

Visualização de edifícios a partir de dados LIDAR

Nuno Rodrigues
ESTG
Instituto Politécnico de Leiria
nunorod@estg.ipleiria.pt

Adriano Lopes, Próspero Santos
DI-CITI/FCT
Universidade Nova de Lisboa
{alopes, ps}@di.fct.unl.pt

Gil Gonçalves
DM/FCT
Universidade de Coimbra
gil@mat.uc.pt

Resumo

Os dados do tipo LIDAR (Light Detection and Ranging) têm suscitado, nos últimos anos, um interesse crescente enquanto fonte de dados para criação de modelos digitais de superfície (MDS), nomeadamente na localização, caracterização e monitorização de malhas urbanas.

Neste artigo descreve-se uma metodologia para identificação e visualização de edifícios com base exclusivamente em dados LIDAR. Após o processo de modelação de dados, o algoritmo começa por identificar, em primeiro lugar, as paredes dos edifícios e só depois as restantes componentes. O processo de classificação recorre também a células com informação adicional que entretanto são criadas a partir dos dados iniciais. No final do artigo são apresentados alguns testes realizados.

Palavras-chave

Identificação e visualização de edifícios, LIDAR, modelo digital de superfície.

1. INTRODUÇÃO

No passado recente tem-se assistido a um esforço de investigação em mecanismos automáticos de identificação e visualização de edifícios a partir de diferentes fontes de dados [Gruen97, Mayer99]. As fontes mais utilizadas têm sido as imagens aéreas e os dados LIDAR. Recentemente, muitos dos estudos apontam para soluções híbridas utilizando ambos os tipos de dados, tentando assim tirar partido das vantagens inerentes a cada uma das metodologias [Liang-chien04].

Neste trabalho pretendemos mostrar que é possível obter resultados satisfatórios recorrendo apenas a dados LIDAR. Estes dados são obtidos através de tecnologia por varrimento laser, que detecta a altura dos objectos acima da superfície do terreno. É comum instalar este tipo de plataforma num avião, onde um sensor envia feixes de luz laser em direcção à superfície em estudo e mede o tempo que estes demoram a ser reflectidos. Assim, é possível calcular a distância entre o sensor e o terreno (ver Figura 1), e gerar uma nuvem de pontos 3D de coordenadas (x,y,z). A partir desta nuvem de pontos é habitualmente interpolada uma grelha altimétrica que representará o modelo digital de superfície descrito na amostra 3D [Gonçalves05]. A densidade típica deste tipo de nuvens de pontos 3D tem aumentado significativamente, o que não só confere uma maior credibilidade à tecnologia enquanto fonte de dados, como também coloca desafios interessantes em termos de modelação e visualização.

A maioria das metodologias de visualização de dados LIDAR existentes sugerem uma abordagem que começa por identificar os telhados dos edifícios e só depois as

restantes componentes [Elaksher02]. Neste artigo apresenta-se uma alternativa oposta, onde se começa por identificar as paredes dos edifícios e só depois as restantes componentes.

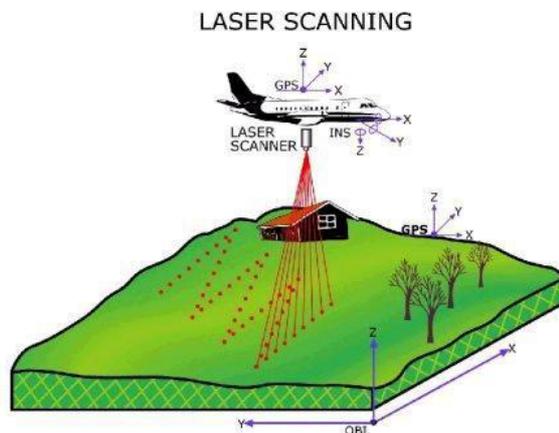


Figura 1: Detecção remota de dados LIDAR [Renslow01].

Para além desta Secção introdutória, o presente artigo está organizado da seguinte forma: na Secção 2 é apresentado o modelo de referência seguido neste trabalho e na Secção 3 é discutida a modelação de dados. Na Secção 4 descreve-se a metodologia seguida na identificação dos vários tipos de região e, na Secção 5, são abordados aspectos da visualização gráfica dos dados de interesse. Finalmente, na Secção 6, são discutidos alguns testes realizados e na Secção 7 são apresentadas conclusões e perspectivas para o trabalho futuro.

