

基于位姿图优化的势均衡多伯努利滤波器 SLAM 方法

张子菁, 章飞

(江苏科技大学海洋学院, 江苏 镇江 212003)

摘要: 在复杂室内环境下, 传统基于随机有限集理论的 SLAM 方法存在机器人位姿精度低、计算量大的问题。针对此问题, 提出一种基于位姿图优化的势均衡多伯努利滤波器 SLAM 方法。首先, 该方法通过势均衡多伯努利滤波器获得地图特征估计, 避免了数据关联。其次, 提出了自适应信息控制法, 丰富先验信息。然后, 通过自适应信息控制法将位姿图优化理论与势均衡多伯努利滤波器 SLAM 结合, 优化机器人的位姿估计。最后, 进行实验对比分析, 结果表明所提方法比 RB-PHD-SLAM 方法有更好的 SLAM 精度及实时性。

关键词: SLAM; 随机有限集理论; 势均衡多伯努利滤波器; 位姿图优化

中图分类号: TP242

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202305

Cardinalized balanced multi-Bernoulli filter SLAM method based on pose graph optimization

ZHANG Zijing, ZHANG Fei

Ocean College, Jiangsu University of Science and Technology, Zhenjiang 212003, China

Abstract: In the complex indoor environment, the traditional SLAM method based on random finite set theory has the problems of low robot pose accuracy and large amount of calculation. To solve these problems, a cardinalized balanced multi-Bernoulli filter SLAM method based on pose graph optimization was proposed. First of all, the cardinalized balanced multi-Bernoulli filter was used to estimate the map features, which avoided data association. What is more, an adaptive information control method was proposed to enrich the prior information. Then, the pose graph optimization theory was combined with cardinalized balanced multi-Bernoulli filter SLAM through adaptive information control method to optimize the pose estimation of the robot. Finally, through experimental comparative analysis, the results show that this method have better SLAM accuracy and real-time performance than the RB-PHD-SLAM method.

Key words: SLAM, random finite set theory, cardinalized balanced multi-Bernoulli filter, posegraph optimization

0 引言

即时定位与地图构建(simultaneous localization and mapping, SLAM)是机器人学领域中非常重要的子领域之一。随着导航技术的不断发展,人们对特殊应用环境的需求日益增加,如在室内火灾救援、粉尘车间巡检等特殊场景中需要移动机器人具备更好的自主定位与导航性能来辅助完成特殊任

务。SLAM方法作为主要导航技术之一,也广受学者们的关注^[1-3]。SLAM方法主要分为两类:一类是基于滤波器的SLAM方法,另一类是基于优化理论的SLAM方法^[4-5]。

基于滤波器的SLAM方法主要以卡尔曼滤波方法及其改进方法为主,但这类方法在具有低信噪比、包含大量虚警和杂波的复杂室内环境下工作时,会由于数据关联复杂出现关联不准确、SLAM

收稿日期: 2022-09-01; 修回日期: 2022-12-07

通信作者: 章飞, zjzf@just.edu.cn

基金项目: 国家自然科学基金资助项目(No.61801170, No.61801435)

Foundation Items: The National Natural Science Foundation of China (No.61801170, No.61801435)

精度下降等问题,同时还伴有计算量大的问题。Mahler R^[6-8]提出了随机有限集(random finite set, RFS)理论,并提出了概率假设密度(probability hypothesis density, PHD)滤波器^[6]、势概率假设密度(cardinalized probability hypothesis density, CPHD)^[7]、多目标多伯努利(multi-target multi-Bernoulli, MeMBer)滤波器^[8]。Vo B N 等人^[9-10]在 Mahler R 的理论基础上提出了基于随机有限集理论的 SLAM 实现方法,即 SLAM 方法的粒子滤波形式实现和混合高斯形式实现。Adams M 等人^[11]提出了一种新特征策略,将移动机器人上一时刻的观测信息集合作为当前时刻的先验信息集合,带入 PHD 滤波器,从而估计出新出现地图特征的位置,但是只采用上一时刻的观测集合,先验信息不足,因此对地图特征位置及数目的估计精度不足。Moratuwage D 等人^[12-13]分别提出了基于标签的多伯努利滤波器 SLAM 方法和基于广义标签的多伯努利滤波器 SLAM 方法,这些方法减少了计算量,但在信噪比(signal-to-noise ratio, SNR)较低的情况下,会出现目标数量过估计问题。闫德立等人^[14]提出一种基于 PHD-SLAM 的改进方法,该方法使用容积卡尔曼滤波器替换原有的扩展卡尔曼滤波器(extended Kalman filter, EKF),使 SLAM 精度得到提升,但是由于处于复杂环境下,仍然需要大量粒子对机器人进行位姿估计,导致实时性不高。Grisetti G 等人^[15]提出基于位姿图优化的 SLAM 方法,但是由于不能实时输出结果,该方法无法实时处理突发状况。Thrun S 等人^[16]提出基于稀疏扩展信息滤波 SLAM 方法,该方法将基于 EKF 的方法和基于位姿图优化的方法进行中和,得到一种可在线输出结果的 SLAM 方法,但是在复杂环境下,目标一致性问题及数据关联问题无法很好地得到处理,因此 SLAM 精度不高。Zhang Q Y 等人^[17]提出了一种基于位姿图优化的粒子滤波 SLAM 方法,该方法减少了粒子轨迹的振荡,并可以在线输出准确的机器人位姿,但是由于使用粒子滤波的框架,在复杂的环境下,复杂的数据关联需要大量粒子,因此计算量大幅度上升。

