

文章编号:1672-3961(2024)05-0144-11 DOI:10.6040/j.issn.1672-3961.0.2023.102

基于特征点提取的 RANSAC-ICP 三维点云配准方法

李岩¹, 张子毅^{2*}, 王建柱²

(1. 山东高速建设管理集团有限公司, 山东 济南 250001; 2. 山东大学齐鲁交通学院, 山东 济南 250002)

摘要:针对现有点云配准算法中易出现的误匹配、迭代时间长、精度低等问题,提出一种基于特征点提取的随机采样一致性与迭代最近点的三维点云配准方法,设计体素滤波降采样、关键特征点提取和几何特征描述、改进的随机采样一致性和点到面的迭代最近点算法框架。在降采样的基础上,提取点云关键几何特征点,并进行关键点邻域描述。采用四点对的随机采样一致性算法和点到面的迭代最近点算法分别进行点云粗配准与精细配准;采用 K 维树方法加速迭代,奇异值分解求解最优变换矩阵,最终实现三维点云配准。利用激光雷达及配套设备,模拟无人车辆采集点云数据,并选取不同时间间隔的点云图像,引入均方根误差和运算时间指标,验证算法的性能。试验结果表明:在粗配准阶段,配准速度相较于采样一致性算法和四点一致性算法,配准速度平均提高78.44%和61.02%,在处理100帧以下的的数据时,配准误差在10 cm范围内;在精配准阶段,配准误差较粗配准、正态分布变换算法、传统的迭代最近点算法分别降低5.11、4.94和0.53 cm,配准时间较传统的迭代最近点算法平均提高33.06%。

关键词:激光 SLAM; 点云配准; 关键点提取; 随机采样一致性; 迭代最近点

中图分类号: TN958.98

文献标志码: A

引用格式: 李岩, 张子毅, 王建柱. 基于特征点提取的 RANSAC-ICP 三维点云配准方法[J]. 山东大学学报(工学版), 2024, 54(5): 144-154.

LI Yan, ZHANG Ziyi, WANG Jianzhu. RANSAC-ICP 3D point cloud registration method based on feature point extraction[J]. Journal of Shandong University (Engineering Science), 2024, 54(5): 144-154.

RANSAC-ICP 3D point cloud registration method based on feature point extraction

LI Yan¹, ZHANG Ziyi^{2*}, WANG Jianzhu²

(1. Shandong Expressway Construction Management Group Co., Ltd., Jinan 250001, Shandong, China; 2. School of Oil Transportation, Shandong University, Jinan 250002, Shandong, China)

Abstract: Aiming at solving the problems of mismatch, long iteration time and low accuracy in data registration, this paper proposed a random sample consensus-iterative closest point registration method based on feature point registration. The algorithm framework consisted of voxel filtering down-sampling, key feature point extraction and geometric feature description, improved random sample consensus and point-to-plane iterative closest point iteration. Based on downsampling, the key geometric feature points of the point cloud were extracted and the key point neighborhood description was performed. We used the random sample consensus algorithm for four-point pairs and the point-to-plane iterative closest point algorithm to realize the point cloud coarse alignment and fine alignment. LiDAR and supporting equipment were used to simulate unmanned vehicles to collect point cloud data. According to the experimental data, the point cloud images of different time intervals were selected, and the root mean square error and the operation time index were introduced to verify the performance of the algorithm. In terms of coarse registration, the registration speed was improved by 78.44% and 61.02% compared with sample consensus initial alignment and 4-Points Congruent Sets algorithms, and the registration error below 100 frames was within 10 cm. In terms of fine registration, the registration error

收稿日期: 2023-05-22

基金项目: 国家自然科学基金资助项目(52002224); 山东省重点研发计划重大科技创新工程(2020CXGC10118); 国家重点研发计划资助项目(2022YFB2602102)

第一作者简介: 李岩(1977—), 女, 山东泰安人, 高级工程师, 主要研究方向为道路建设与管理。E-mail: 418192726@qq.com

* 通信作者简介: 张子毅(2000—), 男, 山东滨州人, 硕士研究生, 主要研究方向为高精度定位与建图。E-mail: 202215422@mail.sdu.edu.cn

was 5.11 cm, 4.94 cm and 0.53 cm lower than that of coarse registration, normal distributions transform algorithm and traditional iterative closest point algorithm respectively, and the registration time was 33.06% higher than that of traditional iterative closest point algorithm.

Keywords: Laser SLAM; point cloud registration; key point extraction; random sample consensus; iterative closest point

0 引言

地图构建是无人驾驶车辆实现高精度定位和自主导航的先决条件。车辆通过环境地图规划驾驶路线,进而完成自动驾驶^[1-2]。地图构建技术主要依赖于机器人的同步定位与建图(simultaneous localization and mapping, SLAM)^[3-5],即无人车通过自身搭载的传感器在行驶过程中定位并感知周围环境。目前,SLAM 技术通常采用的传感器有激光雷达(light detection and ranging, LiDAR)和深度相机^[6],分别对应激光 SLAM 和视觉 SLAM 技术,由于雷达具有不受光照影响且测量精度高等优点,在建图中通常采用激光 SLAM 方案。

点云配准作为激光 SLAM 的核心环节,是关联不同帧点云数据的常用手段^[7]。点云配准是指通过变换矩阵,将不同坐标系获取的点云数据变换到同一坐标系,再通过对齐合并为一个完整的三维点云的数据处理技术。传统的主流点云配准技术主要包括粗配准和精配准 2 个阶段^[8-9]。粗配准阶段的目的是,对于任意初始状态的两帧点云,通过旋转、平移变换,使得两帧点云大致对齐。精配准是在粗配准的基础上,实现更精确、更细化的配准。总而言之,点云配准的过程一定程度上可以认为是矩阵变换的过程。

点云粗配准算法主要分为两大类:基于几何特征描述的配准方法^[10]和基于全局搜索思想的配准方法^[11]。基于几何特征的配准方法主要依靠激光雷达采集数据中的特征信息进行配准。由于点云表面不同处存在空间变化差异,基于局部邻域信息寻找关键点,提取特征描述符,对于确定两帧点云的对应关系尤为重要。文献[12]提出一种基于特征信息进行配准的配准系统,该系统在点云配准效率和配准精度等方面都有较好表现,但在单一场景下,由于缺乏环境特征从而导致点云配准误差较大;文献[13]提出一种基于几何特征和图像特征的特征点云自适应拼接方法,能根据被测物体表面的几何特征和纹理信息自适应选择合适的配准算法,提高拼接的稳定性。基于全局搜索思想的配准方法中最常用的框架是随机采样一致性(random sample

consensus, RANSAC)算法^[14]。该算法由 Fischler 于 1981 年最先提出,通过迭代方式从一组包含异常点的数据中寻找最优的数学模型^[15]。随后,为了解决 RANSAC 算法耗时长、鲁棒性低等缺点,大量学者对此进行了研究和改进。文献[16]依据场景分类结果适应性地结合几何匹配与光度匹配,提出一种改进的 RANSAC,通过有偏重的随机采样与自适应假设评价,提高了变换矩阵估计的稳健性与有效性;文献[17-18]使用 KD-Tree 构建点云拓扑关系,根据法向量对地面点进行粗提取,在满足精度要求的同时,提高了点云配准计算速度;文献[19]针对搜索对应点的策略进行了优化,将基本的 3 组对应点扩展到了 4 组,并提出了超广义四点一致性(4-points congruent sets, 4PCS)算法,提高了算法的精度。

