

doi: 10.11835/j.issn.1000-582X.2022.105

基于改进 FPFH-ICP 的车载激光雷达点云配准方法

蒋风洋^{1a,1b}, 刘永刚^{1a,1b}, 陈智航^{1a,1b}, 陈 峥²

(1. 重庆大学 a. 机械与运载工程学院; b. 机械传动国家重点实验室, 重庆 400044;

2. 昆明理工大学 交通工程学院, 昆明 650500)

摘要: 为了改善传统车载激光雷达点云配准方法准确度低、计算速度慢的问题, 提出了一种基于快速点特征直方图 (fast point feature histograms, FPFH) 初始匹配与改进迭代最近点 (iterative closest point, ICP) 精确配准相结合的改进 FPFH-ICP 配准算法。配准前使用体素滤波器和 statistical-outlier-removal 滤波器进行预处理; 采用 FPFH 提取点云特征, 基于采样一致性 (sample consensus initial alignment, SAC-IA) 进行初始配准, 为精确配准提供良好的位姿信息; 建立 K-D 树并在传统 ICP 配准算法的基础上添加法向量阈值, 对车载激光雷达点云数据进行精确配准; 在 4 种不同场景的实验中, 改进 FPFH-ICP 配准比 ICP 配准的均方根误差和配准用时分别平均减少了 7.56% 和 41.22%, 比点特征直方图 (point feature histograms, PFH) 配准的均方根误差和配准用时分别平均减少了 30.28% 和 18.95%, 表明改进的 FPFH-ICP 能够对车载激光雷达点云数据实现精确且高效的配准。

关键词: 车载激光雷达; 点云配准; 快速点特征直方图; 法向量阈值; 迭代最近点

中图分类号: U461.91

文献标志码: A

文章编号: 1000-582X(2023)05-001-10

Point cloud registration of vehicle-mounted lidar based on improved FPFH-ICP algorithm

JIANG Fengyang^{1a,1b}, LIU Yonggang^{1a,1b}, CHEN Zhihang^{1a,1b}, CHEN Zheng²

(1a. College of Mechanical and Vehicle Engineering; 1b. State Key Laboratory of Mechanical

Transmissions, Chongqing University, Chongqing 400044, P. R. China; 2. Faculty of Transportation

Engineering, Kunming University of Science and Technology, Kunming 650500, P. R. China)

Abstract: To solve the problems of low accuracy and slow calculating speed of the traditional point cloud registration methods for vehicle-mounted lidar, an improved FPFH-ICP registration combining fast point feature histograms (FPFH) initial matching with improved iterative closest point (ICP) accurate registration was proposed. Firstly, voxel grid and statistical-outlier-removal filter were used for preprocessing data before registration. Then, based on sample consensus initial alignment (SAC-IA), FPFH was used for initial registration to provide good pose information for accurate registration. Finally, a K-D tree was established, and a normal vector threshold was added to traditional ICP registration for accurate registration. In the experiments of four different scenarios, the root mean square error and registration time of the improved FPFH-ICP registration were

收稿日期: 2021-07-14 网络出版日期: 2022-03-03

基金项目: 国家自然科学基金资助项目 (52172400)。

Supported by National Natural Science Foundation of China (52172400).

作者简介: 蒋风洋 (1997—), 男, 硕士研究生, 主要研究智能车轨迹规划, (E-mail) 20193213015t@cqu.edu.cn。

通信作者: 刘永刚, 男, 博士, 教授, 主要研究方向为智能汽车决策与控制关键技术, (E-mail) andyliuyg@cqu.edu.cn。

reduced by 7.56% and 41.22%, respectively, compared with ICP registration, and by 30.28% and 18.95%, respectively, compared with point feature histograms (PFH) registration, suggesting that the improved FPFH-ICP registration can achieve accurate and efficient registration of point cloud data of vehicle-mounted lidar.

Keywords: vehicle-mounted lidar; point cloud registration; fast point feature histograms; normal vector threshold; iterative closest point

车载激光雷达安装在快速移动的智能汽车上,持续采集车辆前方的道路环境信息,由于对同一障碍物在不同地点、不同角度采集的点云数据存在一定的偏差,需要对车载激光雷达采集到的点云数据进行配准。同时,车载激光雷达每次扫描的点云数据量有限,距离车载激光雷达较远处的点云密度较低;天气、遮挡、振动及安装误差等原因也会降低车载激光雷达采集点云数据的精度。因此,点云配准方法需保证在低精度、低密度条件下也具有较好的适应性。当前关于点云配准的研究主要集中在正态分布变换法(normal distribution transform, NDT)^[1-2]、随机采样一致性法(random sample consensus, RANSAC)^[3-4]和ICP^[5-6]等配准算法的改进。

