

AVALIAÇÃO DA SEGMENTAÇÃO MULTITEMPORAL EM IMAGENS DO SENTINEL-2 EM UMA ÁREA DE INTENSIFICAÇÃO AGROPECUÁRIA

Palavras-Chave: Coeficiente de variação, Watershed Segmentation, *Object-oriented image analysis*

Autores:

Lohaynes Teixeira dos Santos – FEAGRI, UNICAMP

João Paulo Sampaio Werner – FEAGRI, UNICAMP

Prof.^a Dr.^a Gleyce Kelly Dantas Araújo Figueiredo (orientadora) – FEAGRI, UNICAMP

INTRODUÇÃO:

A disponibilidade global de imagens de satélite da missão Sentinel-2 (ESA, 2020), em suas 13 bandas espectrais com resolução espacial (10 – 60 m) e temporal (5 dias), tem permitido pesquisadores da área do sensoriamento remoto a desenvolverem métodos mais eficientes de monitoramento das atividades agropecuárias. Um exemplo disso, é a classificação do uso e cobertura da terra a partir de imagens em análises baseadas em objetos, uma vez que seus resultados são superiores aos métodos baseados em pixel (VIEIRA et al., 2012). No entanto, apesar das vantagens da classificação baseada em objetos, a literatura mostra que ela é raramente usada para analisar séries temporais de imagens de satélite (BELGIU; CSILLIK, 2018). Logo, a aplicação de métodos de segmentação em imagens multitemporais para identificação espaço-temporal de objetos é uma etapa importante que ainda precisa ser investigada (INGLADA et al., 2015), principalmente em áreas dinâmicas com intensificação das atividades agropecuárias.

Diante desse cenário, o presente projeto tem como objetivo geral testar um método de segmentação em imagens multitemporais do Sentinel-2 em uma área de intensificação agropecuária. A partir desse enfoque aumentam-se as possibilidades de mapear tipos de culturas e culturas de mesmo tipo em diferentes estádios de desenvolvimento fenológico (WATKINS; VAN NIEKERK, 2019; PETITJEAN; INGLADA; GANCARSKI, 2012).

ÁREA DE ESTUDO:

A área de estudo corresponde a uma área de 83,11 Km², localizada no município de Caiuá, no Estado de São Paulo (Figura 1), onde também está inserida a Fazenda Campina, uma Unidade de Referência Tecnológica (URT) de sistemas de integração lavoura-pecuária (ILP). Com exceção da Fazenda Campina, as

propriedades na área de estudo apresentam estrutura fundiária de dimensões de pequeno e médio porte, onde diversos assentamentos estão presentes.

METODOLOGIA:

O fluxo metodológico compreende as seguintes etapas: (1) aquisição de imagens temporais do Sentinel-2; (2) processamento das imagens, que consiste em realizar o preparo delas para a segmentação; (3) segmentação, que envolve o processo de criação de feições de referência de não mudança e o processo de segmentação; (4) avaliação da segmentação, que consiste na aplicação de métricas que avaliam a qualidade da segmentação (Figura 2).

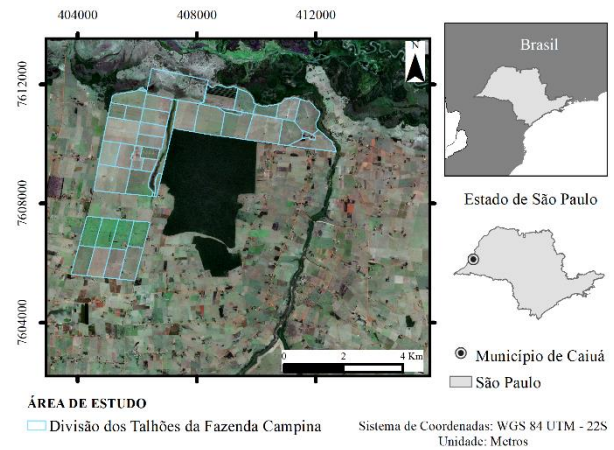


Figura 1 - Área de estudo, em destaque a divisão de talhões da Fazenda Campina, localizada no município de Cauaiá - SP.

