserido erroneamente em determinada classe (Landis & Koch, 1977).

As classificações supervisionadas, em formato raster, foram convertidas para *shapefile*, tornando

do-se possível calcular a área de ocupação de cada classe de uso e cobertura do solo. Esse procedimento foi realizado no software QGIS 2.18. Posteriormente, as tabelas de atributos referentes as classificações do sensor OLI e MODIS foram exportadas para planilha eletrônica para quantificação das áreas de ocupação de cada classe de uso e cobertura do solo.

De posse da estimativa da área agrícola foi possível comparar os valores estimados por meio de sensoriamento remoto e os dados de área agrícola disponíveis no sistema Sistema de Recuperação Automática (SIDRA) do Instituto Brasileiro de Geografia e Estatística (IBGE) para todos os municípios que compõe a área de estudo no ano de 2015. Para avaliar a precisão entre as áreas agrícolas estimadas e observadas (SIDRA) foi aplicado o coeficiente de determinação (R^2) e estimativa dos erros em porcentagem (Erro %).

$$R^2 = 1 - \left(\frac{SQ_{res}}{SQ_t} \right) \quad (1)$$

$$Erro(\%) = \left(\frac{E_i - O_i}{O_i} \right) * 100 \quad (2)$$

em que, SQ_{res} é a soma dos quadrados dos resíduos, é SQ_t a soma total dos quadrados, E_i é o i -ésimo valor estimado e O_i é o i -ésimo valor observado.

3 Resultados e Discussão

A classificação de uso e cobertura do solo apresentou, a partir de imagens derivadas do sensor OLI, AG de 0,81 e estatística K de 0,66 (Figura 2a). Pelo valor encontrado na análise, pode-se considerar que a classificação utilizando imagens do sensor OLI e o algoritmo SVM adequa-se a qualidade muito bom (Landis & Koch, 1977). O uso de bandas na faixa do infravermelho médio pode melhorar o processo de separação das classes por adicionar o aspecto de textura dos alvos, já que as bandas 5, 4 e 3 do sensor OLI não confere essa informação ao algoritmo (LU *et al.*, 2012). Segundo Garofalo *et al.* (2015) o algoritmo SVM apresentou melhores resultados na classificação de imagens do OLI quando comparado ao algoritmo vizinho mais próximo.

O mapeamento realizado com o SVM e imagem MODIS apresentou AG de 0,70 e índice K de 0,37, esse último valor associa a classificação a categoria razoável. Os dois índices obtidos para imagem MODIS foram abaixo dos valores para o sensor OLI (Figura 2b). O SVM é um algoritmo não paramétrico e orientado a objeto que utiliza características geométricas para distinção dos alvos, diferente do algoritmo paramétrico *Maximum Likelihood Classifier* ou Máxima Verossimilhança (MAXVER), muito utilizado na literatura e que se baseia apenas na reflectância dos pixels (Devadas *et al.*, 2012; Souza *et al.*, 2016). Partindo desse pressuposto, imagens com baixa resolução espacial podem apresentar acurácia insatisfatória na classificação quando algoritmos orientados a objeto, já que informações sobre o formato de pequenos alvos não será captado pelo algoritmo.

Variações nos parâmetros do algoritmo como o kernel, que apresenta funções linear, polinomial, radial e sigmoideal, além de valores discretos para os parâmetros *gamma* e *cost* permitem variar a qualidade da classificação que pode ser avaliada pelos índices de acurácia global, *kappa* ou erros de omissão e comissão. Alguns trabalhos tem demonstrado bons resultados na classificação de imagens multiespectral e hiperespectrais utilizando o SVM, porém com diferentes tipos de *kernel*, *cost* e *gamma*. Os valores desses parâmetros são modificados de acordo com as características espectrais dos sensores, época de aquisição a imagem e pela homogeneidade ou heterogeneidade dos alvos a serem detectados (Devadas *et al.*, 2012; Ustuner *et al.*, 2015; Souza *et al.*, 2016), sendo necessário avaliações para identificação desses parâmetros.