针对 SLAM 过程的状态估计部分中基于 RFS 理论的 SLAM 方法在复杂室内环境下存在的精度低、实时性差的问题,提出一种基于位姿图优化的势均衡多伯努利滤波器 SLAM (cardinalized balanced multi-Bernoulli filter SLAM method based on

pose graph optimization, GB-CBMber-SLAM)方法。首先,基于 RFS 理论的 SLAM 方法使用 PHD 滤波器对地图特征进行估计,导致精度低的问题,针对该问题本文所提方法使用改进势均衡多伯努利滤波器对地图特征进行状态估计。其次,基于 RFS 理论的 SLAM 方法使用粒子滤波方法对机器人进行位姿估计,在复杂环境下,为了提升机器人位姿估计精度,使用大量的粒子进行状态估计,这会导致计算量大、实时性差的问题。针对此问题提出自适应信息控制(adaptive information control, AIC)方法,通过 AIC 方法将位姿图优化方法结合进 CBMber-SLAM 方法中,对机器人的位姿估计进行更新。然后,通过 AIC 方法,将合适的已估计的地图特征加入下一时刻的地图特征估计的观测集合中,改进后的势均衡多伯努利滤波器能够同时使用较多时刻的机器人拥有的观测信息,丰富当前时刻的先验信息,提升 SLAM 精度。最后,与基于 RFS 理论的 SLAM 方法,即基于粒子滤波实现的概率假设密度滤波器(RB-PHD-SLAM)方法,进行对比实验,验证本文所提方法的有效性。

1 SLAM 问题描述与模型构建

基于随机有限集理论对陌生环境中的各类信息进行囊括,并建立地图特征和观测信息的随机有限集模型,从而避免复杂环境下的数据关联问题。

1.1 地图特征的 RFS 模型

k 时刻机器人的特征地图用一个随机集合 M_k 表示,其 RFS 模型如式(1)所示:

$$M_k = M_{k-1} \cup (\text{FoV}(X_k) \cap \bar{M}_{k-1}) \quad (1)$$

其中, $M_k = \{m_1, m_2, \dots, m_n\}$, $M_{k-1} = M \cap \text{FoV}(M_{0:k-1})$ 。 $M_{0:k-1}$ 表示机器人 0 到 $k-1$ 时刻地图特征的 RFS, M 表示整个地图特征的 RFS。 X_k 表示 k 时刻机器人的位姿, $\text{FoV}(X_k) \cap \bar{M}_{k-1}$ 表示 k 时刻机器人的新生地图特征。由式(1)可以看出,地图特征数目在机器人的运动过程中逐步增加。

1.2 观测信息的 RFS 模型

用集合 Z_k 表示 k 时刻机器人的特征观测集合,此时机器人位姿为 X_k , 其 RFS 模型 $Z_k = \bigcup_{m \in M_k} D_k(m, X_k) \cup C_k(X_k)$, 其中, $Z_k = \{z_1, z_2, \dots, z_n\}$ 表示机器人在 k 时刻对地图特征的观测。 $D_k(m, X_k)$ 表示机器人在 X_k 处对真实地图特征

