

Uso do algoritmo divisão K-médias adaptado para definição de background em imagens do Landsat 8

Rodrigo Augusto Rebouças ¹
Rafael Duarte Coelho dos Santos ²
Mateus Habermann ¹
Elcio Hideiti Shiguemori ¹

¹ Instituto de Estudos Avançados – IEAv/DCTA
Caixa Postal 6044 - 12228-970 – São José dos Campos - SP, Brasil
{rodrigo.pressa, habermann, elciohs}@gmail.com

² Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
rafaeldcsantos@gmail.com

Abstract. In this paper the use of adaptive bisecting K-Means is addressed for setting a background in images of Landsat 8. The bands 4, 3 and 2 were considered. The technique used in the study is the K-Means with some adjustments to separate images into clusters. It was considered the variance in brightness, clouds, snow and other clusters with images without the presence of those variables, to define a background image. Different set of images with lake, desert, mountain and urban scenarios have been tested. Promising results were presented with these techniques.

Palavras-chave: K-means, image processing, background, K-médias, processamento de imagens, plano de fundo.

1. Introdução

O uso de imagens orbitais tem grande importância nas áreas de sensoriamento remoto Schowengerdt (2006), processamento de imagens e visão computacional Cardim et al. (2014) e Chitra et al. (2014). A disponibilidade de dados e imagens de sensoriamento remoto tem crescido nos últimos anos, com ela, a necessidade de extração automática de informações tem aumentado, no entanto, um problema frequentemente encontrado no processamento automático destes dados é a influência de fatores externos, como presença de nuvens, neblina e sombras Xu et al. (2014). Portanto, a identificação de uma boa imagem padrão, ou background (plano de fundo), é de grande importância em processos automáticos.

Em diversos trabalhos, o foco principal é encontrar influências Xu et al. (2014) e atributos, como por exemplo: cor e textura Benarchid et al. (2013), modelo de iluminação e refletância Shen et al. (2014), segmentação Saranya (2014) e agrupamento Jain et al. (2014) e Tan et al. (2005), mas não estimar uma imagem *background*.

Este trabalho faz uso do algoritmo de divisão K-médias adaptado para definir uma imagem *background*, a modificação foi necessária pois em testes iniciais, o algoritmo padrão do K-médias não apresentou resultados satisfatórios devido a distribuição dos dados.

Como estudo de caso, o trabalho faz uso de imagens do Landsat 8, que em 30 de maio de 2013, os dados deste satélite tornaram-se disponíveis no site USGS (2014).

2. Metodologia

O primeiro passo é a aquisição de um conjunto de n imagens do mesmo tamanho. Toda a metodologia acontece na leitura *pixel a pixel* de n imagens.

Primeiramente percorre-se o primeiro *pixel* de todas as imagens simultaneamente e extrai-se a informação de média ponderada de uma vizinhança 3 por 3 dando um peso maior no *pixel* central em todas as imagens, os atributos das bandas 2, 3 e 4 e também o valor da saturação,

obtido através dos canais HSV, com isso é formado um vetor de atributos do pixel para cada leitura *pixel a pixel*.

Com o vetor de atributos, para cada *pixel* do conjunto de imagens é aplicado o K-médias Selim e Ismail (1984) a fim de separar o vetor em 2 *clusters*, em um com conjunto de imagens com influência de fatores externos e outro com um conjunto de imagens boas para retornar uma imagem *background* para aquele vetor de pixel.

Para este problema é empregada a divisão K-médias proposta por Savaresi e Boley (2001) com algumas simplificações, como será mostrado nos próximos passos.

Para definir os centroides iniciais é feito o uso das próprias médias dos pontos do vetor, para garantir que o centroide não ficará com o *cluster* vazio, ou ser um *cluster* inicial pobre, inicialmente são definidos dois centroides k .

