

APLICAÇÕES DO GOOGLE EARTH ENGINE NA CAFEICULTURA DO SUL DE MINAS GERAIS¹

Vanessa Cristina Oliveira de Souza², Daniel Altino Paredes³, Margarete Marin Lordelo Volpato⁴, Helena Maria Ramos Alves⁵

¹ Trabalho parcialmente financiado pelo Consórcio Brasileiro de Pesquisa e Desenvolvimento do Café – Consórcio Pesquisa Café

² Professora/Pesquisadora, DSc, Universidade Federal de Itajubá, Itajubá-MG, vanessasouza@unifei.edu.br

³ Graduando Sistemas de Informação, Universidade Federal de Itajubá, Itajubá-MG, danielaltino19@gmail.com

⁴ Pesquisadora, DSc, Empresa de Pesquisa Agropecuária de Minas Gerais, Lavras-MG, margarete@epamig.ufla.br

⁵ Pesquisadora, PhD, Embrapa Café, Lavras-MG, helena@epamig.ufla.br

RESUMO: O objetivo desse trabalho foi apresentar como a plataforma em nuvem para análise científica e visualização de dados geoespaciais *Google Earth Engine* (GEE) está sendo utilizada a favor da cafeicultura no Sul de Minas Gerais. São apresentados dois estudos de caso: o mapeamento de áreas cafeeiras, por meio de classificação automática; e a extração de índices espectrais (NDVI, EVI, NDWI) dessas áreas. Em ambos os estudos, todo processamento foi realizado *online*, sem a necessidade de realizar o download e pré-processamento dos dados de sensoriamento remoto. Os resultados indicam que o GEE é um conjunto de ferramentas viável para o mapeamento e monitoramento de áreas cafeeiras.

PALAVRAS-CHAVE: *Google Earth Engine*, geotecnologias, cafeicultura

ABSTRACT: This work presented the viability of the cloud platform for scientific analysis and visualization of geospatial data, called *Google Earth Engine* (GEE), for coffee growing in southern of Minas Gerais. Two case studies are presented: automatic classification of coffee areas and extraction of spectral vegetation indexes. In both studies, all processing was performed online, without download and preprocess the remote sensing data. The results suggest that GEE is a viable toolkit for research in mapping and monitoring coffee areas.

KEYWORDS: *Google Earth Engine*, Geotechnologies, coffee production

INTRODUÇÃO

O sensoriamento remoto orbital (SR) e as técnicas de processamento digital de imagens contribuem significativamente para o monitoramento da cafeicultura. Esses monitoramentos têm sido impactados nos últimos anos pela evolução da computação, que fez surgir conceitos como *big data*, computação em nuvem e aprendizado profundo de máquinas. Exemplo de uso já consolidado por pesquisadores e pelo mercado são as plataformas em nuvem de processamento de dados geoespaciais.

Dentre os serviços de computação em nuvem para análise científica e visualização de dados geoespaciais, o *Google Earth Engine*¹ (GEE) ganhou destaque nos últimos anos e tem sido utilizado em diversos estudos (Gorelick et al., 2017). O maior diferencial da plataforma é que o pesquisador pode realizar seus estudos utilizando o conjunto de dados e a infraestrutura computacional de processamento paralelo da Google gratuitamente, reduzindo tempo e custos de processamento e armazenamento. O catálogo de produtos de Sensoriamento Remoto do GEE possui extensas séries temporais de diferentes satélites e o pesquisador também pode integrar seus próprios dados à plataforma. Para utilizar o GEE é necessário um conhecimento de linguagens de programação de *script* (JavaScript ou Python). O uso do GEE flexibiliza tanto a criação, quanto a utilização de algoritmos de processamento de imagens.

Especialmente nas aplicações agrícolas de sensoriamento remoto, o GEE tem sido avaliado e utilizado em estudos de estimativa do rendimento das culturas, mapeamento da área de cultivo e vulnerabilidade a pragas e doenças. Shelestov et al. (2017) avaliaram o GEE no mapeamento de culturas em extensas áreas da Ucrânia. Os autores concluíram que o GEE apresenta um bom desempenho em seus classificadores e permite acessar e processar com facilidade grande quantidade de imagens de satélite disponíveis gratuitamente. Schultz et al. (2019) utilizaram a plataforma de forma integrada a outras ferramentas no mapeamento de talhões de milho com objetivo de subsidiar previsão de safra no Mato Grosso. Cunha et al. (2019) processaram 27 anos de imagens do satélite Landsat no GEE para gerar índices de vegetação. Os autores conseguiram diferenciar corretamente o período da safra (plantio e colheita) da cultura do arroz e concluem também que o GEE foi eficiente para o processamento do grande volume de dados (ao todo, 685 imagens).

