

Uma breve revisão sobre metodologias para a reconstrução 3D de ambientes urbanos pelo uso de nuvem de pontos

Rodolfo Georjute Lotte
Cláudia Maria de Almeida

Instituto Nacional de Pesquisas Espaciais – INPE
Departamento de Sensoriamento Remoto - DSR
Caixa Postal 515 – 12227-010 – São José dos Campos - SP, Brasil
{lotte, almeida}@dsr.inpe.br

Abstract.

Urban environments are densely populated areas composed mostly by residential, commercial and industrial sectors and alike. From airborne or satellite images shows off cleared linear patterns due to predominance of artificial structures, such as roads, buildings and impervious surfaces. Currently, 54% of the world population lives in urban areas and it is estimated that by 2050 there will be an increasing to 66% of the population, which makes monitoring and management of urban environments one of the most important challenges of the twenty-first century. The systematic collection of information about cities structures are extremely important for the management of those environments. The precise mapping expresses the idea of organization and possibility of future planning, since the disposal of urban objects, their state of preservation and geometry contribute, for instance, in monitoring, drawing up plans for greater comfort of the population, even so, enables computational simulations of numerous natural disasters and their potential impacts. Two major data sources have been an efficient alternative to survey information about the geometry, laser sensors, called LiDAR (Light Detection And Ranging) and optical, that is combined with techniques of photogrammetry by stereo-pair. Both have become the focus of studies involving 3D reconstruction of urban features in the last decades, in particular, volumetric information. The challenge in extracting volumetry of urban environments resides in its heterogeneity. Among the methods proposed over the years, many of them have adopted the workflow: detection and reconstruction, which first the buildings edges are delineated and subsequently geometric modeling procedures are applied to reconstruct the 3D building representation. In this study, we briefly present the most widely used methods for 3D reconstruction, separated in methods for the detection and reconstruction.

Keywords: 3D urban reconstruction, LiDAR, photogrammetry .

1. Introdução

Em 2014, a Divisão de População das Nações Unidas divulgou um relatório anual apresentando o perfil da população mundial, bem como a estimativa e a projeção até 2050 da porcentagem populacional vivendo em áreas urbanas e rurais. Segundo o relatório, aproximadamente 54% da população vive hoje em centros urbanos. Calcula-se ainda que essa porcentagem aumente para 66% até 2050 (UNITED NATIONS, 2014). Grande parte das cidades, atualmente, é constituída por uma estrutura complexa e densa de feições naturais e artificiais, com uma imensa variedade de tamanhos, formas, composições e arranjos (MESEV, 2003). O monitoramento e gestão desses ambientes a partir de dados de sensoriamento remoto (SR) torna-se, desta forma, uma tarefa desafiadora (BRETAR, 2008).

Como recurso aos setores de gestão de cidades, duas principais representações gráficas digitais são normalmente utilizadas, as bidimensionais (2D) e tridimensionais (3D). Em SR, as representações 2D compreendem a forma mais comum de visualização do espaço urbano, em que os objetos são sistematicamente monitorados por imagens orbitais ou aerotransportadas. Recentemente, com os avanços na tecnologia nas últimas duas décadas, sensores remotos com capacidades melhores de imageamento permitiram estudos mais avançados envolvendo

ambientes urbanos, como é o caso do surgimento dos sensores laser em meados de 1995 e sua utilização para estudos topográficos e geração de representações tridimensionais desses ambientes.

As representações 3D por meio de sensores laser surgiu, portanto, como complemento à demanda pela caracterização de objetos. Esses contemplam não somente a disposição geográfica dos objetos na cena, mas também a incorporação da informação volumétrica com níveis de acurácia diferenciados, permitindo compreender melhor seus aspectos geométricos, ocupação do espaço e possíveis impactos ao ambiente. Em ambientes urbanos, o estudo de sombras produzidas por edifícios, identificação de ilhas de calor, conforto térmico (MAIMAITIYIMING et al., 2014; TEWOLDE; CABRAL, 2011), navegação realista, turismo, entretenimento, planejamento urbano, controle de tráfego, fiscalização de construções irregulares ou informações da arborização urbana (ISMAIL, 1996; AHMAD; GADI, 2003) são exemplos de setores e tarefas atualmente amparadas pelo uso de mapas temáticos gerados pela análise de dados 2D.