Em seguida é atribuído para cada ponto do vetor o centroide mais próximo com uso da distância Euclidiana Quadrada (Equação 1) no espaço Euclidiano RGB e V do HSV:

$$d(P, C) = \sqrt{\sum_{i=1}^n \sum_{j=1}^k (p_i - c_j)^2} \quad (1)$$

Onde, P são os pontos (p_1, p_2, \dots, p_n) do vetor, C os centroides (c_1, c_2, \dots, c_k) e k o número de centroides.

Em seguida, enquanto os centroides não mudarem, é recalculado o centroide C de cada *cluster* j pela média dos pontos m pertencentes ao *cluster* (Equação 2):

$$C_j = \frac{1}{m_j} \sum_{p \in C_j} p \quad (2)$$

Por se tratar de um conjunto pequeno de dados, esse processo é calculado entre 2 a 10 vezes, até os centroides não mudarem. Com *clusters* formados, o algoritmo separou bem as imagens entre *background* e as com influência de fatores externos, entretanto as imagens consideradas boas pelo algoritmo, algumas tinham variância principalmente por causa do brilho, para corrigir esse problema, foi necessário subdividir o *cluster* com as imagens boas, para fazer uma separação melhor de um conjunto de dados.

O critério para criação do novo *cluster* é a partir do *cluster* com o maior número de imagens estabilizadas, isso deve pelo fato de ter um maior conjunto de dados bons, do que ruins, com o maior *cluster* é atribuído o novo *cluster* o ponto que estiver com a maior distância euclidiana.

Em seguida repete-se o passo para calcular seus vizinhos mais próximos e recalculando seus centroides até que não haja mais mudanças, para melhorar a amostragem dos dados. Para finalizar é atribuído o centroide com a melhor amostragem de dados para uma matriz resultante que gera um *background*.

O próximo passo é extrair o conjunto de dados do próximo pixel e repetir todos os passos da metodologia até o final da imagem, gerando uma imagem *background* para ser utilizada em outras aplicações. A metodologia é ilustrada na Figura 1.

