

基于改进 Gmapping 算法的果园二维环境地图精准构建

薛金林 王培晓 周俊 程峰
(南京农业大学工学院, 南京 210031)

摘要: 果树树冠的季节性变化及果树成长和衰老造成的果树特征变化会影响已构建的果园三维环境地图的匹配, 故本文提出一种基于改进 Gmapping 算法的果园二维环境地图精准构建算法。首先该算法对 Gmapping 算法的前端里程计和后端优化部分分别进行改进, 以提高果园二维环境地图的构建精度。对于前端里程计部分采用改进的 R-GPF 地面分割方法提高其初始定位精度, 对于后端优化部分采用 BAT 启发式自适应重采样方法提高其最终定位精度。然后进行梨园环境对比试验。通过改进 R-GPF 方法与原始 R-GPF 方法的对比, 改进 R-GPF 方法的激光雷达里程计输出频率可达到 15.58 Hz, 最大横向偏差小于 25 cm, 横向偏差均值为 12.7 cm, 标准差为 13.4 cm, 其各方面性能都优于原 R-GPF 方法的激光雷达里程计。通过新算法与基于原 R-GPF 的 Gmapping 算法对比, 新算法所得的梨树列间距离偏差始终保持在 20 cm 范围内, 行间距离偏差均值为 10.3 cm, 标准差为 6.3 cm, 比基于原 R-GPF 的 Gmapping 算法分别减小 50%、43.41% 和 32.26%; 同时, 梨树行间距离偏差相对于里程计横向偏差的减小侧面反映出后端 BAT 启发式自适应重采样方法的有效性。本文提出的算法能够提高果园二维地图构建精度, 可以满足后续重定位、导航等作业的精度要求。

关键词: 果园; 二维地图; 地面分割; 激光雷达里程计; BAT 自适应重采样

中图分类号: S232.3; TP242.6 文献标识码: A 文章编号: 1000-1298(2023)07-0026-09 OSID: 

Accurate Construction of Orchard Two-dimensional Environmental Map Based on Improved Gmapping Algorithm

XUE Jinlin WANG Peixiao ZHOU Jun CHENG Feng
(College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

Abstract: Seasonal changes of fruit tree crowns and changes of fruit tree characteristics caused by the growth and aging of fruit trees will affect the matching of the three-dimensional environmental map of the orchard. Therefore, an accurate construction algorithm of orchard two-dimensional environmental map was proposed based on improved Gmapping algorithm. In this algorithm, the front-end odometer and the back-end optimization part of Gmapping algorithm were improved respectively, so as to improve the construction accuracy of two-dimensional environment map of orchard. For the front-end odometer part, the improved R-GPF method was used to improve its initial positioning accuracy, and for the back-end optimization part, the BAT heuristic adaptive resampling method was used to improve its final positioning accuracy. Then, the comparative experiment of pear orchard environment was carried out. By comparing the improved R-GPF method with the original R-GPF method, the output frequency of the improved R-GPF LiDAR odometer can reach 15.58 Hz, the maximum lateral deviation was less than 25 cm, the average lateral deviation was 12.7 cm, and the standard deviation was 13.4 cm, its performance was superior to that of the original R-GPF LiDAR odometer. Comparing the proposed algorithm with the original Gmapping algorithm based on R-GPF, the distance deviation between pear columns obtained by the proposed algorithm was always within 20 cm, and the average distance deviation between rows was 10.3 cm, with a standard deviation of 6.3 cm, which was 50%, 43.41% and 32.26% lower than that of the original Gmapping algorithm based on R-GPF, respectively. At the same time, the reduction of the

收稿日期: 2022-11-19 修回日期: 2023-01-03
基金项目: 江苏省现代农机装备与技术示范推广项目(NJ2021-38)、江苏现代农业产业技术体系建设专项资金项目(JATS[2021]483)和南京市现代农机装备与技术创新示范项目(NJ[2022]07)
作者简介: 薛金林(1974—),男,教授,博士,主要从事农业车辆测控技术和智能化研究,E-mail: xuejinlin@njau.edu.cn

distance deviation between pear rows relative to the lateral deviation of odometer reflected the effectiveness of the back-end BAT heuristic adaptive resampling method. The proposed algorithm can improve the accuracy of orchard two-dimensional map construction, and meet the accuracy requirements of subsequent relocation, navigation and other operations.

Key words: orchard; two-dimensional map; ground segmentation; LiDAR odometer; BAT adaptive resampling

0 引言

果园作业机器人的定位与导航技术研究主要集中于基于 SLAM 算法的果园环境地图构建研究, 果园环境地图能否实现精准构建直接影响后续定位与导航作业的效果。

在众多环境信息获取传感器中, 激光雷达以其不易受光照影响、精度和实时性高等优点被广泛应用^[1-3]。针对激光 SLAM 算法, 典型的三维环境地图构建算法有基于 3D 特征匹配的 LOAM 算法^[4-5]和 LeGO-LOAM 算法^[6]。LOAM 算法通过提取环境中面特征和线特征进行帧间匹配, 特征匹配效果良好, 地图构建较为精准。LeGO-LOAM 算法凭借基于线的地面分割方法提取地面点, 有效提升了算法整体的速度。上述三维地图构建算法虽然实现了果园环境的精准构建, 但果树树冠的季节性变化及果树的成长和衰老造成的果树特征变化不利于后续的地图匹配, 为解决此问题有部分研究针对果园中树干这一不变特征进行二维环境地图构建。针对较小的简单果园场景, 张莹莹等^[7]对 DBSCAN 算法采用自适应密度阈值和聚类半径实现对果园树干地图的精准构建; GRISSETTI 等^[8]提出的 Gmapping 算法以较小的计算量实现了稳定且较高精度的地图构建。但对于特征复杂的大场景果园, 张莹莹提出的改进 DBSCAN 算法在作业机器人转向角度过大时可能超出阈值范围造成树木的漏检; Gmapping 算法基于 3D 点云匹配方法的 ICP 前端里程计在后期累计误差较大^[9], 并且后端优化部分对前端里程计的初始定位信息的优化效果有限, 导致最终的定位精度较低, 不利于精准二维地图的构建。LIM 等^[10]采用了鲁棒的基于多平面的 R-GPF 地面分割方法, 有效提高了前端里程计精度, 但该方法在面对果园内较为竖直的果树树干和低矮平缓的草坪或灌木时可能分割失败。针对后端优化, ROH 等^[11]提出的改进 PSO 粒子群优化算法的前期优化效果稳定, 但在迭代后期由于无法权衡全局搜索的程度易陷入局部最优的困境。

