

Classificação de feições na superfície a partir de dados LiDAR e medidas de entropia e desvio padrão das altitudes

Renan Américo Ribeiro de Oliveira¹
Maurício Galo^{1,2}

¹ Universidade Estadual Paulista - FCT/UNESP

Bolsista de IC – Iniciação Científica, PIBIC/CNPq: 2015-2016

² Departamento de Cartografia

Rua Roberto Simonsen, 305 - 19060-900 - Presidente Prudente - SP, Brasil
renanamerico@gmail.com, galo@fct.unesp.br

Abstract. This paper describes a methodological approach to automatic classification of LiDAR data aiming at filtering and classifying the following classes: ground, buildings, vegetation and transmission lines. The classification approach is based on the use of the following attributes: height standard deviation and height entropy, among others attributes, estimated from LiDAR point cloud. Those attributes enable to find patterns in this kind of data through the establishment of limits on normal distribution curves, which later serve as parameters for sequentially filtering and classifying in the classes mentioned. Besides these attributes, some additional filters, such as the minimum height to distinguish building points, removal of isolated points and coherence analysis of height between nearby objects, were used to refine the classification at the end of the algorithm. The results obtained by the proposed algorithm were compared with the results obtained by other software. From a visual analysis of these two classifications and from the optical image of the same area, it was possible to highlight the positive and negative aspects of the proposed approach. From these results it was verified that, despite the need for some improvements, it was possible to perform the classification based on attributes such as entropy and standard deviation estimated from the point cloud obtained by LiDAR systems.

Palavras-chave: dados LiDAR, extração de edificações, filtragem e classificação, análise de entropia, LiDAR data, building extraction, filtering and classification, entropy analysis.

1. Introdução e objetivos

Em função do crescente desenvolvimento de tecnologias nas ciências ligadas ao Sensoriamento Remoto, Fotogrametria e áreas afins, novos métodos e técnicas vêm sendo desenvolvidos para os processamentos dos dados de natureza espacial, gerados a partir dessas tecnologias. Uma dessas tecnologias, utilizadas tanto por pesquisadores quanto usuários nas áreas de Sensoriamento Remoto e Fotogrametria, são os sistemas ativos LiDAR (*Light Detection and Ranging*), baseados na emissão e recepção de feixes LASER (*Light Amplification by Stimulated Emission of Radiation*) que podem ser obtidos a partir de plataformas aerotransportadas (sejam aeronaves ou RPAS - *Remotely Piloted Aircraft Systems*), orbitais ou terrestres.

Como citam El-Sheimy et al. (2005), a tecnologia LiDAR é resultante da integração de outras três: LASER, sistema de navegação inercial (INS), e GNSS (*Global Navigation Satellite System*), que devem operar de modo sincronizado. Axelsson (1999) ressaltava que a aquisição de dados a partir destes sistemas é uma importante alternativa para a geração de Modelos Digitais de Superfície (MDS), que após os processamentos adequados, podem gerar Modelos Digitais de Terreno (MDT), com importantes aplicações práticas, tanto na Cartografia, quanto em algumas áreas da engenharia. Além disto, a aplicação deste tipo de dado, pode ser útil ao controle de dados cadastrais (FILIN et al., 2005) e projetos ambientais na área de florestas (SILVA et al., 2013), dentre outros.

De acordo com Chang et al. (2008), o nível de detalhamento e a qualidade dos pontos extraídos de uma nuvem de pontos LiDAR, motivou a comunidade científica a investigar a possibilidade de automatizar a extração de objetos da superfície, a partir deste tipo de dado. Dentre estes objetos que podem ser extraídos pode-se mencionar a vegetação, os topos de edificações (telhados), assim como quaisquer feições antrópicas, que ao serem extraídas

automaticamente podem reduzir o trabalho do operador humano, como por exemplo, na etapa de restituição fotogramétrica.

Para realizar a extração automática de informações de interesse a partir de dados LiDAR é importante o desenvolvimento de métodos robustos, que devem ser otimizados o suficiente para trabalhar geralmente com um volume grande de dados. Como exemplo de um *software* desenvolvido para o processamento de dados LiDAR tem-se a biblioteca *LAStools* (ISENBURG, 2011), que permite realizar uma série de operações, como por exemplo a filtragem e a classificação de feições do espaço objeto. Diferentes procedimentos e *softwares* podem ser utilizados com este propósito, como se pode ver em Sithole e Vosselman (2005), Miqueles e Centeno (2003), Meng et al. (2010) e Silva et al. (2013a).