Li等^[7]提出一种基于正态分布变换单元的改进RANSAC方法,用每个单元内的正态分布对观察点进行建模。杨玉泽等^[8]提出FPFH初始匹配和NDT精确配准结合的配准方法,在牺牲配准效率的前提下提高了精度。相较于上述方法,ICP配准作为当前应用最广泛的点云配准方法,应用最小二乘法迭代计算获取最优的变换矩阵^[9]。但是该算法存在计算难、效率低、依赖初始变换估计且易陷于局部最优的不足,很多学者对该算法进行了改进。Liu等^[10]设计了一种随机策略来计算两点云之间变换矩阵的初始值,结合ICP自动地实现点云配准,但该方法的鲁棒性有待验证。Li等^[11]将重叠率、角度、距离和噪声作为ICP的影响因素,利用4个数据集对点对点和对平面ICP的有效性、鲁棒性、准确性和效率进行了评估。Shi等^[12]将NDT与ICP结合,提高了配准效率。Zaganidis等^[13]提出语义辅助正态分布变换配准点云,但应用范围有限。Li等^[14]建立高斯混合模型来拟合点云,虽提高了配准精度但降低了配准效率。

为进一步提高车载激光雷达点云配准的效率和精度,同时满足在低精度、低密度条件下的配准需求,提出了一种基于FPFH初始匹配与改进ICP精确配准相结合的改进FPFH-ICP配准方法。首先对激光雷达点云数据进行预处理,并采用FPFH提取点云特征,基于SAC-IA进行初始配准,然后建立K-D树并在传统ICP配准算法的基础上添加法向量阈值进行精确配准,最后在不同场景下与ICP配准和PFH配准进行对比实验,验证了所提方法对车载激光雷达点云数据的配准效果。

1 基于FPFH特征的初始配准

初始配准可减小点云对应点对间在平移与旋转上的错位,为点云的精确配准提供良好的位姿。使用体素滤波器和statistical-outlier-removal滤波器对点云数据进行预处理,采用FPFH特征描述子提取点云特征,使用SAC-IA进行车载激光雷达点云数据的初始配准。

1.1 FPFH特征描述子

3D点云特征描述和提取是点云数据处理最关键的部分,点云配准的效果直接受到特征描述和提取的影响。FPFH特征描述子基于PFH进行改进,解决了PFH在处理密集点云时效率低下的问题,提供的信息具有旋转不变性。车载激光雷达点云数据量较庞大,采用FPFH特征描述子进行点云特征的描述和提取,其工作原理如图1所示^[15]。

计算过程如下:

1) 计算查询点 p_q 与其 k 邻域点 p_k 间的特征元素,该结果成为简化的点特征直方图;

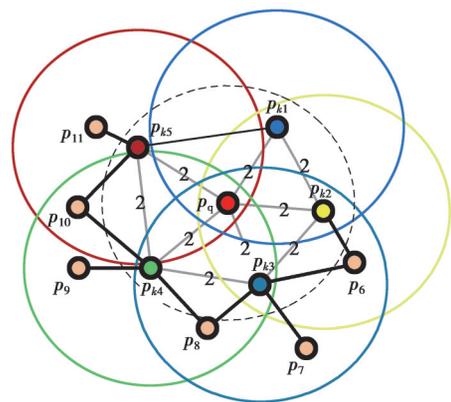


图1 FPFH计算原理

Fig. 1 The principle of FPFH calculation

2)重新确定每个点的 k 邻域,使用邻近简化点特征直方图的值得出 p_q 的FPFH。

$$\text{FPFH}(p_q) = \text{SPFH}(p_q) + \frac{1}{k} \sum_{i=1}^k \left[\frac{1}{w_k} \text{SPFH}(p_k) \right], \quad (1)$$

式中:权重 w_k 表示查询点 p_q 与其 k 邻域点 p_k 间的距离;SPFH(simple point feature histograms)为简化的点特征直方图,表示查询点 p_q 与其 k 邻域点间对应法线构成的角度集合。

1.2 SAC-IA 初始配准

SAC-IA 初始配准无需获取点云数据对应关系的全部组合,通过 FPFH 点云特征描述子从大量候选对应关系中获得最优的初始变换矩阵估计,避免了传统方法依赖点云数据旋转不变性过程中出现计算困难、易陷于局部最优的弊端。SAC-IA 初始配准的过程为:

1)在源点云 S 中选取 x 个样本数据点,所选样本数据点两两之间的距离应大于所设定的距离阈值 ω_d ,以保证所选的 x 个样本数据点具备不同的 FPFH 特征;

2)在目标点云 T 中找出与样本数据点具备相似 FPFH 特征的点云数据点,对其进行存储并进行随机采样,用它们之间的对应关系来代表所有样本数据点之间的对应关系;

3)计算这些样本数据点对的变换参数,得出平移和旋转矩阵,并利用 Huber 评价函数判定是否为最优变换矩阵,评价函数设定为:

$$H(a) = \begin{cases} \frac{1}{2} a^2, & |a| \leq \omega_d; \\ \omega_d (|a| - \frac{1}{2} \omega_d), & |a| > \omega_d. \end{cases} \quad (2)$$