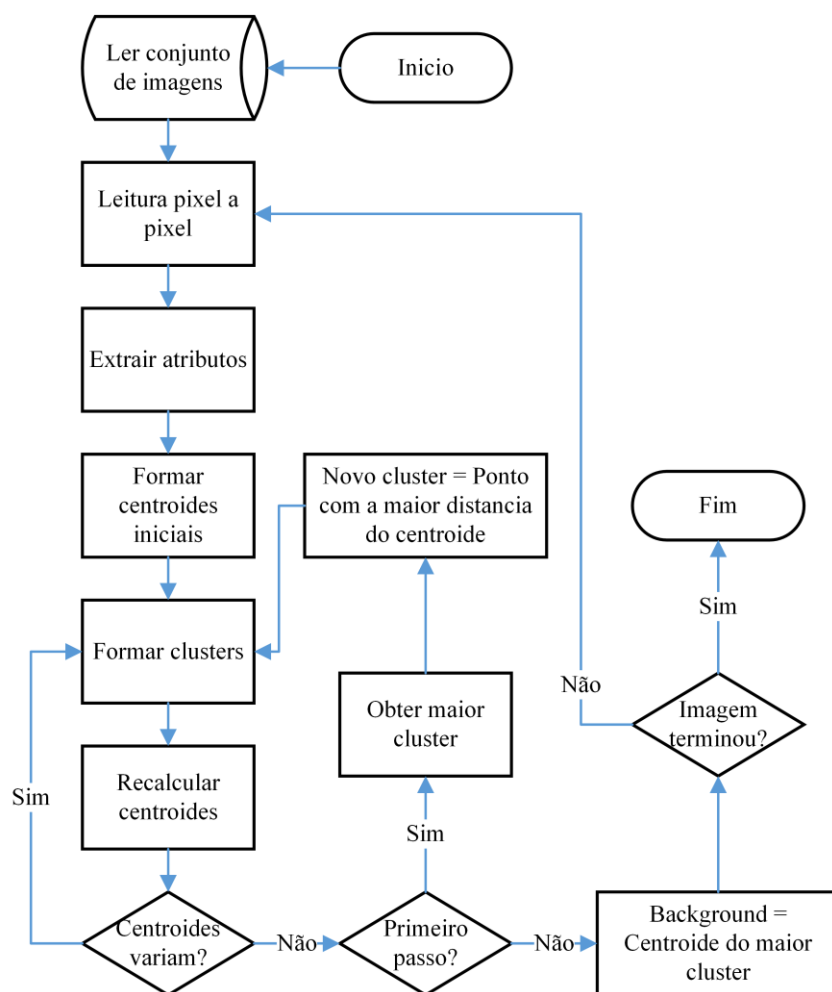



Figura 2. Fluxograma da metodologia.

3. Aquisição de Imagem

O trabalho faz uso das imagens do Landsat 8 em datas que variam de maio 2013 até maio de 2014, em um período de 16 dias para cada imagem no site de USGS na zona do lago Great Salt (Figura 2.a), Utah, EUA, na latitude 41.1158 e longitude -112.4768 e de uma parte do Vale do Paraíba (Figura 2.b), Brasil, na latitude -23.2237e longitude -45.9009.



(a)



(b)

Figura 2. Exemplo de imagem do conjunto de imagens do Landsat 8 da zona de Utah, USA (a) e do Vale do Paraíba, Brasil (b).

Neste trabalho faz uso do instrumento *Operacional Terra Imager (OLI)* do Landsat 8 apenas com as bandas multiespectrais 2, 3 e 4, ambas com resolução de 30 metros, para gerar o resultado da cor natural RGB. Para fazer a combinação dessas bandas, teve uso do Programa ENVI, onde foi feito as combinações das bandas e o corte das imagens.

4. Resultados e Discussão

A fim de testar a metodologia para definir um *background*, foram testadas diferentes quantidades de conjunto de imagens de resolução 4407 x 4803px da região dos EUA em comparação com um *background* já existente, para melhor visualização e análise dos resultados foram divididos em 4 casos de diferentes áreas: lago, deserto, montanha e urbana e com diferentes conjunto de imagens: 5, 10, 18 e 23.

No primeiro caso, faz uso de região com lago, como mostrada na Figura 3 uma parte do lago Great Salt, com variância de iluminação e presença de nuvens.




Figura 3. A imagem (a) representa o plano de fundo com um conjunto de 5 imagens e (b) com um conjunto de 23 imagens.

Como pode ser observado na Figura 3.a com um conjunto de 5 imagens não foi possível definir uma imagem *background*, entretanto a partir de 10 imagens diminui os fatores externos e os conjuntos a partir de 23 imagens na Figura 3.b o *background* está estável, como mostrado na Tabela 1 a mudança entre os conjuntos de imagens, através da distância quadrática entre as imagens.

Tabela 1. Resultados do primeiro caso, região de lago.

Conjunto de Imagens	Distancia Quadrática
5	17.11
10	12.10
18	10.14
23	5.79

Como pode ser observado na Tabela 1 conforme maior o conjunto de imagens, a diferença entre as imagens vai diminuindo, ou seja, forma-se um melhor *background*.

No segundo caso, faz uso de região de deserto, como mostrada na Figura 4, com variância de iluminação e presença de nuvens.




Figura 4. A imagem (a) representa o plano de fundo com um conjunto de 5 imagens e (b) com um conjunto de 23 imagens.

Como pode ser observado na Figura 4.a aparentemente os 2 conjuntos apresentaram um *background* similar, porém como mostrado na Tabela 2 as imagens apresentam diferenças.

Tabela 2. Resultados do segundo caso, região de deserto.

Conjunto de Imagens	Distancia Quadrática
5	8.38
10	19.37
18	7.18
23	4.34

No terceiro caso, faz uso de região montanhosa, como mostrada na Figura 5, com variância de iluminação, presença de nuvens e neve.




