

INTEGRAÇÃO DE INFORMAÇÃO RADIOMÉTRICA PARA CLASSIFICAÇÃO DE NUVEM DE PONTOS OBTIDAS POR VARP

A. C. Carrilho¹, G. G. Pessoa¹, G. T. Miyoshi¹, M. Galo², A. Amorim²

Universidade Estadual Paulista, Brasil

Faculdade de Ciências e Tecnologia – FCT

¹ Programa de Pós-Graduação em Ciências Cartográficas – PPGCC

² Departamento de Cartografia

Comissão IV – Sensoriamento Remoto, Fotogrametria e Interpretação de Imagens

RESUMO

Métodos de classificação podem ser categorizados a partir da abordagem utilizada: supervisionada ou não supervisionada; por pixel ou por objetos; e pelo tipo de informação utilizada: radiométrica, geométrica ou ambas. Uma alternativa à utilização de sistemas LASER (*Light Amplification by Stimulated Emission of Radiation*) para a obtenção de informação geométrica consiste na geração de nuvem de pontos densas por correspondência de imagens. Este trabalho propõe uma abordagem simples para a classificação de nuvens de pontos geradas por correspondência de imagens aéreas adquiridas por veículos aéreos remotamente pilotados (VARP). O método proposto consiste de uma classificação supervisionada por pixel, baseado em uma árvore de decisões, onde são utilizadas informações radiométricas e de natureza geométrica. Os dados utilizados foram obtidos em um voo realizado sobre o distrito de Espigão, município de Regente Feijó-SP, utilizando uma câmara digital com as bandas R, G e NIR. A análise quantitativa da classificação indica que o método proposto apresenta problemas na distinção entre as classes de chão e asfalto, entretanto a acurácia temática global é aceitável.

Palavras chave: Classificação, Nuvem de Pontos, Veículo Aéreo Remotamente Pilotado

ABSTRACT

Classification methods can be categorized by the approach used: supervised or unsupervised; pixel-based or object-based; and by the information used: radiometric, geometric or both. An alternative to airborne LASER scanning systems point cloud generation is dense image matching. This paper proposes a simple point cloud classification, using data generated with remotely piloted aircraft systems (RPAS). The proposed method consists of a supervised pixel-based decision tree, in which both radiometric and geometric information are considered. The data used correspond to a flight performed over the Espigão district (within the Regente Feijó-SP municipality), using a digital camera with the R, G and NIR bands. The quantitative analysis of the results indicates that the proposed method presents problems to distinguish ground from asphalt, however the overall thematic accuracy is acceptable.

Keywords: Classification, Point Cloud, Remotely Piloted Aircraft System

1- INTRODUÇÃO

A identificação automática de alvos a partir de dados de sensoriamento remoto tornou-se um dos principais tópicos de pesquisa na comunidade científica nas últimas décadas, uma vez que os produtos temáticos resultantes das operações de classificação subsidiam diversas tarefas de planejamento e gestão, além de auxiliar na tomada de decisões. As abordagens usualmente empregadas nesses trabalhos distinguem-se a partir do tipo de informação utilizada: radiométrica, geométrica ou ambas. Dados radiométricos (imagens) estão associados às características físicas do alvo e ao

nível digital discretizado e registrado pelo sensor, enquanto que dados geométricos (nuvem de pontos) correspondem à informação tridimensional da superfície investigada, e geralmente são obtidos por técnicas de varredura a LASER (*Light Amplification by Stimulated Emission of Radiation*) aerotransportado ou técnicas fotogramétricas como a correspondência de imagens.

Apesar do esforço dos pesquisadores no desenvolvimento de procedimentos automáticos de classificação, a obtenção dos resultados com a acurácia desejada permanece como um desafio, como destacam

Awrangjeb et al. (2010). Os algoritmos precisam ser robustos o suficiente para lidar com as diversas estruturas presentes nas cenas, tais como as naturais (vegetação e hidrografia, por exemplo) e as antrópicas (edificações). Dentre os fatores complicadores referentes à classificação automática pode-se incluir a complexidade da cena, ausência de informações e/ou oclusões, e as características dos equipamentos utilizados na aquisição dos dados (Sohn e Dowman, 2007).