式中: a 为样本数据点对变换后的距离差; ω_d 为超参数。

重复上述过程,当 Huber 评价函数最小时,所得变换矩阵即为最优。

2 基于改进 ICP 的精确配准

经过 SAC-IA 初始配准的点云数据已经有了较好的位姿,但要获得更为精准的结果还需进行精确配准。ICP 算法通过最小二乘法迭代获取最优变换矩阵,有着计算直观简单的优势,但也存在迭代次数过多易陷于局部最优的不足。改进 FPFH-ICP 配准通过传统 ICP 配准算法的基础上增加 K-D 树和法向量阈值实现车载激光雷达点云数据的精确配准。

2.1 K-D 树建立

传统 ICP 配准花费大量时间在最近点搜索上,且需要多次重复迭代,计算效率较低。K-D 树是带约束的二分查找树,常用于搜索和存储多维空间中的数据点,可降低 ICP 在查询最近点时的计算复杂度,加速 ICP 配准的迭代过程,其工作原理如图 2 所示。

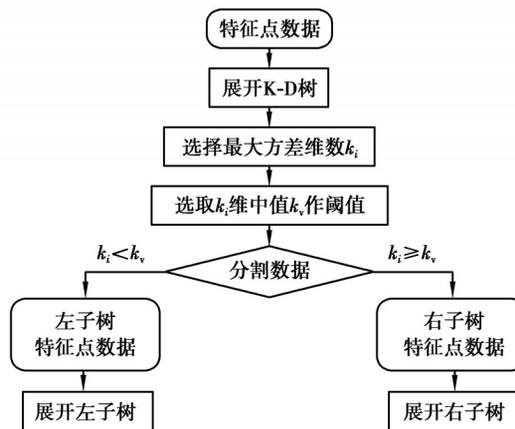


图 2 K-D 树流程图

Fig. 2 Flow chart of K-D tree

2.2 法向量阈值

需要进行精确配准的车载激光雷达源点云与目标点云间的拓扑关系是一致的,因此,可选用对应点对的法向量夹角来判断是否为点云数据正确的对应点对 s_p 与 t_q 。从车载激光雷达源点云数据集 S 和目标点云数据集 T 中,计算各匹配点法向量夹角的余弦值 $\cos \theta$,当大于法向量阈值 ω_v 时,则认定为正确的匹配点对,否则剔除错误点对。由此便提高了车载激光雷达点云的配准精度,剔除错误点对在一定程度上也加快了配准速度。

$$\begin{cases} \cos \theta > \omega_v, & \text{保留;} \\ \cos \theta \leq \omega_v, & \text{剔除。} \end{cases} \quad (3)$$

式中: θ 为对应点对 s_p 和 t_q 法向量 n_p 与 n_q 的夹角; ω_v 为设定的法向量阈值。

2.3 基于改进ICP精确配准原理

点云配准的目的是源点云数据集 S 和目标点云数据集 T 通过变换矩阵 (\mathbf{R}, \mathbf{t}) 变换后,使源点云与目标点云中的数据点对应。

$$t_q = \mathbf{R} \cdot s_p + \mathbf{t}, \quad (4)$$

式中: \mathbf{t} 为平移矩阵; \mathbf{R} 为旋转矩阵。

当目标函数

$$E(\mathbf{R}, \mathbf{t}) = \frac{1}{n} \sum_{i=1}^n \|t_q - (\mathbf{R} \cdot s_p + \mathbf{t})\|^2 \quad (5)$$

为最小值时, \mathbf{t} 与 \mathbf{R} 为最优,这里的 n 为目标点云数据点的个数。

改进后的ICP精确配准对初始变换后的源点云和目标点云建立K-D树加速近邻搜索,通过法向量阈值 ω_v 剔除错误的点对,使用奇异值分解法计算变换矩阵 (\mathbf{R}, \mathbf{t}) ,使目标函数 $E(\mathbf{R}, \mathbf{t})$ 最小,循环迭代从而获得最优的配准效果,其工作原理如图3所示。

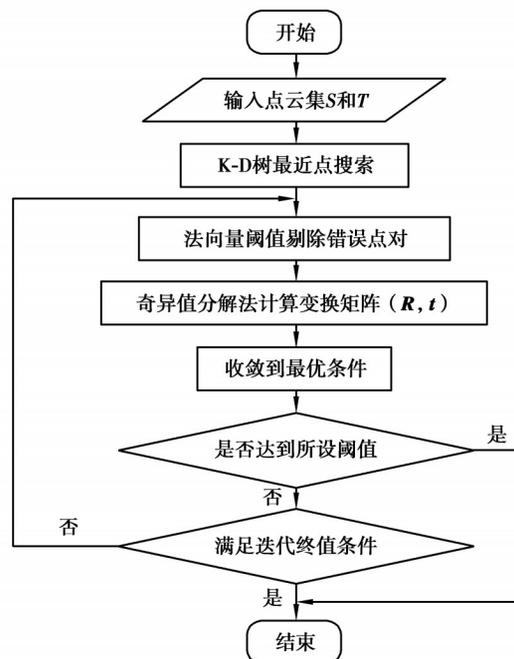


图3 基于改进ICP精确配准方法

Fig. 3 Method of accurate registration based on improved ICP

3 实验结果与分析

KITTI数据集是当前自动驾驶领域广泛应用的计算机视觉算法评测数据集。从KITTI实车采集的数据集中选取4个不同的场景,对预处理后的点云数据分别采用ICP、PFH和改进FPFH-ICP进行车载激光雷达点云数据配准,验证所提算法的配准效果。