2. MODELO DE REFERÊNCIA

Este trabalho tem como suporte o modelo de referência clássico de visualização científica – *dataflow model* [Haber90].

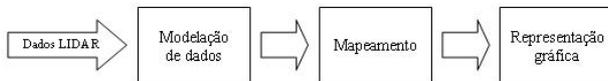


Figura 2: Modelo de referência.

Assim, numa primeira fase efectua-se a modelação dos dados LIDAR, o que consiste na geração, por interpolação, de uma grelha de pontos a partir de uma nuvem de pontos 3D. Os dados são ainda enriquecidos através da geração de informação adicional. De seguida, os dados são classificados e posteriormente mapeados em entidades geométricas. Finalmente, procede-se à visualização dos mesmos, incluindo eventualmente uma operação de simplificação quando tal se revelar apropriado.

3. MODELAÇÃO DE DADOS

Os dados LIDAR são frequentemente disponibilizados em ficheiros no formato *ASCII xyz file*. Este formato corresponde a um ficheiro de texto que utiliza a codificação ASCII (*American Standard Code*) para armazenar os dados numa nuvem de pontos 3D de amostragem.

3.1 Interpolação de dados

O objectivo principal desta fase é gerar, por interpolação, uma grelha de pontos. Por norma essa grelha é rectangular, igualmente espaçada nos eixos X e Y , com o valor de elevação no eixo Z . De facto, muitos pacotes de software de visualização de modelos digitais de superfície requerem que os pontos sejam interpolados numa grelha regular.

Existem vários métodos de interpolação espacial, os quais podem ser classificados de diversas formas: locais ou globais, exactos ou aproximados, e determinísticos ou estocásticos. Muito sumariamente, nos métodos globais cada valor Z interpolado (nó da grelha) é influenciado por todos os valores Z dos pontos dados (pontos LIDAR), enquanto que, nos métodos locais, cada valor interpolado é apenas influenciado pelos valores Z dos pontos contidos numa dada vizinhança. Os métodos de interpolação exactos produzem uma superfície que passa pelos pontos dados. No caso dos métodos aproximados, a superfície gerada não passa necessariamente pelos pontos dados, sendo implícita a existência de alguma incerteza nos valores Z . Os métodos estocásticos incorporam o conceito de geo-estatística para produzir superfícies com determinados níveis de incerteza. Finalmente, os métodos determinísticos não utilizam quaisquer elementos da teoria das probabilidades.

Neste trabalho, tendo em consideração a natureza irregular de uma nuvem de pontos LIDAR, foi utilizado um interpolador local, exacto e determinista: interpolação linear baseada numa rede triangular irregular (TIN –

Triangular Irregular Network). Este algoritmo gera uma estrutura TIN a partir de uma triangulação de Delaunay. Os pontos LIDAR são ligados de modo a que nenhuma aresta de um triângulo intersecte outro triângulo. De seguida, utilizando uma pesquisa sequencial, o algoritmo procura, para cada nó da grelha, o triângulo que o contém e interpola o valor Z deste nó, recorrendo ao gradiente do triângulo.

O espaçamento da grelha gerada é concordante com a densidade da nuvem de pontos que a originou.

3.2 Enriquecimento de dados

A utilização de apenas informação local (x,y,z) na identificação de edifícios tornaria esta operação algo errática. Assim, optou-se por criar células rectangulares contíguas com variáveis derivadas de modo a facilitar a tarefa posterior de classificação de dados (terreno ou edifício).

Cada célula é criada a partir de um conjunto de quatro pontos vizinhos, e podemos ter como variáveis associadas o comprimento, a altura e a normal unitária da célula. Os valores destas variáveis derivam essencialmente das características dos referidos pontos. Por exemplo, a altura de uma célula pode ser definida como a média (ou a maior/menor) das alturas dos pontos associados.

Estes novos dados vão substituir os dados existentes, com a particularidade de serem armazenados em ficheiros binários, atendendo às vantagens inerentes a este tipo de formato, tais como o espaço ocupado e a flexibilidade e rapidez de acesso.

