

DOI: 10.19650/j.cnki.cjsi.J2311656

基于点云稀疏语义特征的智能网联 汽车协同感知配准算法*

朱 浩,倪锐峰

(重庆邮电大学自动化学院 重庆 400065)

摘 要:针对道路场景下多智能网联汽车协同感知问题,本文提出一种基于点云稀疏语义特征的智能网联汽车协同感知配准算法。所提算法旨在通过点云集成配准扩展智能网联汽车感知范围,进而实现智能网联汽车协同感知。首先,在道路语义特征基础上进行几何特征提取进而得到点云稀疏语义特征。其次,计算道路语义特征点云间的角度偏差以提供配准初值,并将点云语义信息作为配准约束条件实现全局语义集成配准。实验表明所提算法有效扩大了多智能网联汽车协同感知范围,提高了多点云集成配准的精度与鲁棒性。与当前主流算法 JRMPC 相比,本文所提算法配准精度提高了 2.45%。

关键词: 智能网联汽车协同感知;点云集成配准;点云稀疏语义特征;语义约束

中图分类号: TP391.4 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.40

A cooperative perception registration algorithm for intelligent and connected vehicles based on sparse semantic features

Zhu Hao, Ni Ruifeng

(College of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: To address the problem of cooperative perception for multiple intelligent and connected vehicles (ICVs) in road scenarios, this article proposes a cooperative perception registration algorithm for ICVs, which is based on sparse semantic features. The proposed algorithm aims to extend the perception range of ICVs by point cloud ensemble registration. Therefore, the cooperative perception for ICVs is achieved. Firstly, the sparse semantic features are obtained by geometric feature extraction based on road semantic features. Secondly, the angle deviation among the road semantic features is calculated to provide the initial registration value. The point cloud semantic information is used as the registration constraint condition to realize the global semantic ensemble registration. The experiments show that the proposed algorithm effectively expands the cooperative sensing range of multi-ICVs. The accuracy and robustness of multi-point cloud ensemble registration are enhanced. Compared with the current mainstream algorithm JRMPC, the registration accuracy of the proposed algorithm is improved by 2.45%.

Keywords: cooperative perception for intelligent and connected vehicles; point set ensemble registration; point cloud sparse semantic features; semantic constraints

0 引 言

智能网联汽车利用各种车载传感器进行环境感知,并使用通信技术交换感知信息的过程称为协同感知^[1-2]。基于激光雷达的协同感知是通过多个激光雷达传感器实

现对周围环境的感知和理解的技术。该技术包括数据采集、数据预处理、点云配准与融合、地图构建、目标检测与跟踪以及信息融合与决策等步骤。将多个激光雷达的数据进行配准与融合,生成全局参考坐标系下的点云地图。通过 3D 目标检测可以识别出点云地图中的目标并进行跟踪和预测。最后,通过数据的融合与决策,为自动驾驶

收稿日期:2023-07-12 Received Date: 2023-07-12

* 基金项目: 国家自然科学基金(62073052)、重庆市自然科学基金(cstc2021jcyj-msxmX0373)、重庆市教委科学研究重点项目(KJZD-K202200603)资助

系统提供协同感知技术支持。基于激光雷达的协同感知能够提供丰富的环境信息和高精度的空间感知,提高智能车驾驶安全性。Chen 等^[3]提出一种利用点云特征进行处理的智能网联汽车协同感知框架(F-Cooper),通过该框架来获得更高的协同感知精度。Hurl 等^[4]针对协同感知中的 3D 目标检测提出一种信任机制以防止其受到协同感知系统中其他因素的干扰。

智能网联汽车在协同感知过程中由于车辆位姿的差异,车载激光雷达采集到的点云角度不同、相互独立且部分重叠。与此同时,车载激光雷达对道路环境进行点云数据采集时,由于采集范围的限制,存在投影盲点或视野盲区,常需要多次分区地进行^[5]。因此,在真实道路场景下准确、快速地实现多点云的鲁棒集成配准是一个重要的问题。本文提出基于点云稀疏语义特征的智能网联汽车协同感知配准算法以解决协同感知中多点云集成配准问题。现有集成配准算法配准过程中存在误差积累、配准效率低等问题,从而影响其配准性能^[6]。本文所提算法主要解决集成配准算法受噪声干扰导致鲁棒性能差、配准算法受点云位移影响导致协同感知范围小、算法处理大规模点云数据方面实时性差等问题。

点集配准算法根据建模方法的不同可分为基于距离表征的、基于概率模型的和基于特征的特征点云配准算法^[7]。基于距离表征的方法通过寻找最近点或以其他标准来确定对应点,模型为对应点之间的距离残差。其中代表性的算法为迭代最近点(iterative closest point, ICP)^[8],该算法利用最近距离作为寻找点集之间对应关系的准则,并计算其最小二乘变换以更新对应关系,但该算法易陷于局部最优,对配准初值要求较高。因此一些基于 ICP 的改进方法被提出^[9],这些算法增强了点集间的对应关系,使其适应高维点集。Tsin 等^[10]重新设计了点集间的对应关系,通过最小化点集间的核相关函数以实现配准。Campbell 等^[11]提出一种支持向量配准算法,其输出函数近似于混合高斯模型,该算法通过最小化两个混合高斯模型的欧氏距离来实现点集配准。Bergevin 等^[12]提出一种多视图点云集成配准算法,该算法首先构建一个网络,将一个点云放置于网络中心并与其他点云以边连接,进而组合刚性变换来完成多点云的集成配准。Zhu 等^[13]提出一种由粗到细的点云集成配准算法,该算法将点集分为数据集与模型集来处理,但该方法对配准初值较为敏感。