的观测，其模型是一个多伯努利 RFS。 $D_k(m, X_k) = \{Z_k\}$ 的概率密度是 $P_D(m|X_k)$ $g_k(z|m, X_k)$ ，并且 $P_D(m|X_k)$ 表示当机器人姿态为 X_k 时，该机器人可以检测到位于 m 处的地图特征概率，即检测概率。 $g_k(z|m, X_k)$ 表示机器人的观测模型。 $C_k(X_k)$ 表示机器人在位姿为 X_k 时观测到的杂波 RFS。

1.3 SLAM 过程

在 RFS 框架下，SLAM 问题可以转化为在机器人观测集 Z_k 条件下估计地图特征 M_k 和机器人位姿 $X_{1:k}$ 的联合后验概率密度的过程。这种转换实现了机器人位姿和地图的同时估计。转换后的表示如式 (2) 所示：

$$\pi_{k|k}(M_k, X_{1:k} | Z_{1:k}, u_{1:k}, X_0) = \frac{g_k(Z_k | M_k, X_k) p_{k|k-1}(M_k, X_{1:k})}{\iint g_k(Z_k | M_k, X_k) p_{k|k-1}(X_{1:k}, M_k) dX_k dM_k} \quad (2)$$

由于陌生环境的限制，在 SLAM 过程中无法知道机器人本身的真实位姿。因此，不能直接估计 M_k 和 $X_{1:k}$ 的联合后验概率密度，只能用条件概率将 $\pi_{k|k}$ 分解成两部分。分解后联合后验估计的表示如式 (3) 所示：

$$\pi_k(M_k, X_{1:k} | Z_{0:k}, u_{0:k-1}, X_{0:k}) = \pi_k(X_{1:k} | Z_{0:k}, u_{0:k-1}, X_0) \pi_k(M_k | Z_{0:k}, X_{0:k}) \quad (3)$$

地图信息用多伯努利 RFS 表示，其后验概率密度可视为多目标状态，其表示记为多伯努利 RFS。几个独立的伯努利集合组合形成一个多伯努利 RFS。它的表示可以简写为 $\pi = \{(r, p)\}$ 。在 $k-1$ 时刻，每个机器人的 CBMber-SLAM 的强度函数如式 (4) 所示：

$$\pi_k(M_k | Z_{0:k}, X_{0:k}) = \left\{ X_{k-1}, \left\{ \left(r_{k-1}^{(l)}, p_{k-1}^{(l)}(m | X_{k-1}) \right) \right\}_{l=1}^{L_{k-1}} \right\} \quad (4)$$

式 (4) 中， X_{k-1} 表示 $k-1$ 时刻该机器人的位姿， $r_{k-1}^{(l)}$ 和 $p_{k-1}^{(l)}(m | X_{k-1})$ 分别表示粒子对应的存在概率和条件概率密度， L_{k-1} 表示多伯努利项数。

1.4 基于位姿图优化的势均衡多伯努利滤波器 SLAM 方法

本文提出的 GB-CBMber-SLAM 方法结构如图 1 所示。该方法主要包含地图特征估计过程和机器人位姿估计过程两个部分。其中，地图特征估计过程

使用本文提出的 GB-CBMber-SLAM 方法对状态进行估计，而每个机器人的位姿估计采用基于位姿图优化的 SLAM 方法^[18-19]，相较于传统基于 RFS 的 SLAM 方法中使用的 Rao-Blackwellised 粒子滤波方法^[9-10]，不需要大量的粒子近似机器人后验概率密度，而是通过位姿图优化理论的方法就可以得到机器人的状态估计。与传统的位姿图优化方法相比，本文所提方法避免了复杂的数据关联问题，并使目标一致，因而不需要为复杂数据关联或匹配方法花费时间。除此之外，以观测信息构建的观测约束边，并不是机器人与真实地图特征进行构建观测联系，而是与每一时刻 CBMber 滤波器滤波所得的地图特征估计值进行观测边构建，此时的观测误差几乎为 0，即机器人 x_i 时刻和 x_j 时刻之间的关系可以通过这两个时刻对同一地图特征观测，得到一个虚拟观测边，而这个虚拟观测边是可信的。




图 1 GB-CBMber-SLAM 方法结构

初始时刻作为标准的先验信息带入初始时刻的地图估计和机器人位姿估计，通过势均衡多伯努利滤波方法估算出地图特征较为准确的位姿信息，可将该信息作为已知确定的特征点，并带入之后的位姿图优化，作为一部分的顶点，随后根据无噪声的观测方程和有噪声的运动方程进行位姿图的构建。