A complexidade da cena é um agravante principalmente em áreas urbanas, as quais necessitam de processamentos específicos. De forma geral a separação entre vegetação e edificações pode ser realizada a partir do cálculo de índices espectrais, como o *normalized difference vegetation index* (NDVI), por exemplo. Entretanto, a identificação correta desses alvos é prejudicada em situações onde ocorre a sobreposição de copas de árvores em telhados.

Os dados LiDAR (*Light Detection and Ranging*) são frequentemente utilizados em estudos de vegetação, pois podem ser associados à variáveis dendrométricas (Ali-Sisto e Packalen, 2017). A vantagem do uso de dados LiDAR para estudos de vegetação consiste no registro dos diversos retornos dos pulsos LASER emitidos, que penetram o dossel das árvores, e por vezes atingem a superfície do solo. De acordo com Buján et al. (2012), outra vantagem dos dados LiDAR com relação às nuvens de pontos obtidas por outras técnicas é a independência de condições atmosféricas, uma vez que o pulso LASER não é afetado por sombras e ângulo solar, por ser um sensor ativo.

Entretanto, a obtenção de dados LiDAR pode ser um complicador em termos práticos devido ao alto custo dos equipamentos necessários, principalmente para estudos realizados em pequenas áreas ou que necessitem de atualização ou aquisição dos dados com frequência. Uma alternativa é a geração de nuvem de pontos densas por correspondência de imagens, cujas técnicas apresentaram um avanço considerável nos últimos anos, principalmente com a introdução do *Semi-Global Matching* (SGM) por Hirschmüller (2005).

A classificação automática desses conjuntos de dados pode apresentar problemas quando estes são obtidos por sistemas de aquisição diferentes, isto é, informação geométrica (LiDAR) e informação radiométrica (imagens aéreas), por exemplo. A sinergia entre esses conjuntos de dados motivou sua integração visando aprimorar a qualidade dos resultados (Hermosilla et al., 2011; Buján et al., 2012; Malpica et al., 2013).

Com base no exposto, este trabalho propõe uma abordagem simples para a classificação de nuvens de pontos geradas por correspondência de imagens aéreas adquiridas por veículos aéreos remotamente pilotados (VARP).

2- DESCRIÇÃO DOS DADOS

Os dados utilizados nesse trabalho (Fig. 1) correspondem a uma nuvem de pontos gerada a partir de imagens obtidas em um voo realizado sobre o distrito de Espigão, do município de Regente Feijó, no oeste do estado de São Paulo. As coordenadas Universal Transversa de Mercator (UTM) aproximadas do centro da área de estudo são: E=463336 m, N=7545302 m, 22S. A área é caracterizada por uma mancha urbana na qual a maioria das edificações apresentam cobertura com telhas de barro, vegetação nas calçadas, áreas de solo coberto por vegetação rasteira e vias pavimentadas (asfalto).

Na área teste foram implantados oito (8) pontos de apoio, cujas coordenadas foram determinadas a partir do posicionamento por *Global Navigation Satellite System* (GNSS), pelo método relativo estático rápido. Destaca-se que, tais pontos foram implantados a fim de dar suporte ao processamento fotogramétrico e geração dos produtos, visando garantir a acurácia posicional das coordenadas.

A missão de voo realizada em janeiro de 2016 utilizou um VARP Sensefly eBee equipado com o sistema de posicionamento baseado em receptor GNSS, sistema inercial *Micro Electro Mechanical Systems* (MEMS) e câmara digital Cannon S110 NIR (*Near Infra-Red*), cujas bandas verde, vermelho e infra-vermelho próximo registradas pelo sensor correspondem aos comprimentos de onda 550 nm, 625 nm e 850 nm, respectivamente. O planejamento da missão foi realizado no programa Sensefly Emotion2, no qual configurou-se a altura de voo de 157 m, correspondente a um *ground sample distance* (GSD) de 5,5 cm, e também as sobreposições lateral e longitudinal de 70% e 80%, respectivamente.




Fig. 1 – Integração da informação radiométrica à geométrica. (a) Coloração a partir das altitudes, (b) composição falsa cor.

Para a geração do Modelo Digitais de Superfície (MDS) foram utilizadas as imagens adquiridas, as informações de orientação exterior aproximadas (georreferenciamento direto) e as coordenadas dos pontos de apoio. Os processamentos foram realizados no programa Pix4D Mapper Pro, o qual emprega o algoritmo *Structure from Motion* (SfM), que consiste da medição de pontos

fotogramétricos (extração de pontos de interesse), fototriangulação simultânea por feixes de raios perspectivos (*Bundle Block Adjustment*) e na correspondência de imagens para geração de nuvem de pontos densa (SGM).