Apesar da popularização da plataforma, no contexto da cafeicultura, a pesquisa realizada para este trabalho identificou apenas o artigo de Kelley et al. (2018), que objetivou o mapeamento de cafés sombreados na Nicarágua. No Brasil, o trabalho de Paredes et al. (2019) avaliou a viabilidade do uso da plataforma GEE e de seus algoritmos de classificação no mapeamento de áreas cafeeiras em Minas Gerais. Os autores concluíram que a plataforma é conveniente para o

¹ <https://earthengine.google.com/>

mapeamento automatizado da cafeicultura no Estado, possibilitando gerar mapas com acurácia satisfatória, com baixo custo.

O objetivo desse trabalho é apresentar como o GEE está sendo utilizado a favor da cafeicultura no Sul de Minas Gerais. Para tanto, são apresentados dois exemplos de estudos em andamento: mapeamento de áreas cafeeiras e índices de vegetação. O monitoramento orbital de áreas cafeeiras subsidia inúmeras aplicações relacionadas à cafeicultura, como o monitoramento em larga escala de pragas, doenças, danos causados por geadas, secas ou inundações; além de poder auxiliar na estimativa de produtividade e consequente previsão de safra. Os índices de vegetação (IV) retratam o comportamento espectral da vegetação e estão correlacionados aos parâmetros agrônômicos da cultura, como estresse hídrico, nutrientes no solo e planta e perda foliar. Dada a importância da cafeicultura mineira, este trabalho apresenta a utilização da plataforma *online* de dados geoespaciais *Google Earth Engine* na cafeicultura.

MATERIAL E MÉTODOS

Os resultados apresentados nesse trabalho foram gerados utilizando a plataforma *Google Earth Engine*, onde os conjuntos de dados podem ser acessados e manipulados por meio de um ambiente de desenvolvimento integrado (IDE) chamado *GEE Code Editor*. No *Code Editor*, o pesquisador escolhe o dado que deseja utilizar², indica o local do estudo e pode utilizar os *scripts* já existentes na plataforma, ou criar os seus próprios. No *Code Editor* tudo é feito por meio de programação *javascript*.

Para esse trabalho os dados utilizados foram do satélite Sentinel-2 MSI, *Level 1C* com 10 metros de resolução espacial; e Landsat 8 TOA – *Tier 2*, com 30 metros de resolução espacial. Os produtos escolhidos já são disponibilizados com correção atmosférica e ortorretificados. O uso da plataforma é gratuito e não demanda que o pesquisador faça *download* das imagens para processá-las.

Estudo de caso 1: Mapeamento de Áreas Cafeeiras

Para esse estudo, foi escolhido o município de Três Pontas, MG (21°17'10,07" S a 21°27'57,41" S de latitude e 45°30'4,69" O a 45°45'3,33" O de longitude), numa área de aproximadamente 690 km². O objetivo foi gerar mapas de uso da terra com café por meio de classificação automática.

Foram escolhidas as imagens dos sensores Sentinel-2 (bandas 2, 3, 4 e 8), de 26/07/2016, com 10m de resolução espacial; e Landsat 8 (bandas 2, 3, 4 e 5) de 08/08/2016, com 30 metros de resolução espacial. Para a classificação das imagens foram selecionados alguns algoritmos supervisionados disponíveis no GEE, sendo dois baseados em árvore de decisão (*Random Forest - RF* e *CART*), um de rede neural (*Perceptron Multiclass*) e o distância mínima com as medidas Euclidiana e Mahalanobis. A validação dos mapas classificados foi feita com base em um mapa produzido pela Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG), sob a imagem do satélite Sentinel-2, com as mesmas bandas e data descritas acima. Após obter os mapas de uso da terra com café utilizando os algoritmos de classificação acima mencionados, os mesmos foram combinados, utilizando um sistema de votação simples (moda). A metodologia detalhada, incluindo os algoritmos, escolha das amostras de treinamento e teste e a técnica de combinação dos mapas de uso, é apresentada por Paredes et al. (2019). Adicionalmente, camadas de textura (Haralick et al., 1973) foram incorporadas, com objetivo de melhorar a classificação automatizada.