基于概率的方法通常是将点集放入概率模型中,通过构造对数似然函数求解模型参数。具有代表性的算法是相干点漂移(coherent point drift, CPD)^[14],它将点集放入混合高斯模型中,并加入一个额外的均匀分布来表示噪声,从而建立负对数似然函数。朱等^[15]将其应用于目标跟踪,提出基于一致性点漂移的智能车视觉目标跟踪方法。Mateo 等^[16]提出一种基于贝叶斯框架的点云集

成配准方法,该方法考虑了点云间存在的错误对应关系,但是因潜在变量计算导致时间复杂度较高。余仁伟等^[17]引入卡尔曼滤波方程来计算空间变换参数,实现了相机运动下轨迹状态的最优估计。Evangelidis 等^[18]提出一种点云集成配准算法(joint registration of multiple point clouds, JRMPC),该方法将全部点集均等对待以建立统一模型,以混合高斯模型模拟点集并将点云集成配准问题转化为聚类问题;Min 等^[19]对该方法进行了拓展,通过引入点云位置与方向信息来对点云进行升维并配准。正态分布变换(normal distributions transform, NDT)^[20]方法利用概率密度函数对点云进行建模和匹配,其适用于大规模点云配准,并且对于噪声和局部形变具有一定的鲁棒性。

基于特征的方法通过特征提取方法从点云中提取出具有辨识度和稳定性的特征并对其进行匹配以估计刚体变换,提高了配准的准确性和鲁棒性。Wohlking 等^[21]提出了一种结合角度、点距和面积的形状描述符来提高准确率。Wang 等^[22]提出了一种集成激光雷达点云几何特征与强度特征的全局描述符,并将该特征应用于同步定位与建图中的回环检测中,有效提高了定位的鲁棒性。扫描上下文^[23-24]将点云转换为极坐标,然后沿方位角和径向划分为块,并将每个块中最高点的 z 坐标编码为 2D 全局描述符。孙炜等^[25]通过计算点云轮廓特征关键点,并将其用于配准迭代以计算变换参数。基于深度特征的特征点云配准方法通过将低级的几何结构编码为更高级的局部特征,其通常在点云间距离较大时会失败,且需要推断复杂的网络,在处理大规模数据方面时间复杂度较高。

基于上述研究,本文提出基于点云稀疏语义特征的智能网联汽车协同感知配准算法。算法首先是基于点云稀疏语义特征的偏航角计算,该偏航角能够为后续的点云集成配准提供准确的初始值,使得算法在不依靠多余传感器提供初值的情况下实现点云较为准确的配准;然后是基于点云语义信息约束的集成配准,进一步优化算法的配准参数,本文所提算法的主要贡献可概括为:

- 1) 本文基于点云语义特征计算得到偏航角,为配准提供初值,解决配准算法对于初值的依赖问题;
- 2) 两阶段的集成配准方案简化了算法,解决了配准算法在处理大规模数据方面实时性较差的问题;
- 3) 本文所提算法通过添加点云的语义信息约束以提高配准精度,能更好的应对点云间的距离变换,有效降低噪声对配准效果的影响,提高了算法的鲁棒性。

1 点云稀疏语义特征提取

在智能网联汽车协同感知过程中,车载激光雷达所采集的点云数据大多来自道路场景。针对道路场景下点

云的固有特征以及激光雷达采集范围,本文设计道路场景下智能网联汽车雷达点云稀疏语义特征提取算法。图1为智能网联汽车协同感知示意图。




图1 智能网联汽车视野受限示意图

Fig. 1 Diagram of cooperative perception for ICVs

1.1 道路语义描述符

此步旨在提取点云中明显的道路特征,如护栏、交通标志、车辆、建筑物等。给定智能网联汽车车载激光雷达点云 P ,首先将它转换为极坐标系统。然后,沿方位和径向将点云分成 $N_s \times N_r$ 块。每个块 B_{ij} 表示为:

$$B_{ij} = \left\{ l_{ij} \left| \frac{(i-1) \cdot R_{\max}}{N_r} \leq \sqrt{x_i^2 + y_i^2} \leq \frac{i \cdot R_{\max}}{N_r}, \right. \right. \\ \left. \left. \frac{(j-1) \cdot 2\pi}{N_s} - \pi \leq \arctan\left(\frac{y_i}{x_i}\right) \leq \frac{j \cdot 2\pi}{N_s} - \pi \right\} \quad (1)$$

其中, $R_{\max}$ 为车载激光雷达的最大有效测量距离, l_{ij} 为点云语义标签, x_i, y_i 为原始点云中第 i 点坐标, $i \in [1, N_r], j \in [1, N_s]$ 。描述符可以定义为:

$$S(i, j) = f(B_{ij}) = \arg\max_{l_{ij} \in B_{ij}} F(l_{ij}) \quad (2)$$

其中, f 为编码函数,用于对 B_{ij} 的特征进行编码。 F 是一个用于衡量标签代表性的函数,标签出现的次数越少则认为其代表性越高,则选择这个标签作为这个网格的编码,由此可以得到一个基于语义的道路特征二维矩阵编码。