O conjunto de dados resultante apresenta uma densidade média de 5,4 pontos/m², e um total de 266.712 pontos. Embora o formato LAS tenha sido proposto para a transferência e armazenamento de dados LiDAR, como por exemplo as coordenadas (X, Y, Z), ele permite a incorporação de outras informações tais como informações radiométricas (R, G, B) e o rótulo de cada ponto. Por esta razão os pontos gerados, e estas informações adicionais, foram armazenadas neste formato. Por conta da câmara utilizada no voo conter o infra-vermelho próximo além de duas bandas do espectro visível, as informações radiométricas foram codificadas no formato falsa-cor (R, G, NIR) ao invés das componentes (R, G, B).

3- MÉTODO DE CLASSIFICAÇÃO

O método de classificação supervisionado proposto (Fig. 2) consiste inicialmente na distinção dos pontos entre pertencentes ou não ao terreno (filtragem). Este processamento é realizado com o LAStools, o qual, segundo Motealegre et al. (2015), utiliza uma versão modificada do algoritmo de filtragem proposto por Axelsson (2000), o qual baseia-se em uma densificação progressiva de uma malha triangular irregular (*triangular irregular network* - TIN). Embora este método de filtragem tenha sido desenvolvido para dados LiDAR é possível processar nuvens de pontos obtidas por outras fontes, como por exemplo por correspondência de imagens. Dois conjuntos de pontos resultam desta etapa, o primeiro com pontos do terreno, e o segundo com os demais pontos (não terreno), isto é, de objetos como edificações, vegetação, entre outros.

Esses dois conjuntos de pontos são processados individualmente para a obtenção da classificação final. Nos pontos do terreno (primeiro conjunto) é feita a separação entre vias asfálticas das demais classes, aqui tratadas genericamente como pontos de chão, englobando pastagem e solo exposto, por exemplo. A distância calculada a partir das três bandas (R, G, NIR), entre um determinado pixel, aos centros das classes de treinamento é comparada e o ponto é rotulado à classe de menor distância. Já no segundo conjunto de pontos (de não terreno) a distinção entre pontos de edificações e vegetação é feita a partir do valor de NDVI.

O método de classificação proposto foi implementado na linguagem C++ utilizando o ambiente de desenvolvimento integrado Code::Blocks. Outros programas foram utilizados neste trabalho: rapidlasso LAStools para pequenas manipulações da nuvem de pontos, isto é, recorte da área de estudos e a filtragem do MDS, e o Applied Imagery Quick Terrain Reader para a visualização.

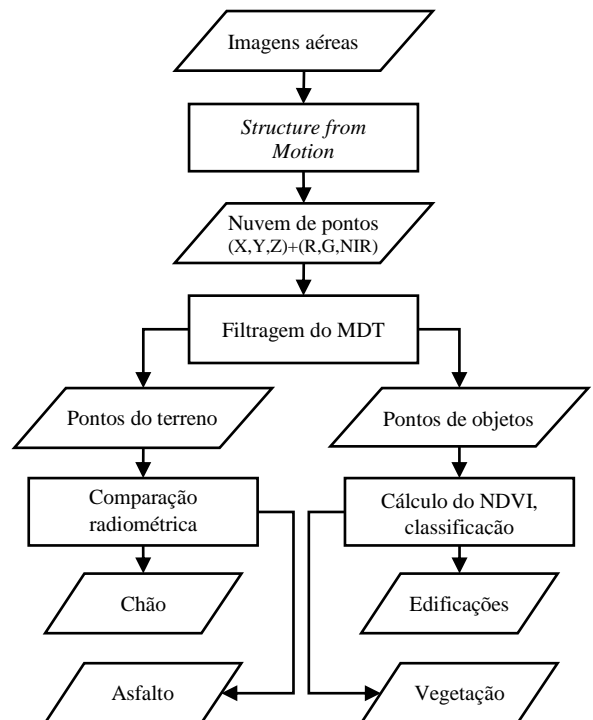


Fig. 2 – Fluxograma com as etapas do método de classificação proposto.

