第 31 卷 第 12 期
Vol. 31 No. 12

控 制 与 决 策
Control and Decision

2016 年 12 月
Dec. 2016

文章编号: 1001-0920 (2016) 12-2299-06 **DOI:** 10.13195/j.kzyjc.2015.1227

基于高斯分布重采样的 Rao-Blackwellized 粒子滤波 SLAM 算法

张 毅, 郑潇峰, 罗 元, 庞冬雪

(重庆邮电大学 信息无障碍工程与机器人技术研发中心，重庆 400065)

摘 要: 针对移动机器人同时定位与地图构建中 RBPF-SLAM 算法因粒子匮乏而导致栅格地图估计不精确问题, 提出一种基于高斯分布重采样的 RBPF-SLAM 算法. 首先, 根据粒子权重大小对重采样粒子进行排序; 然后, 在重采样中利用高斯分布分散高权重粒子得到新粒子, 从而保证粒子多样性, 避免粒子匮乏, 保证栅格地图的精确构建. 实验结果表明了所提出算法的有效性, 同时也证明该算法能在粒子数减少的条件下保持可靠的估计, 有效地减少了计算量.

关键词: 移动机器人；同时定位与地图构建；Rao-Blackwellized 粒子滤波；高斯分布重采样

中图分类号: TP242.6 **文献标志码:** A

SLAM algorithm with Gaussian distributed resampling Rao-Blackwellized particle filter

ZHANG Yi, *ZHENG Xiao-feng*, *LUO Yuan*, *PANG Dong-xue*

(Research and Development Center of Information Accessibility Engineering and Robotics，Chongqing University of Posts and Telecommunications，Chongqing 400065，China. Correspondent：ZHANG Yi，E-mail：zhangyi@cqupt.edu.cn)

Abstract: For the estimation problem that the RBPF-SLAM algorithm used in mobile robots suffers from sample impoverishment in grid mapping, a Gaussian distributed resampling(GDR) based RBPF-SLAM algorithm is proposed. Firstly, the improved algorithm sorts particles according to the weight size. Furthermore, Gaussian distributed resampling is applied to disperse the high-weight particles so as to generate new particles. By using GDR, particle diversity can be maintained and sample impoverishment can be avoided. Thus accurate grid mapping is guaranteed. Experimental results show the effectiveness of the proposed algorithm. Meanwhile, the results prove that the proposed algorithm guarantees reliable estimation with less samples, and the computation burden can be reduced efficiently.

Keywords: mobile robots；simultaneous localization and mapping(SLAM)；Rao-Blackwellized particle filter(RBPF); Gaussian distributed resampling

0 引 言

移动机器人同时定位与地图构建 (SLAM) 是指, 移动机器人在不确定其自身位置的条件下, 在完全未知的环境中, 根据对自身的位姿估计和对传感器观测数据的处理完成地图创建的过程. SLAM 最早由 Montemerlo 等提出, 它解决了移动机器人通过得到的一系列观测值而构建未知关键地图的问题[1].

在 SLAM 问题的研究中, 对于非线性、非高斯系统的状态估计, 目前研究热点是基于序列蒙特卡洛方法 (SMC) 的粒子滤波算法. 该算法首先解除系统噪声的干扰, 然后预测和更新概论密度函数的样本集, 最后对系统的递归贝叶斯估计进行估计. Murphy 等[2]将 Rao-Blackwellized 粒子滤波 (RBPF) 算法作为一种新的方法来处理 SLAM 问题. 随后, Montemerlo 等[3]于 2003 年提出了一种基于 Rao-Blackwellized 粒子滤波器的 FastSLAM 算法 (RBPF-SLAM). 相比于适合高斯线性系统的 EKF-SLAM 算法, RBPF-SLAM 算法根据 SLAM 问题的条件独立特性, 将高维状态下的环境地图和移动机器人轨迹的联合后验概率密度解耦为低维状态估计, 从而解决了状态空间 SLAM 算法维数高

收稿日期: 2015-10-08；**修回日期:** 2016-01-14.

基金项目: 国家自然科学基金项目(51075420)；国家科技部国际合作项目(2010DFA12160).

