

一种室内场景点云平面分割的新方法

李琪琪^{1,2}, 花向红^{1,2*}, 赵不钊^{1,2,3}, 陶武勇^{1,2}, 李丞^{1,2}

¹ 武汉大学测绘学院, 湖北 武汉 430079;

² 武汉大学灾害监测与防治研究中心, 湖北 武汉 430079;

³ 东华理工大学江西省数字国土重点实验室, 江西 南昌 330013

摘要 针对室内场景点云平面分割存在的问题, 提出一种基于投影长度点云分层和基于均值漂移法向量约束的平面分割新方法。该方法首先通过主成分分析方法估算点云的法向量, 再求取点云的投影长度并进行分层, 然后取最大分层点云进行法向量约束, 利用余下点云拟合求取平面参数并去除该平面模型包含的点云, 重复上述步骤以求取所有平面的参数, 接着在原始点云中提取模型点云并进行模型优化, 得到最终的平面分割结果。实验结果证明, 所提方法可以有效分割室内场景点云中的平面结构, 提取的点云平面有较高的精度, 且相较于最大似然采样一致性算法和改进的 3D 霍夫变换方法, 所提方法在时间效率上有很大提升, 更适用于室内场景点云的平面分割。

关键词 测量; 激光点云; 室内场景; 平面分割; 投影长度; 点云分层; 均值漂移

中图分类号 P237

文献标志码 A

doi: 10.3788/CJL202148.1604002

1 引言

近年来, 随着三维激光扫描技术的发展, 物体的三维点云模型被广泛应用在测绘^[1-2]、导航^[3]、工业生产^[4]以及古建筑修复和保护^[5]等领域。随着虚拟现实(Virtual Reality, VR)技术及室内导航定位技术的快速发展, 室内三维点云的提取及建模成为了众多学者研究的热点话题之一。通常情况下, 室内场景环境比较复杂, 扫描得到的点云数据较为杂乱, 而且存在较多物件和遮挡, 所以无法对其进行自动化建模, 此时需要对复杂的室内点云进行分割处理以形成简单的几何图元^[6], 通过对这些图元的识别和建模来构建复杂的室内场景三维模型。因此, 对室内场景点云的分割是实现三维模型重建的重要基础。

目前, 国内外针对室内场景点云的分割进行了大量研究, 其中主流方法有语义分割法^[7-9]与几何模型分割法两类。语义分割法主要通过点云的上下文

拓扑关系来识别一定的特征, 进而对模型进行判别; 几何模型分割法通常采用简单的几何参数模型作为先验信息, 通过验证点云对参数模型的符合程度来实现对点云模型的识别和分割。其中最典型的几何模型分割法就是随机采样一致性(RANSAC)方法^[10], 目前绝大多数的几何模型分割方法都是由 RANSAC 改进而来的, 包括 MLESAC(Maximum Likelihood Estimation Sample Consensus)^[11]和 Multi-RANSAC^[12]等。文献[13]在 RANSAC 算法的基础上利用八叉树对其进行优化, 提高了平面的提取效率。文献[14]在 MLESAC 算法的基础上引入点云的平面维度特征来估算点云模型的先验概率, 提出了一种附加点云先验概率的随机采样一致性算法(Prior-MLESAC), 其在拟合精度和速度上均有一定的提升。文献[15]提出了一种多模型拟合的分割算法, 首先生成假设模型, 然后对假设模型进行分裂和组合, 最终实现室内点云的分割, 实验表明该算法对平面和柱面模型有较好的分割效果, 且时

收稿日期: 2020-12-17; 修回日期: 2021-01-17; 录用日期: 2021-02-25

基金项目: 国家重点研发计划(2017YFB0503400)、国家自然科学基金(41674005, 41871373)、东华理工大学江西省数字国土重点实验室开放研究基金(DLLJ202015)

通信作者: * xhhua@sgg.whu.edu.cn

间消耗远低于常规方法。另一种典型的几何模型分割法是由 Paul 等于 1962 年提出的 Hough 变换 (HT) 法, 该算法最初用于二维图像中的直线检测^[16]。目前, Hough 变换法已经发展出多种形式, 包括改进的概率 Hough 变换 (PHT)^[17]、随机 Hough 变换 (RHT)^[18] 和 3D-Hough 变换 (3D-HT)^[19] 等算法, 这些算法均能够完成多种二维和三维模型的识别。文献[20]提出了一种基于优化稀疏三维矩阵模型投票和 Hough 空间有效峰值检测的 3D-HT 算法, 其可以有效加速投票过程。文献[21]通过采样点投票的方式提取了平面, 减少了时间复杂度。文献[22]利用点云法向信息大大减少了 3D-HT 算法在识别平面过程中的计算复杂度, 从而缩减了点云平面的探测时间。因为室内场景中大量诸如墙体和地面一样的平面结构, 所以对平面点云的分割是室内场景点云分割的重要组成部分之一。由于室内场景点云的复杂性和庞大性, RANSAC 算法和 3D-HT 算法在室内场景平面点云的分割过程中分别存在着迭代次数多和计算复杂度随角度步长的减小而急剧上升的问题, 上述问题会影响点云分割的效率。

针对室内场景点云平面提取效率的问题, 本文提出一种新的室内场景点云平面分割方法, 在每次点云平面提取之前, 先进行一种基于投影长度的点云分层并对最大的分层点云进行基于均值漂移^[23]的法向量约束, 使得处理后得到的点云基本来自一个平面模型, 从而大大提高单次平面提取的内点比例, 减少 RANSAC 算法的迭代次数, 进而提高平面点云的分割速度。通过对平面模型进一步优化处理, 能够有效去除模型点云中的过分割点云和无关点。