本文对 Gmapping 算法进行改进, 前端里程计以 LeGO-LOAM 测程框架为底层, 针对果园实际环境对 R-GPF 方法的探测区模型和地面点估计方法进

行相应改进, 提高果园内地面分割效果, 进而获得高精高频的激光雷达里程计。后端优化部分采用一种受蝙蝠寻找猎物行为启发的自适应重采样方法实现对初始定位信息的有效和合理程度的优化, 以提高最终的定位精度, 从而获得精准的果园环境地图。

1 精准果园环境地图构建方法

本文提出的精准果园环境地图的构建算法需要对 Gmapping 算法的前端里程计和后端优化部分进行改进, 其中前端里程计用基于改进 R-GPF 方法的激光雷达里程计模块进行替换, 后端优化 Rao-Blackwellised 粒子滤波器^[12]的重采样方式采用 BAT 启发式自适应重采样, 基于改进 Gmapping 算法的精准地图构建算法框架如图 1 所示。




图 1 精准地图构建算法框架

Fig. 1 Framework of precision map construction algorithm

1.1 精准地图构建算法整体流程

基于改进 Gmapping 算法的整体流程就是实现作业平台的位姿预估和利用预估位姿最终实现地图的获取。位姿预估即作业平台依靠激光雷达观测信息 $z_{1:t} = z_1, z_2, \dots, z_t$ 与前端里程计信息 $u_{1:t-1} = u_1, u_2, \dots, u_{t-1}$ 进行后端优化得到最终定位信息 $x_{1:t} = x_1, x_2, \dots, x_t$, 即求解自身位姿的后验概率分布 $p(x_{1:t} | z_{1:t}, u_{1:t-1})$, 后端优化步骤概括如下:

(1) 粒子初始化。 $t = 0$ 时刻, 初始化 n 个权重相等即 $\omega_0^i = 1/n$ 的粒子构成粒子集合 $\{x_0^i\}$ 。

(2) 采样。结合 $p(x_t | x_{t-1}, u_t)$ 进行粒子的传播, 粒子集 $\{x_t^i\}$ 由上一时刻粒子集产生。

(3) 权重计算。通过重要性采样公式计算粒子权重 ω_t^i 。

$$\omega_t^i = \frac{p(x_{1:t}^i | z_{1:t}, u_{1:t})}{q(x_{1:t}^i | z_{1:t}, u_{1:t})} = p(z_t | m_{t-1}^i, x_t^i) \omega_{t-1}^i \quad (1)$$

得到权重迭代公式(其中 $q(x_{1:t}^i | z_{1:t}, u_{1:t})$ 表示未将当前时刻的测量值 z_t 考虑进去的先验概率 $p(x_{1:t}^i | z_{1:t-1}, u_{1:t})^{[13]}$)。

再进行权重归一化处理

$$\hat{\omega}_t^i = \omega_t^i / \sum_{i=1}^n \omega_t^i \quad (2)$$

式中 $\hat{\omega}_t^i$ ——归一化处理后 t 时刻第 i 个粒子的权重

(4)重采样。根据归一化后得到的权重进行重采样,权重较大的粒子得以保留,权重较小的粒子予以剔除。重采样结束后,可计算获得最终定位信息,同时所有粒子的权重都重新设置为 $1/n_r$, n_r 为剩余粒子数。

最后进行地图更新。根据历史观测信息 $z_{1:t}$ 和步骤(4)获得的最终定位信息计算 $p(m | x_{1:t}, z_{1:t})$, 实现地图更新。

1.2 基于改进 R-GPF 地面分割方法的激光雷达里程计

图 1 里程计模块以 LeGO-LOAM 框架为底层,并将 LeGO-LOAM 基于线的地面分割方法用改进 R-GPF 方法代替,测程过程概括为以下 4 个步骤:①基于改进 R-GPF 方法进行地面分割,识别得到地面点。②将全部点云和地面点分别进行点云投影。③基于投影图像中的平滑度提取边缘特征和平面特征。④利用特征的对应关系,获得连续扫描之间的变换矩阵来估计测程。激光雷达里程计框架如图 2 所示。




图 2 激光雷达里程计框架

Fig. 2 Framework of laser radar odometer

1.2.1 地面分割问题定义

首先,将激光雷达捕获的 N 个三维点云组成点云集合 P , 设定 $P = \{p_1, p_2, \dots, p_k, \dots, p_N\}$, 其中每个点云 $p_k = \{x_k, y_k, z_k\}$ 。同时点云 P 可以被分为两类:实际地面点 G 及实际非地面点 G^c , 非地面点包括行人、灌木、果树的树干和树冠等, 它们满足 $G \cup G^c = P$ 。接下来, 点云 P 进行地面分割后, 估计的地面点和非地面点可以定义为 $\tilde{G}$ 和 $\tilde{G}^c$ 。由于地面

分割方法难免会产生误差,一些实际上来自非地面对象的点可能被评估在 $\tilde{G}$ 中,将此类点定义为 FP, 同时将被评估在 $\tilde{G}$ 中的实际地面点定义为 TP;一些实际上来自地面对象的点可能被评估在 $\tilde{G}^c$ 中,将此类点定义为 FN,同时将被评估在 $\tilde{G}^c$ 中的实际非地面点定义为 TN。综上所述, $\tilde{G}$ 和 $\tilde{G}^c$ 表示为

$$\begin{cases} \tilde{G} = TP \cup FP \\ \tilde{G}^c = FN \cup TN \end{cases} \quad (3)$$