O uso da textura na classificação automática do café já foi testada e gera bons resultados (Marujo et al., 2017; Souza et al., 2016; Souza et al., 2009a; Souza et al., 2009b). O GEE disponibiliza algoritmos que calculam as métricas texturais de Haralick, por meio da matriz de co-ocorrência. As imagens texturais foram extraídas a partir da banda do infravermelho próximo (NIR – banda 8 do Sentinel e banda 5 do Landsat) e incluídas na classificação automática. As diferentes métricas texturais (Haralick et al., 1973) foram testadas e, nesse estudo, serão apresentados os resultados com a métrica contraste, por ter apresentado as melhores acurácias.

Estudo de caso 2: Avaliação dos índices de vegetação da cafeicultura

Para esse estudo escolheu-se um pixel (30 x 30 m) em uma área de café do município de Santo Antônio do Amparo, MG (20°54'57" S; 44°51'13" W; altitude 1090 m) (figura 1). Nessa área, pertencente à NKG Fazendas Brasileiras Ltda., são desenvolvidas várias pesquisas científicas pela EPAMIG. A região conta com uma estação meteorológica, de onde foram coletados dados de precipitação acumulada mensal. O objetivo desse estudo foi gerar séries temporais longas de diferentes índices espectrais de vegetação na plataforma GEE. O período avaliado foi de 2013 a 2018 e os índices foram gerados com o satélite Landsat 8.

Utilizando a ferramenta *Code Editor* do GEE foi possível implementar e executar os *scripts* para os seguintes índices de vegetação: Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Vegetação Melhorado (EVI), e uma variação do Índice de Diferença Normalizada da Água (NDWI) que reflete a quantidade de água contida na planta (NDWI_vegetação). Parte dos *scripts* está ilustrado na figura 2. A função '*normalizedDifference*' computa a diferença normalizada entre duas bandas *b1* e *b2*, da seguinte forma: $(b1 - b2) / (b1 + b2)$. A função '*expression*' computa a álgebra de mapas conforme uma determinada expressão. Ambas funções já são disponibilizadas pelo GEE.

² A descrição completa do catálogo de dados do GEE pode ser acessada no link <https://developers.google.com/earth-engine/datasets/catalog/>.



Figura 1. Localização do Pixel de 30 x 30 m, em uma área de café no município de Santo Antônio do Amparo, MG.
Fonte: Google Earth.

```
var app = function (image) {  
  // NDVI  
  var ndvi = image.normalizedDifference(['B5', 'B4']);  
  image = image.addBands(ndvi.rename('NDVI'));  
  
  //EVI  
  var evi = image.expression(  
    '2.5 * (nir - red) / (nir + 6 * red - 7.5 * blue + 1)',  
    {  
      red: image.select('B4'), // 620-670nm, RED  
      nir: image.select('B5'), // 841-876nm, NIR  
      blue: image.select('B2') // 459-479nm, BLUE  
    });  
  image = image.addBands(evi.rename('EVI'));  
  
  //NDWI vegetacao  
  var ndwi_veg = image.normalizedDifference(['B5', 'B6']);  
  image = image.addBands(ndwi_veg.rename('NDWI_veg'));
```

Figura 2. Scripts utilizados no Code Editor do GEE para geração dos índices espectrais de vegetação NDVI, EVI e NDWI.