2 研究方法

所提方法的总体流程如图 1 所示。首先通过主成分分析 (PCA) 法^[24]估算点云法向量, 然后根据点云的法向量和三维坐标来求取各点的投影长度并取合适步长进行分层, 再取最大分层点云进行进一步基于均值漂移的法向量约束, 接着对余下点进行随机采样一致性和最小二乘 (RANSAC-LS) 的平面拟合, 以求取目标平面的参数并去除该平面模型包含的点云, 重复上述步骤直到提取所有平面的参数。根据平面参数在原始点云中提取模型点云并进行优化, 得到最终的平面分割结果。

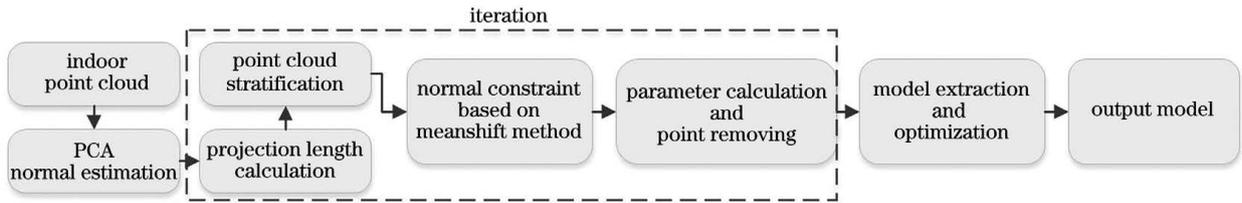


图 1 所提方法的处理流程

Fig. 1 Processing flow of proposed method

2.1 点云的法向量估计

采用 PCA 方法对点云进行法向量估计。该方法通过构建每个采样点的局部邻域并拟合最小二乘平面, 对应平面的法向量即为采样点的法向量。对点云进行局部邻域搜索, 得到每个采样点 q 和局部邻近点 $w(q_i)$, 其中 i 为邻近点的个数。通过拟合局部最小二乘平面, 可以使邻域点到平面的距离平方和最小。PCA 方法可以将拟合的最小二乘平面转化为对邻域协方差矩阵的特征值分解, 表达式为

$$M = \frac{1}{k} \sum_{i=1}^k (q_i - \bar{q})(q_i - \bar{q})^T, \quad (1)$$

$$M \times \mu_n = \lambda_n \cdot \mu_n, n \in \{0, 1, 2\}, \quad (2)$$

式中: k 为局部邻近点 q_i 的个数; \bar{q} 为局部邻近点的重心; λ_n 和 μ_n 分别为邻域协方差矩阵 M 的第 n 个特征值和对应的特征向量。

邻域协方差矩阵 M 的最小特征值所对应的特征向量即为局部最小二乘平面的法向量^[25], 即采样点 q 的估计法向量。由 PCA 方法估计得到的点云法向量具有二向性, 还需要根据其与其与视点方向的关系进行重定向, 可表示为

$$n_i = \begin{cases} n_i, & \text{if } n_i \cdot (v_p - q) > 0 \\ -n_i, & \text{else} \end{cases}, \quad (3)$$

式中: v_p 为视点; q 为采样点, 其法向量为 n_i 。

2.2 基于投影长度的点云分层

在理想状态下, 位于同一平面上的各个点指向原点的向量在该平面法向量方向上的投影长度都等于一个固定的值, 即该平面到原点的距离长度。点云的投影长度模型如图 2 所示。对于平面 P 上的任意一点 q , 原点指向 q 点的向量 v 在平面法向量 n 的投影长度恒等于平面 P 到原点 O 的距离长度, 称

该长度为点 q 的投影长度 ρ , 表达式为

$$\rho = \left| \frac{\mathbf{n} \cdot \mathbf{v}}{|\mathbf{n}|} \right|. \quad (4)$$

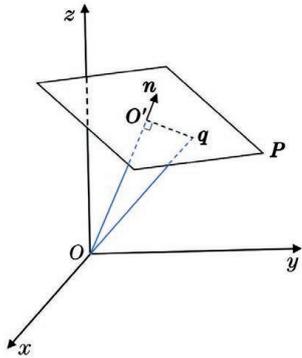


图 2 点云的投影长度模型

Fig. 2 Projection length model of point cloud

基于以上性质, 提出一种基于投影长度的点云分层方法, 用于单个平面上点云的初步聚类。因为室内场景点云中存在大量的平面, 且这些平面到原点的距离通常是不同的, 因此可以基于投影长度的点云分层方法来实现室内场景在不同平面上的点云聚类。对于点云中的每个点, 将法向量和三维坐标代入(4)式以求取对应的投影长度 ρ , 由此将整个点云映射到投影长度空间中。实际扫描得到的室内场景点云存在一定的点位误差, 且各个点的法向量估计值与实际值存在一定的偏差, 使得位于同一个平面上点的投影长度不相同, 但分布在一个较小的范围内, 故可以根据扫描点云的实际点位精度来设置一个合适的长度步长 l , 再对整个场景的点云进行分层处理, 这样位于同一分层的点基本是位于同一平面上的。每次选取当前数目最大的分层点云进行后续操作, 即每次处理当前最大的平面点云。

2.3 基于均值漂移的法向量约束

点云的法向量估计有一定误差, 特别是边缘点和离散点的法向量估计误差较大, 使得点云中的部分点出现分层错误; 或者是室内场景中恰巧存在投影长度相近的平面, 使得基于投影长度的点云分层结果中同一分层包含不止一个平面上的点。因此, 采用均值漂移法对分层点云的法向量进行进一步的约束, 通过求取法向量最集中区域的点云来找到目标平面上的点云, 以此排除上述分层错误点, 以便于后序点云平面的参数求取。