3.1 点云数据预处理

车载激光雷达采集到的点云数据掺杂了部分噪声点和离群点,而且庞大的点云数据量会降低计算机的处理速度,所以在点云配准前需进行预处理过程^[6]。基于体素滤波器对激光雷达点云数据进行下采样,采用statistical-outlier-removal滤波器剔除偏移有效点云的离群点,结果如图4所示。

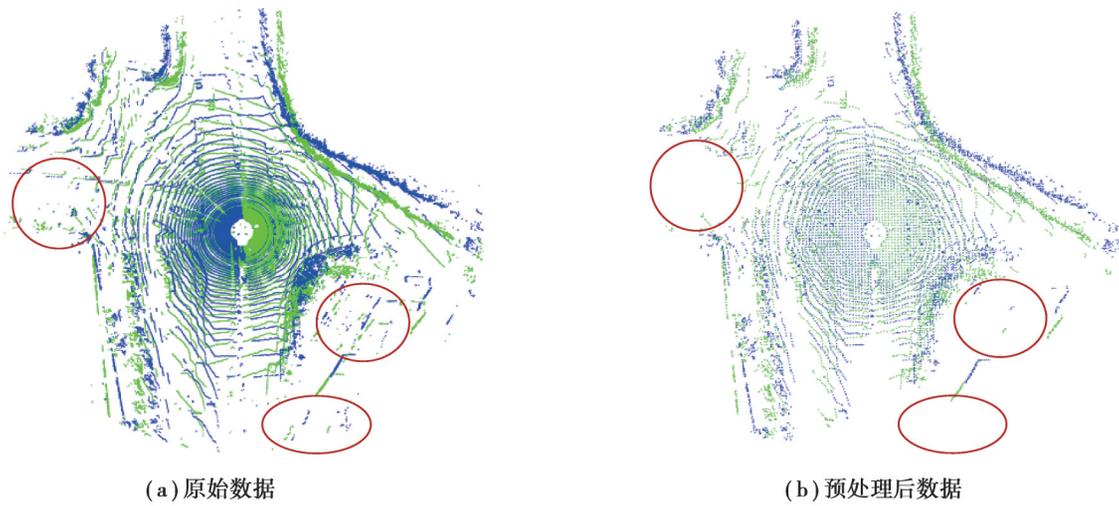


图4 车载激光雷达点云数据预处理结果

Fig. 4 Preprocessing results of point cloud data of vehicle-mounted lidar

由图4可知,车载激光雷达点云数据经预处理后明显变得更加稀疏,源点云数据点的个数由120 119变为6 400,目标点云数据点的个数由119 510变为6 431,在不改变原有数据结构的前提下精简了数据,而且从图中的圆圈标记位置看出,点云数据经预处理后有效剔除了离群点,为提升点云配准效果奠定了基础。

3.2 点云配准结果

点云配准的效率和精度是评估点云配准效果的重要指标,配准效率由配准时间评估,配准精度采用均方根误差(root mean square error, RMSE)进行评估。

$$\text{RMSE} = \sqrt{\frac{1}{n_s} \sum_{i=1}^{n_s} \|e_i\|^2}; \quad (6)$$

$$e_i = \mathbf{R}s_i + \mathbf{t} - t_i. \quad (7)$$

式中: n_s 为源点云数据点的个数; e_i 为源点云与目标点云中对应点对间的距离误差; s_i 为源点云中的数据点,依赖刚体变换矩阵变换到目标点云中; t_i 为目标点云中的与 s_i 对应的数据点。

场景1获取的车载激光雷达点云数据有着旋转偏移量较小而平移偏移量较大的特点,初始源点云与目标点云的数据点数量分别为120 308和120 636,将预处理后的点云数据分别采用ICP、PFH和改进FPFH-ICP进行配准,结果如图5所示。