RESULTADOS E DISCUSSÃO

Estudo de caso 1: Mapeamento de Áreas Cafeeiras

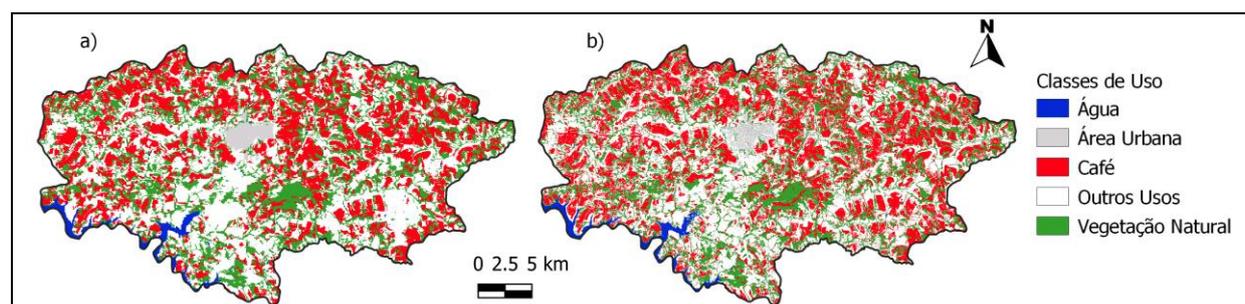
A tabela 1 apresenta os resultados para o mapeamento do uso da terra com café obtidos por meio da plataforma *Google Earth Engine*, utilizando os classificadores automáticos *Random Forest*, *CART*, *Perceptron*, Mínima Distância Euclidiana e Mínima Distância Mahalanobis. Além disso, as duas combinações testadas, sendo a primeira (combinação 1), uma votação simples (moda) entre todos os algoritmos acima citados e a segunda (combinação 2), votação simples entre os classificadores *Random Forest*, *CART* e *Perceptron*. Os resultados são apresentados para as imagens do satélite Sentinel 2 e Landsat 8. Nos resultados indicados com textura, além das bandas espectrais, adicionou-se a banda textural.

Verifica-se que a acurácia global da classe café e da classe mata melhoram com a inclusão das bandas texturais, corroborando estudos anteriores (Marujo et al., 2017; Souza et al., 2016; Souza et al., 2009a; Souza et al., 2009b). A melhor acurácia para a classe café aconteceu com mapeamento utilizando o satélite Sentinel, com textura e o classificador de Mínima Distância Euclidiana (73,83%), apesar de a acurácia global desse classificador ter sido ruim (30,41%). A melhor acurácia para a classe mata ocorreu com o satélite Sentinel, com textura e o classificador de rede neural *Perceptron* (70,42%). No entanto, as melhores acurácias globais ocorreram nas combinações dos algoritmos e com o classificador *Random Forest*. O melhor mapa foi obtido para o classificador *Random Forest*, com o satélite Sentinel e banda textural (71,77%). Resultado semelhante foi obtido para a combinação 2 com o satélite Sentinel e banda textural (71,39%), com discreta melhora na acurácia da classe café (69,13% contra 68,67% do RF). A figura 3a apresenta o mapa de uso com café de referência, produzido pela EPAMIG e a figura 3b o mapa considerado com melhor acurácia na classificação automática do uso da terra com café.

O algoritmo de classificação *Random Forest* (Breiman, 1999) tornou-se popular na comunidade de sensoriamento remoto devido à precisão de suas classificações (Belgiu & Drăguț, 2016). Ele, por si só, já é uma combinação de diversos classificadores de árvore de decisão (*random tree*). Neste trabalho, dez árvores foram utilizadas no processamento com o *random forest*. Segundo Pal (2005), o RF apresenta como vantagens o fato de ter poucos parâmetros que precisam ser inicializados, poder manipular dados categóricos, não balanceados e com valores omissos. Kelley et al. (2018) utilizaram o RF no GEE no mapeamento de cafés sombreados na Nicarágua. Os autores obtiveram acurácia superior a 90% na classificação, considerando o RF uma boa solução.

Tabela 1. Resultado da classificação automática para o uso da terra com café no município de Três Pontas, MG.