经过粗配准之后,两片点云的重叠部分已经大致对齐,为了进一步提升配准的精度,还需要进行精配准。点云精配准主要采用迭代最近点(iterative closest point, ICP)算法^[20-21],该算法本质上是基于最小二乘法的最优配准。该算法重复进行选择对应关系点对,计算最优刚体变换,直到满足正确配准的收敛精度要求。但传统迭代最近点 ICP 算法在进行点云配准时,若点云初始位置相差较大,容易陷入局部最优^[22],且利用欧式距离判断最近点存在计算量大、耗时长等问题^[23]。文献[24]提出基于双向 KD-Tree 的 ICP 算法,大幅缩减 ICP 算法的迭代时间。此外,众多研究学者对 ICP 算法进行了改进,提出了点到面的 ICP^[25]、广义 ICP^[26]、概率 ICP^[27]等多种方法。

针对现有算法存在的配准问题,本研究提出了一种基于关键特征点提取和几何特征描述(intrinsic shape signatures-fast point feature histograms, ISS-FPFH)的改进 RANSAC-ICP 三维点云配准方法。在降采样的基础上,进行关键点提取与几何特征描述,再结合改进的四点对多次迭代 RANSAC 粗配准算法以及点到面的 ICP 精配准算法实现点云配准。并采用 KD-Tree 方法快速搜索最近点,采用奇异值分解(singular value decomposition, SVD)计算匹配得分,得到最佳的初始变换矩阵和变换后的源点云,完成点云配准,配准流程如图 1 所示。

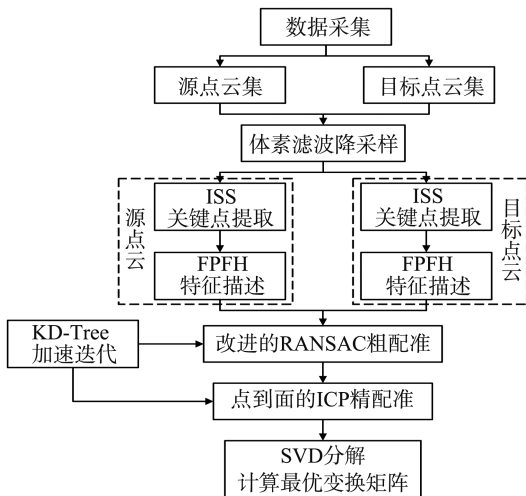


图1 配准算法流程图

Fig.1 Flow chart of registration algorithm

表1 LS-C32 雷达的关键物理参数

Table 1 Key physical parameters of LS-C32 LiDAR

测量范围/m	测距精度/cm	视场角/(°)		角度分辨率/(°)	
		垂直	水平	垂直	水平
100~200	±3	-18~14	360	0.33/0.66/1/2/3	0.09/0.18/0.36

1.1.2 数据采集

本研究试验用到的试验仪器包括:LS-C32 激光雷达、多功能三脚架、220 V 移动电源、变压器、笔记本电脑、平板推车。

试验利用平板小推车搭载激光雷达等设备模拟无人驾驶车辆行驶,利用上位机软件同步记录点云图像与实时位置、移动距离等信息,移动至固定位置处,结束测量,具体的试验步骤如下。

(1)利用多功能三脚架安装激光雷达,调整至合适高度,水准仪调至水平,并将激光雷达固定。

(2)连接移动电源、变压器与激光雷达,保证整个试验供电正常。

(3)连接激光雷达与笔记本电脑设备,打开上位机软件,验证是否可以实时显示点云图像信息。

(4)安装好设备后,利用平板小推车将设备移动至指定地点,开始试验,并在上位机软件录制点云 PCAP(packet capture)文件,该文件是常用的点云数据文件,主要存储点云位置、回波强度、颜色等信息。

(5)缓慢移动平板小推车,待移动至固定地点时,录制 PCAP 文件结束,试验完成。

试验数据采集地点为山东大学千佛山校区某校园路段,为避免行人、车辆对试验的干扰,数据采集时间段为 13:00~15:00,共选取长度 50 m 的路段,试验时每 10 m 间隔采集一次数据,每个间隔数

1 试验数据采集与处理

1.1 试验介绍与数据采集

1.1.1 试验设备

试验过程中用到的采集设备为激光雷达,它主要由发射模块、接收模块和信号处理模块 3 个模块组成,发射模块发射的激光遇到物体后,经过漫反射返回至激光接收器。接收到的反射信号经处理可得到点云的位置、角度、距离、反射强度等信息^[28]。本研究采用深圳镭神公司生产的型号为 LS-C32 的 32 线机械式激光雷达,雷达的关键物理参数如表 1 所示。

据录制 3 次。

1.2 数据可视化与预处理

激光雷达的扫描频率为 10 Hz,即每 0.1 s 采集一帧数据,为更好地显示配准效果,以相隔 200 帧的点云图像为例,对两帧点云进行配准,未经处理的两帧点云在 MTALAB 软件中的可视化图像如图 2 所示,在试验进行过程中,由于位置变化以及环境噪声干扰,第 50 帧和第 250 帧图像中点云的位置坐标有明显偏差,且包含不同点云信息,点云配准的目的是通过刚体变化实现点云信息的互补,是无人驾驶车辆高精度建图的基础。

进行点云滤波预处理,主要是去除点云中的无效点,以及点云降采样。本研究采用体素滤波器进行下采样,它的作用是利用体素化网格方法减少点云数量,采用体素栅格中接近中心点的点替代体素内的全部点,同时去除一定程度的噪音点及离群点^[29]。具体步骤如下。

(1)建立空间体素网格。选定点云 $P = \{p_1, p_2, \dots, p_n\}$,首先计算点云 x 、 y 和 z 坐标的最小值和最大值。根据最大、最小值,建立点云的最小立方空间边界框。将每个多维数据集的网格大小设置为 l ,并分别对 x 、 y 和 z 方向划分获得网格,网格数为 $N_x \times N_y \times N_z$, N_x 、 N_y 、 N_z 计算公式为:

$$\begin{cases} N_x = (x_{\max} - x_{\min}) / l \\ N_y = (y_{\max} - y_{\min}) / l, \\ N_z = (z_{\max} - z_{\min}) / l \end{cases} \quad (1)$$