Dentro deste contexto, o propósito deste trabalho consistiu em desenvolver e avaliar um procedimento destinado à classificação de objetos presentes numa área urbana, a partir do uso de dados LiDAR. Para isso foram consideradas algumas métricas, como desvio-padrão e entropia, por exemplo, estimadas a partir das altitudes, possibilitando deste modo filtrar e classificar feições (objetos) de interesse sobre a nuvem de pontos original obtida a partir dos dados LiDAR. Com este propósito foram desenvolvidos, implementados e testados algoritmos na linguagem ANSI C, bem como *scripts* para visualização e amostragem no *software Octave*.

2. Metodologia de Trabalho

Os métodos utilizados neste trabalho podem ser separados em duas etapas. A primeira teve o objetivo de analisar o comportamento de atributos como desvio padrão das altitudes, entropia das altitudes, dentre outros, estimados a partir dos dados LiDAR, procurando comparar os resultados obtidos destes atributos para algumas classes de feições: vegetação alta e baixa (de menor porte), linhas de transmissão, edificações e solo. A segunda etapa consistiu na filtragem e classificação dos dados, na qual foram utilizados os valores dos atributos estimados a partir de dados amostrais na primeira etapa. Deste modo, a partir dos valores de média e desvio padrão dos atributos e das curvas de distribuição normal para cada classe, foram estabelecidos limites estatísticos que permitiram fazer a filtragem e classificação de toda a nuvem de pontos. Além disto, foram utilizadas outras heurísticas ao final do processo, criadas para melhorar o resultado da classificação.

2.1 Etapa 1: Criação das matrizes de atributos

A partir de uma nuvem de pontos LiDAR, obtida a partir de um voo sobre a região de Presidente Prudente, São Paulo, foi feita a escolha de duas quadras urbanas, que seriam utilizadas como áreas teste. Uma vez escolhida a região de trabalho foram definidos os atributos que seriam estimados sobre esta região, como pode-se ver na Tabela 1.

Tabela 1. Simbologia e descrição dos atributos.

Atributo	Símbolo	Descrição
Desvio padrão das altitudes	σ	Medida de dispersão do valor de altitude dos pontos numa dada vizinhança
Entropia das altitudes	ε	Nível de “desordem” dos valores de altitude dos pontos numa dada vizinhança
Porcentagem de pontos próximos a altitude mínima	ρ	Proporção de pontos que estão abaixo de uma altura especificada (informada junto com os parâmetros de entrada do algoritmo), para cada vizinhança
Intensidade	\bar{I}	Valor médio da intensidade de retorno do pulso LASER numa dada vizinhança

Uma vez que os dados LiDAR não são amostrados de forma regular, estes atributos foram estimados e armazenados em uma estrutura matricial, ou matriz de atributos, cujo GSD (*Ground Sample Distance*) é definido pelo usuário.

O algoritmo criado para esta etapa faz uma varredura por todas as posições da matriz, de acordo com a dimensão do GSD e também dos limites da área. Então, em cada posição da matriz de atributos, que pode ser associada com as coordenadas (E, N) no espaço objeto, é feita a busca de todos os pontos da nuvem que estão dentro de um raio de busca (r) no plano, sendo os pontos que atendem a esta condição utilizados para estimar os atributos descritos na Tabela 1.

A entropia foi um dos atributos utilizados, sendo ela calculada a partir de uma adaptação da abordagem realizada por Demantké et al. (2011), onde a entropia de um sistema foi estimada a partir do uso de autovalores. Neste trabalho utilizou-se da equação:

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

Nesta equação h_i representa a altitude de um ponto genérico i , situado na vizinhança estabelecida a partir do raio r , e h_{min} a altitude mínima nesta vizinhança. Pode-se notar na equação acima que foi incluído um termo Δ , que tem a função de evitar singularidade no caso de regiões 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).