均值漂移法是基于滑动窗口的算法一种, 可以用于数据点密集区域的查找。在实际操作过程中, 将当前最大分层点云的法向量映射到高斯球面上以形成对应的法向量点云, 这时同一平面上的非边缘

点高度聚集在高斯球面上一个很小的范围内, 错误分层的点通常位于该范围之外。通过对法向量点云进行均值漂移聚类, 可以找到法向量最聚集的区域点云, 即同一平面上的点。

均值漂移聚类流程: 1) 在高斯球面上法向量点集 C 中随机取 10 个点并求取以窗口半径为 r 的邻域中的点数目, 将邻域中数目最大的点作为初始中心点 O_{initial} ; 2) 找到距离中心点 O_{initial} 小于 r 的点, 记作集合 S ; 3) 计算中心点指向集合 S 中点的向量平均值, 得到偏移向量; 4) 使中心点 O_{initial} 沿着偏移的方向移动, 移动距离为偏移向量的模; 5) 重复步骤 2)~4), 直到中心点窗口半径内的点数不再增加; 6) 输出最大的点集作为最终结果 S_{final} 。通常错误分层的点所占比例很小, 因此在经过少数几次偏移后即可找到法向量最聚集的区域点云。

2.4 点云平面参数的求解

对室内场景点云基于投影长度的点云分层处理和对最大分层点云基于均值漂移的法向量约束处理后, 余下的点集 S_{residue} 基本属于同一个平面, 可用于求取对应平面的参数。采用 RANSAC-LS 方法求取点云平面的参数, 具体流程如下。1) 从点集 S_{residue} 中随机选取最小样本集 I_m , 并根据最小样本集 I_m 计算平面参数 P_h ; 2) 计算 S_{residue} 中的所有点 q_i 到 P_h 的距离残差值 d_i , 将 d_i 小于距离阈值 T_d 的点云设置为集合 S_h ; 3) 若 S_h 中的点云数目为当前最大值, 则将 S_h 存储为最优平面内点集合; 4) 重复上述步骤 t_{max} 次, 对集合 S_h 进行最小二乘平面拟合以求取最终平面参数 P 。其中最大迭代次数 t_{max} 满足

$$t_{\text{max}} = \frac{\lg(1 - \alpha)}{\lg(1 - f^m)}, \quad (5)$$

式中: α 为在全部迭代中至少一次正确选取最小样本集的置信概率; m 为平面拟合的最小样本数, 这里 $m=3$; f 为平面模型的内点比例。

采用 RANSAC-LS 方法求取点云的平面参数后, 设置距离阈值参数 T_{d2} , 依据求取的参数将场景点云中距该平面小于 T_{d2} 的点剥离出来。通常设置 $T_{d2} > T_d$, 这样就可以减少已识别出的平面及附着在其表面的噪声点云对后序平面提取的影响。重复 2.2~2.4 节的流程, 即可陆续求解场景中平面的参数, 直到最后剥离出的点云数目小于数目阈值 T_{num} 为止, T_{num} 根据点云密度和具体平面提取的需求来设置。

2.5 平面模型的优化

经过迭代的平面分割步骤, 室内场景点云中的

平面结构参数可以全部求得。根据平面参数来设置厚度阈值参数 T , 在原始场景点云中提取距离小于 T 的点, 作为平面模型点云。在实际处理过程中发现, 当根据平面参数来提取平面模型点云时, 除了在目标区域内提取出相应平面的内点, 还会在其他平面点云或无关点云中提取出符合该平面参数的点, 造成点云过分割, 此时需要对其进行修正或者剔除, 因此还需要对提取的模型点云进行进一步优化。以下只说明两个平面模型的情况, 多个模型的情况可以此类推。

1) 平面合并。若存在点 q 同时被平面模型 S_a 和 S_b 包含, 说明两个平面模型相交; 当平面模型 S_a 和 S_b 的夹角小于阈值 θ 时, 表示两平面既相交又平行, 在点云场景中属于同一平面结构, 需要对两个模型进行合并。

2) 过分割区域的修正。若存在点 q 同时被平面模型 S_a 和 S_b 包含, 且 S_a 和 S_b 不属于同一结构, 说明点 q 为需要修正的过分割点。通过求取点 q 的法向量与 S_a 和 S_b 的法向量的夹角, 可推断出点 q 属于夹角较小的平面模型。

3) 无关点剔除。完成过分割修复后, 在模型点云中还存在一些非结构的无关点, 这些点通常较为分散, 可以通过聚类并设置合适的数目阈值进行剔除。

3 实验结果与分析

3.1 实验平台与数据

实验平台为英特尔 Core i5-5200U @2.20 GHz 处理器, 4 GB 内存, MATLAB 2017。实验采用三组数据, 其中前两组数据由苏黎世大学(UZH)的可视化和多媒体实验室提供的办公室扫描数据 (<https://www.ifl.uzh.ch/en/vmml/research/datasets.html>), 三组数据情况如图 3 所示。为了便于观察, 图中未显示顶部点云, 但数据处理过程中依然使用完整点云。图 3(a) 中的点数有 114582 个,

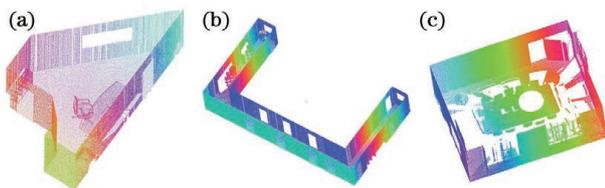


图 3 实验使用的三组数据。(a) data 1; (b) data 2; (c) data 3

Fig. 3 Three sets of data used in experiment.