1.2 稀疏语义特征

智能网联汽车协同感知对实时性具有较高要求,为此算法在上述点云道路语义特征的基础上进一步进行几何特征提取。点云稀疏语义特征通过计算道路场景语义特征点云表面法向量进行局部几何特征提取。该特征保持了原有点云的姿态,具有旋转平移不变性,有助于接下来的基于点云稀疏语义特征的全局配准计算。对于道路场景语义特征点云的第 m 个扫描点 p_m ,搜索与其最近

邻的 t 个相邻点,计算这些点最小二乘意义上的局部平面 P ,此平面可以表示为:

$$P(\vec{n}, d) = \arg\min_{(\vec{n}, d)} \sum_{i=1}^t (\vec{n} \cdot p_m - d)^2 \quad (3)$$

其中, $\vec{n}$ 为平面 P 的法向量,由主成分分析得到, d 为 p_m 到坐标原点的距离。 p_m 经过其 t 邻域的质心 P_0 ,且法向量 $\vec{n}$ 满足 $\|\vec{n}\| = 1$ 。

$$\mathbf{M} = \frac{1}{t} \sum_{i=1}^t (p_m - p_0)(p_m - p_0)^T \quad (4)$$

其中, $\mathbf{M}$ 为协方差矩阵,对其进行特征值分解,最小特征值所对应的特征向量即 p_m 的法向量。根据连接点的法线信息 $\mathbf{n}_s, \mathbf{n}_t$ 对点云中的点 p_s, p_t 以半径 r 邻域计算 α, ϕ 和 σ 3 个特征算子:

$$\alpha = \mathbf{n}_s \times \frac{(p_t - p_s)}{\|p_t - p_s\|_2} \cdot \mathbf{n}_t \quad (5)$$

$$\phi = \mathbf{n}_s \cdot \frac{p_t - p_s}{d} \quad (6)$$

$$\sigma = \arctan\left(\mathbf{n}_s \times \mathbf{n}_s \times \frac{(p_t - p_s)}{\|p_t - p_s\|_2} \cdot \mathbf{n}_t, \mathbf{n}_s \cdot \mathbf{n}_t\right) \quad (7)$$

在此基础上得出简化点特征直方图(simplified point feature histogram, SPFH)。对于每个点都需要另外包含 $2r$ 内的其它点。对于新包含进来的点在第一步计算中得到的 SPFH 进行加权并与点 P_q 本身的 SPFH 求和,最后得到目标点 P_q 的稀疏语义特征(sparse semantic feature, SSF)

$$SSF(P_q) = SPFH(P_q) + \frac{1}{t} \sum_{i=1}^t \frac{1}{\omega_i} \cdot SPFH(p_i) \quad (8)$$

其中, ω_i 为当前点 P_q 与其近邻点 P_i 间的欧氏距离, k 为 P_q 邻域内的近邻点个数。

2 全局语义集成配准

考虑智能网联汽车协同感知中相互独立的激光雷达点云,应用快速偏航角将其旋转至同一角度,以此降低智能网联汽车独立点云间角度对配准的影响,提高算法实时性与配准精度。应用基于点云语义约束的全局集成配准,实现智能网联汽车协同感知,扩大单智能网联汽车感知范围。图2为基于点云稀疏语义特征的智能网联汽车协同感知配准算法方法流程。

2.1 快速偏航角计算

对于目标智能网联汽车激光雷达点云 P_t 与主车激光雷达点云 P_s ,从中筛选出具有语义代表性的点,比如车辆、交通标志等内容,其余的点则忽略不计。对于其中的每个点,将它们向二维平面上投影,以激光雷达为中




图 2 基于点云稀疏语义特征的智能网联汽车协同感知配准算法方法流程

Fig. 2 Flowchart of the ICVs cooperative perception registration algorithm based on sparse semantic features

心,计算其极坐标和平面坐标:

$$r_i = \sqrt{x_i^2 + y_i^2} \quad (9)$$

$$\varphi_i = \arctan\left(\frac{y_i}{x_i}\right) \quad (10)$$

$$p_i = [r_i, \varphi_i, x_i, y_i, l_i] \quad (11)$$

其中, x_i, y_i 为语义特征点云中第 i 点 p_i 坐标, r_i, φ_i 分别表示极径与极角, l_i 代表该点语义信息。之后按照角度划分 N 个扇形区域, 每个扇区内, 只保留径向上离圆心最近的点, 则 P_n 与 P_n 中每个点可以用一个 N 维向量 $\mathbf{v}_1, \mathbf{v}_2$ 来表示。偏航角计算公式为:

$$\theta = 360 - \left(\argmin_{i \in [0, N]} \Phi(\mathbf{v}_1, \mathbf{v}_2^i) \times \frac{360}{N} \right) \quad (12)$$

其中, $\mathbf{v}_2^i$ 表示 $\mathbf{v}_2$ 按第 i 个元素移动。 Φ 定义为:

$$\Phi(\mathbf{v}_1, \mathbf{v}_2^i) = \|\mathbf{v}_1 - \mathbf{v}_2^i\|_1 \quad (13)$$

因此, 式(12)可进一步表示为:

$$\theta = 360 - \left(\argmin_{i \in [0, N]} \|\mathbf{v}_1 - \mathbf{v}_2^i\|_1 \times \frac{360}{N} \right) \quad (14)$$

利用两帧点云之间的角度偏差 θ 将点云旋转到同一个方向上:

$$\begin{aligned} x_{ai} &= x_i \cos(\theta) - y_i \sin(\theta) \\ y_{ai} &= x_i \sin(\theta) + y_i \cos(\theta) \end{aligned} \quad (15)$$

