

引用格式:王森援,蔡国榕,王宗跃,等.基于加权约束的单体建筑物点云表面重建算法[J].地球信息科学学报,2019,21(5):654-662. [Wang S Y, Cai G R, Wang Z Y, et al. Algorithm based on weighted constraints for reconstructing the point cloud surface of single-building[J]. Journal of Geo-information Science, 2019,21(5):654-662.] DOI:10.12082/dqxxkx.2019.180661

基于加权约束的单体建筑物点云表面重建算法

王森援¹, 蔡国榕^{2,3}, 王宗跃², 吴云东^{2,3*}

1. 集美大学理学院, 厦门 361021; 2. 集美大学计算机工程学院, 厦门 361021;
3. 福建省海西政务大数据应用协同创新中心, 福州 350003

Algorithm based on Weighted Constraints for Reconstructing the Point Cloud Surface of Single-Building

WANG Senyuan¹, CAI Guorong^{2,3}, WANG Zongyue², WU Yundong^{2,3*}

1. School of Science, Jimei University, Xiamen 361021, China; 2. School of Computer Engineering, Jimei University, Xiamen 361021, China; 3. Fujian Collaborative Innovation Center for Big Data Applications in Governments, Fuzhou 350003, China

Abstract: Building reconstruction based on 3D point cloud data has broad application prospects in fields such as high precision urban mapping and virtual reality. Due to the diverse geometry of buildings, there are widespread problems in traditional reconstruction algorithms, e.g., slow computation speed, low fitting precision, and incompleteness of building structures. Thus, with single-building as the research object, this paper proposed an algorithm based on weighted constraints for reconstructing point cloud surfaces. By fully considering each point's contribution to the fitting plane during the surface initialization process, the proposed algorithm, which is based on regular sets, simultaneously optimizes the error of adaptively weighted fitting and the smoothness of neighbor structures. The algorithm was applied to the 3D point clouds of various buildings. Results showed that, compared with conventional building reconstruction strategies, the weighted-constraints based algorithm of this study can design adaptive weights according to different types of point clouds, and can choose the optimal weight for model fitting. In cases where the point cloud data contain high noise and low accuracy, the proposed algorithm can help generate more accurate surface models for single-building.

Key words: 3D reconstruction of single-building; point cloud surface fitting; weighted constraint; regular set; Lidar point clouds; UAV

***Corresponding author:** WU Yundong, E-mail: yundongwu@jmu.edu.cn

收稿日期: 2018-12-14; 修回日期: 2019-01-20.

基金项目: 国家自然科学基金项目(61702251); 福建省高校产学研合作科技重大项目(2017H6015); 福建省自然科学基金项目(2016J01310、2016J01309); 厦门市科技局项目(3502Z20183032)。[**Foundation items:** National Natural Science Foundation of China, No.61702251; Major Projects of Industry-University Cooperation in Fujian Province, No.2017H6015; Project supported by the Natural Science Foundation of Fujian Province, No.2016J01310, 2016J01309; Science and Technology Bureau of Xiamen, No.3502Z20183032.]

作者简介: 王森援(1993-), 女, 山西长治人, 硕士生, 主要研究方向为测绘遥感技术和点云的三维重建算法。

E-mail: collenwang@jmu.edu.cn

***通讯作者:** 吴云东(1967-), 男, 浙江衢州人, 博士, 教授, 主要研究方向为遥感信息处理, 三维重建等。

E-mail: yundongwu@jmu.edu.cn

摘要: 建筑物点云表面重建在高精度城市测绘、虚拟现实等领域有十分广泛的应用前景。由于建筑物的几何形态多变,重建算法普遍存在计算速率慢、拟合精度低和模型结构不完整的问题。为此,本文以单体建筑物为研究对象,提出基于加权约束的单体建筑物点云表面重建算法,在表面初始化过程中充分考虑数据对结构拟合的贡献。在此基础上,构建基于正则集的单体建筑物表面重建算法,实现建筑物拟合过程中的加权拟合误差、近邻结构平滑的同步优化。针对多类建筑物三维点云的实验结果表明,相比传统的建筑物重建策略,本文的加权约束方法可根据不同类型的点云数据设计自适应权重,并选择模型拟合中最优的权重函数,在高噪声、低精度点云数据下能得到更高精度的单体建筑物表面模型。

关键词: 单体建筑物三维重建;点云表面拟合;加权约束;正则集;Lidar点云;无人机

1 引言

高精度、大场景三维虚拟环境的快速重建,是当前“智慧城市”、“虚拟现实”等应用领域的关键技术问题。由于建筑物具有几何结构多变、纹理复杂等特点,要从原始点云数据中还原出建筑物的几何结构具有很大的挑战。为此,研究人员针对快速、高精度建筑物三维重建算法展开了深入的研究。根据重建策略的差异,现有的建筑物点云表面重建方法主要分为2类,基于表面平滑的重建方法和基于原始基元的重建方法。