(a) data 1; (b) data 2; (c) data 3

储物柜和盆栽等物体, 记为 data 1; 图 3(b) 中的点数有 409286 个, 其为办公室外部的走廊点云数据, 内部包括门框、储物柜和盆栽等物体, 记为 data 2; 图 3(c) 中的点数有 1672434 个, 其为采用 FARO 型的三维激光雷达扫描仪在武汉大学校园内某一会议室采集的点云数据, 内部包括会议桌椅、门、内嵌的窗户和小黑板等物体, 无关点数目较多, 遮挡较为严重, 该数据记为 data 3。对以上三组数据进行处理和分析, 用来验证所提方法的可行性、精度和效率。

3.2 可行性分析

为了验证所提方法的可行性, 将 data 1 作为原始数据输入, 按照点云平面分割的流程进行处理。首先通过 PCA 方法来估计点云的局部法向量, 然后结合三维坐标来求取各个点的投影长度 ρ , 再根据求取的投影长度 ρ 对整体点云进行分层处理。

设置分层步长 $l=0.05$ m, 基于投影长度的分层点云数目如图 4 所示。从图 4 可以看到, 其中存在 4 个大数目的波峰和 6 个小数目的波峰, 共 10 个在不同的投影长度区间的峰值, 由此可以初步推测出在 data 1 场景点云中至少存在 10 个不同的平面 (可能存在投影长度相近的平面被包括在同一个波峰或其周围)。

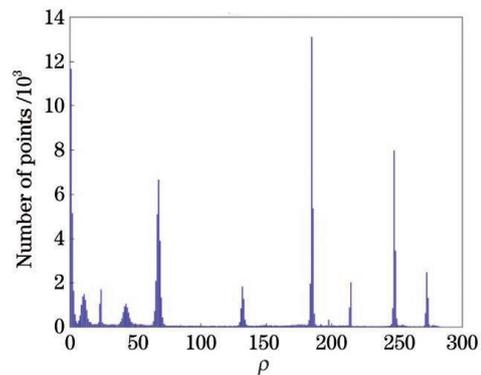


图 4 分层点云数目

Fig. 4 Number of stratified point clouds

完成点云分层后, 取出当前点数目最大的分层点云, 如图 5(d) 和图 5(e) 所示。从图 5 可以看到, 分层点云中除了目标平面点云以外, 还存在小部分其他点云。其中图 5(d) 属于场景中不存在与目标平面投影长度相近的其他平面 (如事先将坐标原点设置在 data 1 点云的重心上, 则存在与投影长度相近的平面), 而且部分法向量估计存在误差, 使得框中点云也被扫描到最大分层中。图 5(e) 属于场景中不存在与投影长度相近的其他平面, 故最大分层中只有因法向量估计误差而导致错误分层的少数外

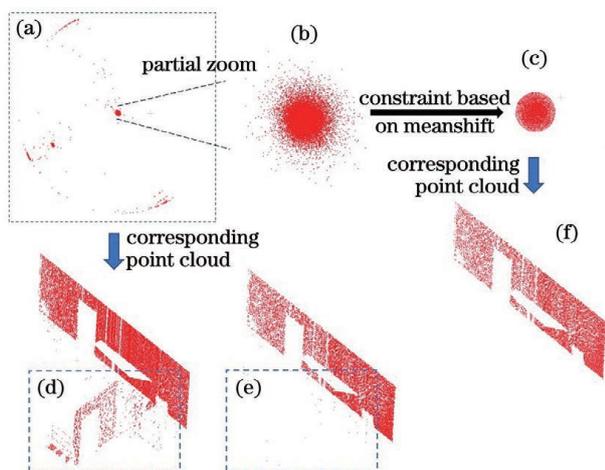


图 5 法向量约束前后的法向量高斯映射和点云。(a) 高斯球;(b)局部放大;(c)约束后的法向量;(d)最大分层点云 1;(e)最大分层点云 2;(f)约束后的点云

Fig. 5 Normal Gaussian map and point cloud before and after normal constraint. (a) Gaussian ball; (b) partial zoom; (c) constrained normal vector; (d) point cloud at maximum layer 1; (e) point cloud at maximum layer 2; (f) constrained point cloud

点。图 5(d)中的点云对应高斯球面上的法向量点云,如图 5(a)所示。从图 5(a)可以看到,目标平面对应的法向量点云高度集中在高斯球面上一个角度约为 1° 的范围内,而外点的法向量点云则在该范围

表 1 data 1 场景点云中平面的参数

Table 1 Parameters of planes in point cloud of data 1 scene

Plane	A	B	D
Plane 1	213.2745	0.0305	1971.6564
Plane 2	-2.5988×10^{-5}	1.7823×10^{-5}	-0.0034
Plane 3	26.3625	-26.9836	469.1850
Plane 4	-2.7181×10^{-6}	1.0147×10^{-5}	3.3648
Plane 5	-82.5261	-0.3624	-1122.2972
Plane 6	-498.5125	0.0325	-5334.4432
Plane 7	-281.2597	-281.1161	-2618.1471
Plane 8	0.0016	1.1324×10^{-4}	1.1738
Plane 9	0.0273	-148.1639	77.4453
Plane 10	-0.2417	-93.3212	197.1178
Plane 11	25.7364	-25.7179	454.0566

根据求得的平面模型参数来提取模型点云,设置分割点云厚度的阈值 $T=0.02$ m,初步分割结果如图 6 所示,图 6(a)为分割得到的平面,图 6(b)为天花板和地板,图 6(c)为平面分割后剩余的点云。从图 6 可以看到,室内场景中的主要结构面(如墙体、地面、天花板和桌面)都被有效分割,点云数目小

