



# UTILIZAÇÃO DO ALGORITMO K-MÉDIAS PARA A FILTRAGEM E CLASSIFICAÇÃO DE DADOS LIDAR

R. A. R. Oliveira<sup>1</sup>, M. Galo<sup>1,2</sup>

<sup>1</sup> Universidade Estadual Paulista, Brasil  
Faculdade de Ciências e Tecnologia – FCT, Presidente Prudente - SP  
<sup>2</sup> Departamento de Cartografia

Comissão IV – Sensoriamento Remoto, Fotogrametria e Interpretação de Imagens

## RESUMO

Este trabalho apresenta uma metodologia de filtragem e classificação de dados obtidos por sistemas LiDAR (*Light Detection And Ranging*) embarcados em plataformas aerotransportadas. Estes sistemas são baseados na integração de sensores LASER (*Light Amplification by Stimulated Emission of Radiation*) com Unidades de Medidas Inerciais (IMU) e receptores GNSS (*Global Navigation Satellite System*) para gerar nuvens de pontos com coordenadas no espaço 3D. O principal interesse na área da cartografia para este tipo de dado é a geração de MDTs (Modelos Digitais de Terreno), bem como a extração de feições como edificações, vegetação, dentre outras. Para obter o MDT é necessário aplicar operações de filtragem e classificação de feições, que podem ser realizadas por diferentes técnicas. Neste trabalho foi desenvolvido em linguagem ANSI C, um procedimento que utilizou o algoritmo k-médias, bem como informações de atributos como entropia e desvio padrão das altitudes registradas, além de heurísticas computacionais visando eliminar inconsistências e melhorar os resultados. Os experimentos realizados com dados reais indicam que os resultados são coerentes, sendo necessários aprimoramentos no sentido de reduzir alguns erros na classificação.

**Palavras-chave:** Dados LiDAR, Algoritmo K-médias, Entropia.

## ABSTRACT

This paper describes a methodological approach to filtering and classifying data obtained by LiDAR (*Light Detection And Ranging*) systems that are embedded to airborne platforms. These systems are based on the integration of LASER (*Light Amplification by Stimulated Emission of Radiation*) sensors with Inertial Measurement Units (IMU) and GNSS (*Global Navigation Satellite System*) receivers to generate point clouds with the coordinates in 3D space. The main interest in the cartography area for this type of data is the generation of DTMs (Digital Terrain Models), as well as the extraction of features such as buildings, vegetation, among others. To obtain the DTM from this kind of data is necessary to apply filtering and features classification operations, which can be performed by different techniques. In this work, a procedure using the k-means algorithm, as well as attributes information such as entropy and standard deviation of the registered height, besides computational heuristics aiming to eliminate inconsistencies and improve the results were developed in ANSI C language. The experiments based on real data indicate that the results are coherent, besides some additional improvements that are needed to mitigate the misclassification errors.

**Keywords:** LiDAR Data, K-means Algorithm, Entropy.

## 1- INTRODUÇÃO

Conforme avançam as tecnologias para a aquisição de dados e mapeamento nas áreas de Fotogrametria e Sensoriamento Remoto, surgem novas técnicas para a realização destas tarefas. Dentre estas, uma que vem se destacando tanto pela agilidade do processo, quanto pela grande quantidade de informação que pode ser obtida, é a utilização dos sistemas ativos LiDAR, baseados na emissão e recepção de feixes LASER a partir de plataformas aerotransportadas, orbitais ou terrestres.

Os sistemas LiDAR, podem ser descritos como a integração de outras três tecnologias: sistema de varredura a LASER, sistema de medição inercial, e o sistema de posicionamento pelo GNSS (El-Sheimy et al., 2005). A aplicação deste tipo de dado vem sendo mais explorada nos últimos anos, para a geração e atualização de MDTs com alto grau de detalhamento (Vosselman, 2000). Entretanto, para isso é preciso a implementação de filtros e algoritmos que possam diferenciar os tipos de feições presentes em uma nuvem de pontos. Além das aplicações mais

usuais na área da cartografia, os dados LiDAR podem também ser utilizados para o controle de dados cadastrais nas áreas urbanas (Filin et. al., 2005) e no manejo ambiental (Silva et al., 2013), por exemplo.

