



CONFORMIDADE E ADEQUABILIDADE NA SEGMENTAÇÃO DE IMAGENS OLI/LANDSAT 8-9 PARA MAPEAMENTO DE PASTAGENS DEGRADADAS

Izabela Chiarato de **Souza**¹; Hilton Luís Ferraz da **Silveira**²; Cristina Aparecida Gonçalves **Rodrigues**³; José Paulo **Franzin**⁴; Carlos Cesar **Ronquim**⁵

Nº 23504

RESUMO – O uso do Sensoriamento Remoto para o planejamento e a tomada de decisão é cada vez mais frequente em função da grande disponibilidade de dados e de ferramentas de manipulação. No mapeamento de pastagens degradadas, por exemplo, além dos valores de reflectância, métricas associadas à estatística descritiva, como média, moda e desvio-padrão, podem fornecer informações importantes para sua classificação, as quais seriam impossíveis de obter usando uma estratégia de classificação pixel-a-pixel, onde $n = 1$. Um desses métodos de segmentação é o mean shift. Apesar da facilidade de utilizá-lo, o ajuste de seus parâmetros e a avaliação de seus resultados são feitos, em muitos casos, por meio da análise visual e empírica. Esta pesquisa tem como objetivo avaliar três segmentações feitas em áreas de pastagens, por meio do algoritmo mean shift, para uma cena do estado de São Paulo (órbita 220 e ponto 75). Para obter a acurácia posicional de cada segmentação, foi calculada a raiz do erro quadrático médio (RMSE) das distâncias entre os limites de 100 polígonos segmentados e os limites dos polígonos de referência vetorizados em tela, em quatro pontos distintos da feição. Como resultado, a segmentação mais adequada para o trabalho de mapeamento de pastagens foi a que utilizou os valores 19, 15 e 20 para os parâmetros espectral, espacial e de tamanho mínimo dos polígonos respectivamente, que obteve RMSE de 73,7.

Palavras-chaves: acurácia posicional, SIG, segmentação, sensoriamento remoto, RMSE.

1 Autora, Bolsista CNPq (PIBIC): Graduação em geologia, Unicamp, Campinas-SP; izabela.souza@colaborador.embrapa.br

2 Orientador, Analista da Embrapa Territorial, Campinas-SP; hilton.ferraz@embrapa.br

3 Colaboradora, Pesquisadora da Embrapa Territorial, Campinas-SP

4 Colaborador, Técnico da Embrapa Territorial, Campinas-SP

5 Colaborador, Pesquisador da Embrapa Territorial, Campinas-SP

ABSTRACT – *The use of Remote Sensing for planning and decision-making is becoming increasingly common due to the extensive availability of data and manipulation tools. In the mapping of degraded pastures, for example, in addition to reflectance values, metrics associated with descriptive statistics such as mean, mode, and standard deviation may provide important information for classification, information which would be impossible to obtain using a pixel-by-pixel classification strategy, in which $n = 1$. One of these segmentation methods is Mean Shift. Despite the ease of using it, adjusting its parameters and evaluating its results are often done through visual and empirical analysis. This research aims to evaluate three segmentations of pasture areas produced using the Mean Shift algorithm for a scene in the state of São Paulo (orbit 220, point 75). To obtain the positional accuracy for each segmentation, the Root Mean Square Error (RMSE) of distances between the boundaries of 100 segmented polygons and the boundaries of reference polygons vectorized on-screen was calculated at four distinct points of the feature. As a result, the most suitable segmentation for pasture mapping was the one that used values 19, 15, and 20 for the spectral, spatial, and minimum polygon size parameters, respectively, which reached an RMSE of 73.7.*

Keywords: positional accuracy, GIS, segmentation, remote sensing, RMSE.

1. INTRODUÇÃO

O uso do Sensoriamento Remoto para o planejamento e a tomada de decisão é cada vez mais frequente, em função da grande disponibilidade de dados e de ferramentas de manipulação. Apesar de os aspectos visuais das imagens já fornecerem, em muitos casos, informações relevantes, elas podem não ser suficientes para representar determinados fenômenos.