基于网格结构的表面重建^[1-2]是表面平滑重建中常用的算法,如The Power Crust法^[3]、A-Shape法^[4]、R-Graphs法^[5]等,通过对点云进行Delaunay三角剖分,然后根据一定的拓扑准则提取点云的三角面片来重建物体表面。这类方法能构造一致的网格拓扑结构,但由于采用四面体剖分来搜索网格,因此其速度慢、效率低,且依赖于与点位置相关的定向法线和其他特定的测量信息。Brinkley^[6]、Schmitt等^[7]对上述直接进行空间三角剖分的方法进行了改进,通过将点云投影到二维切平面,对投影点进行Delaunay三角化后还原到三维空间。改进后的算法虽然能加快网格化速度,但从二维点的拓扑结构还原到三维空间时会出现结构错乱、网格不一致的情况。在此基础上,邵磊等^[8]将点云数据投影到二维影像,并结合建筑物自身的几何特征进行提取,该方法明显提高了数据处理效率和模型立面的准确率,但面对低矮建筑物中具有相似结构的地物时,仍会出现错误和模型不完整的结果。刘凯斯等^[9]针对复杂环境低矮建筑物问题提出二面角滤波法。

基于原始基元重建方法的兴起,弥补了网格结构重建速度慢、效率低的问题,受到研究者的广泛关注。经典的方法是RANSAC^[10]算法及其变形,例如Groupsac^[11]、PROSAC^[12]和Multi-Structure Estimation^[13]等。该类算法通过迭代从数据集中选择内点集,利用其对模型进行估计。通过不断优化从数据

集中选择内点的方式,提高了重建效率,但算法迭代次数较多且不稳定。Jenke等^[14]运用RANSAC算法提取基本的几何模型和轮廓候选点,通过优化函数得到边界轮廓。Chen等^[15]和Chauve等^[16]运用平面近似表面,其中丢失平面用自定义自动补全的方式进行重建。Lafarge等^[17]从激光雷达数据中通过重排平面和二次曲面重建建筑物,该方法仅限于2.5D重建。Gallup等^[18]提出了一种基于多视角平面扫描的立体视觉算法,借助GPU加速进行实时三维重建。Straub等^[19]将场景描述为曼哈顿结构的叠加,使用基于梯度优化的混合Gibbs采样方法来进行重建。Arikan等^[20]提出贪婪的更新迭代算法来确定原始基元的内在关系。国内武汉大学将结构模型的相互关系表示为层次拓扑树,在数据不完整的情况下也能生成完整的结构模型^[21]。上述方法通过提取基元的方式明显提高了重建效率,然而忽略了基元间的邻接关系,尽管根据先验知识,如共面性,同轴性或并行性等全局关系重新调整模型结构,但得到的平面有可能倾斜,降低了模型的精确度。为此从全局的角度考虑,Aron等^[22]提出基于正则集的人造场景重建算法,在提取基元的同时获取基元之间的关系,从而保证较小的主结构不会被较大的主结构覆盖,同时又能兼顾全局结构,最后通过能量函数选择最终的平面集合。

基于正则集的重建算法中初始基元直接影响重建的后续处理,在数据初始化时,研究者通过设计单一的权重函数来剔除局外点。由于数据不同,所以权重函数产生的效果各不相同,这不适用于对建模精度要求较高的情况。故本文提出基于加权约束的建筑物点云表面重建算法,在表面初始化过程中充分考虑数据对结构拟合的贡献。

2 加权约束的正则集点云表面重建算法

本文提出的正则集重建方法首先对初始基元

集进行加权约束,从全局的角度考虑面之间的拓扑关系,在此基础上,通过生成结构的规则约束,包括数据拟合约束、正则项约束以及相邻结构的平滑约束来优化模型拟合的精度。

2.1 正则集点云表面重建算法流程

基于正则集的点云表面重建算法主要分为3个步骤:点云的初始化、候选集的生成和正则集的选择。

(1)点云的初始化:给定大规模原始无序点集 S ,先用区域生长算法对点云集 S 进行过分割,根据法线一致性得到近似平面的点云块 $\{S_j\}$, j 为每个分块点云的索引,再通过初始平面拟合得到该点云的局部初始基元集 $P: \{P_j\}$ 。

(2)候选集的生成:由于局部拟合生成的原始基元集 $P: \{P_j\}$ 容易受到异常值的影响,从全局结构来看, S_j 可能被其他位置的平面模型通过刚性变换更好的拟合,比如基元 P_i (P_i 为点云块 S_i 初始拟合后的基元平面)旋转 90° 平移到点云块 S_j 的几何中心。这样 S_j 就有一系列新的模型集 $\{P_{i \rightarrow j}, \dots\}$, $i=1,2,\dots$ 。通过如上的规则,在每一个点云块生成更多地平面模型。由此得到了扩充集合 $P=\{P_{i \rightarrow j}, \dots\}$, $i=1,2,\dots$ 。

(3)正则集的选择:正则集的选择是从扩充的候选集中选择子集的过程。设二值指示变量 $\chi_{i \rightarrow j} \in \{0,1\}$,如图1所示,以二维矩形为例,图1(a)中点云块 $S_{i,j,k,l}$ 的初始拟合平面分别为 P_i, P_j, P_k, P_l ,点云块 S_j 的候选模型由 P_i, P_k, P_l 经过平移旋转得到,图1(b)中, P_i 旋转 90° 后经过平移得到 $P_{i \rightarrow j}$,同样地, $P_{k \rightarrow j}, P_{l \rightarrow j}$ 为 S_j 的候选模型。若 $P_{i \rightarrow j}$ 被选中为点云块 S_j 的有效拟合模型,则 $\chi_{i \rightarrow j}=1$,若未选中, $\chi_{i \rightarrow j}=0$ 。