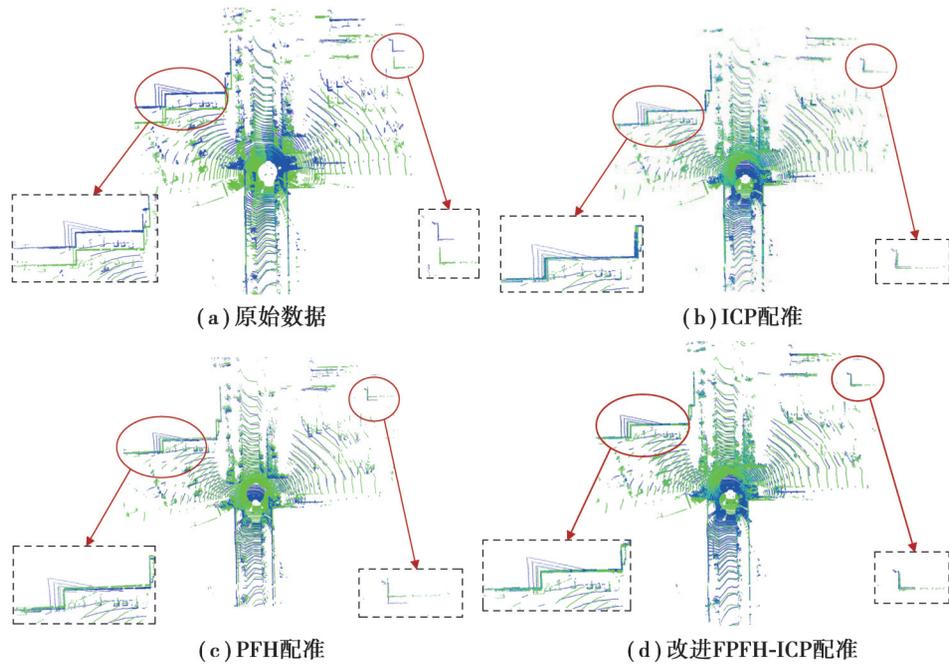


图5 不同算法在场景1的配准结果

Fig. 5 Registration results of different algorithms in Scenario 1

表1 不同算法在场景1的点云配准效果对比

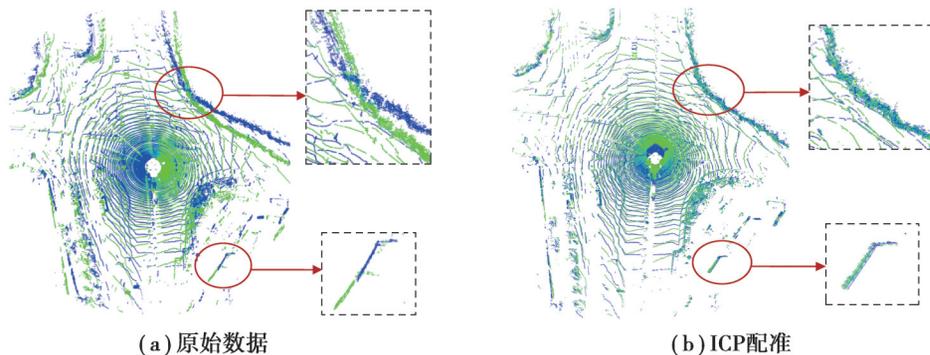
Table 1 Comparison of point cloud registration effects of different algorithms in Scenario 1

算法	RMSE/m	时间/s
ICP	0.047 2	25.478
PFH	0.055 3	22.393
改进 FPFH-ICP	0.037 4	15.163

由图5和表1得出,在场景1中改进 FPFH-ICP 配准均方根误差为 0.037 4 m,其精度优于传统 ICP 配准和 PFH 配准,配准时间为 15.163 s,比 ICP 配准和 PFH 配准所用配准时间少。由此可得出,改进 FPFH-ICP 配准适用于在车载激光雷达点云数据平移偏移量较大而旋转偏移量较小的场景。

与场景1不同,场景2的车载激光雷达点云数据有着平移偏移量较小而旋转偏移量较大的特点,初始源点云和目标点云数据点的数量分别为 120 119 和 119 510,将预处理后的点云数据分别采用 ICP、PFH 和改进 FPFH-ICP 进行配准,结果如图6所示。

由图6和表2得出,采用 ICP 配准和改进 FPFH-ICP 配准的源点云与目标点云配准效果良好,配准精度均优于 PFH 配准,但改进 FPFH-ICP 的配准效率更高,所用配准时间最短。由此可得出,在平移偏移量较小而旋转偏移量较大的场景中,改进 FPFH-ICP 配准效果最佳。



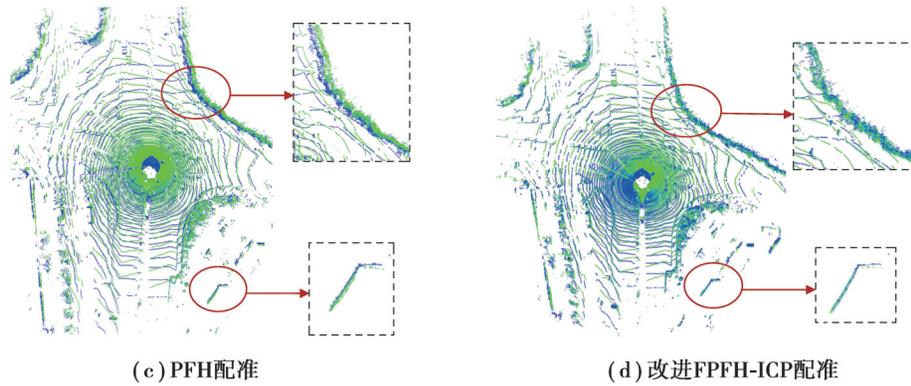


图 6 不同算法在场景 2 的配准结果

Fig. 6 Registration results of different algorithms in Scenario 2

场景 3 选取自弯道处的车载激光雷达点云数据,平移和旋转偏移量均较小。初始源点云与目标点云的数据点数量分别为 118 679 和 118 464,将预处理后的点云数据分别采用 ICP、PFH 和改进 FPFH-ICP 进行配准,结果如图 7 所示。

