

CLASSIFICAÇÃO MULTIESCALA TEXTURAL UTILIZANDO O *GOOGLE EARTH ENGINE*

Daniel Altino Cotti Paredes¹, Vanessa C O Souza¹, Margarete M L Volpato² and Helena M R Alves³

¹Instituto de Matemática e Computação – Universidade Federal de Itajubá (UNIFEI), Itajubá/MG, danielaltino19@gmail.com, vanessasouza@unifei.edu.br ²Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG), Lavras/MG, margarete@epamig.br; ³Empresa Brasileira de Pesquisa Agropecuária (Embrapa), helena.alves@embrapa.br, Lavras/MG

RESUMO

A plataforma em nuvem *Google Earth Engine* (GEE) foi utilizada neste trabalho para avaliar a performance de uma metodologia de Classificação Multiescala Textural na classificação automática do uso da terra com café na região Sul de Minas Gerais. Na multiescala textural, a escala da imagem é definida pelo tamanho da janela utilizada para gerar a matriz de co-ocorrência, a partir da qual as medidas texturais são extraídas. Dentre os modelos testados, a métrica Contraste obteve o melhor resultado, com acurácia de 70,85% para classe Café e 72,66% de acurácia global. A escala definida pela janela 7x7 apresentou os melhores resultados para a classificação do uso da terra com café. Portanto, os resultados mostraram que a metodologia avaliada é adequada para a classificação automática de áreas cafezeiras.

Palavras-chave – GEE, cafeicultura, textura, multiescala

ABSTRACT

The Google Earth Engine (GEE) cloud platform was used in this work to evaluate the performance of a Textural Multiscale Classification methodology in the automatic classification of land use with coffee in the southern region of Minas Gerais. In textural multiscale, the image scale is defined by the size of the window used to generate the co-occurrence matrix, from which the textural measures are extracted. Among the models tested, the Contrast metric obtained the best result, with 70.85% accuracy for Coffee class and 72.66% overall accuracy. The scale defined by the 7x7 window presented the best results for coffee land use classification. Therefore, the results showed that the evaluated methodology is adequate for the automatic classification of coffee areas.

Key words – GEE, coffee growing, texture, multi-resolution classification

1. INTRODUÇÃO

Devido à importância econômica e financeira da cafeicultura no Brasil e, especialmente no Estado de Minas Gerais, o mapeamento das lavouras cafezeiras por meio de geotecnologias tem sido objeto de estudo há vários anos, por diferentes grupos de pesquisadores.

O uso de geotecnologias e classificações automáticas no mapeamento de áreas cafezeiras em Minas Gerais é comumente utilizado [1–3]. Porém, apresenta ainda desafios científicos, uma vez que fatores como a alta variabilidade de

padrões espectrais da cultura e características do plantio e do relevo mineiro, dificultam o acerto dos classificadores [1,4,5].

A incorporação de textura no processamento de classificação de imagens pode melhorar o resultado da classificação [6]. Na cafeicultura, diversos autores já utilizaram atributos texturais e relataram melhora na acurácia dos mapeamentos [1–3]. A técnica mais comum usada para derivar medidas de textura é a matriz de co-ocorrência de nível de cinza (GLCM, do inglês *Gray Level Cooccurrence Matrix Method*), proposta por [7]. Esta técnica é composta por duas fases: na primeira, constrói-se a GLCM, que é uma tabulação de diferentes combinações de valores de intensidade dos *pixels* que ocorrem em uma imagem; na segunda fase, são calculadas as métricas a partir da matriz de co-ocorrência, que descrevem a informação espacial do alvo. A construção da GLCM considera o tamanho da janela (em *pixels*) para a análise da vizinhança de um *pixel*. A menor janela que pode ser considerada é de 3x3 *pixels*.

No trabalho de [6], os autores propõem uma abordagem denominada multiescala textural, onde diferentes imagens texturais são geradas a partir da variação do tamanho da janela na construção da GLCM.