二值指示变量集合 $[\chi_{i \rightarrow j}, \dots]$, $i,j=1,2,\dots$ 表示最终的有效模型集,即正则集。由于建筑物拓扑结构的复杂性,需根据结构相似性分组选择正则集,因此引入指示变量 $\chi_i \in \{0,1\}$, χ_i 表示一组模型中变换的源基元,所以指示变量 $\chi_i = \max_j \chi_{i \rightarrow j}$ 。此算法将正则

集的选择问题转换为最小化能量函数的问题。算法的优化过程同时考虑数据项 E_{data} 、非正则项 E_{irr} 和空间平滑项 E_{spat} ,能量最小化公式为式(1):

$$\{\chi_i\}, \{\chi_{i \rightarrow j}\} = \arg \min E = \lambda E_{data} + (1-\lambda) E_{irr} + E_{spat} \quad (1)$$

式中: $\sum_j (\chi_{i \rightarrow j} \chi_i - \chi_{i \rightarrow j}) \geq 0, \forall i$, 保证当 $P_{i \rightarrow j}$ 被选中为 S_j 的有效拟合模型时,该组模型的源基元 S_i 也需有效。 $\lambda \in [0, 1]$, 输入高精度数据或经过预处理的数据时,选择接近1的数据项权重,如0.8;当数据中含有大量噪声或数据缺失,选择小的 λ 值,甚至接近0;一般情况下,取 λ 近似等于0.5。

2.2 基于变权重的数据项加权约束分析

数据项 E_{data} 是用来评价模型对点云数据的拟合准确度,使用待拟合点与模型的拟合误差总和作为评价指标。在初始拟合阶段中,基于正则集的重建算法使用主成分分析^[23](Principal Component Analysis, PCA)将待拟合点到模型的距离误差总和作为评价指标,在含有大量噪声的数据中会出现较大偏差。故本文根据拟合点到模型的距离设定权重,其标准函数为式(2)、式(3):

$$E_{data} = \sum_j \sum_i \chi_{i \rightarrow j} E_d(P_{i \rightarrow j}, S_j) \quad (2)$$

$$E_d(P_{i \rightarrow j}, S_j) = \frac{1}{|\{p_h \in S_j\}|} \sum_{p_h \in S_j} weights(d(p_h, P_{i \rightarrow j}))^2 \quad (3)$$

式中:二值指示变量 $\chi_{i \rightarrow j}$ 表示某个候选模型 $P_{i \rightarrow j}$ 是否被选中为点云块 S_j 的拟合模型; E_d 为模型 $P_{i \rightarrow j}$ 到点云块 S_j 的误差;其中 $weights$ 是自变量为点到相应模型距离的权重函数,可由式(4)计算得到:

$$weights(d^*(i)) = f(d^*(i)) \quad (4)$$

式中: $d^*(i)$ 为点 i 到相应平面的距离; f 为设定的权重函数; $weights(d^*(i))$ 为点 i 得到的权重。

根据点云数据特点的不同,可采用以下几种典型加权函数。根据原始正则集的重建算法,其权重




图1 $\chi_{i \rightarrow j}$ 的图示表述

Fig. 1 Graphical illustration of $\chi_{i \rightarrow j}$

函数可由式(5)表示二次凸型加权主成分分析曲线(Convexity Principal Component Analysis, CnvPCA2)。

$$weights(d) = (d^2 - 1)^2 \quad (5)$$

比较曲线的曲率, 本文在式(5)的基础上提出函数 $f = (x^4 - 1)^2$, 其曲率大于式(5), 用四次凸型加权主成分分析曲线(Convexity Principal Component Analysis, CnvPCA4)表示, 同时参考直线型函数 $f = -|x| + 1$, 用线型加权主成分分析曲线(Line Principal Component Analysis, LinePCA)表示, 此外比较曲线弧向下弯曲的函数 $f = |x^2 - 2|x| + 1$ (凹型加权主成分分析曲线(Convexity Principal Component Analysis, CncPCA)), 分析权重函数的曲率对重建效果的影响。

在设定权重函数的方法中, 局内点的权重值反应了该点与拟合模型的一致性。理想的权重函数可以抑制异常点/噪声点的参与, 同时而不会过度惩罚正常的点。为此, 本文根据平面的最大内点数确定最合适的平面 \hat{M} , 具体如式(6)所示。

$$\hat{M} = \arg \max_M \left\{ \sum_{p_i \in U} T(p_i, M) \right\} \quad (6)$$

式中: U 是总点集; $T(p_i, M)$ 是局内点的判定函数, 计算公式如下:

$$T(p_i, M) = \begin{cases} 1 & d_i < d_t \\ 0 & \text{否则} \end{cases} \quad (7)$$