图2 未处理的两帧图像对比
Fig.2 Comparison of two unprocessed images

式中, x_{\max} 、 y_{\max} 、 z_{\max} 分别为 x 、 y 和 z 方向的最大值, x_{\min} 、 y_{\min} 、 z_{\min} 分别为 x 、 y 和 z 方向的坐标值最小值, N_x 、 N_y 、 N_z 分别为 x 、 y 和 z 方向的网格数。

(2) 计算体素索引。建立空间体素网格后, 点 $p_i = (x_i, y_i, z_i)$ 的体素索引计算公式为:

$$\begin{cases} i_x = (x_i - x_{\min}) / l \\ i_y = (y_i - y_{\min}) / l \\ i_z = (z_i - z_{\min}) / l \end{cases} \quad (2)$$

$$i = i_x + i_y \times N_x + i_z \times N_x \times N_y, \quad (3)$$

式中: i_x 、 i_y 、 i_z 分别为 x 、 y 、 z 方向的体素索引值; i 为转换的一维编码值, 可通过编码检索点云内任意点所在的体素网格。

(3) 计算质心。由体素索引号确定网格中包含的点数, 并计算网格重心, 利用距离重心最近的点代替网格的质心, 公式为:

$$G_i = \frac{1}{k} \sum_{i=1}^k p_i, \quad (4)$$

式中, G_i 为网格编码 i 的重心, k 为网格中的点数。

(4) 用每个体素网格的质心代替网格中包含的所有点, 以减少点云集中的点数, 完成体素滤波下采样。

2 理论方法

首先, 采用 ISS-FPFH 算法对源点云和目标点云提取特征点, 计算以及描述点云特征值。其次, 采用改进的 RANSAC、点到面的 ICP 算法进行点云粗配准与精配准, 并利用 KD-tree 加快点云搜索速度, 实现点云配准。

2.1 点云特征提取与描述

2.1.1 特征点提取

在无人小车移动过程中, 激光雷达会采集不同帧的点云数, 经过预处理后的点云数据量依然较大, 直接配准会影响运算的精度和效率, 此时需要提取 3D 点云的特征点, ISS 算法是通过计算各个点领域的协方差矩阵的特征值, 并通过特征值之间的线性关系选取特征点。主要计算过程如下。

(1) 针对点云集 P 中的每个点 p_q , 建立局部坐标系, 并设定搜索半径。在半径内查找周围的所有点, 并计算每个点的权重, 公式为:

$$\omega_i = \frac{1}{\|p_i - p_q\|}, \quad (5)$$

式中: ω_i 为点 p_q 与其局部邻域中的点数成反比的权重; r 为搜索半径; p_i 为邻域内的点, 采样区域中的点越稀疏, 所占权重越高。

(2) 计算每个点的三维加权协方差矩阵, 公式为:

$$\text{cov}(p_q) = \frac{\sum_{|p_i - p_q| < r} \omega_i (p_i - p_q) (p_i - p_q)^T}{\sum_{|p_i - p_q| < r} \omega_i} \quad (6)$$

(3) 根据协方差矩阵求解各个点的特征值 $\{\lambda_1^1, \lambda_1^2, \lambda_1^3\}$, 并按照由大到小的顺序排列, 这 3 个特征值之间的关系反映了数据点的主要特征及其相对重要性。如果某个点恰好处于角点, 则点云较为稀疏, 3 个方向主特征值相差较小。角点往往代表点云表面上起伏剧烈的区域, 比平坦区域中的点包含更多的独特形状信息。

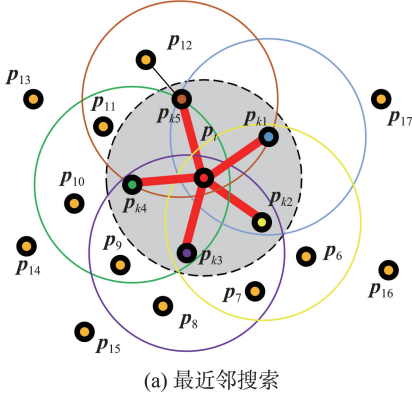
(4) 设定两个阈值 ε_1 和 ε_2 , 若查询点 p_q 作为 ISS 特征点, 需满足

$$\begin{cases} \lambda_i^2/\lambda_i^1 < \varepsilon_1 \\ \lambda_i^3/\lambda_i^2 < \varepsilon_2 \end{cases} \quad (7)$$

2.1.2 特征描述

利用 FPFH 方法,从不同帧点云表面蕴含的特征信息中提取关键点,通过处理这些特征信息可以形成特有的标签,有助于区分与识别。它的思想在于采用点特征描述法分别计算查询点的 k 邻域中每个点的简化点特征直方图(simplified point feature histogram, SPFH),再将所有的 SPFH 加权成最后的快速点特征直方图^[30]。FPFH 计算流程如下:

(1)对点云集中的每个点 p_i 求得表面法线 n_i ,确定一个邻域半径 r 并搜索临近点 p_{ij} ,以各点为原点计算每个点的局部坐标值,公式为:



$$\begin{cases} U = n_i \\ V = \frac{(p_i - p_{ij})}{\| (p_i - p_{ij}) \|^2} \times U, \\ W = U \times V \end{cases} \quad (8)$$

式中, (U, V, W) 表示各点的局部坐标。

(2)计算点云集中每点的 SPFH 特征,即 p_i 与临近点 p_{ij} 的角度关系 $(\alpha, \varphi, \theta)$, 公式为:

$$\begin{cases} \alpha = V \cdot n_i \\ \varphi = U \cdot \frac{(p_i - p_{ij})}{\| (p_i - p_{ij}) \|} \\ \theta = \arctan(W \cdot n_i, U \cdot n_i) \end{cases} \quad (9)$$

式中: α, φ, θ 是某点的 FPFH 特征三要素,其原理及转换的示意图如图 3 所示。




图 3 FPFH 原理及坐标转换示意图

Fig.3 FPFH principle and coordinate transformation diagram

(3)对邻域中的各个 SPFH 进行加权统计,计算该点的 FPFH 特征描述子,公式为:

$$F(p_i) = S(p_i) + \frac{1}{k} \sum_{j=1}^k \left(\frac{1}{w_j} \cdot S(p_{ij}) \right), \quad (10)$$

式中, $F(p_i)$ 为点 p_i 的 FPFH 值, $S(p_i)$ 为点 p_i 的 SPFH 值, w_j 为点 p_i 到临近点 p_{ij} 之间的欧氏距离, k 为临近点数量。

2.2 点云配准

2.2.1 基于 RANSAC 的粗配准

采用 RANSAC 算法进行点云配准,算法的本质是不断地对源点云进行随机样本采样并求出对应的变换模型,接着对每一次随机变换模型进行测试,并不断循环该过程直到选出最优的变换模型作为最终结果。