因此,地面分割方法的目标是从点云 P 中识别出 $\tilde{G}$ 和 $\tilde{G}^c$, 并尽可能少地获得 FPs 和 FNs。

1.2.2 探测区模型

LeGO-LOAM 使用激光雷达位于不同水平分辨率上同一直线上任意两点之间的角度差来提取地面,它往往对某些噪声很敏感,如崎岖不平的地面,草坪或灌木丛也会阻碍地面分割,因为它们的形状梯度是任意的。鉴于基于线的地面分割方法易受干扰,因此提出了鲁棒的基于多平面的 R-GPF 地面分割方法,该方法以激光雷达为坐标原点建立二维圆形探测网格,再根据点云的三维坐标进行空间上点云的多平面分布。

R-GPF 方法的探测网格 M 沿径向和周向进行规则划分,最终形成环区和扇区,其中 N_r 和 N_θ 分别是环数和扇区的数目,这样 M 最终将分为径向距离为 $R_{\max}/N_r$, 对应轴向角为 $2\pi/N_\theta$ 的 $N_r \times N_\theta$ 个网格,其中 $R_{\max}$ 为最大边界,探测网格 M 划分结果如图 3a 所示。




图 3 探测区模型示意图

Fig. 3 Schematics of detection area model

然而在语义 KITTI 数据集上对所有序列的各帧点云数据进行测量的实验数据^[14]表明,有 90% 以上的地面点位于激光雷达原点附近 20 m 范围内。因此,R-GPF 方法的探测网格 M 的划分方式面临以下两个问题:①当点云距离坐标原点过远时,对应网格内的点云过于稀疏,因此难以拟合出地平面。②由于靠近坐标原点的网格太小并且原点附近点云过于密集,这种情况有时会导致地平面的法向量

估计失败^[15]。

为了解决这些问题,对 R-GPF 方法的探测区模型进行了改进,以简单计算方式在探测区内给点云分配适当的密度。首先将 M 划分为 3 个区域,如图 3b 所示,设 Z_m 为 M 的第 m 区域, $m = 1, 2, 3$, $Z_m = \{p_k \in P \mid R_{\min,m} \leq r_k < R_{\max,m}\}$, 其中 $R_{\min,m}$ 和 $R_{\max,m}$ 分别表示 Z_m 的最小和最大径向半径, $r_k = \sqrt{x_k^2 + y_k^2}$; 之后每个区域将根据不同的网格划分规则进行划分,其中 Z_1 内区和 Z_3 外区将被划分成固定尺寸的网格,每个网格 $S_{i,j,m}$ 定义为

$$S_{i,j,m} = \left\{ p_k \in Z_m \mid \frac{(i-1)\Delta R_m}{N_{r,m}} \leq r_k - R_{\min,m} < \frac{i\Delta R_m}{N_{r,m}}, \frac{2\pi(j-1)}{N_{\theta,m}} \leq \theta_k < \frac{2\pi j}{N_{\theta,m}} \right\} \quad (4)$$

其中

$$\theta_k = \arctan2(y_k, x_k) \quad (5)$$

$$\Delta R_m = R_{\max,m} - R_{\min,m} \quad (6)$$

$$R_{\max,m} = R_{\min,m+1} \quad (7)$$

进行参数的合理设定,取 $\{N_{r,1}, N_{r,3}\} = \{4, 6\}$, $\{N_{\theta,1}, N_{\theta,3}\} = \{30, 40\}$ 。同时, $R_{\max,3} = R_{\max}$, $R_{\min,1} = R_{\min}$, $R_{\max} = 80.0$ m, 且全局最小边界 $R_{\min}$ 取 1.0 m 来去除掉移动平台对点云数据的影响。

同时 Z_2 中区的网格尺寸根据实时点云密度进行自适应调整,其中整数 $N_{r,2}$ 和 $N_{\theta,2}$ 变化范围分别为 $[6, 8]$ 和 $[36, 60]$ 。改进的探测区模型如图 3b 所示。

与 R-GPF 方法的探测网格划分方式相比,改进的探测区模型中, Z_1 内区和 Z_3 外区的网格更大,可以有效地解决外侧的稀疏性问题,同时可以实现对原点周围地平面法向量的稳健估计,加以 Z_2 中区的自适应调整策略,最终有助于提高地面分割的效果;此外,探测区模型网格的数量减少到 576 ~ 840 个,有助于里程计的高频输出。

1.2.3 地面点似然估计

R-GPF 地面分割方法将点云分配至各个网格对应的空间后,拟合出该空间内符合设定条件的地平面,进而得到分割的地面点。代替常用的平面拟合方法 RANSAC^[16], R-GPF 方法使用了主成分分析 PCA^[17] 方法,虽然 RANSAC 对异常值的敏感性往往较低,但 PCA 的处理速度相较 RANSAC 更快,并能达到可接受的拟合效果^[18]。

R-GPF 方法获取地面点的步骤如下:①任一网格空间内高度最低的点最有可能属于地面点^[19],选择最低高度的点作为初始种子,根据高度阈值得到初始估计地面点。②结合平面距离阈值,对初始估计地面点进行多次 PCA 平面拟合迭代,获取最终估计地面点,设定迭代次数为 3 次^[20]。