Paralelamente ao enriquecimento de dados, optou-se também por providenciar uma análise estatística com o objectivo de auxiliar os utilizadores na visualização de dados. Esta análise descreve essencialmente a forma como as variáveis mais significativas na identificação de células variam ao longo da grelha. O utilizador pode, assim, observar a coloração das células da grelha de acordo com o valor da variável em causa.

4. MAPEAMENTO

Após a modelação de dados, é chegada a altura de definir a informação geométrica a visualizar. Em primeiro lugar, as células da grelha de dados são classificadas em termos de tipos de região: terreno ou edifício. Ainda dentro da categoria de edifício, tem de ser feita a distinção entre paredes e telhados.

4.1 Algoritmo Proposto

O algoritmo proposto para a identificação dos edifícios é do tipo *Region-Growing*, começando primeiro pela identificação das paredes e só depois das restantes componentes. A Figura 3 ilustra o algoritmo.

Após a especificação do método de identificação, parametrizações e restrições iniciais como sejam altura e área mínimas do edifício, o algoritmo começa por definir células contíguas que satisfazem os requisitos. No essencial, ao ser localizada uma célula que satisfaça esses parâmetros, o algoritmo processa sucessivamente as células vizinhas que também satisfazem tais requisitos, de forma a criar regiões (*Region-Growing*). A definição

destas regiões permite, por outro lado, obter informação adicional, agora de cariz mais global. Assim, estas regiões são submetidas de seguida a um processo de filtragem, com o objectivo de excluir regiões de células que possam pôr em causa alguma das restrições iniciais. Por exemplo, a dimensão do edifício, ou a área mínima das paredes. Em suma, as operações de selecção e filtragem são realizadas com o propósito de melhorar o desempenho do algoritmo (note-se que apenas um subconjunto de células passa à fase seguinte).

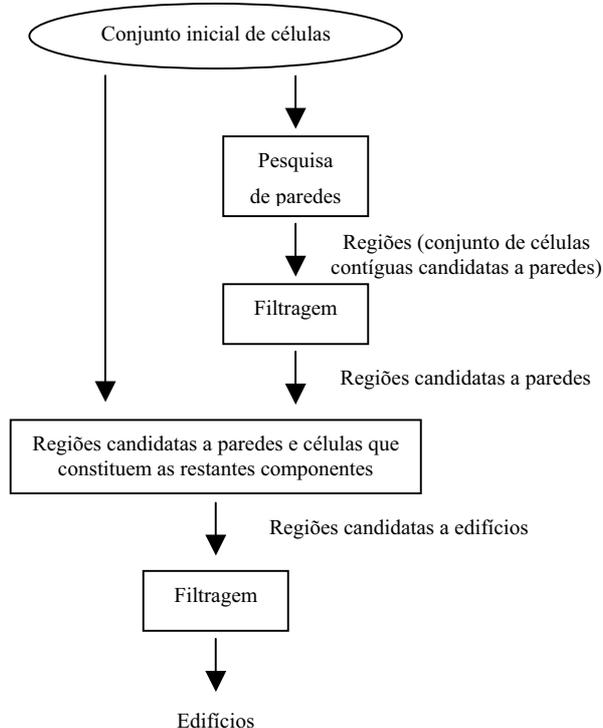


Figura 3: Algoritmo para a identificação de edifícios.

Identificadas as regiões candidatas a paredes, segue-se a identificação das restantes componentes, as quais se encontram no interior dessas regiões. Assim, o novo conjunto de células em análise é constituído pelas regiões identificadas na etapa anterior e pelas células localizadas no seu interior. Esta operação de reunião é relativamente delicada em consequência de situações particulares de localização de edifícios, as quais são abordadas na Secção seguinte. Tal como foi feito anteriormente, o resultado desta operação é novamente submetido a um processo de filtragem para remoção das regiões que não satisfazem as restrições iniciais. É de referir que esta duplicação de filtrações não prejudica o desempenho do algoritmo, uma vez que são realizadas ao nível de regiões e não de células *per si*. Por exemplo, para o MDS da Figura 9, composto por 40260 células, apenas foram detectadas 7 regiões candidatas.

