

# 基于图优化的激光 SLAM 点云整体配准方法

唐浩<sup>1,2</sup>, 黎东<sup>1,2\*</sup>, 王成<sup>2</sup>, 聂胜<sup>2</sup>, 刘佳音<sup>1</sup>, 段焯<sup>1</sup>

<sup>1</sup>昆明理工大学国土资源工程学院, 云南 昆明 650093;

<sup>2</sup>中国科学院空天信息创新研究院数字地球重点实验室, 北京 100094

**摘要** 针对激光同步定位与制图(SLAM)算法在扫描轨迹过长时,获得的点云容易出现漂移误差且精度变差的问题,提出一种基于图优化的激光 SLAM 点云整体配准方法。对于有一定漂移误差的激光 SLAM 点云,先后构建初始位姿图和迭代位姿图进行级联优化。首先基于分段点云相似性和形心距离,构建初始位姿图进行优化,以减小轨迹漂移误差,获得漂移误差较小的 SLAM 点云。然后基于分段点云重叠度构建迭代位姿图,依次进行点云迭代粗优化和精优化,获得更高精度的 SLAM 点云。使用一组手持和三组车载激光 SLAM 数据进行实验。优化后,4 组实验数据的各自重复扫描点云很好地重叠在一起,匹配关键点之间的距离的均方根误差(RMSE)分别由优化前的 2.667 m、10.348 m、19.018 m 和 3.412 m 降为 0.158 m、0.211 m、0.218 m 和 0.157 m。实验结果表明,所提算法可以有效解决激光 SLAM 点云长轨迹扫描的漂移误差问题,提升点云数据精度。

**关键词** 点云整体配准; 同步定位与制图; 图优化; K-means 算法

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP232000

## Global Registration Method for Laser SLAM Point Clouds Based on Graph Optimization

Tang Hao<sup>1,2</sup>, Li Dong<sup>1,2\*</sup>, Wang Cheng<sup>2</sup>, Nie Sheng<sup>2</sup>, Liu Jiayin<sup>1</sup>, Duan Ye<sup>1</sup>

<sup>1</sup>Faculty of Land Resources Engineering, Kunming University of Science and Technology,

Kunming 650093, Yunnan, China;

<sup>2</sup>Key Lab of Digital Earth Science, Aerospace Information Research Institute,

Chinese Academy of Sciences, Beijing 100094, China

**Abstract** To address the issue of drift errors and inadequate precision in point clouds produced by laser-based simultaneous localization and mapping (SLAM) algorithms during lengthy scanning trajectories, this study presents a global point cloud registration approach for laser SLAM that relies on graph optimization. We constructed initial and iterative pose graphs for cascaded optimization in succession for laser SLAM point clouds with specific drift errors. The pose graph is initially created using point cloud similarity and centroid distance of segments to reduce trajectory drift error, resulting in SLAM point clouds with smaller drift errors. From this, iterative pose graphs are formed based on the overlap of point clouds between segments. Subsequently, the point clouds are coarsely and finely adjusted in an iterative manner to produce higher precision SLAM point clouds. Experiments were performed in this paper using one set of handheld and three sets of vehicle-mounted laser SLAM data. After optimization, the point clouds of the four experimental data sets were well overlapped by their respective repeated scans. The distance root mean square error (RMSE) between the matched keypoints is reduced to 0.158, 0.211, 0.218, and 0.157 m from 2.667, 10.348, 19.018, and 3.412 m, respectively, before the optimization. Experimental results indicate that the proposed algorithm can resolve the issue of drift error during laser SLAM point cloud long trajectory scanning, ultimately improving the accuracy of the point cloud data.

**Key words** point cloud global registration; simultaneous localization and mapping; graph optimization; K-means algorithm

收稿日期: 2023-08-28; 修回日期: 2023-10-07; 录用日期: 2023-10-20; 网络首发日期: 2023-11-07

基金项目: 国家重点研发计划(2021YFF0704600)、浙江省尖兵领雁研发攻关计划(2023C03190)

通信作者: \*lidong@aircas.ac.cn

# 1 引言

激光雷达(LiDAR)能够快速、准确地获取物体表面的三维点云数据<sup>[1]</sup>。该技术在无人驾驶、形变监测和测绘<sup>[2]</sup>等领域有广泛应用。同步定位与制图(SLAM)技术源于机器人领域,主要用于在动态且全球定位系统(GPS)失效的环境中进行自主探索的机器人<sup>[3]</sup>。激光 SLAM 技术结合了 LiDAR 技术和 SLAM 技术,使用激光雷达传感器观察环境特征来定位自身,并逐步构建周围环境的地图<sup>[4]</sup>。激光 SLAM 技术生成的点云地图在扫描轨迹较短时具有较高的精度,但是随着扫描轨迹的延长,常常会出现漂移误差。这是由于激光 SLAM 后端图优化算法要求实时性,无法利用点云的所有信息对地图进行优化。在测绘领域中,对点云地图的实时性要求低,而对几何精度要求高,因此可以利用获取的全部 SLAM 点云进行离线整体配准,得到具有高精度的点云地图。

目前,已有一些点云整体配准方法,这些方法主要适用于地面及机载激光扫描点云,对移动激光扫描点云的研究较少。文献[5]提出了一种新的点云整体配准方法,该方法利用傅里叶变换将点云从空间领域转换到频率领域,然后借助鲁棒相位相关技术将旋转、缩放和平移的复杂估计问题简化为一个仅涉及平移的简单问题。该方法避免了局部特征的提取和对应关系的建立,配准的精度不依赖中间步骤,所以在处理高频噪声和低重叠度等问题方面具有很高的鲁棒性和适用性。文献[6]提出了一种针对地铁隧道点云的整体配准方法。该方法利用地铁隧道的自闭合性,消除分段点云中的累计误差,并实现最佳整体配准。文献[7-8]提出了一种基于图论框架的盲配准方法,无需标记即可实现多个森林点云数据集的整体配准。文献[9]提出了一种针对机载点云的全自动条带调整方法,该方法基于迭代最近点算法对每个条带的轨迹误差进行单独校正,达到整体配准的目的。文献[10]提出了一种考虑地形特征的数字高程模型-迭代最近点配准方法,该方法使用图优化对无人机点云数据的所有点云条带进行整体配准。针对激光 SLAM 点云,文献[11]对 SLAM 重叠点云进行配准,形成轨迹约束,然后用位姿图对轨迹进行优化,实现点云整体配准,但是该方法处理耗时较长。文献[12]提出了一种在位姿图中加入卫星定位节点的激光 SLAM 位姿优化算法,该算法在无回环和有回环的情况下都能提高激光雷达位姿的全局一致性。