作者简介: 张毅 (1966−), 男, 教授, 博士生导师, 从事机器人导航、多模人机交互等研究；郑潇峰 (1992−), 女, 硕士生, 从事机器人导航的研究.

的问题, 提高了 SLAM 的计算效率[4].

然而, 随着时间的递增, 粒子权值方差也随之增大, 粒子退化现象是不可避免的[5]. 为了减少粒子退化现象, 引入重采样方法, 即复制高权值粒子, 舍弃低权值粒子, 产生多个等权值的粒子. 这样虽然改善了粒子退化, 但同时造成粒子匮乏. 为此, 自适应的重采样的方法成为研究重点. Moral 等[6]对自适应重采样策略及收敛性进行了详细分析, 一些利用自适应方法改进重采样的 SLAM 算法[7]被提出. 虽然这些算法能够抑制样本匮乏现象, 提高估计准确性, 但其增加了计算时间. 该类算法以较少的粒子数完成重采样, 但在同等时间条件下仅能达到有限的精度.

针对 RBPF-SLAM 中重采样粒子匮乏及计算量大的问题, 本文提出一种高斯分布的重采样 (GDR) 算法, 在高斯分布中进行粒子的重采样可以保持粒子多样性, 避免粒子匮乏问题. 该改进算法可以减小计算代价, 增强粒子滤波算法的鲁棒性, 同时保证可靠精确的估计. 仿真实验结果验证了该改进算法的有效性.

1 RBPF-SLAM 算法描述

RBPF-SLAM 算法的关键步骤是利用机器人传感器获得的观测信息 $z_{1:t} = z_1, z_2, \cdots, z_t$ 和里程计控制的历史信息 $u_{1:t} = u_1, u_2, \cdots, u_{t-1}$ 来估计环境地图 m 和机器人轨迹 $x_{1:t} = x_1, x_2, \cdots, x_t$ 的联合后验概率分布 $P(x_{1:t}, m|z_{1:t}, u_{1:t-1})$. 基于 SLAM 的条件独立性结论是: 若移动机器人轨迹 $x_{1:t} = x_1, x_2, \cdots, x_t$ 已知, 环境地图 m 各个相互独立, 则联合后验概率分布可表示为

$$P(x_{1:t}, m|z_{1:t}, u_{1:t-1}) = P(m|x_{1:t}, z_{1:t})P(x_{1:t}|z_{1:t}, u_{1:t-1}). \tag{1}$$

式 (1) 称为 Rao-Blackwellized 分解. 由该分解可知, RBPF-SLAM 算法首先估计机器人轨迹的后验概率, 然后由轨迹计算环境地图的后验概率. 采用 Rao-Blackwellized 粒子滤波器估计轨迹后验概率, 其中: 每个粒子代表一种潜在的轨迹和一幅环境地图; 根据地图之间相互独立的特性, 采用卡尔曼滤波器估计每个粒子地图的独立高斯分布.

Rao-Blackwellized 粒子滤波器采用序列重要性重采样 (SIR) 滤波器在地图构建过程中增量式地处理即时获得的里程计数据及传感器观测数据作为提议分布 π, 它用来更新和表示轨迹和地图的后验概率. 该过程可总结为以下 4 个步骤.

1) 粒子采样. 将机器人里程计信息和激光测距仪获得的观测信息的概率分布作为提议分布 π, 在该分布中由上一代粒子 $\{x_{1:t-1}^{(i)}\}$ 获得下一代粒子 $\{x_{1:t}^{(i)}\}$.

2) 权值计算. 每个粒子都有一个权值 $w_t^{(i)}$, 由重要性采样原则计算求得权值的大小为

$$w_t^{(i)} = \frac{P(x_{1:t}^{(i)}|z_{1:t}, u_{1:t})}{\pi(x_{1:t}^{(i)}|z_{1:t}, u_{1:t})}. \tag{2}$$

权值大小说明了提议分布 π 与状态的目标分布不相同.