式中: d_i 是点到平面距离; d_t 是距离阈值; 用 Classic 表示。

由于式(7)将阈值之外的点全部舍去, 同时也剔除了部分正常点, 有可能降低数据质量。故提出式(8)的权重函数: 线型递减加权主成分分析曲线(Line Descending Principal Component Analysis, LDPCA)。

$$weight(d) = \begin{cases} 1 & |d| \leq d_1 \\ \frac{d_2 - |d|}{d_2 - d_1} & d_1 < |d| < d_2 \\ 0 & \text{其他} \end{cases} \quad (8)$$

式中: d_1 和 d_2 是 0 到距离阈值 d_t 的设定值 (如 0.2 d_t , 0.7 d_t)。相对于式(8), 较连续的权重函数式(9)是沿着“钟”曲线递减的平滑曲线, 即“钟”型递减加权主成分分析曲线(Bell Descending Principal Component Analysis, BDPCA)。

$$weight(d) = \exp\left(-\frac{d^2}{\sigma_d^2}\right) \quad (9)$$

综上, 本文提出模型拟合过程中的权重函数方程如图2所示。




图2 模型拟合的权重函数在0-1上的图像

Fig. 2 Image of the weight functions of model fitting at 0-1

2.3 正则集点云表面重建算法非正则项与平滑项约束

非正则项 E_{irr} (式(10)) 用来评价基元模型间的匹配度, 非正则项越小模型越准确。

$$E_{irr} = \sum_{i,k} \chi_i \chi_k Irr(p_{i \rightarrow i}, p_{k \rightarrow k}) \quad (10)$$

式中: $Irr(p_{i \rightarrow i}, p_{k \rightarrow k})$ 为非正则项函数, $Irr(p_{i \rightarrow i}, p_{k \rightarrow k}) := f(\angle(n_i, n_k))$, 定义 $f(x) := 1 - \exp(-\delta x)$, χ_i 表示模型 $P_{i \rightarrow i}$ 是否被选择, 需满足: $\sum_i \chi_i - \chi_i \geq 0, \forall i$ 。

空间平滑项将满足距离足够小, 并且法向量方向足够近的2个点云块 S_j 和 S_l 合并, 平滑项的能量方程为(式(11)):

$$E_{spat} = \sum_{j,l,i,k,j \neq l} \chi_{i \rightarrow j} \chi_{k \rightarrow l} neigh(S_j, S_l) C_{spat}, \quad (11)$$

$$C_{spat} = (1 - \lambda)/10$$

式中: C_{spat} 为固定的空间惩罚项。其中, $neigh(S_j, S_l) := I\left(\min_{p_g \in S_j, p_h \in S_l} \|p_g - p_h\| < 2\rho\right), I(\angle(n(S_j), n(S_l)) < \tau)$, 当点云块 S_j, S_l 距离小于 2ρ , 且法向量方向夹角小于 τ , 则认为是邻近点云块。 S_j, S_l 距离通过2点云块中点 $P_g \in S_j, P_h \in S_l$ 的最小距离来计算。

2.4 算法流程

为了提高算法效率, 表1在候选集生成阶段, 通过设置阈值控制生成的候选集的数量, 并且采用从粗到精的平面提取策略。在粗略的水平上, 只考虑较大的初始平面 (基于面积)。提取后的平面集的关系被确定, 即不允许改变。然后, 引入下一级别的候选集, 重复之前的提取过程。

表1 加权约束的正则集点云表面重建算法
Tab. 1 A regular-set point cloud surface reconstruction algorithm with weighted constraints

输入:点云分割块 $\{S_i\} \in \mathcal{S}$,局部匹配候选集 $\{P_{i-j} \in P\}$,角度集 θ
输出:正则集 $P'=\{P_{i-j}\}$,模型之间的关系集 $\{<P_{i-j}, P_{i-k}, rels>\}$
1: $P^0:=\{P_{i-j}\} \in P$ // (1) 初始化
2: $P':=\emptyset$ // 候选集的初始集合
3: $\theta:=area_{max}/area_{min}$ // 估计面积阈值
4:while $P' \neq \emptyset$ do // (2) 候选集生成
5: $P_0:=\{P_{i-j}, s.t. \forall j \ area(P_{i-j}) > \theta\} \in P^0$ // 选择大于阈值的初始候选集
6: $P^0:=P^0 \setminus P_0$
7: $\tilde{P}:=P_0 \cup Enrich(P_0, P') \cup Enrich(P_0, P_0)$ // 扩充候选集
8: $P':=P' \cup \{P \subseteq \tilde{P}\}$ // 最小化能量方程 // (3) 选择正则集
if no break in enrich then decrease area threshold $\theta = \theta / 2$ // (4) 迭代
9:return P'
10:function Enrich($P, P_{fixed}, \tilde{P} _{max}=2300$)
11:for each pair $<P_{i-j} \in P, P_{k-l} \in P_{fixed}>$ do
12: if $\min_e (\theta_e - \angle(n_i, n_k)) < r$
13: then $\tilde{P}:=\tilde{P} \cup \{P_{k-l}\}$ // 生成新的候选集
14: if $ \tilde{P} > \tilde{P} _{max}$ then break // 限制变量的数目
15:return \tilde{P} // 候选集扩充结束