A automação dos processamentos ligados a esta técnica de mapeamento é uma das motivações da comunidade científica da área, como se pode ver em Axelsson (1999) e Sithole e Vosselman (2005). Neste trabalho, o propósito central foi desenvolver um método para a filtragem e classificação de pontos gerados por um sistema LiDAR, utilizando o algoritmo k-médias, com base em métricas como desvio padrão e entropia das altitudes dos pontos da nuvem, além da incorporação de heurísticas adicionais visando a correção de alguns erros na classificação. Para isso, foram implementados algoritmos na linguagem ANSI C, além da utilização de funções da biblioteca FLANN (*Fast Library for Approximate Nearest Neighbors*) e do *software Octave* para a visualização de alguns resultados.

Na análise dos resultados obtidos pela classificação da nuvem de pontos foram utilizadas imagens ópticas da região de trabalho, além da comparação com os resultados proporcionados pela biblioteca LAStools (Isenburg, 2011), amplamente utilizada no processamento de dados LiDAR.

## 2- DESCRIÇÃO DO MÉTODO

A partir dos dados de varredura LiDAR de uma parte do município de Presidente Prudente, São Paulo, obtidos com o sistema RIEGL LMS-Q780 em Dezembro de 2014, pela empresa Sensormap Geotecnologia, foi escolhida uma área urbana onde seriam realizados os testes do algoritmo. A densidade média da nuvem de pontos da área escolhida é da ordem de 13,5 pontos/m<sup>2</sup>.

Primeiramente, os pontos selecionados para o processamento foram amostrados em uma grade bidimensional regular com espaçamento definido pelo usuário e, desta forma, ao final do processamento, cada célula desta grade teria uma classe associada. A partir destes pontos da grade regular, foi estabelecida uma vizinhança, onde os cálculos dos atributos utilizados na classificação seriam realizados. A vizinhança  $V_r$  considerada foi estabelecida a partir de um raio ( $r$ ) contado a partir do centro de cada célula, aos pontos em coordenadas UTM (E, N) da nuvem original. No

estabelecimento da vizinhança  $V_r$  foi utilizada a função *Radius Search* presente na biblioteca FLANN. Portanto, com os pontos pertencentes à vizinhança de cada célula devidamente identificados, foi possível calcular os atributos descritos na Tabela 1.

Em Demantké et al. (2011) a entropia é utilizada no processamento de dados LiDAR, sendo calculada a partir de autovalores estimados para uma dada região. No presente caso a entropia (E) é estimada a partir das altitudes na vizinhança  $V_r$  no entorno de cada célula da grade, a partir da Equação 1.

$$E = \frac{\sum_{i=1}^n [-(h_i - h_{min} + \Delta) \ln(h_i - h_{min} + \Delta)]}{n} \quad (1)$$

Nesta equação  $h_i$  representa a altitude de um ponto genérico  $i$ , situado na vizinhança  $V_r$  estabelecida a partir do raio  $r$ , e  $h_{min}$  a altitude mínima nesta vizinhança. Na equação acima foi incluído o termo  $\Delta$ , que tem a função de evitar singularidade no caso de regiões planas onde  $h_i - h_{min} = 0$ . O valor adotado para este termo foi  $\Delta = 0,001$  m. Nota-se também que ao utilizar  $h_i - h_{min}$  está sendo estimado o valor da entropia para o MDSn (Modelo Digital da Superfície Normalizado).

Numa segunda etapa, os atributos foram testados e analisados através de um *script* no *software Octave*, visando identificar quais atributos seriam melhor aproveitados para a construção iterativa dos centroides de agrupamento pelo algoritmo k-médias disponível na biblioteca FLANN. Estes centroides variam de acordo com a quantidade de classes escolhidas para serem geradas. Após os testes, percebeu-se que, o atributo porcentagem de pontos próximos a altitude mínima gerava muitos ruídos na separação das classes, e os atributos desvio padrão e entropia possuíam certas características redundantes por destacarem regiões parecidas na nuvem. Portanto, para a obtenção dos centroides foi utilizado apenas a entropia das altitudes. Além disto, o número de classes iniciais foi definido como sendo três. De forma sintetizada, o método proposto e implementado é apresentado no fluxograma da Figura 1.

