

基于图优化理论和 GNSS 激光 SLAM 位姿优化算法

陆世东¹, 涂美义^{1*}, 罗小勇², 郭超²

¹湖北省国土资源研究院, 湖北 武汉 430071;

²湖南格纳微信息科技有限公司, 湖南 长沙 410006

摘要 提出一种激光雷达 SLAM(simultaneous localization and mapping)位姿优化算法。该算法基于图优化算法理论并融合 GNSS(global navigation satellite system)数据,在位姿图中加入卫星定位节点,可以有效将无回环时轨迹误差控制在 GNSS 定位误差范围内,有长时性回环时可以准确定位回环检测点,从而达到提高激光雷达 SLAM 位姿全局一致性的效果。在室外刚性特性较好的城市环境和刚性特性较差的非城市环境下进行测试,从结果可以看出:所提算法将在无回环 300 m 距离直线建图情况以及在 360 m 以上距离一次、二次回环情况下的轨迹偏差分别控制在 1 m 左右、0.2 m 以内以及 0.1 m 左右,这充分证明了所提算法的有效性。

关键词 图像处理; 激光雷达; 实时定位与地图构建; 位姿图优化; 全球导航卫星系统

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP57.081024

Laser SLAM Pose Optimization Algorithm Based on Graph Optimization Theory and GNSS

Lu Shidong¹, Tu Meiyi^{1*}, Luo Xiaoyong², Guo Chao²

¹Hubei Provincial Research Institute of Land and Resources, Wuhan, Hubei 430071, China;

²Hunan Glonavin Information Technology Co., Ltd., Changsha, Hunan 410006, China

Abstract In this paper, a LiDAR simultaneous localization and mapping (SLAM) pose optimization algorithm is proposed based on graph optimization theory and global navigation satellite system (GNSS) data. By adding the satellite positioning node into the pose graph, the trajectory error can be effectively controlled within the range of GNSS positioning error when there is no loopback. In long distance loopback, the loopback detection point can be accurately located, which improves the global consistency of the LiDAR SLAM pose graph. The proposed algorithm is tested in the urban environment with better rigidity and in the non-urban environment with weaker rigidity. Experimental results show that the trajectory drift can be controlled to be about 1 m for 300 m straight-line mapping when there is no loopback. In the case of long distance (above 360 m) loopback, the proposed algorithm controls the trajectory drift to be within 0.2 m and about 0.1 m for the primary and the secondary loopback, respectively. These results fully demonstrate the effectiveness of the proposed algorithm.

Key words image processing; LiDAR; simultaneous localization and mapping; pose graph optimization; global navigation satellite system

OCIS codes 100.6890; 010.3640; 120.4640

1 引言

激光雷达 SLAM(simultaneous localization and mapping)是自动驾驶、服务型机器人、测绘等使用的重要手段之一,其一般实现思路是通过两帧点云一一配准累积估计位姿,并使用回环检测及位姿

优化来校正这种长时性匹配误差积累造成的漂移,从而获得全局一致性良好的地图^[1-2]。由于点云采集过程中机器人运动造成点云变形^[3]、连续匹配精度误差造成漂移、回环估计遍历数据量大^[4]、存在回环区域预判误差等多种原因,仅使用激光雷达很难建立一致性好、鲁棒性强的地图,因此,多传感器融

收稿日期: 2019-08-16; 修回日期: 2019-09-23; 录用日期: 2019-09-26

* E-mail: 76235431@qq.com

合方案成为激光雷达 SLAM 普遍选择。

激光雷达传感器与图像传感器融合是一种较好的融合方案,该方案利用图像高结构化数据提取特征以生成特征词典^[5]用于回环检测,与激光雷达非结构化数据互补,从而生成一致性高的地图。Pierzchała 等^[6]通过整合激光雷达、深度相机、IMU (inertial measurement unit)、GPS (global positioning system) 等获取的数据提出一种 SLAM 方法,并将该方法用于森林建图研究中,该方法中深度相机主要用于视觉路标生成。在光线相对稳定的情况下,基于视觉 SLAM 由于图像传感器的特征提取优势,已经成为一个独立的分支^[7-10]。但该方法同时增加了大量图像处理运算开支,难以用于实时系统。

相较于图像传感器增加了大量运算开支,利用全球导航卫星系统 (GNSS) 定位数据和激光雷达 SLAM 融合校正位姿是一种更为经济有效的方法。Soloviev 等^[11]基于卡尔曼滤波算法整合 GPS 数据与激光雷达惯性导航等来实现机器人在城市环境下的导航。Gamma-SLAM^[12]使用 GPS 来提升视觉