A matriz de confusão, relativa a imagem do sensor OLI, mostrou que a classe rios teve 31% de acerto, sendo classificado, principalmente, como floresta e pastagem (69%) devido a proximidade que esses usos têm dos cursos d'água. A classificação para área com eucalipto teve 68% de acerto, tendo omitido, aproximadamente, 21% e confundido cerca de 32% com as classes de agricultura e floresta, devido a alta concentração de fitomassa desses alvos, dificultando a distinção espectral dos mesmos (Garofalo *et al.*, 2015). Já a pastagem apresentou

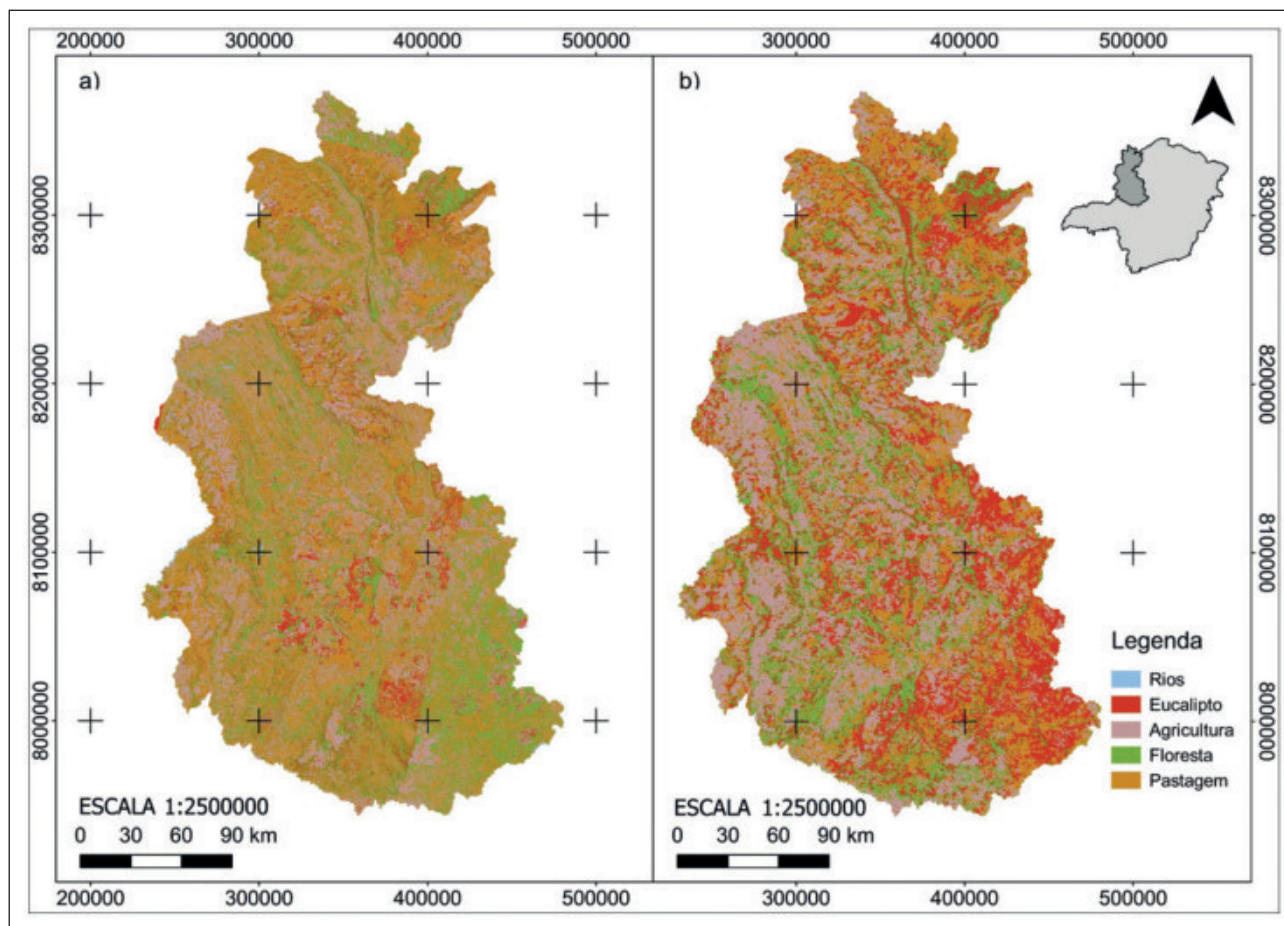


Figura 2 Mapa do uso e cobertura do solo do noroeste de Minas a partir de imagens do satélite/sensor: a) Landsat 8/ OLI e b) Terra/ MODIS.

55% de acerto, tendo confundido e omitido, ambos, 45%. As classes de agricultura e floresta apresentaram precisão de 92% e 87%, respectivamente. A agricultura apresentou os menores erros de omissão (12%) e comissão (8%) (Tabela 1). Percebe-se que o mapeamento da agricultura apresentou erro de comissão, em grande parte, ocasionado pelas classes de pastagem e eucalipto, o que pode influenciar na estimativa da área ocupada por essa classe na região. Isso pode estar relacionado a semelhança no comportamento espectral desses alvos, já que no período de aquisição da imagem a agricultura, o cerrado e o eucalipto estão com alto vigor fisiológico após o período de chuva.

A estatística da classificação com imagem MODIS apresentou 0% de acerto para classe rios. Esse baixo percentual de acerto está relacionado a largura dos cursos d'água da região que são menores

que o pixel da imagem MODIS (500 m), prevalecendo a resposta espectral dos alvos vizinhos como eucalipto (32%) e floresta (26%). A classe eucalipto também teve baixa precisão na classificação (42%), já que apresentou 60% de erro de omissão e 58% de erro de comissão. As classes de floresta e pastagem