Algoritmos	Acurácia Global	Kappa	Acurácia Café	Acurácia Mata	Acurácia Global	Kappa	Acurácia Café	Acurácia Mata
	Sentinel-2 (sem textura)*				Landsat (sem textura)*			
Random Forest	66,87	0,51	66,50	49,69	67,37	0,52	65,83	52,80
CART	62,57	0,45	62,00	45,57	63,81	0,47	66,89	45,89
Perceptron	65,57	0,48	62,46	45,26	66,11	0,49	61,93	48,06
MD Euclidiana	53,33	0,36	59,35	50,47	56,13	0,39	59,55	55,20
MD Mahalanobis	42,15	0,26	53,47	48,60	51,60	0,35	52,35	55,98
Combinação 1	66,00	0,50	64,71	47,59	66,47	0,51	64,11	50,78
Combinação 2	66,89	0,51	66,89	47,98	67,59	0,52	68,54	48,76
	Sentinel-2 (com textura)				Landsat (com textura)			
Random Forest	71,77	0,58	68,67	66,38	69,79	0,55	70,39	55,90
CART	68,35	0,53	67,35	57,38	64,68	0,48	67,28	53,26
Perceptron	66,71	0,51	63,52	70,42	67,59	0,51	66,75	51,71
MD Euclidiana	30,41	0,11	73,83	17,93	33,43	0,10	54,26	56,83
MD Mahalanobis	52,80	0,38	59,09	61,49	51,93	0,36	69,53	17,08
Combinação 1	69,45	0,56	71,25	62,11	68,81	0,54	71,18	52,56
Combinação 2	71,39	0,58	69,13	66,38	69,61	0,55	71,18	54,43

**Figura 3.** Mapa de uso da terra para o município de Três Pontas, MG. Em a, mapa de referência produzido pela EPAMIG. Em b, mapa cuja classificação automática obteve melhor acurácia. Resultado da combinação dos classificadores *Random Forest*, *CART* e *Perceptron*, para a imagem Sentinel, com bandas espectrais e texturais.

Os próximos passos para essa pesquisa será a inserção de novas camadas de dados na classificação, como diferentes bandas texturais e uma votação ponderada entre os classificadores. Por exemplo, como o algoritmo de Mínima Distância Euclidiana teve melhor acurácia na classe café, numa votação, seria atribuído um peso maior para esse algoritmo quando uma classe café for atribuída a um pixel da imagem.

Estudo de caso 2: Avaliação dos índices de vegetação da cafeicultura

O GEE oferece ao pesquisador um amplo catálogo de dados espectrais orbitais e a flexibilidade de gerar novos *scripts* para produzir o resultado esperado. A plataforma permite que o pesquisador crie o gráfico diretamente ou exporte os valores tabulares para serem preparados em uma planilha. Os gráficos das figuras 4a, 4b e 4c apresentam as séries temporais dos índices espectrais EVI, NDVI e NDWI, respectivamente, gerados a partir de uma planilha, para o ponto (pixel) da lavoura indicado na figura 1. A figura 4d apresenta a série temporal da precipitação acumulada mensal, obtida na estação meteorológica da NKG Fazendas Brasileiras Ltda..

Observa-se que os índices tem a variação temporal relacionada à variação da precipitação, em períodos longos sem chuva os valores dos índices vão diminuindo lentamente, os valores dos índices são dependentes do tamanho do período de seca, após as primeiras chuvas os valores dos índices ainda permanecem baixos e lentamente começam a aumentar com a continuidade do período das chuvas, retratando o comportamento vegetativo dos cafeeiros. Em Volpato et al. (2013) essa relação é apresentada para o NDVI. Analisando a série histórica observam-se os menores valores dos índices de vegetação nos meses de Novembro e Maio, acompanhando a baixa na precipitação acumulada. Apesar dos valores serem maiores nos meses de Janeiro e Dezembro, os gráficos da figura 4 realçam a seca atípica em 2014, com baixa precipitação, refletindo em baixos valores dos índices de vegetação.