Ao final desta etapa, com as matrizes criadas, para cada um dos atributos selecionados, pode-se perceber que algumas classes ficam bem evidenciadas. A partir desta observação foram escolhidos manualmente pontos para amostragem em cada uma das classes de interesse. Deste modo foi possível estimar a média e desvio padrão dos atributos para cada uma das classes consideradas.

2.2 Etapa 2: Filtragem e classificação dos dados LiDAR

De acordo com os valores estatísticos obtidos da amostragem feita na Etapa 1, com base em 10 amostras por classe, e supondo que o comportamento dos atributos estimados ocorra em outras regiões, foram criadas curvas gaussianas de distribuição normal para a análise dos atributos. Na Figura 1 são mostradas algumas dessas curvas.

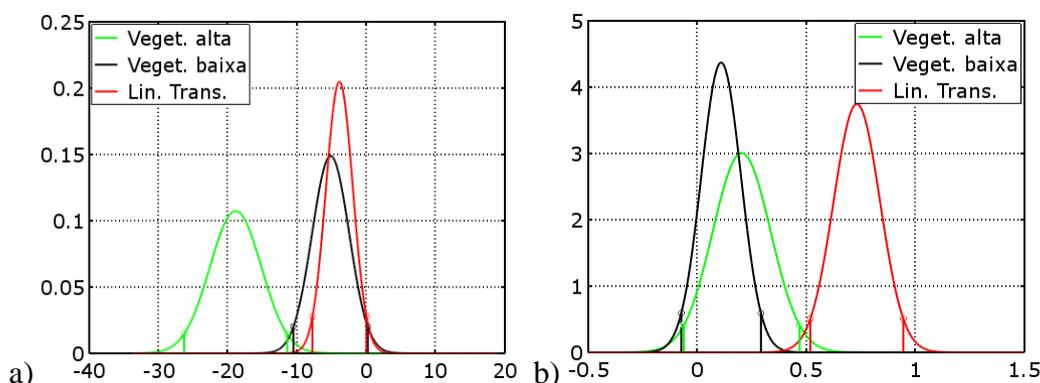


Figura 1. Curvas gaussianas para Entropia das altitudes (a) e Porcentagem de pontos próximos a altitude mínima (b) para três classes de feições.

Através das Figuras 1(a) e (b) é possível notar que certos atributos permitem diferenciar algumas classes de feições e outras não. Portanto, a partir de limites obtidos por estas curvas, considerando, por exemplo, um, dois ou três desvios padrões a partir do valor médio, pode ser

feita a verificação nos pontos da matriz, podendo ser determinado em cada caso, em qual classe cada ponto pode ser enquadrado.

Este processo foi implementado, de acordo com o fluxograma da Figura 2, que sintetiza as operações realizadas pelo algoritmo da Etapa 2. Então, a partir da entrada dos parâmetros estatísticos adquiridos ao final da Etapa 1 e das opções ajustáveis para a criação da matriz (limiares de altura, dimensão do raio de busca, GSD, etc.), são feitos testes para verificar se um ponto da matriz se enquadra em algumas das classes citadas.