之外。因此,进一步基于均值漂移的法向量约束可以快速找到高斯球上法向量点云密度最大的区域,由此找到目标平面的点云。将均值漂移的搜索窗口半径设为 0.5° ,高斯球上经过均值漂移聚类得到的最密法向量区域如图 5(c)所示,其对应的点云是经过法向量约束的,已经去除了肉眼可见的所有外点,如图 5(f)所示。

经过法向量约束后得到的点云平面表面仍然会包含部分误差较小的噪声点,这会影响到平面模型参数的精度,故采用 RANSAC-LS 方法先剔除靠近墙体表面的噪声点,再进行最小二乘平面拟合。经过基于投影长度的分层和法向量的约束后,平面点云的内点比例达到 90% 以上,设置随机采样一致性的迭代次数 $t_{\max}=5$,设置距离阈值 $T_d=0.005$ m,这能够有效提高最终拟合得到平面模型的参数精度。

设置距离阈值参数 $T_{d2}=0.02$ m,用来剔除场景中已识别出的平面点云。由此循环迭代,逐步提取出场景中所有的平面模型。由于 data 1 的点云较为稀疏,所以为 data 1 设置最小平面点数的阈值 $T_{\min}=1000$,即当提取到的平面模型中点云数目小于 1000 时,则舍弃该模型并停止迭代。最终在 data 1 场景点云中提取出 11 个平面模型,生成的平面几何参数如表 1 所示,平面方程的形式为 $Ax + By - z + D = 0$ 。

于 1000 的平面点云(储物柜)和非结构目标点云(如椅子和盆栽)被剔除,但根据平面参数提取出来的模型点云仍存在过分割的现象,需要对点云进行优化处理,处理过程如下。1)平面合并:图 6(a)中的上方墙体同一墙面结构被过分割成两个平面(对应表 1 中平面 3 和平面 11),设置的角度阈值 $\theta = 5^\circ$,

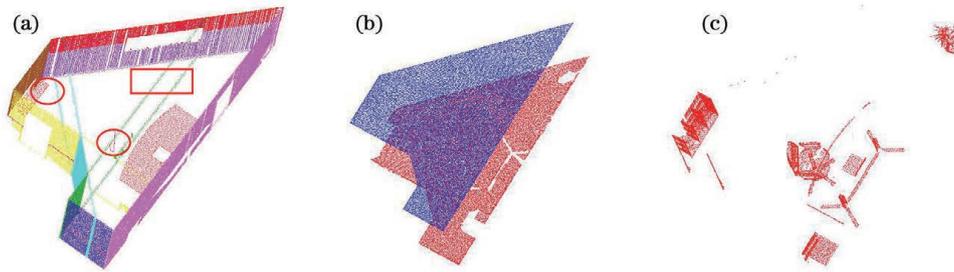


图 6 data 1 数据的初步分割结果。(a)分割的平面点云;(b)地面和天花板平面;(c)剩余点云
Fig. 6 Preliminary segmentation results of data 1. (a) Partitioned plane point clouds; (b) floor and ceiling plans; (c) residual point clouds

根据两平面模型参数求取的平面夹角为 0.69° , 故将两平面点云进行合并; 2) 过分割区域的修正: 图 6(a) 中部分平面模型点云包含其他平面上的点, 如长方型框体中墙面所在的平面点云包含了地板和天花板点云, 需根据重复点的法向量与各平面的夹角关系来判断点云所属类别; 3) 无关点去除: 图 6(a) 中椭圆框出的桌面平面点云包含了椅子靠背和储物柜的部分点云, 通过聚类并加以数目限制可以去掉。经过上述优化后的平面模型点云如图 7 所示。

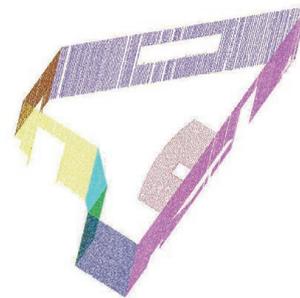


图 7 data 1 模型优化后的平面分割结果
Fig. 7 Plane segmentation results of data 1 after model optimization

经过优化处理后, data 1 数据最终分割出 10 个平面模型, 与图 4 结果一致; 通过平面参数来计算这 10 个平面的投影长度, 并与图 4 的点云投影长度峰值区间进行对比, 对比结果如表 2 所示。从表 2 可

以看到, 除了平面 2、5 和 10 的投影长度位于峰值的相邻区间, 其他平面的投影长度均落在峰值区间内, 进一步验证了所提方法的可行性。

表 2 平面模型投影长度 ρ 和点云投影长度峰值区间的对比

Table 2 Comparison between peak interval of projection length ρ of plane model and projection length of point cloud

Parameter	Plane 1	Plane 2	Plane 3	Plane 4	Plane 5	Plane 6	Plane 7	Plane 8	Plane 9	Plane 10
ρ	9.244	0.003	12.433	3.365	13.598	10.701	6.584	1.174	0.523	2.112
Peak interval	[9.225, 9.275]	[0.025, 0.075]	[12.425, 12.475]	[3.325, 3.375]	[13.625, 13.675]	[10.675, 10.725]	[6.575, 6.625]	[1.125, 1.175]	[0.475, 0.525]	[2.125, 2.175]

为了进一步验证所提方法的适用性, 继续对 data 2 和 data 3 点云进行处理, 分割结果如图 8 所示, 其中顶部点云未显示。其中图 8(a) 和图 8(c) 分

别为 data 2 和 data 3 平面点云的分割结果, 图 8(b) 和图 8(d) 为剩下的点云, data 2 点云中分割出 10 个平面 (包括天花板), data 3 点云中分割出 9 个