apresentaram 44% e 35% de acerto, respectivamente. Já a classe agricultura, apresentou o maior acerto entre as classes, cerca de 90%, com erro de omissão de 21% e erro de comissão de aproximadamente 10% (Tabela 1). A resposta espectral contribuiu significativamente na separação dos alvos quando comparado a variáveis secundárias como textura e geometria. Porém, a baixa resolução espacial do sensor MODIS, não contribuiu na distinção da geometria de objetos semelhantes, como agricultura e pastagem, além de alvos com texturas similares como o cerrado e silvicultura, o que dificulta a separabilidade das classes (Yi *et al.*, 2007; Souza *et al.*, 2016).

Ao se analisar a assinatura espectral das classes de uso e cobertura do solo, referente ao sensor OLI, percebe-se que as classes, cujo sua resposta espectral foi diferente das demais classes, apresenta-

Preditos	Verdade - OLI					Verdade - MODIS				
	C01	C02	C03	C04	C05	C01	C02	C03	C04	C05
C01	5	0	0	0	0	0	0	0	0	0
C02	0	15	4	0	0	6	8	4	2	0
C03	2	3	124	3	9	4	11	129	8	11
C04	4	4	3	20	0	5	0	3	8	0
C05	5	0	4	0	11	4	0	8	0	6

Tabela1 Matriz de confusão proveniente da classificação supervisionada com SVM em imagem Landsat 8-OLI e Terra – MODIS. A abreviação das classes de uso e cobertura do solo são C01=Rios, C02=Eucalipto, C03=Agricultura, C04=Pastagem e C05=Floresta.

ram menor erro de confusão na classificação, como as feições de curso d’água que mesmo apresentando baixa precisão não foi confundido com outras classes (Figura 2a). As classes de pastagem, floresta e eucalipto apresentaram os maiores erros de comissão e omissão, pois essas classes tiveram alta reflectância na faixa do infravermelho próximo (banda 5) e alta absorção na faixa do vermelho (banda 4) (Figura 3a). Mesmo a agricultura apresentando resposta espectral similar a floresta, eucalipto e pastagem, houve baixo erros de omissão (12%) e comissão (8%).