A geração de modelos 3D urbano tornou-se um importante segmento de pesquisa nas últimas décadas (HAALA; KADA, 2010). Reproduções digitais fiéis do mundo real são, entre os recursos computacionais para gestão e monitoramento de cidades, aquele cujo interesse se insere no desenvolvimento de formas otimizadas de navegação e visualização interativa do espaço urbano, de modo a integrar informações atualizadas da geometria urbana às tecnologias atuais.

A reconstrução 3D¹ consiste no processo de transformação de objetos ou cenas do mundo real em representações computacionais tridimensionais, tal que, dependendo da aplicação, o grau de realismo poderá compreender uma maior ou menor precisão geométrica (FORLANI et al., 2003), a qual também é função da capacidade do sensor em discriminar os alvos a serem reconstruídos.

Modelos bidimensionais (2D) e tridimensionais (3D) de ambientes urbanos vêm sendo reproduzidos a partir de fontes de dados, como óptico (pela técnica de estéreo-par), radar (por interferometria, por meio da técnica de Espalhamento Persistente (*Persistent Scattered Interferometry* - PSI)) e laser (*Light Amplification by Simulated Emission of Radiation*), essa, disponibilizada recentemente no mercado de sensores para medidas de distância. Devido a elevada acurácia vertical dos dados, os sensores laser para fins topográficos, comumente referenciado como LiDAR (*Ligh Detection And Ranging*), reconduziu a pesquisa da reconstrução 3D urbana para níveis mais sofisticados de processamento, por conseguinte, à geração de modelos 3D com elevada qualidade geométrica (ROTTENSTEINER et al., 2005; BLAIS, 2004).

A disponibilidade de métodos para reconstrução 3D urbana, sobretudo, a reconstrução de edificações, geralmente aderem ao delineamento das formas de seus telhados (*footprints*), com detalhes e acurácia necessários, utilizando essa informação para gerar representações 3D em uma etapa subsequente (HAALA; KADA, 2010).

Em termos de reconstrução 3D urbana, dois grupos podem ser encontrados na literatura: baixo e alto detalhamento. O primeiro, consiste em gerar modelos cuja representabilidade dos objetos urbanos é mais grosseira. Normalmente, estes modelos são feitos em larga escala, com sensores aerotransportados. Por outro lado, modelos 3D em níveis mais elevados de

¹O termo “extração volumétrica” urbana ou “extração 3D” urbana envolve as etapas de aquisição dos dados, pré-processamento, remoção de ruídos, classificação dos pontos e a reconstrução do objeto propriamente dito (modelagem geométrica). Na literatura (e também neste trabalho), no entanto, é comum a utilização do termo “reconstrução” para caracterizar o processo de geração tridimensional do objeto como todo, ou ainda, o termo “modelo 3D” para caracterizar o conjunto de objetos já reconstruídos.

detalhamento são obtidos por meio do imageamento de curto alcance. Neste trabalho são expostos os principais métodos referentes ao reconstrução 3D urbana em baixo nível de detalhamento.

2. Resumo metodológico das técnicas de reconstrução 3D a partir de nuvem de pontos

Mesmo com o surgimento de sensores com desempenho e capacidade elevada de imageamento, estudos envolvendo a reconstrução 3D urbana ainda enfrentam um desafio comum: a complexidade desses ambientes. A variabilidade espectral e espacial existente nestes os tornam ainda mais complexos e desafiadores, tal que seria otimista dizer que um único sensor poderia fornecer todas informações necessárias para a caracterização de objetos (GAMBA; DELL'ACQUA; HOUSHMAND, 2003).

As conquistas mais recentes em termos de autonomia na geração de modelos 3D urbanos são baseados na integração de duas ou mais fontes de dados (ROTTENSTEINER, 2003). Notoriamente, tais estudos frequentemente remetem ao uso de dados estruturais (tridimensionais). Por conseguinte, nesta seção são apresentados trabalhos e metodologias que fazem o uso deste recurso.