SLAM 地图一致性,该算法先使用 RBPF (Rao-Blackwellized particle filters)^[13]累积估计机器人位姿,然后基于奇异值分解和块理论来最小化误差函数。Schleicher 等^[14]提出了一种层次化结构,其在低级子地图中使用一种基于广角相机 EKF_SLAM 方法来整合 GPS 以提高地图一致性,然后基于多层次 GPS 相关性和块理论来整合子地图以形成高一级地图。这些方法主要将 GNSS 数据用于 SLAM 前端,需要依据不同的位姿估计方法进行修改。

因此,本文提出一种融合 GNSS 数据和激光雷达点云的匹配位姿估计方法,直接在位姿优化部分融合 GNSS 数据进行基于 GNSS 路标的增量式位姿校准,而不引入额外 SLAM 地图整合模块,实现了快速历史点云数据匹配回环优化方法及无回环下基于 GNSS 轨迹漂移控制。该方法适用于任意 SLAM 算法(包括视觉 SLAM 算法)复用。

2 算法理论及实现

算法整体框架如图 1 所示。




图 1 算法框架图

Fig. 1 Algorithm framework diagram

图 1 中通过将激光雷达位姿估计结果直接与 GNSS 位置进行整合,构建位姿图,当检测到回环时在位姿图中添加回环约束,然后基于经典位姿图优化理论优化位姿图,继而输出最终位姿。算法适用于 ICP (iterative closest point)^[15]、基于特征匹配配准、随机采样一致性算法等激光雷达位姿估计方法。

2.1 位姿图优化理论

图优化^[16]是求解大规模定位建图问题的有效方法,当不考虑已收敛观测点而只优化位姿构成图(位姿图^[17])时,称之为位姿图优化算法。位姿图优化作为一种轻量级优化方法推进了 SLAM 的发展。

本文使用六维向量 $\xi \in \mathbb{R}^{1 \times 6}$ 来表达雷达位姿,位姿集 $\epsilon = \{\xi_1, \xi_2, \dots, \xi_n\}$ 中任意两个位姿之间的变换(位姿边)可表示为

$$\Delta \xi_{ij} = \xi_i^{-1} \circ \xi_j^{-1} = \ln [\exp(-\xi_i) \exp(\xi_j)]^{\vee}, \quad (1)$$

式中:符号 \circ 为向量反对称矩阵化运算;符号 \vee 为反对称矩阵到向量的运算; $\Delta \xi_{ij}$ 表示相邻位姿之间的

运动,该运动也可以用变换矩阵来描述:

$$\mathbf{T}_{ij} = \mathbf{T}_i^{-1} \mathbf{T}_j, \quad (2)$$

式中: \mathbf{T}_i 、 \mathbf{T}_j 分别表示节点*i*、*j*对应的位姿变换矩阵。误差存在使得实际中(1)式或者(2)式并不会精确成立。针对该问题,采用位姿优化思路,即构造最小二乘误差对变量进行优化以使得误差平方和最小。根据(1)、(2)式可以构造误差方程:

$$\mathbf{e}_{ij} = \ln (\mathbf{T}_{ij}^{-1} \mathbf{T}_i^{-1} \mathbf{T}_j)^{\vee} = \ln \{ \exp [(-\xi_{ij})^{\wedge}] \exp(-\xi_i^{\wedge}) \exp(\xi_j^{\wedge}) \}^{\vee}. \quad (3)$$

对 \mathbf{e}_{ij} 关于各位姿节点优化变量进行求导,即给 ξ_i 和 ξ_j 各施加一个左扰动,使得误差方程转换为

$$\hat{\mathbf{e}}_{ij} = \ln \{ \mathbf{T}_{ij}^{-1} \mathbf{T}_i^{-1} \exp [(-\delta \xi_i)^{\wedge}] \exp(\delta \xi_j^{\wedge}) \mathbf{T}_j \}^{\vee}, \quad (4)$$

式中: $\hat{\mathbf{e}}_{ij}$ 为加扰动后误差。李代数在变换矩阵(特殊欧氏群)上的伴随性质^[18]可表示为

$$\begin{cases} \exp [Ad(\mathbf{T})^{\wedge}] = \mathbf{T} \exp(\xi^{\wedge}) \mathbf{T}^{-1} \\ \exp(\xi^{\wedge}) \mathbf{T} = \mathbf{T} \exp\{ [Ad(\mathbf{T}^{-1})]^{\wedge} \xi^{\wedge} \} \end{cases}, \quad (5)$$