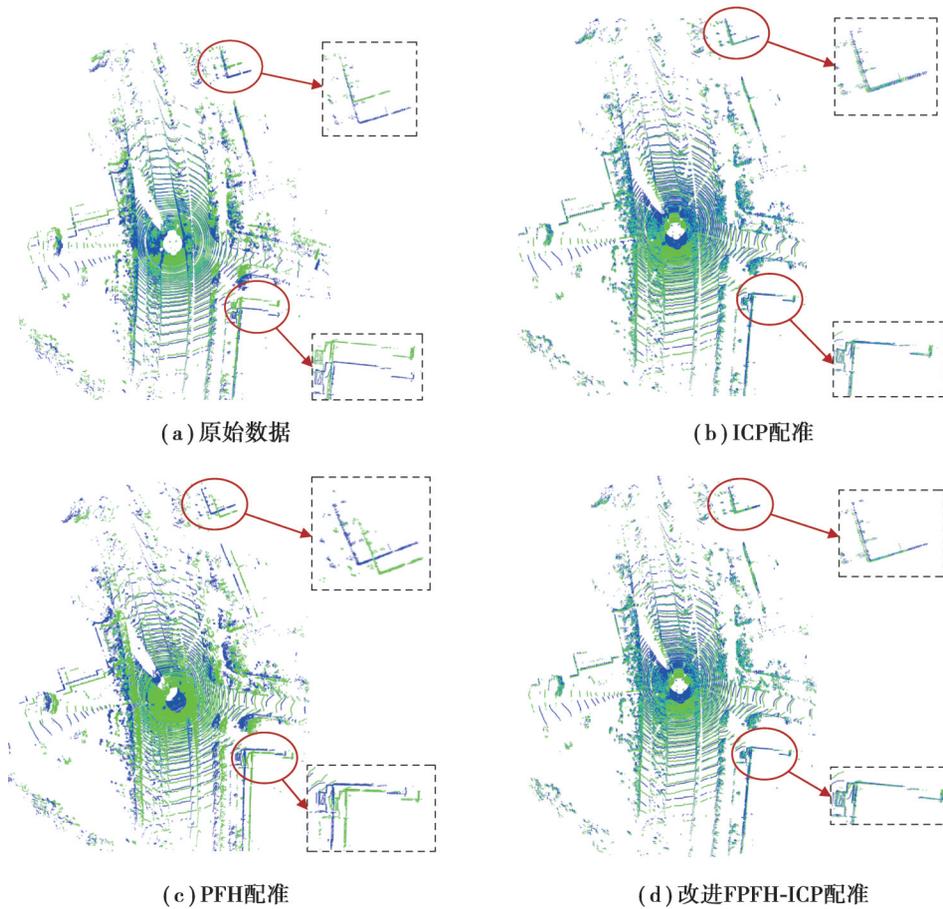


图 7 不同算法在场景 3 的配准结果

Fig. 7 Registration results of different algorithms in Scenario 3

由图 7 和表 3 得出,在场景 3 中改进 FPFH-ICP 配准的均方根误差为 0.053 1 m,ICP 配准的精度与 FPFH-ICP 接近,但 ICP 配准所消耗的时间最长,配准效率最低,PFH 配准的精度最差。改进 FPFH-ICP 同样适用于

弯道处平移和旋转偏移量均较小的车载激光雷达点云数据的配准。

表2 不同算法在场景2的点云配准效果对比

Table 2 Comparison of point cloud registration effects of different algorithms in Scenario 2

算法	RMSE/m	时间/s
ICP	0.059 8	25.633
PFH	0.075 2	21.395
改进FPFH-ICP	0.058 7	18.106

表3 不同算法在场景3的点云配准效果对比

Table 3 Comparison of point cloud registration effects of different algorithms in Scenario 3

算法	RMSE/m	时间/s
ICP	0.055 1	25.072
PFH	0.089 7	17.493
改进FPFH-ICP	0.053 1	15.008

场景4采用了较为稀疏的点云数据,以此来验证当车载激光雷达在低精度、低密度条件下的配准效果。初始源点云的数据点的数量为20 911,目标点云的数据点的数量为20 765,不同配准方法的配准效果如图8和表4所示。