4- EXPERIMENTOS E RESULTADOS

A avaliação do método de classificação proposto considerou a nuvem de pontos da área de estudo. Foram selecionadas pequenas amostras de cada classe para o treinamento do algoritmo, e o resultado da classificação é apresentado na Fig. 3a, na qual as edificações comparecem na cor laranja, a vegetação em verde, asfalto em cinza escuro e os demais pontos de chão em marrom.




Fig. 3 – Área de estudo (a) distribuição espacial das subregiões amostradas para o cálculo da acurácia temática, (b) classificação a partir do método proposto.

Para a análise quantitativa da acurácia temática, amostrou-se aleatoriamente 100 subregiões na área de estudo (Fig. 3b). Por tratar-se de uma nuvem

de pontos obtida por correspondência de imagens, algumas regiões (em branco) apresentam problemas devido à baixa variabilidade (superfície homogênea) ou padrão repetitivo. Desta forma, desconsiderou-se as subregiões amostradas que não continham nenhum ponto.

A matriz de confusão (Tabela 1) foi construída a partir da avaliação de todos os pontos presentes em cada subregião. Além disso, calculou-se também os erros de comissão (EC) e erros de omissão (EO) para as quatro classes: chão (C), asfalto (A), edificações (E), e vegetação (V).

TABELA 1 – MATRIZ DE CONFUSÃO.

	C	A	E	V	EC	EO
C	137	0	15	0	9,87	63,17
A	161	228	17	5	44,53	0,00
E	52	0	151	7	28,10	17,49
V	22	0	0	86	20,37	12,24

A acurácia global da classificação foi de 68,33%, o que indica que seriam necessárias edições manuais adicionais para a confecção dos produtos finais. Os maiores problemas originam-se da distinção entre as classes asfalto e chão, enquanto que a separação entre edificações e vegetação foi adequada, com erros de omissão inferiores à 20%.

A principal diferença entre os dois casos se dá pela utilização do NDVI, que permite caracterizar melhor a vegetação com relação às demais classes. No entanto, a partir de uma análise visual, observou-se que sombras de edificações e árvores implicam diretamente nos resultados da classe asfalto, e deveriam ser removidas em uma etapa de pré-processamento.

5- CONCLUSÕES

A partir da análise quantitativa da acurácia temática, observou-se que o método de classificação proposto apresenta confusão na distinção entre asfalto e os demais pontos de chão. Entretanto, a adição da informação radiométrica na nuvem de pontos proporcionou bons resultados, principalmente para a separação de pontos de vegetação das demais classes. Trabalhos futuros devem investigar outras alternativas para o classificador, com o intuito de mitigar os problemas identificados.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte ao projeto 304189/2016-2.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ali-Sisto, D.; P. Packalen, 2017. Forest change detection by using point clouds from dense image matching together with a LiDAR-derived terrain model. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 10, Nº 3, pp. 1197-1206.
- Awrangjeb, M.; M. Ravanbakhsh; C. S. Fraser, 2010. Building detection from multispectral imagery and LiDAR data employing a threshold-free evaluation system. In International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. 38, pp. 49-55.
- Axelsson, P., 2000. DEM generation from laser scanner data using adaptive TIN models. In International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. 33, pp. 110-117.
- Buján, S.; E. González-Ferreiro; F. Reyes-Bueno; L. Barreiro-Fernández; R. Crecente e D. Miranda, 2012. Land use classification from LiDAR data and ortho-images in a rural area. The Photogrammetric Record, Vol. 27, Nº 140, pp. 401-422.
- Hermosilla, T.; L. A. Ruiz ; J. A. Recio e J. Estornell, 2011. Evaluation of automatic building approaches combining high resolution images and LiDAR data. Remote Sensing, Vol. 3, Nº 6, pp. 1188-1210.
- Hirschmüller, H., 2005. Accurate and efficient stereo processing by semi-global matching and mutual information. In IEEE Conference on Computer Vision and Pattern Recognition, Vol. 2, pp. 807-814.
- Malpica, J. A.; M. C. Alonso ; F. Papí; A. Aronzarena e A. M. De Aguirre, 2013. Change detection of buildings from satellite imagery and LiDAR data. International Journal of Remote Sensing, Vol. 34, Nº 5, pp. 1652-1675.
- Montealegre, A. L.; M. T. Lamelas; J. A. Riva, 2015. comparison of open-source LiDAR filtering algorithms in a mediterranean forest environment. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 8, Nº 8, pp. 4072-4085.
- Sohn, G.; I. Dowman, 2007. Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 68, pp. 43-63.