

DOI:10.11918/202005106

三维点云极化地图表征模型与智能车定位方法

胡钊政¹, 李 飞^{1,2}, 陶倩文¹, 陈佳良¹

(1. 武汉理工大学 智能交通系统研究中心, 武汉 430063; 2. 武汉理工大学 重庆研究院, 重庆 401120)

摘要: 为提高智能车定位精度提出一种基于三维点云极化地图表征模型的定位方法。该模型以点云极化图为节点, 利用高精度 GPS (Global Positioning System) 和欧拉角实现该节点的全局位置表征; 从极化图中提取点云的二维与三维特征, 实现该节点的多尺度特征表征; 通过一系列极化节点实现道路场景的数值描绘与虚拟重构。定位过程中, 通过对实时获取的三维激光点云进行极化表征并与地图节点进行多尺度特征匹配实现智能车的地图定位。具体而言, 首先根据待定位智能车 GPS 信号的稳定情况选用 GPS 匹配或者拓扑定位筛选地图节点并获取定位候选集, 完成初定位; 其次运用点云二维特征匹配结果从定位候选集中检测距离待定位智能车最近的地图节点, 完成节点级定位; 最后利用点云三维特征匹配结果与最近地图节点的全局位置计算智能车位姿, 完成度量级定位。实验在两种典型场景下进行, 节点定位准确率 98.7%, 平均定位误差 21.4 cm, 最大定位误差 42.9 cm。结果表明, 本文算法满足智能车高精度定位需求, 且鲁棒性强、成本低、计算过程简单。

关键词: 智能交通; 极化地图; 场景表征; 地图定位; 数据融合; 智能车定位

中图分类号: U495

文献标志码: A

文章编号: 0367-6234(2021)08-0103-06

Localization method for intelligent vehicles based on map representation from 3D point cloud polarization

HU Zhaozheng¹, LI Fei^{1,2}, TAO Qianwen¹, CHEN Jialiang¹

(1. Intelligent Transportation Systems Research Center, Wuhan University of Technology, Wuhan 430063, China;

2. Chongqing Research Institute, Wuhan University of Technology, Chongqing 401120, China)

Abstract: A method to improve the localization accuracy of intelligent vehicles was proposed by using map representation model from three-dimensional (3D) point cloud polarization. The point cloud polarization image was used as the node in this model, and the global position representation of the node could be realized through high-precision Global Positioning System (GPS) and Euler angle. The 2D and 3D features of the point cloud were then extracted from the polarization image to realize the multi-scale feature representation of the node, and the numerical description and virtual reconstruction of the road scene were realized through a series of polarization nodes. During the localization process, the 3D laser point cloud was in real-time acquired for polarization representation, and multi-scale feature matching was carried out with map nodes to realize the map localization of the intelligent vehicles. Specifically, map nodes were first filtered through GPS matching or topological localization based on the stability condition of the GPS signal of the intelligent vehicle, and a localization candidate set was obtained for the coarse localization. Then, the nearest map node was detected by matching the 2D point cloud features of the polarization image from the candidate set to complete the node localization. Finally, for the metric localization, the position of the intelligent vehicle was calculated by using the 3D point cloud feature matching results and the global position of the nearest map node. The experiment was carried out in two typical scenarios. The node localization accuracy rate was 98.7%, the average localization error was 21.4 cm, and the maximum localization error was 42.9 cm. Results show that the proposed algorithm has the advantages of high positioning accuracy, strong robustness, low cost, and simple calculation process.