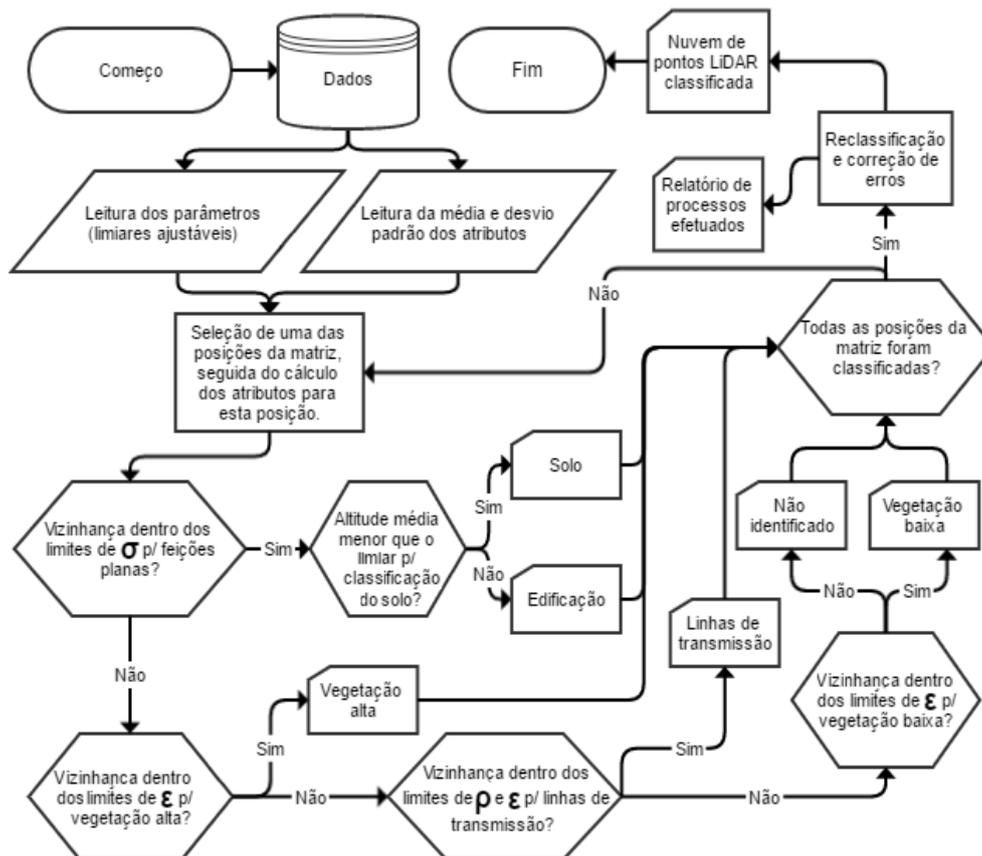


Figura 2. Fluxograma dos procedimentos realizados na etapa de filtragem e classificação.

Além do uso desses limites, para uma melhor distinção entre as classes edificações e solo, que podem ser confundidas ao usar os atributos desvio padrão e entropia, é utilizado um limiar de altura e um raio, que auxilia na diferenciação de uma edificação (telhado) do solo. Esta verificação consiste em comparar as diferenças de altitude entre pontos classificados como edificação, que são vizinhos a pontos classificados como solo, partindo do princípio que os pontos de edificações não podem ter sua altitude muito próxima à altitude de pontos de solo. Embora isso melhore a classificação dessas duas classes de feições, alguns pontos que estão sobre carros e outros veículos que tem o teto "plano", são muitas vezes considerados como edificações. Para evitar este, bem como outros problemas, foram desenvolvidas outras heurísticas, na forma de filtros adicionais ao final do algoritmo.

Estes filtros, ao final dos processamentos da Etapa 2, são aplicados para eliminar algumas incoerências da classificação. O primeiro filtro reclassifica edificações ao lado de pontos de solo. Caso a altitude média do ponto que representa esta feição seja menor que a altitude do solo verificado mais um pequeno limiar de altura, então este é reclassificado como solo. O segundo filtro verifica se os pontos ao redor de uma feição isolada são iguais. Caso sejam, a feição isolada muda para a classe de seus pontos vizinhos. Finalmente, o terceiro procura por pontos da classe edificação que estejam sem pontos de edificação ao seu redor, e reclassifica-os como não identificável.

3. Resultados e Discussão

Os dados utilizados neste trabalho correspondem a uma nuvem de pontos LiDAR obtida a partir do sistema RIEGL LMS-Q780 em um voo realizado em dezembro de 2014 pela empresa *SensorMap – Geotecnologia*. As imagens ópticas foram adquiridas pela mesma empresa usando uma câmara *Phase One* também na mesma data. Também foram utilizados o compilador *Code Blocks* e os softwares *Octave* e *Fugro Viewer*, este último para a visualização da classificação.

Na Figura 3 são apresentados os valores dos atributos σ , ε e ρ para uma mesma região. É possível observar que alguns atributos destacam mais a vegetação do que feições como edificações e o solo, como pode-se ver na Figura 3(a) e (b). Entretanto, apesar do algoritmo implementado ser capaz de diferenciar a vegetação, percebe-se que esta distinção é melhor percebida ao utilizar o atributo entropia, em função dos valores elevados obtidos para a vegetação de maior porte.