R-GPF 地面分割方法针对大多数场景虽然能够获得不错的分割效果,但针对果园环境下的某些特定场景,如较为竖直的果树树干和灌木侧面、灌木的平缓顶端易被识别为初始估计地面点,导致最终被错误识别成 FPs,影响后续的特征提取和匹配,从而最终影响激光雷达里程计性能。因此本文通过对 R-GPF 方法获得的地面点 $\tilde{G}_n$ 进行进一步筛选,获得在果园环境中稳定的地面分割效果。地面点的似然估计可表示为

$$L(\delta|\chi) = f(\chi|\delta) = \prod_n f(\chi_n|\delta_n) \quad (8)$$

式中 δ, δ_n ——前面工作的所有参数和 $\tilde{G}_n$ 对应拟合地平面的参数

χ, χ_n ——遵循密度函数 f 的连续概率分布的

随机变量和 $\tilde{G}_n$ 对应拟合地平面的随机变量

同时假设每个网格的对应空间都相互独立。

对 $\tilde{G}_n$ 进一步筛选, $\tilde{G}_n$ 作为地面点的可能性由 $\tilde{G}_n$ 对应拟合地平面的水平度和高度决定,分别用 $\sigma(\cdot)$ 和 $\tau(\cdot)$ 表示为

$$f(\chi_n|\delta_n) = \sigma(\mathbf{u}_{3,n})\tau(\bar{z}_n, N_{\theta,m}) \quad (9)$$

式中 $\mathbf{u}_{3,n}$ —— $\tilde{G}_n$ 对应拟合地平面的法向量

$\bar{z}_n$ —— $\tilde{G}_n$ 的 z 值均值

(1) 水平度:如果 $\tilde{G}_n$ 属于实际地面,则 $\mathbf{u}_{3,n}$ 倾向垂直于激光雷达框架的 $X-Y$ 平面。因此提出水平度评价函数

$$\sigma(\mathbf{u}_{3,n}) = \begin{cases} \text{case} \left(\arccos \left| \frac{\mathbf{u}_{3,n} \mathbf{z}}{\|\mathbf{u}_{3,n}\| \|\mathbf{z}\|} \right| < \phi_1 \right) & (r_n \leq R_{\max,1}) \\ \text{case} \left(\arccos \left| \frac{\mathbf{u}_{3,n} \mathbf{z}}{\|\mathbf{u}_{3,n}\| \|\mathbf{z}\|} \right| < \phi_2 \right) & (r_n > R_{\max,1}) \end{cases} \quad (10)$$

式中 $\mathbf{z}$ ——单位竖直向量

$\text{case}(\cdot)$ ——条件判断函数

在式(10)中, $\text{case}(\cdot)$ 满足条件时返回 1, 否则返回 0。一般情况下激光雷达周围的地平面相较参考 $X-Y$ 平面变化不大,但较远处地面可能为陡峭的坡面,故水平度阈值 ϕ_2 的设定应更加保守,故取 $\phi_1 = 30^\circ, \phi_2 = 45^\circ$ 。

(2) 高度:经水平度评价函数评估后,一些 FPs 如较为竖直的果树树干和灌木侧面已经被剔除,但灌木等物体的平缓顶端未被过滤,故针对此类 FPs 提出高度评价函数为

$$\tau(\bar{z}_n, N_{\theta, m}) = \begin{cases} \text{case}\left(\bar{z}_n - \sum_{i=1}^{\rho(N_{\theta, m})} \bar{z}_i / \rho(N_{\theta, m}) < 0.1\right) & (r_n \leq R_{\max, 1}) \\ 1 & (r_n > R_{\max, 1}) \end{cases} \quad (11)$$

当 $\tilde{G}_n$ 所处网格位于激光雷达周围时,则计算 $\tilde{G}_n$ 所处网格内地面点高度均值 $\bar{z}_n$,并以该网格为中心沿该网格所处环区向外自适应扩展 $\rho(N_{\theta, m})$ 个网格,各自计算每个网格包含的地面点高度均值,并求平均值,最终考虑 $\bar{z}_n$ 与该平均值的差值,其中 $\rho(N_{\theta, m})$ 个网格对应的角度设定为 60° ;较远处的 $\tilde{G}_n$ 可能位于陡峭的坡面上,故不再纳入评估。至此灌木等物体的平缓顶端的 FPs 剔除任务完成。

因此,最终估计的地面点可以直接表示为

$$\tilde{G} = \bigcup_{n \in \sum_{m=1}^3 (N_{r, m} \times N_{\theta, m})} \text{case}(f(\chi_n | \delta_n) = 1) \tilde{G}_n \quad (12)$$

1.2.4 改进 R - GPF 地面分割方法的有效性验证

验证改进 R - GPF 地面分割方法的有效性,在语义 KITTI 数据集 00 序列第 5 帧附近的地面估计结果如图 4 所示。由图 4 可以看到,原始 R - GPF 方法错误地将一些较为竖直的树干、灌木侧面和墙体识别为地面点,同时灌木和汽车的平缓顶端也未能正确分割,而改进 R - GPF 方法成功地过滤掉了错误估计的地面部分,从而显著地减少了 FPs,验证了较为竖直的树干、灌木侧面和墙体以及灌木和汽车的平缓顶端可以分别被水平度和高度过滤器过滤。




图 4 在语义 KITTI 数据集 00 序列第 5 帧附近的地面分割结果

Fig.4 Ground segmentation results near frame 5 of semantic KITTI dataset sequence 00

比较基于原始 R - GPF 地面分割方法的激光雷达里程计和基于改进 R - GPF 地面分割方法的激光雷达里程计的测程效果,直观比较如图 5 所示,具体数据如图 6 和表 1 所示。可以明显看出,本文提出的改进激光雷达里程计显示出更好的性能,在整个过程中都保持较小且稳定的绝对误差产出,同时可以得出,精确的地面分割可以有效提高激光雷达里

程计的性能。




图 5 在语义 KITTI 数据集 00 序列上的测程结果与实际轨迹的绝对误差

Fig.5 Absolute error diagram of odometer measurement result and actual trajectory on semantic KITTI dataset sequence 00