Portanto, uma alternativa de classificação ainda não testada para a cafeicultura mineira é a Classificação Multiescala Textural. Nesse contexto, esse trabalho parte da hipótese de que a classificação multiescala de imagens de satélite pode melhorar a acurácia de classificação automática de áreas cafezeiras na região Sul de Minas Gerais. Para provar a hipótese apresentada, a metodologia de [6] foi adaptada.

Esse trabalho tem como objetivo avaliar a Classificação Multiescala Textural de áreas cafezeiras do Sul de Minas Gerais utilizando a plataforma em nuvem *Google Earth Engine* - GEE [8]. Foi utilizado o classificador *Random Forest* com imagens do satélite Sentinel-2.

2. MATERIAL E MÉTODOS

A área de estudo compreende o município de Três Pontas (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 km na região Sul do Estado de Minas Gerais. Na região prevalece relevo predominantemente ondulado (60% da área do município) com algumas regiões montanhosas (20% da área do município).

O mapa de uso da terra de Três Pontas utilizado como referência (mapa verdade) foi concedido pela Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG). O mapa foi gerado a partir da fotointerpretação visual de imagens do satélite Sentinel 2-A. As classes consideradas no mapeamento foram: Corpos D'Água, Área Urbana,

Café, Outros Usos (solo exposto, pastagens, outras cultivares agrícolas) e Mata. Os modelos de classificação foram obtidos com o algoritmo *Random Forest*, a partir da seguinte parametrização: 100 árvores aleatórias, 50 *variablesPerSplit* e 10 *minLeafPopulation*.

As amostras para treinamento e teste foram geradas aleatoriamente sobre o mapa verdade. Cinco mil pontos foram distribuídos pela área, como conjuntos disjuntos. Como métricas de avaliação foram utilizadas as acurácias das classes café e mata, a acurácia global e o índice Kappa.

Todo processamento foi realizado no ambiente de programação *Code Editor* do GEE, por meio de *scripts* desenvolvidos na linguagem *JavaScript*.

2.1. Multiescala Textural

A metodologia para classificação multiescala textural foi adaptada de [6]. O objetivo dos autores foi classificar diferentes espécies de árvores de Pinus e, como procedimento metodológico, utilizaram bandas texturais processadas com janelas de diferentes tamanhos (de 5x5 a 15x15).

No presente trabalho, foi usado uma função nativa do GEE denominada *glcmTexture*, que calcula a matriz de co-ocorrência e extrai 18 métricas texturais. A partir da banda do infravermelho próximo (B8) do satélite Sentinel-2 foram geradas seis imagens texturais para cada métrica, cada uma em uma escala (janela) diferente: 5x5, 7x7, 9x9, 11x11, 13x13 e 15x15. As 18 métricas retornadas pelo GLCM foram avaliadas, mas apenas as métricas Contraste, Entropia, Variância e Segundo Momento Angular (SMA) foram selecionadas. Seguindo o indicado por [7], essa redução de dimensionalidade foi realizada a partir de uma análise de acurácia.

Para a etapa de classificação foram utilizadas quatro bandas espectrais (azul, vermelho, verde e infravermelho próximo) e mais 6 (seis) bandas texturais, uma para cada escala, para cada medida textural (Contraste, Entropia, Variância ou Segundo Momento Angular). Ao final, portanto, foram gerados quatro mapas, um para cada medida textural, que foram avaliados individualmente. Denominamos esses mapas de **Contraste Multiescala**, **Entropia Multiescala**, **Variância Multiescala** e **SMA Multiescala**. Posteriormente, os quatro mapas foram combinados para avaliar se tal estratégia melhoraria a acurácia da classificação, utilizando a metodologia definida por [2]. Esse mapa foi denominado **Combinação Multiescala** e utilizou o filtro de moda para combinar as classificações prévias.