No mapeamento de pastagens degradadas, por exemplo, o uso de métricas associadas à estatística descritiva pode fornecer informações importantes para a classificação, as quais seriam impossíveis de obter usando uma estratégia de classificação pixel-a-pixel. Nesse contexto, o Mapeamento de Níveis de Degradação de Pastagens no Bioma Cerrado por meio de Geotecnologias (GeoPasto Cerrado), projeto conduzido pela Embrapa Territorial, pretende segmentar as áreas de pastagens no Cerrado dos estados de São Paulo e Mato Grosso do Sul, e encontrar áreas adjacentes e consideradas semelhantes espectralmente. A principal vantagem de trabalhar com classificação por regiões é que essa técnica fornece informações de natureza espacial, que não podem ser

extraídas individualmente de pixels e que são normalmente consideradas durante o processo de análise visual de imagens (Moreira; Assad, 2000).

Um desses métodos de segmentação é o *mean shift*, um algoritmo não supervisionado e não paramétrico que usa uma janela móvel para avaliar e calcular um valor médio e determinar qual pixel deve ou não ser incluído em cada segmento (Comaniciu; Meer 1999; Zhou et al., 2014). Conforme a janela se move sobre a imagem, ela recalcula iterativamente o valor, para garantir que cada segmento seja adequado, por meio de uma avaliação constante e dinâmica (Heng et al., 2015). Embora seja um algoritmo não paramétrico, especificamente nas análises de dados espacialmente distribuídos, foram inseridos os critérios para controlar a continuidade e a área dos segmentos criados. Essas características dos segmentos de imagem dependem de três parâmetros: detalhe espectral, detalhe espacial e tamanho mínimo do segmento (Zhou et al., 2014). Com base no tema de interesse, as especificações de cada parâmetro são modificadas na tentativa de salientar as feições distintas possíveis. Diferentemente da classificação supervisionada, esse tipo de algoritmo necessita apenas da disposição dos dados e suas propriedades internas, como cor, textura, forma, tamanho e localização (Dronova, 2015).

Dadas a importância e a facilidade do processo de segmentação para os trabalhos de classificação em sensoriamento remoto, têm surgido, ao longo do tempo, técnicas que visam obter métricas para a análise quantitativa do desempenho dos algoritmos, como é o caso do IAVAS, IAVAS_{mod} (Dlugosz et al., 2009), o GShape e o FITXY (Costa, 2019). Apesar do desenvolvimento dessas técnicas, a conformidade com os objetivos do trabalho, e conseqüentemente a mudança dos parâmetros de ajuste, é feita, em muitos casos, por meio da análise visual e da tentativa e erro (Costa, 2019; Belloli et al., 2022).

Especificamente para o mapeamento de pastagens, os limites dos piquetes e das fazendas são feições muito importantes, uma vez que determinam mudanças nos tratos culturais e no manejo do gado e da pastagem. Nesse contexto, esta pesquisa tem como objetivo avaliar três segmentações feitas em áreas de pastagens usando o algoritmo *mean shift*, para uma cena do estado de São Paulo (órbita 220 e ponto 75), calculando a acurácia posicional dos limites dos polígonos gerados (segmentação) com os limites de polígonos vetorizados manualmente em tela (referência) em quatro pontos por meio da raiz do erro quadrático médio (*root mean square error*, RMSE).

2. MATERIAL E MÉTODOS

As etapas aqui descritas foram feitas usando o software ArcGIS Pro 2023 para processamento e análise de resultados.

2.1 Organização do banco de dados

A imagem utilizada foi gerada a partir dos dados de reflectância de superfície dos sensores OLI/Landsat-8 e OLI/Landsat-9 e produzida a partir da seleção, em um banco de dados, de cenas de três datas diferentes (20/03/2023, 05/04/2023 e 21/04/2023). O valor de reflectância foi escolhido, pixel a pixel, com base na cena mais próxima do dia 25 de março de 2023 (data do trabalho de campo do projeto GeoPasto Cerrado) e com a melhor qualidade (ausência de cobertura de nuvem ou sombra), e correspondeu à cena 220-075. Para a segmentação, foi gerada uma composição colorida com as bandas do vermelho, infravermelho próximo e infravermelho médio nos canais vermelho, verde e azul, respectivamente.

2.2 Criação das geometrias de referência

Para limitar o estudo dentro de uma única classe de uso e ocupação e auxiliar em uma análise mais específica para o objetivo do projeto, foi recortada a feição do tipo “pastagem” ao longo da cena. Os dados de pastagem foram obtidos da plataforma Mapbiomas e representam os dados da coleção 6.0 para o ano de 2022 (Mapbiomas, 2023). Com o objetivo de avaliar áreas de pastagens, foram sorteados 100 pontos aleatórios em áreas de pastagens, para evitar o enviesamento decorrente do agrupamento espacial das amostras (Santos et al., 2016).