O fato de grande parte dos objetos em ambientes urbanos serem artefatos artificiais faz com que esses apresentem quase sempre bordas lineares e superfícies planas, a exemplo de telhados e estradas (GUO et al., 2011). Ainda assim, a distribuição espacial dos pontos segue a ordem irregular e complexa do mundo real, sofrendo também influências atmosféricas², da superfície ou do próprio instrumento, que torna, conseqüentemente, o desenvolvimento de métodos ou modelos matemáticos para representações 3D uma tarefa não trivial.

Com o surgimento de novos sensores, técnicas e práticas, pode-se dizer que nos últimos 20 anos a geração de modelos 3D de cidades a partir de nuvem de pontos evoluiu consideravelmente. Entretanto, não há ainda na literatura uma metodologia consagrada que determine um roteiro ótimo. Nota-se, porém, um padrão no fluxo de processamento compreendendo dois estágios fundamentais: detecção e reconstrução (ROTTENSTEINER, 2003; SOHN; DOWMAN, 2007; SHAN; SAMPATH, 2007; VOSSelman; MAAS, 2010). No primeiro estágio, normalmente, os dados são submetidos à rotinas de filtragem na qual são gerados Modelos Digitais de Elevação (MDE)³. A partir desses subprodutos, são identificadas e reconstruídas as regiões de interesse (edificações, vegetação arbórea, gramínea, estradas, corpos d'água, entre outros).

Por conveniência de revisão, nesta seção serão listados apenas alguns dos principais métodos, obedecendo-se a seqüência “detecção e reconstrução”, mencionada acima.

2.1. Detecção

O principal foco no estágio de detecção é a classificação de cada um dos pontos imageados. Muitas metodologias para a classificação de pontos foram exploradas ao longo dos anos, podendo ser divididos em duas categorias (VOSSelman, 2000): métodos que estimam diretamente os parâmetros de superfície por agrupamento e localização de máximos no espaço de parâmetros e os métodos que consideram as relações de conectividade entre pontos (por exemplo proximidade, inclinação e similaridade de superfície). Ambos são frequentemente

²Atividades humanas, radiação solar e outros fatores provocam variação aleatória da temperatura atmosféricas, o que conseqüentemente leva à formação de ventos e causa de turbulência atmosférica. Somado a isso, a variação na temperatura atmosférica produz mudanças na densidade do ar. O efeito acumulado dessas mudanças resulta em espalhamento e desvio (difração) do feixe óptico e outros efeitos (ZHAO et al., 2013).

³Neste estudo, considerar a nomenclatura: Modelo Digital de Superfície (MDS), Modelo Digital de Terreno (MDT) e Modelo Digital de Superfície Normalizado (MDSn)

referenciados na literatura como conceitos *Data-Driven* e *Model-Driven*

Shan e Sampath (2007) consideraram dois critérios na determinação de um ponto pertencer a classe solo ou não: o ângulo entre pontos vizinhos e a elevação. O primeiro critério permite detectar as fronteiras entre duas classes pela mudança brusca de ângulo entre dois pontos. O critério de elevação considera o fato de que pontos na superfície possuem valores inferiores em relação aos da classe não-solo, considerando um determinado limiar de vizinhança. O problema em utilizar apenas esses critérios de separação é a dependência das características da superfície analisada. Em topografias acidentadas, com variações bruscas de elevação e inclinação, o algoritmo se confundiria constantemente.

Uma abordagem comum é o uso de operadores morfológicos (OM) para o ajuste e classificação dos pontos. A morfologia matemática é um tipo de transformação não-linear que processa imagens de acordo com critérios básicos de forma, tamanho, textura, uniformidade, entre outros. Dentre os operadores, incluem os de erosão, dilatação, abertura e fechamento. Segundo Rottensteiner et al. (2005), a filtragem por OM permite a aquisição de MDTs mais consistentes. Lindenberger (1993) introduziu a utilização de operadores morfológicos para classificação de pontos, de modo que operadores de abertura com estrutura horizontal classificam os pontos de acordo com suas elevações médias locais. Nesse caso, entretanto, o operador possui a limitação na qual necessita determinar o tamanho da estrutura. Arefi e Hahn (2005) apresentaram um filtro por OM com estruturas dinâmicas.