其中 $Ad(\mathbf{T})$ 运算式为

$$Ad(\mathbf{T}) = \begin{bmatrix} \mathbf{R} & t\mathbf{R} \\ 0 & \mathbf{R} \end{bmatrix}. \quad (6)$$

根据(5)式对(4)式进行化简及变换,可得

$$\hat{\mathbf{e}}_{ij} \approx \mathbf{e}_{ij} + \frac{\partial \mathbf{e}_{ij}}{\partial \delta \xi_i} \delta \xi_i + \frac{\partial \mathbf{e}_{ij}}{\partial \delta \xi_j} \delta \xi_j, \quad (7)$$

式中: $\frac{\partial \mathbf{e}_{ij}}{\partial \delta \xi_i} = -\mathbf{J}_r^{-1}(\mathbf{e}_{ij})Ad(\mathbf{T}_i^{-1})$, $\frac{\partial \mathbf{e}_{ij}}{\partial \delta \xi_j} = -\mathbf{J}_r^{-1}(\mathbf{e}_{ij})Ad(\mathbf{T}_j^{-1})$, $-\mathbf{J}_r^{-1} \approx \mathbf{I} + \frac{1}{2} \begin{bmatrix} \hat{\varphi}_e & \hat{p}_e \\ 0 & \hat{\varphi}_e \end{bmatrix}$; \mathbf{I}

为单位矩阵; \mathbf{J}_r^{-1} 为变换矩阵李代数右乘可比矩阵; $\hat{\varphi}_e$ 和 \hat{p}_e 分别是 $\hat{\mathbf{e}}_{ij}$ 旋转和平移部分反对称矩阵。

对误差函数关于优化变量进行求导后,位姿优化算法可表示为

$$\min_{\xi} \frac{1}{2} \sum_{i,j \in \epsilon} \mathbf{e}_{ij}^T \boldsymbol{\Sigma}_{ij}^{-1} \mathbf{e}_{ij}, \quad (8)$$

式中: $\boldsymbol{\Sigma}_{ij}^{-1}$ 为信息矩阵,为位姿估计变量协方差矩阵的逆。该函数可使用高斯牛顿法或者列文伯格-马夸尔特方法求得最优解,本文主要工作是将 GNSS 位置位姿数据 ξ_i 代入其中以获得雷达 SLAM 的最

优位姿估计。

2.2 整合 GNSS 数据和 SLAM 位姿

GNSS 数据虽然并不精准但是具有不发散特性^[19],这种特性可以用来进行激光 SLAM 概率路标设置。概率路标不是精准位置但是它保证了 SLAM 轨迹漂移在一个可控范围之内,可以有效应对 SLAM 长时性漂移。所以,在传统 SLAM 位姿图中加入 GNSS 概率路标可优化位姿。加入 GNSS 概率路标后的位姿图如图 2 所示。

图 2 中实心圆点代表从 GNSS 数据获得并变换的本地横轴墨卡托投影坐标。虚线表示机器人运动轨迹,三角符号代表机器人根据激光雷达采样频率进行更新的位姿数据,实心三角表示和 GNSS 时间对齐采样处机器人位姿。位姿向量坐标可表示为

$$\xi = (x_r, y_r, z_r, R, P, Y), \quad (9)$$

式中: (x_r, y_r, z_r) 表示位姿向量在雷达坐标系中的坐标; R, P, Y 分别表示向量的横滚、俯仰、偏航角度。(9)式代表每个机器人点云配准约束估计,其表达式是(2)式变换矩阵或者(3)式李代数表达。




图 2 加入 GNSS 定位数据后的位姿图

Fig. 2 Pose graph integrated with GNSS position data

初始时间及位置机器人和 GNSS 时间对准后,经过 N 个位姿点得到位姿点 ξ_i 和其对应 GNSS 数据观测值 g_j (图 2)。先进行点云配准精度误差估计,然后在该估计上整合 GNSS 数据和对应位姿点,以控制整体误差在一定范围。假设点云配准位

置估计精度与激光雷达移动速度为线性关系并且符合高斯分布模型,其估计精度与机器人移动速度成反比(当机器人运动过于剧烈时,单位时间内两帧点云间距离或旋转差异变大会造成点云位姿估计精度降低),位置估计误差如图 3 所示。