1.3 BAT 启发式自适应重采样方法

Gmapping 算法由于其后端较为粗暴的重采样方式和重采样过程中对粒子收敛程度的较少干预分别导致其粒子的多样性表述能力和定位准确性难以适应果园等大场景下的环境地图构建。受蝙蝠寻找猎物行为启发本文提出了一种重采样方法来解决这两个问题从而实现在果园等大场景下环境地图的精准构建。

BAT 启发式自适应重采样方法的流程概括为图 7,rand 为在 $[0,1]$ 范围内均匀分布的随机数^[21]。首先筛选权重最高的粒子作为最佳粒子,再自适应生成重采样粒子集并将每个粒子对应为蝙蝠,最佳粒子对应为目标猎物,每个蝙蝠随机提取固定频率,并将其定位和分配速度,根据其与目标猎物的接近程度自动调整脉冲的发射率和响度来搜索猎物,并不断靠近猎物,同时不断判断是否到达自适应调整的迭代时间,以生成最终定位信息。




Fig. 6 Diagram of data corresponding to absolute error

表 1 绝对误差对应数据						
Tab.1 Data corresponding to absolute error						m
地面分割方法	最大误差	最小误差	平均误差	误差中值	均方根误差	标准差
原始 R - GPF 方法	11. 115 728	1. 163 046	5. 603 563	5. 163 358	6. 108 143	2. 818 296
改进 R - GPF 方法	5. 362 723	0. 182 624	1. 975 403	1. 726 247	2. 215 098	0. 996 554

1.3.2 迭代时间的自适应调整

由重采样粒子集的自适应生成过程可知需要重新采样的粒子已经接近于真实状态,所以重采样不需要过长时间的迭代优化,过长时间的迭代优化会导致粒子的退化^[22],故应根据重采样前作业平台预估位姿粒子与最佳粒子之间的实际差异程度指标 d_t 来自适应调整迭代时间

$$d_t = (\mathbf{z}_t - \hat{\mathbf{z}}_t)^T \mathbf{M}_t^{-1} (\mathbf{z}_t - \hat{\mathbf{z}}_t)$$

(14)

式中 $\hat{\mathbf{z}}_t$ ——重采样前作业平台预估位姿的测量值
 $\mathbf{z}_t$ ——全局最佳粒子对应的测量值

$\mathbf{M}_t^{-1}$ —— t 时刻测量值 $\mathbf{z}_t$ 对应的协方差矩阵
同时结合重采样粒子集自适应生成阈值,提出了一种能够在重采样步骤中自适应调整粒子优化迭代时间的策略

1.3.1 重采样粒子集的自适应生成

执行完后端优化的权重归一化处理步骤后,对整个粒子群进行权重差异性评估,判断当前是否需要执行重采样步骤,粒子群权重差异性指标 N_{eff} 的计算公式为

$$N_{\text{eff}} = 1 / \sum_{i=1}^n (\hat{\omega}_t^i)^2$$

(13)

如果权重差异性指标计算值大于设定重采样阈值,说明差异性很小,不需要执行重采样步骤;反之则表明差异性较大,易造成定位不准,需执行自适应重采样步骤。

相比于权重较大的粒子,权重较小的粒子并不能很好地反映真实的后验分布,并且由于部分高权重粒子已经接近于真实状态,并不需要过度优化。故为提高整个粒子群的定位准确性并保证算法的实时性,该改进算法的重采样步骤仅作用于权重较小的部分粒子。

根据粒子权重将整个粒子群进行降序排序,筛选权重最高的粒子作为最佳粒子,其次设定重采样粒子集自适应生成阈值为粒子群权重差异性指标计算值向下舍入得到的最近整数。将集合中粒子次序大于自适应生成阈值的粒子放入新生成的粒子集中。该方法可以根据粒子群权重差异性程度来自适应调整重采样粒子集的大小来获得更合理重采样粒子覆盖范围。

$$T = \begin{cases} T_{\min} & (0 < d_t \leq \ell/8) \\ T_{\min} + 8(T_{\max} - T_{\min})(d_t - \ell/8)/(3\ell) & (\ell/8 < d_t < \ell/2) \\ T_{\max} & (d_t \geq \ell/2) \end{cases}$$

(15)

式中 T ——迭代时间 $T_{\min}$ ——迭代时间下限
 $T_{\max}$ ——迭代时间上限
 ℓ ——自适应生成阈值

基于以上分析,BAT 启发式自适应重采样方法可以在保证粒子多样性的前提下获得更好的粒子群定位效果,即获得更准确的最终定位信息来实现果园等大场景地图的精准构建。

2 果园环境地图构建试验

2.1 试验环境及设备

试验在江苏省农业科学院梨园进行,由于处于堆




图 7 BAT 启发式自适应重采样流程图

Fig. 7 Flow chart of BAT heuristic adaptive resampling

肥时期故选取可进行试验的 3 行梨树,梨树行间距为 6 m 左右,梨树和棚架立柱交叉分布,间距为 1.5 m 左右,梨树单行长 25 m 左右,试验环境如图 8 所示。



图 8 梨园试验环境

Fig. 8 Pear orchard test environment

试验采用 Velodyne 公司的 VLP-16 型激光雷达进行果园环境信息采集,数据的处理与分析使用 Dongtintech 公司的 DTB-3049-H310 型工控机,处理器为 i7-9700,16 GB 内存,500 GB 固态硬盘,无显卡。

2.2 地面分割及里程计测程试验

首先进行地面分割的试验,试验结果如图 9 所示。可以看到原始 R-GPF 方法错误地将果树树干、棚架的竖直立柱部分和远处的竖直墙体识别为地面点,而改进 R-GPF 方法在避免以上问题的同时获得了更好的空旷地面分割效果,故改进 R-GPF 方法拥有更好的地面分割效果。

再在梨园中进行前端里程计试验,基于原始 R-GPF 方法的激光雷达里程计和基于改进 R-GPF 方法的激光雷达里程计的输出结果与实际轨迹的对比如图 10 所示,进行调头和弯曲行进的目的是检测里程计在场景变化较大的情况下的鲁棒性。针对实