Keywords: intelligent transportation; polarization map; scene representation; map localization; data fusion; localization for intelligent vehicles

随着人工智能、大数据、云计算、物联网等先进

科学技术的应用和通信交互能力的增强, 智能车技术已日趋成熟^[1]。感知与定位技术在智能车的发展过程中占据重要地位, 而由于 LiDAR 具有高频、远程、高精度的数据采集性能, 使得其在智能车定位中被广泛运用。目前基于激光的主流定位方法为 SLAM(simultaneous localization and mapping)。SLAM

收稿日期: 2020-05-22

基金项目: 国家重点研发计划(2018YFB1600801); 重庆市自然科学基金(cstc2020jcyj-msxmX0978); 武汉市科技局项目(2020010601012165, 2020010602011973, 2020010602012003)

作者简介: 胡钊政(1979—), 男, 教授, 博士生导师

通信作者: 胡钊政, zhu@whut.edu.cn

主要分为里程计和优化两部分。里程计根据帧间点云匹配结果计算车辆的运动。ICP (iterative closest point)^[2]是经典的点云帧间匹配算法,通过逐点查找对应关系,ICP 不断尝试对齐两组点云,直到满足条件为止,当点云数量过多时,ICP 算法会有较高的计算复杂度。基于特征点云的帧间匹配算法通过环境中寻找具有代表性的特征而只需要较少的计算资源,备受关注。Rusu 等^[3]提出的 PFH (point feature histogram) 特征通过参数化查询点和邻域点的空间差异并形成一个多维直方图来描述查询点 k 邻域的几何属性,该类特征提取方法简单且具有旋转不变性,同时对采样密度和噪声点具有较强的鲁棒性。虽然通过帧间特征匹配可快速获取车辆位姿,但随着车辆行驶距离增长及帧间匹配次数增多,累计误差逐渐增大。LOAM^[4-5] (lidar odometry and mapping in real-time) 算法通过三维重建图校定位轨迹,但其地图为在线生成且在制图前需对点云进行下采样、滤波等预处理,导致算法的空间复杂度和时间复杂度较高;并且随着定位距离的增长,LOAM 算法仍会存在较大的累计误差。

本文提出了一种三维点云极化地图表征模型,该模型以极化图为节点,通过融合全局位置信息、点云的二维和三维特征并结合多尺度定位方法实现智能车定位。实验在两种典型场景下进行,结果表明,本文算法在节点级和度量级定位上均具有高精度,满足智能车的定位需求,且鲁棒性强、成本低、计算过程简单。本文的创新点为:

1) 离线制图和在线定位均以极化图为节点,极化图构造方法简单且保留了点云的原始数据,同时将点云的二维和三维信息融合。

2) 利用极化图提取点云的二维和三维特征,实现制图和定位节点的多尺度特征表征。

3) 提出了一种基于点云极化地图表征模型的多尺度定位方法,该方法采用多尺度渐进定位策略,通过基于 GPS/拓扑结构的初定位、基于点云二维特征的节点级定位和基于点云三维特征的度量级定位,获取智能车位姿。

1 本文算法

1.1 系统概述

图 1 为系统流程图,输入为 LiDAR 和普通 GPS 采集的激光点云及 GPS 数据,输出为待定位车辆位姿。系统分为离线制图、初定位、节点级定位和度量级定位 4 个模块:

1) 离线制图模块利用高精度惯导数据和点云数据制作极化地图,主要包含全局位置信息、点云的

二维和三维特征。

2) 初定位模块在 GPS 信号良好时,将待定位节点与地图节点进行 GPS 匹配并根据 GPS 精度筛选地图节点;若 GPS 信号缺失,则利用拓扑结构进行初定位并筛选地图节点。

3) 节点级定位模块通过极化表征生成点云极化图并利用加权特征匹配算法与初定位结果进行 SURF (speeded up robust features)^[6] 和 ORB (oriented FAST and rotated BRIEF)^[7] 全局特征匹配,结合 WH-KNN (weighted hybrid k -nearest neighbor)^[8] 算法挑选最近地图节点。

4) 度量级定位利用极化图提取点云角特征点和面特征点并与最近地图节点进行特征点云匹配,结合 L-M (Levenberg-Marquardt)^[9] 算法计算待定位车辆位姿。