2 基于位姿图优化的势均衡多伯努利滤波器 SLAM 方法的实现

2.1 地图特征估计

2.1.1 地图特征预测过程

在 k 时刻，假设机器人新生地图特征 $b(m | X_k)$ 的多伯努利概率密度参数集合为 $\{(r_{b,k}^{(l)}, p_{b,k}^{(l)})\}_{l=1}^{L_{b,k}}$ 。通过自适应信息控制方法将 k 时刻之前满足要求的各个

机器人修剪合并后的高斯分量信息加入 k 时刻的新生地图特征集合中, 作为 k 时刻的先验信息集合, 新生地图特征密度的高斯混合形式如式 (5) 所示:

$$p_{b,k}^{(l)}(m|Z_{k-1}) = \left\{ \sum_{j=1}^{J_{b,k}^{(l)}} w_{b,k}^{(l,j)} N(m; \mu_{b,k}^{(l,j)}, P_{b,k}^{(l,j)}) \right\} \cup \{M_{k-t:k}\} \quad (5)$$

其中, $J_{b,k}^{(l)}$ 表示新生地图特征的多伯努利项对应的高斯分量的个数, $w_{b,k}^{(l,j)}$ 表示其高斯分量的权重, $\mu_{b,k}^{(l,j)}$ 表示其高斯分量的均值, $P_{b,k}^{(l,j)}$ 表示其高斯分量的协方差矩阵, $M_{k-t:k}$ 表示上一时刻优化过程中获得的地图特征估计值, t 表示优化过程的时刻数。

在 $k-1$ 时刻, 机器人位姿 X_{k-1} 是通过运动方程及优化后的机器人位姿预测获得的, 那么先验地图的密度可用集合 $\pi_{k-1} = \{(r_{k-1}^{(l)}, p_{k-1}^{(l)}(m|X_{k-1}))\}_{l=1}^{L_{k-1}}$ 来表示, $p_{k-1}^{(l)}(m|X_{k-1})$ 的高斯混合形式如式 (6) 所示:

$$p_{k-1}^{(l)}(m|X_{k-1}) = \sum_{j=1}^{J_{k-1}^{(l)}} w_{k-1}^{(l,j)} N(m; \mu_{k-1}^{(l,j)}, P_{k-1}^{(l,j)}) \quad (6)$$

式 (6) 为机器人在位姿为 X_{k-1} 时地图特征的一系列高斯分量表示, $w_{k-1}^{(l,j)}$ 、 $\mu_{k-1}^{(l,j)}$ 、 $P_{k-1}^{(l,j)}$ 分别代表权重、均值和协方差, $J_{k-1}^{(l)}$ 为 $p_{k-1}^{(l)}$ 时的高斯分量个数。

进一步可推导出式 (7) ~ 式 (9):

$$\pi_{k|k-1} = \left\{ (r_{P,k|k-1}^{(l)}, p_{P,k|k-1}^{(l)}) \right\}_{l=1}^{L_{k-1}} \cup \left\{ (r_{b,k}^{(l)}, p_{b,k}^{(l)}) \right\}_{l=1}^{L_{b,k}} \quad (7)$$

$$p_{P,k|k-1}^{(l)}(m|X_{k|k-1}) = \sum_{j=1}^{J_{k|k-1}^{(l)}} w_{P,k-1}^{(l,j)} N(m; \mu_{P,k-1}^{(l,j)}, P_{P,k|k-1}^{(l,j)}) \quad (8)$$

$$r_{P,k|k-1}^{(l)} = r_{k-1}^{(l)} p_{S,k} \quad (9)$$

2.1.2 地图特征更新过程

由于多伯努利 RFS 的并集仍然是一个多伯努利 RFS, 因此式 (7) 记为 $\pi_{k|k-1} = \{(r_{k|k-1}^{(l)}, p_{k|k-1}^{(l)})\}_{l=1}^{L_{k|k-1}}$, 式中 $L_{k|k-1} = L_{k-1} + L_{b,k}$ 。此时, 单个粒子概率密度的高斯混合表达形式如式 (10) 所示:

$$p_{k|k-1}^{(l)}(m|X_{k|k-1}) = \sum_{j=1}^{J_{k-1}^{(l)}} w_{k-1}^{(l,j)} N(m; \mu_{k-1}^{(l,j)}, P_{k|k-1}^{(l,j)}) \quad (10)$$