Em virtude da dinâmica do uso da terra verificada nos trabalhos de campo (campanhas de 2022 e 2023) pela substituição das áreas de pastagens por cultivos agrícolas cada ponto sorteado foi verificado se na imagem de 2023 o piquete de pastagem era persistente.

A partir dos 100 pontos gerados anteriormente, foram vetorizados em tela os polígonos para a área de pastagem correspondente. Nessa vetorização, adotada como referência, foram levados em conta os limites texturais (como estradas ou linhas de vegetação), cor e geometria.

2.3 Segmentação de imagens

A composição colorida foi então segmentada por meio do algoritmo *mean shift*, utilizando três configurações para o detalhe espectral, espacial e o tamanho mínimo do segmento, conforme a Tabela 1.

Tabela 1. Configuração dos parâmetros de segmentação para o *mean shift*.

Segmentação	Espectral	Espacial	Tamanho mínimo
S19_5_15	19	5	15
S19_15_30	19	15	30
S155_15_20	15.5	15	20

Os arquivos matriciais gerados das três combinações foram então transformados para o formato vetorial. Uma vez que a acurácia posicional é a distância relativa entre o dado espacial e o terreno ou um valor de referência (Fonte et al., 2017; Santos et al., 2016), para comparar os limites dos polígonos gerados pelo *mean shift* e a vetorização em tela foi estabelecido um ponto central no polígono de referência e a partir dele, no eixo *y* representado pelo sentido Norte-Sul (N-S) e no eixo *x* por Leste-Oeste (L-O), foi calculada a distância relativa (*d*) entre os limites dos dois polígonos nos quatro pontos distintos N, S, O e L (Figura 1). Dessa forma, valores positivos são encontrados quando o limite da segmentação está fora do polígono de referência (ponto O) e valores negativos, quando o limite da segmentação está dentro do polígono de referência (pontos N, L e S). Com base nos valores de *d*, foi calculada a acurácia posicional das linhas por meio da raiz do erro quadrático médio (RMSE).




Figura 1. Representação da relação espacial dos polígonos de referência e da segmentação com as distâncias relativas *d* nos pontos N, S, O e L.

3. RESULTADOS E DISCUSSÃO

A partir da vetorização em tela, foram obtidos 100 polígonos de referência em área de pastagens (Figura 2A). Com as três configurações dos parâmetros de segmentação, foram obtidos três mapas de áreas de pastagens segmentadas (Figuras 2B, 2C e 2D).

Segundo o comportamento estabelecido por relações matemáticas e do *software*, as definições dos detalhes espectral e espacial variam para valores tendendo a 20 (valor máximo) quando os segmentos comportam-se com menor suavização e “agregação” entre os pixels. Quanto ao fator valor mínimo do segmento, segmentos menores que o valor especificado serão mesclados com seu agrupamento vizinho de melhor ajuste (ESRI, 2023a). Com isso estabelecido, é possível dizer que, mesmo com um parâmetro isolado definido, a segmentação dependerá também da combinação de variáveis entre si para a decisão final de agrupamento dos pixels em regiões. Antunes (2003) comenta que não existe um modelo formal para a segmentação, e que os limites definidos devem variar conforme a complexidade dos alvos investigados.




Figura 2. Composição colorida em áreas de pastagens com o polígono de referência (A), com a segmentação S19_5_15 (B), com a segmentação S19_15_30 (C) e com a segmentação S155_15_20 (D).

Segundo o referencial teórico para subsidiar o entendimento da extrapolação e omissão de áreas entre a verdade de campo e a segmentação, foi encontrado o conceito de “consistência topológica”. Segundo França e Portugal (2022), no contexto de um sistema de informações geográficas (SIG), a consistência topológica está relacionada à verificação da adequação dos relacionamentos espaciais de suas geometrias às situações identificadas no mundo real, neste trabalho entendidos como as regiões segmentadas e os polígonos de verdade de campo, respectivamente.

A validação topológica é uma das etapas estabelecidas da Metodologia de Conversão de Dados Geoespaciais da Secretaria do Patrimônio da União (SPU). A modelagem de dados geoespaciais utilizada na Especificação Técnica para Estruturação de Dados Geoespaciais Vetoriais do Patrimônio Público Federal (ET-EDGV) gerou um modelo que compõe primitivas geográficas para modelar a geometria e a topologia dos dados. Dentre as propriedades previstas na descrição dos modelos, existe a que se denomina “perto de”, que se encaixa melhor nos objetivos do trabalho, assim definido por Borges et al. (2005): “Duas instâncias de classes de objetos próximas, a uma distância “d”. Esta distância poderá ser euclidiana, um raio ou qualquer outra definida pelo usuário”. Além disso, pressupõe que uma das instâncias das classes que se relacionam tenha a geometria do tipo polígono. A norma ISO 19157:2013 estabelece, dentre seis categorias, a “consistência lógica” (elemento consistência topológica) e “acurácia posicional” (elemento acurácia posicional absoluta e relativa), que descrevem a qualidade das feições com base na “completude”, uma taxa que relaciona número de omissão e comissão dos dados dentro de uma área.