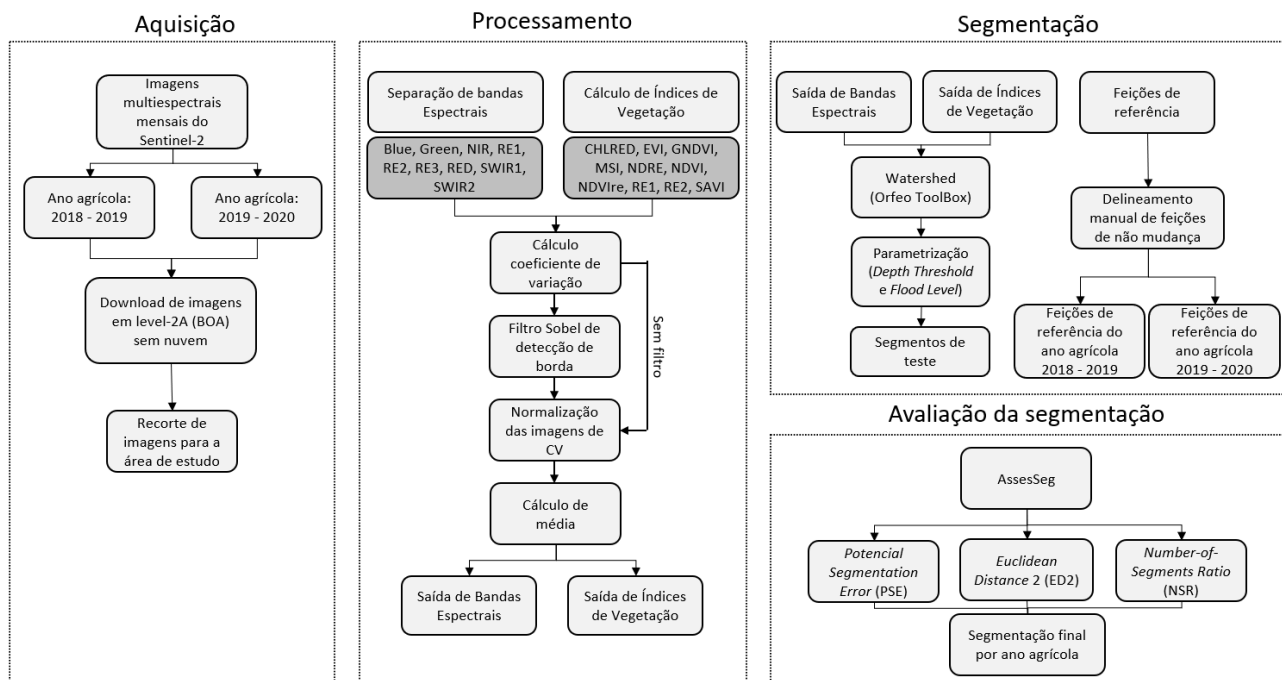


Figura 2 - Fluxo metodológico do projeto de segmentação de séries temporais de imagens do Sentinel-2.

Imagens mensais sem nuvem do Sentinel-2 (Level-2A – *Bottom of Atmosphere*) foram baixadas da base de dados da Agência Espacial Europeia (ESA) e correspondem a dois anos agrícolas: 2018-2019 e 2019-2020. A fim de acompanhar o calendário agrícola da região, a imagem de início foi definida no mês de setembro de um ano e a imagem final definida no mês de agosto do ano seguinte, perfazendo 12 imagens multiespectrais para cada ano agrícola e totalizando 24 imagens.