Frameworks mais sofisticados de classificação consideram a distribuição dos pontos e suas informações contextuais, como é o caso da técnica de Campo Aleatório Markoviano (*Markov Random Fields* - MRF). A utilização de MRF nas áreas de visão computacional e processamento de imagem em sensoriamento remoto é baseada na ideia de que: (i) imagens são consideradas um conjunto de nós relacionados individualmente a cada *pixel* ou aglomerado de *pixels*; (ii) variáveis ocultas associadas a cada nó são introduzidas no modelo designado para representar os valores dos *pixels* (cores ou intensidades); (iii) o modelo de junção probabilística é construído sobre os *pixels* e variáveis ocultas; (iv) a dependência estatística direta entre as variáveis ocultas é expressa por um agrupamento explícito. Tais grupos são frequentemente descritos como pares de arestas em um grafo. Anguelov et al. (2005) apresentaram uma extensão do modelo markoviano denominado AMN (*Associative Markov Network*), que classifica os pontos baseando-se em estatísticas de forma, informações de distância, elevação ou inclinação, no entanto, falha ao analisar objetos pequenos, como arbustos ou carros.

Os Campos Aleatórios Condicionais ou CRFs (*Conditional Random Fields*) (LAFFERTY; MCCALLUM; PEREIRA, 2001) são também *frameworks* probabilísticos sofisticados e reconhecidos para o propósito da classificação contextual. Assim como MRF, a técnica também recai sobre a teoria de grafos, em que a relação entre os pontos é expressa pelas arestas no grafo, que modelam as relações contextuais entre os pontos adjacentes. Em termos de classificação da nuvem de pontos, CRF apresenta um ganho de performance e exatidão na rotulação dos pontos. Niemeyer, Rottensteiner e Soergel (2013) propuseram um classificador de nuvem de pontos CRF incorporado a Florestas Aleatórias (*Random Forest* - RF)(BREIMAN, 2001), em experimentos realizados, o classificador apresentou melhorias sobre o modelo CRF tradicional, principalmente, na separabilidade entre as classes de edificações e árvores de grande porte, sendo os resultados mais expressivos para a classe de edificações, além de apresentar vantagens no desempenho.

Métodos baseados em aprendizado de máquina são também frequentemente explorados na literatura. Devido a sua capacidade em manusear grandes quantidades de dados, o conceito já conhecido pela aplicação em dados 2D foi rapidamente estendido para planos 3D. A exemplo disso, as Máquinas de Vetores Suporte (*Support Vector Machines* - SVM) (VAPNIK; CORTES,

1995) está no grupo de métodos de aprendizado supervisionado que podem ser aplicados na classificação, regressão e tarefas em aprendizado de máquina, sendo consideradas como as mais adotadas na análise de dados e reconhecimento de padrões em visão computacional e sensoriamento remoto. Em seu conceito mais comum (classificação binária), um conjunto de amostras de treinamento representando duas categorias de dados é apresentado, e a partir de um algoritmo de treinamento, constrói-se o modelo de separação linear entre essas classes. Na prática, os pontos de diferentes classes muitas vezes se sobrepõem uns aos outros. Por essa razão, a separabilidade se torna difícil ou impraticável com o uso do modelo linear. O conceito de classificação para problemas não-linearmente separáveis utilizando SVM surgiu em 1995 (VAPNIK; CORTES, 1995) com finalidade de complementar essa necessidade. Em comparação com outros métodos de aprendizagem de máquina frequentemente utilizados na classificação, como K-médias (MACQUEEN, 1967) e Mapas Auto-Organizáveis (*Self-Organizing Maps* (SOM)) (KOHONEN, 1982), o SVM apresenta vantagens no que diz respeito à não necessidade de inúmeros treinamentos ou de diferentes arquiteturas para os tipos variados de dados.