图 3 点云配准位姿估计精度示意图

Fig. 3 Accuracy of point cloud registration pose estimation

图 3 中速度 $v = S/t$, 其中: t 为点云配准采样周期常数, 实际系统中为激光雷达数据采样频率; S 为位置估计两点真实曼哈顿距离。设 Σ_{r_0} 为速度为 0 时点云位置估计协方差矩阵, 定义 $\Sigma_{rv} = v\Sigma_{r_0}/k$ 为速度 v 情况下点云位置估计协方差矩阵, 其中 k 为点云位置估计误差增益常数。实际应用中只能得到带误差观测值 $S' = S + \delta S$, 并且假设 δS 随 S 呈线性增加, 将速度 v 情况下点位置估计协方差矩阵定义为

$$\Sigma_{rv} = (v + \lambda)\Sigma_{r_0}/k, \quad (10)$$

式中: λ 为速度 v 下位置协方差误差估计值。根据 (10) 式可以近似估计任一时刻位姿点协方差矩阵 $\Sigma_{ir} (i = 1, 2, \dots, n)$ (这里用 i 表示机器人位姿序列), 则任意位姿及 GNSS 位置数据整合精度估计矩阵可以表示为

$$\mathbf{A} = \sum_{i=1}^N \Sigma_{ir}^{-1} + \Sigma_{gj}^{-1}, \quad (11)$$

式中: Σ_{ir} 为各个位姿节点协方差矩阵; Σ_{gj} 为当前 GNSS 数据协方差矩阵; \mathbf{A} 为数据整合精度估计矩阵。当前整合的机器人位置精度可信度为

$$\mathbf{A}_{ri} = \mathbf{A}^{-1} \Sigma_{ir}^{-1}. \quad (12)$$

当前整合的 GNSS 位置精度可信度为

$$\mathbf{A}_{gj} = \mathbf{A}^{-1} \Sigma_{gj}^{-1}. \quad (13)$$

当前位姿节点位置参数和 GNSS 数据整合后的位姿位置参数为

$$\xi_{iT} = \mathbf{A}_{ri} \mathbf{T}_r + \mathbf{A}_{gj} \mathbf{g}_j, \quad (14)$$

式中: \mathbf{T}_r 为当前机器人位置数据 (位姿前三维)。(12)、(13) 式分别对机器人位置精度可信度和 GNSS 位置精度进行了估计, 可以看出: 在 \mathbf{A}^{-1} 一致的情况下 \mathbf{A}_{gj} 和 \mathbf{A}_{ri} 对当前位置节点 ξ_{iT} 的影响程度取决于两者精度, 其精度越高则其估计对当前节点影响占比越大, 表现为位姿图中系统运行时间越长,

点云位置估计整体可信度 $\sum_{i=1}^N \Sigma_{ir}^{-1}$ 越低, 从而使得结果越偏向于 GNSS 的位姿估计 \mathbf{A}_{gj} 。为充分利用位姿估计中的点在短时间内的有效性, 在每一次 GNSS 及位姿整合后更新当前位点误差估计协方差矩阵:

$$\Sigma_{ir} = \mathbf{A}^{-1}. \quad (15)$$

本文 GNSS 和姿态数据整合利用了卡尔曼估计朴素思想, 设计了点云配准姿态估计模型, 并在无 GNSS 数据时进行每个节点误差估计, 当有 GNSS 数据时进行 GNSS 数据和当前位姿位置数据的无偏估计, 从而实现 GNSS 与 SLAM 位姿数据融合。

2.3 使用 GNSS 数据优化位姿

2.3.1 整体位姿优化

GNSS 数据和激光 SLAM 结合整体位姿优化主要是纠正明显错误。考虑一种机器人长时性运动无回环情况, 这时机器人 SLAM 的误差累积随着时间增加, 其漂移越来越大, 最终对应点将明显漂出 GNSS 数据精度范围之外, 如图 4 所示。

在图 4 中, 同步 GNSS 和 SLAM 数据采集设备时间后, 确定一个初始点。随着机器人运动, 基于点云配准进行里程计估计同时存储位姿和轨迹数据。GNSS 位置和姿态数据整合在 SLAM 轨迹漂移变大时将其“拉回”一个可靠精度范围内, 这种“拉回”效应表现为 (11) 式, 其中 $\sum_{i=1}^N \Sigma_{ir}^{-1}$ 表示位置累积精度, 当处于长时性无回环运动时该精度会越来越低, 而 GNSS 的精度则在一个稳定值, 当位姿累积精度明显低于 GNSS 精度时, 在数据整合中 GNSS 数据可信度 \mathbf{A}_{gj} 远大于位姿位置可信度 \mathbf{A}_{ri} , 此时当前位姿值将以 GNSS 数据为主导, 从而保证轨迹漂移在一个稳定的范围内, 见 (12)~(14) 式。