A etapa 3 consistiu na classificação propriamente dita, relacionando cada célula da grade uma classe, tendo como base o cálculo da menor distância dos valores de entropia aos centroides

Tabela 1 – Descrição dos atributos utilizados na classificação.

Atributo	Descrição
Desvio Padrão das altitudes	Dispersão estatística do valor de altitude em relação à média de altitude dos pontos na vizinhança $V_r$ considerada
Entropia das altitudes	Nível de desordem dos valores de altitude dos pontos na vizinhança $V_r$
Porcentagem de pontos próximos a altitude mínima	Proporção de pontos que estão abaixo de uma altura especificada, a partir do ponto de menor altitude, para uma dada vizinhança $V_r$

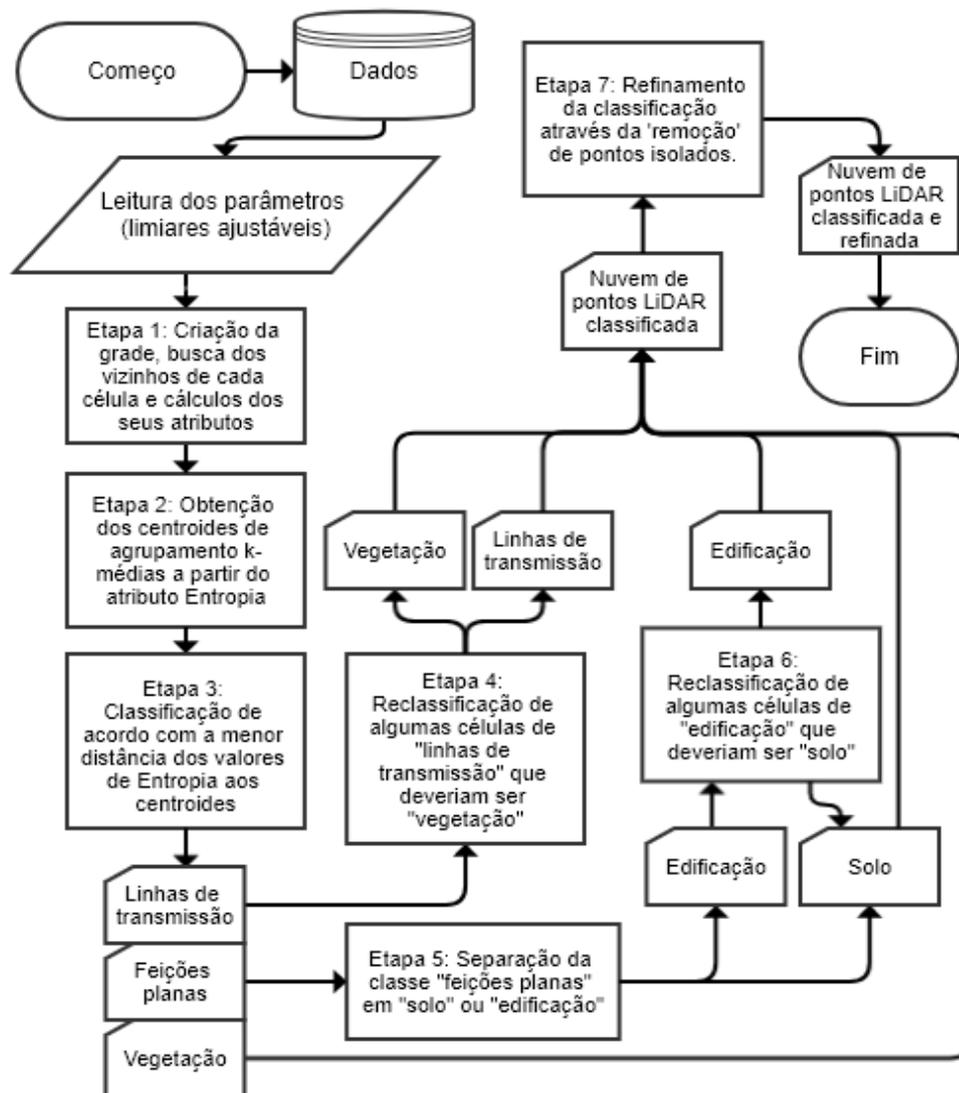


Figura 1 - Fluxograma das etapas realizadas.

determinados na etapa anterior pelo método de agrupamento k-médias.