A classificação de dados ou imagens pela técnica de RF (BREIMAN, 2001) estende o conceito da classificação por árvore de decisão simples, que utiliza todo o conjunto de dados para formular a árvore. Diferentemente, o método RF divide aleatoriamente os dados em subconjuntos, de forma que a cada subconjunto seja criado um tipo de amostragem (árvore), denominada inicialização (*bootstrap*). Quando a floresta está formada, há um número grande de árvores de decisão a serem testadas e todas contribuem para a classificação do objeto em estudo, por meio de um voto sobre qual classe o atributo meta deve pertencer. Cada voto é ponderado de acordo com a similaridade e força entre as árvores; quanto menor o valor e precisão de uma árvore, melhor será sua nota. Esta técnica pode ser considerada mais precisa quando comparada a SVMs (CARUANA; KARAMPATZIAKIS; YESSINALINA, 2008), além de serem computacionalmente mais efetivas, evitar sobreajuste, serem pouco sensíveis a ruídos e eficientes na classificação de conjuntos grandes de dados, tal como nuvens de pontos (GISLASON; BENEDIKTSSON; SVEINSSON, 2006).

Por fim, a técnica OBIA pode ser entendida como uma das mais recentes a ser aplicada em nuvem de pontos. O acrônimo OBIA (*Object-Based Image Analysis*) ou GEOBIA (*GEographic-Object-Based Image Analysis*) refere-se à análise de imagens utilizando-se do bem sucedido paradigma de orientação-a-objeto (OO) das subáreas da computação. No paradigma as características dos alvos terrestres são associadas ao comportamento espectral, forma, textura, relações contextuais e semânticas, podendo ser utilizadas para a análise de imagens, de modo a se aproximar dos processos cognitivos humanos de interpretação (BLASCHKE, 2010). Na análise baseada em objeto, o modelo de conhecimento é expresso por uma rede semântica, de forma que cada classe relaciona-se a níveis hierárquicos, que contêm os objetos que as diferentes classes representam na imagem⁴.

2.2. Reconstrução

Neste ponto, as regiões de interesse estão estritamente definidas, mas sem qualquer estrutura lógica que relacione um conjunto de pontos de uma determinada classe como pertencente a um determinado modelo geométrico urbano. Para tanto, na etapa de reconstrução as classes são processadas de acordo com suas características. Essas são definidas conforme a necessidade da aplicação, por exemplo, para estudos de vegetação ou ambientes urbanos, a princípio, são definidos apenas as classes de solo e não-solo. A partir dessa classificação, grande parte dos

⁴Redes semânticas são tipos específicos de grafos que podem exercer e representar o conhecimento humano por meio das relações entre os inúmeros vértices.

pontos são descartados em processos posteriores, em que a vegetação não é considerada em tarefas envolvendo extração de edificações.

A etapa de reconstrução consiste principalmente na aplicação de rotinas de modelagem geométrica. Segmentação, neste caso, consiste no processo de subdividir um determinado dado em regiões menores, cuja homogeneidade de cada região obedece a um determinado critério de semelhança. Na reconstrução geométrica, portanto, o conjunto de pontos referente a cada segmento é submetido a processos de reconstrução geométrica, de forma que pontos de um segmento relacionado a uma superfície plana logo é relacionado também a uma região de telhado, a partir disso o objeto edifício é reconstruído.

Segmentadores clássicos normalmente empregam o conceito *Data-Driven*, como técnicas utilizando a formulação por crescimento de regiões, na qual um ponto arbitrário evolui conforme critérios de similaridade pré-estabelecidos. Brenner (2005) aplicou o método sobre pontos classificados como não-solo com o objetivo de delinear as áreas de telhados ou áreas planas. Os segmentos finais são então submetidos à análise de vizinhança para a formação das diferentes faces de um mesmo edifício. Embora a técnica seja promissora quando aplicada em dados já classificados, é necessário estabelecer ainda métricas que considerem as variações estruturais dos desníveis dos telhados. Ademais, a técnica falha quando duas ou mais regiões estão sobre fronteiras suavizadas.

Aplicações envolvendo a reconstrução de edifícios a partir de seus telhados partem da premissa fundamental de que esses assumam estruturas lineares e superfícies planas. Ao estabelecerem isso, os resultados nem sempre são bons pelo motivo dos algoritmos serem extremamente sensíveis a ruídos (VOSELMAN; VELDHUIS, 1999). Overby et al. (2004) exploram a utilização da técnica de Transformada Hough (TH)(HOUGH, 1962) para a identificação de telhados. A técnica tornou-se uma contribuição relevante em visão computacional pela sua capacidade robusta e eficiente em detectar formas geométricas em imagens. Em Schindler e Bauer (2003), a TH foi então estendida para a identificação de formas no plano 3D. O problema maior dessa abordagem é que são geradas inúmeros segmentos planos, por vezes, sobrepostos entre si. Assim, é necessário identificar quais dessas faces correspondem de fato às vertentes do telhado.