其中, (x_i, y_i) 与 (x_{ai}, y_{ai}) 分别代表 P_{n2} 和 P_{la} 中的第 i 点。与扫描上下文和强度扫描上下文相比, 该方法只需要比较一维向量, 效率更高。此外, 该方法没有通过最大化得分来获得角度, 这有助于识别非闭环点对。

2.2 语义约束集成配准

首先使用基于语义约束的点对点的方式寻找邻近点, 点云语义约束误差公式为:

$$E = \argmin_{\mathbf{R}, \mathbf{t}} \sum_{m=1}^K \sum_{n=1, n \neq m}^K \sum_{i=1}^{N_{mn}} \Gamma(L_{mi}, L_{ni}) \times \|\mathbf{R}_m \mathbf{P}_m^i + \mathbf{t}_m - (\mathbf{R}_n \mathbf{P}_n^i + \mathbf{t}_n)\|^2 \quad (16)$$

其中, K 是点云个数, N_{mn} 是第 m 片点云和第 n 片点云邻近点的个数, $\mathbf{R}_m, \mathbf{R}_n$ 分别是第 m 和 n 片点云的旋转矩阵, $\mathbf{t}_m, \mathbf{t}_n$ 分别是第 m 和 n 片点云的平移矩阵。 L_{mi} 和 L_{ni} 为点的语义标签。若 L_{mi} 和 L_{ni} 相等, 则 $\Gamma(L_{mi}, L_{ni})$ 的输出为 1, 否则为 0。点云语义约束配准算法通过引入对应点语义一致性函数来刻画对应点关系, 该函数能够有效约束噪声点与距离对点云配准影响, 通过移除语义不一致的对应点以降低配准误差。

由于点云是有序的, 可以在偏航角与目标点一致的位置附近搜索相应的点。具体来说, 对第 i 个目标点的搜索间隔为:

$$\left[i + \argmin_{i \in [0, N]} \Phi(\mathbf{v}_1, \mathbf{v}_2^i) - \frac{N_l}{2}, i + \argmin_{i \in [0, N]} \Phi(\mathbf{v}_1, \mathbf{v}_2^i) + \frac{N_l}{2} \right] \quad (17)$$

其中, N_l 为搜索间隔的长度, 经过迭代可以得到输入点云之间的相对平移。语义约束集成配准目的是找到使误差 E 最小的旋转矩阵 $\{\mathbf{R}_i\}$ ($i = 1, \dots, K$) 和平移矩阵 $\{\mathbf{t}_i\}$ ($i = 1, \dots, K$)。首先将每片点云中的点减去质心坐标, 用以消除平移矩阵 $\{\mathbf{t}_i\}$ 的影响。定义点云集 $\{Q_i\}$ ($i = 1, \dots, K$):

$$Q_m^i = P_m^i - P_m^- = P_m^i - \frac{1}{N_m} \sum_{i=1}^{N_m} P_{mi} \quad (18)$$

原公式可被简化为:

$$\begin{aligned} E = \argmin_{\mathbf{R}, \mathbf{t}} \sum_{m=1}^K \sum_{n=1, n \neq m}^K \sum_{i=1}^{N_{mn}} \Gamma(L_{mi}, L_{ni}) \times \|\mathbf{R}_m Q_m^i - \mathbf{R}_n Q_n^i\|^2 = \\ \sum_{m=1}^K \sum_{n=1, n \neq m}^K \sum_{i=1}^{N_{mn}} \Gamma(L_{mi}, L_{ni}) \times (\mathbf{R}_m Q_m^i - \mathbf{R}_n Q_n^i)^T (\mathbf{R}_m Q_m^i - \mathbf{R}_n Q_n^i) = \\ \sum_{m=1}^K \sum_{n=1, n \neq m}^K \sum_{i=1}^{N_{mn}} \Gamma(L_{mi}, L_{ni}) \times (Q_m^iT \mathbf{R}_m^T - Q_n^iT \mathbf{R}_n^T) (\mathbf{R}_m Q_m^i - \mathbf{R}_n Q_n^i) \end{aligned} \quad (19)$$

展开后, 求和符号内部为

$$(Q_m^iT \mathbf{R}_m^T - Q_n^iT \mathbf{R}_n^T) (\mathbf{R}_m Q_m^i - \mathbf{R}_n Q_n^i) = Q_m^iT \mathbf{R}_m^T \mathbf{R}_m Q_m^i - Q_m^iT \mathbf{R}_m^T \mathbf{R}_n Q_n^i - Q_n^iT \mathbf{R}_n^T \mathbf{R}_m Q_m^i + Q_n^iT \mathbf{R}_n^T \mathbf{R}_n Q_n^i \quad (20)$$

采用梯度下降法求解旋转矩阵。固定 $i=1$ 的点云, 则上述公式右边 $K-1$ 个待求变量为 $\{\mathbf{R}_2, \mathbf{R}_3, \dots, \mathbf{R}_k\}$ 。

每次迭代过程中,更新后的变量求解公式为:

$$\mathbf{R}^{i+1} = [\mathbf{R}_2^{i+1}, \mathbf{R}_3^{i+1}, \dots, \mathbf{R}_k^{i+1}]^T = \mathbf{R}^i - \alpha \nabla \mathbf{R} = [\partial E / \partial \mathbf{R}_2^i, \partial E / \partial \mathbf{R}_3^i, \dots, \partial E / \partial \mathbf{R}_k^i]^T \quad (21)$$