3 实验结果及分析

3.1 实验设置

本文的算法在Ubuntu平台上,使用c++编程实现,分别在不同数据源和数据规模上进行实验。其中集装箱,楼房来源于集美大学无人机航拍影像点云数据,欧拉大楼(Euler),组合箱(Boxunion)为激光雷达点云数据,Euler数据来源于文献[24],Boxunion来自伦敦大学智能几何处理实验室^[25];帝国大厦(Empire)、含噪声的组合箱(Boxunion_noise)为含有大量噪声的激光雷达点云数据,其中Empire来源于文献[17],Boxunion_noise在Boxunion的基础上加了高斯噪声。

为比较本文所述权重函数对模型拟合误差的影响,主要从2个方面考虑评估误差:几何保真度和覆盖范围,即计算模型与内部点的均方根距离和分配给形状的点的比例。图3为原始数据,表2为实验数据的参数,其中点密度用点之间的平均距离衡量。

3.2 实验结果分析

第一组在影像点云集装箱上进行实验,图4为集装箱在以上所述权重函数下的可视化实验结果,各种方法在正视图上效果相差不大,侧面的效果图

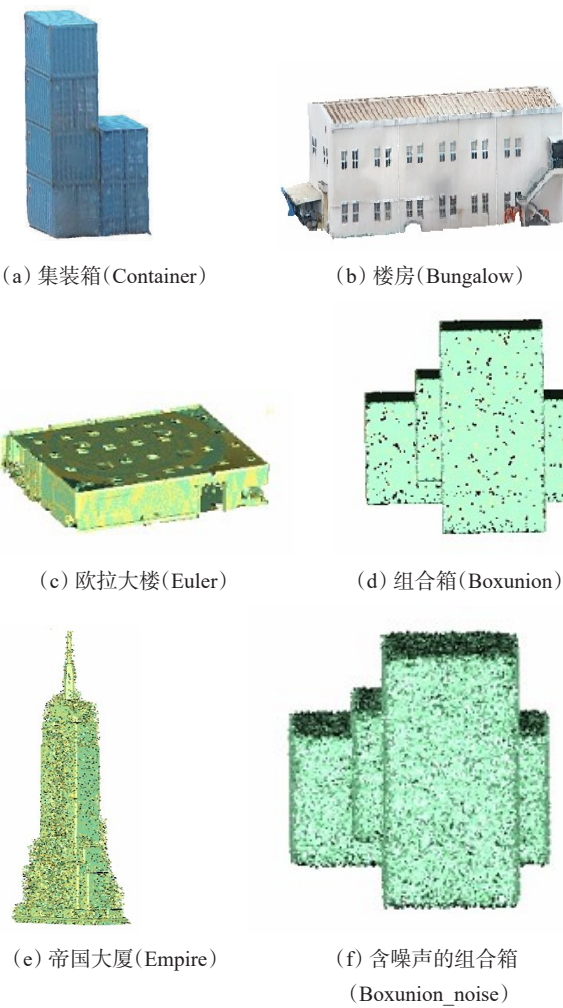


图3 实验数据
Fig. 3 Experimental data

表2 实验数据的参数
Tab. 2 Parameters of the experimental data

数据	输入点的个数	点密度/m
集装箱(Container)	81 k	0.08
楼房(Bungalow)	71 k	0.3
欧拉大楼(Euler)	586 k	0.004
组合箱(Boxunion)	100 k	0.02
帝国大厦(Empire)	1.2 M	0.0025
含噪声的组合箱(Boxunion_noise)	100 k	0.08

显示,除CnvPCA2和CnvPCA4外,均有多余的一个小平面。表3显示了各种方法的误差对比。可以看出,CnvPCA2使数据达到最大利用率,分配给形状的点的比例远超过其他方法,均方根误差最小。上凸型曲线CnvPCA2给予正常点较大的权重,使其对平面拟合有更大的贡献。相比CnvPCA2,CnvPCA4给所有点的权重更大,容易受到异常值的干