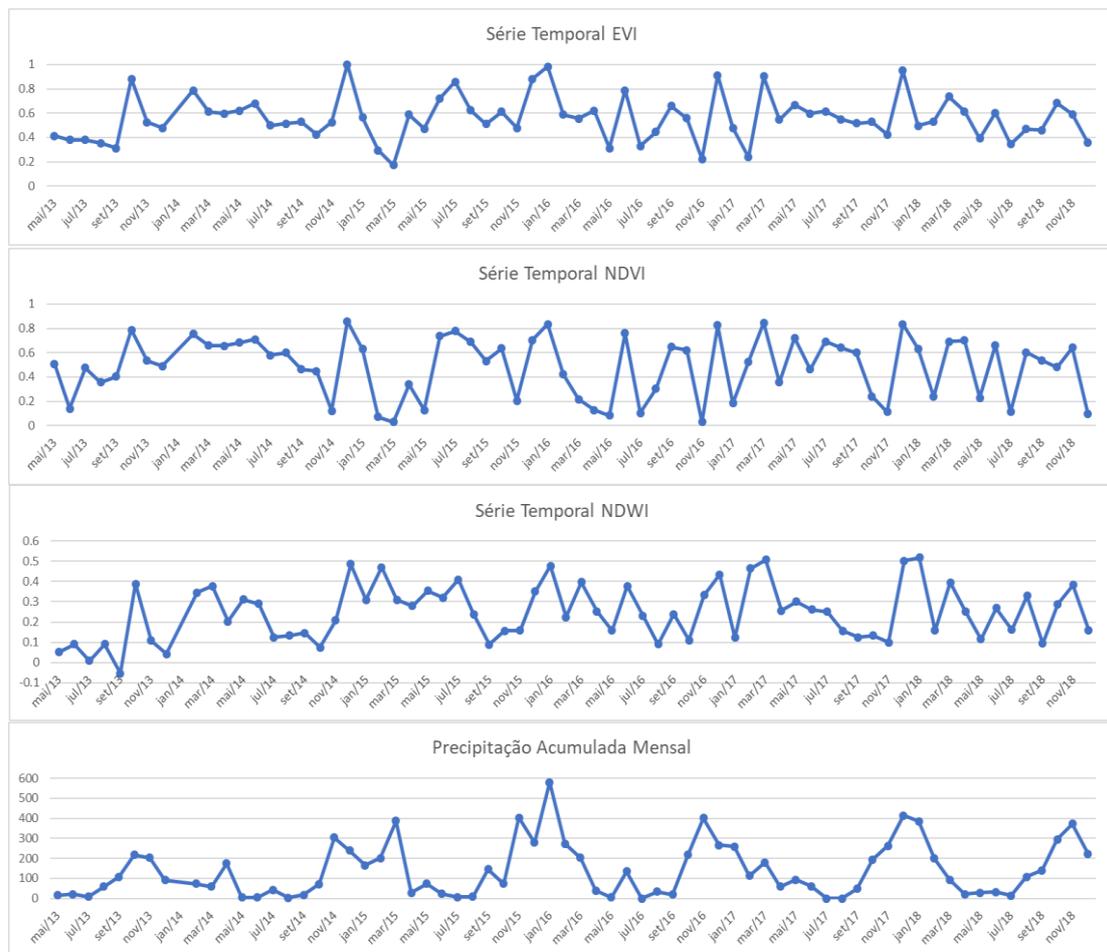


Figura 4. Séries Temporais dos índices de vegetação de uma região cafeeira do Sul de Minas geradas no *Code Editor* do GEE. a) EVI. b) NDVI. c) NDWI e d) Precipitação Acumulada Mensal (em milímetros).

Diversos autores estudam índices espectrais de vegetação na cafeicultura. Bernardes et al. (2013) avaliaram a dependência da produtividade do cafeeiro em função da biomassa foliar, por meio dos índices de vegetação EVI e NDVI no Sul de Minas Gerais. Os índices foram gerados a partir de imagens do satélite Landsat entre 2004 e 2009. Os autores concluíram que, quando associados a outras variáveis, os índices de vegetação podem ser úteis nas estimativas da produtividade do cafeeiro. Chaves et al. (2019) utilizaram series temporais dos índices EVI, NDVI e NDWI para estimar as áreas destinadas à cafeicultura na mesorregião Triângulo Mineiro / Alto Paranaíba, utilizando os sensores MODIS e SPOT-VEGETATION. Os autores definiram ainda limiares dos valores de EVI e NDVI que podem subsidiar estudos de classificação automática de uso da terra.

CONCLUSÕES

1. A utilização de técnicas de *machine learning* e computação de alta performance traz novas oportunidades para o gerenciamento do setor agrícola, auxiliando tomadas de decisão em toda cadeia produtiva
2. A plataforma *online* para dados geoespaciais *Google Earth Engine* contempla ferramentas valiosas para os estudos de mapeamento e monitoramento do uso da terra com café, uma vez que expande as possibilidades de pesquisa por meio de um ambiente de programação gratuito e muito versátil.
3. Diferentes algoritmos e metodologias de classificação automática podem ainda ser testados no mapeamento de áreas cafeeiras.