Assim, foi calculada a intensidade (distância em metros) de erro para todas as colunas positivas e negativas de cada ponto cardeal (N, S, L e O) e em cada uma das três segmentações, para obter os resultados das médias dos erros, bem como o desvio-padrão que são apresentados na Tabela 2.

Tabela 2. Três combinações de segmentação, média dos seus valores positivos (N-S-L-O) e negativos (N-S-L-O), e quantidade de casas ocupadas por cada um desses valores em relação ao total (400 análises).

Segmentada	Média positiva	Média negativa	Quant. de ocorrências positivas	Quente. de ocorrências negativas	D.P. ocorrências positivas	D.P. ocorrências negativas	RMSE
155_15_20	95,16m	-36m	272	128	125,96	34,33	155,2
19_15_30	59,61m	-46,12m	218	182	68,67	49,50	73,7
19_05_15	40,59m	-61,90m	182	218	44,61	73,16	103,6

A combinação 155_15_20 apresentou maior média positiva em relação ao polígono de checagem, isto é, os segmentos gerados foram maiores que os polígonos de referência, resultado reforçado pela quantidade de valores positivos de d (272), e também apresentou o maior valor para a RMSE.

Em seguida, com o mesmo comportamento, apresenta-se a combinação 19_15_30, porém com menos valores positivos para d (218) e com menor intensidade de aumento de área, salientada por uma média menor. Houve diminuição do valor do desvio-padrão, e também menos flutuação nessa estratégia, na qual o RMSE desta segmentação foi o mais baixo.

A discussão acerca dos parâmetros pode ser baseada na alteração do parâmetro espectral (acrécimo de 3.5), que resultou em uma classificação mais detalhada. Por tratar-se de um uso (pastagem) que apresenta características espectrais semelhantes em campo, atribuir classes distintas é de alta relevância para discriminação dos “objetos” entre si. Com o aumento do tamanho mínimo do segmento (acrécimo de 10 pixels) a agregação entre os segmentos foi menor, uma vez que puderam ter maior independência para formar uma região com um valor mínimo de 30 pixels. Isso pode ser significativo, uma vez que a variação de 10 pixels na verdade de campo pode ser pouco relevante, e contribuir para distâncias (erros) menores entre a segmentação 19_15_30 e os pontos de checagem. É válido lembrar que, segundo a ESRI (2023b), o valor padrão indicado pelo software é 20.




Figura 3. Distribuição das medidas de distâncias entre os limites dos polígonos de referência e da segmentação S19_5_15 (1), da segmentação S19_15_30 (2) e da segmentação S155_15_20 (3).

Comparadas a segmentação 19_15_30 e a segmentação 155_15_20, há uma diminuição de 10 para o detalhe espacial. Isso influenciou diretamente o processo de fragmentação excessiva, pois os pixels não são atribuídos às classes, o que aumenta para 218 as ocorrências de distâncias internas aos polígonos de verdade de campo. Em relação ao desvio-padrão negativo, também foram obtidos resultados mais variáveis de distâncias em relação à segmentação 19_15_30.

Analisando a proporção de D.P., principalmente de forma visual, a segmentação 2 apresenta aceitação maior quanto à verdade de campo que a segmentação 3. Apesar de fragmentar positivamente (polígonos maiores que a referência), esse avanço não foi tão saliente quanto o da segmentação 155_15_20.

4. CONCLUSÃO

A melhor combinação para representar a classe “pastagem” foi encontrada na segmentação 19_15_30, com valores de parâmetro espectral, espacial e de tamanho mínimo de segmento de 19, 15 e 30, respectivamente.

Ao longo da pesquisa, foram percebidas diversas diretrizes que regem a construção da comparação espacial entre feições em produtos cartográficos. Apesar de a pesquisa ter um enfoque no processo de segmentação, associar a qualidade dos produtos finais às classes e normativas de qualidade estatísticas pode sustentar uma discussão maior acerca do comportamento dos parâmetros altimétricos determinados nas ferramentas de SIG.