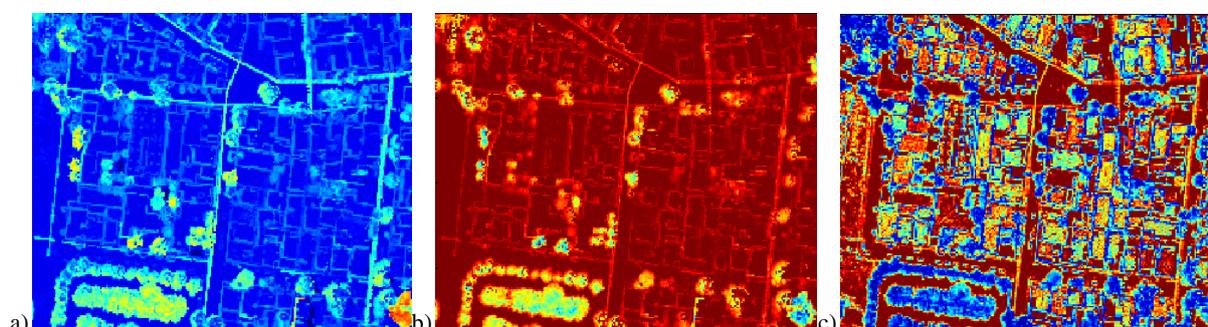


Figura 3. Matrizes de saída para os atributos σ (a); ε (b) e ρ (c).

Percebe-se que os valores dos atributos σ e ε para vegetação baixa e linhas de transmissão são muito parecidos, sendo necessário o uso do atributo adicional ρ (Figura 3(c)) para distinguir as linhas de transmissão destas outras feições. Isso se torna claro ao observar os valores de ρ , onde a vegetação se apresenta com valores baixos (cor azulada), e as linhas de transmissão com valores maiores (cor alaranjada), comparação que pode também ser feita através das curvas gaussianas da Figura 1(b). Porém, apesar da dupla verificação do algoritmo (limites das matrizes, de acordo com o fluxograma da Etapa 2 ao classificar linhas de transmissão), algumas bordas de telhados e árvores ainda são classificadas erroneamente como pertencentes a esta classe. Este problema se dá devido ao processo de amostragem inerente aos dados LiDAR, que não permite representar com alta qualidade as bordas em geral.

Para que fosse realizada a classificação a partir dos valores dos atributos mostrados na Figura 3, foram calculadas para cada uma das classes analisadas, a média e a dispersão dos valores armazenados nas matrizes de atributos. Para isso foram coletadas 10 amostras de cada classe, sendo obtidos os valores mostrados na Tabela 2. Com essas informações foi possível criar as curvas gaussianas para a análise e escolha dos limites utilizados na classificação.

Tabela 2. Valor dos atributos utilizados no algoritmo, para cada classes de interesse.

Classe	Atributo	Média e desvio padrão
Vegetação alta	ε	$-18,841 \pm 3,722$
Vegetação baixa		$-5,126 \pm 2,683$
Linhas de transmissão	ρ	$73,2 \% \pm 10,1 \%$
Edificação	σ	$0,121 \text{ m} \pm 0,025 \text{ m}$
Solo		$0,030 \text{ m} \pm 0,014 \text{ m}$

Ao fim da filtragem e classificação dos dados LiDAR, foi obtida uma nuvem de pontos regularmente espaçada (Figura 4(b)), contendo os resultados do algoritmo em diferentes cores.