更新后的地图特征密度可由如式 (11) 所示的多伯努利随机集表示:

$$\pi_k = \left\{ (r_{L,k}^{(l)}, p_{L,k}^{(l)}) \right\}_{l=1}^{L_{k|k-1}} \cup \left\{ (r_{U,k}^{(l)}(z), p_{U,k}^{(l)}(z)) \right\}_{z \in Z_k} \quad (11)$$

由式 (11) 可知, 每个机器人更新后的地图特征概率密度由两部分组成, 前半部分表示漏检目标部分, 具体如式 (12) 和式 (13) 所示, 后半部分表示由观测得到的更新部分, 具体如式 (14) 和式 (15) 所示。

$$r_{L,k}^{(l)} = r_{k|k-1}^{(l)} \frac{1 - p_{D,k}}{1 - r_{k|k-1}^{(l)} p_{D,k}} \quad (12)$$

$$P_{L,k}^{(l)}(m|X_k) = P_{k|k-1}^{(l)}(m|X_{k|k-1}) \quad (13)$$

其中, $X_{k|k-1}$ 通过 AIC 方法获得, 表示 k 时刻的机器人位姿预测值, 即下一步优化过程的初始值。

$$r_{U,k}^{(l)}(z) = \frac{\sum_{l=1}^{L_{k|k-1}} \frac{r_{k|k-1}^{(l)} (1 - r_{k|k-1}^{(l)}) \rho_{U,k}^{(l)}(z)}{(1 - r_{k|k-1}^{(l)} p_{D,k})^2}}{\kappa_k(z) + \sum_{l=1}^{L_{k|k-1}} \frac{r_{k|k-1}^{(l)} \rho_{U,k}^{(l)}(z)}{1 - r_{k|k-1}^{(l)} p_{D,k}}} \quad (14)$$

$$p_{U,k}^{(l)}(m|Z_k, X_k) = \frac{\sum_{l=1}^{L_{k|k-1}} \sum_{j=1}^{J_{k|k-1}^{(l)}} w_{U,k}^{(l,j)}(z) N(m; \mu_{U,k}^{(l,j)}, P_{U,k}^{(l,j)})}{\sum_{l=1}^{L_{k|k-1}} \sum_{j=1}^{J_{k|k-1}^{(l)}} w_{U,k}^{(l,j)}(z)} \quad (15)$$

与多伯努利滤波器不同的是, 式 (14) ~ 式 (15) 改变了多伯努利滤波器的计算方式, 通过选择一组时变伯努利分布拟合多目标状态 RFS 的后验概率密度, 递推表征伯努利分布的参数集合传递多目标后验概率。该方法有效解决了多伯努利滤波带来的过多估计地图特征数目的问题, 提高了估计精度。高斯分量的权值、均值以及协方差矩阵均通过 EKF 获得。

2.1.3 高斯分量的剪切和合并与地图特征提取

为了减少计算量, 需要对高斯分量中多余的部分进行剪切合并。多余的高斯分量多为杂波、虚警带来的小权重高斯分量。首先, 设置一个存在概率门限 $T_r = 10^{-3}$, 每次更新后, 剔除存在概率小于门限值的伯努利项。然后, 对剩余多伯努利项的高斯分量进行剪切、合并处理。

在高斯分量修剪和合并之后需要对地图特征进行提取。首先, 将幸存的多伯努利项的势和取整数, 得到的就是地图特征的数目。接着, 取每一

时刻机器人所得的幸存的多伯努利项对应的高斯分量中权重最大的高斯分量，该高斯分量的均值即地图特征点的状态值，并可作为幸存的多伯努利项对应的地图特征的状态估计值。

2.2 机器人位姿估计

在获取每一时间段的地图特征后，进行局部位姿图优化操作。由于同一个特征点会被多个时刻的机器人观测到，且该特征点是通过 CBMber 滤波器获得的，因此可以假设通过不带噪声的观测方程建立观测边，再通过有噪声的运动方程获取运动边的信息，此时在已知边及顶点信息后就可以构建关于同一个特征估计的图，并带入优化过程，求取满足边约束的最优的机器人位姿。最后，获取这几个时刻的机器人位姿，并与原来的机器人位姿估计结果作比较，选取最佳状态的位姿带入下一时刻的地图特征估计过程，作为 CBMber 预测过程中对基准机器人位姿的预测，即下一时刻的位姿初始校准点，并根据运动方程，获得下一步地图特征估计所需的机器人位姿信息。