Após a aquisição das imagens, separou-se as bandas espectrais (Blue, Green, NIR, RE1, RE2, RE3, RED, SWIR1, SWIR2), calculou-se os índices de vegetação (CHLRED, EVI, GNDVI, MSI, NDRE, NDVI, NDVIre, RE1, RE2, SAVI) e, em seguida, calculou-se o coeficiente de variação para ambos. Para as demais etapas de processamento seguiu-se o método proposto por Watkins & Niekerk (2019), em que primeiro se

aplica o filtro Sobel para a detecção de bordas das parcelas agrícolas na região de estudo e, posteriormente, se obtém as imagens de média das imagens filtradas de bandas espectrais e de índices de vegetação.

Para realizar a segmentação, utilizou-se o Watershed Segmentation (WS), um algoritmo baseado em região que usa mínimos locais como pontos centrais e expande objetos para fora com níveis crescentes de intensidade até que alcancem as bordas de outro objeto (SALMAN, 2006). O WS está implementado no [Orfeo ToolBox](#) (uma ferramenta *open source* para processar imagens de sensoriamento remoto) e possui dois parâmetros de segmentação: *Depth Threshold* e *Flood Level*. Para este trabalho, optou-se por realizar testes de segmentação variando apenas os valores do primeiro parâmetro e mantendo o segundo constante.

A fim de avaliar a qualidade dos resultados de segmentação produzidos, uma centena de feições de referência foram manualmente vetorizadas para cada ano agrícola, os quais representam parcelas agrícolas de comportamento uniforme no período investigado. Assim, essas feições de referência foram comparadas com as saídas do processo de segmentação no AssesSeg, uma ferramenta gratuita e desenvolvida por Novelli *et al.* 2017. Por meio do AssesSeg foram geradas métricas que estão associadas à qualidade da segmentação. A principal métrica é uma versão modificada da medida de discrepância supervisionada chamada Euclidean Distance (ED2), proposta por Liu *et al.* (2012), que por sua vez depende de outras duas métricas: Potencial Segmentation Error (PSE) e Number-of-Segments Ratio (NSR).

O PSE é uma medida geométrica que calcula a razão entre a área total dos subsegmentos e a área total dos polígonos de referência, dessa forma, um valor igual a zero deste índice, indica que não há subsegmentos. Por outro lado, o NSR é uma medida aritmética que calcula a diferença absoluta no número de polígonos de referência e no número de segmentos correspondentes dividido pelo número de polígonos de referência. Assim, um valor igual a zero deste índice, indica que existe uma relação preferencial de um para um entre os polígonos de referência e os segmentos correspondentes, ou seja, ele representa a discrepância aritmética na situação de supersegmentação (Liu *et al.*, 2012). Tendo isso em vista, o ED2 é uma medida que considera as discrepâncias geométricas e aritméticas, portanto, um valor igual a zero pode indicar uma boa qualidade de segmentação (Liu *et al.*, 2012).

RESULTADOS E DISCUSSÃO:

Para o ano agrícola de 2018-2019, destaca-se que quando não foi aplicado o filtro Sobel de detecção de bordas o resultado ficou mais próximo de zero, considerando a imagem de média das bandas espectrais. Por outro lado, para a imagem de média dos índices de vegetação o melhor resultado de segmentação foi obtido quando o filtro foi aplicado (Figura 3).

Ano Agrícola 2018-2019						
	Nome	Depth Threshold	Flood Level	NSR	PSE	ED2
Banda Índice	Média (Sem Filtro)	0,0080	0,10	7,139	1,471	7,289
		0,0294	0,10	12,822	1,401	12,898
Banda Índice	Média (Com Filtro)	0,022	0,12	10,178	2,506	10,482
		0,026	0,12	10,337	4,203	11,158

Figura 3 - Avaliação da segmentação do ano agrícola de 2018-2019.

Em relação ao ano agrícola de 2019-2020 o comportamento foi semelhante, uma vez que a melhor segmentação ocorreu quando não aplicou o filtro Sobel na imagem de média das bandas espectrais e quando ele foi aplicado na imagem de média dos índices de vegetação (Figura 4).