图 1 系统流程图

Fig. 1 Flow chart of the system

1.2 基于三维点云极化地图表征模型的地图构建

三维点云极化地图表征模型以极化图为节点,融合了全局位置信息、点云的二维和三维特征,地图构建示意图见图 2。利用数据采集车辆搭载 LiDAR 和组合惯导并结合 RTK (real-time kinematic) 技术在待定位路段采集激光点云和高精度惯导数据。在数据采集之前,需通过 LiDAR 对组合惯导定位接收器进行标定以获取其在 LiDAR 坐标系中的位置,通过标定获取的位置参数用于在线定位中的坐标修正。设 $P_1 = \{P_{11}, P_{12}, \dots, P_{1i}, \dots\}$ 为 LiDAR 扫描在惯导定位接收器上的点云集合,计算 P_1 的质心坐标 P_{1NS} 并以此作为组合惯导定位接收器在 LiDAR 坐标系中的位置,计算公式为

$$P_{\text{INS}} = \frac{1}{n_1} \sum_i (P_{li}) \quad (1)$$

式中 n_1 为 P_1 中点云数量。标定完成后, 以等距的方式在待定位路段进行数据采集, 采集频率 1 m/次, 每次数据采集包含一帧点云数据和一条高精度惯导数据。值得提出的是, 组合惯导结合 RTK 仅用于构建极化地图, 在线定位时采用普通 GPS 接收机即可。数据采集完成后, 离线处理每个数据节点, 处理步骤为: 1) 全局位置表征; 2) 二维特征表征; 3) 三维特征表征。具体实施如下。




图 2 极化地图

Fig. 2 Polarization map

从高精度惯导数据中提取全局位置信息。全局位置信息包含 GPS 信息和欧拉角, 其中欧拉角由翻滚角 (roll)、俯仰角 (pitch) 和航向角 (yaw) 组成。

点云二维特征表征。首先通过极化表征将激光点云数据转化成极化图, 本文所选用 VLP-16 LiDAR 的激光扫描线数、水平视场和水平角分辨率分别为 16、360°、0.2°, 故极化图的分辨率为 1 800 × 16, 根据每个点云所在激光扫描线位置及水平视场角度确认其像素坐标并以其与 LiDAR 的欧式距离作为灰度值进行投影, 生成极化图。其次对极化图进行切割及预处理并提取预处理图像子块的 SURF 和 ORB 全局特征, 具体而言: 1) 将极化图切割成 N 个图像子块, 本文 N 为 30, 图像子块分辨率为 60 × 16; 2) 对图像子块进行直方图均衡化和尺寸归一化 (63 × 63) 处理; 3) 将处理后的图像子块中心作为特征点, 整个图像子块作为特征点的邻域; 4) 计算特征描述符, 并将此描述符作为图像子块的全局特征描述符。最终得到的 SURF 全局特征描述符是一个 64 维的向量, ORB 全局特征是一个 256 位的二进制字符串, 见图 3。




图 3 SURF (上方) 和 ORB (下方) 全局特征

Fig. 3 SURF (above) and ORB (below) holistic features

点云三维特征表征。首先基于极化图像的列式评估方法^[10]完成地面点云提取并将其作为一类特殊的聚类点簇, 地面点云对后续的面特征点提取具有重要意义。其次基于图像的点云聚类方法^[11]对极化图上非地面点云进行聚类, 需要注意的是, 小物体 (例如树叶) 点云会在后续的特征点云提取中形成琐碎且不可靠的特征点云, 而车辆在两次不同的激光数据采集, 很难捕捉到同一个小物体, 为了提取到可靠的特征点云, 通过设置聚类点云数量阈值 k_p 剔除小物体聚类点簇, 本文 $k_p = 30$ 。聚类结果如图 4(b) 所示, 图 4(a) 为原始点云。最后提取点云三维特征, 即面特征点云和角特征点云, 特征提取方式与 LOAM^[5] 类似, 不同的是, 本文在聚类点云中完成特征提取, 具体而言: 1) 计算点云 P_i 的曲率 c_i , 计算公式为


$$c_i = \frac{1}{|S|} \times \left| \sum_{j \in S, j \neq i} (r_j - r_i) \right|^2 \quad (2)$$