Como forma de comparar a performance do método textural multiescala, três outros mapas foram gerados: **Mapa Espectral**: gerado com as bandas azul, vermelho, verde e infravermelho próximo do satélite Sentinel-2; **Mapa Textural**: gerado apenas com as bandas texturais (Contraste, Entropia, Variância ou Segundo Momento Angular) e em uma única escala. Para esse mapa, das janelas utilizadas, a 7x7 obteve melhor resultado; **Mapa Espectral e Textural (Multitextural)**: gerado com as bandas espectrais e texturais acima descritas.

O código desenvolvido nesse trabalho, assim como o dataset estão disponíveis no GEE e pode ser acessado por <https://code.earthengine.google.com/>

56355f9fba09906e31d338a4d01bc6cd?accept_repo=users%
2Fdanielaltino19%2FTFG.

3. RESULTADOS E DISCUSSÕES

A Figura 1 ilustra o resultado da métrica Contraste nas diferentes escalas (janelas), para um recorte da área de estudo. As áreas mais claras representam um valor mais alto do contraste. As áreas mais escuras, valores mais baixos. As áreas de *Mata* apresentam valores de contraste bem mais altos do que as áreas de *Café*. O aumento da janela (diminuição da escala) causa o borramento da imagem e, nesse caso, a diferença entre os valores altos e baixos fica diminuída. No recorte apresentado na figura, os valores de Contraste para a resolução 5x5 variam entre 109 e 65535. Para a escala 15x15, os valores variam entre 1877 e 65535.

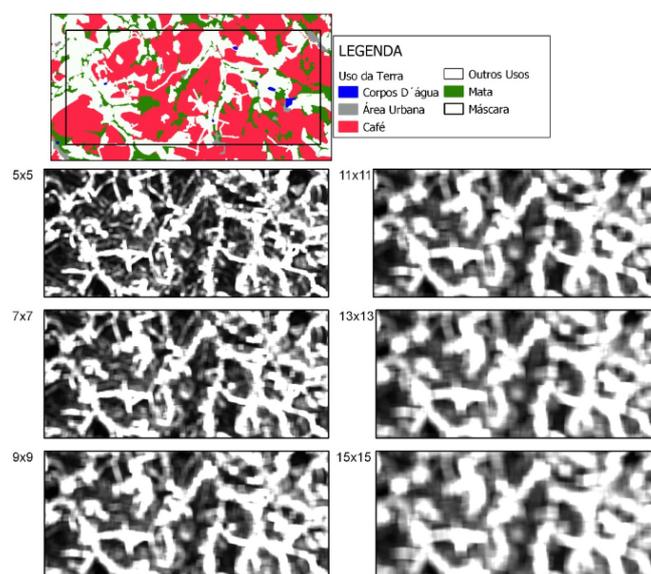


Figura 1: Métrica de contraste em diferentes janelas.

A Tabela 1 apresenta a acurácia global das imagens classificadas de acordo com a métrica textural utilizada. Os modelos obtiveram um bom resultado comparado com a literatura [1–3]. A métrica contraste obteve um melhor resultado comparado com as demais. Na classe Café, a variância obteve o pior resultado. Já para a classe Mata, a medida SMA apresentou o pior resultado. A combinação multiescala apresentou a melhor acurácia para a classe Café e a pior acurácia para a classe Mata. Para a acurácia global, não há diferença significativa entre as métricas Entropia, Variância e SMA, ficando todas em torno de 70%. O índice Kappa teve o maior valor com o modelo contraste multiescala, e o menor valor utilizando as métricas de variância e segundo momento angular. O índice Kappa foi classificado como moderado para todos os modelos testados, segundo classificação de [9].

A Tabela 2 compara a acurácia das classes Café e Mata, a Acurácia Global e o índice Kappa dos modelos de classificação automática utilizando o melhor resultado da multiescala textural (Contraste Multiescala) e a Combinação Multiescala com o modelo puramente espectral (Espectral), os gerados utilizando apenas as imagens texturais na janela

Modelo	Acurácia Café	Acurácia Mata	Acurácia Global	Kappa
Contraste Multiescala	70,85	66,93	72,66	59,57
Entropia Multiescala	69,00	59,47	70,37	58,07
Variância Multiescala	68,54	61,02	70,17	55,74
SMA Multiescala	69,40	58,46	70,15	55,74
Combinação Multiescala	74,82	56,99	71,39	59,57

Tabela 1: Acurácia (em %) e Kappa da classificação multiescala das métricas texturais avaliadas.