其中, ∇ 为梯度算符, α 为学习率, E 为点云语义约束误差模型, 梯度求解公式为:

$$\partial E / \partial \mathbf{R}_m = \sum_{n=1, n \neq m}^K \sum_{i=1}^{N_{mn}} \frac{\partial Q_m^{iT} \mathbf{R}_m^T \mathbf{R}_m Q_m^i}{\partial \mathbf{R}_m} - \frac{\partial Q_m^{iT} \mathbf{R}_m^T \mathbf{R}_n Q_n^i}{\partial \mathbf{R}_m} - \frac{\partial Q_n^{iT} \mathbf{R}_n^T \mathbf{R}_m Q_m^i}{\partial \mathbf{R}_m} \quad (22)$$

偏导数求解为:

$$\frac{\partial Q_m^{iT} \mathbf{R}_m^T \mathbf{R}_m Q_m^i}{\partial \mathbf{R}_m} = 2 \mathbf{R}_m Q_m^i Q_m^{iT} \quad (23)$$

$$\frac{\partial Q_m^{iT} \mathbf{R}_m^T \mathbf{R}_n Q_n^i}{\partial \mathbf{R}_m} = \mathbf{R}_n Q_n^i Q_m^{iT} \quad (24)$$

$$\frac{\partial Q_n^{iT} \mathbf{R}_n^T \mathbf{R}_m Q_m^i}{\partial \mathbf{R}_m} = \mathbf{R}_n Q_n^i Q_m^{iT} \quad (25)$$

即:

$$\partial E / \partial \mathbf{R}_m = \sum_{n=1, n \neq m}^K \sum_{i=1}^{N_{mn}} 2 \mathbf{R}_m Q_m^i Q_m^{iT} - 2 \mathbf{R}_n Q_n^i Q_m^{iT} \quad (26)$$

求解平移矩阵:

$$\mathbf{t}_m = \mathbf{P}_1^- - \mathbf{R}_m \mathbf{P}_m^- \quad (27)$$

将更新后的 $\mathbf{R}_m$ 、 $\mathbf{t}_m$ 应用到点云集之后需要重新计算邻近点, 并不断迭代至算法收敛。

3 实验及分析

3.1 实验设置

本文在 64 线激光雷达采集的 KITTI 里程计数据集^[26]上进行实验, 选择具有循环闭包的序列 (00, 02, 05, 06, 07, 08) 进行测试。语义标签真值来自 SemanticKITTI 数据集^[27]。所有实验都在同一系统上完成, 使用 12th Gen Intel (R) Core (TM) i5-12400F CPU @ 2.50 GHz with 16.0 GB RAM。为了评估所提出方法的性能, 比较了 ICP、CPD、NDT 和 JRMPC 算法在 KITTI 数据集上的配准性能。上述对比算法除了 JRMPC 均为两两配准算法, 本文顺序应用两两配准算法进行多点云配准, 进而综合评估各算法实现多点云配准的性能。实验采用对应点之间的欧式距离均方根误差 (root mean square error, RMSE)^[28]作为评价指标进行算法的性能分析。理想状态下, 完全配准后对应点之间的距离为 0, 因此均方根误差越小代表配准精度越高。同时, 实验从时间复杂度、点云语义相似性得分与旋转平移误差等多个方面衡量所提方法的快速性以及协同感知的准确性与鲁棒性, 图 3(a)~(f) 展示了所提算法在 KITTI 数据集上 6 个不同序列上最终的语义集成配准结果图。本文使用的部分点云数据如图 4(a)~(d) 所示。




图 3 KITTI 全局语义约束集成配准结果图

Fig. 3 The results of global semantic constraint ensemble registration on KITTI dataset

3.2 协同感知配准鲁棒性分析

在道路场景下, 点云数据中存在的噪声对智能网联汽车协同感知是一项挑战。噪声导致点云位置产生偏移, 对物体检测与识别产生干扰, 从而影响智能网联汽车对周围环境的感知。因此, 正确处理点云位置差异对于多智能网联汽车协同感知的准确性和一致性具有重要意

义。同时, 多个智能网联汽车协同感知过程中存在因物体遮挡而导致的点云结构差异问题, 进而引起协同感知结果的不一致。有效处理上述问题对于智能网联汽车协同感知至关重要。

首先, 为测试所提算法在不同噪声水平下的鲁棒性, 实验采用高斯噪声作为配准影响因素, 高斯噪声的均值




图 4 实验所用部分点云数据

Fig. 4 Part of the point cloud data used in the experiment

为 0, 方差范围为 0~0.07。如图 5(a)~(d) 所示, 在高斯噪声方差较低时, 所提算法与 JRMPC 算法在 00、05 两个序列中配准误差最小, ICP 算法的总体配准误差最大。随着噪声方差水平的提高, 所提算法性能优于其他对比

算法。所提算法通过计算点云稀疏语义特征并添加语义信息约束以消除点云位置偏差, 将噪声对配准产生的影响降低。实验表明所提算法可有效应对智能网联汽车协同感知中存在的噪声干扰。