4.2 Casos Problemáticos

Tal como foi referido na Secção anterior, existem algumas situações reais que podem colocar alguns obstáculos a uma correcta classificação. Essas situações derivam sobretudo de:

- resolução insuficiente de dados;
- sobreposição de entidades distintas;
- dados iniciais incompletos.

A Figura 4 ilustra uma situação de resolução insuficiente de dados, em que dois ou mais edifícios estão fisicamente mais próximos entre si do que o intervalo de amostragem da grelha. Deste modo, os edifícios são reconhecidos como um único. Na prática, é de esperar que esta situação seja pouco usual se atendermos às regras de construção de edifícios.



Figura 4: Conjunto de edifícios classificados como um único edifício.

A Figura 5 mostra um edifício assente num terreno com declive. No limite, a inclinação pode ser tal que se venha a anular a altura de uma ou mais paredes, não permitindo reconhecimento. A resolução deste problema passa pela definição de um intervalo de valores para a base das edificações dos edifícios. De facto, a base de muitos edifícios tem a configuração de um plano inclinado.

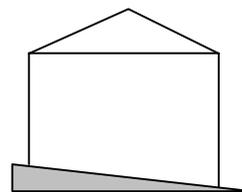


Figura 5: Sobreposição de entidades que são na realidade distintas: edifício–terreno com declive.

Por fim, a existência de dados iniciais incompletos. Esta situação pode não permitir a obtenção de uma região fechada, tal como se pode ver na Figura 6. No caso em apreço, a não identificação de uma ou mais paredes implica que não seja possível reconhecer as restantes componentes do edifício.

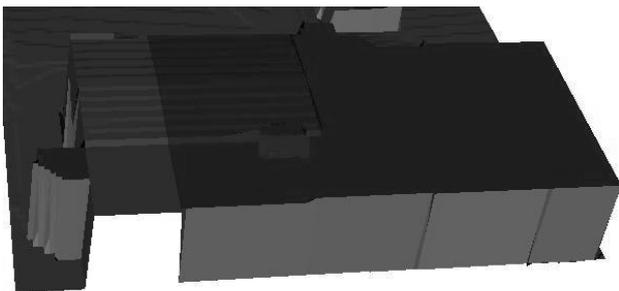


Figura 6: Dados iniciais incompletos: devido à ausência de parte da parede do edifício (cor mais clara), uma parte do telhado (cor mais escura) foi erroneamente reconhecida como terreno.

5. REPRESENTAÇÃO GRÁFICA

Seguindo o modelo de referência tem-se finalmente a representação gráfica. No essencial, pretende-se mostrar valores escalares Z numa grelha rectangular X,Y , ou seja, representar superfícies. A técnica é simples e não requer cuidados especiais. De qualquer forma, as superfícies podem ainda ser coloridas de acordo com variáveis derivadas dos dados a representar, cuja utilidade é particularmente notória em fases de estudo do modelo digital de superfície.

A Figura 7 e a Figura 8 mostram algumas colorações típicas, em função da área (Figura 7) e da normal (Figura 8). De todas as variáveis estudadas, estas foram seguramente as mais interessantes.

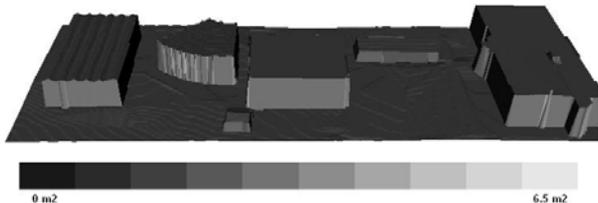


Figura 7: Modelo de superfície colorido de acordo com a área de célula.

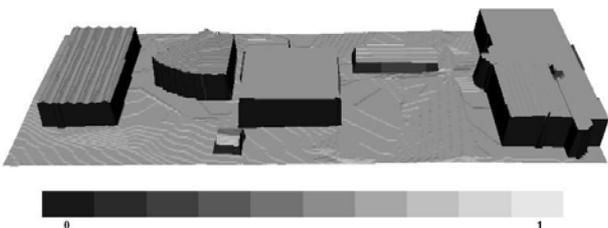


Figura 8: Modelo de superfície colorido de acordo com a direcção da normal de célula.