7x7, e o modelo gerado com as bandas espectrais e as texturais na janela 7x7, chamado aqui de Multitextural.

Pela análise da Tabela 2, verifica-se que a Combinação Multiescala obteve resultado superior às demais na classificação da classe Café (74,82%). A classificação com o Contraste Multiescala obteve o melhor resultado para a classe Mata (66,93%). A classificação Multitextural alcançou a melhor acurácia global e melhor índice Kappa. Este último, ficando muito próximo ao Contraste Multiescala. Com valor próximo a 60%, o Kappa obtido é classificado por [9] como moderado.

A Tabela 2 destaca ainda que as classificações utilizando apenas as bandas texturais não obtêm bons resultados, apresentando acurácia global inferior a 50% e índice Kappa menor que 20% que, segundo [9] representa uma classificação insignificante.

Modelo	Acurácia Café	Acurácia Mata	Acurácia Global	Kappa
Contraste Multiescala	70,85	66,93	72,66	59,57
Combinação Multiescala	74,82	56,99	71,39	59,57
Espectral	68,67	47,98	66,97	50,82
Contraste 7x7	36,15	60,87	46,03	19,87
SMA 7x7	15,33	40,37	43,97	13,55
Entropia 7x7	16,46	40,37	43,73	13,37
Variância 7x7	31,26	54,50	42,05	14,22
Multitextural	72,48	64,55	72,82	59,73

Tabela 2: Comparação de acurácia entre os diferentes classificadores avaliados.

Os resultados obtidos nesse trabalho corroboram com [10]. Esses autores concluíram que variáveis texturais melhoram a acurácia da classificação quando associadas às variáveis espectrais; e que classificações que não utilizam variáveis espectrais não resultam em bons índices de acurácia.

O trabalho de [11] concluiu também que as métricas texturais podem ser usadas com sucesso no mapeamento automático áreas cafeeiras. Nesse trabalho, os autores obtiveram um índice Kappa de 86%.

No entanto, é importante ressaltar que os trabalhos [1,3,10] utilizaram a metodologia de classificação orientada a objetos, que depende de *software* proprietário e uma etapa de pré-processamento importante, onde é realizada segmentação e a construção do vetor de atributos. Já em [11], apenas as classes Café e Mata foram consideradas. As demais foram mascaradas, diminuindo a confusão do classificador com outras classes. Além disso, em [10,11], as áreas de estudo eram menores, compreendendo partes de um município. Sendo, portanto, menos diversificadas.

Utilizar todas as escalas texturais é uma estratégia que ameniza particularidades dos alvos estudados. No entanto, a relação entre o tamanho da janela de processamento da

GLCM e a natureza da textura é complexa. Em [6], concluiu-se que para áreas com menor variação espacial, tamanhos de janela menores tiveram melhor desempenho, enquanto para áreas com mais variação espacial, janelas maiores obtiveram melhores resultados; e que, imagens que contêm estruturas espaciais complexas, não existe um tamanho de janela ideal para extrair as informações texturais. Para esses tipos de dados, uma técnica de processamento que combina várias escalas de informações tem melhor desempenho.

De acordo com [12], a textura fornece informações suplementares sobre as propriedades do objeto que podem ser úteis para a discriminação do uso e cobertura da terra, embora tenham uma desvantagem de alto custo computacional. Nesse quesito, o uso do GEE e, consequentemente, plataformas em nuvem clusterizadas, apresenta baixo custo. A Tabela 3 mostra para cada etapa do processamento executado, o tempo gasto no GEE. Os tempos são uma média de 30 execuções do código, utilizando uma internet cabeada com 100 MB/s de banda e um notebook com processador intel core i5 8250u.