Figura 5. A imagem (a) representa o plano de fundo com um conjunto de 5 imagens e (b) com um conjunto de 23 imagens.

Como pode ser observado na Figura 5, ambas os conjuntos definiram um *background* similar, como apresentado no caso anterior, entretanto a Figura 5.b teve um realce melhor de

brilho, como mostrado na Tabela 3 a mudança entre os conjuntos de imagens, através da distância quadrática entre as imagens.

Tabela 3. Resultados do terceiro caso, região montanhosa.

Conjunto de Imagens	Distancia Quadrática
5	19.95
10	16.36
18	14.36
23	10.69

No quarto caso, faz uso de região urbana, faz uso da cidade de Las Vegas, como mostrada na Figura 6, com variância de iluminação, presença de nuvens e neve.



Figura 6. A imagem (a) representa o plano de fundo com um conjunto de 5 imagens e (b) com um conjunto de 23 imagens.

Como pode ser observado na Figura 6 ambos os conjuntos definiram um *background*, como mostrado na Tabela 4 a mudança entre os conjuntos de imagens, através da distância quadrática entre as imagens.

Tabela 4. Resultados do quarto caso, região urbana

Conjunto de Imagens	Distancia Quadrática
5	14.89
10	18.75
18	14.18
23	8.80

Para finalizar, na Tabela 5 é apresentada a distância quadrática de toda a imagem, afim de confirmar os dados dos 4 casos considerados no trabalho.

Tabela 5. Resultados da distância quadrática em toda a imagem com os diferentes conjuntos de imagens.

Conjunto de Imagens	Distancia Quadrática
5	18.47
10	18.82
18	13.02

Após testar a metodologia com um background já existente, foram realizados testes exploratórios em um conjunto de imagens de outra região. O teste foi realizado com uso de imagens do Vale do Paraíba, onde a presença de nuvens e neblinas são frequentes. Como não existe uma imagem *background* pré-definida, pois todas as imagens apresentam algum tipo de fator externo, trata-se apenas de um trabalho exploratório. Na Figura 7 são ilustradas as imagens teste.




Figura 7. Conjunto de 15 imagens do Landsat-8 do Vale do Paraíba.

Visualmente, o *background* gerado pelo algoritmo, como apresentado na Figura 8, melhora na medida em que a quantidade de imagens aumenta. Com uso de 5 imagens são observadas falhas na imagem *background*. Com uso de 10 e 15 imagens o algoritmo remove influências externas como nuvens.