式中: S 为与 P_i 在极化图上呈行连续的点集且均匀分布在 P_i 两侧, r_i 为 P_i 在极化图中对应点的灰度值, r_j 为 S 中第 j 个点云在极化图中对应点灰度值; 2) 点云分类, 通过设置曲率阈值 c_{th} 将点云划分为面特征点 ($c_i < c_{th}$) 和角特征点 ($c_i > c_{th}$); 3) 特征筛选, 为了让特征点云均匀分布, 将极化图沿水平方向划分为数个相等大小的子图像, 从每行点云中分别挑选 N_e 个具有最大曲率 c_i 的角特征点和 N_p 个具有最小曲率 c_i 的面特征点, 本文将极化图分为 6 个子图像, $N_e = 20, N_p = 40$ 。


1.3 基于极化地图的多尺度定位

本文在线定位采用多尺度渐进定位策略, 通过基于 GPS/拓扑结构的初定位, 基于点云二维特征的节点级定位和基于点云三维特征的度量级定位, 获取智能车位姿, 具体实施如下。

基于 GPS/拓扑结构的初定位。定位之前需利用 LiDAR 对 GPS 接收机进行标定以获取其在 LiDAR 坐标系中的位置 P_{GPS} , 方法与制图所用相同。



(a) 原始点云



(b) 聚类点云

图 4 点云聚类

Fig. 4 Point cloud clustering

标定完成后,根据以下两种情况进行初定位:

1) GPS 信号良好时,匹配待定位节点与地图节点的 GPS,完成初定位。设待定位节点 L 的粗 GPS 为 $g_l = (a_l, b_l)$,地图节点序列 M_i 的高精度 GPS 为 $G_m = \{g_{m1}, g_{m2}, \dots, g_{mi}, \dots\} = \{(a_{m1}, b_{m1}), (a_{m2}, b_{m2}), \dots, (a_{mi}, b_{mi}), \dots\}$,计算待定位节点与地图节点的欧氏距离并通过设置距离阈值 k_g 对地图节点进行筛选,计算公式为:

$$\begin{cases} U_l = (X_l, Y_l) = \text{trans}(a_l, b_l) \\ U_{mi} = (X_{mi}, Y_{mi}) = \text{trans}(a_{mi}, b_{mi}) \end{cases} \quad (3)$$

$$D_l = \{U_{mi} | \text{dist}(U_l, U_{mi}) \leq k_g\} \quad (4)$$

式中: $U_l = (X_l, Y_l)$ 为待定位节点的粗 GPS 数据经转化后的欧氏坐标, $U_{mi} = (X_{mi}, Y_{mi})$ 为第 i 个地图节点的高精度 GPS 数据经转化后的欧氏坐标, $\text{trans}()$ 为 GPS 坐标转欧氏坐标的公式, $\text{dist}()$ 为欧氏距离计算公式, D_l 为符合要求的地图节点集合。由于普通 GPS 的定位精度为 10 m,故 $k_g = 10$ 。

2) GPS 信号缺失时,利用拓扑结构完成初定位,示意图见图 5。在很短的时间内,智能车被认为匀速运动,可通过前一位置来预测智能车当前位置范围。智能车在 t_{i-1} 时刻的位置为 U_{i-1} , d_{i-1} 为智能车从 t_{i-2} 到 t_{i-1} 时刻的移动距离,由于之前位置已知,故智能车在 t_i 时刻的位置可用下式推导

$$U_i = U_{i-1} + \sum_{k=1}^n \frac{d_{i-k}}{n} \quad (5)$$

由于拓扑定位存在误差 d_g ,则智能车的位置范围为 $U_i \pm d_g$,以此范围筛选地图节点。 d_g 根据实际设置,本文 $d_g = 10$ m。




图 5 拓扑初定位

Fig. 5 Coarse localization based on topology

基于点云二维特征的节点级定位。首先基于极化表征将待定位节点激光点云数据转化成极化图并进行切割及预处理,提取预处理图像子块的 SURF 和 ORB 全局特征,方法与制图所用相同。其次匹配待定位节点和初定位结果的 SURF 和 ORB 全局特征,为了更准确表达不同极化图之间的相似度,本文提出了加权特征匹配算法,具体而言:1) 待定位节点与初定位结果分别进行 SURF 和 ORB 全局特征匹配;2) 计算 SURF 和 ORB 特征距离加权均值,距离值越小,说明不同极化图之间的相似度越高,具体计算公式为