本文提出了一种基于图优化的激光 SLAM 点云整体配准方法,旨在解决长时间扫描轨迹下点云地图漂移误差的问题。该方法首先对存在轨迹漂移误差的 SLAM 点云进行降采样和分段等预处理,然后基于分段点云相似性和形心距离构建初始位姿图,进行位姿图优化,减小轨迹漂移误差。接着,基于点云重叠度构

建迭代位姿图,依次进行点云迭代粗优化和精优化,最终得到优化后的点云地图。

## 2 基于图优化的点云整体配准方法

### 2.1 图优化

基于图优化的 SLAM 的研究基础是图论,其中常用  $G = \{V, E\}$  表示图结构,  $V$  表示图的顶点,  $E$  表示边<sup>[13]</sup>。在位姿图中常用  $v_i$  表示一个顶点,  $e_{i,j}$  表示一条边。其中:顶点表示分段点云的位姿;边表示位姿之间的约束条件,在本文中即两个点云之间配准的匹配点对。

图优化是对 SLAM 前端构建的位姿图进行非线性优化的方法,计算得到满足约束条件的最优解,输出优化后的位姿和全局点云地图<sup>[14]</sup>。在图优化过程中,位姿中的旋转分量的估计在欧氏空间中可能会出现奇异,通常采用四元数或流形空间来解决这个问题<sup>[15]</sup>。然而,四元数会引入额外的自由度,从而降低计算效率。为此,Grisetti 等<sup>[16]</sup>采用在流形空间中进行位姿图优化的思想,提出了一种分层优化的图优化技术(HOG-MAN 方法),该方法在线建图过程中只对场景的粗略结构进行校正,而不对整个地图进行校正,从而提高了效率。Kümmerle 等<sup>[13]</sup>进一步将 HOG-MAN 方法和 sparse pose adjustment(SPA)<sup>[17]</sup>思想结合起来,提出了基于流形空间的通用图优化框架,即 g2o(a general framework for graph optimization)框架。g2o 是一个通用的非线性最小二乘优化框架,可以处理各种类型的图结构和状态空间参数。

### 2.2 预处理

SLAM 算法通常产生一个点云地图,该地图由多个关键帧点云构成。为提高整体流程的效率和精度,需要对 SLAM 点云进行预处理。首先采用距离滤波对每一帧点云进行处理,去除距离过远和过近的点;然后根据点云数据的总帧数确定每个分段点云中合并的点云帧数,以获得合并后的分段点云;接着使用统计滤波对点云进行去噪,去除孤立点;最后,使用体素栅格滤波进行下采样,以减少点的个数,同时保留点云的几何特征。

### 2.3 位姿图构建

位姿图构建包含连接边构建策略与约束条件两部分,第一部分是通过计算点云的形心距离、相似性和重叠度来确定位姿图中顶点之间的连接边,第二部分是

#### 2.3.1 连接边构建策略

通过计算点云之间的匹配点对构建连接边对应的约束条件。连接边构建策略是判断位姿图中一个顶点是否与其他顶点存在连接边的关键步骤。通过计算点云之间的相似性和重叠度来判断位姿图中顶点与顶点之间的连接边。位姿图中的连接边分为两种类型:一种是点云距离较远,只能依赖点云形心距离和相似性构建的回环边;另一种是点云距离较近,可以根据点云重叠度

构建的相邻边。

对于点云之间相似性的计算,先对每个分段点云计算 ensemble of shape functions(ESF)特征向量<sup>[18]</sup>,将其作为全局描述子,然后对不同的 ESF 特征向量之间的相似性进行度量。采用 Dong 等<sup>[19]</sup>提出的比较两个特征向量相似性的方法计算两个分段点云之间的相似性,计算公式为

$$\text{sim}(\mathbf{V}_i, \mathbf{V}_j) = \frac{1}{K} \sum_k \omega_k \frac{1}{\|\mathbf{V}_i(k) - \mathbf{V}_j(k)\|}, \quad (1)$$

式中: $K$ 是特征向量的维数, $K=640$ ; $\omega_k=1-k/K$ ,是特征向量中每一维分量的权重; $\mathbf{V}_i$ 和 $\mathbf{V}_j$ 是两个分段点云的 ESF 特征向量; $\|\cdot\|$ 为二范数符号。

对于点云之间重叠度的计算,将两个点云放进两个八叉树中,对于每个八叉树将其划分为多个体素,如果一个点所在体素内有另一个点云的点,则说明该体素内部存在重叠区域,计算所有存在重叠区域的体素的里点的数量并除以两个点云中点的总数,则可得两个点云的重叠度。

寻找位姿图中的回环边。首先选取时间顺序上的第一个分段点云 $c_1$ 。假设点云 $c_n$ 与点云 $c_1$ 之间存在一条回环边。尽管存在漂移误差,点云 $c_n$ 与点云 $c_1$ 的形心距离很远,但从全局来看,点云 $c_n$ 仍然是形心距离点云 $c_1$ 最近的几个点云之一。计算所有分段点云与点云 $c_1$ 之间的形心距离,然后提取形心距离最近、但分段点云索引不相邻的3个分段点云。根据前面介绍的方法计算目标点云与提取的三个点云之间的相似性,若相似性最大的点云与点云 $c_1$ 之间的全局相对距离较近,则该点云为点云 $c_n$ ,并将相似性记为 $s_{1,n}$ 。通过上述步骤计算所有分段点云的回环边及对应的相似性,选取具有最大相似性 $s_{\max}$ 的分段点云 $c_i$ 和 $c_j$ ( $i < j$ )。点云 $c_i$ 和 $c_j$ 之间形成第一条回环边,然后以点云 $c_i$ 为起点,按照图1向两侧寻找回环边,其中 $N$ 为分段点云的总数。若点云 $c_{i-2}$ 和 $c_{j-2}$ 之间的相似性 $s_{i-2,j-2}$ 低于阈值,则停止寻找回环边。