图 4 无回环 GNSS-SLAM 位姿修正

Fig. 4 GNSS-SLAM pose correction when there is no loopback

当 GNSS 数据和位姿节点数据进行整合后, 得到一个纯位姿构成图, 然后对该图进行优化, 整体算

法流程如下:

- 1) 构建位姿图。(1) 根据 GNSS 测试参数, 初

始化 Σ_g ; (2) 静态点云配准测试, 初始化 Σ_{r0} ; (3) 初始化点云位置估计误差增益 k 及速度误差增益 λ [(10)式]; (4) 固定轨迹及速率下调整 k 和 λ ; (5) GNSS 雷达时间对齐, 求解累积位姿信息矩阵; (6) GNSS 位姿数据整合, 更新位姿信息矩阵。

2) 构建目标函数。(1) 根据(3)式, 构建误差函数; (2) 根据步骤 1) 的信息矩阵依次求解节点误差并进行求和, 得到(8)式所示目标函数。

3) 求解目标函数。(1) 根据(7)式对目标函数关于各优化变量求一阶偏导; (2) 令所求导数为 0; (3) 线性化误差方程; (4) 使用迭代法(LM)求解该线性方程, 使误差平方和最小; (5) 输出校正位姿, 并根据该位姿变换将对应激光点云变换到地图坐标系下。

2.3.2 回环优化

回环优化思路是寻找当前 SLAM 数据和历史数据或者历史数据和历史数据之间的关系, 以形成更好约束, 从而保证地图一致性。目前回环检测方法有全历史数据匹配^[20]、随机历史数据匹配^[21]、分块回环与绑定方法^[22]等。这些方法因为不能获得回环出现位置估计, 都需要大量的历史数据匹配, 而且在长时性无回环情形时极易因位姿估计误差过大而失效。

本文算法可以有效应对长时性位姿漂移情况, 位姿节点的 GNSS 数据虽然不是精准位置, 但其在误差精度内具有很高可信度, 位姿节点位置匹配可以在历史数据中准确找出任意历史时间段内出现在该范围内的 SLAM 数据, 从该数据段中进行回环检测实现回环优化。回环优化示意图如图 5 所示。

图 5 中机器人绕着圆形围墙运动(图中实心三角表示机器人主体, 箭头方向表示运动方向), 当经过一段较长时间后, 机器人回到出发点附近, 但由于




图 5 回环优化示意图

Fig. 5 Diagram of loop closure optimization

存在传感器数据采集误差及算法处理精度误差, 机器人运算得到的轨迹如图 5 中外围实线所示, 在该较大偏差及点云特征高度相似的情况下, 传统处理方法已经难以根据特征、里程计或者时间相关性来判断回环可能出现的位置。

通过分析点云位姿估计算法对不同距离位移点云配准的准确度, 发现 5 m 以内具有较高可信度。综合考虑雷达载体的移动速度(正常步行速度为 1 m/s 左右), 设置回环距离参数为 3 m(该值处于 2 倍 GNSS 位置精度范围内), 历史时间间隔为 3 s。当到达未知区域并且得到点云测量值和 GNSS 位置数据后在历史位姿(3 s 前)中寻找距离小于回环距离参数的位姿, 当存在该类位姿时, 使用当前测量值和对应位姿及其附近多个位姿对应点云进行匹配, 若是在该匹配中找到有效变换估计, 则在对应位姿和当前位姿之间添加一条回环边, 以保证得到能促进全局一致性的回环约束。




图 6 回环检测示意图

Fig. 6 Loop closure detection diagram

图 6 中黑点表示机器经过 N 个位姿后回到接近历史位姿位置, 轨迹首尾接近处的连接边表示当前测量和历史某一测量的约束估计(回环)。基于 GNSS 的位姿优化在回环检测时不需要将当前测量数据与所有历史数据进行比较, 而只需要对 GNSS 位置上相近数据进行分析, 该方法可以在保证回环被检出的同时极大节约运算开支。

3 实验分析

本文实验硬件构成如图 7 所示。该系统使用一个 16 线激光雷达作为 SLAM 主传感器, 激光测量数据将用于位姿累积估计, 将 GNSS 定位模块嵌入激光雷达挂载底座中, 并将主要运算模块、能源模块等置于背包中以便携带。