Com as três classes separadas, observou-se que estas representavam três tipos de feições: vegetação, bordas (neste trabalho foram relacionadas também às linhas de transmissão) e feições planas. Apesar da classe “linhas de transmissão” incorporar as redes (elétricas e telefônicas) suspensas sobre os postes, foram também atribuídas muitas bordas e outras regiões (vegetação) nesta classe. Portanto, na etapa 4, foi realizada uma reclassificação de algumas células erroneamente enquadradas na classe “linhas de transmissão”. Este processo utilizou-se dos valores médios do atributo “Porcentagem de pontos próximos a altitude mínima” para linhas de transmissão, partindo do princípio de que em regiões com vegetação, os valores desse atributo tendem a serem menores, devido a ramificação das árvores.

A etapa 5 foi criada para separar as feições consideradas planas, nas classes solo e edificação. A

partir de um limiar de altura definido pelo usuário, e de outro raio ( $r_p$ ) determinado a partir do centro de cada célula classificada como “feição plana”, foi feita uma verificação que consistiu em comparar as diferenças de altitude entre pontos desta classe. Escolhendo o ponto com cota mais baixa ( $h_{min}$ ) num certo raio  $r_p$ , e considerando-o como solo, os pontos desta classe que estivessem dentro de  $r_p$  e que fossem menores que o limiar estabelecido também seriam definidos como solo, caso contrário seriam classificados como edificação. Embora esse procedimento tenha melhorado a classificação e separado as duas classes de feições, alguns pontos que estavam sobre carros e outros veículos que tem o teto “plano”, foram também considerados como edificações.

Apesar da etapa 5 separar a maioria dos pontos de solo e edificação, ainda houveram pontos da grade classificados erroneamente como edificações devido às variações do terreno e declividade de algumas regiões. Deste modo, na etapa 6, a partir de uma vizinhança-8 na grade, e com um processo

iterativo de correção a partir de um pequeno limiar de altura, os pontos de solo classificados de maneira errada como edificações foram corrigidos.

Após realizadas as seis etapas do procedimento apresentado, foram obtidos resultados parciais satisfatórios. No entanto, visando refinar e corrigir alguns *outliers*, foram programadas algumas funções que eliminariam, ou classificariam como pontos não identificados, alguns pontos que apareciam de forma isolada. Por exemplo, um ponto classificado como edificação, numa vizinhança-8 formada apenas por vegetação, pode ser resultado de um erro na classificação, ou ser uma edificação de pequena área. Neste caso, o mais coerente é enquadrá-lo como “não classificado”.

Resalta-se que o método proposto, diferente do apresentado em Oliveira e Galo (2017), conseguiu realizar a classificação de maneira automática devido à utilização do algoritmo k-médias, sendo informados apenas alguns limiares de altura e os raios das vizinhanças, que foram ajustados através dos testes realizados.

### 3- RESULTADOS

A imagem da nuvem de pontos LiDAR classificada pode ser vista na Figura 2b, onde o solo é representado na cor magenta, as edificações em vermelho, vegetação em verde e as linhas de transmissão em amarelo. Comparando visualmente a classificação em 2b com a imagem óptica (Figura 2a) das quadras analisadas, é possível perceber que o método apresenta resultados coerentes.

No detalhe da Figura 3, na região 1 destacada, nota-se o erro mais comum apresentado pelo método, onde grande parte das bordas de feições como telhados, e também algumas linhas de transmissão, são classificadas erroneamente como vegetação. Essa confusão, apesar de esperada, devido à dificuldade intrínseca dos dados LiDAR em distinguir linhas de

quebra, é agravada ainda mais pela criação da grade regular na classificação. A maioria das células que ficam nas regiões próximas as linhas de quebra, ou seja, regiões de bordas de edificações ou copas de árvores tem sua altitude real afetada por pontos com uma diferença muito grande de elevação na vizinhança, o que afeta também o cálculo da entropia.