在观测方程 $e_{k,z} = z_k - h(x_k)$ 中，由于观测是基于已估计出的地图特征进行的，因此此时的 $e_{k,z}$ 几乎为 0，在实验当中，可直接根据三角关系获得机器人位姿与地图特征的相对位姿关系，这样就避免了基于位姿图优化 SLAM 方法需要前端构建地图所需的数据关联、数据匹配等操作。

距离筛选的阈值如式 (16) ~ 式 (17) 所示：

$$d_r = R + v \times dt \quad (16)$$

$$A = (n_f(X_j) - n_f(X_i)) + \sum_{j=i}^{N_f} n_z(X_j) \quad (17)$$

其中， $n_z(X_j)$ 表示机器人位姿为 X_j 时所观测到地图特征的数目， n_f 表示由运动信息构成的边的数目， A 为信息控制量值。当 $A \leq A_r$ 时（ A_r 为自适应信息控制阈值），继续下一步 CBMber 估计地图特征状态，令 $k=k+1$ ， $t=t+1$ ，并将前一时刻所获得的地图特征对应的高斯分量加入下一时刻的新生地图信息集合中，以丰富先验信息。当不满足 $A \leq A_r$ 时，对 t 个时刻数的机器人位姿进行后端优化，获得这些时刻数对应的最优位姿并进行更新，并使 $t=0$ 。

AIC 方法结构如图 2 所示，具体步骤见表 1。




图2 AIC方法结构

表1 基于位姿图优化的势均衡多伯努利滤波器 SLAM 方法步骤

步骤	内容
步骤1	初始化第0时刻的机器人位姿及地图特征 RFS
步骤2	初始化运行时刻数 k ，优化时刻数 t 及 $n_z(X_i)$
步骤3	机器人位姿预测，得到在 CBMber-SLAM 中的机器人预测位姿
步骤4	按照式 (5) ~ 式 (15) 进行对应时刻数 t 的地图特征预测过程和更新过程
步骤5	经过高斯项修剪、合并、地图特征提取，获得地图特征的状态，输出地图特征估计值
步骤6	判断信息控制量值 A 是否小于距离阈值，若小于则执行步骤8，否则执行步骤7
步骤7	将当前时刻获得的地图特征对应的高斯分量加入下一步地图特征估计过程的新生地图集合中，丰富先验信息，然后执行步骤3，令 $k=k+1$ ， $t=t+1$
步骤8	若 A 大于数目阈值，则记录该 t 个时刻数所对应的机器人位姿、地图特征位姿信息
步骤9	对步骤3~步骤8获得的机器人位姿信息、地图特征信息进行图构建
步骤10	对步骤9中构建完成的图进行优化，获得最优的机器人位姿。并更新该 t 个时刻数所对应的机器人位姿，令 $t=0$ ， $k=k+1$ ，输出机器人位姿估计值，并跳转至步骤3

3 实验与分析

本节进行仿真实验,对实验结果进行展示和分析。仿真环境在 Matlab 2019b 平台运行,地图区域大小为 $120\text{ m} \times 400\text{ m}$,共 18 个坐标,预估信噪比在 $[15,25]$ 区间。机器人的传感器为毫米波雷达,仿真实验中的噪声均采用高斯噪声,仿真环境参数设置见表 2。

表 2 仿真环境参数设置

参数	值
机器人移动速度/($\text{m} \cdot \text{s}^{-1}$)	10
过程噪声/m	0.3
雷达扫描范围	150°
雷达扫描半径距离/m	20
角度观测噪声	1°
距离观测噪声/m	0.1

对基于随机有限集理论的 RB-PHD-SLAM 方法、势均衡多伯努利滤波器 SLAM 方法,以及本文提出的 GB-CBMber-SLAM 方法进行对比和分析。实验结果如图 3~图 5 所示,地图特征的真实位置用“o”表示,估计的地图特征位置用“+”表示,地图环境中的杂波用“x”表示。黑色虚线代表机器人真实的位姿信息,而红色“-□-”、蓝色“-□-”、淡蓝色“-□-”分别表示 3 种方法的机器人位姿的估计结果。具体实验数据见表 3。




图 3 RB-PHD-SLAM 方法仿真实验结果

如图 3~图 5 所示,通过真实值“o”与估计值“+”的重合效果可以看出, RB-PHD-SLAM 方法对地图特征的位置估计值与真实值相差甚远,并且对真实地图特征的估计有很多错误,这是因为 RB-PHD-SLAM 方法使用的 PHD 滤波器只能对多目标状态后验概率密度函数一阶矩近似。而势均衡多伯