A técnica Consenso de Amostra Aleatória (*RANdom SAmple Consensus - RANSAC*)(FISCHLER; BOLLES, 1981) é também popular entre as técnicas para identificação de superfícies planas. O conceito da técnica é determinar os parâmetros de um modelo geométrico com o uso mínimo de pontos. Em aplicações como a identificação de telhados de inúmeras faces, o processo é aplicado iterativamente de maneira subtrativa, ou seja, telhados extraídos em iterações anteriores são eliminados nas seguintes. A nuvem de pontos, entretanto, ocasionalmente apresenta irregularidades ou contem ruído em excesso. Nesse caso, a tendência de identificar superfícies planas falsas é maior. A combinação do método RANSAC e a técnica de crescimento de regiões é apresentada por Forlani et al. (2006). Nesse estudo, são verificadas todas as inclinações dos pontos, a fim de agrupá-los em regiões cuja semelhança obedeça um determinado critério de inclinação. Novamente, em regiões com níveis anormais de ruído, a determinação da inclinação pode ser complexa. Telhados quase sempre possuem muitos outros itens, como chaminés, circuladores de ar, janelas, desníveis, entre outros, que podem também dificultar o processo de segmentação.

Considerando como objetivo a criação de modelos 3D de edificações, a geração dos edifícios a partir das superfícies planas detectadas é, de fato, a parte mais custosa de todo o processo, pois antes de se gerarem os objetos poliédricos finais, deve-se ainda eliminar superfícies planas espúrias, agrupá-las de modo a formar os telhados conforme suas edificações, preenchendo também os espaços cuja informação não foi extraída ou foi eliminada do processo (OVERBY et

al., 2004).

Embora todos os métodos analisados tenham mostrado potencial na reconstrução 3D de edificações, poucos exploram a acurácia dos dados inerente aos respectivos sensores ou relevância altimétrica e geométrica dos resultados. Para a extração de árvores, a maioria dos métodos falha quando aplicados em áreas de vegetação densa ou quando estas estão muito próximas de estruturas artificiais. A separação entre as classes de edificações e árvores é difícil se somente um critério, tal como o tamanho ou forma, for considerado. A maioria das estruturas artificiais, no entanto, pode ser geometricamente descrita por suas informações de borda e superfícies planas (padrões lineares) utilizando simplesmente uma representação poliédrica. Árvores e edifícios podem facilmente serem discriminados de gramínea ou estradas utilizando-se dados de elevação (HAALA; BRENNER, 1999).

3. Considerações finais

Ambientes urbanos consistem em um complexo e, em geral, extenso sistema dinâmico, cuja variedade de classes assente ao uso de diversas fontes de dados com objetivo de medir, visualizar, analisar e decidir sobre tarefas envolvendo necessidades urbanas, como o planejamento e manutenção de grandes cidades e, principalmente, no registro recorrente dos objetos urbanos quanto a sua localização, regulamentação e construções futuras. Esse documento apresentou de forma breve as diversas possibilidades de reconstrução 3D por meio de dados estruturais.

Embora a tarefa em selecionar um método que satisfaça idealmente todas as condições de contorno para a reconstrução 3D urbana não seja simples e o nível atual de automatização seja comparavelmente baixo, técnicas recentes têm proporcionado a obtenção de modelos 3D com elevado nível de detalhamento, concomitantemente ao desenvolvimento de novos instrumentos e formas mais otimizadas de aquisição dos dados.

Com o progresso dos sensores, a pesquisa foi aprimorada e enriquecida com novas formas de mapeamento e análise do espaço urbano. Os dados oferecidos atualmente permitem atingir resoluções finas e a geração de produtos em alta qualidade e precisão geométrica. A utilização de dados 2D como multiespectrais, hiperspectrais e de radar tem sido essencial para a compreensão da dinâmica urbana. Entretanto, pode-se dizer que a tecnologia por nuvem de pontos tem sido decisiva para a exploração de feições urbanas tridimensionais nos últimos anos.