图1 位姿图中的回环边

Fig. 1 Loop closure edges in the pose graph

寻找位姿图中的相邻边。因为时间顺序上相邻的分段点云之间必定存在边的关系,所以只需要对不相邻的分段点云之间是否存在边进行判断,需要通过重叠度进行判断。首先计算所有相邻分段点云之间的重

叠度,并对其进行排序;然后设定重叠度阈值 $N_0$ ,该阈值 $N_0$ 必须小于最小的重叠度,才能保证位姿图闭环;接着计算所有不相邻分段点云之间的重叠度,若大于阈值 $N_0$ ,则说明这两个分段点云之间存在相邻边的关系。

### 2.3.2 约束条件

在位姿图中,每个顶点对应点云的位姿,而边则表示位姿之间的约束条件,即两个点云之间的配准匹配点对。因此需要计算匹配点对来生成位姿约束。计算匹配点对的过程分为两步:第一步是寻找匹配点对,第二步是筛选匹配点对。

采用两种方法寻找匹配点对,一种是根据 fast point feature histograms(FPFH)描述子<sup>[20]</sup>寻找,另一种是用最近邻搜索寻找。根据 FPFH 描述子寻找匹配点对,先根据点云 $c_1$ 和 $c_2$ 之间的最小 FPFH 特征向量的欧氏距离初步寻找匹配点对 $(p_i, p_j)$ 。FPFH 特征向量的欧氏距离计算公式为

$$d = \sqrt{\sum_{k=1}^K [\mathbf{F}_i(k) - \mathbf{F}_j(k)]^2}, \quad (2)$$

式中: $K$ 是 FPFH 特征向量的维数; $\mathbf{F}_i$ 和 $\mathbf{F}_j$ 是点 $p_i$ 与点 $p_j$ 对应的 FPFH 特征向量。

然后以匹配点对 $(p_i, p_j)$ 中的点 $p_j$ 为搜索点,在点云 $c_1$ 中搜索与 FPFH 特征向量的欧氏距离最近的点 $p_k$ ,并判断点 $p_k$ 是否与 $p_i$ 为同一个点,同时点 $p_k$ 与点 $p_j$ 的距离是否小于距离阈值。如果两个条件都满足,则保留匹配点对 $(p_i, p_j)$ ;否则剔除。对点云 $c_1$ 和点云 $c_2$ 中所有的点都执行以上操作,即可获取两个点云之间的匹配点对。

再用最近邻搜索寻找匹配点对。首先以点云 $c_1$ 为目标点云,取点云 $c_1$ 中的任意一点 $p_i$ ,计算该点与点云 $c_2$ 中所有点的欧氏距离 $d_{\text{xyz}}$ 。如果点云 $c_2$ 中某个点 $p_j$ 与点 $p_i$ 的距离值最小且小于设定的距离阈值,则这两个点构成匹配点对 $(p_i, p_j)$ 。这里只对点云 $c_1$ 中所有点进行操作,不以点云 $c_2$ 中的点为搜索点获取匹配点对。对点云 $c_1$ 中所有点重复以上操作,即可获取两个点云之间的匹配点对。

接着采用熊风光等<sup>[21]</sup>提出的剔除误匹配点对方法对匹配点对进行筛选,相比常用的 random sample consensus(RANSAC)算法,该方法有更高的准确率。剔除误匹配点对方法分为边缘点点对剔除方法和 K-means 剔除误匹配点对方法。边缘点点对方法剔除了距离点云边缘点过近的匹配点对。K-means 剔除误匹配点对方法先对每个匹配点对计算出一个表示变换关系的向量,然后对向量进行 K-means 聚类,只保留最大的簇对应的匹配点对。对匹配点对进行筛选后,剔除了大量的误匹配点对,保留了正确的匹配点对。