A assinatura espectral da classe agricultura para imagem MODIS apresentou maior reflectância na faixa do infravermelho próximo, quando compa-

rado as classes de pastagem e eucalipto, o que pôde facilitar a discriminação da agricultura em relação as outras categorias (Figura 2b). Assim como na imagem OLI, o MODIS também apresentou alta confusão das classes pastagem (67%), eucalipto (60%) e floresta (50%). Isso pode ser observado pelo comportamento espectral semelhante entre a floresta e o eucalipto, com baixa reflectância nas bandas vermelha e azul, e alta reflectância na banda do infravermelho próximo (Figura 3b).

As imagens OLI e MODIS foram adquiridas no verão, período em que há consideráveis índices de chuva nesta região que contribuem para o aumento do vigor fisiológico da pastagem, fazendo com que sua resposta espectral seja confundida com agricultura e vice-versa (Devadas *et al.*, 2012). As culturas agrícolas são implantadas em diferentes datas e ainda culturas de mesma espécie são implantadas em dias diferentes devido a particularidades dos produtores. Com isso, a pastagem pode ser confundida com espécies agrícolas em estágio inicial de desenvolvimento (Jensen, 2007).

O sistema SIDRA indicou que em 2015, a área total com produção agrícola, considerando culturas perenes e temporários, foi de aproximadamente 914.710 ha no noroeste de Minas Gerais. A classificação da imagem OLI indicou 2.131.219,03 ha e o MODIS 2.126.166,30 ha, ou seja, diferença de 132,99% e 132,44%, respectivamente, comparado ao dado observado. Observa-se que mesmo as duas classificações apresentando valores de Kappa distintos, apresentaram o mesmo erro na estimativa

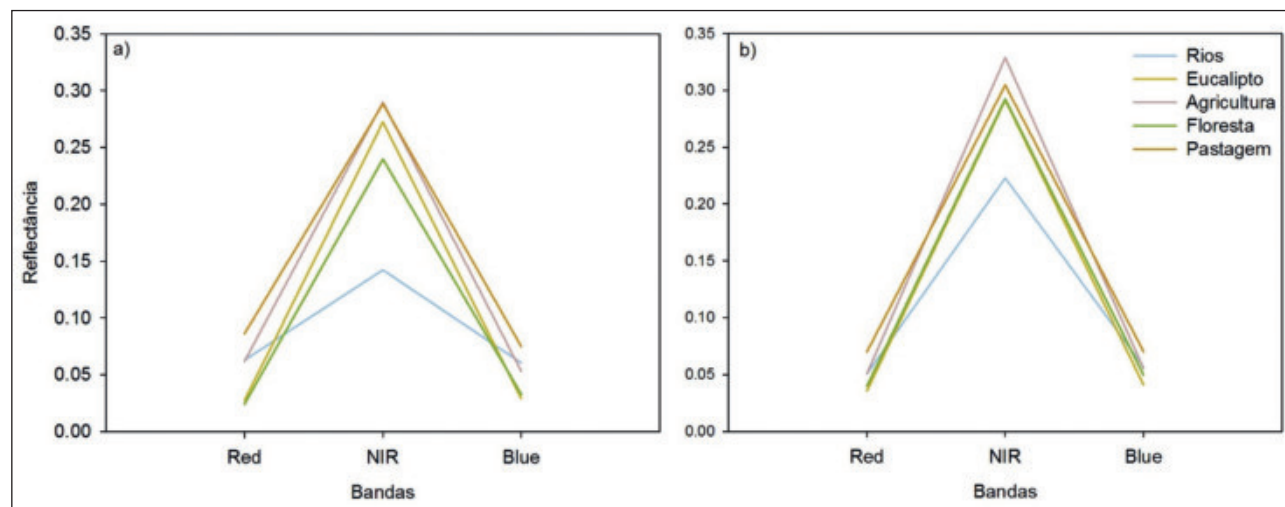


Figura 3 Assinatura espectral dos alvos utilizados no mapeamento de uso e cobertura do solo para imagem a) Landsat 8 – OLI e b) Terra-MODIS nas bandas vermelho (*Red*), infravermelho-próximo (*NIR*) e azul (*Blue*).

de cobertura com agricultura. A proximidade entre os erros dos dois sensores pode estar relacionada a proximidade entre a largura e o posicionamento das bandas espectrais (Tisot *et al.*, 2007). Além disso, o alto erro na estimativa mostra que houve inserção de áreas não agrícolas dentro da classe, como foi o caso da pastagem e do eucalipto que apresentam alta concentração de fitomassa (Garofalo *et al.*, 2015).