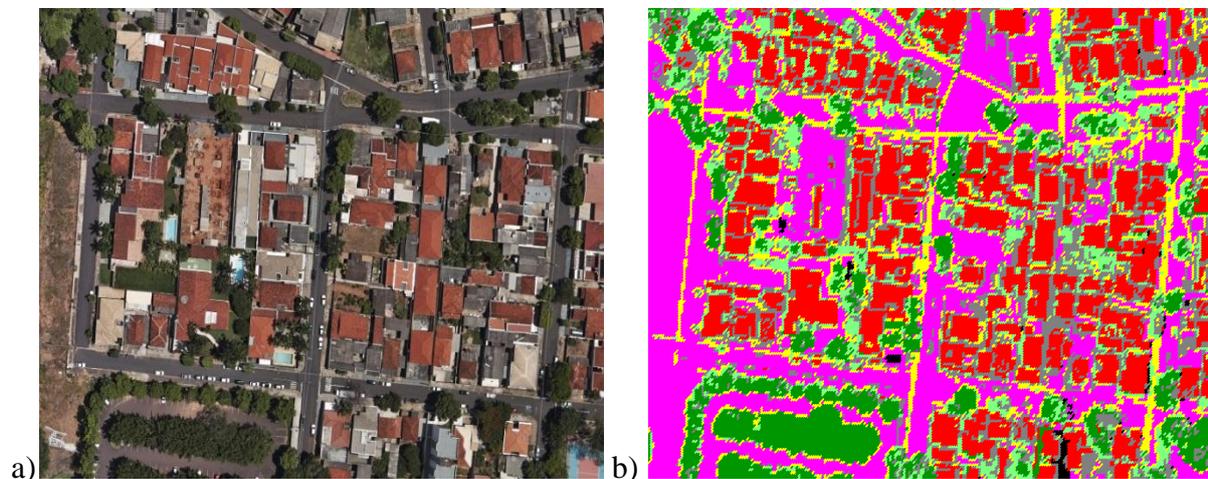


Figura 4. Imagem óptica (a) e resultado da classificação da nuvem de pontos LiDAR (b).
Legenda: vegetação alta (●), vegetação baixa (●), linhas de transmissão (●), edificações (●), solo (●), não identificados (●) e área sem dados (●).

Através da comparação entre a imagem óptica e os processamentos realizados pelo algoritmo criado é possível perceber que os resultados são coerentes, e apresentam uma boa qualidade visual (sendo necessária ainda uma análise quantitativa). Visando comparar os resultados obtidos pelo procedimento implementado e o obtido por outra solução, foi feita a comparação com o resultado da biblioteca *LAStools*. Nas Figuras 5(a) e (b) estão destacadas algumas regiões que apresentam divergências entre estes processamentos. Nas regiões 1 e 2 são mostradas feições classificadas como vegetação pela biblioteca *LAStools*, já no algoritmo criado eles foram classificados corretamente como edificações. A região 3 mostra algumas bordas de árvores que foram consideradas de forma equivocada como linhas de transmissão, o que não ocorre na classificação do *LAStools*. Por outro lado, a delimitação da vegetação neste caso, não foi uniforme como no algoritmo criado.

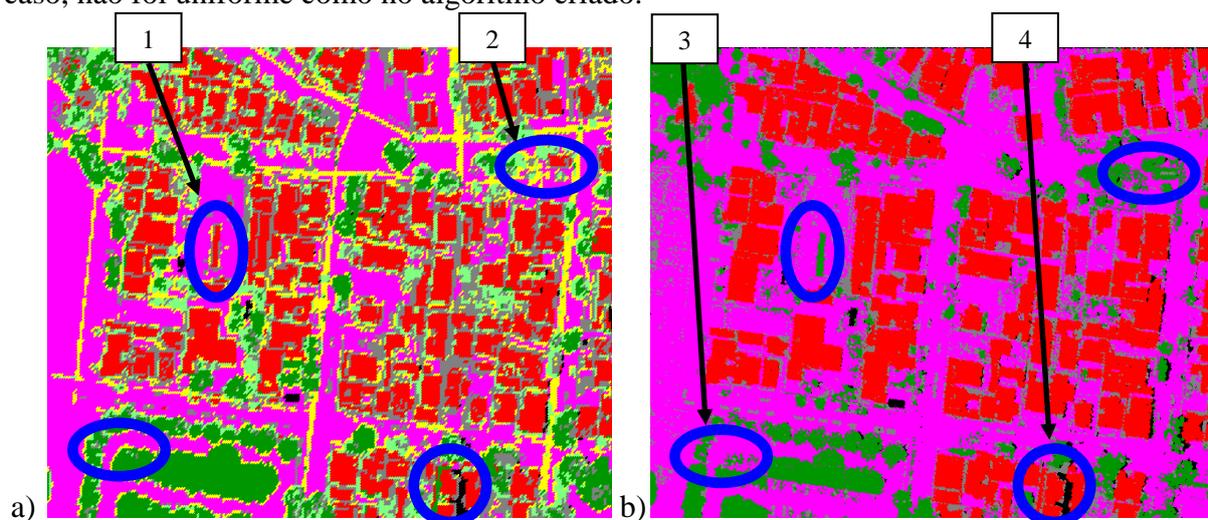


Figura 5. Classificação com o algoritmo desenvolvido (a) e com a biblioteca *LAStools* (b).