$$d_t = \frac{1}{n_f} \times \sum_{i=1}^{n_f} d_{fi} \quad (6)$$

式中: n_f 为相匹配的特征点对数目, d_{fi} 为第 i 个相匹配特征点对之间的距离, d_t 为不同极化图之间的特征距离。加权特征匹配算法通过对图像进行区域划分,将区域图像作为特征并进行匹配,利用匹配特征间的距离加权均值作为不同图像的特征距离,更加准确地表达了不同图像的相似度。最后通过 WH-KNN 算法挑选最近的地图节点,WH-KNN 算法通过引入权值解决识别模糊性问题,结合加权特征匹配算法,极大提高了最近节点检测的正确率。

基于点云三维特征的度量级定位。首先通过待定位节点极化图完成点云聚类、特征点云提取,方法与制图所用相同,需要注意的是,待定位节点只需从子图像每行点云中挑选较少数量的角特征点和面特征点即可,本文挑选数量分别为 2 和 4。其次匹配待定位节点和最近地图节点的角特征点和面特征点,匹配方式分别为点到线和点到面的特征匹配方法^[5]。再次利用标定获取的 GPS 接收机位置参数 P_{GPS} 和组合惯导定位接收器位置参数 P_{INS} 对匹配点云对进行坐标修正,地图数据采集时,以组合惯导定位接收器代替车辆的位置,而在线定位时,以 GPS

接收机代替车辆的位置,所以应将点云坐标原点分别移至两者处,计算公式为

$$\begin{cases} x_{\text{after}} = x_{\text{before}} - x_c \\ y_{\text{after}} = y_{\text{before}} - y_c \\ z_{\text{after}} = z_{\text{before}} - z_c \end{cases} \quad (7)$$

式中: $P_{\text{before}} = \{x_{\text{before}}, y_{\text{before}}, z_{\text{before}}\}$ 为修正前的点云坐标, $P_{\text{after}} = \{x_{\text{after}}, y_{\text{after}}, z_{\text{after}}\}$ 为修正后的点云坐标, $P_c = \{x_c, y_c, z_c\}$ 为 GPS 接收机或组合惯导定位接收器位置参数。最后通过修正后的匹配点云对坐标及 L-M 算法计算待定位节点与最近地图节点的旋转向量 R 和平移向量 T , 结合最近地图节点的全局位置信息, 即可获取待定位车辆的位置和姿态, 完成定位。

2 实验结果

实验在两种典型场景下进行: 1) 某高校园区闭环路线, 见图 6(a), 该路线长为 600 m, 覆盖面积为

15 000 m²; 2) 某工业园区闭环路线, 见图 6(b), 该路线长为 891 m, 覆盖面积为 20 900 m²。极化地图构建采用 Velodyne VLP-16 LiDAR 与组合惯导结合 RTK 技术来完成, 在线定位采用 Velodyne VLP-16 LiDAR 与普通 GPS 接收机来完成。VLP-16 LiDAR 的最大测量范围为 100 m, 精度为 3 cm, 16 条激光扫描线, 垂直视场为 30° (±15°), 垂直角分辨为 2°, 水平视场为 360°, 水平角分辨率可在 0.1°~0.4° 中进行选择, 本文设置的扫描速率为 10 Hz, 水平角分辨率为 0.2°; 组合惯导的工作速率为 10 Hz, 结合 RTK 技术后的定位精度为 1 cm; 普通 GPS 接收机的定位精度为 10 m; 本文系统的运算平台为具有 2.8 GHz i7-7700HQ CPU 的笔记本电脑。场景 1 采用比亚迪 E5 电动车作为测试车, 实验平台见图 6(c); 场景 2 采用智能物流车作为测试车, 实验平台见图 6(d)。