O mapeamento das áreas agrícolas municipais proveniente do sensor OLI comparado com os dados do SIDRA teve R^2 de 0,70. O sensor MODIS apresentou a relação mais forte com os dados do SIDRA, com R^2 de 0,83, ou seja, a regressão linear pode explicar 83% da variação das áreas agrícolas (Figura 4a). Resultados similares a esses foram encontrados por Santos *et al.* (2014) no mapeamento de áreas de soja no Sul do Brasil com imagens *Normalized Difference Vegetation Index* (NDVI) do sensor MODIS. Os menores erros encontrados pelo OLI, foram nos municípios de Buritis (33%), São Gonçalo do Abaete (34%) e Guarda-Mor (-10%), sendo que a área agrícola nesse último foi subestimada pelo algoritmo. Com imagens provenientes do sensor MODIS, os menores erros foram nos municípios de Buritis (17%), Formoso (19%) e Guarda-Mor (27%), esse último, diferente do que foi observado na imagem OLI, foi superestimada pelo MODIS.

Por meio da relação dos dados obtidos da classificação não supervisionada com os dados do

SIDRA-IBGE, observa-se que houve superestimativa em alguns municípios como Arinos, Brasilândia de Minas, Natalândia e Vazante, onde a diferença entre o valor esperado e o estimado pelo algoritmo foi superior a 1000%. Nos demais municípios também houve diferenças significativas na estimativa de área agrícola obtida pelo algoritmo e somente no município de Guarda-Mor que a área estimada pelo IBGE foi superior a estimada pelo SVM (Figura 4b).

Para melhorar a separação das classes pode-se aumentar o número de amostras de treinamento para pastagem, ou mesmo, agrupar as amostras em classes como agricultura e não-agricultura, por exemplo, afim de aumentar os vetores de separação e melhorar a acurácia da classificação e evitar a superestimativa para a classe de agricultura (Ouzemou *et al.*, 2018). Segundo Schmidt *et al.* (2016), a identificação de culturas agrícolas, por meio de aprendizado de máquina, tem maior precisão com uso de imagens no inverno, já que áreas de pastagem não irrigadas apresentam menor fitomassa e não seriam confundidas com culturas agrícolas. Porém, o noroeste de Minas Gerais destaca-se por apresentar grande produção de grãos, com plantios concentrados no verão devido a ocorrência de chuvas, sendo, dessa forma, necessário avaliar a melhor época de aquisição de imagem para identificação da agricultura.




Figura 4 Relação entre as áreas estimadas por meio de imagens dos a) sensores OLI e MODIS com dados do sistema SIDRA – IBGE e b) erro obtido para os municípios do Noroeste de Minas Geais.

A densidade de pontos amostrais relativos a reflectância de alvos agrícolas para treinamento do SVM foi relacionado com a acurácia da classificação das áreas agrícolas por municípios, porém não foram encontradas evidências que relacionassem essas variáveis. No entanto, foi observado que os municípios com maiores áreas agrícolas indicadas pelo sistema SIDRA-IBGE apresentaram os menores erros estatísticos utilizando a aprendizagem de máquina e imagens dos sensores OLI e MODIS (Figura 5).