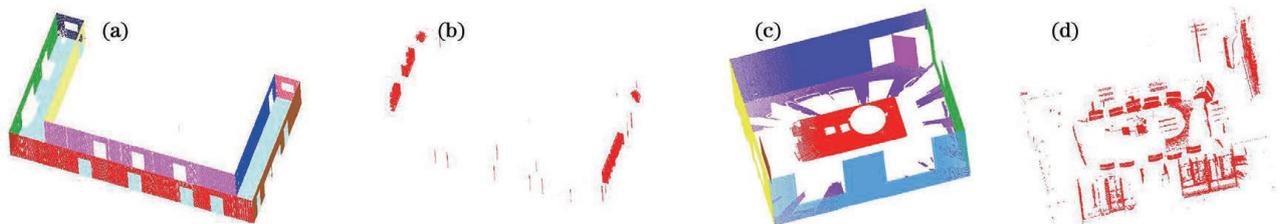


图 8 data 2 和 data 3 点云的平面分割结果。data 2 平面点云, (a) 分割结果, (b) 剩余点云; data 3 平面点云, (c) 分割结果, (d) 剩余点云

Fig. 8 Plane segmentation results of point clouds in data 2 and data 3. data 2 plane point cloud, (a) segmentation results, (b) residual point cloud; data 3 plane point cloud, (c) segmentation results, (d) residual point cloud

平面(包括天花板)。上述结果证明所提方法可以将室内场景点云中规模较大的平面结构完整分割出来,包括墙体、天花板、地面和桌面等结构,同时场景中其他无关结构如盆栽、椅子和门框等在分割过程中被剔除,避免对后续点云的分类和重建造成干扰,表明所提方法在室内场景点云平面分割中具有较好的适用性。

3.3 精度和效率分析

为了检验所提方法平面分割的精度,将 data 3 点云中提取的平面模型间的距离与实际测量数

据进行对比,结果如表 3 所示。其中平面模型间的距离由一平面点云到另一平面模型的距离的平均值表示,实测距离由徕卡 PD68 型的手持测距仪多次测量结果的平均值表示。从表 3 可以看到,所提方法计算的距离与实测值的误差都在毫米级别,远小于在点云提取中设置的阈值(0.02 m),说明所提方法分割得到的平面点云具有较高的精度;距离相对精度都大于 99%,说明了测量结果的可信度较高,侧面反映所提方法的分割精度高。

表 3 平面点云的分割精度

Table 3 Segmentation precision of plane point cloud

Object	Model distance / m	Average distance / m	Measured distance / m	Distance error / mm	Relative accuracy / %
Ceiling-desktp	2.2598	2.2595	2.2572	2.3	99.89
Desktop-ceiling	2.2592				
Floor-ceiling	3.0225	3.0223	3.0180	4.3	99.86
Ceiling-floor	3.0221				
Front wall-back wall	5.9730	5.9737	5.9749	1.2	99.97
Back wall-front wall	5.9744				
Left wall-right wall	7.7577	7.7561	7.7532	2.9	99.96
Right wall-left wall	7.7544				

考虑到在平面不平行的情况下,利用平面间距来评定精度不是十分严谨,实验继续利用空间姿态进行精度评定。采用单点测量拟合平面参数的方式来获取 data 3 点云中的主要平面模型参数,再与所

提方法求得的平面模型参数进行比较,获取每个平面的偏转角如表 4 所示。从表 4 可以看到,各个平面的偏转角都在 0.2°以内,验证了所提方法在平面分割过程中有较高的精度。

表 4 平面的偏转角

Table 4 Deflection angle of planes

Object	Ceiling	Floor	Desktop	Front wall	Back wall	Left wall	Right wall
Deflection angle/(°)	0.077	0.056	0.147	0.028	0.170	0.135	0.103

为了进一步检验所提方法的效率,将所提方法与 MLESAC 方法^[11]和改进的 3D-HT 方法^[22]进行比较,三种方法分割 data 1、data 2 和 data 3 点云平面所需的时间(均不包括优化时间)如表 5 所示。根据已经求得的结果推算 data 1、data 2 和 data 3 点云平面分割过程中目标平面的内点比例,取置信概

率 $\alpha=0.95$,由(5)式计算得到采用 MLESAC 方法处理三组数据每次迭代所需次数的平均值分别为 723 次、435 次和 1015 次。在对比实验中,设置 MLESAC 方法的迭代次数为 500 次,改进的 3D-HT 方法的水平角和竖直角步长均为 2°。

表 5 平面点云的分割耗时

Table 5 Segmentation time-consuming of plane point clouds

Data	Number of points	Proposed method / s	MLESAC method/s	Improved 3D-HT method / s
1	114582	4.760	15.687	10.291
2	409286	16.724	60.385	31.516
3	1672434	67.997	208.213	140.930

从表 5 可以看到,所提方法的耗时均是最短的,且远小于另外两种方法;MLE SAC 方法由于在单次分割的过程中内点比例较小,需要进行较多次的迭代计算,为此相对耗时;改进的 3D-HT 方法不仅需要计算法向量,而且在点云坐标转换到霍夫空间的过程中需要大量的计算和内存,耗时也是大于所提方法的;所提方法虽然在点云的法向量计算过程中消耗较多的时间,但是经过分层和法向量约束后,所要提取的目标平面点云的内点比例高于 90%,大大减少平面提取的迭代次数,因此在总体时间的消耗上明显少于另外两种方法。

4 结 论

提出一种室内场景点云平面分割的新方法,通过基于投影长度的点云分层和基于均值漂移的法向量约束,该方法能够快速得到单个平面的点云,由此实现平面的快速拟合和分割,然后经过模型优化得到最终的结果。实验结果证明,所提方法可以有效分割室内场景点云中的平面结构,且模型优化后可以避免过分割的现象并去除无关点。同时,实验证明了所提方法的分割结果有较高的精度,满足后期建模的要求。此外,相较于其他两种改进的经典点云分割方法,所提方法在时间效率上有很大提升,适用于大数目点云的分割处理。