图 6 实验场景与平台
Fig. 6 Experimental scenarios and platforms

2.1 高校园区实验

首先在闭环路线上采集数据构建极化地图, 数据采集频率 1 m/次, 每次采集数据包括一帧高精度惯导数据和一帧点云数据。极化地图构建完成后, 进行在线定位实验, 该闭环路线上共 786 个待定位节点, 地图采集和在线定位时间间隔超过 24 h。本文选取 Tao 等^[12] 提出的算法作为节点级定位对比算法, 该算法首先将待定位节点和地图节点的点云俯视投影图进行 ORB 特征匹配并利用 RANSAC (random sample consensus) 算法去除错误匹配点对,

其次根据匹配点对数量选取最近地图节点。若通过节点定位获取的地图节点与待定位节点的 GPS 真值 (ground truth) 距离最短, 则认为节点定位正确。同时, 本文选取经典的 SLAM 算法 LOAM^[5] 作为度量级定位对比算法。本文算法在该闭环路线上的定位轨迹见图 7(a), 定位误差见图 7(b), 对比实验结果见表 1。

在该闭环路线上, 本文算法正确定位最近地图节点个数为 773, 节点定位准确率为 98.3%, 度量级定位误差为 33.2 cm, 最大定位误差为 42.9 cm, 满

足智能车高精度定位需求。与 Tao 等提出的算法和 LOAM 算法相比,本文算法节点级定位准确率提高了 51.2%,度量级定位误差降低了 43.1 cm。




图 7 高校园区定位结果
Fig. 7 Localization results of campus

表 1 高校园区对比实验

Tab. 1 Comparative experiment on campus		
算法	节点定位准确率/%	度量定位误差/cm
本文算法	98.3	33.2
Tao 等算法	47.1	76.3

2.2 工业园区实验

与高校园区的定位实验相似,首先在该闭环路线上采集数据构建极化地图,其次进行在线定位,该闭环路线上共 5 205 个待定位节点,构图与定位的时间间隔超过 24 h,分别选取 Tao 等提出的算法和 LOAM 算法作为节点级定位和度量级定位的对比算法。本文算法在该闭环路线上的定位轨迹和定位误差分别如图 8(a) 和 8(b) 所示,对比实验结果见表 2。

在该闭环路线上,本文算法正确定位最近地图节点个数为 5 138,节点定位准确率为 98.7%,度量级定位误差为 19.6 cm,最大定位误差为 38.4 cm,满足智能车高精度定位需求。与 Tao 等提出的算法和 LOAM 算法相比,本文算法节点级定位准确率提高了 52.4%,度量级定位误差降低了 77.8 cm。




图 8 工业园区定位结果
Fig. 8 Localization results of factory

表 2 工业园区对比实验

Tab. 2 Comparative experiment on factory		
算法	节点定位准确率/%	度量定位误差/cm
本文算法	98.7	19.6
Tao 等算法	46.3	97.4

3 结 论

本文提出一种基于三维点云极化地图表征模型的智能车定位算法,以点云极化图 as 节点,采用多尺度渐进定位策略,首先利用 GPS/拓扑结构完成初定位,其次利用点云二维特征完成节点级定位,最后利用点云三维特征完成度量级定位,通过两种典型场景的实验验证,结论如下:

- 1)通过极化地图和点云二维特征定位最近地图节点,整体节点定位准确率,即两种实验场景的平均节点定位准确率,为 98.7%,证明该方法可有效定位最近地图节点。
- 2)通过基于三维点云极化地图表征模型的多尺度定位算法实现智能车定位,整体定位误差,即两种实验场景的平均定位误差,为 21.4 cm,最大定位误差为 42.9 cm,满足智能车高精度定位需求。
- 3)实验中选取了不同的场景和实验车进行测试,均实现了高精度定位,证明本文算法在不同的场景和实验车中具有良好的鲁棒性。同时,本文算法在线定位时,只需要 LiDAR 和普通 GPS 接收机,降低了定位成本。