Tal como é patente na Figura 7, as células de maior área representam paredes de edifícios, o que se explica pelo facto de, ao estarem os pontos de amostragem igualmente espaçados em X,Y e ao surgirem paredes, as diferenças de elevação em Z entre os diversos pontos que constituem as células serem superiores às das células quase na horizontal.

Relativamente às normais, é de salientar que estas são sempre imprescindíveis para a representação gráfica do modelo 3D, independentemente da sua utilização no contexto de estudo do modelo.

Convém ainda referir que, em grandes extensões de dados, é em geral notória a existência de um gradiente praticamente nulo de valores Z . É o caso de regiões do tipo terreno. Deste modo, optou-se por facultar uma operação de dizimação (*decimation*) tendo em vista uma simplificação da malha de pontos a representar. A remoção de pontos é parametrizada pelo utilizador. Em suma, consegue-se uma melhoria de desempenho sem pôr em causa a qualidade de representação.

5.1 VTK

O VTK (*The Visualisation ToolKit*) é uma biblioteca de rotinas gráficas 3D, de código aberto, que desde há alguns anos vem sendo utilizada por muitos investigadores em todo o mundo. Esta ferramenta é composta por cerca de 700 classes em C++ e as aplicações que a utilizam podem ser implementadas num conjunto vasto de linguagens – C++, Tcl, Java ou Python. A escolha do VTK está relacionada com o facto de estar a um nível de abstracção elevado, ser código aberto e estar particularmente vocacionada para visualização científica. A título de exemplo, o VTK disponibiliza o algoritmo de dizimação referido na Secção anterior, sendo eficiente em termos de desempenho e taxa de redução, com preservação da topologia do modelo [Schroeder04].

6. TESTES

No presente trabalho foram utilizados dois MDS. O primeiro, cuja visualização se apresenta na Figura 9, consiste num MDS obtido por restituição fotogramétrica sobre um par estereoscópico de imagens áreas, onde o operador seleccionou manualmente os detalhes a representar. O segundo, representado na Figura 10, é um MDS interpolado a partir de uma nuvem de pontos LIDAR. Como este MDS não foi submetido a nenhuma operação de pré-processamento, a superfície representada pelo modelo contém, além do terreno natural, todos os objectos que se encontravam sobre a superfície no momento do varrimento laser: edifícios, pontes, vegetação, automóveis, etc.

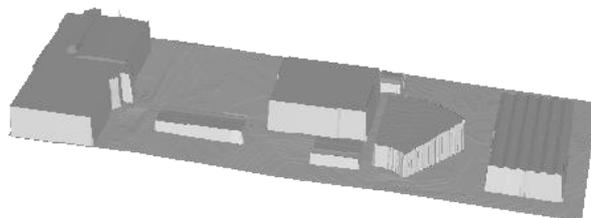


Figura 9: Resultado para o MDS obtido por restituição fotogramétrica.



Figura 10: Resultado para o MDS obtido de dados LIDAR (sem restituição fotogramétrica).

No primeiro caso (Figura 9), quase todas as células dos edifícios foram correctamente identificadas, devido sobretudo à simplicidade do modelo e à ausência de elementos que pudessem perturbar a classificação.

No segundo caso (Figura 10), como era de esperar, a existência de elementos perturbadores, como seja o caso da vegetação, conduziu a uma menor qualidade na classificação dos dados. De facto, a vegetação constitui uma das principais dificuldades na identificação de edifícios [Brunn98]. Por exemplo, mesmo que fosse possível evitar a classificação isolada de árvores como edifícios, recorrendo a restrições iniciais como a área mínima de cada edifício, existiria sempre o problema de um conjunto de árvores estarem relativamente próximas entre si, o que levaria a classificar todo o conjunto como um único edifício; ou, ainda, quando existissem árvores relativamente próximas de um edifício e que seriam classificadas como parte integrante deste. Estas situações são ilustradas na Figura 11.