Ainda na Figura 3 estão destacadas outras duas regiões que também apresentaram inconsistências geradas pelo método. Na região 2 observa-se regiões de bordas em vegetação, que pelo mesmo motivo da região anterior, tem células da grade classificadas erroneamente devido à confusão que a entropia das altitudes passa para o algoritmo k-médias. Na região 3 é indicada uma confusão entre as classes vegetação e edificação. Embora tenha ocorrido em menor frequência, este tipo de erro se encontra presente em regiões onde a vegetação tem aproximadamente a mesma altura ao redor da copa, e quando elas se encontram nas proximidades de algum telhado, o que leva o algoritmo a reconhecer a feição como plana.

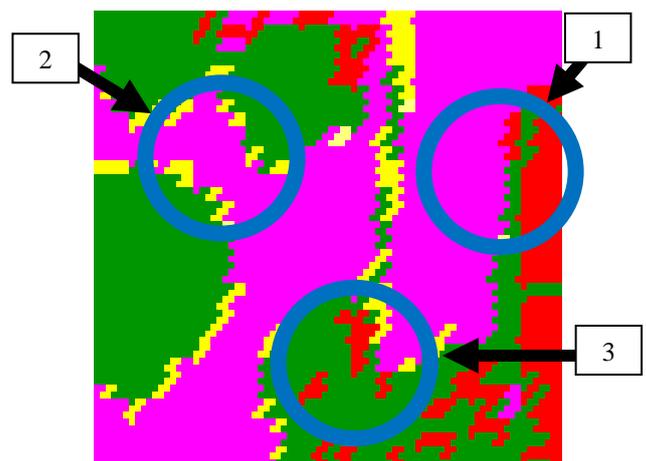


Figura 3 – Detalhes de regiões com células classificadas erroneamente.

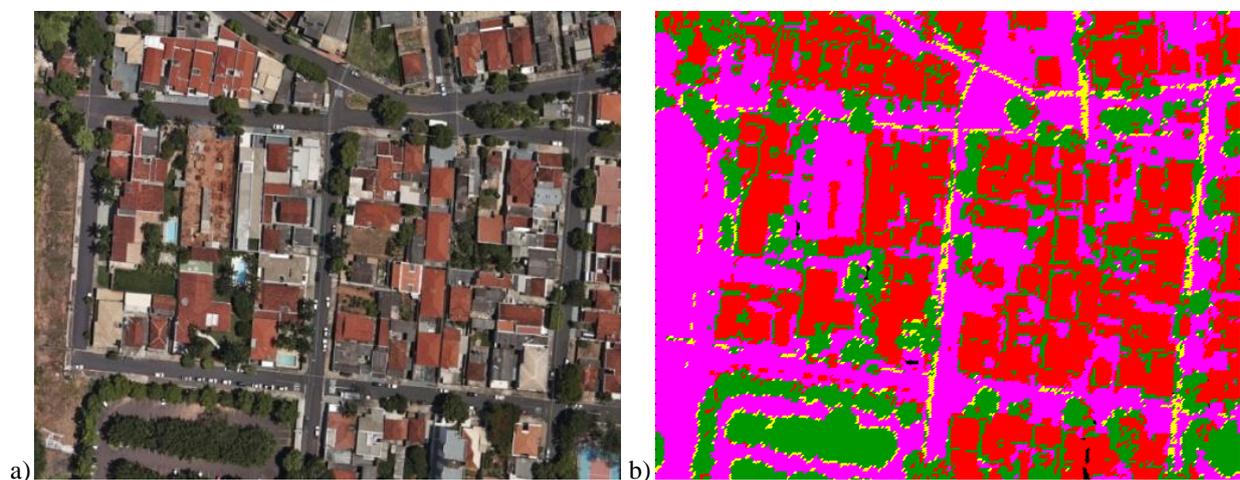


Figura 2 - Comparação entre a imagem óptica de referência (a) e a nuvem de pontos LiDAR classificada (b).