为提高算法的鲁棒性和运行效率,本研究将对对应点的个数增加到 4 个,且保证 4 个点之间非共线,采用 KD-Tree 方法搜索最近邻点,其基本流程如下:

(1)在对应点集中随机选取 4 个对应点对,并通过最小二乘法求解刚体变换矩阵 H 。假设源点云

P 中选取数据点为 $\{p_1, p_2, p_3, p_4\}$, 目标点云 Q 中选取数据点为 $\{q_1, q_2, q_3, q_4\}$, 刚体旋转平移变换矩阵后的点云集

$$P' = R_c P + t_c, \quad (11)$$

式中, $i=1, 2, 3, 4$, R_c 为旋转矩阵, t_c 为平移向量。

(2)计算源点云 P 在该刚体变换矩阵下的新点云集 P' 与目标点云 Q 对应点的距离投影误差。若点对的距离误差小于设定的阈值误差,则该点加入样本内点集合 I ,并计算匹配得分 S_i ,得分 S_i 为内点与点云总数之比,即:

$$d_{\perp} = d^2(p'_i, H p_i), \quad (12)$$

式中, H 为对应点的空间变换矩阵, d 为对应点间的距离, d_{\perp} 为距离误差阈值。

(3)设定循环次数 N 以及匹配得分阈值 S_{\min} ,若点云的匹配得分小于 S_{\min} ,跳出循环,否则重复以上步骤直至迭代次数达到 N 。统计不同刚体变换模型下的样本内点数量,内点数量最多的作为最佳数学模型,对应的刚体变换矩阵用于点云粗配准操作,记粗配准后的源点云集为 P_b 。

2.2.2 基于点到面的ICP精配准

经过粗配准之后,2个点云图像的重叠部分已大致对齐,精配准算法是在粗配准的基础上再进一步配准,提升配准精度。

ICP算法的本质内容是最小二乘法的数学思想,传统的ICP以对应点间的最小距离为目标函数,本研究结合了表面法线信息,采用点到面的ICP算法进行精配准,以提高算法的运算性能。

基于粗配准后的源点云中每个点的表面法线,最小化目标点云Q在源点云P_b表面法线上的投影,求解变换矩阵,并通过不断迭代的方式使点云之间的误差损失值达到最小。主要步骤如下。

(1)寻找匹配最近点时,利用KD-tree方法加快搜索速度,找出源点云P_b中每一个点在目标点云Q中的最近邻点作为对应点。




图4 ICP算法原理图
Fig.4 Illustration of ICP algorithm

最优变换通常借助SVD计算,首先定义源点云与目标点云的质心,并将2组数据去中心化,源点云、目标点云的计算公式分别为:

$$p_{bc} = \frac{1}{n} \sum_{i=1}^n p_{bi}, \hat{p}_{bi} = p_{bi} - p_{bc}, \quad (14)$$

$$q_c = \frac{1}{n} \sum_{i=1}^n q_i, \hat{q}_i = q_i - q_c, \quad (15)$$

式中,p_{bc}、q_c为源点云p_b和目标点云q的质心,ŷ_{bi}和q̂_i为去中心化后的源点云和目标点云。

定义变换矩阵G,G=ŷ_i×p̂_{bi},将G进行SVD分解,最终求得此时的旋转矩阵和平移向量:

$$\begin{cases} R_f = AB^T \\ t_f = p_{bc} - R_f q_c \end{cases}, \quad (16)$$

表2 不同阈值下体素滤波数据分析

Table 2 Analysis of voxel filtering data under different thresholds

体素栅格/m	源点云		目标点云		运算时间/s
	总数	降采样后的点云数	总数	降采样后的点云数	
(0.07, 0.07, 0.07)	59 968	30 485	60 000	30 665	0.905
(0.10, 0.10, 0.10)	59 968	26 721	60 000	26 868	0.823
(0.15, 0.15, 0.15)	59 968	22 528	60 000	22 713	0.783
(0.20, 0.20, 0.20)	59 968	19 521	60 000	19 610	0.729
(0.30, 0.30, 0.30)	59 968	15 301	60 000	15 438	0.651
(0.50, 0.50, 0.50)	59 968	10 541	60 000	10 583	0.563

(2)计算最优变换,粗配准后的源点云为{p_{b1}, p_{b2}, ..., p_{bn}},目标点云为{q₁, q₂, ..., q_n},需要计算使得两帧对应点云配准的最优旋转和平移参数,目标优化函数为:

$$F(R_f, t_f) = \arg \min_G \left\{ \sum_i \|\eta_i \cdot (F_i(R_f, t_f) p_{bi} - q_i)\|^2 \right\}, \quad (13)$$

式中,F(R_f,t_f)为最小化变换后对应点到面之间的最佳刚体变换,η_i为q_i到p_i的表面法线上的投影,F_i(R_f,t_f)为第i次迭代中由旋转和平移组成的刚性变换,G为所有对应点到面刚性变换组成的集合,R_f,t_f分别为旋转矩阵和平移向量。

传统的ICP算法以及点到面的ICP算法原理如图4所示。

式中,A和B是经过SVD分解后的正交矩阵。

(3)重复上述步骤,设定最大迭代次数N_{max}和最小阈值ε,其中ε=F_k(R_f,t_f)-F_{k-1}(R_f,t_f),如果两次迭代的误差小于阈值ε或者当前迭代次数大于N_{max},则迭代结束,否则继续迭代,直至满足收敛条件。

3 试验效果分析

3.1 特征点分析

首先进行点云预处理,以相隔200帧的两点云试验数据为例,在不同体素栅格下的点云预处理数据如表2所示。

当网格间隔 l 设置得越大,点云越稀疏,运行时间越短。在栅格边长的阈值小于 0.07 m 时,由于栅格太小,整数指标会溢出,无法进行降采样;栅格阈值过大时,点云数量过少,点云配准效果降低。

在不同的栅格下,比较 ISS 算法下的源点云与目标点云特征点提取数量,再通过特征描述 FPFH 匹配对应点,搜索半径设置为 5 倍的体素栅格值,计算的特征及匹配点个数如表 3 所示,不同栅格下的特征提取点分布如图 5 所示。

表 3 不同阈值下的特征点提取

Table 3 Feature point extraction under different thresholds

体素栅格/m	特征点数		匹配点数	计算时间/s
	源点云	目标点云		
(0.07, 0.07, 0.07)	2 117	2 280	736	7.520
(0.10, 0.10, 0.10)	2 284	2 377	753	7.690
(0.15, 0.15, 0.15)	1 785	1 817	558	8.155
(0.20, 0.20, 0.20)	1 298	1 309	363	7.858
(0.30, 0.30, 0.30)	733	731	192	7.595
(0.50, 0.50, 0.50)	364	335	88	6.899