### 2.4 整体配准

整体配准的流程如图2所示。整体配准分为两个

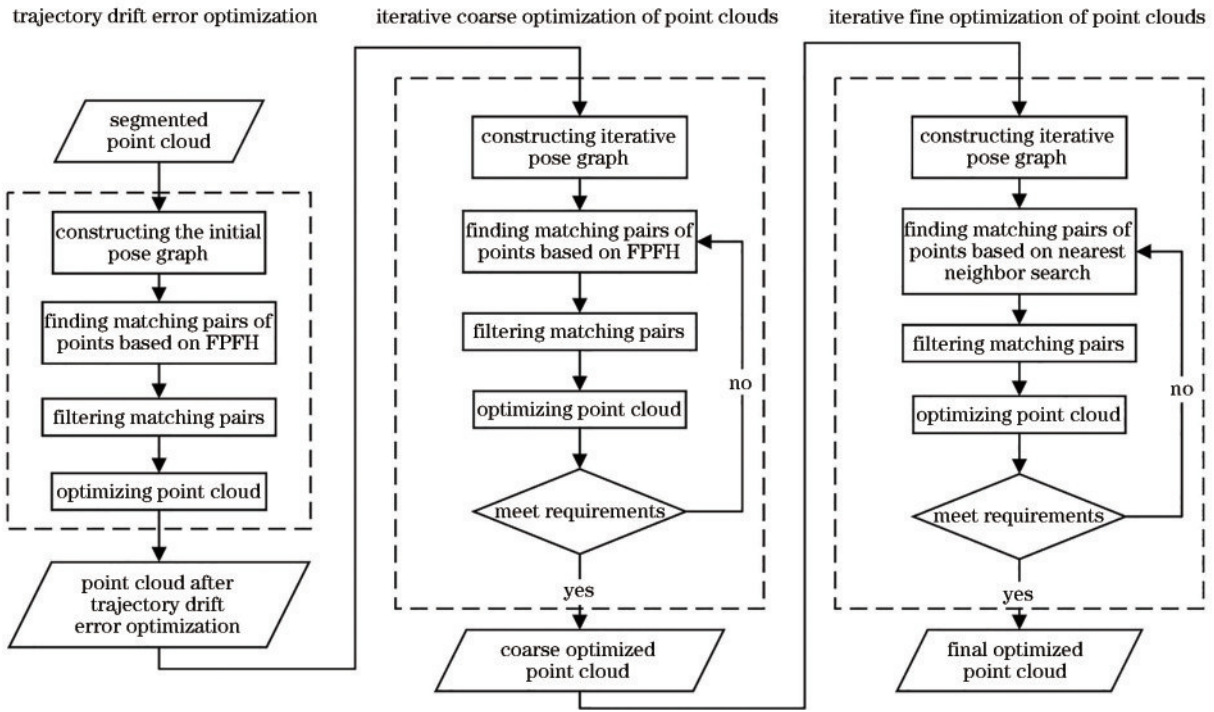


图 2 整体配准流程

Fig. 2 Global registration flow chart

部分:轨迹漂移误差优化和点云迭代优化。其中,点云迭代优化又分为粗优化和精优化。第一部分中,构建初始位姿图,旨在减小分段点云较大的轨迹漂移误差。第二部分中,通过构建迭代位姿图对优化后的点云再次进行优化,进一步提高点云整体精度。

#### 2.4.1 轨迹漂移误差优化

首先,通过计算点云相似性和形心距离寻找回环边,同时计算点云重叠度来寻找相邻边。然后,利用回环边和相邻边构建初始位姿图,针对具有连接边关系的节点,使用配准匹配点对建立约束条件。为确保匹配点对的准确性,使用 FPFH 描述子寻找匹配点对,并根据前述方法剔除误匹配点对,保留正确的匹配点对。需要注意的是,在寻找匹配点对时,针对相邻边和回环边,分别设定了固定值和基于点云形心之间距离的不同距离阈值。最后,在已知初始位姿图和节点之间约束条件的情况下,使用 g2o 框架<sup>[13]</sup>进行位姿图优化,同时引入 Huber 核函数以提高对误匹配点对的鲁棒性。通过这一优化过程,获得每个分段点云优化后的相对位姿。用相对位姿对每个点云进行坐标变换,获得优化后的点云,从而优化了轨迹漂移误差。

#### 2.4.2 点云迭代优化

首先,基于分段点云的重叠度寻找相邻边来构建迭代位姿图。值得注意的是,位姿图的连接边在整个点云迭代过程中保持不变,但约束条件需要在每一次迭代优化后重新计算。随后,利用迭代位姿图和约束条件,依次进行粗优化和精优化。

在粗优化阶段,首先计算节点对应点云之间的配

准匹配点对,作为节点之间约束条件,通过 FPFH 描述子来寻找匹配点对,并使用误匹配点对剔除方法来筛选这些点对。在寻找匹配点对时,对每条边都采用相同的距离阈值。在已知迭代位姿图和节点之间约束条件的情况下,使用 g2o 框架进行位姿图优化,以获取每个分段点云在优化后的相对位姿。接着,使用这些相对位姿对每个点云进行坐标变换,即可得到粗优化后的点云。然后,重新计算约束条件,并再次进行位姿图优化。其中关键的一步是,需要使用比上一次粗优化阶段更小的距离阈值来寻找匹配点对,以获取新的、更准确的约束条件。如此重复,直到各分段点云之间没有明显的偏差。

在精优化阶段,采用最近邻搜索方法来寻找匹配点对。在这一阶段,使用固定的距离阈值同样可以获得新的、更准确的约束条件。这一阶段类似于迭代最近邻(ICP)算法<sup>[22]</sup>,其中距离阈值保持固定,但残差会随迭代而变小。其余步骤与点云迭代粗优化过程相似。完成点云迭代精优化后,即可获得最终优化后的点云。

## 3 实验结果与定量分析

### 3.1 数据集

为了验证所提算法的有效性,分别采用手持和车载激光扫描数据作为 FAST-LIO 2 算法<sup>[23]</sup>的输入数据,然后以 FAST-LIO 2 算法的结果作为本文的试验数据。数据 1 由集成了 Livox Avia 激光探测测距仪的手持式 SLAM 扫描仪获取,图 3 为 FAST-LIO 2 算法

结果的俯视图,即数据1。数据2、数据3和数据4分别为公开数据集 Mulran Dataset KAIST 03(网址为 <https://sites.google.com/view/mulran-pr/dataset>)、DDC 02 和 Riverside 02,由搭载了 Ouster OS1-64 3D 激光雷达的汽车获取,图 4~6 为数据 2、数据 3 和数据 4 FAST-LIO 2 算法结果的俯视图。数据具体参数如表 1 所示。实验的计算机环境为 Intel(R) Core(TM) i9-10885H CPU @ 2.40 GHz, 64.0 GB 内存。在预处理阶段,根据激光探测测距仪的性能,对于户外场景数据,距离滤波的最大距离阈值  $D_{max}$  设为 300 m,最小距离阈值  $D_{min}$  设为 0.5 m,去除超出距离阈值的点。60 帧点云合并为一段点云。




图 3 数据 1 FAST-LIO 2 算法结果  
Fig. 3 FAST-LIO 2 algorithm result of Data 1




图 4 数据 2 FAST-LIO 2 算法结果  
Fig. 4 FAST-LIO 2 algorithm result of Data 2



图 5 数据 3 FAST-LIO 2 算法结果  
Fig. 5 FAST-LIO 2 algorithm result of Data 3



图 6 数据 4 FAST-LIO 2 算法结果  
Fig. 6 FAST-LIO 2 algorithm result of Data 4

表 1 输入数据说明  
Table 1 Description of input data

Data name	Trajectory length /m	Point cloud frame rate	Scanning time /s
Data 1	410	2018	797
Data 2	2930	2700	265
Data 3	3580	3420	344
Data 4	2010	3180	322