Verifica-se na Tabela 3 que o código utilizado para gerar a GLCM e as 18 bandas texturais leva menos de um minuto para ser executado. De fato, o que mais consome tempo é a classificação das imagens. O alto tempo pode ser em função também da quantidade de bandas utilizadas para a tarefa que, no caso, foram dez.

Etapa	Tempo
Geração das imagens texturais	menos de 1 segundo
Treinamento do modelo	menos de 1 segundo
Classificação das imagens	9 minutos
Obtenção da matriz de confusão	menos de 1 segundo
Combinação dos mapas classificados	8 segundos

Tabela 3: Tempo médio de processamento no GEE para as etapas da classificação textural multiescala.

Em relação ao desempenho do classificador obtido nesse trabalho, uma observação importante é que o mapa de referência, por ter sido gerado a partir de interpretação visual, é um mapa que integra as classes de uso por regiões e não por *pixel*. Assim, talhões de café são completamente mapeados como café, desconsiderando as ruas dos talhões e possíveis árvores nativas plantadas no meio do cafezal, ou algum terreiro de secagem, por exemplo. Outro exemplo típico é a Área Urbana. No mapa verdade ela aparece como uma mancha, desconsiderando os diferentes alvos presentes em uma cidade. Na classificação *pixel-a-pixel*, tais detalhes presentes nas imagens são considerados e podem ser claramente detectados nos mapas classificados. A consequência é que pontos classificados corretamente podem ser erroneamente avaliados, quando comparados ao mapa de referência. Isto é, a classificação está correta, mas é considerada incorreta em relação à referência utilizada.

A Figura 2 ilustra o exposto com o mapa verdade produzido pela EPAMIG e o mapa classificado a partir do modelo multiescala textural obtido com a métrica Contraste. O talhão de café apresenta arruamentos que não estão presentes no mapa verdade. No mapa classificado, os arruamentos foram classificados como Outros Usos, enquanto no mapa verdade, pertencem à classe Café. Isso significa que as métricas de acurácia consideram a classificação errada, quando na

verdade não é. O efeito é claramente visível na Área Urbana, que obteve as piores acurácias de classificação em ambas metodologias testadas. Sendo assim, entende-se que a acurácia real dos mapas classificados pode ser maior do que a que foi apresentada, assim como o índice Kappa.

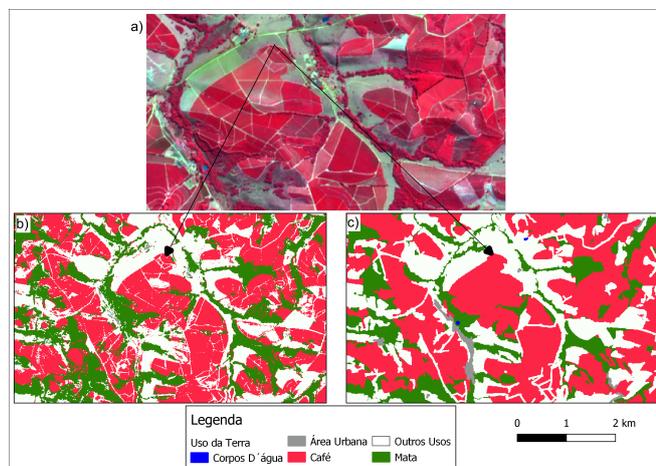


Figura 2: Comparação entre os mapas Contraste Multiescala (b) e Mapa Verdade (c) para um recorte da área de estudo. Acima (a), a imagem falsa-cor (RGB-8,4,3) destacando cafezais (em vermelho) com ruas (azul claro).

4. CONCLUSÕES

O estudo foi realizado com o objetivo de classificar automaticamente áreas cafeeiras utilizando a plataforma *Google Earth Engine* como uma ferramenta de auxílio a dados e informações geoespaciais das regiões.