AGRADECIMENTOS

Os autores agradecem à Empresa de Pesquisa Agropecuária de Minas Gerais (Laboratório de Geoprocessamento – GeoSolos) por ceder os dados aqui disponibilizados, e ao Consórcio Pesquisa Café, FAPEMIG e CNPQ pelo apoio financeiro e concessão de bolsas.

REFERÊNCIAS BIBLIOGRÁFICAS

- BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 114, p. 24–31, 1 abr. 2016. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0924271616000265>>. Acesso em: 15 out. 2018.
- BERNARDES, T. et al. Variáveis e modelos para estimativa da produtividade do cafeeiro a partir de índices de vegetação derivados de imagens Landsat. In: Simpósio Brasileiros de Sensoriamento Remoto, 2013, Foz do Iguaçu/PR: MCT/INPE, 2013. p. 720–727.
- BREIMAN, L. Random forests—random features. Berkeley: [s.n.], 1999.
- CHAVES, M. E. D.; FERREIRA, E.; DANTAS, A. A. A. Thresholds definition in MOD13Q1 and VGT-S10 time series for coffee crop area estimation in Triângulo Mineiro/Alto Paranaíba. *Theoretical and Applied Engineering*, v. 3, n. 2, p. 1–10, jan. 2019.
- CUNHA, C. S.; SILVEIRA, P. O.; RUHOFF, A. L. Busca de padrões em diferentes classes de uso do solo na Bacia Hidrográfica do Rio Santa Maria-Rs Entre 1990 a 2017. In: Simpósio Brasileiros de Sensoriamento Remoto, 2019, Santos/SP: MCT/INPE, 2019.
- GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, v. 202, p. 18–27, 2017.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, v. 3, p. 610–620, 1973.
- KELLEY, L. C.; PITCHER, L.; BACON, C. Using Google Earth Engine to Map Complex Shade-Grown Coffee Landscapes in Northern Nicaragua. *Remote Sensing*, v. 10, n. 952, 2018.
- MARUJO, R. de F. B. et al. Mapeamento da cultura cafeeira por meio de classificação automática utilizando atributos espectrais, texturais e fator de iluminação. *Coffee Science*, v. 12, n. 2, p. 164–175, 2017.
- PAL, M. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, v. 26, n. 1, p. 217–222, jan. 2005.
- PAREDES, D. A. C.; SOUZA, V. C. O.; VOLPATO, M. M. L. Viabilidade da plataforma Google Earth Engine em pesquisas cafeeiras no Sul de Minas Gerais. In: Simpósio Brasileiros de Sensoriamento Remoto, 2019, Santos/SP: MCT/INPE, 2019. p. 2458–2461.
- SCHULTZ, B. et al. Datasafra - Monitoramento de milho safrinha no Mato Grosso por sensoriamento remoto e Google Earth Engine. In: Simpósio Brasileiros de Sensoriamento Remoto, 2019, Santos/SP: MCT/INPE, 2019. p. 2933–2936.
- SHELESTOV, A. et al. Exploring Google Earth Engine Platform for Big Data Processing: Classification of Multi-Temporal Satellite Imagery for Crop Mapping. *Frontiers in Earth Science*, v. 5, n. February, p. 1–10, 24 fev. 2017. Disponível em: <<http://journal.frontiersin.org/article/10.3389/feart.2017.00017/full>>.
- SOUZA, C. G. et al. Algoritmos de aprendizagem de máquina e variáveis de sensoriamento remoto para o mapeamento da cafeicultura. *Boletim de Ciências Geodésicas*, v. 22, n. 4, p. 751–773, dez. 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1982-21702016000400751&nrm=iso>.
- SOUZA, V. C. O. de et al. Mapeamento de áreas cafeeiras por classificação automática utilizando medidas texturais. In: Simpósio de Pesquisa dos Cafés do Brasil, 2009a, Vitória/ES, 2009.
- SOUZA, V. C. O. et al. Análise e classificação textural de áreas de mata e café na região de Machado – MG. In: Simpósio Brasileiros de Sensoriamento Remoto, 2009, Natal/RN: INPE, 2009b. p. 7925–7932.
- VOLPATO, M.M.L.; VIEIRA, T.G.C.; ALVES, H.M.R.; SANTOS W.J.R. Modis images for agrometeorological monitoring of coffee areas. *Coffee Science*, v.8, n.2, p.168-175, 2013.