Ano Agrícola 2019-2020						
	Nome	Depth Threshold	Flood Level	NSR	PSE	ED2
Banda	Média (Sem Filtro)	0,0006	0,10	2,050	1,482	2,529
Índice		0,0275	0,10	10,980	1,460	11,077
Banda	Média (Com Filtro)	0,0180	0,12	5,416	3,905	6,677
Índice		0,022	0,12	7,9703	4,447	9,127

Figura 4 - Avaliação da segmentação do ano agrícola de 2019-2020.

Ao considerar os resultados encontrados da métrica Euclidean Distance 2, a segmentação obteve seu melhor desempenho quando foi aplicada na imagem de média das bandas espectrais sem filtro para os anos agrícolas de 2018-2019 e 2019-2020 (Figura 5), com um ED2 igual a 7,289 e 2,529, respectivamente.

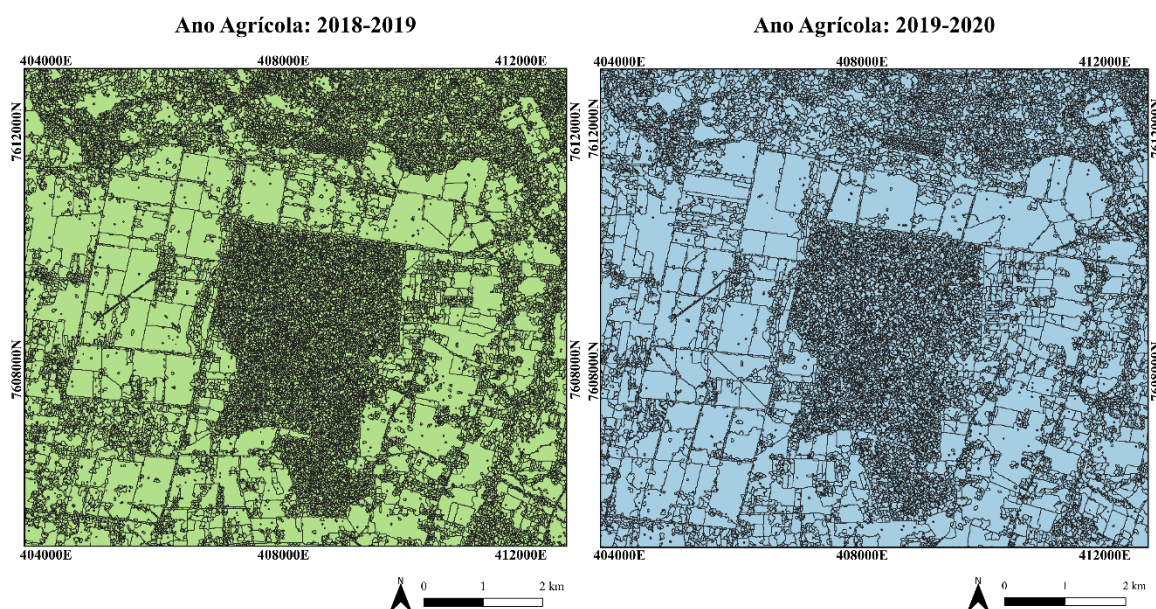


Figura 5 – Segmentações de imagens de média das bandas espectrais dos anos agrícolas de 2018-2019 e 2019-2020.

Ressalta-se que por se tratar de uma região onde as propriedades são de pequeno e médio porte com intensificação agropecuária e, conseqüentemente, muito dinâmica, é esperado uma exigência mais alta no processo de segmentação quando comparada com outras regiões que apresentam propriedades maiores e de formas mais definidas. Assim, essas dificuldades contribuíram para que os valores de ED2 ficassem acima de zero, uma vez que paisagens não uniformes e heterogêneas como essa são mais difíceis para se ajustar às feições de referência. Em geral, os resultados da métrica NSR, relacionada com o número de segmentos criados, influenciaram mais os resultados de ED2, o que já era esperado, uma vez que o uso do algoritmo de segmentação WS normalmente produz grande número de pequenos objetos e é propenso a supersegmentação (WATKINS & NIEKERK, 2019).