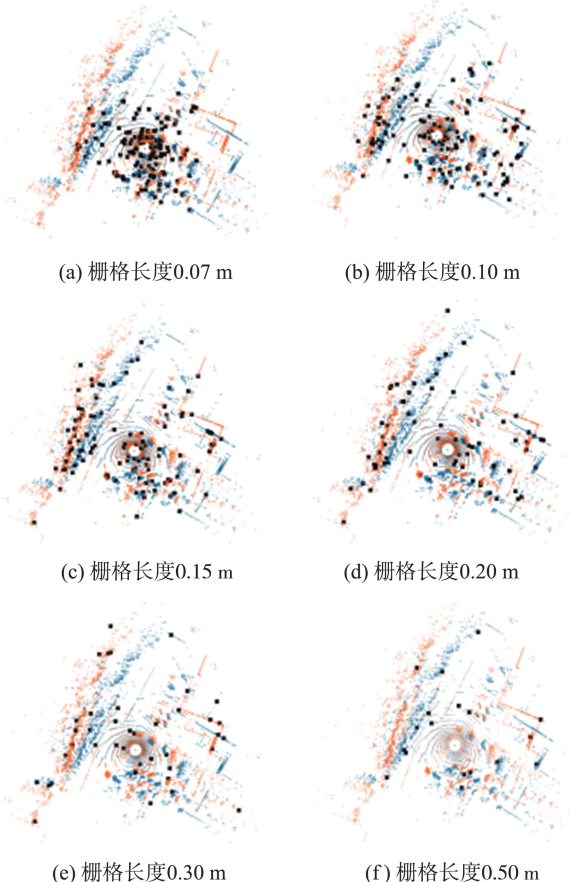


图 5 不同降采样下的特征匹配点分布

Fig.5 Distribution of feature points under different downsampling

图 5 中黑色的点代表特征匹配点,随着体素栅格值的增大,总体上特征点数量减小,但运算时间

呈现先增大后减小的趋势。当体素栅格增大时,会涉及到更多的稀疏区域和更大的搜索空间,导致运算时间增加。当体素栅格继续增大,特征点数量减少,从而减少匹配的计算量。因此,选择合适的体素栅格大小是权衡特征点数量和匹配效率的关键问题。当体素栅格边长在 0.1~0.2 m 时,匹配点较为分散,以 0.01 m 为间隔,计算其匹配点数量及匹配时间,如表 4 所示。

表 4 不同栅格下的精细化对比

Table 4 Refined comparison under different grids

体素栅格/m	匹配点数/个	计算时间/s
0.10	753	7.690
0.11	671	8.006
0.12	703	8.187
0.13	609	8.162
0.14	620	8.186
0.15	558	8.155
0.16	517	8.148
0.17	460	8.003
0.18	428	8.312
0.19	417	7.910
0.20	363	7.858

由表 4 可知,随着体素栅格边长的增加,点云匹配点数整体呈减少态势,但由于计算机的内存占用、并行化处理、算法复杂度等问题,会导致运算时间和匹配点数有一定波动,如表 4 中体素栅格为 0.18 m 时出现的时间激增现象。综合 2 个指标的数据变化,在体素栅格边长为 0.1 m,搜索半径为 0.5 m 的条件下,点云匹配点个数最大,运算时间最短,以该最优条件进行点云提取和配准。为了展示不同特征点几何表面的 FPFH 特征存在的差异性,在源点云及目标点云上提取两组点对,其中 x 轴表示 33 个分布区间, y 轴表示落在某区间的比率。

不同匹配点的 FPFH 特征柱状图如图 6 所示,由图 6(a) 可知,在人行道旁的树木部分,邻域内点的法线方向相对一致,故直方图集中在几个特定的子区间内;由图 6(b) 可知,在建筑物拐角等特征明显部位,邻域点的法线朝向散乱,直方图统计数据较为分散。

3.2 点云配准效果对比

为验证本研究粗配准算法在具体点云模型上配准的性能,将算法与采样一致性初始配准算法 (sample consensus initial alignment, SAC-IA)^[31]、4PCS 算法^[19] 比较,分别选取间隔 50 帧、100 帧、150 帧的点云图像,在特征提取的基础上配准,试验结果如图 7 所示。

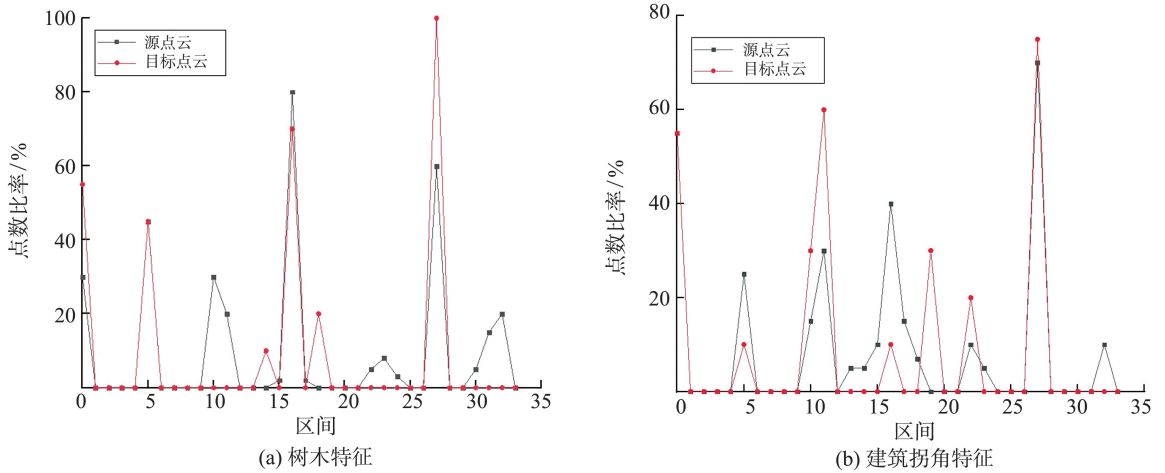


图6 不同匹配点的 FPFH 特征柱状图
Fig.6 FPFH characteristic histogram of different matching points