Outra região que deve ser levada em consideração são áreas com ausência de dados, que podem surgir em regiões com corpos d'água ou oclusão. Na região 4 é mostrado um exemplo onde há oclusão devido à altura de um edifício. Nota-se também que na face oposta à área de

oclução há vegetação, equivocadamente classificada pelo algoritmo implementado, diferentemente da classificação no *Lastools*.

Na Figura 6 é mostrado o resultado da classificação para uma outra quadra da cidade de Presidente Prudente. Ressalta-se que os valores dos atributos e respectivos desvios padrão utilizados foram determinados a partir da quadra mostrada na Figura 4, ou seja, em outra quadra.

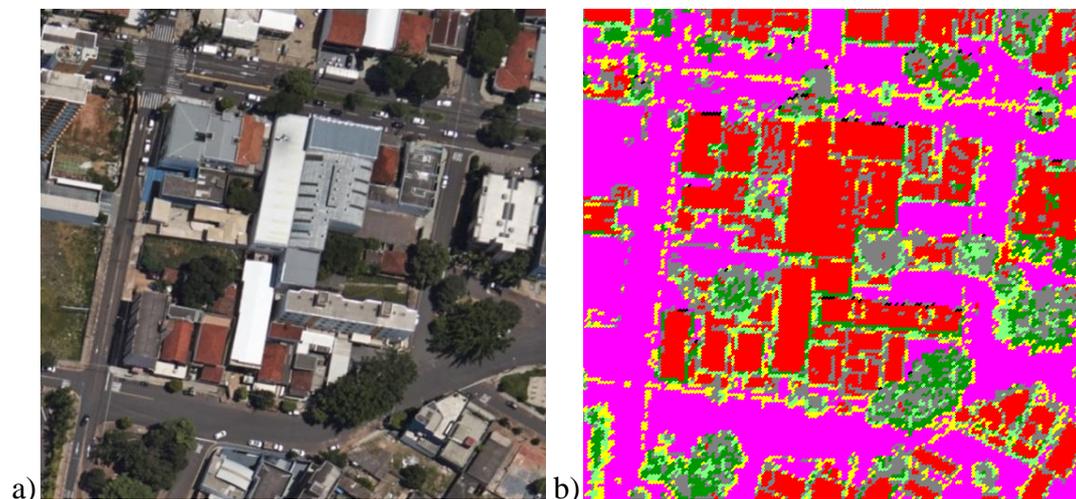


Figura 6. Imagem óptica (a) e resultado da classificação da nuvem de pontos LiDAR (b) para uma segunda quadra. Legenda: igual à da Figura 4.

Pode-se notar que os resultados para a quadra mostrada na Figura 6 também foram coerentes, mesmo considerando que foram utilizados os parâmetros determinados a partir de outra quadra, o que pode causar algumas distorções dos valores de entropia para as vegetações devido ao maior declive do terreno, deteriorando a qualidade visual dessa classe.

É importante ressaltar também que os parâmetros considerados no processamento pela biblioteca *LAStools* foram os da configuração *default*, indicada para áreas urbanas pelo seu autor. Isto significa que os resultados mostrados podem ser aprimorados através da mudança dos parâmetros de processamento disponíveis pelo aplicativo.

4. Conclusões

A partir das análises realizadas constatou-se que o algoritmo desenvolvido conseguiu atingir o objetivo de classificar as feições desejadas. É interessante destacar que devido ao comportamento dos atributos estimados para as diferentes classes, bem como em função dos valores de média e desvio padrão dos mesmos, foi possível não só classificar edificações, vegetação e solo, mas também linhas de transmissão, sendo que a identificação desta última não era esperada no início do desenvolvimento.

Os resultados se mostraram coerentes na maior parte dos casos, sendo possível observar a presença de alguns problemas em bordas de edificações e vegetação. Deve-se ressaltar que o procedimento proposto pode ser aprimorado, visando evitar ou reduzir os problemas encontrados. Neste sentido sugere-se o uso de outras técnicas para a classificação.