图 9 梨园环境下地面分割结果

Fig. 9 Ground segmentation results in pear orchard environment

际轨迹的获取,由于果园上方存在金属棚架导致 GPS 信号接收较差,影响实际定位效果,故通过直接测量获取实际轨迹:沿激光雷达前进方向每隔 50 cm 左右选取一测量点,该测量点即为激光雷达实际位置,设定初始测量点为全局坐标系原点,通过卷尺测量初始测量点与下一测量点的相对坐标即可获得下一测量点的全局坐标,按照该方法遍历剩余测量点来获得所有测量点的全局坐标便可得到实际轨迹;再分析该实际轨迹的精度,每 4 个测量点选取一点直接测量该点在全局坐标系下的具体坐标,并计算该坐标与之前遍历所获得坐标的偏差,所有所选测量点在 x 和 y 方向上的偏差不超过 7 cm,故可通过以上方法获取实际轨迹。相比于原始 R-GPF 方法的激光雷达里程计的平均输出频率 10.40 Hz,改进 R-GPF 方法的平均输出频率可达到 15.58 Hz,满足前端里程计的输出频率要求。




图 10 梨园环境下里程计输出结果

Fig. 10 Output results of odometer in pear orchard environment

再通过计算两种里程计的输出轨迹和实际轨迹的横向偏差来评价其测程性能,如图 11 所示,设定里程计输出轨迹在实际轨迹左侧时横向偏差为正值,在右侧时为负值。计算横向偏差的相关数据,原始 R-GPF 方法所对应的最大横向偏差接近 50 cm,横向偏差均值为 22.5 cm,标准差为 24.7 cm;改进 R-GPF 方法所对应的最大横向偏差小于 25 cm,横

向偏差均值为 12.7 cm, 标准差为 13.4 cm。可以明显看出, 本文提出的改进激光雷达里程计在整个过程中都保持着较小且较为稳定的横向偏差, 而原始激光雷达里程计的横向偏差变化幅度大且一直处于较高位。综合分析基于改进 R-GPF 方法的激光雷达里程计在更高频率的输出情况下仍能获得更好的测程效果。




图 11 梨园环境下里程计横向偏差

Fig. 11 Lateral deviation of odometer in pear orchard environment

2.3 地图构建试验及 BAT 启发式自适应重采样方法有效性分析

由于原始 Gmapping 算法前端里程计采用的 ICP 方法累计误差大且果园环境复杂、场景大, 所以原始 Gmapping 算法的前端里程计表现效果很差, 故最终建图效果对比在基于原始 R-GPF 的 Gmapping 算法和基于改进 Gmapping 算法两者中进行, 最终两种算法的建图效果如图 12 所示。由于梨园两侧地头分别为墙体和较宽的空旷道路, 中间部分为 3 行交叉分布的梨树和棚架立柱, 故图 12 最左侧为构建的墙体, 最右侧无构建内容, 中间部分为构建的梨树和棚架立柱。




图 12 梨园环境下建图效果

Fig. 12 Mapping results in pear orchard environment

先进行地图构建偏差的计算和对比, 从每行的最右侧果树或棚架立柱开始分别向左计算列间距离偏差和向下计算行间距离偏差, 最终共遍历 51 棵果树和棚架立柱, 建图偏差对比如图 13 所示。可以看到原始地图构建算法所得到的梨树列间距离偏差在 40 cm 范围内, 行间距离偏差均值为 18.2 cm, 标准差为 9.3 cm。相比于原始地图构建算法波动较大的为列间距离偏差, 改进地图构建算法的列间距离

偏差始终保持在 20 cm 范围内, 表现较好; 同时在行间距离偏差方面改进地图构建算法表现更好, 行间距离偏差均值为 10.3 cm, 标准差为 6.3 cm; 可以看到相比于原始地图构建算法, 改进地图构建算法在列间距离偏差、行间距离偏差和行间距离偏差的标准差 3 个方面分别减小了 50%、43.41% 和 32.26%; 一般情况下地图更新步骤会进一步增加地图构建的误差, 在此前提下改进地图构建算法的行间距离偏差的各项数据相比于里程计横向偏差的各项数据仍有进一步减小, 这也可以从侧面反映出后端 BAT 启发式自适应重采样方法有效实现了对初始定位信息的进一步优化。




图 13 梨园环境下建图偏差对比

Fig. 13 Comparison charts of mapping deviation in pear orchard environment

再结合图 12 分析整体建图效果, 当作业平台从第 2、3 行间沿逆时针方向调头来到第 1、2 行间时, 场景变化较大, 而原始地图构建算法地面分割鲁棒性较差导致前端里程计输出误差较大, 且其后端优化部分对定位情况的再优化效果不明显导致左侧墙壁出现重叠和偏移, 最终导致第 1 行出现较大偏移, 第 2 行右侧出现重叠, 建图效果较差; 改进地图构建算法凭借精确和稳健的前端激光雷达里程计和后端优化重采样算法对定位的再优化获得较好的建图效果, 可以满足后续重定位、导航等作业的精度要求。

3 结论

(1) 为了获得高精度果园二维环境地图, 首先通过改进 R-GPF 方法实现准确和快速的地面分

割,进而获得高精度高频率的前端激光雷达里程计信息,再在后端优化部分提出了一种 BAT 启发式自适应重采样算法对激光雷达里程计信息进行合理程度的再优化获得更优的定位信息,最终获得精准的果园二维环境地图。

(2)在梨园中进行前端里程计试验,基于改进 R-GPF 方法的激光雷达里程计的平均输出频率可达到 15.58 Hz,其对应的最大横向偏差小于 25 cm,横向偏差均值为 12.7 cm,标准差为 13.4 cm,比基