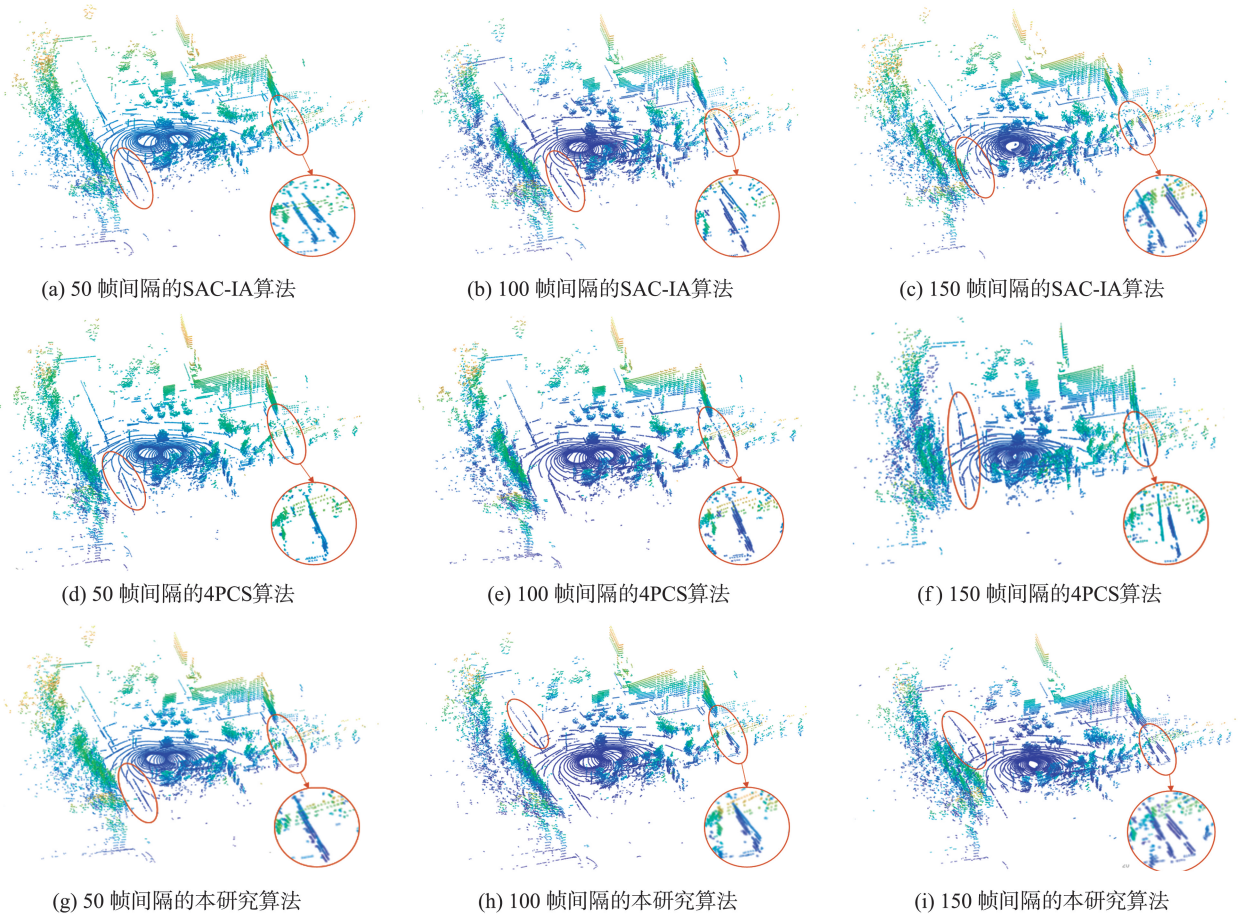


图7 点云粗配准对比试验结果

Fig.7 Point cloud coarse registration comparison experiment results

由图7可知,在 SAC-IA 匹配算法中,粗配准在不同时间间隔下的匹配效果均一般,在 4PCS 算法以及本研究的粗配准算法中,虽然由于时间间隔不同会出现配准精度下降的情况,但仍具有良好的初始位姿。

为定量分析配准精度误差,引入均方根误差 (root mean square error, RMSE) 试验分析,均方根

误差数值以 E_{RMSE} 表示,它是指对应点之间距离平方和的均值的平方根,计算公式为:

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_{bi} - q_i)^2}, \quad (17)$$

式中, n 为对应点的数量。误差值越小,两个点云集的重合度越高,配准效果越好。各初始配准算法的配准时间和配准误差如表5所示。

表5 初始配准效果对比

Table 5 Comparison of coarse registration effects

粗配准算法	点云间隔/帧	配准时间/s	配准误差/cm
SAC-IA	50	558.839	11.459
	100	561.491	12.037
	150	530.620	20.726
4PCS	50	418.818	6.119
	100	184.432	5.695
	150	504.247	13.558
本研究算法	50	121.556	9.011
	100	120.494	9.850
	150	113.929	10.417

由表5可知,SAC-IA算法普遍运行时间长,4PCS算法在同样的试验条件以及参数下运行时间不稳定,而本研究的RANSAC算法在配准时间以及

鲁棒性上较SAC-IA算法和4PCS算法均有大幅度提升,其中配准时间分别提升78.44%和61.02%。在配准精度方面,100帧以内的间隔下4PCS算法和RANSAC算法的配准误差均在10 cm以内,可以提供较好的初始位姿,但时间间隔超过100帧后,4PCS算法出现配准精度大幅度下降的现象。综合配准时间及配准精度,本研究的粗配准算法具有良好的配准效率、稳定性以及更强的适用性。

对于点云精细配准,在本研究粗配准算法的初始位姿基础上,对比本研究算法、传统的ICP算法、正态分布变换(normal distributions transform, NDT)算法^[32]3种常用方法,不同时间间隔下的点云配准效果如图8所示。