Além destas considerações, é necessário lembrar que o atributo intensidade do retorno do LASER, apesar não ter sido utilizado na etapa de classificação, pode revelar características do tipo de material de cada classe de feição, podendo assim ser utilizado na identificação de algumas classes não consideradas neste trabalho, como vias e estradas, por exemplo.

Agradecimentos

Os autores agradecem à empresa *Sensor Map - Geotecnologia* por fornecer os dados LiDAR e as imagens ópticas da região de Presidente Prudente, ao CNPq pelo suporte ao

projeto CNPq - Proc. 307788/2012-1, bem como ao programa PIBIC/CNPq pela bolsa de Iniciação Científica concedida ao primeiro autor no período 2015-2016.

Referências Bibliográficas

- Axelsson, P. Processing of laser scanner data – algorithms and applications. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 54, 1999, p. 138-147.
- Baltsavias, E. P. Airborne laser scanning: basic relations and formulas. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 54, 1999, p. 199-214.
- Bartels, M.; Wei, H. Segmentation of LIDAR data using measures of distribution. In: **ISPRS Mid-term Symposium 2006 "Remote Sensing: From Pixels to Processes"**, WG V. 11/4 Advanced Classification Techniques, Enschede, Netherlands, 2006.
- Chang, Y. C.; Habib, A. F.; Lee, D. C.; Yom, J. H. Automatic classification of LiDAR Data into ground and non-ground points. In: **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. Vol. XXXVII. Part B4. Beijing, 2008.
- Demantké, J.; Mallet, C.; David, N., Vallet, B. Dimensionality based scale selection in 3D LiDAR point clouds. In: **ISPRS Workshop on Laser Scanning 2011**, Calgary Canada, 2011.
- El-Sheimy, N.; Valeo, C.; Habib, A. **Digital Terrain Modeling: Acquisition, Manipulation and Applications**. USA: Artech House Remote Sensing Library, 1ª ed., 2005, p. 1-256.
- Filin, S.; Kulakov, Y.; Doytsher, Y. Application of airborne LASER technology to 3D cadastre. In: **FIG Working Week 2015 and GSDI-8**, Cairo, April 16-21, pp. 1-13, 2005.
- Hug, C.; Krzystek, P.; Fuchs, W. Advanced LiDAR data processing with LasTools. In: **Int. Arch. Of Photogrammetry and Remote Sensing. Commission II, ISPRS 20th Congress**, Istanbul, Turkey, 13th - 23rd July, 2004.
- Isenburg, M. **LAStools Software Suite**. 2011. Disponível em: <<http://rapidlasso.com/lastools/download>>. Acesso em 10 de Outubro de 2015.
- Meng, X.; Currit, N.; Zhao, K. Ground Filtering Algorithms for Airborne LiDAR Data: A Review of Critical Issues. **Remote Sensing**. 2010, Vol. 2, p. 833-860.
- Miqueles, M. A. S.; Centeno, J. A. S. Detecção e caracterização de vegetação usando dados do laser scanner aerotransportado. In: **Anais do III Colóquio Brasileiro de Ciências Geodésicas**. Curitiba: Editora da UFPR, 2003. v. 1, p. 1-12.
- Silva, C. A.; Kaluberg, C.; Hudak, A.; Liebermann, R.; Carvalho, S. de P. C. e; Rodriguez, L. C. E. Utilização da tecnologia LiDAR para estimação da biomassa florestal em povoamentos de *Eucalyptus sp.* In: **Anais do XVI Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, Foz do Iguaçu, 13-18 Abril, p. 6097-6104, 2013.
- Silva, C. A.; Liesenberg, V.; Klauberg, C.; Hudak, A.; Liebermann, R.; Rodriguez, L. C. E. Variações de MDTs gerados a partir de dados LiDAR: estudo comparativo entre diferentes classificadores. In: **Anais do XVI Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, Foz do Iguaçu, 13-18 Abril, p. 6113-6120, 2013a.
- Sithole, G.; Vosselman, G. Filtering of airborne laser scanner data based on segmented point clouds. **Proceedings of the ISPRS Workshop Laser scanning 2005**, ISPRS Archives, Enschede, the Netherlands, 2005. v. 36, p. 66-71.
- Wehr, A.; Lohr, U. Airborne laser scanning – an introduction and overview. **ISPRS Journal of Photogrammetry and Remote Sensing**. 1999. v. 54, p. 68-82.