### 3.2 实验结果

表 2 为所提算法对数据 1、数据 2、数据 3 和数据 4 的处理时间、粗优化和精优化迭代次数,可以看出,所提算法有较快的处理速度。图 7 为数据 1 和数据 2 轨迹漂移误差优化前后的点云对比。从图 7(a)可知,优化前建筑物外墙和右边花坛里的树有明显的重影,优化后建筑物外墙重影减少,且右侧花坛里的树变得清晰;从图 7(b)可知,优化前建筑物外墙和右下角的过河马路有明显的重影,优化后重影减少。图 8 为数据 3 和数据 4 轨迹漂移误差优化前后的点云对比。从图 8(a)可知,优化前建筑物外墙和马路上的行道树有明显的重影,优化后重影明显减少;从图 8(b)可知,优化前同一段马路有明显的漂移误差,优化后漂移误差大大减小。

图 9 为数据 1 优化前与优化后的场景对比。从图 9(a)可知,优化后建筑物柱子轮廓明显,没有重影,

表 2 实验结果说明

Table 2 Description of experimental results

Data name	Processing time /s	Number of coarse optimization iterations	Number of fine optimization iterations
Data 1	748	2	8
Data 2	1000	4	5
Data 3	1231	3	5
Data 4	1173	3	5

外墙轮廓清晰;从图 9(b)可知,优化后建筑物外墙轮廓重影消失;从图 9(c)可知,优化后树干部分重影消失,花坛部分点云变薄;从图 9(d)可知,优化后行道树由两排变成一排,重影消失。图 10 为数据 2 优化前与优化

后的场景对比。从图 10(a)可知,优化后过河马路边和树木的重影消失,道路清晰;从图 10(b)可知,优化后两棵树木的重影消失,道路清晰;从图 10(c)可知,优化后建筑物外墙由两个变成一个,重影消失;从图 10(d)可知,优化后建筑物外墙轮廓清晰,无明显漂移误差。图 11 为数据 3 优化前与优化后的场景对比。从图 11(a)可知,优化后建筑物外墙和道路旁的行道树重影明显减少;从图 11(b)可知,优化后马路及马路旁的行道树重影明显减少;从图 11(c)可知,优化后建筑物外墙重影消失;从图 11(d)可知,优化后道路和树木的重影明显减少。图 12 为数据 4 优化前与优化后的场景对比。从图 12 可知,优化前同一段马路明显相距很远,优化后两段马路很好地重叠在了一起,重影消失。

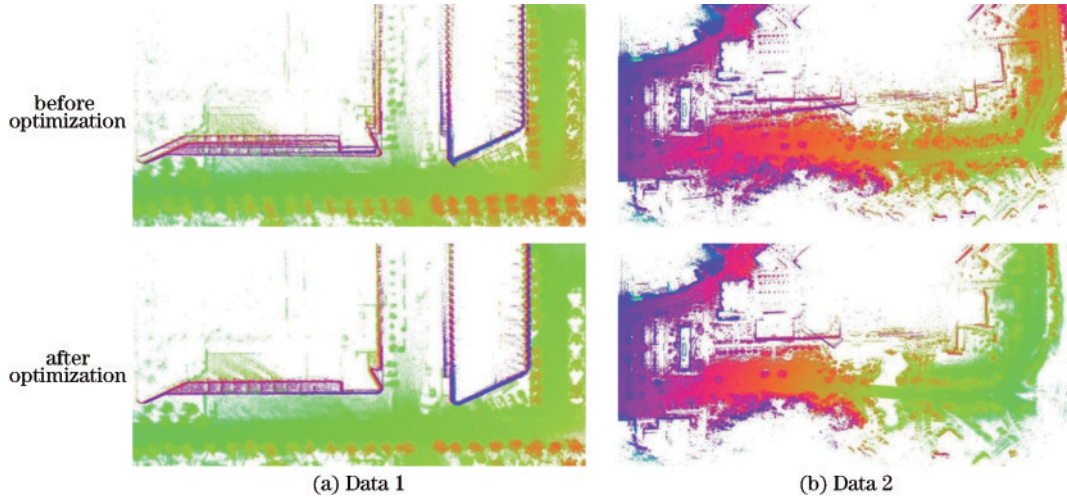


图 7 数据 1 和数据 2 轨迹漂移误差优化前后的点云对比

Fig. 7 Comparison of point clouds before and after trajectory drift error optimization for Data 1 and Data 2

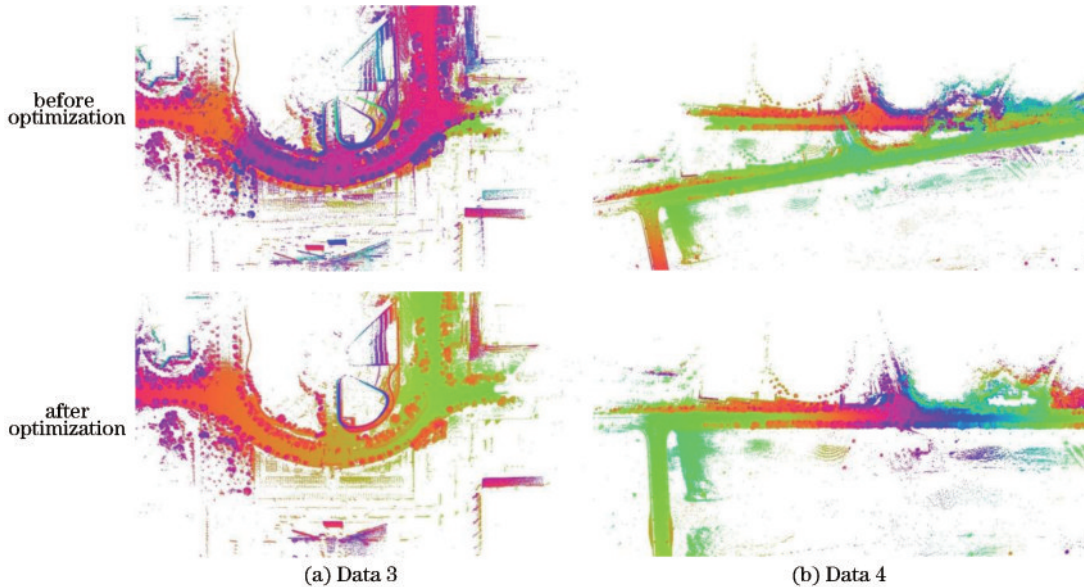


图 8 数据 3 和数据 4 轨迹漂移误差优化前后的点云对比

Fig. 8 Comparison of point clouds before and after trajectory drift error optimization for Data 3 and Data 4