同时应该看到所提方法还存在一定不足,所提方法目前仅适用于分割点云平面,分割的模型类型有待进一步丰富拓展,应用场景也有待由室内延伸至室外。

参 考 文 献

- [1] Zhao M N, Hua X H, Feng S Q, et al. Information extraction of buildings, doors, and windows based on point cloud slices [J]. Chinese Journal of Lasers, 2020, 47(6): 0604002.
赵梦娜, 花向红, 冯绍权, 等. 基于点云切片的建筑物门窗信息提取 [J]. 中国激光, 2020, 47(6): 0604002.
- [2] Lu W X, Wan Y C, He P P, et al. Extracting and plane segmenting buildings from large scene point cloud [J]. Chinese Journal of Lasers, 2015, 42(9): 0914004.
卢维欣, 万幼川, 何培培, 等. 大场景内建筑物点云提取及平面分割算法 [J]. 中国激光, 2015, 42(9): 0914004.
- [3] Wei S F, Liu M L, Zhao J H, et al. A survey of methods for detecting indoor navigation elements from point clouds [J]. Geomatics and Information Science of Wuhan University, 2018, 43(12): 2003-2011.
危双丰, 刘明蕾, 赵江洪, 等. 利用点云检测室内导航元素的方法综述 [J]. 武汉大学学报·信息科学版, 2018, 43(12): 2003-2011.
- [4] Zhao B F, Hua X H, Xuan W, et al. A new algorithm of feature plane deformation in point cloud based on threshold discrimination and normal distribution model [J]. Journal of Geomatics, 2018, 43(6): 102-105.
赵不钊, 花向红, 宣伟, 等. 基于阈值判别和正态分布模型结合的点云特征平面变形新算法 [J]. 测绘地理信息, 2018, 43(6): 102-105.
- [5] Zhao X, Zhou K Q, Yan L, et al. 3D reconstruction method for large scale relic landscape from laser point cloud [J]. Geomatics and Information Science of Wuhan University, 2008, 33(7): 684-687.
赵煦, 周克勤, 闫利, 等. 基于激光点云的大型文物景观三维重建方法 [J]. 武汉大学学报·信息科学版, 2008, 33(7): 684-687.
- [6] Li Y Y, Wu X K, Chrysathou Y, et al. GlobFit: consistently fitting primitives by discovering global relations [C] // ACM SIGGRAPH 2011 papers on SIGGRAPH' 11, August 7-11, 2011, Vancouver, British Columbia, Canada. New York: ACM Press, 2011: 52.
- [7] Rottensteiner F. Automatic generation of high-quality building models from lidar data [J]. IEEE Computer Graphics and Applications, 2003, 23(6): 42-50.
- [8] Papon J, Abramov A, Schoeler M, et al. Voxel cloud connectivity segmentation-supervoxels for point clouds [C] // 2013 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2013, Portland, OR, USA. New York: IEEE Press, 2013: 2027-2034.
- [9] Qi C R, Yi L, Su H, et al. Pointnet ++: deep hierarchical feature learning on point sets in a metric space [C] // Advances in Neural Information Processing Systems, December 4-9, 2017, Long Beach, CA, USA. New York: Curran Associates, 2017: 5099-5108.
- [10] Fischler M A, Bolles R C. Random sample consensus [J]. Communications of the ACM, 1981, 24(6): 381-395.
- [11] Torr P H S, Zisserman A. MLESAC: a new robust estimator with application to estimating image geometry [J]. Computer Vision and Image Understanding, 2000, 78(1): 138-156.
- [12] Zuliani M, Kenney C S, Manjunath B S. The multiRANSAC algorithm and its application to detect

- planar homographies[C]//IEEE International Conference on Image Processing 2005, September 14-14, 2005, Genova, Italy. New York: IEEE Press, 2005: III-153.
- [13] Schnabel R, Wahl R, Klein R. Efficient RANSAC for point-cloud shape detection[J]. Computer Graphics Forum, 2007, 26(2): 214-226.
- [14] Zhao B F, Hua X H, Yu K G, et al. Indoor point cloud segmentation using iterative Gaussian mapping and improved model fitting [J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(11): 7890-7907.
- [15] Zhang L P, Zhang Y, Chen Z Z, et al. Splitting and merging based multi-model fitting for point cloud segmentation[J]. Acta Geodaetica et Cartographica Sinica, 2018, 47(6): 833-843.
张良培, 张云, 陈震中, 等. 基于分裂合并的多模型拟合方法在点云分割中的应用[J]. 测绘学报, 2018, 47(6): 833-843.
- [16] Duda R O, Hart P E. Use of the Hough transformation to detect lines and curves in pictures [J]. Cacm, 1972, 15(1): 11-15.
- [17] Kiryati N, Eldar Y, Bruckstein A M. A probabilistic Hough transform[J]. Pattern Recognition, 1991, 24(4): 303-316.
- [18] Xu L, Oja E, Kultanen P. A new curve detection method: randomized Hough transform (RHT) [J]. Pattern Recognition Letters, 1990, 11(5): 331-338.
- [19] Borrmann D, Elseberg J, Lingemann K, et al. The 3D Hough Transform for plane detection in point clouds: a review and a new accumulator design[J]. 3D Research, 2011, 2(2): 3.
- [20] Coggrave C R. Automated detection of planes in 3-D point clouds using fast Hough transforms[J]. Optical Engineering, 2011, 50(5): 053609.
- [21] Yla-Jaaski A, Kiryati N. Adaptive termination of voting in the probabilistic circular Hough transform [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1994, 16(9): 911-915.
- [22] Li M L, Li G Y, Wang L, et al. Automatic feature detecting from point clouds using 3D Hough Transform[J]. Bulletin of Surveying and Mapping, 2015(2): 29-33.
李明磊, 李广云, 王力, 等. 3D Hough Transform 在激光点云特征提取中的应用[J]. 测绘通报, 2015(2): 29-33.
- [23] Fukunaga K, Hostetler L. The estimation of the gradient of a density function, with applications in pattern recognition [J]. IEEE Transactions on Information Theory, 1975, 21(1): 32-40.
- [24] Hoppe H, DeRose T, Duchamp T, et al. Surface reconstruction from unorganized points [J]. ACM SIGGRAPH Computer Graphics, 1992, 26(2): 71-78.
- [25] Xuan W, Hua X H, Zou J G, et al. A new method of normal estimation for point cloud based on adaptive optimal neighborhoods[J]. Science of Surveying and Mapping, 2019, 44(10): 101-108, 116.
宣伟, 花向红, 邹进贵, 等. 自适应最优邻域尺寸选择的点云法向量估计方法[J]. 测绘科学, 2019, 44(10): 101-108, 116.