3) 重采样. 在采样集中找到可替换的小权值粒子. 经过重采样步骤, 得到权值相同的粒子. 归一化后的重要性权值为

$$w_t^{(i)} = \frac{\tilde{w}(x_{1:t}^{(i)})}{\sum\limits_{j=1}^{N} \tilde{w}(x_{1:t}^{(i)})}. \tag{3}$$

归一化权值 $w_t^{(i)}$ 与样本粒子 $\{x_{1:t}^{(i)}, m^{(i)}\}$ 共同决定联合后验概率分布 $P(x_{1:t}, m|z_{1:t}, u_{1:t-1})$. 假设用 N 个带权值的样本 $\{(x_{1:t}^{(i)}, m^{(i)}), w_t^{(i)}\}_{i=1}^N$ 来表示后验概率分布 $P(x_{1:t}, m|z_{1:t}, u_{1:t-1})$, 则

$$P(x_{1:t}, m|z_{1:t}, u_{1:t-1}) = \sum_{i=1}^{N} w_t^{(i)} \delta_{x_{1:t}^{(i)}, m}(x_{1:t}, m), \tag{4}$$

其中 $\delta_{(\cdot)}(\cdot)$ 为 Dirac 函数.

4) 地图更新. 对于每个粒子, 采用其轨迹 $x_{1:t}^{(i)}$ 和观测值 $z_{1:t}^{(i)}$ 计算相应的 $P(m^{(i)}|x_{1:t}^{(i)}, z_{1:t})$, 即

$$P(m^{(i)}|x_{1:t}^{(i)}, z_{1:t}) = \sum_{i=1}^{N} w_t^{(i)} P(m|z_{1:t}, u_{1:t-1}, x_{1:t}^{(i)}). \tag{5}$$

基本的采样方法、计算权值、重采样和地图估计过程已在文献 [8] 中详细描述, 本文重点研究重采样过程舍弃低权重粒子, 保留高权重粒子造成的粒子匮乏问题.

2 RBPF-SLAM 算法改进

2.1 基于高斯分布重采样的 RBPF-SLAM 算法

文献 [7] 中用到了自适应重采样方法, 通过计算有效采样尺度 N_{eff} 来确定粒子退化程度. N_{eff} 定义为 $N_{\text{eff}} = N/(1 + \text{var}_{P((\cdot)|z_{1:t})}(w_t^{(i)})) \leqslant N$. 但是, 实际中无法按照该式确切计算 N_{eff} 数值, 所以通过下式近似估计:

$$N_{\text{eff}} = 1 \Big/ \sum_{i=1}^{N} (w_t^{(i)})^2, \tag{6}$$

其中 $w_t^{(i)}$ 代表粒子的归一化权重.

设定有效样本数 $N_{\text{threshold}} = aN_{\text{particle}}$ 作为阈值 (其中 N_{particle} 为粒子个数, $0 < a < 1$), 当 $N_{\text{eff}} < N_{\text{threshold}}$ 时, 进行重采样步骤. 上述方法虽在一定程度上减少了重采样次数, 但判断有效采样粒子的时间却有所增加, 且未在保持粒子多样性方面做出改进.

为了解决上述问题, 需要在重采样过程中适当增加粒子多样性以提高估计精度, 因此, 在继传统

RBPF-SLAM 算法使用自适应重采样的基础上, 本文提出一种基于高斯分布的改进重采样 (GDR)RBPF-SLAM 算法. 相比于一般重采样中采用的均匀分布, GDR 算法采用高斯分布得到的新粒子有着更密集的分布, 从而保留了较为完整的重采样信息, 改善了重采样过程并且保持了粒子多样性. 该算法在减小计算量的同时也表现出稳定的性能.

GDR 算法的核心概念是用一个高斯分布来分散足够高权重的粒子, 而不是简单地复制高权重粒子. 由以下两个步骤来实现该算法.

1) 运用改进的重量累积和 (CSW) 方法. 改进的 CSW 方法根据权重大小将粒子排序, 然后计算权重的累积和. 图 1 为标准 CSW 方法和改进 CSW 方法的对比. 图 1 中每一条垂直的线视为粒子进入采样区的界限. 在标准 CSW 方法中, 一些低权重粒子在界限附近, 因此采样过程中很容易进入采样区. 但在改进的 CSW 方法中, 界限附近的低权重粒子个数减少, 因而可进入采样区的高权重粒子个数相对增加. 换言之, 在改进的 CSW 方法中由于低权重粒子进入采样区的数量减少, 高权重粒子进入采样区的概率将增加.