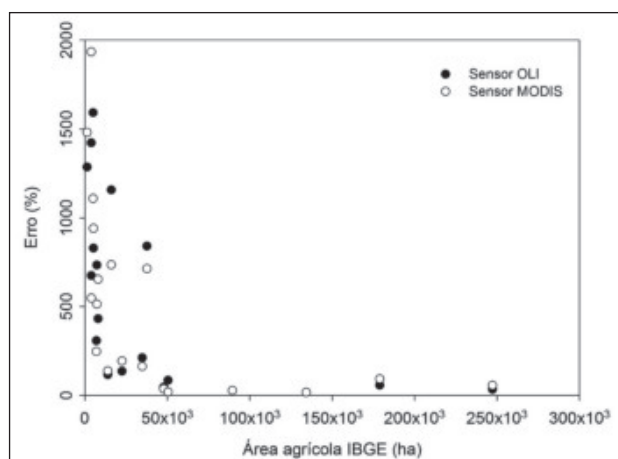


Figura 5 Relação entre as áreas agrícolas do sistema SIDRA-IBGE e o erro na estimativa das áreas agrícolas pelos sensores OLI e MODIS.

Os municípios que apresentaram áreas agrícolas acima de 500.000 hectares tenderam a apresentar os menores erros, por outro lado, municípios com áreas agrícolas menores que 500.000 hectares apresentaram os maiores erros tanto utilizando imagem de alta resolução espacial como de resolução espacial moderada. Isso pode estar relacionado aos diferentes tipos de cultivos agrícolas presentes nesses municípios, que facilitaram a discriminação dessa classe com relação as demais no processo de criação dos vetores de suporte em hiperplano n-dimensional.

4 Conclusão

O sensor OLI apresentou melhor mapeamento utilizando o algoritmo SVM em relação ao sensor MODIS. Os sensores OLI e MODIS superestimaram o mapeamento de áreas agrícolas no noroeste de Minas Gerais, mesmo o sensor OLI apresentando Acurácia Global e índice Kappa superior ao MODIS.

A maioria dos municípios do noroeste mineiro tiveram suas áreas agrícolas superestimadas pelo algoritmo SVM, sendo que menos de cinco dos dezenove municípios apresentaram boas estimativas.

Houve tendência de superestimativa de municípios com áreas menores que 500.000 ha, sendo necessário outros estudos modificando os parâmetros do SVM e aumentando ou modificando o método de distribuição dos pontos amostrais para coleta da resposta espectral dos alvos de interesse.

5 Referências

- Adami, M.; Moreira, M.A.; Rudorff, B.F.F.; Freitas, C.C.; Faria, R.T. & Deppe, F. 2007. Painel amostral para estimativa de áreas agrícolas. *Revista Pesquisa Agropecuária Brasileira*, 42(1): 81-88.
- Alvares, C.A.; Stape, J.L.; Sentelhas, P.C.; Gonçalves, J.L.M. & Sparovek G. 2013. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22(6): 711-728.
- Delgado, R.C.; Sedyama, G.C.; Costa, M.H.; Soares, V.P. & Andrade, R.G. 2012. Classificação espectral de área plantada com a cultura da cana-de-açúcar por meio da árvore de decisão. *Revista de Engenharia Agrícola*, 32(2): 369-380.
- Devadas, R.; Denham, R.J. & Pringle, M. 2012. Support Vector Machine classification of object-based data for crop mapping, using multi-temporal Landsat imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39(1): 185-190.
- Epiphanyo, J.C.N.; Luiz, A.J.B. & Formaggio, A.R. 2002. Estimativa de áreas agrícolas municipais, utilizando sistema de amostragem simples sobre imagens de satélite. *Revista Bragatinga*, 61(2): 187-197.
- Garofalo, D.F.T.; Messias, C.G.; Liesenberg, E.L.B. & Ferreira, M.C. 2015. Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicados ao mapeamento temático. *Pesquisa Agropecuária Brasileira*, 50(7): 593-604.
- Gonçalves, M.L. 2009. *Métodos de classificação não-supervisionada de imagens de sensoriamento remoto usando mapas auto-organizáveis de Kohonen*. Programa de Pós-Graduação em Engenharia Elétrica, Universidade Estadual de Campinas, Tese de doutorado, 689p.
- IBGE – Instituto Brasileiro De Geografia E Estatística. *Resultados do Universo do Censo Demográfico 2010*. Rio de Janeiro, 2019.
- Jensen, J.R. 2009. *Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres*. 2ª ed. São José dos Campos, Parêntese, 672p.
- Landis, J. & Koch, G.G. 1977. The measurements of observer agreement for categorical data. *Biometrics*, 33(3): 159-179.
- Lu, D.; Batistella, M.; Li, G.; Moran, E.; Hetrick, S.; Freitas, C.C.; Dutra, L.V. & Sant'anna, S.J.S. 2012. Land use/cover classification in the Brazilian Amazon using

