

EXTRAÇÃO DE ATRIBUTOS DE UMA NUVEM DE PONTOS LIDAR

Roberto Neves Salles¹, Elcio Hideiti Shiguemori², Haroldo Fraga de Campos Velho³

^{1,2}Instituto de Estudos Avançados - IEAv/DCTA
{salles;elcio}@ieav.cta.br

³Instituto Nacional de Pesquisas Espaciais - INPE
haroldo.camposvelho@inpe.br

RESUMO

Este trabalho apresenta a exploração de dados LiDAR (*Light Detection and Ranging*) obtidos através da participação no *IEEE Data Fusion Contest 2018*. O objetivo principal foi extrair atributos úteis para posterior uso em classificadores como redes neurais, árvores de decisão entre outros. Para tanto, foi feita uma exploração, seleção e transformação dos dados da nuvem de pontos LiDAR em imagens matriciais 2D. Foram calculados os momentos estatísticos da posição dos pontos, de suas intensidades e um atributo extra, a densidade de pontos por pixel, demonstrando qualitativamente resultados interessantes e um enorme potencial para novos algoritmos de classificação.

Palavras-chave — LiDAR, nuvem de pontos.

ABSTRACT

This paper presents the exploration of LiDAR (Light Detection and Ranging) data obtained when participating on IEEE Data Fusion Contest 2018. Our main objective was to extract useful attributes for later use on classifiers such as neural networks, decision trees and others. To achieve this we explored, selected and transformed the cloud point data into 2D matrices. We calculated the statistical moments of the position of the points, of their intensities and an extra attribute, density of points per pixel, demonstrating qualitatively interesting results and a great potential for new classification algorithms.

Key words — LiDAR, cloud point data.

1. INTRODUÇÃO

Os sensores LiDAR, do inglês *Light Detection and Ranging*, apresentam uma nova maneira de realizar sensoriamento remoto utilizando luz na forma de um laser pulsado para medir distâncias a partir da plataforma até a superfície terrestre[1]. Ao contrário dos métodos tradicionais de sensoriamento, cujas saídas são imagens matriciais 2D, o resultado primário desta nova forma de sensoriamento é uma nuvem de pontos 3D esparsa e irregular[2]. Este trabalho apresenta uma exploração, seleção e transformação dos dados de uma nuvem de pontos LiDAR em imagens matriciais 2D.

2. MATERIAIS E MÉTODOS

Uma nuvem de pontos é um conjunto de pontos agrupados em um arquivo .LAS[3], georreferenciados em coordenadas UTM. A Figura 1 ilustra uma célula de resolução com pontos amostrados pelo sensor.




Figura 1. Pontos LiDAR numa célula UTM.

Os dados brutos foram primeiramente visualizados e explorados através da implementação de um *plugin* de leitura e exibição para a Plataforma AEROGRAF. A Figura 2 mostra essa implementação, onde a intensidade do pixel é representada por uma cor mais clara enquanto as cores cinza, vermelha, verde e azul representam, respectivamente, grupos com um, dois, três ou quatro retornos.




Figura 2. Pontos LiDAR na Plataforma AEROGRAF.

A partir da seleção vertical de todos os pontos contidos num plano horizontal de 0,5m por 0,5m foram geradas imagens de atributos derivados da seleção de pontos. A rasterização da nuvem de pontos não apenas sintetiza os atributos num formato facilmente manipulável como também abre a possibilidade de utilização de ferramentas e algoritmos tradicionais que operam sobre imagens digitais. Foram geradas imagens 2D de intensidade média, variância da intensidade, densidade de pontos amostrados, média da altura, variância da altura entre outros momentos estatísticos de maior ordem. Através da análise dos dados também foram criados subgrupos denominados Primeiro Retorno (1R), Meio (ME) e Superfície Escondida (SE) para os quais imagens dos momentos estatísticos também foram geradas, demonstrando qualitativamente resultados interessantes para essa separação. Essa subdivisão em grupos está ilustrada na Figura 3.




Figura 3. Divisão em subgrupos 1R, ME e SE.

3. EXPERIMENTOS

Os dados brutos foram obtidos através da participação no *IEEE Data Fusion Contest 2018*. Eles abrangem uma parcela da cidade de Houston, TX, especificamente abrangem trechos da Universidade de Houston. Os dados foram coletados com um sensor LiDAR multiespectral aerotransportado de três bandas em comprimentos de onda 1550nm (B1), 1064nm (B2), and 532nm (B3), o que permite a composição em falsa cor dos resultados (R=B1, G=B2 e B=B3), conforme Figura 4. Essa imagem apresenta a média da intensidade dos pixels 1R. Onde não havia dado foi utilizado o preenchimento pelo vizinho mais próximo e, no caso de mais de um vizinho, pela média deles. A imagem apresentou melhor nitidez do que uma imagem também de primeiro retorno fornecida pelos organizadores do concurso.