A variedade de soluções em relação aos processos de aquisição de modelos 3D de cidades é extensa. Nota-se, porém, que seguem o fluxo comum de detecção e reconstrução dos objetos. Em suma, na detecção é considerado a identificação da localização apurada de edificações (*footprint*) e, a partir dessas hipóteses, são adquiridas formas geométricas consistentes, assim como para árvores, estradas e demais objetos.

Por fim, técnicas de filtragem para separação entre classes de solo e não-solo ainda não oferecem qualidade aceitável. A edição manual é quase sempre necessária para a remoção de possíveis pontos classificados incorretamente. Esse processo torna-se o fator de principal impacto no esforço e tempo de processamento pós-aquisição dos dados. Além disso, os resultados dessa classificação em regiões de topografia acidentada e ambientes urbanos complexos são ainda mais insatisfatórios.

Agradecimentos

Os autores agradecem o apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

Referências

- AHMAD, A.; GADI, M. Simulation of solar radiation received by curved roof in hot-arid regions. In: *Proceedings Building Simulation 2003, Eighth International IBPSA Conference*. [S.l.: s.n.], 2003.
- ANGUELOV, D. et al. Discriminative learning of Markov Random Fields for segmentation of 3D scan data. In: *IEEE. Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. [S.l.], 2005. v. 2, p. 169–176.
- AREFI, H.; HAHN, M. A morphological reconstruction algorithm for separating off-terrain points from terrain points in laser scanning data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Citeseer, v. 36, n. 3/W19, 2005.
- BLAIS, F. Review of 20 years of range sensor development. *Journal of Electronic Imaging*, v. 13, n. 1, p. 231–240, 2004.
- BLASCHKE, T. Object-based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, Elsevier, v. 65, n. 1, p. 2–16, 2010.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001.
- BRENNER, C. Building reconstruction from images and laser scanning. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 6, n. 3, p. 187–198, 2005.
- BRETAR, F. Topographic laser ranging and scanning. In: _____. [S.l.]: CRC Press, 2008. cap. Feature extraction from LiDAR data in urban areas, p. 422–438.
- CARUANA, R.; KARAMPATZIAKIS, N.; YESSINALINA, A. An empirical evaluation of supervised learning in high dimensions. In: *ACM. Proceedings of the 25th international conference on Machine learning*. [S.l.], 2008. p. 96–103.
- FISCHLER, M. A.; BOLLES, R. C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, ACM, v. 24, n. 6, p. 381–395, 1981.
- FORLANI, G. et al. Building reconstruction and visualization from LiDAR data. *International Archives Of Photogrammetry Remote Sensing And Spatial Information Sciences*, NATURAL RESOURCES CANADA, v. 34, n. 5/W12, p. 151–156, 2003.
- FORLANI, G. et al. Complete classification of raw LiDAR data and 3D reconstruction of buildings. *Pattern Analysis and Applications*, Springer, v. 8, n. 4, p. 357–374, 2006.
- GAMBA, P.; DELL'ACQUA, F.; HOUSHMAND, B. Comparison and fusion of LiDAR and InSAR digital elevation models over urban areas. *International journal of remote sensing*, Taylor & Francis, v. 24, n. 22, p. 4289–4300, 2003.
- GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover classification. *Pattern Recognition Letters*, Elsevier, v. 27, n. 4, p. 294–300, 2006.
- GUO, L. et al. Relevance of airborne LiDAR and multispectral image data for urban scene classification using random forests. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 66, n. 1, p. 56–66, 2011.
- HAALA, N.; BRENNER, C. Extraction of buildings and trees in urban environments. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 54, n. 2, p. 130–137, 1999.
- HAALA, N.; KADA, M. An update on automatic 3D building reconstruction. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 65, n. 6, p. 570–580, 2010.