Apesar das incoerências apresentadas, ao comparar a classificação pelo método, com a classificação gerada pelo LAStools (Figura 4), percebe-se que as duas tem a maioria das regiões classificadas como o mesmo tipo de feição.



Figura 4 - Classificação pelo LAStools.

Apesar da importância da análise quantitativa dos resultados obtidos na classificação, pode-se observar que neste trabalho foi realizada apenas uma análise visual dos resultados obtidos, o que permitiu identificar aspectos que devem ser melhorados e otimizados na abordagem proposta. Vale também lembrar que os resultados apresentados foram obtidos em uma região onde a densidade de pontos é relativamente alta. Alguns testes preliminares foram também realizados em regiões com menor densidade, e os resultados se mostraram mais deteriorados, como esperado.

#### 4- CONCLUSÃO

Com os resultados obtidos e as análises realizadas, é possível constatar que, apesar dos resultados em grande parte das regiões serem coerentes, é preciso aprimorar o método, visando reduzir o erro na classificação.

Outro fato a destacar se refere a classificação das linhas de transmissão, que apesar da confusão gerada entre essa classe e algumas bordas, pode ter seus resultados refinados se houver uma ênfase maior para este tipo de feição.

Portanto, embora sejam necessários algumas melhorias no método, os procedimentos implementados se mostraram adequados e mostram que os algoritmos de classificação não supervisionados, neste caso o k-médias, podem ser utilizados como uma alternativa para classificar dados LiDAR. Como trabalhos futuros destaca-se a incorporação de funções e operações que visem refinar a extração de linhas de transmissão, a avaliação

quantitativa com base em índices de completude e correteza e a avaliação em dados com diferentes densidades.

#### AGRADECIMENTOS

Os autores agradecem à empresa SensorMap Geotecnologia, do grupo Engemap, pelo fornecimento dos dados LiDAR e das imagens da região de Presidente Prudente, e ao CNPq pela concessão da bolsa de iniciação científica ao primeiro autor.

#### REFERÊNCIAS BIBLIOGRÁFICAS

- Axelsson, P. 1999. Processing of laser scanner data – algorithms and applications. em ISPRS Journal of Photogrammetry and Remote Sensing. Vol. 54, p. 138-147.
- Demantké, J.; C. Mallet; N. David e B. Vallet, 2011. Dimensionality based scale selection in 3D LiDAR point clouds, em ISPRS Workshop on Laser Scanning 2011, Calgary Canada.
- El-Sheimy, N.; C. Valeo e A. Habib, 2005. Digital Terrain Modeling: Acquisition, Manipulation and Applications. USA: Artech House Remote Sensing Library, 1ª ed., p. 1-256.
- Filin, S.; Y. Kulakov e Y. Doytsher, 2005. Application of airborne LASER technology to 3D cadastre, em FIG Working Week 2015 and GSDI-8. Cairo, pp. 1-13.
- Isenburg, M., 2011. LAStools Software Suite. Disponível em: <<http://rapidlasso.com/lastools/download>>. Acesso em Outubro de 2016.
- Oliveira, R. A. R. e M. Galo, 2017. Classificação de feições na superfície através de dados LiDAR e medidas de entropia e desvio padrão das altitudes, em Anais XVIII Simpósio Brasileiro de Sensoriamento Remoto. Santos, p. 2892-2899.
- Silva, C. A.; C. Kaluberg; A. Hudak; R. Liebermann; S. de P. C. Carvalho e L. C. E. Rodriguez, 2013. Utilização da tecnologia LiDAR para estimação da biomassa florestal em povoamentos de *Eucalyptus SP*, em Anais do XVI Simpósio Brasileiro de Sensoriamento Remoto. Foz do Iguaçu, p. 6097-6104.
- Sithole, G. e G. Vosselman, 2005. Filtering of airborne laser scanner data based on segmented point clouds, em Proceedings of the ISPRS Workshop Laser scanning 2005. ISPRS Archives, Enschede, the Netherlands, Vol. 36, p. 66-71.
- Vosselman, G. 2000. Slope based filtering of LASER altimetry data, em IAPRS The International Archives. Vol. 33, Amsterdam, p. 935-942.