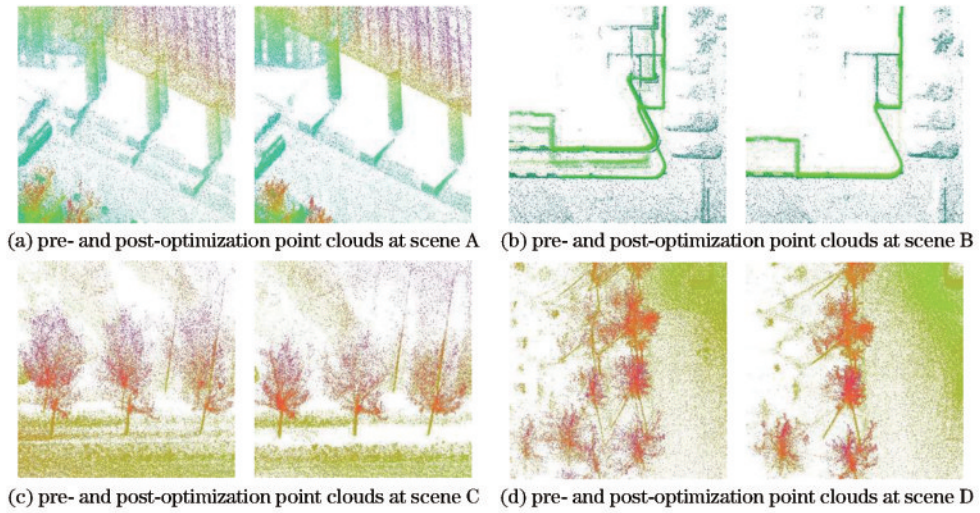


图 9 数据 1 优化前后的场景对比  
Fig. 9 Scene comparison of Data 1 before and after optimization

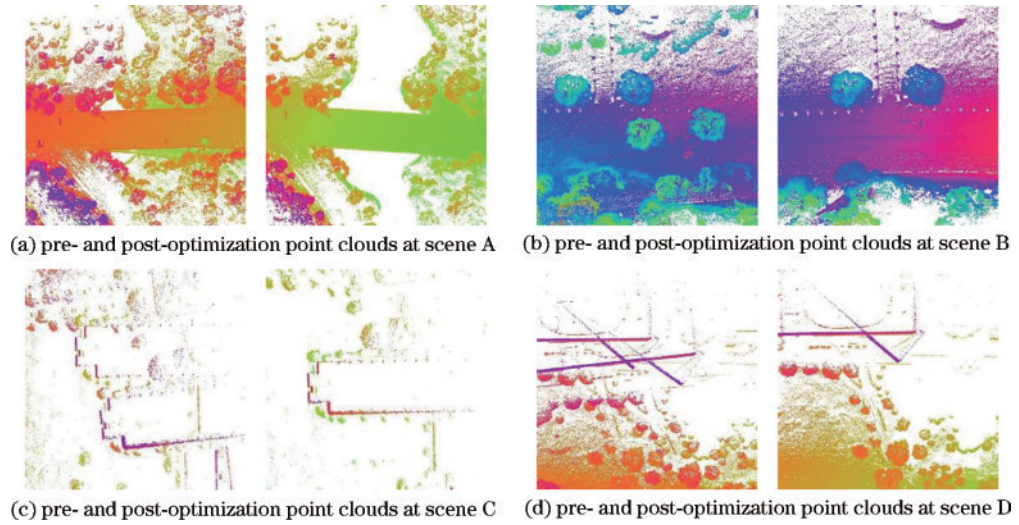


图 10 数据 2 优化前后的场景对比  
Fig. 10 Scene comparison of Data 2 before and after optimization

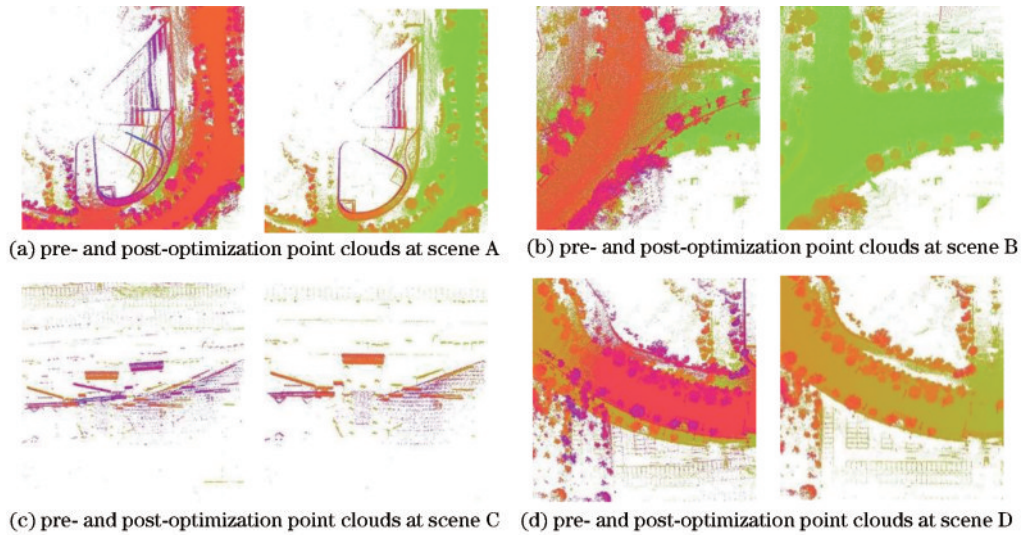


图 11 数据 3 优化前后的场景对比  
Fig. 11 Scene comparison of Data 3 before and after optimization