- HOUGH, P. V. C. Method and means for recognizing complex patterns. *United States Patent*, n. 3069654, 1962. Disponível em: <<http://www.freepatentsonline.com/3069654.html>>.
- ISMAIL, A. M. *Wind Driven Natural Ventilation in High-Rise Office Building With Special Reference To The Hot-Humid Climate of Malaysia*. Tese (Doutorado) — PhD, Thesis, University of Wales College of Cardiff, 1996.
- KOHONEN, T. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, v. 43, p. 59–69, 1982.
- LAFFERTY, J. D.; MCCALLUM, A.; PEREIRA, F. C. N. Conditional Random Fields: Probabilistic models for segmenting and labeling sequence data. In: *Proceedings of the Eighteenth International Conference on Machine Learning*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2001. (ICML '01), p. 282–289. ISBN 1-55860-778-1. Disponível em: <<http://dl.acm.org/citation.cfm?id=645530.655813>>.
- LINDENBERGER, J. *Laser-Profilmessungen zur topographischen Gelaedeaufnahme*. Tese (Doutorado) — University of Stuttgart, Munich, Germany, 1993.
- MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: OAKLAND, CA, USA. *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*. [S.l.], 1967. v. 1, n. 14, p. 281–297.
- MAIMAITIYIMING, M. et al. Effects of green space spatial pattern on land surface temperature: Implications for sustainable urban planning and climate change adaptation. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 89, p. 59–66, 2014.
- MESEV, V. *Remotely-sensed cities: an introduction*. London: CRC Press, 2003.
- NIEMEYER, J.; ROTTENSTEINER, F.; SOERGEL, U. Classification of urban LiDAR data using conditional random field and random forests. In: *IEEE. Urban Remote Sensing Event (JURSE), 2013 Joint*. [S.l.], 2013. p. 139–142.
- OVERBY, J. et al. Automatic 3D building reconstruction from airborne laser scanning and cadastral data using hough transform. *International Archives of Photogrammetry and Remote Sensing*, v. 35, n. B3, p. 296–301, 2004.
- ROTTENSTEINER, F. Automatic generation of high-quality building models from LiDAR data. *Computer Graphics and Applications*, IEEE, v. 23, n. 6, p. 42–50, 2003.
- ROTTENSTEINER, F. et al. Using the Dempster–Shafer method for the fusion of LiDAR data and multi-spectral images for building detection. *Information Fusion*, Elsevier, v. 6, n. 4, p. 283–300, 2005.
- SCHINDLER, K.; BAUER, J. Towards feature-based building reconstruction from images. Václav Skala-UNION Agency, 2003.
- SHAN, J.; SAMPATH, A. Urban terrain and building extraction from airborne LiDAR data. In: _____. [S.l.]: CRC Press, Boca Raton (USA), 2007. cap. Urban Remote Sensing, p. 21–42.
- SOHN, G.; DOWMAN, I. Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 62, n. 1, p. 43–63, 2007.
- TEWOLDE, M. G.; CABRAL, P. Urban sprawl analysis and modeling in Asmara, Eritrea. *Remote Sensing*, Molecular Diversity Preservation International, v. 3, n. 10, p. 2148–2165, 2011.
- UNITED NATIONS. *World Urbanization Prospects: The 2014 Revision*. New York, July 2014. Disponível em: <<http://esa.un.org/unpd/wup/Highlights/WUP2014-Highlights.pdf>>.
- VAPNIK, V.; CORTES, C. Support-vector networks. *Machine learning*, v. 20, n. 3, p. 273–297, 1995.
- VOSSelman, G. Slope based filtering of laser altimetry data. *International Archives of Photogrammetry and Remote Sensing*, INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY & REMOTE, v. 33, n. B3/2; PART 3, p. 935–942, 2000.
- VOSSelman, G.; VELDHUIS, H. Mapping by dragging and fitting of wire-frame models. *Photogrammetric Engineering and Remote Sensing*, ASPRS AMERICAN SOCIETY FOR PHOTOGRAMMETRY AND, v. 65, p. 769–776, 1999.
- VOSSelman, G. V.; MAAS, H.-G. *Airborne and terrestrial laser scanning*. [S.l.]: Whittles Publishing, UK, 2010.
- ZHAO, Y. et al. The influence of atmospheric turbulence on 3d flash lidar range imagery. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *International Conference on Optical Instruments and Technology (OIT2013)*. [S.l.], 2013. p. 90460G–90460G.