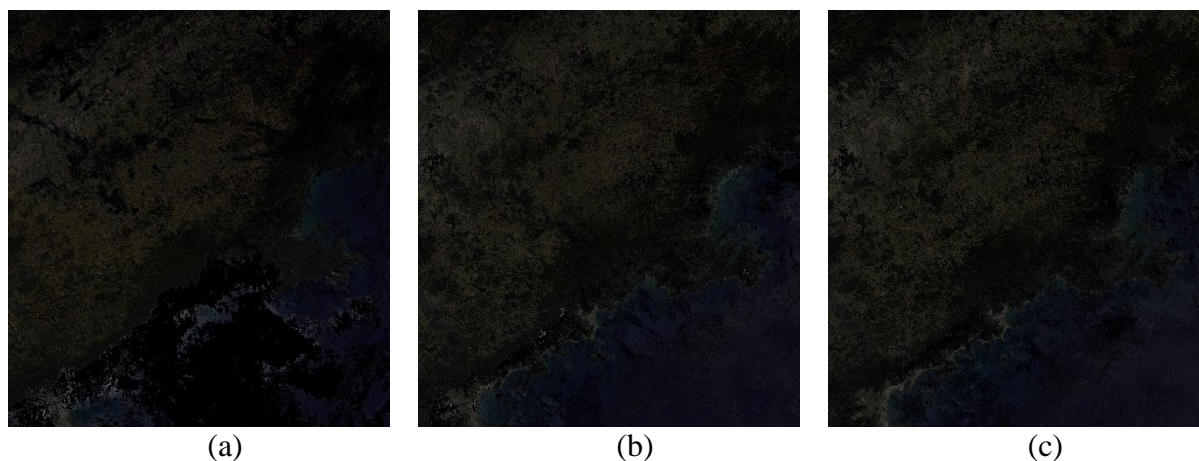


Figura 8. Resultado com uso de 5 imagens (a), 10 imagens (b) e 15 imagens (c).

5. Conclusões

Os resultados indicam que as técnicas apresentadas na metodologia podem ser aplicadas para definição de uma imagem *background* com uso de um conjunto de imagens de uma mesma região e obtidas em tempos diferentes. A metodologia é promissora pois elimina influências externas. Observa-se que quanto maior o conjunto de imagens, melhor a definição do *background*.

Porém, este estudo está em desenvolvimento e outras abordagens serão consideradas para fazer o agrupamento, extração de atributos e a validação dos *clusters*, para que em trabalhos futuros, possam ser usados outros atributos e bandas. Além de fazer uso de outros conjuntos de imagens do Landsat-8 para testar melhor a eficiência do algoritmo.

Agradecimentos

Agradecimentos ao CNPq, processo no.: 560190/2010-7.

Referências Bibliográficas

- Benarchid, O.; Raissouni, N.; El Adib, S.; Abbous, A.; Azyat, A.; Achhab, N. B.; Chahboun, A. Building extraction using object-based classification and shadow information in very high resolution multispectral images, a case study: Tetuan, Morocco. **Canadian Journal on Image Processing and Computer Vision**, v. 4, p. 1-8, 2013.
- Cardim, G. P.; da Silva, E. A.; Dias, M. A. Algorithm Development for Analysis of Statistical Accuracy of the Extraction of Cartographic Features in Digital Images. **Transactions on Machine Learning and Artificial Intelligence**, v. 2, p. 32-47, 2014.
- Chitra, S.; Subash, R.; Premalatha, C. Vegetation of Low Cost Remote Sensing Images by Mean Shift Algorithm, v. 3, 2014.
- Jain, P. M.; Gawande, D. A.; Gautam, P. L. Image Mining for Image Retrieval Using Hierarchical K-Means Algorithm. **International Journal of Research in Computer Engineering & Electronics**, v. 2, 2014.
- Saranya, K. Classification of High-Resolution Remotely Sensed Image by Combining Spectral, Structural and Semantic Features Using SVM Approach, 2014.
- Savaresi, S. M.; Boley, D. L. On the performance of bisecting K-means and PDDP. In *SDM*, p. 1-14, 2001.
- Schowengerdt, R. A. **Remote sensing: models and methods for image processing**. Academic press, 2006.
- Selim, S. Z.; Ismail, M. A. K-means-type algorithms: a generalized convergence theorem and characterization of local optimality. *IEEE Trans. On Pattern Analysis and Machine Intelligence*, v. 6, p. 81-86, 1984.
- Shen, L.; Li, Z.; Guo, X. Remote Sensing of Leaf Area Index (LAI) and a Spatiotemporally Parameterized Model for Mixed Grasslands. **International Journal of Applied**, v. 4, 2014.
- Tan, P. N.; Steinbach, M.; Kumar V. **Introduction to Data Mining**. Addison-Wesley, 2005.
- U.S. Geological Survey (USGS): Science for a changing world. Disponível em: <<http://www.usgs.gov/>>. Acesso em: 14.maio.2014.
- Xu, M.; Jia, X.; Pickering, M. Automatic cloud removal for Landsat 8 OLI images using cirrus band. **Geoscience and Remote Sensing Symposium (IGARSS)**, p. 13-18, 2014.