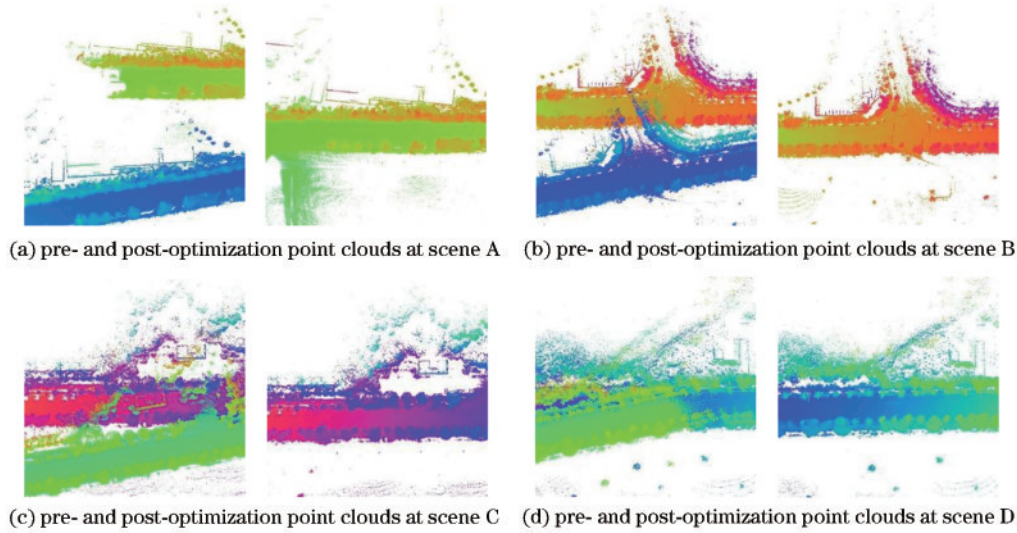


图 12 数据 4 优化前后的场景对比

Fig. 12 Scene comparison of Data 4 before and after optimization

### 3.3 定量分析

通过计算优化前点云和优化后点云的匹配关键点之间的距离 RMSE 来进行定量分析。用匹配点对的距离 RMSE 作为评价标准来定量地分析优化前后分段点云的相对精度变化。点云  $c_i$  与  $c_j$  之间匹配点对距离的 RMSE 计算公式为

$$\sigma_{i,j} = \sqrt{\frac{\sum_{n=1}^N \|d_n - g_n\|_2^2}{N}}, \quad (3)$$

式中:  $N$  是两个点云匹配点对的数量;  $d_n$  与  $g_n$  是点云  $c_i$  与  $c_j$  对应的匹配关键点;  $n$  为匹配关键点的编号。

对数据 1 与数据 2 构建的迭代位姿图中的每条边对应的两个点云之间用最近邻搜索寻找匹配点对, 然后计算匹配点对的距离 RMSE。将所有边对应的距离 RMSE 加起来除以边的个数获得距离 RMSE 的平均值。优化前后的点云匹配点对的距离 RMSE 平均值如表 3 所示。

表 3 匹配点对的距离 RMSE 平均值

Optimization state	Average value of the distance RMSE of the matching point pairs			
	Data 1	Data 2	Data 3	Data 4
Before optimization	2.667	10.348	19.018	3.412
Drift error optimization	0.231	0.329	0.398	0.223
After coarse optimization	0.171	0.284	0.342	0.193
After fine optimization	0.158	0.211	0.218	0.157

从表 3 可以看出, 在优化前, 匹配点对的距离 RMSE 平均值相对较高, 表明存在着显著的轨迹漂移误差。然而, 所提算法在处理这些数据时, 表现出了较好的效果。在数据 1 中, 经过漂移误差优化后, 匹配点对的距离 RMSE 平均值从 2.667 m 降至 0.231 m, 粗优化进一步将其降至 0.171 m, 最终, 精优化使其减少

到 0.158 m, 相对于优化前的情况, RMSE 平均值减小了 94.1%。对于数据 2, 漂移误差优化将距离 RMSE 平均值从 10.348 m 降至 0.329 m, 粗优化进一步将其降至 0.284 m, 而精优化使其减小到 0.211 m, 减小幅度达到了 97.9%。数据 3 和数据 4 的结果也呈现出相似的趋势, 在经过最后的精优化后, 距离 RMSE 平均值分别降低了 98.8% 和 95.3%。

实验结果表明, 所提算法对手持和车载激光 SLAM 点云数据进行整体匹配后, 轨迹漂移误差明显减小, 匹配点对的距离 RMSE 显著降低。实验验证了所提优化方法的有效性和可行性。

## 4 结 论

针对激光 SLAM 技术在构建点云地图时产生的漂移误差问题, 提出了一种基于图优化的点云整体配准方法, 包括点云预处理、轨迹漂移误差优化和点云迭代优化 3 个步骤。对 FAST-LIO 2 算法生成的四组激光 SLAM 数据进行实验, 结果表明所提方法能有效减小轨迹漂移误差, 提高 SLAM 点云地图的整体精度。后期将尝试在配准过程中加入少量的控制点作为约束条件, 进一步提高点云的精度。

### 参 考 文 献

- [1] 杨必胜, 梁福逊, 黄荣刚. 三维激光扫描点云数据处理研究进展、挑战与趋势[J]. 测绘学报, 2017, 46(10): 1509-1516.  
Yang B S, Liang F X, Huang R G. Progress, challenges and perspectives of 3D LiDAR point cloud processing[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(10): 1509-1516.
- [2] Cheng L, Chen S, Liu X Q, et al. Registration of laser scanning point clouds: a review[J]. Sensors, 2018, 18(5): 1641.