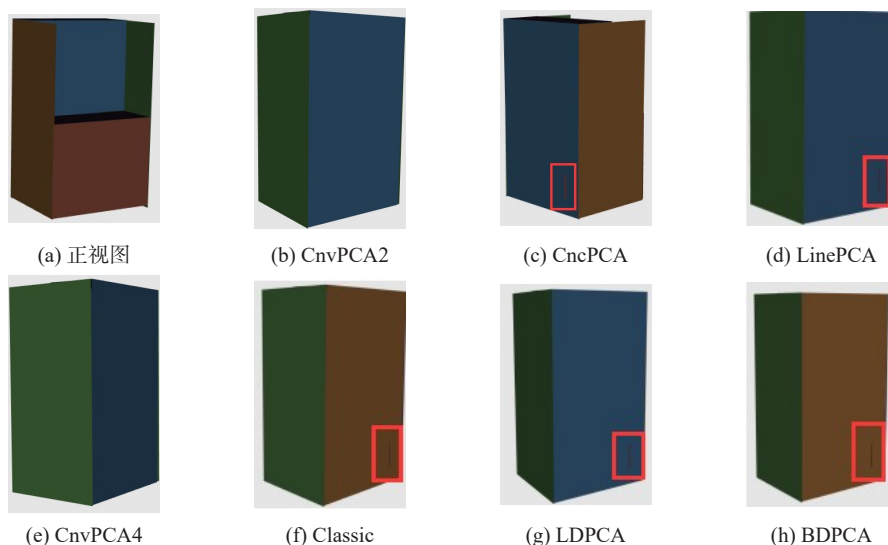


图4 集装箱的可视化重建效果

Fig. 4 Visual reconstruction effect of container

表3 模型拟合的权重函数的结果误差对比

Tab. 3 Comparison of result errors using weight functions of model fitting

方法	均方根误差/m	分配给形状的点的比例/%
CnvPCA2	7.975	72.83
CncPCA	14.072	26.97
LinePCA	14.065	26.98
CnvPCA4	12.165	49.33
Classic	15.039	13.19
LDPCA	14.002	26.94
BDPCA	14.334	26.01

扰,从而误差变大。Classic将一定阈值之外的点全部去掉,拟合效果严重依赖于此阈值的设定,但其值难以准确判定。CncPCA,LinePCA,LDPCA更关注距离模型较远的点的抑制,LDPCA通过分段给拟合点分配权重,距离模型足够近的点给予充分大的权重,其余点的权重在一定阈值范围内随距离单调递减,抑制效果较好。曲率较小的曲线BDPCA对距离模型较远的点抑制作用不明显,在分配给形

状的点比例较小的情况下产生了较大的均方根误差。图5为楼房的可视化重建效果。

第二组在激光点云 Euler 上进行实验,图6为 Euler 在以上所述权重函数下的可视化结果。表4显示了各种方法的误差对比。对于激光点云数据,由于原始数据精度较高,各种权重函数对拟合结果的影响相差不大。抛物线非线性加权方法 CnvPCA2 分配给形状的点的比例最大,拟合误差小于其他方法。如图6所示,CncPCA 和 Classic 方法中,建筑物 Euler 的墙面出现了碎片。LinePCA 和 CnvPCA4 方法没有完全重建侧面墙上的板。LDPCA 在水平面和垂直面的邻接部分出现较明显的空隙。图7为 Boxunion 的可视化重建效果。

第三组在带有噪声的激光点云 Empire 上进行实验,图8-图9为 Empire 在以上所述权重函数下的可视化实验结果。表5显示了各种方法的误差对比。对于含有噪声的激光点云数据,如前两类数据




图5 楼房的可视化重建效果

Fig. 5 Visual reconstruction effect of Bungalow

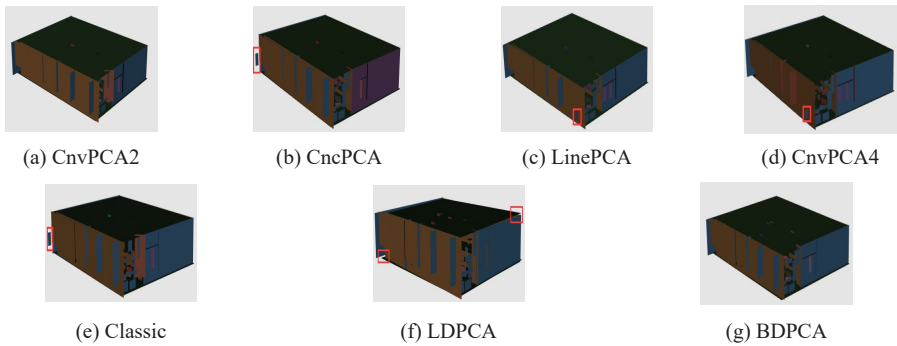


图6 欧拉大楼的可视化重建效果
Fig. 6 Visual reconstruction effect of Euler

表4 模型拟合的权重函数的结果误差对比
Tab. 4 Comparison of result errors using weight functions of model fitting

方法	均方根误差/m	分配给形状的点的比例/%
CnvPCA2	0.0614	77.614
CncPCA	0.0654	77.019
LinePCA	0.0632	76.437
CnvPCA4	0.0647	77.612
Classic	0.0689	77.014
LDPCA	0.0703	76.462
BDPCA	0.0627	77.612

的实验结果, CnvPCA4 比 CnvPCA2 误差较大。Classic 使得更多的噪声点参与到模型拟合中, 误差

明显增大, 图9(e)Classic的实验结果所示, Empire的顶部小圆柱体各个面较分散。曲率小的曲线BDPCA分配权重时, 随拟合点到模型的距离增大而缓慢递减, 最终模型由各个点贡献的加权和决定, 如表5所示整体拟合误差相对较小。CncPCA, LinePCA算法拟合效果相近, 下凸型曲线CncPCA较大程度抑制了正常点的贡献率, 导致拟合误差大于LinePCA。LDPCA在阈值内直线下降, 正常点参与拟合的贡献极低, 另外加上大量的噪声点, 局外点的干扰, 极端情况如图8(f)LDPCA所示, Empire的一个侧面没有生成。图10为Boxunion_noise的可视化重建效果。