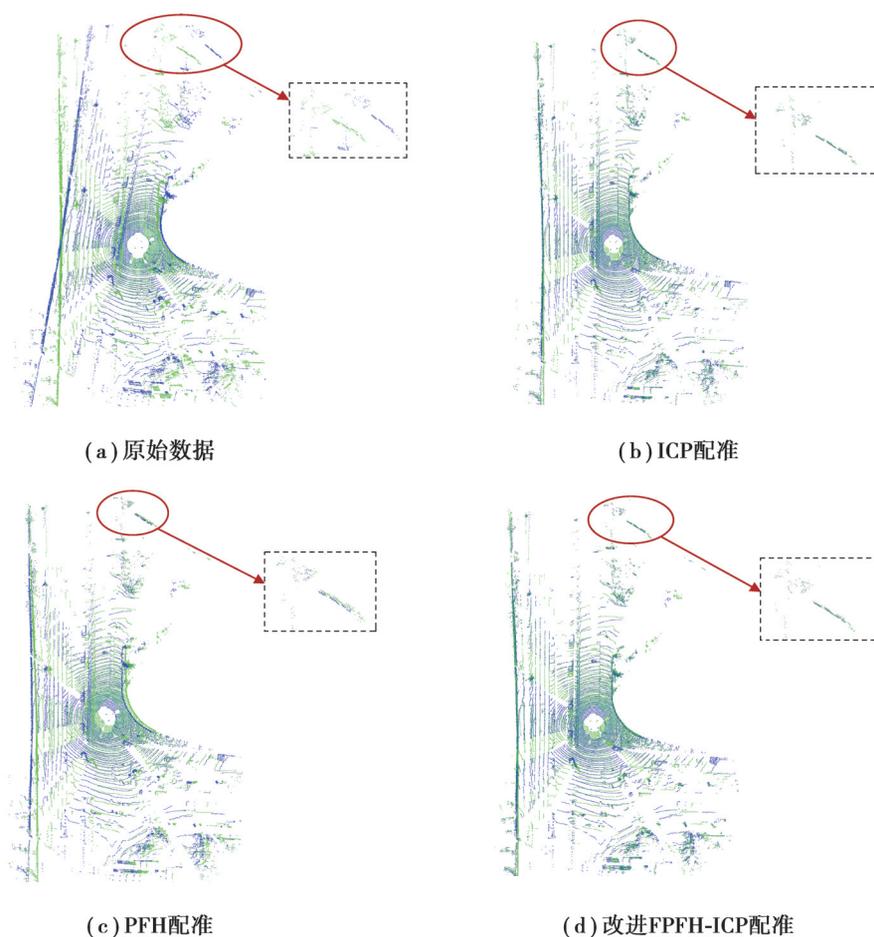


图8 不同算法在场景4的配准结果

Fig. 8 Registration results of different algorithms in Scenario 4

表 4 不同算法在场景 4 的点云配准效果对比

Table 4 Comparison of point cloud registration effects of different algorithms in Scenario 4

算法	RMSE/m	时间/s
ICP	0.064 1	36.619
PFH	0.079 7	20.537
改进 FPFH-ICP	0.059 9	18.032

由图 8 和表 4 得出,在场景 4 中改进 FPFH-ICP 配准的均方根误差为 0.059 9 m,配准精度最高;所用配准时间最短,不到 ICP 配准时间的 50%。因此,改进 FPFH-ICP 配准可以较好地适应低精度、低密度条件。

图 9 表明,改进 FPFH-ICP 配准方法分别在不同的 4 个场景中 RMSE 和配准时间均低于 ICP 配准和 PFH 配准,证明了提出的改进 FPFH-ICP 配准方法有较高的配准精度和配准效率,具有良好的鲁棒性。

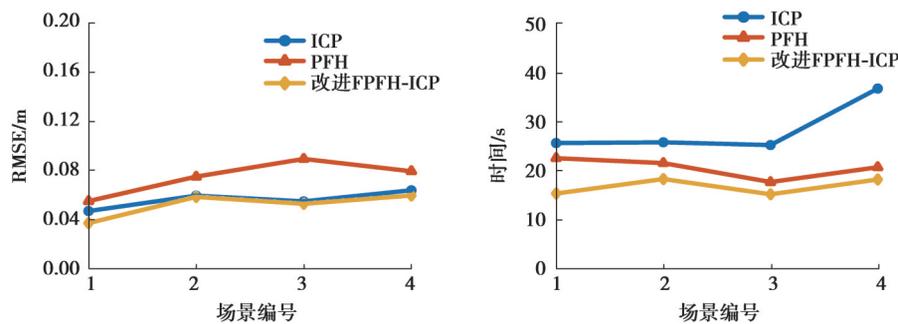


图 9 不同算法在各个场景的配准结果

Fig. 9 Registration results of different algorithms in various scenes

4 结 论

为了改善车载激光雷达点云配准方法计算效率低、依赖初始变换估计等问题,采用 FPFH 特征,基于 SAC-IA 方法进行初始配准,在传统 ICP 配准算法的基础上增加 K-D 树和法向量阈值进行精确配准。最后利用 KITTI 数据集中车载激光雷达实车采集的不同场景下的点云数据,与 ICP 配准和 PFH 配准进行对比实验。结果表明,改进 FPFH-ICP 配准相比于 ICP 配准均方根误差平均减少 7.56%,配准用时平均减少 41.22%,配准效率显著提高;相比于 PFH 配准均方根误差平均减少 30.28%,配准用时平均减少 18.95%,配准精度显著提高。由此得出,所提的改进 FPFH-ICP 配准方法能够对车载激光雷达点云数据实现精确且高效的配准,为后续智能车的决策规划提供良好的数据支持。