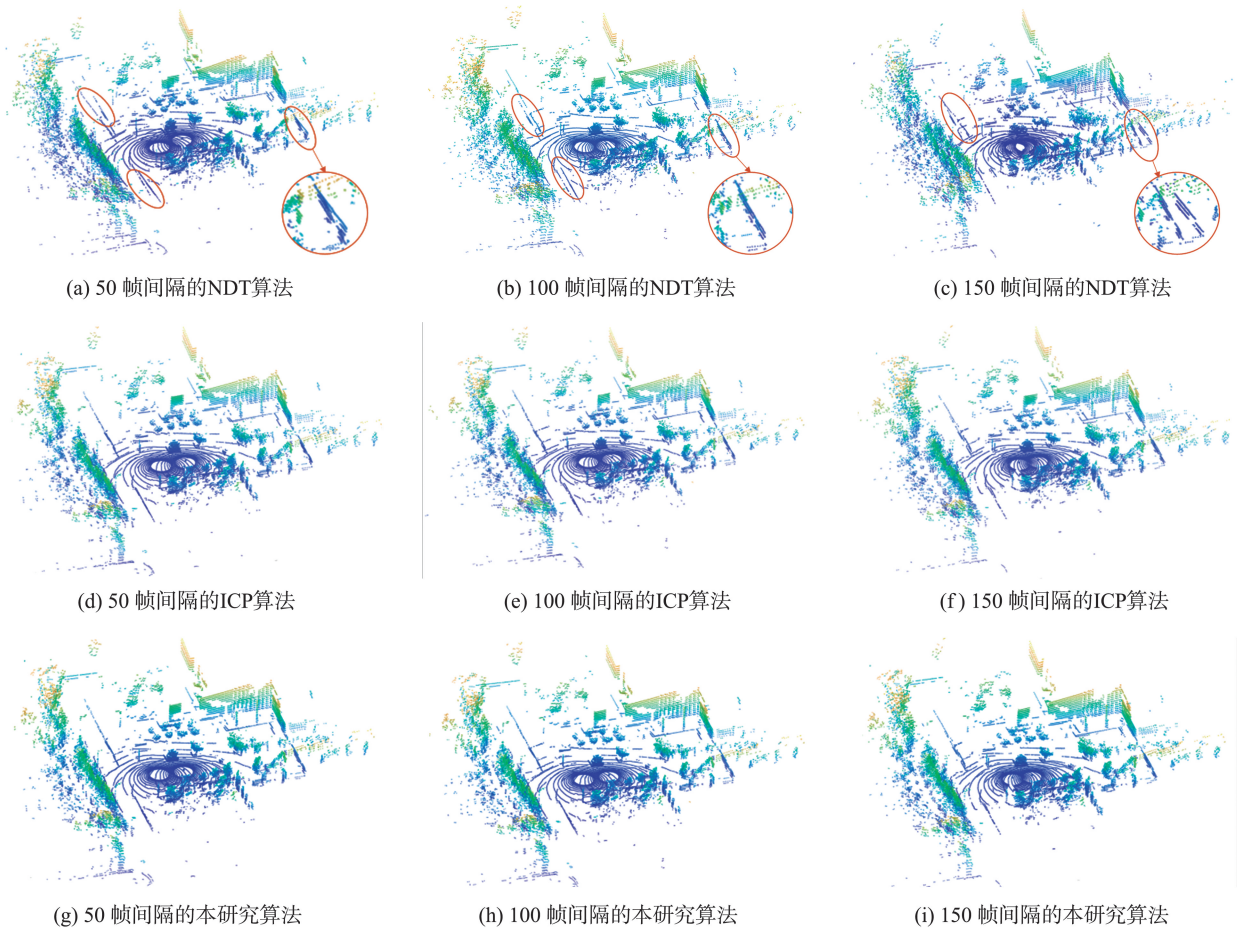


图8 点云精配准对比试验结果

Fig.8 Point cloud precision registration comparison experiment results

由图8(a)~8(c)可知,NDT算法在配准后仍然出现部分区域未配准现象,配准效果不显著,而ICP算法和点到面的ICP算法均能实现精确配准,精配准效果较好。3种精配准算法的配准时间和配准均方根误差如表6所示。

在配准时间方面,NDT精配准所需时间最短,本研究使用的点到面的ICP算法次之,传统的ICP算法耗时最长。虽然NDT算法整体时间低于1 s,

较另2种大幅度降低,但配准效果较粗配准效果仅提升1.64%,精配准效果差。在配准精度方面,ICP算法与本研究算法配准误差较粗配准平均分别降低4.58 cm和5.11 cm,本研究算法较NDT、传统的ICP算法精度分别提升51.5%和10.2%,均方根误差分别降低4.94 cm和0.53 cm;在配准时间方面,本研究的ICP算法比传统ICP算法速度平均提高33.06%。从总体匹配过程来看,本研究的精配准性

能优于其余 2 种算法。

表 6 精配准效果对比

Table 6 Comparison of precision registration effects

精配准算法	点云间隔/帧	配准时间/s	配准误差/cm
NDT	50	0.625	8.683
	100	0.594	10.453
	150	0.641	9.648
ICP	50	20.918	4.624
	100	9.909	4.856
	150	24.317	6.066
本研究算法	50	10.941	4.447
	100	6.760	4.511
	150	19.527	5.002

4 结论

本研究提出一种基于关键点提取的三维点云配准方法,在完成降采样的基础上,利用 ISS 关键点提取及 FPFH 特征描述,确定两帧点云的对应关系。再结合改进的 RANSAC 算法以及点到面的 ICP 算法完成点云配准。经数据采集及试验对比,在粗配准方面,配准速度较 SAC-IA、4PCS 算法平均提升 78.44%和 61.02%,配准精度上,100 帧以内的数据 4PCS 算法更精准,超过 100 帧本研究算法更为稳定;在精配准方面,配准精度较粗配准、NDT 算法、ICP 算法分别提升 5.11、4.94 和 0.53 cm,配准时间较 ICP 算法提升 33.06%。但是,本研究的算法在鲁棒性和效率上仍需进一步提升,下一步将尝试在本研究框架下结合深度学习,并采集不同场景的数据集测试,探究算法在不同噪声和离群值下的配准效率与稳定性。

参考文献:

[1] 康俊民,赵祥模,徐志刚. 无人车行驶环境特征分类方法[J]. 交通运输工程学报, 2016, 16(6): 140-148.
KANG Junmin, ZHAO Xiangmo, XU Zhigang. Classification method of running environment features for unmanned vehicle[J]. Journal of Traffic and Transportation Engineering, 2016, 16(6): 140-148.

[2] 王润民,朱宇,赵祥模,等. 自动驾驶测试场景研究进展[J]. 交通运输工程学报, 2021, 21(2): 21-37.
WANG Runmin, ZHU Yu, ZHAO Xiangmo, et al. Research progress on test scenario of autonomous driving [J]. Journal of Traffic and Transportation Engineering, 2021, 21(2): 21-37.

[3] TREJOS Kevin, RINCÓN Laura, BOLANOS Miguel, et al. 2D SLAM algorithms characterization, calibration, and comparison considering cose rror, map accuracy as

well as CPU and memory usage[J]. Sensors, 2022, 22(18): 6903-6940.

[4] 吴建清,宋修广. 同步定位与建图技术发展综述[J]. 山东大学学报(工学版), 2021, 51(5): 16-31.
WU Jianqing, SONG Xiuguang. Review on development of simultaneous localization and mapping technology[J]. Journal of Shandong University (Engineering Science), 2021, 51(5): 16-31.

[5] 高扬,曹王欣,夏洪垚,等. 低可见度环境下基于同步定位与构图的无人驾驶汽车定位算法[J]. 交通运输工程学报, 2022, 22(3): 251-262.
GAO Yang, CAO Wangxin, XIA Hongyao, et al. Driverless vehicle positioning algorithm based on simultaneous positioning and mapping in low-visibility environment[J]. Journal of Traffic and Transportation Engineering, 2022, 22(3): 251-262.

[6] WU Jianqing, XU Hao, SUN Renjuan, et al. Road boundary-enhanced automatic background filtering for roadside LiDAR sensors[J]. IEEE Intelligent Transportation Systems Magazine, 2021, 14(4): 60-72.

[7] 杨佳琪,张世坤,范世超,等. 多视图点云配准算法综述[J]. 华中科技大学学报(自然科学版), 2022, 50(11): 16-34.
YANG Jiaqi, ZHANG Shikun, FAN Shichao, et al. Survey on multi-view point cloud registration algorithm [J]. Journal of Huazhong University of Science and Technology(Natural Science Edition), 2022, 50(11): 16-34.

[8] MARTÍN Bueno, HENSE González-Jorge, JOAQUÍN Martínez-Sánchez, et al. Automatic point cloud coarse registration using geometric keypoint descriptors for indoor scenes [J]. Automation in Construction, 2017, 81: 134-148.