图 5 KITTI 数据集不同噪声水平下不同方法的 RMSE

Fig. 5 RMSE of different methods under different noise levels on KITTI dataset

其次, 针对智能网联汽车协同感知中因物体遮挡而导致激光雷达点云部分结构缺失问题, 通过设置点云不同部分的缺失程度以测试算法在应对上述问题时的配准精度和鲁棒性能。本文在 KITTI 数据集 4 个不同序列上进行测试。如图 6(a)~(d) 所示, 本文所提算法在点云存在不同程度结构缺失情况下配准误差低于其他对比算法, 随着点

云结构缺失程度增大, 算法仍能保持较高的配准精度, 鲁棒性能明显优于其他算法。算法通过提取道路场景中明显的语义特征如护栏、交通标志等有效降低点云结构差异对配准的影响。实验表明所提算法能够应对多个智能网联汽车协同感知过程中物体遮挡和点云结构差异问题, 以及不同线束激光雷达引起的点云稀疏程度不同的问题。




图 6 KITTI 数据集不同结构缺失水平下不同方法的 RMSE

Fig. 6 RMSE of different methods under different missing partial structures on KITTI dataset

3.3 实时性能评估

配准算法的效率对智能网联汽车协同感知有着重要的影响, 高效的配准算法可以提高协同感知系统的实时性和响应能力, 为智能网联汽车提供更可靠的决策支持。

为评估所提算法的效率, 本文在 KITTI 数据集的 6 个不同序列上与 ICP、CPD、NDT 和 JRMPC 方法相比并记录它们的平均时间成本。表 1 展示了本文所提方法的可接受的总时间成本, 本文所提算法平均配准时间仅需

表 1 各算法在 KITTI 上的时间成本

Table 1 Time cost of each algorithm on KITTI dataset

算法	00	02	05	06	07	08
ICP/s	7.06	6.96	7.28	6.94	7.01	6.99
JRMPC/s	2.86	2.83	2.86	2.86	2.91	2.87
NDT/s	5.59	5.40	5.33	5.43	5.49	5.28
CPD/s	20.52	20.35	20.15	20.48	20.77	20.39
本文/s	0.49	0.48	0.50	0.44	0.50	0.47

0.481 s。首先,算法只保留了点云的稀疏语义特征点,相较于原始点云(约 120 000 个点),计算成本大大降低。其次,算法采用两阶段的集成配准方案简化了算法,有效降低了算法的时间复杂度。最后,在计算旋转平移矩阵

时,算法预先使用偏航角对输入点云进行对齐。因此,所提算法有效解决了因车载激光雷达采集的数据规模大导致的配准实时性较差的问题,能够满足智能网联汽车协同感知对实时性的要求。

3.4 协同感知性能评估

首先,本文采取点云位移为影响因素对协同感知范围进行性能评估,位移范围为 1~8 m。如图 7(a)~(d)所示,在点云位移量较小的情况下几种算法的误差相差不大。随着位移距离的增大,ICP 与 NDT 的配准误差显著增加,JRMPC 在点云位移为 8 m 时误差急剧增加,所提算法配准误差随位移变化较小,配准精度高于其他算法。可见所提算法对位移变化不敏感。算法通过添加对应点语义约束,能更好的应对点云间的距离变换,可有效扩大智能网联汽车协同感知范围。




图 7 KITTI 数据集不同位移下不同方法的 RMSE

Fig. 7 RMSE of different methods under different displacements on KITTI dataset

其次,本文采用平均准确率(average precision, AP ↑)作为评价指标对协同感知精度与点云融合程度进行评估,智能网联汽车在点云交并比为 0.7 的情况下进行环境感知时协同感知平均准确率为常数 0.47。图 8 展示了所提算法与 F-Cooper^[3]、OPV2V^[29]协同感知算法在 OPV2V 公开数据集上的点云平均准确率定量比较结果,对于所提算法通过配准后语义特征点云的重叠部分来计算协同感知 AP 值。实验通过设置参与协同感知的智能网联汽车数量来探究算法协同感知精度的变化,智能网联汽车数量为 2~8,所有算法均在 OPV2V 统一框架下实现。本文所提算法协同感知平均准确率总体最高,当智能网联汽车数量为 8 时算法协同感知 AP 达到 0.91,随着参与协同感知的智能网联汽车数量的提高,性能明显优于其他算法,拥有较好的协同感知精度。

本文通过对比各算法的时间复杂度来对所提算法的协同感知效率进行评估。实验设置激光雷达点云数为 4,因智能网联汽车数量达到 4 时已经可以提供足够的视点完成对道路环境的协同感知。本文选取 OPV2V 数据集其中 4 种不同的道路场景进行实验,具体对比结果如表 2 所示,表中加粗的数值表示协同感知最短耗时。




图 8 协同感知平均准确率定量比较

Fig. 8 Quantitative comparison of cooperative perception AP

表 2 不同算法运行时间对比

Table 2 Comparison of running time of different algorithms s

算法	十字路口	T 形路口	弯道	直道
F-Cooper	0.64	0.79	0.57	0.97
OPV2V	1.25	1.43	0.93	2.02
本文	0.48	0.51	0.44	0.67

本文所提算法在多种道路场景下协同感知效率均高于对比算法,具有较好的协同感知实时性能。

最后,本文采用不同道路场景下协同感知配准算法旋转平移误差作为评价指标对智能网联汽车协同感知鲁棒性能进行评估。图 9(a)~(c)分别展示了本文所提算法在 KITTI 数据集 4 种道路场景下的相对平移误差与旋转误差。所提算法在包含直道场景的 00 序列与包含十