参考文献

- [1] 范强,刘鹏,杨俊,等. 基于 3D-Harris 与 FPFH 改进的 3D-NDT 配准算法[J]. 图学学报, 2020, 41(4): 567-575.
Fan Q, Liu P, Yang J, et al. Improved 3D-NDT point cloud registration algorithm based on 3D-Harris and FPFH[J]. Journal of Graphics, 2020, 41(4): 567-575. (in Chinese)
- [2] 袁志聪,鲁铁定,刘瑞. 一种基于 BFGS 修正的正态分布变换点云配准方法[J]. 测绘通报, 2020(10): 38-42.
Yuan Z C, Lu T D, Liu R. A normal distribution transform point cloud registration method based on BFGS correction[J]. Bulletin of Surveying and Mapping, 2020(10): 38-42. (in Chinese)
- [3] Kang G H, Zhang Q, Wu J Q, et al. Pose estimation of a non-cooperative spacecraft without the detection and recognition of point cloud features[J]. Acta Astronautica, 2021, 179: 569-580.
- [4] Koguciuk D. Parallel RANSAC for point cloud registration[J]. Foundations of Computing and Decision Sciences, 2017, 42(3): 203-217.

- [5] 易倩, 钟浩宇, 刘龙, 等. 基于 ROI-RSICP 算法的车轮廓形动态检测[J]. 中国激光, 2020, 47(11): 154-165.
Yi Q, Zhong H Y, Liu L, et al. Dynamic inspection of wheel profile based on ROI-RSICP algorithm[J]. Chinese Journal of Lasers, 2020, 47(11): 154-165. (in Chinese)
- [6] 王飞, 刘如飞, 任红伟, 等. 利用道路目标特征的多期车载激光点云配准[J]. 测绘科学技术学报, 2020, 37(5): 496-502.
Wang F, Liu R F, Ren H W, et al. Multi-stage vehicle-mounted laser point cloud registration using road target features[J]. Journal of Geomatics Science and Technology, 2020, 37(5): 496-502. (in Chinese)
- [7] Li L, Yang F, Zhu H H, et al. An improved RANSAC for 3D point cloud plane segmentation based on normal distribution transformation cells[J]. Remote Sensing, 2017, 9(5): 433.
- [8] 杨玉泽, 孙英伟, 林文树. 基于 FPFH 特征和 NDT 算法的树木点云配准[J]. 西北林学院学报, 2019, 34(5): 141-146.
Yang Y Z, Sun Y W, Lin W S. Tree point cloud registration based on FPFH feature and NDT algorithm[J]. Journal of Northwest Forestry University, 2019, 34(5): 141-146. (in Chinese)
- [9] Wu Z Z, Chen H C, Du S Y, et al. Correntropy based scale ICP algorithm for robust point set registration[J]. Pattern Recognition, 2019, 93: 14-24.
- [10] Liu J B, Guo P Y, Sun X L. An automatic 3D point cloud registration method based on biological vision[J]. Applied Sciences, 2021, 11(10): 4538.
- [11] Li P, Wang R S, Wang Y X, et al. Evaluation of the ICP algorithm in 3D point cloud registration[J]. IEEE Access, 2020, 8: 68030-68048.
- [12] Shi X Y, Peng J J, Li J P, et al. The iterative closest point registration algorithm based on the normal distribution transformation [J]. Procedia Computer Science, 2019, 147: 181-190.
- [13] Zaganidis A, Sun L, Duckett T, et al. Integrating deep semantic segmentation into 3-D point cloud registration[J]. IEEE Robotics and Automation Letters, 2018, 3(4): 2942-2949.
- [14] Li Q S, Xiong R, Vidal-Calleja T. A GMM based uncertainty model for point clouds registration[J]. Robotics and Autonomous Systems, 2017, 91: 349-362.
- [15] Zheng L, Li Z K. Virtual namesake point multi-source point cloud data fusion based on FPFH feature difference[J]. Sensors, 2021, 21(16): 5441.
- [16] 谢德芳, 陈丛桂, 周聪, 等. 基于 RANSAC 的点云配准优化算法[J]. 机电工程技术, 2020, 49(9): 38-39,67.
Xie D F, Chen C G, Zhou C, et al. Optimization algorithm of point cloud registration based on RANSAC[J]. Mechanical & Electrical Engineering Technology, 2020, 49(9): 38-39,67. (in Chinese)

(编辑 罗 敏)