New Method for Plane Segmentation of Indoor Scene Point Cloud

Li Qiqi^{1,2}, Hua Xianghong^{1,2*}, Zhao Bufan^{1,2,3}, Tao Wuyong^{1,2}, Li Cheng^{1,2}

¹School of Surveying and Mapping, Wuhan University, Wuhan, Hubei 430079, China;

²Disaster Monitoring and Prevention Research Center of Wuhan University, Wuhan, Hubei 430079, China;

³Key Laboratory for Digital Land and Resources of Jiangxi Province, East China University of Technology, Nanchang, Jiangxi 330013, China

Abstract

Objective With the rapid development of virtual reality technology, indoor navigation technology, and indoor positioning technology, the extraction and modeling of indoor 3D point cloud objects have become a research hotspot. Under normal circumstances, an indoor scene is quite complex, and the point cloud data obtained by scanning is usually cluttered. There are many objects and occlusions, and automatic modeling cannot be carried out. It is necessary to segment a complex indoor point cloud into simple geometric primitives to perform modeling. Because there are several plane structures in indoor scenes, such as walls and ground, plane segmentation for indoor scene point cloud is a crucial part of segmentation for indoor scene point clouds. Owing to the complexity and bulkiness of indoor scene point clouds, traditional random sample consensus (RANSAC) and 3D Hough transform methods are

complex and inefficient in the process of plane segmentation for indoor scene point clouds. In this article, we propose a new method for plane segmentation of indoor scene point clouds. Compared with existing methods, this method has a great improvement in time efficiency and is more suitable for plane segmentation for indoor scene point clouds.

Methods In this article, a new plane segmentation method based on projection length point cloud layering and mean shift (MS) normal vector constraint is proposed. First, the method estimates the normal vector of the point cloud by the principal component analysis method, combines the coordinates of the point cloud to obtain the projection length, and then layers the point cloud according to the projection length by a certain step. Afterward, it takes the current maximum stratified point cloud for normal vector constraint based on the MS method to get the point cloud with the most concentrated normal vector. Next, it uses the remaining points to perform RANSAC and least squares plane fitting to obtain the plane parameters and then removes the point cloud contained in the current plane model by a certain thickness threshold. The above steps are repeated to obtain the parameters of all planes until the number of plane points extracted is less than a certain value. Finally, the model point clouds are extracted from the original point cloud based on the obtained plane parameters, and after the model optimization that includes planes merging, error point reclassification, and irrelevant point elimination, the final plane segmentation result is obtained.

Results and Discussions In this article, a new concept of projection length of point cloud is proposed that is used to segment the plane of point cloud in an indoor scene (Fig. 2). The indoor point cloud is layered on the basis of the projection length, and the resultant point cloud number histogram can initially reflect the number of planes and distance distribution in the scene (Fig. 4). The projection lengths of the planes calculated from the resulting plane parameter fall in the peak or adjacent interval in the resultant point cloud number histogram (Table 2). After the point cloud layering based on the projection length, most points in the maximum layer come from the same target plane, and there are only a small number of irrelevant points. After MS clustering, the remaining points are all from the target plane, which is convenient for plane fitting (Fig. 5). The proposed method can completely segment the plane structure of indoor scenes, including walls, ceiling, floor, and desktop. Meanwhile, other irrelevant structures, such as potted plants, chairs, and door frames, are removed in the segmentation process (Figs. 7 and 8). The distances between the obtained plane models are very close to the actual measured distances; the difference is in the millimeter level (Table 3). The deflection angles between the planes obtained in this study, and the planes obtained by single-point measurement are all within 0.2° (Table 4). Compared with the maximum likelihood sample consensus method and improved 3D Hough transform method, the proposed method is obviously better in terms of total time consumption (Table 5).

Conclusions In this article, we propose a new method of plane segmentation for indoor scene point cloud. Through the point cloud layering based on projection length and normal vector constraint based on MS, the proposed method can quickly obtain points from a single plane, thereby achieving plane fitting and segmentation rapidly and then gets the final result after model optimization. Experiments show that the proposed method can effectively segment the plane structure in the indoor scene point cloud, and the model optimization can avoid over-segmentation and remove irrelevant points. Simultaneously, the experiment proves that the segmentation result of the proposed method has higher accuracy and meets the requirements of later modeling. In addition, compared with two improved classical methods for point cloud segmentation, the proposed method is time efficient and is suitable for segmentation for a large number of point clouds.

Key words measurement; lidar point cloud; indoor scene; plane segmentation; projection length; point cloud layering; mean shift

OCIS codes 120.6650; 280.3640; 140.3430; 330.6110