本文算法的实验软硬件相关信息如表 1 所示。为了验证本文算法, 在环境特征刚性较强的城市环境下进行了无回环和回环实时 SLAM 建图测试。




图7 实验硬件图

Fig. 7 Hardware picture of experiment

表1 实验软硬件相关说明及参数

Table 1 Experimental software and hardware related instructions and parameters

Hardware		Software	
Sensor	Models (parameters)	Name	Version
LiDAR	Robosense RS-LiDAR-16	Operating System	Ubuntu16.04 LTS
	(ranging accuracy ± 0.02 m, distance measuring range of 100–150 m)		
GPS module	Glonavin GNSS Single site location module	ROS	Kinetic
	(Horizontal position precision 1 m, vertical position precision 2 m)	(robot operating system)	
Hardware platform	CPU (Intel i7 8core 1.8 GHZ), RAM(16 GB)	Point cloud registration algorithm	ICP




图8 城市环境无回环测试。(a)加入 GNSS 位姿优化;(b)不加入 GNSS 位姿优化

Fig. 8 Test without loopback in urban environment. (a) With GNSS pose optimization;

(b) without GNSS pose optimization

图9中整体路径长度为728 m。可以看到;轨迹角度变化时产生了严重漂移,特别是当回环间隔时间较长时,已经难以从大量历史数据中找出产生回环的数据[图9(b)]。而利用GNSS位姿优化实时建图时,可以依据位置信息来定位历史数

图8测试场景中测试路径长度为302 m,图8(a)为使用GNSS位姿优化实时建图效果,图8(b)为使用非GNSS位姿优化实时建图效果,白色圆点表示建图起始位置。以第一个建筑外墙为基准作一条参考直线,则在无GNSS位姿优化时,一段时间后,累积误差使得建图开始偏移,并且这种偏移随着建图规模的增大而递增,而加入了GNSS位姿优化实时建图则表现出更好的一致性。

该实验中尽量保证行进轨迹成一条直线,以观察位姿估计偏差情况,可以看到;在刚性城市环境下这种纯ICP位姿估计偏差“似乎在一个可以接受范围内”,但当加入部分转向时情况则开始发生变化,如图9所示。

据并进行回环处理,从而保证了地图一致性[图9(a)]。

为进一步观察GNSS位姿优化对环境的适应性,选择环境特征刚性较弱的非城市环境进行回环和非回环两种实验分析。




图9 城市环境回环测试。(a)加入 GNSS 位姿优化;(b)不加入 GNSS 位姿优化

Fig. 9 Loop trajectory test in urban environment. (a) With GNSS pose optimization; (b) without GNSS pose optimization

图 10 为一山地环境,其最近建筑到测试场所的距离在激光雷达测距范围之外。树叶等受环境(风等)影响较大,激光点云特征刚性较建筑弱,这在一定程度上会增加 ICP 位姿估计精度误差。图 10(b)中无回环无 GNSS 位姿优化情况下,纯 ICP 位姿估计在轨迹末端产生了反向运动的明显错误(这是由大量相似及不稳定特征干扰导致),并且

在高程上产生了严重漂移(横灰色线为水平面网格)。而加入 GNSS 位姿优化建图无论是在水平漂移还是高程漂移上都得到更好的效果。在同一环境下,测试路径在图 10 所示的交叉路口绕山体行进,使得建图轨迹产生回环,观察 GNSS 优化和非 GNSS 优化效果。其实际环境图片如图 11 所示。




图 10 非城市环境无回环测试。(a)加入 GNSS 位姿优化;(b)不加入 GNSS 位姿优化

Fig. 10 Test without loopback in non-urban environment. (a) With GNSS pose optimization; (b) without GNSS pose optimization



图 11 非城市环境实景图

Fig. 11 Picture of non-urban environment

图 11 中弧形箭头表示回环路径,直箭头表示非回环测试场景。图 12 所示测试路径为逆时针绕山体两周,可以看到:当第一圈接近出发点时,非 GNSS 位姿优化因为相似特征检测到了错误回环,造成后期更大漂移及错误位姿估计,而 GNSS 位姿优化算法在环境特征刚性降低情况下依然达到很好的效果,生成了一致性良好的地图。

使用 CloudCompare 开源点云显示与分析软件量化分析上述实验结果。在非回环场景下(图 8、图 10)取起止点,回环场景下(图 9、图 12)取两次轨迹回到出发点处,分别统计距离、水平和高程偏差,如表 2 所示。




图 12 非城市环境回环测试。(a)加入 GNSS 位姿优化;(b)不加入 GNSS 位姿优化
 Fig. 12 Loop trajectory test in non-urban environment. (a) With GNSS pose optimization;
 (b) without GNSS pose optimization