- satellite images. *Pesquisa Agropecuária Brasileira*, 47(9):1185-1208.
- Luiz, A.J.B.; Formaggio, A.R.; Epiphânio, J.C.N.; Arenas-Toledo, J.M.; Goltz, E. & Brandão, D. 2012. Estimativa amostral objetiva de área plantada regional, apoiada em imagens de sensoriamento remoto. *Revista Pesquisa Agropecuária Brasileira*, 47(9): 1279-1287.
- Oliveira, G.C.; Martins, V.S.; Fernandes Filho, E.I. & Xavier, F.V. 2014. Classificação supervisionada como ferramenta para avaliação da dinâmica do uso e cobertura do solo. *Enciclopedia biosfera*, 10(18): 924-935.
- Ouzemou, J.; Abderrazak, E.H.; Lhissou, R.; Moujahid, A.E.; Bouch, N.; Ouazzani, R.E.; Bachaoui, E.M. & Ghmari, A.E. 2018. Crop type mapping from pansharpened Landsat 8 NDVI data: A case of a highly fragmented and intensive agricultural system. *Remote Sensing Applications: Society and Environment*, 11(1): 94-103.
- Santos, J.S.; Fontana, D.C.; Silva, T.S.F. & Rudorff, B.F.T. 2014. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. *Revista Brasileira de Engenharia Agrícola*, 18(1): 54-63.
- Schmidt, M.; Pringle, M.; Devadas, R.; Denham, T. & Tindall, D. 2016. A Framework for Large-Area Mapping of Past and Present Cropping Activity Using Seasonal Landsat Images and Time Series Metrics. *Remote Sensing*, 8(4): 1-25.
- Shiratsuchi, L.S.; Brandão, Z.N.; Vicente, L.E.; Victoria, D.C.; Ducati, J.R.; Oliveira, R.P. & Vilela, M.F. 2014. Sensoriamento Remoto: conceitos básicos e aplicação na Agricultura de Precisão. *In: Agricultura de Precisão Resultado de um Novo Olhar*, Brasília (DF), Embrapa, p. 58-73.
- Souza, C.G.; Carvalho, L.; Aguiar, P. & Arantes, T.B. 2016. Algoritmo de aprendizagem de máquina e variáveis de sensoriamento remoto para mapeamento de cafeicultura. *Boletim de Ciências Geodésicas*, 22(4): 751 – 773.
- Tisot, D.A.; Formaggio, A.R.; Rennó, C.D. & Galvão, L.S. 2007. Eficácia de dados Hyperion/ EO-1 para identificação de alvos agrícolas: comparação com dados ETM+/Landsat-7. *Revista de Engenharia Agrícola*, 27(2): 511-519.
- Ustuner, M.; Sanli, F.B. & Dixon, B. 2015. Application of Support Vector Machines for Landuse Classification Using High-Resolution RapidEye Images: A Sensitivity Analysis. *European Journal of Remote Sensing*, 48(1): 403-422.
- Vaeza, R.G.; Filho, P.C.O.; Maia, A.G. & Disperati, A.A. 2012. Uso e ocupação do solo em Bacia Hidrográfica urbana a parti de imagens orbitais de alta resolução. *Floresta e Ambiente*, 17(1): 23-29.
- Yi, J.L.R.; Shimabukuro, Y.E. & Quintanilha, J.A. 2007. Identificação e mapeamento de áreas de milho na região sul do Brasil utilizando imagens MODIS. *Revista de Engenharia Agrícola*, 27(3): 753-763.