于原始 R-GPF 方法的激光雷达里程计表现更好,并且满足前端里程计的输出频率和精度要求。进行梨园环境地图构建,改进地图构建算法表现更好:列间距离偏差方面表现良好,始终保持在 20 cm 范围内,在行间距离偏差方面表现更优秀,行间距离偏差均值为 10.3 cm,标准差为 6.3 cm,建图精度可以满足后续重定位、导航等作业的精度要求,同时行间距偏差侧面反映出后端 BAT 启发式自适应重采样方法的有效性。

参 考 文 献

- [1] 季宇寒,李寒,张漫,等. 基于激光雷达的巡检机器人导航系统研究[J]. 农业机械学报, 2018, 49(2): 14-21.
JI Yuhao, LI Han, ZHANG Man, et al. Research on navigation system of inspection robot based on LiDAR[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(2): 14-21. (in Chinese)
- [2] 薛金林,张顺顺. 基于激光雷达的农业机器人导航控制研究[J]. 农业机械学报, 2014, 45(9): 55-60.
XUE Jinlin, ZHANG Shunshun. Research on navigation control of agricultural robot based on LiDAR[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(9): 55-60. (in Chinese)
- [3] 毕松,王宇豪. 基于自适应半径滤波的农业导航激光点云去噪方法研究[J]. 农业机械学报, 2021, 52(11): 234-243.
BI Song, WANG Yuhao. Research on laser point cloud denoising method for agricultural navigation based on adaptive radius filtering[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(11): 234-243. (in Chinese)
- [4] ZHANG J, SINGH S. LOAM: liDAR odometry and mapping in real-time[C]//Proc. Robot. Sci. Syst., 2014: 1-9.
- [5] 范永祥,冯仲科,陈盼盼,等. 基于改进 LOAM 的森林样地调查系统设计与试验[J]. 农业机械学报, 2022, 53(7): 291-300.
FAN Yongxiang, FENG Zhongke, CHEN Panpan, et al. Design and experiment of forest plot investigation system based on improved LOAM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 291-300. (in Chinese)
- [6] SHAN T, ENLOT B. LeGO-LOAM: lightweight and groundoptimized LiDAR odometry and mapping on variable terrain[C]//Proc. IEEE/RSJ Int. Conf. Intell. Robot. and Syst., 2018: 4758-4765.
- [7] 张莹莹,周俊. 基于激光雷达的果园树干检测[J]. 中国农业大学学报, 2015, 20(5): 249-255.
ZHANG Yingying, ZHOU Jun. Detection of orchard trunk based on LiDAR[J]. Journal of China Agricultural University, 2015, 20(5): 249-255. (in Chinese)
- [8] GRISETTI G, STACHNISS C, BURGARD W. Improved techniques for grid mapping with Rao-Blackwellized particle filters[J]. IEEE Transactions on Robotics, 2007, 23(1): 34-46.
- [9] 张顺利,徐艳芝,周明全,等. 基于自适应邻域匹配的点云配准方法[J]. 计算机学报, 2019, 42(9): 2114-2126.
ZHANG Shunli, XU Yanzhi, ZHOU Mingquan, et al. Point cloud registration method based on adaptive neighborhood matching[J]. Chinese Journal of Computers, 2019, 42(9): 2114-2126. (in Chinese)
- [10] LIM H, HWANG S, MYUNG H. ERASOR: egocentric ratio of pseudo occupancy-based dynamic object removal for static 3D point cloud map building[J]. IEEE Robot. Automat. Lett., 2021, 6(2): 2272-2279.
- [11] ROH B, LEE H C, LEE B H. Multi-hypothesis map merging with sinogram-based PSO for multi-robot systems[J]. Electronics Letters, 2016, 52(14): 1213-1214.
- [12] DOUCET A, DE FREITAS N, MURPHY K, et al. Rao-Blackwellised particle filtering for dynamic Bayesian networks[C]//Uncertainty in Artificial Intelligence, 2000: 176-183.
- [13] 张毅,杜凡宇,罗元,等. 一种融合激光和深度视觉传感器的 SLAM 地图创建方法[J]. 计算机应用研究, 2016, 33(10): 2970-2972,3006.
ZHANG Yi, DU Fanyu, LUO Yuan, et al. A SLAM map creation method based on the fusion of laser and depth vision sensor[J]. Application Research of Computers, 2016, 33(10): 2970-2972,3006. (in Chinese)
- [14] BEHLEY J, GARBADE M, MILIOTO A, et al. SemanticKITTI: a dataset for semantic scene understanding of LiDAR sequences[C]//Proc. IEEE Int. Conf. Comput. Vis., 2019: 9297-9307.
- [15] 许振瑛,何宁,晁建刚,等. 三维点云关键点局部坐标系重构方法研究[J]. 载人航天, 2022, 28(3): 344-349.
XU Zhenying, HE Ning, CHAO Jian'gang, et al. Research on reconstruction method of local coordinate system of key points of three-dimensional point cloud[J]. Manned Space Flight, 2022, 28(3): 344-349. (in Chinese)
- [16] 苏云龙,平雪良,李楠. 基于 RANSAC 三维点云的平面提取算法[J]. 激光与红外, 2019, 49(6): 780-784.
SU Yunlong, PING Xueliang, LI Nan. Plane extraction algorithm based on RANSAC three-dimensional point cloud[J]. Laser and Infrared, 2019, 49(6): 780-784. (in Chinese)

LI Yuehua, ZHU Shiqiang, YU Yiqi. Improved visual SLAM algorithm in factory environment[J]. Robot, 2019, 41(1): 95 – 103. (in Chinese)

[22] 黎达, 邢艳秋, 黄佳鹏, 等. 基于双目立体视觉 SLAM 的林下实时定位[J]. 中南林业科技大学学报, 2021, 41(2): 16 – 22, 34.
LI Da, XING Yanqiu, HUANG Jiapeng, et al. Real-time positioning in forests based on binocular stereo visual SLAM[J]. Journal of Central South University of Forestry & Technology, 2021, 41(2): 16 – 22, 34. (in Chinese)