表 2 轨迹偏移对比表
 Table 2 Trajectory drift comparison

Experiment			With GNSS pose optimization			Without GNSS pose optimization		
			δd	δy	δz	δd	δy	δz
Without loopback	Urban		1.11	0.07	0.97	3.83	0.35	3.56
	Non-urban		0.62	0.17	0.09	25.25	14.30	3.32
Loop trajectory	Urban	First loop drift	0.20	0.12	0.15	30.21	8.98	15.38
		Second loop drift	0.11	0.10	0.08	51.95	10.30	39.76
	Non-urban	First loop drift	0.16	0.14	0.05	5.52	4.92	0.33
		Second loop drift	0.10	0.09	0.04	77.49	19.30	55.75

表 2 中 δd 、 δy 、 δz 分别代表距离、水平、高程偏差。在非回环情况下该数据由量算起止点激光点云坐标和测量仪器测量值比较得到,在回环情况下则通过量算起始点激光点云前后两次坐标得到。通过偏差情况对比,可知无论是非回环还是回环情况,GNSS 位姿优化 SLAM 算法明显优于非 GNSS 位姿优化算法,在回环情况下,这种优势更为明显。表 2 中非城市情况下无 GNSS 位姿优化第一环距离偏差为 5.52 m,这是一个错误回环估计,这种错误使得第二环建图效果急剧恶化,距离偏差在第二环建图中达 77.49 m。而 GNSS 位姿优化回环情况下距离偏差在亚米级,非回环情况下也可控制在 GNSS 单点定位精度内(GNSS 单点定位精度见表 1)。

4 结 论

针对激光 SLAM 点云位姿估计因误差累积而出现漂移问题,基于位姿图优化理论和 GNSS 定位提出了一种 SLAM 位姿优化方法。该方法通过直接融合 GNSS 位置数据和 SLAM 位姿图,在位姿图中加入概率路标,使用该位置数据对 SLAM 位姿进

行无偏估计来提高位姿数据准确性。相较于传统 GNSS 融合 SLAM 方法,本文算法有以下特点:

1) 直接在位姿图层次整合 GNSS 数据。这有效解决了传统传感器数据融合方法需要针对不同传感器特性设计对应算法的弊端,使得在不同 SLAM 算法上都可简单设置复用该算法模块。

2) GNSS 与位姿无偏估计方法。该算法直接对位姿和 GNSS 数据进行无偏估计,是对卡尔曼滤波理论的一种创新性运用,可为使用 GNSS 进行大规模 SLAM 建图优化算法提供一定的理论及实践支持。

本文算法在城市建筑环境和非建筑环境下分别对有、无回环情况进行实验验证,实验结果表明:利用 GNSS 位置融合位姿优化算法,在无回环长距离(300 m 以上)建图时能将误差有效控制在 2 m 以内,长距离(360 m 以上)回环时能有效找到回环点,并将偏差有效控制在 0.2 m 以内。本文算法不考虑位姿估计过程,实现简单,可以应用于室外服务型机器人建图导航等领域。本文算法实现中采用了全点云 ICP 算法估计位姿,存储和运算消耗较大,而使