- [3] 阴贺生, 裴硕, 徐磊, 等. 多机器人视觉同时定位与建图技术研究综述[J]. 机械工程学报, 2022, 58(11): 11-36.  
Yin H S, Pei S, Xu L, et al. Review on simultaneous positioning and mapping technology of multi-robot vision[J]. Journal of Mechanical Engineering, 2022, 58(11): 11-36.
- [4] 危双丰, 刘振彬, 赵江洪, 等. SLAM 室内三维重建技术综述[J]. 测绘科学, 2018, 43(7): 15-26.  
Wei S F, Liu Z B, Zhao J H, et al. A review of indoor 3D reconstruction with SLAM[J]. Science of Surveying and Mapping, 2018, 43(7): 15-26.
- [5] Huang R, Xu Y S, Yao W, et al. Robust global registration of point clouds by closed-form solution in the frequency domain[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 171: 310-329.
- [6] Wang B Q, Kang Z Z. Self-closure global registration for subway tunnel point clouds[C]//2012 International Conference on Computer Vision in Remote Sensing, December 16-18, 2012, Xiamen, China. New York: IEEE Press, 2013: 152-157.
- [7] Kelbe D, van Aardt J, Romanczyk P, et al. Marker-free registration of forest terrestrial laser scanner data pairs with embedded confidence metrics[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(7): 4314-4330.
- [8] Kelbe D, van Aardt J, Romanczyk P, et al. Multiview marker-free registration of forest terrestrial laser scanner data with embedded confidence metrics[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(2): 729-741.
- [9] Glira P, Pfeifer N, Briese C, et al. Rigorous strip adjustment of airborne laserscanning data based on the ICP algorithm[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2015, II-3/W5: 73-80.
- [10] Chen Z Q, Li J P, Yang B S. A strip adjustment method of UAV-borne LiDAR point cloud based on DEM features for mountainous area[J]. Sensors, 2021, 21(8): 2782.
- [11] 闫利, 戴集成, 谭骏祥, 等. SLAM 激光点云整体精配准位姿图技术[J]. 测绘学报, 2019, 48(3): 313-321.  
Yan L, Dai J C, Tan J X, et al. Global fine registration of point cloud in LiDAR SLAM based on pose graph[J]. Acta Geodaetica et Cartographica Sinica, 2019, 48(3): 313-321.
- [12] 陆世东, 涂美义, 罗小勇, 等. 基于图优化理论和 GNSS 激光 SLAM 位姿优化算法[J]. 激光与光电子学进展, 2020, 57(8): 081024.  
Lu S D, Tu M Y, Luo X Y, et al. Laser SLAM pose optimization algorithm based on graph optimization theory and GNSS[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081024.
- [13] Kümmerle R, Grisetti G, Strasdat H, et al. G2o: a general framework for graph optimization[C]//2011 IEEE International Conference on Robotics and Automation, May 9-13, 2011, Shanghai, China. New York: IEEE Press, 2011: 3607-3613.
- [14] 周洽国, 曹江微, 邸顺帆. 3D 激光雷达 SLAM 算法综述[J]. 仪器仪表学报, 2021, 42(9): 13-27.  
Zhou Z G, Cao J W, Di S F. Overview of 3D lidar SLAM algorithms[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 13-27.
- [15] 王忠立, 赵杰, 蔡鹤皋. 大规模环境下基于图优化 SLAM 的后端优化方法[J]. 哈尔滨工业大学学报, 2015, 47(7): 20-25.  
Wang Z L, Zhao J, Cai H G. A survey of back-end optimization method for graph-based SLAM under large-scale environment[J]. Journal of Harbin Institute of Technology, 2015, 47(7): 20-25.
- [16] Grisetti G, Kümmerle R, Stachniss C, et al. Hierarchical optimization on manifolds for online 2D and 3D mapping[C]//2010 IEEE International Conference on Robotics and Automation, May 3-7, 2010, Anchorage, AK, USA. New York: IEEE Press, 2010: 273-278.
- [17] Konolige K, Grisetti G, Kümmerle R, et al. Efficient sparse pose adjustment for 2D mapping[C]//2010 IEEE/RSJ International Conference on Intelligent Robots and Systems, October 18-22, 2010, Taipei, China. New York: IEEE Press, 2010: 22-29.
- [18] Wohlkinger W, Vincze M. Ensemble of shape functions for 3D object classification[C]//2011 IEEE International Conference on Robotics and Biomimetics, December 7-11, 2011, Karon Beach, Thailand. New York: IEEE Press, 2012: 2987-2992.
- [19] Dong Z, Yang B S, Liang F X, et al. Hierarchical registration of unordered TLS point clouds based on binary shape context descriptor[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 144: 61-79.
- [20] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration[C]//2009 IEEE International Conference on Robotics and Automation, May 12-17, 2009, Kobe, Japan. New York: IEEE Press, 2009: 3212-3217.
- [21] 熊风光, 霍旺, 韩燮, 等. 三维点云中关键点误匹配剔除方法[J]. 光学学报, 2018, 38(2): 0210003.  
Xiong F G, Huo W, Han X, et al. Removal method of mismatching keypoints in 3D point cloud[J]. Acta Optica Sinica, 2018, 38(2): 0210003.
- [22] 李仁忠, 杨曼, 田瑜, 等. 基于 ISS 特征点结合改进 ICP 的点云配准算法[J]. 激光与光电子学进展, 2017, 54(11): 111503.  
Li R Z, Yang M, Tian Y, et al. Point cloud registration algorithm based on the ISS feature points combined with improved ICP algorithm[J]. Laser & Optoelectronics Progress, 2017, 54(11): 111503.
- [23] Xu W, Cai Y X, He D J, et al. FAST-LIO2: fast direct LiDAR-inertial odometry[J]. IEEE Transactions on Robotics, 2022, 38(4): 2053-2073.