字路口场景的 08 序列中均取得较小的配准误差,证明所提算法能够提高智能网联汽车协同感知鲁棒性与稳定性。算法通过道路语义特征计算得到偏航角,为提供配准初值,并添加点云语义信息约束进一步优化配准参数,使得算法可以给出准确的 3D 姿态估计,可有效解决智能网联汽车在协同感知过程中为获得初始位姿而产生的传感器冗余、位姿依赖问题。




图 9 旋转平移误差

Fig. 9 Rotation and translation error

3.5 真实实验结果分析

本文在校园真实道路场景中对激光雷达原始点云进行数据采集,采用的激光雷达型号为 RS-LiDAR-32,安装位置为智能网联汽车车顶,如图 10(a)~(b)所示。实验采集的激光雷达原始点云数据共有 10 835 帧,每帧激光雷达点云数为 57 600 点左右。为综合验证所提算法在不同交通场景中的配准性能,实验选择在交叉路口、弯道、匝道等具有代表性的真实道路场景中采集到的多帧激光雷达点云进行集成配准,配准结果如图 11(a)~(f)所示。




图 10 试验车与实验场景

Fig. 10 Test ICVs and experimental scene




图 11 真实实验全局语义约束集成配准结果

Fig. 11 The result of global semantic constraint ensemble registration on real data

同时,本文对真实数据进行处理以测试算法在真实道路场景中应对点云的噪声、位移和结构缺失等情况下的协同感知性能。实验分别设置点云噪声方差为 0.03、位移为 3 m 以及点云 30% 结构缺失并计算了算法在这 3 种情况下的配准均方根误差 RMSE。如表 3 所示,本文选取了 4 种较为典型的道路场景,分别为十字路口、弯道、T 形路口以及匝道场景。对于每种道路场景,第 1 列表示算法在点云噪声方差为 0.03 时的配准误差,第 2 列

表示算法在点云间位移为 3 m 时的配准误差,第 3 列表示算法在点云 30% 结构缺失时的配准误差,表中加粗的数值表示最小配准误差。正如预期,所提算法在多种道路场景中均有着较高的配准精度,在十字路口与匝道这两种复杂道路场景中配准性能明显优于其他对比算法。实验证明所提算法能够应对智能网联汽车协同感知过程中车载激光雷达点云数据存在的噪声、位移以及物体遮挡问题,拥有较好的鲁棒性以及实时性。

表 3 真实实验结果(RMSE)定量对比
Table 3 Quantitative comparison results (RMSE) on real data

算法	十字路口			弯道			T 形路口			匝道		
ICP	0.172	0.137	0.269	0.170	0.145	0.251	0.144	0.204	0.290	0.182	0.169	0.293
JRMPC	0.122	0.116	0.196	0.126	0.133	0.200	0.107	0.115	0.215	0.161	0.141	0.231
NDT	0.167	0.172	0.246	0.118	0.131	0.244	0.103	0.148	0.292	0.162	0.239	0.290
CPD	0.125	0.147	0.214	0.135	0.166	0.187	0.117	0.148	0.243	0.131	0.198	0.258
本文	0.114	0.111	0.156	0.104	0.132	0.180	0.104	0.114	0.158	0.107	0.121	0.168

4 结 论

本文提出了基于点云稀疏语义特征的智能网联汽车协同感知配准算法,算法分为点云稀疏语义特征计算与基于语义信息约束的点云语义集成配准两个阶段。所提算法在 KITTI 公开数据集多个序列,以及包含交叉路口、弯道、匝道等具有代表性的真实道路场景中进行实验验证与性能评估。KITTI 公开数据集实验表明本文所提算法在应对点云噪声、结构缺失方面配准性能优于其他对比算法。同时,在包含多种交通场景的真实道路实验中,本文所提算法与主流算法 JRMPC 相比法配准精度提高了 2.45%。本文所提算法能够有效扩大协同感知范围,实现智能网联汽车鲁棒协同感知。

参考文献

[1] YUAN Y, CHENG H, SESTER M. Keypoints-based deep feature fusion for cooperative vehicle detection of autonomous driving[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 3054-3061.

[2] THANDAVARAYAN G, SEPULCRE M, GOZALVEZ J. Generation of cooperative perception messages for connected and automated vehicles [J]. IEEE Transactions on Vehicular Technology, 2020, 69 (12): 16336-16341.

[3] CHEN Q, MA X, TANG S, et al. F-cooper: Feature

based cooperative perception for autonomous vehicle edge computing system using 3D point clouds [C]. Proceedings of the 4th ACM/IEEE Symposium on Edge Computing, 2019: 88-100.

[4] HURL B, COHEN R, CZARNECKI K, et al. Trupercept: Trust modelling for autonomous vehicle cooperative perception from synthetic data [C]. 2020 IEEE Intelligent Vehicles Symposium (IV), IEEE, 2020: 341-347.

[5] CHEN H, SUN D, LIU W, et al. An automatic registration approach to laser point sets based on multidiscriminant parameter extraction [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(12): 9449-9464.

[6] YUAN M, HUANG X, FU K, et al. Boosting 3D point cloud registration by transferring multi-modality knowledge [C]. IEEE International Conference on Robotics and Automation (ICRA), 2023: 11734-11741.

[7] CHOY C, DONG W, KOLTUN V. Deep global registration [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 2514-2523.

[8] BESL P J, MCKAY N D. A method for registration of 3D shapes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.