[23] 董蕊芳, 王宇鹏, 阚江明. 基于改进 ORB_SLAM2 的机器人视觉导航方法[J]. 农业机械学报, 2022, 53(10): 306 – 317.
DONG Ruifang, WANG Yupeng, KAN Jiangming. Visual navigation method for robot based on improved ORB_SLAM2[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(10): 306 – 317. (in Chinese)

[24] 郭成洋, 范雨杭, 张硕, 等. 果园车辆自动驾驶技术研究进展[J]. 东北农业大学学报, 2019, 50(8): 87 – 96.
GUO Chengyang, FAN Yuhang, ZHNAG Shuo, et al. Progress on vehicle automatic navigation in orchard[J]. Journal of Northeast Agricultural University, 2019, 50(8): 87 – 96. (in Chinese)

[25] 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. (in Chinese)

[26] ZHANG L, ZHANG Y. Improved feature point extraction method of ORB-SLAM2 dense map[J]. Assembly Automation, 2022, 42(4): 552 – 566.

[27] 高翔, 张涛, 颜沁睿, 等. 视觉 SLAM 十四讲: 从理论到实践[M]. 北京: 电子工业出版社, 2019.

[28] 侯荣波, 魏武, 黄婷, 等. 基于 ORB-SLAM 的室内机器人定位和三维稠密地图构建[J]. 计算机应用, 2017, 37(5): 1439 – 1444.
HOU Rongbo, WEI Wu, HUANG Ting, et al. Indoor robot localization and 3D dense mapping based on ORB-SLAM[J]. Journal of Computer Applications, 2017, 37(5): 1439 – 1444. (in Chinese)

[29] HUO X, ZHANG L, LIU G, et al. Application of an improved fast corner detection algorithm in ORB-SLAM2[C] // International Conference on Autonomous Unmanned Systems. Springer, Singapore, 2021: 1825 – 1833.

[30] 李国竣, 徐延海, 段杰文, 等. 利用局部自适应阈值方法提取 ORB-SLAM 特征点[J]. 测绘通报, 2021(9): 32 – 36, 48.
LI Guojun, XU Yanhai, DUAN Jiewen, et al. ORB-SLAM method based on local adaptive threshold extraction feature points[J]. Bulletin of Surveying and Mapping, 2021(9): 32 – 36, 48. (in Chinese)

[31] XIE P, SU W, LI B, et al. Modified keyframe selection algorithm and map visualization based on ORB-SLAM2[C] // 2020 4th International Conference on Robotics and Automation Sciences (ICRAS). IEEE, 2020: 142 – 147.

[32] ZENG M, ZHAO F, ZHENG J, et al. Octree-based fusion for realtime 3D reconstruction[J]. Graphical Models, 2013, 75(3): 126 – 136.

[33] 林辉灿, 吕强, 张洋, 等. 稀疏和稠密的 VSLAM 的研究进展[J]. 机器人, 2016, 38(5): 621 – 631.
LIN Huican, LÜ Qiang, ZHANG Yang, et al. The sparse and dense VSLAM: a survey[J]. Robot, 2016, 38(5): 621 – 631. (in Chinese)

[34] KULKARNI M, JUNARE P, DESHMUKH M, et al. Visual SLAM combined with object detection for autonomous indoor navigation using Kinect V2 and ROS[C] // 2021 IEEE 6th International Conference on Computing, Communication and Automation (ICCCA). IEEE, 2021: 478 – 482.

(上接第 34 页)

[17] 浮丹丹, 周绍光, 徐洋, 等. 基于主成分分析的点云平面拟合技术研究[J]. 测绘工程, 2014, 23(4): 20 – 23.
FU Dandan, ZHOU Shaoguang, XU Yang, et al. Research on plane fitting technology of point cloud based on principal component analysis[J]. Engineering of Surveying and Mapping, 2014, 23(4): 20 – 23. (in Chinese)

[18] 童子良, 余学祥, 汪涛, 等. 一种新的鲁棒三维点云平面拟合方法[J]. 合肥工业大学学报(自然科学版), 2020, 43(12): 1684 – 1688.
TONG Ziliang, XU Xuexiang, WANG Tao, et al. A new robust three-dimensional point cloud plane fitting method[J]. Journal of Hefei University of Technology(Natural Science), 2020, 43(12): 1684 – 1688. (in Chinese)

[19] 郭庆华, 刘瑾, 陶胜利, 等. 激光雷达在森林生态系统监测模拟中的应用现状与展望[J]. 科学通报, 2014, 59(6): 459 – 478.
GUO Qinghua, LIU Jin, TAO Shengli, et al. Application status and prospect of LiDAR in forest ecosystem monitoring and simulation[J]. Chinese Science Bulletin, 2014, 59(6): 459 – 478. (in Chinese)

[20] ZERMAS D, IZZAT I, PAPANIKOLOPOULOS N. Fast segmentation of 3D point clouds: a paradigm on LiDAR data for autonomous vehicle applications[C] // Proc. IEEE Int. Conf. Robot. Automat., 2017: 5067 – 5073.

[21] 许德刚, 赵萍. 蝙蝠算法研究及应用综述[J]. 计算机工程与应用, 2019, 55(15): 1 – 12, 31.
XU Degang, ZHAO Ping. Review on research and application of bat algorithm[J]. Computer Engineering and Applications, 2019, 55(15): 1 – 12, 31. (in Chinese)

[22] 孙伟, 刘经洲. 基于 Huber 鲁棒容积裂变粒子滤波的协同导航方法[J]. 仪器仪表学报, 2022, 43(2): 166 – 175.
SUN Wei, LIU Jingzhou. Cooperative navigation method based on Huber robust volume fission particle filter[J]. Chinese Journal of Scientific Instrument, 2022, 43(2): 166 – 175. (in Chinese)