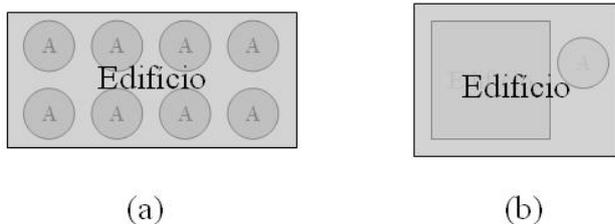


Figura 11: (a) Conjunto de árvores classificadas como edifício (b) Edifício e árvore classificadas como um único edifício.

7. CONCLUSÕES E TRABALHO FUTURO

O desenvolvimento do trabalho permite concluir, desde já, que é possível obter bons resultados na visualização de modelos digitais de superfícies utilizando apenas dados LIDAR. Por outro lado, a estratégia seguida de identificação inicial das paredes e só depois das restantes componentes revelou-se eficaz na minimização do número de testes necessários a uma correcta classificação das células.

No entanto, continuam a subsistir problemas de resolução algo complicada, nomeadamente os casos que decorrem de resolução insuficiente de dados ou de dados iniciais incompletos. Por exemplo, a classificação incorrecta devido a dados iniciais incompletos, patente na Figura 6, não surgiria se fosse seguida a estratégia clássica de identificação dos telhados em primeiro lugar. No entanto, essa estratégia também não se prestaria a uma correcta classificação de superfícies topográficas relativamente pouco planas. Nesses casos existem grandes diferenças de elevação de terreno e assim, a altura mínima a partir da qual as células são classificadas como telhado teria apenas um valor relativo – por exemplo, uma célula com determinada altura mínima pode estar associada a um telhado ou a uma montanha. Naturalmente que, em situações em que tal seja computacionalmente aceitável, poder-se-á sempre equacionar a utilização de estratégias híbridas.

A investigação futura estará direccionada para a melhoria da análise estatística de dados, derivando e conjugando novas variáveis recorrendo, inclusive, a métodos de análise inteligente sobre dados correctamente identificados. Neste campo incluem-se alguns algoritmos de inteligência artificial, nomeadamente de redes neuronais, utilizando, por exemplo, os pacotes de *software* SAS ou Clementine.

É importante referir, a terminar, que o presente trabalho se enquadra no da construção de um ambiente interactivo de visualização de dados georreferenciados, com características evolutivas em termos espaciais e temporais.

8. REFERÊNCIAS

- [Brunn98] A. Brunn, U. Weidner. Hierarchical Bayesian nets for building extraction using dense digital surface models. *ISPRS Journal of Photogrammetry & Remote Sensing*, 53(5): 296-307, 1998.
- [Elaksher02] Ahmed Elaksher, James Bethel. Reconstructing 3D buildings from LIDAR data. Technical Commission IV Symposium 2002 - Geospatial Theory, Processing and Applications, 2002.
- [Gonçalves05] G. Gonçalves. Análise do erro de interpolação em MDS urbanos obtidos por varrimento Laser. Actas da IV Conferência Nacional de Cartografia e Geodesia. pp 23-32, Lidel - Edições Técnicas, 2005.
- [Gruen97] A. Gruen, E.P. Baltsavias, O. Henricsson, (Eds.) Automatic Extraction of Man-Made Objects

from Aerial and Space Images (II), Birkhaeuser Verlag, 1997.

[Haber90] R. Haber, D. McNabb. Visualization idioms: a conceptual model for scientific visualization idioms. Visualization in Scientific Computing, pp. 74-93. IEEE Computer Society Press, 1990.

[Liang-chien04] C. Liang-chien, T. Tee-ann, S. Yi-chen, L. Yen-chung, R. Jiann-yeou. Fusion of Lidar Data and Optical Imagery for Building Modeling. XXth ISPRS Congress, Istanbul, Turkey, p. 732 ff, 2004.

[Mayer99] H. Mayer. Automatic object extraction from aerial imagery: a survey focusing on buildings. Com-

puter Vision and Image Understanding, 74(2): 138-149, 1999.

[Renslow01] M. Renslow. Development of a Bare Ground DEM and Canopy Layer in NW Forestlands Using High Performance LIDAR. ESRI international user conference, 2001.

[Schroeder04] William Schroeder, Ken Martin, Bill Lorensen. The Visualization Toolkit, 3rd edition. Kitware, Inc. Publishers, 2004.