Por sua vez, a ferramenta AssesSeg se mostrou ser uma ferramenta muito poderosa quando combinada com algoritmos semiautomáticos de segmentação para avaliar a qualidade da segmentação, visto que ela foi

capaz de produzir todos os resultados para diferentes parâmetros estabelecidos na etapa de segmentação. Além disso, ela não depende de um software específico de segmentação, o que facilita e torna mais amplo seu uso.

CONCLUSÕES:

Os produtos gerados a partir do coeficiente de variação das bandas espectrais e dos índices de vegetação de imagens mensais do Sentinel-2 são capazes de delinear parcelas agrícolas que apresentam comportamento espectro-temporal similar. Embora houve uma tendência do algoritmo Watershed Segmentation (WS) supersegmentar a área de estudo, seu uso se mostrou eficaz para identificação de objetos em uma paisagem dinâmica com intensificação de atividades agropecuárias.

Dentre todos os testes realizados – com ou sem filtro de detecção de borda (Sobel) – a segmentação de melhor desempenho utiliza a imagem média das bandas espectrais sem filtro, evidenciada no ano de 2019-2020. Além disso é válido destacar que um aumento no número de feições de referência pode contribuir para diminuir a incerteza na avaliação da qualidade da segmentação.

BIBLIOGRAFIA

BELGIU, M.; CSILLIK, O. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. **Remote Sensing of Environment**, [s. l.], v. 204, p. 509–523, 2018.

ESA. **Sentinel-2 - Missions - Sentinel Online**. 2020. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 9 jul. 2020.

INGLADA, J.; ARIAS, M.; TARDY, B.; HAGOLLE, O.; VALERO, S.; MORIN, D.; DEDIEU, G.; SEPULCRE, G.; BONTEMPS, S.; DEFOURNY, P.; KOETZ, B. Assessment of an Operational System for Crop Type Map Production Using High Temporal and Spatial Resolution Satellite Optical Imagery. **Remote Sensing**, [s. l.], v. 7, n. 9, p. 12356–12379, 2015.

LIU, Y. et al. Discrepancy measures for selecting optimal combination of parameter values in object-based image analysis. **International Society for Photogrammetry and Remote Sensing, Inc. (ISPRS)**, v. 68, p. 144-156, mar. 2012.

NOVELLI, A.; AGUILAR, M. A.; AGUILAR, F. J.; NEMMAOUI, A.; TARANTINO, E. AssesSeg—A Command Line Tool to Quantify Image Segmentation Quality: A Test Carried Out in Southern Spain from Satellite Imagery. **Remote Sensing**, [s. l.], v. 9, n. 1, p. 40, 2017.

PETITJEAN, F.; INGLADA, J.; GANCARSKI, P. Satellite Image Time Series Analysis Under Time Warping. **IEEE Transactions on Geoscience and Remote Sensing**, [s. l.], v. 50, n. 8, p. 3081–3095, 2012.

SALMAN, N. Image Segmentation Based on Watershed and Edge Detection Techniques. [s. l.], v. 3, n. 2, p. 7, 2006.

VIEIRA, M. A.; FORMAGGIO, A. R.; RENNÓ, C. D.; ATZBERGER, C.; AGUIAR, D. A.; MELLO, M. P. Object Based Image Analysis and Data Mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. **Remote Sensing of Environment**, [s. l.], v. 123, p. 553–562, 2012.

WATKINS, B.; VAN NIEKERK, A. A comparison of object-based image analysis approaches for field boundary delineation using multi-temporal Sentinel-2 imagery. **Computers and Electronics in Agriculture**, [s. l.], v. 158, p. 294–302, 2019.