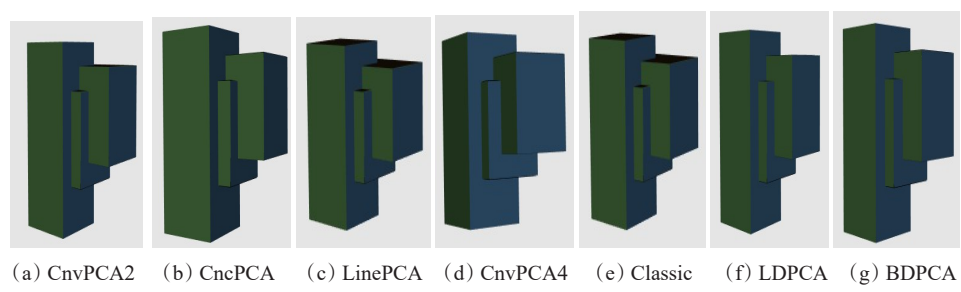


图7 组合箱的可视化重建效果
Fig. 7 Visual reconstruction effect of Boxunion

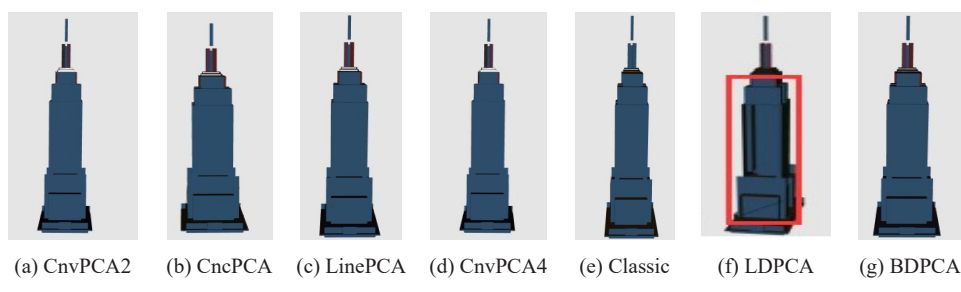


图8 帝国大厦塔身的可视化重建效果
Fig. 8 Visual reconstruction effect of Empire tower




图9 帝国大厦塔顶的可视化重建效果

Fig. 9 Visual reconstruction effect of the tower top

表5 模型拟合的权重函数的结果误差对比

Tab. 5 Comparison of result errors using weight functions of model fitting

方法	均方根误差/楼高/m	分配给形状的点的比例/%
CnvPCA2	0.491	80.75
CncPCA	0.499	80.50
LinePCA	0.476	80.64
CnvPCA4	0.496	80.68
Classic	1.724	80.50
LDPCA	10.570	78.62
BDPCA	0.466	80.64

4 结论

建筑物点云表面重建精度受点云质量和复杂结构的影响,传统的单体建筑物点云表面重建精度不高,结构不完整,本文算法使用数据加权约束的策略以及正则集的全局结构约束方法进行重建,主要有以下3个结论:

(1)基于正则集的重建算法提出抛物线非线性权重策略和钟形权重策略。根据数据质量选择相

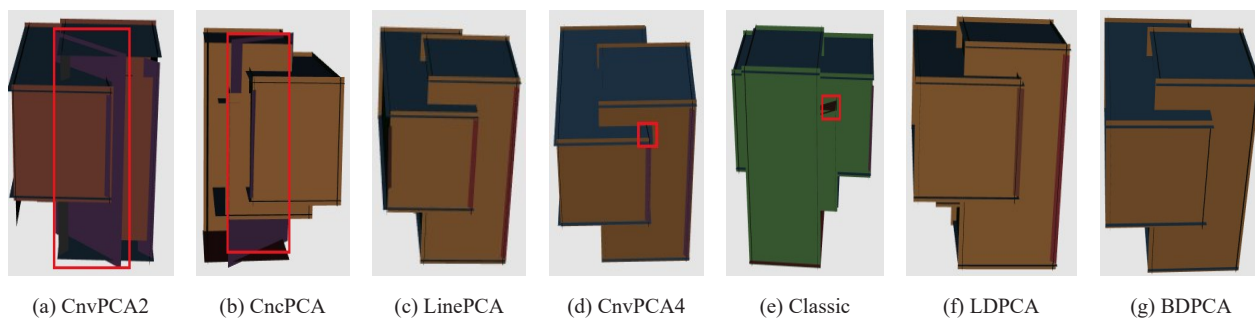


图10 含噪声的组合箱的可视化重建效果

Fig. 10 Visual reconstruction effect of Boxunion_noise

应的加权策略,当原始数据精度较高时,选择抛物线非线性权重函数CnvPCA2进行拟合,点落在模型上的数量可保持在70%,均方根误差可比其他权重函数小,甚至降低一倍;当数据含有大量噪声,选择钟形权重函数BDPCA比Aron等^[21]提出基于正则集的人造场景重建算法均方根误差可降低5%。

(2)对含有噪声的数据进行拟合时,如果使用LDPCA直接剔除一定阈值外的所有点,会导致整体模型拟合的均方根误差增高10%,显著影响拟合效果。

(3)通过提取基元的同时获取基元间的关系,从全局角度进行重建,可保留易被主结构淹没的细小结构,有效地构建完整的建筑物模型。

参考文献(References):