[9] FAN A, MA J, TIAN X, et al. Coherent point drift

- revisited for non-rigid shape matching and registration[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 1424-1434.
- [10] TSIN Y, KANADE T. A correlation-based approach to robust point set registration[C]. Proceedings of European Conference on Computer Vision (ECCV), 2004: 558-569.
- [11] CAMPBELL D, PETERSSON L. An adaptive data representation for robust point-set registration and merging[C]. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2015: 4292-4300.
- [12] BERGEVIN R, SOUCY M, GAGNON H, et al. Towards a general multi-view registration technique[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996, 18(5): 540-547.
- [13] ZHU J, LI Z, DU S, et al. Surface reconstruction via efficient and accurate registration of multiview range scans[J]. Optical Engineering, 2014, 53(10): 102104-102104.
- [14] MYRONENKO A, SONG X. Point set registration: Coherent point drift[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(12): 2262-2275.
- [15] 朱浩, 李鑫. 基于一致性点漂移的智能车视觉目标跟踪方法[J]. 仪器仪表学报, 2023, 43(10): 195-204.
- ZHU H, LI X. Visual multi-object tracking method for intelligent vehicle based on coherent point drift[J]. Chinese Journal of Scientific Instrument, 2023, 43(10): 195-204.
- [16] MATEO X, ORRIOLS X, BINEFA X. Bayesian perspective for the registration of multiple 3D views[J]. Computer Vision and Image Understanding, 2014, 118: 84-96.
- [17] 余仁伟, 朱浩, 蔡昌恺. 基于薄板样条函数的无人机多目标跟踪算法[J]. 仪器仪表学报, 2021, 42(3): 168-176.
- YU R W, ZHU H, CAI CH K. Multi-object tracking algorithm for UAV based on the thin plate spline function[J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 168-176.
- [18] EVANGELIDIS G D, HORAUD R. Joint alignment of multiple point sets with batch and incremental expectation-maximization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(6): 1397-1410.
- [19] MIN Z, WANG J, MENG M Q H. Joint rigid registration of multiple generalized point sets with hybrid mixture models[J]. IEEE Transactions on Automation Science and Engineering, 2019, 17(1): 334-347.
- [20] BIBER P, STRASSER W. The normal distributions transform: A new approach to laser scan matching[C]. Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE, 2003, 3: 2743-2748.
- [21] WOHLKINGER W, VINCZE M. Ensemble of shape functions for 3d object classification[C]. 2011 IEEE International Conference on Robotics and Biomimetics, IEEE, 2011: 2987-2992.
- [22] WANG H, WANG C, XIE L. Intensity scan context: Coding intensity and geometry relations for loop closure detection[C]. 2020 IEEE International Conference on Robotics and Automation (ICRA), IEEE, 2020: 2095-2101.
- [23] HUANG Y, SHAN T, CHEN F, et al. DiSc-SLAM: Distributed scan context-enabled multi-robot lidar slam with two-stage global-local graph optimization[J]. IEEE Robotics and Automation Letters, 2021, 7(2): 1150-1157.
- [24] LI L, KONG X, ZHAO X, et al. SSC: Semantic scan context for large-scale place recognition[C]. 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE, 2021: 2092-2099.
- [25] 孙炜, 苑河南, 刘乃铭, 等. 融合轮廓特征的线激光点云的快速配准算法[J]. 电子测量与仪器学报, 2023, 35(7): 156-162.
- SUN W, YUAN H N, LIU N M, et al. Fast registration algorithm combining contour features for line laser point clouds[J]. Journal of Electronic Measurement and Instrumentation, 2023, 35(7): 156-162.
- [26] GEIGER A, LENZ P, STILLER C, et al. Vision meets robotics: The KITTI dataset[J]. The International Journal of Robotics Research, 2013, 32(11): 1231-1237.
- [27] BEHLEY J, GARBADE M, MILIOTO A, et al. Semantic KITTI: A dataset for semantic scene understanding of lidar sequences[C]. Proceedings of the

IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 9296-9306.

[28] TANG H, LIU Z, ZHAO S, et al. Searching efficient 3d architectures with sparse point-voxel convolution [C]. Proceedings of European Conference on Computer Vision (ECCV), 2020: 685-702.

[29] XU R, XIANG H, XIA X, et al. Opv2v: An open benchmark dataset and fusion pipeline for perception with vehicle-to-vehicle communication[C]. 2022 International Conference on Robotics and Automation (ICRA), IEEE, 2022: 2583-2589.

作者简介



E-mail: sandwish@ 163. com

朱浩(通信作者), 2005 年于大连海事大学获得学士学位, 分别在 2007 年和 2012 年于重庆大学获得硕士学位和博士学位, 现为重庆邮电大学教授, 主要研究方向为信号处理、信息融合。

Zhu Hao (Corresponding author) received his B. Sc. degree from Dalian Maritime University in 2005, received his M. Sc. and Ph. D. degrees both from Chongqing University in 2007 and 2012, respectively. He is currently a professor at Chongqing University of Posts and Telecommunications. His main research interests include single processing and information fusion.



倪锐峰, 2021 年于重庆理工大学获得学士学位, 现于重庆邮电大学攻读研究生硕士学位, 主要研究方向为智能网联汽车, 协同感知。

E-mail: niruif714@ 163. com

Ni Ruifeng received his B. Sc. degree from Chongqing University of Technology in 2021. He is currently a master student at Chongqing University of Posts and Telecommunications. His main research interests include intelligent and connected vehicles, and collaborative perception.