A metodologia de [6] foi adaptada para a classificação de áreas cafeeiras no Sul de Minas e mostrou bons resultados, assim como os encontrados pelos autores. A janela 7x7 apresentou os melhores resultados para a classificação do uso da terra com café. Dentre os modelos de classificação automática gerados a partir da multiescala textural, a métrica Contraste obteve o melhor resultado. A combinação dos modelos multiescala gerou uma melhora na classificação da classe Café e uma piora na acurácia global, incluindo a classe Mata.

Pode-se concluir que o uso da abordagem Multiescala Contraste apresenta resultado próximo à abordagem Multitextural (bandas espectrais junto com as quatro bandas texturais na escala 7x7).

De modo geral o GEE se apresentou viável para a área de estudo e as tarefas de classificação utilizadas. A plataforma é flexível e permitiu realizar as adaptações necessárias para reproduzir as metodologias avaliadas nesse estudo.

Sendo assim, conclui-se que as hipóteses testadas foram corroboradas, uma vez que as classificações multiescala apresentaram acurácia melhor do que as que utilizam escala única. Além disso, o GEE foi suficientemente bom para os processamentos realizados.

AGRADECIMENTOS

Os autores agradecem à Empresa de Pesquisa Agropecuária de Minas Gerais por ceder os dados aqui disponibilizados, obtidos com

o apoio do Consórcio Pesquisa Café, FAPEMIG e CNPQ.

5. REFERÊNCIAS

- [1] R. F. B. Marujo, M. A. Moreira, M. M. L. Volpato, and H. M. R. Alves. Coffee crop detection by automatic classification using spectral and textural attributes and illumination factor. *Coffee Science - ISSN 1984-3909*, 12(2):164–175, Jun. 2017.
- [2] D. A. C. Paredes, V. C. O. Souza, M. M. L. Volpato, and H. M. R. Alves. Viabilidade da plataforma google earth engine em pesquisas cafeeiras no sul de minas gerais. *SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 19:2458–2461, 2019.
- [3] R. F. B. Marujo, M. M. L. Volpato, T. G. C. Vieira, H. M. R. Alves, and M. B. P. Ribeiro. Classificação orientada à objetos aplicada à cultivos cafeeiros em três pontas, mg. *SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 16:1338–1345, 2013.
- [4] T. Bernardes, H. M. R. Alves, and T. G. C. Vieira. Classificação automática de imagens de satélites no mapeamento da região cafeeira de patrocínio, mg. In *SIMPÓSIO DE PESQUISA DOS CAFÉIS DO BRASIL*, Águas de Lindóia/SP, 2007. Embrapa Café.
- [5] L. N. Andrade, T. G. C. Vieira, W. S. Lacerda, M. M. L. Volpato, and C. A. Davis Jr. Application of artificial neural network in the classification of coffee áreas in machado, minas gerais state. *Coffee Science - ISSN 1984-3909*, 8(1):78–90, Apr. 2013.
- [6] C. A. Coburn and A. C. B. Roberts. A multiscale texture analysis procedure for improved forest stand classification. *International Journal of Remote Sensing*, 25(20):4287–4308, 2004.
- [7] R. M. Haralick, K. Shanmugam, and I.H. Dinstein. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, 6:610–621, 1973.
- [8] N. Gorelick, M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, and R. Moore. Google earth engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202:18–27, 2017.
- [9] V. Abaira. El índice kappa. *Semergen-Medicina de Familia*, 27(5):247–249, 2001.
- [10] C. G. Souza, L. Carvalho, P. Aguiar, and T. B. Arantes. Algoritmos de aprendizagem de máquina e variáveis de sensoriamento remoto para o mapeamento da cafeicultura. *Boletim de Ciências Geodésicas*, 22(4):751–773, 2016.
- [11] V. C. O. Souza, T. G. C. Vieira, H. M. R. Alves, and M. M. L. Volpato. Análise e classificação textural de áreas de mata e café na região de machado-mg. In *Embrapa Café-Artigo em anais de congresso (ALICE)*. In: *SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 14., 2009, Natal., 2009.
- [12] J. M. Peña-Barragán, M. K. Ngugi, R. E. Plant, and J. Six. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, 115(6):1301–1316, 2011.