- [1] Amenta N, Bern M, Kamvysselis M. A new voronoi-based surface reconstruction algorithm[C]// Proceedings of the 25th annual conference on Computer graphics and interactive techniques, ACM, 1998:415-421.
- [2] Labatut P, Pons J P, Keriven R. Robust and efficient surface reconstruction from range data[C]// Computer graphics forum. Oxford, UK: Blackwell Publishing Ltd, 2009, 28(8):2275-2290.
- [3] Amenta N, Bern M W, Kamvysselis M. A new voronoi-based surface reconstruction algorithm[C]//Siggraph. 1998, 98:415-421.
- [4] Edelsbrunner H, Mucke E. Three dimension alpha shapes

- [J]. ACM Transactions on Graphics, 1994,13(1):43-72.
- [5] Amenta N, Bern M, Kamvy. A new voronoi-based surface reconstruction algorithm[C]// Proceedings of SIGGRAPH'98, 1998:19-24.
- [6] Brinkley J F. Knowledge-driven ultrasonic three-dimensional organ modeling[C]// IEEE Trans. Pat. Anal. Mach. Intell, 1985,7(4):431-441.
- [7] Schmitt F, Barsky B A, Du W. An adaptive subdivision method for surface fitting from sampled data[J]. Computer Graphics, 1986,20(4):179-128.
- [8] 邵磊,董广军,于英,等.车载激光扫描数据中建筑物立面快速提取[J].地球信息科学学报,2018,20(4):462-470. [Shao L, Dong G J, Yu Y, et al. A fast method of building extraction from mobile Li DAR scanning data[J]. Journal of Geo-information Science, 2018,20(4):462-470.]
- [9] 刘凯斯,王彦兵,宫辉力,等.机载 Li DAR 点云数据的二面角滤波算法[J].地球信息科学学报,2018,20(4):414-421. [Liu K S, Wang Y B, Gong H L, et al. Dihedral angle filtering algorithm for airborne Li DAR point cloud data [J]. Journal of Geo-information Science, 2018,20(4):414-421.]
- [10] Schnabel R, Wahl R, Klein R. Efficient RANSAC for point-cloud shape detection[C]// Computer graphics forum. Oxford, UK: Blackwell Publishing Ltd, 2007,26(2): 214-226.
- [11] Ni K, Jin H, Dellaert F. Groupsac: Efficient consensus in the presence of groupings[C]// Computer Vision, 2009 IEEE 12th International Conference on. IEEE, 2009:2193-2200.
- [12] Chum O, Matas J. Matching with PROSAC-progressive sample consensus[C]// Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on. IEEE, 2005,1:220-226.
- [13] Wong H S, Chin T J, Yu J, et al. Dynamic and hierarchical multi-structure geometric model fitting[C]// Computer Vision (ICCV), 2011 IEEE International Conference on. IEEE, 2011:1044-1051.
- [14] Jenke P, Krückeberg B, Straßer W. Surface reconstruction from fitted shape primitives[C]// Vision, Modeling & Visualization Conference, Konstanz, Germany, 2008:31-40.
- [15] Chen J, Chen B. Architectural modeling from sparsely scanned range data[J]. International Journal of Computer Vision, 2008,78(2-3):223-236.
- [16] Chauve A L, Labatut P, Pons J P. Robust piecewise-planar 3D reconstruction and completion from large-scale unstructured point data[C]// Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on. IEEE, 2010:1261-1268.
- [17] Lafarge F, Alliez P. Surface reconstruction through point set structuring[C]// Computer Graphics Forum. Oxford, UK: Blackwell Publishing Ltd, 2013,32(2pt2):225-234.
- [18] Gallup D, Frahm J M, Mordohai P, et al. Real-time plane-sweeping stereo with multiple sweeping directions[C]// 2007 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2007:1-8.
- [19] Straub J, Rosman G, Freifeld O, et al. A mixture of manhattan frames: Beyond the manhattan world[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2014:3770-3777.
- [20] Arikan M, Schwärzler M, Flöry S, et al. O-snap: Optimization-based snapping for modeling architecture[J]. ACM Transactions on Graphics (TOG), 2013,32(1):6.
- [21] Hu P B, Yang B S, Dong Z, et al. Towards reconstructing 3D buildings from ALS data based on gestalt laws. Remote Sensing, 2018,10(7):1127.
- [22] Monszpart A, Mellado N, Brostow G J, et al. RAPter: Rebuilding man-made scenes with regular arrangements of planes[J]. ACM Transactions on Graphics, 2015,34(4): 10301-10312.
- [23] Mackiewicz A, Ratajczak W. Principal components analysis (PCA)[J]. Computers and Geosciences, 1993,19:303-342.
- [24] Oesau S, Lafarge F, Alliez P. Indoor scene reconstruction using feature sensitive primitive extraction and graph-cut [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014,90:68-82.
- [25] Guerrero P, Kleiman Y, Ovsjanikov M, et al. PCPNet learning local shape properties from raw point clouds[C]// Computer Graphics Forum, 2018,37(2):75-85.