用基于特征匹配方法优化点云配准的方法可以降低存储和运算消耗,适用于嵌入式等设备,是下一步需要研究的问题。

参 考 文 献

- [1] Liu M, Shu Q, Yang Y X, et al. Three-dimensional point cloud registration based on independent component analysis [J]. *Laser & Optoelectronics Progress*, 2019, 56(1): 011203.
刘鸣, 舒勤, 杨赞秀, 等. 基于独立成分分析的三维点云配准算法[J]. *激光与光电子学进展*, 2019, 56(1): 011203.
- [2] Liu Q, Duan F H, Sang Y, et al. A survey of loop-closure detection method of visual SLAM in complex environments[J]. *Robot*, 2019, 41(1): 112-123, 136.
刘强, 段富海, 桑勇, 等. 复杂环境下视觉 SLAM 闭环检测方法综述[J]. *机器人*, 2019, 41(1): 112-123, 136.
- [3] Alismail H, Baker L D, Browning B. Continuous trajectory estimation for 3D SLAM from actuated lidar [C] // 2014 IEEE International Conference on Robotics and Automation (ICRA), May 31-June 7, 2014, Hong Kong, China. New York: IEEE, 2014: 6096-6101.
- [4] Wen G C, Zeng B, Chen Y H. Loop closure detection method for large scale map of laser SLAM [J]. *Application Research of Computers*, 2018, 35(6): 1724-1727, 1732.
文国成, 曾碧, 陈云华. 一种适用于激光 SLAM 大尺度地图的闭环检测方法[J]. *计算机应用研究*, 2018, 35(6): 1724-1727, 1732.
- [5] Galvez-López D, Tardos J D. Bags of binary words for fast place recognition in image sequences [J]. *IEEE Transactions on Robotics*, 2012, 28(5): 1188-1197.
- [6] Pierzchała M, Giguère P, Astrup R. Mapping forests using an unmanned ground vehicle with 3D LiDAR and graph-SLAM[J]. *Computers and Electronics in Agriculture*, 2018, 145: 217-225.
- [7] Davison A J, Reid I D, Molton N D, et al. MonoSLAM: real-time single camera SLAM [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(6): 1052-1067.
- [8] Chen W, Wu T, Li Z, et al. A monocular vision SLAM algorithm based on particle filter[J]. *Robot*, 2008, 30(3): 242-247, 253.
陈伟, 吴涛, 李政, 等. 基于粒子滤波的单目视觉 SLAM 算法[J]. *机器人*, 2008, 30(3): 242-247, 253.
- [9] Zhang Y, Chen Q, Luo Y. Three dimensional visual SLAM for mobile robots in indoor environments[J]. *CAAI Transactions on Intelligent Systems*, 2015, 10(4): 615-619.
张毅, 陈起, 罗元. 室内环境下移动机器人三维视觉 SLAM[J]. *智能系统学报*, 2015, 10(4): 615-619.
- [10] Lin H C, Lü Q, Wei H, et al. Quadrotor autonomous flight and three-dimensional dense reconstruction based on VI-SLAM[J]. *Acta Optica Sinica*, 2018, 38(7): 0715004.
林辉灿, 吕强, 卫恒, 等. 基于 VI-SLAM 的四旋翼自主飞行与三维稠密重构[J]. *光学学报*, 2018, 38(7): 0715004.
- [11] Soloviev A, Bates D, van Graas F. Tight coupling of laser scanner and inertial measurements for a fully autonomous relative navigation solution [J]. *Navigation*, 2007, 54(3): 189-205.
- [12] Marks T K, Howard A, Bajracharya M, et al. Gamma-SLAM: using stereo vision and variance grid maps for SLAM in unstructured environments[C] // 2008 IEEE International Conference on Robotics and Automation, May 19-23, 2008. Pasadena, CA, USA. New York: IEEE, 2008: 3717-3724.
- [13] Murphy K, Russell S. Rao-blackwellised particle filtering for dynamic Bayesian networks[M] // Doucet A, de Freitas N, Gordon N. *Sequential Monte Carlo methods in practice. Statistics for engineering and information science*. New York, NY: Springer, 2001: 499-515.
- [14] Schleicher D, Bergasa L M, Ocaña M, et al. Real-time hierarchical GPS aided visual SLAM on urban environments [M] // Moreno-Diaz R, Pichler F, Quesada-Arencibia A. *Computer aided systems theory-EUROCAST 2009. Lecture notes in computer science*. Berlin, Heidelberg: Springer, 2009, 5717: 326-333.
- [15] Chen X, He B W. A fast global registration algorithm based on correcting point cloud principal component coordinate system [J]. *Laser & Optoelectronics Progress*, 2018, 55(6): 061003.
陈旭, 何炳蔚. 一种基于校正点云主成分坐标系的快速全局配准算法[J]. *激光与光电子学进展*, 2018, 55(6): 061003.
- [16] Cadena C, Carlone L, Carrillo H, et al. Past, present, and future of simultaneous localization and mapping: toward the robust-perception age[J]. *IEEE*

- Transactions on Robotics, 2016, 32(6): 1309-1332.
- [17] Latif Y, Cadena C, Neira J. Robust loop closing over time for pose graph SLAM[J]. The International Journal of Robotics Research, 2013, 32(14): 1611-1626.
- [18] Iserles A, Munthe-Kaas H Z, Nørsett S P, et al. Lie-group methods [J]. Acta Numerica, 2000, 9: 215-365.
- [19] Carlson J. Mapping large, urban environments with GPS-aided slam [D]. Pittsburgh: Carnegie Mellon University, 2010: 49-71.
- [20] Endres F, Hess J, Sturm J, et al. 3-D mapping with an RGB-D camera [J]. IEEE Transactions on Robotics, 2014, 30(1): 177-187.
- [21] Shan T X, Englot B. LeGO-LOAM: lightweight and ground-optimized lidar odometry and mapping on variable terrain [C] // 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 1-5, 2018. Madrid, Spain. New York: IEEE, 2018: 4758-4765.
- [22] Hess W, Kohler D, Rapp H, et al. Real-time loop closure in 2D LIDAR SLAM [C] // 2016 IEEE International Conference on Robotics and Automation (ICRA), May 16-21, 2016. Stockholm, Sweden. New York: IEEE, 2016: 1271-1278.