A Figura 5 apresenta a densidade de pontos por metro quadrado, considerando todos os pontos. Ela é especialmente útil pois demonstra que os pixels são gerados com uma quantidade diferente de amostras devido a sombreamentos, regiões de forte inclinação como prédios e pela quantidade de vezes que o sensor sobrevoou a região. Pode-se notar, por exemplo, que à direita da imagem existem passagens norte-sul além de leste-oeste.

Outros resultados são apresentados na Figura 6, Figura 7 e Figura 8. A Figura 6 apresenta a sutil diferença de se gerar a intensidade média utilizando todos os pontos. Comparada à Figura 4, pode-se notar que as árvores estão mais escuras pois agora a informação relacionada a outros retornos, mais fracos, está misturada no pixel, entre outras diferenças.




Figura 4. Composição em falsa cor da intensidade média dos pontos contidos no subgrupo 1R.



Figura 5. Densidade de pontos por metro quadrado.

A Figura 7 apresenta a intensidade média do grupo ME (esq) e SE (dir). Nela é possível perceber como, removendo-se o primeiro retorno, tem-se um resultado primário de separação de árvores (esq) e a obtenção de informação

geralmente relacionada às superfícies ocultas (dir). Apesar de parecer que as árvores estão presentes em ambas as imagens, a imagem da direita possui informações muito mais relacionadas com o solo abaixo das árvores.




Figura 6. Composição em falsa cor da intensidade média de todos os pontos da nuvem de pontos LiDAR.




Figura 7. Intensidade média do subgrupo ME (esq) e SE (dir).



Figura 8. Altura média (esq) e variância da altura (dir).

A Figura 8 apresenta a média da altura de todos os pontos de uma mesma banda contidos numa célula de resolução (esq) e a variância dessa altura (dir), sendo possível perceber que árvores, fios de energia e paredes são

especialmente distintos na segunda imagem. Essa é uma tendência que se mantém independente da banda analisada. As árvores também apresentam uma variância grande pois, normalmente, o laser consegue atravessar o dossel e atingir partes internas e o solo. Por fim a variância também se destaca nas paredes de edificações.

4. CONCLUSÕES

Através da exploração dos dados LiDAR em sua forma bruta, i.e. a nuvem de pontos, é possível concluir que existe uma riqueza muito grande de informações para ser explorada, algo que múltiplas rasterizações 2D não são capazes de representar. Evidentemente, isso aponta para a necessidade da criação de novos algoritmos de segmentação e novos classificadores 3D, que saibam utilizar dados esparsos (não regulares) e busquem informações antes não disponíveis neste formato para a comunidade de Sensoriamento Remoto.

Adicionalmente, por ser um dado de natureza amostral, ao ser rasterizado pode-se associar uma medida de qualidade da informação representada num pixel, algo indisponível aos sensores tradicionais. Este trabalho apenas tocou superficialmente nesse aspecto quando realizou o cálculo exploratório do segundo momento estatístico. Muito mais pode ser feito no tratamento estatístico dos dados.

Por fim, pode-se ver que a nuvem de pontos LiDAR traz informações geométricas em conjunto com a informação de intensidade, algo similar até então produzido num único sensor apenas pela combinação de interferometria SAR com seus pares em intensidade. Desta forma é de se imaginar que tão logo dados LiDAR se tornem mais comuns e difundidos a pesquisa em Sensoriamento Remoto ganhará novo fôlego através da criação de novas formas de utilização.

5. AGRADECIMENTOS

Os autores gostariam de agradecer ao *National Center for Airborne Laser Mapping* e ao *Hyperspectral Image Analysis Laboratory* da Universidade de Houston pela aquisição e fornecimento dos dados utilizados neste estudo e ainda ao *IEEE GRSS Image Analysis and Data Fusion Technical Committee*.

6. REFERÊNCIAS

- [1] Killinger, D. K. *Laser Spectroscopy for Sensing*. Woodhead Publishing, 2014. p. 292.
- [2] U.S. GEOLOGICAL SURVEY *Light Detection and Ranging (LiDAR)*. 2015. Disponível em: <https://lta.cr.usgs.gov/lidar_digialelevation>. Acesso em: 18 jul. 2018.
- [3] LAS SPECIFICATION, Version 1.4-R13, 2013. Disponível em <https://www.asprs.org/a/society/committees/standards/LAS_1_4_r13.pdf>. Acesso em 01 fev. 2018.