努利滤波器能够通过计算漏检目标和量测更新的多伯努利 RFS 近似整个多目标后验概率密度,使得 SLAM 对地图特征的估计精度提升,如图 4~图 5 所示。相比 CBMber-SLAM 方法,本文所提 GB-CBMber-SLAM 方法改进了势均衡多伯努利滤波器的观测集,获得了更多先验信息,使得其对地图特征位置和数量的估计更加准确。




图 4 CBMber-SLAM 方法仿真实验结果




图 5 GB-CBMber-SLAM 方法仿真实验结果

3.1 机器人位姿估计对比分析

如图 6 所示,相比 RB-PHD-SLAM 方法,本文所提 GB-CBMber-SLAM 方法在机器人位姿估计精度方面有显著的提升。虽然 CBMber-SLAM 方法与 GB-CBMber-SLAM 方法在地图特征估计方面相差无几,但是通过均方根误差对比,本文所提 GB-CBMber-SLAM 方法在机器人位姿估计精度方面优于 CBMber-SLAM 方法 21.3%,这是因为 GB-CBMber-SLAM 方法使用更多时刻的机器人观测信息作为先验,使得地图特征估计的精度提升对当前时刻机器人的位姿估计精度提升起了很大作用。




图6 机器人位姿估计误差对比




图8 OSPA 距离

3.2 地图特征估计对比分析

在基于 RFS 理论的 SLAM 方法中, 地图特征估计对比分析采用地图特征估计数目及最优子模式分配距离 (optimal sub-pattern assignment, OSPA)^[20]作为标准进行对比分析, 如图 7~图 8 所示。如图 7 所示, 本文所提方法和 CBMBer-SLAM 方法在地图特征数目估计方面的准确度都远胜于 RB-PHD-SLAM 方法。如图 8 所示, GB-CBMBer-SLAM 方法相比 RB-PHD-SLAM 方法在 OSPA 误差方面提升了 75.3%, 这是因为势均衡多伯努利滤波器相比于 PHD 滤波器更能够近似整个多目标后验概率函数, 精度可达二阶, 且能够在低信噪比环境中对目标的数目进行准确估计。




图7 地图特征估计数目

3.3 实时性对比分析

如图 9 所示, RB-PHD-SLAM 方法和 CBMBer-SLAM 方法都采用了大量的粒子近似机器人的位姿估计分布, 因此每一时刻所需时间相比不需要大量粒子的 GB-CBMBer-SLAM 方法要多, GB-CBMBer-SLAM 相比 RB-PHD-SLAM 提升了 20.8%。虽然 GB-CBMBer-SLAM 拥有更多的先验信息, 但是相较于使用 CBMBer 滤波器的 SLAM 方法所需时间更少, 提升了 9.5%。具体数据见表 3。




图9 所需时间对比

4 结束语

针对复杂环境下基于 RFS 理论的 SLAM 方法

表3

仿真实验数据对比表

方法	机器人位姿误差/m	特征数目	特征数目误差	OSPA 误差/m	时间/s
RB-PHD-SLAM 方法	5.749	45	27	12.173	0.024
CBMBer-SLAM 方法	1.284	18	0	3.007	0.021
GB-CBMBer-SLAM 方法	0.525	18	0	3.004	0.019

存在计算量大、地图特征估计精度低、机器人位姿精度不高的问题,提出了一种基于位姿图优化的势均衡多伯努利滤波器 SLAM 方法。该方法主要具有以下优点。(1)使用改进势均衡多伯努利滤波方法对地图特征进行估计,避免了复杂的数据关联问题。(2)提出自适应信息控制方法,将 CBMber 与位姿图优化理论结合,对机器人位姿估计进行优化,提升机器人的位姿估计精度及实时性。(3)通过自适应信息控制方法丰富每一时刻的先验信息集合,提升了地图特征估计精度。最后,通过实验验证,在机器人位姿精度方面,该方法比 CBMber-SLAM 方法和 RB-PHD-SLAM 方法好,在实时性方面相较于 RB-PHD-SLAM 和 CBMber-SLAM 方法得到了提升。


参考文献:

- [1] KEGELEIRS M, GRISETTI G, BIRATTARI M. Swarm SLAM: challenges and perspectives[J]. *Frontiers in Robotics and AI*, 2021, 8.
- [2] 李伟, 任孟瀚, 黄威豪, 等. 基于改进 M-ORB 的视觉 SLAM 直接-闭环检测算法[J]. *智能科学与技术学报*, 2021, 3(4): 482-491.
LI W, REN M H, HUANG W H, et al. Improved M-ORB based direct-loop closure detection algorithm for visual SLAM[J]. *Chinese Journal of Intelligent Science and Technology*, 2021, 3(4): 482-491.
- [3] FERRERA M, EUDES A, MORAS J, et al. OV² SLAM: a fully online and versatile visual SLAM for real-time applications[J]. *IEEE Robotics and Automation Letters*, 2021, 6(2): 1399-1406.
- [4] TANG M, CHEN Z, YIN F L. Robot tracking in SLAM with masreliez-martin unscented Kalman filter[J]. *International Journal of Control, Automation and Systems*, 2020, 18(9): 2315-2325.
- [5] HUANG Y W, SHAN T X, CHEN F F, et al. DiSCo-SLAM: distributed scan context-enabled multi-robot LiDAR SLAM with two-stage global-local graph optimization[J]. *IEEE Robotics and Automation Letters*, 2022, 7(2): 1150-1157.
- [6] MAHLER R. Multitarget Bayes filtering via first-order multitarget moments[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1152-1178.
- [7] MAHLER R. PHD filters of higher order in target number[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(4): 1523-1543.
- [8] MAHLER R. Statistical multisource-multitarget information fusion[M]. Boston: Artech House, 2007: 565-682.
- [9] VO B N, SINGH S, DOUCET A. Sequential Monte Carlo methods for multitarget filtering with random finite sets[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(4): 1224-1245.
- [10] VO B N, MA W K. The Gaussian mixture probability hypothesis density filter[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4091-4104.
- [11] ADAMS M, VO B N, MAHLER R, et al. SLAM gets a PHD: new concepts in map estimation[J]. *IEEE Robotics & Automation Magazine*, 2014, 21(2): 26-37.
- [12] MORATUWAGE D, ADAMS M, INOSTROZA F. δ -generalized labeled multi-bernoulli simultaneous localization and mapping with an optimal kernel-based particle filtering approach[J]. *Sensors*, 2019, 19(10): 2290.
- [13] DEUSCH H, REUTER S, DIETMAYER K. The labeled multi-bernoulli SLAM filter[J]. *IEEE Signal Processing Letters*, 2015, 22(10): 1561-1565.
- [14] 闫德立, 宋永端, 宋宇, 等. 一种改进的高斯混合概率假设密度 SLAM 算法[J]. *控制与决策*, 2014, 29(11): 1959-1965.
YAN D L, SONG Y D, SONG Y, et al. An improved Gaussian mixture PHD SLAM algorithm[J]. *Control and Decision*, 2014, 29(11): 1959-1965.
- [15] GRISETTI G, KÜMMERLE R, STACHNISS C, et al. A tutorial on graph-based SLAM[J]. *IEEE Intelligent Transportation Systems Magazine*, 2010, 2(4): 31-43.
- [16] THRUN S, LIU Y F, KOLLER D, et al. Simultaneous localization and mapping with sparse extended information filters[J]. *The International Journal of Robotics Research*, 2004, 23(7/8): 693-716.
- [17] ZHANG Q Y, LI Y, MA T, et al. Bathymetric particle filter SLAM with graph-based trajectory update method[J]. *IEEE Access*, 2021, 9: 85464-85475.
- [18] KÜMMERLE R, STEDER B, DORNHEGE C, et al. Large scale graph-based SLAM using aerial images as prior information[J]. *Autonomous Robots*, 2011, 30(1): 25-39.
- [19] SCHUHMACHER D, VO B T, VO B N. A consistent metric for performance evaluation of multi-object filters[J]. *IEEE Transactions on Signal Processing*, 2008, 56(8): 3447-3457.
- [20] CHEVUL S, BINZENHFER A, SCHMID M, et al. A self-organizing concept for distributed end-to-end quality monitoring[J]. *Informatik Uni*, 2006.

[作者简介]



张子菁(1995—),男,江苏科技大学海洋学院硕士生,主要研究方向为移动机器人 SLAM 方法。



章飞(1979—),男,博士,江苏科技大学副教授,主要研究方向为水下自主导航、MIMO 雷达信号处理、多传感器信息融合。