Embora o estudo tenha atendido ao propósito do projeto, a pouca quantidade de configurações de segmentações não permitiu estabelecer uma relação causal entre os parâmetros e os valores obtidos da RMSE.

5. AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela bolsa concedida à primeira autora. À Embrapa, pelo financiamento do projeto GeoPasto Cerrado.

6. REFERÊNCIAS

- ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 147 f. Tese (Doutorado em Ciências Geodésicas) – Setor De Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2003.
- BELLOLI, T. F.; GUASSELLI, L. A.; KUPLICH, T. M.; RUIZ, L. F. C.; SIMIONI, J. P. D. Classificação baseada em objeto de tipologias de cobertura vegetal em área úmida integrando imagens ópticas e SAR. **Revista brasileira de cartografia**, v. 74, n. 1, p. 67-83, 2022.
- BORGES, K. A. V.; CLODOVEU JUNIOR, A. D.; ALBERTO, H. F. L. Modelagem conceitual de dados geográficos. In: CASANOVA, M.; CÂMARA, G.; DAVIS, C.; VINHAS, L.; QUEIROZ, G. R. DE. **Banco de dados geográfico**. Curitiba: MundoGEO, 2005. p. 83-136.
- COMANICIU, D.; MEER, P. Mean Shift Analysis and applications. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION, 17., 1999, **Proceedings....** p. 1197-1203.
- COSTA, W. S. **Segmentação de imagens de sensoriamento remoto baseada em séries temporais e DTW**. São José dos Campos: INPE, 2019.
- DLUGOSZ, F. L.; ROSOT, N. C.; ROSOT, M. A. D.; OLIVEIRA, Y. M. M. DE. Índice para a avaliação de segmentação de imagens. **Floresta**, v. 39, n. 1, 2009.
- DRONOVA, I. Object-based image analysis in wetland research: a review. **Remote Sensing**, v. 7, n. 5, p. 6380–6413, 2015.
- ESRI. ARCGIS PRO. **Accuracy Assessment**. Disponível em: <https://esri.com/en-us/arcgis/products/arcgis-pro/overview>. Acesso em: 29 maio, 2023a.
- ESRI. ARCGIS PRO. **The Image Classification Wizard**. Disponível em: <https://Pro.Arcgis.Com/En/Proapp/Latest/Help/Analysis/Image-analyst/Theimage-classification-wizard.htm>. Acesso em: 29 maio, 2023b.
- FONTE, C. C.; ANTONIOU, V.; BASTIN, L.; ESTIMA, J.; ARSANJANI, J. J.; BAYAS, J.-C. L.; SEE, L.; VATSEVA, R. Assessing VGI data quality. In: FOODY, G.; SEE, L.; FRITS, S.; MOONEY, P.; OLTEANU-RAMOND, A-M.; FONTE, C. C.; ANTONOU, V. (ed.). **Mapping and the citizen sensor**. London: Ubiquity Press, 2017. p. 137-163.
- FRANÇA, L. L. S. DE; PORTUGAL, J. L. Consistência Topológica de dados Geoespaciais. **Revista Brasileira de Cartografia**, v. 74, n. 3, 2022.



HENG, L.; CHAO, L.; NAI-WEN, L.; JIA-WEI, G. Segmentation of high spatial resolution remote sensing images of mountainous areas based on the improved mean shift algorithm. **Journal of Mountain Science**, v. 12, p. 671–681, 2015.

MAPBIOMAS. **Mapeamento anual de cobertura e uso da terra do Brasil**. Coleção 6. Disponível em: <https://mapbiomas.org/>. Acesso em: 24 mar. 2023.

MOREIRA, L.; ASSAD, E. D. Segmentação e classificação supervisionada para identificar pastagens degradadas. WORKSHOP BRASILEIRO DE GEOINFORMÁTICA, 2., 2000, São Paulo. **Anais...** São Paulo: Sociedade Brasileira de Computação, 2000.

SANTOS, A. DE P. DOS; RODRIGUES, D. D.; SANTOS, N. T.; GRIPP JUNIOR, J. Avaliação da acurácia posicional em dados espaciais utilizando técnicas de estatística espacial: proposta de método e exemplo utilizando a norma brasileira. **Boletim de Ciências Geodésicas**, v. 22, p. 630-650, 2016.

ZHOU, J.-X.; LI, Z.-W.; FAN, C. Improved fast mean shift algorithm for remote sensing image segmentation. **IET Image Processing**, v. 9, n. 5, p. 389–394, 2014.