[9] 刘江,张旭,朱继文. 一种基于 K-D 树优化的 ICP 三维点云配准方法[J]. 测绘工程, 2016, 25(6): 15-18.
LIU Jiang, ZHANG Xu, ZHU Jiwen. ICP three-dimensional point cloud registration based on K-D tree optimization[J]. Engineering of Surveying and Mapping, 2016, 25(6): 15-18.

[10] 康俊民,赵祥模,杨荻. 二维激光雷达数据角点特征的提取 [J]. 交通运输工程学报, 2018, 18(3): 228-238.
KANG Junmin, ZHAO Xiangmo, YANG Di. Corner feature extraction of 2D lidar data[J]. Journal of Traffic and Transportation Engineering, 2018, 18(3): 228-238.

[11] 蓝秦隆. 基于改进 GA-SA 的点云配准算法研究[D]. 武汉:武汉大学, 2021.
LAN Qinlong. Research on point cloud registration algorithm based on improved GA-SA [D]. Wuhan: Wuhan University, 2021.

- [12] ZHANG Ji, SINGH Sanjiv. Low-drift andreal-time Lidar odometry and mapping[J]. *Autonomous Robots*, 2017, 41(2): 401-416.
- [13] 伍梦琦, 李中伟, 钟凯, 等. 基于几何特征和图像特征的点云自适应拼接方法[J]. *光学学报*, 2015, 35(2): 237-244.
WU Mengqi, LI Zhongwei, ZHONG Kai, et al. Adaptive point cloud registration method based on geometric features and photometric features [J]. *Acta Optica Sinica*, 2015, 35(2): 237-244.
- [14] ZHANG Jing, YU Keping, WEN Zheng, et al. 3D reconstruction for motion blurred images using deep learning-based intelligent systems [J]. *CMC-computers Materials & Continua*, 2021, 66(2): 2087-2104.
- [15] DERPANIS Konstantinos. Overview of the RANSAC algorithm[J]. *Image Rochester NY*, 2010, 4(1): 2-3.
- [16] 王鹏, 朱睿哲, 孙长库. 基于改进的RANSAC的场景分类点云粗配准算法[J]. *激光与光电子学进展*, 2020, 57(4): 312-320.
WANG Peng, ZHU Ruizhe, SUN Changku. Point cloud coarse registration algorithm with scene classification based on improved RANSAC[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 312-320.
- [17] WU Qinghua, LIU Jiacheng, GAO Can, et al. Improved RANSAC point cloud spherical target detection and parameter estimation method based on principal curvature constraint[J]. *Sensors*, 2022, 22(15): 5850.
- [18] 梁涛, 韩峰, 陈国栋. 基于连续点云数据的既有铁路轨面信息快速提取算法设计[J]. *铁道科学与工程学报*, 2021, 18(10): 2544-2551.
LIANG Tao, HAN Feng, CHEN Guodong. Algorithm design for fast extraction of rail-surface information for existing railway based on continuous point cloud data [J]. *Journal of Railway Science and Engineering*, 2021, 18(10): 2544-2551.
- [19] MOHAMAD Mustafa, AHMED Mirza Tahir, RAPPAPORT David, et al. Super generalized 4pcs for 3d registration [C]//2015 International Conference on 3D Vision. Lyon, France: IEEE, 2015: 598-606.
- [20] 石雪飞, 徐粹齐, 朱荣, 等. 基于三维模型重构技术的公路预制构件尺寸检验评价方法[J]. *交通运输工程学报*, 2021, 21(2): 66-81.
SHI Xuefei, XU Ziqi, ZHU Rong, et al. Dimensional inspection and evaluation method of highway prefabricated components based on3D model reconstruction technology [J]. *Journal of Traffic and Transportation Engineering*, 2021, 21(2): 66-81.
- [21] 周勇, 吕琛, 侯福金, 等. 基于坐标转换的多路侧激光雷达数据配准方法[J]. *山东大学学报(工学版)*, 2022, 52(6): 41-49.
ZHOU Yong, LÜ Chen, HOU Fujin, et al. Datafusion method of multi roadside LiDAR based on coordinate transformation [J]. *Journal of Shandong University (Engineering Science)*, 2022, 52(6): 41-49.
- [22] 李慧慧, 刘超, 陶远. 一种改进的ICP激光点云精确配准方法[J]. *激光杂志*, 2021, 42(1): 84-87.
LI Huihui, LIU Chao, TAO Yuan. A laser point cloud precise registration method with improved ICP[J]. *Laser Journal*, 2021, 42(1): 84-87.
- [23] ZHANG Juyong, YAO Yuxin, DENG Bailin. Fast and robust iterative closest point[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3450-3466.
- [24] GUAN Wei, LI Wentao, REN Yan. Point cloud registration based on improved ICP algorithm [C]//2018 Chinese Control and Decision Conference (CCDC). Shenyang, China: IEEE, 2018: 1461-1465.
- [25] CHEN Yang, MEDIONI Gérard. Object modelling by registration of multiple range images [J]. *Image and Vision Computing*, 1992, 10(3): 145-155.
- [26] SEGALV Aleksandr, HAEHNEL Dirk, THRUN Sebastian. Generalized-icp [J]. *Robotics: Science and Systems*, 2009, 2(4): 435-443.
- [27] DU Shaoyi, LIU Juan, ZHANG Chunjia, et al. Probability iterative closest point algorithm for mD point set registration with noise[J]. *Neurocomputing*, 2015, 157: 187-198.
- [28] WU Jianqing, LÜ Chen, YUE Hongya. Grid-based lane identification with roadside LiDAR data[J]. *International Journal of Sensor Networks*, 2022, 38(2): 85-96.
- [29] WU Jianqing, TIAN Yuan, XU Hao, et al. Automatic ground points filtering of roadside LiDAR data using a channel-based filtering algorithm [J]. *Optics & Laser Technology*, 2019, 115: 374-383.
- [30] RUSU Radu Bogdan, BLODOW Nico, BEETZ Michael. Fast point feature histograms (FPFH) for 3D registration [C] //2009 IEEE International Conference on Robotics and Automation. Kobe, Japan: IEEE, 2009: 3212-3217.
- [31] 张晗, 康国华, 张琪, 等. 基于改进 SAC-IA 算法的激光点云粗配准[J]. *航天控制*, 2019, 37(5): 67-74.
ZHANG Han, KANG Guohua, ZHANG Qi, et al. Laser point cloud coarse registration based on improved SAC-IA algorithm [J]. *Aerospace Control*, 2019, 37(5): 67-74.
- [32] LI Lin, YANG Fan, ZHU Haihong, et al. An improved RANSAC for 3D point cloud plane segmentation based on normal distribution transformation cells[J]. *Remote Sensing*, 2017, 9(5): 433-449.