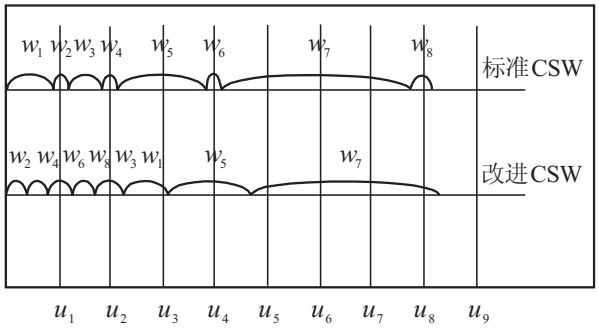

图 1　标准 CSW 方法和改进 CSW 方法对比

2) 用高斯分布代替简单的复制方法将高权重粒子进行分散. 利用进入采样区的高权重粒子得到高斯分布中的新粒子. 图 2 表示了新得到粒子数量与进入采样区粒子数量相同, 正比于粒子权重大小.

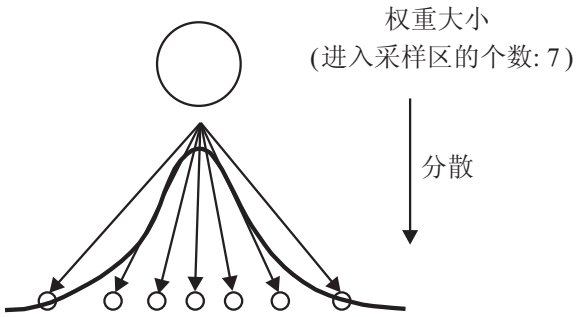

图 2　高斯分布分散高权重粒子

用 $\hat{x}_k$ 来表示进入采样区粒子的状态向量. 新得到的粒子在高斯分布中具有均值, 该均值与状态 $\hat{x}_k$ 相对应; 还具有与权重成反比的方差. 表示如下:

$$\hat{x}_k^j \sim N(\hat{x}_k^i, \Sigma_k), \tag{7}$$

$$\Sigma_k \propto \frac{1}{w_k^i},\ \Sigma_k = \frac{\alpha}{w_k^i}. \tag{8}$$

其中: α 是调整分布程度的参数, i 是进入采样区粒子的序列数, j 是当前新得到粒子的序列数, Σ_k 是表示新粒子离散程度的方差参数. 设置方差参数 Σ_k 来分散高权重粒子. GDR 算法流程如下:

1) 重采样过程中采用改进 CSW 方法排序粒子权重大小;

2) 利用高斯分布分散高权重粒子;

3) 得到新粒子.

GDR 算法改善了样本贫乏问题, 同时避免了样本局部最小.

2.2　基于高斯分布重采样 RBPF-SLAM 算法流程

针对传统 RBPF-SLAM 在重采样过程中粒子匮乏的缺陷, 加入基于高斯分布重采样的 RBPF-SLAM 算法, 解决了粒子匮乏问题, 在保持粒子多样性的同时可以减小计算量, 有效提高估计精度. 改进算法的具体步骤如下:

1) 由机器人位姿 $x_{t-1}^{(i)}$ 和里程计控制信息 u_{t-1} 估计机器人初始位姿 $x_{t-1}^{'(i)}$;

2) 由地图扫描匹配算法 (根据机器人轨迹 $x_{1:t-1}^{(i)}$) 计算地图 $m_{t-1}^{(i)}$;

3) 在提议分布 π 中对粒子采样;

4) 计算及更新每个粒子的权重;

5) 根据 2.1 节所述在高斯分布中对粒子进行重采样操作;

6) 根据机器人位姿 $x_t^{(i)}$ 和观测信息 z_t 计算地图 $m_t^{(i)}$, 并进行地图更新.

3　实验研究

3.1　仿真实验

为验证所提出算法较文献 [7] 中的基于自适应重采样 RBPF-SLAM 算法的有效性, 进行两组仿真实验. 使用平台为 Matlab7.0 (计算机主频 2.9 GHz), 采用悉尼大学野外机器人中心发布的两个数据集进行仿真研究[9]. 仿真环境由简单到复杂 (由路标个数决定). 图 3 中的环境地图为 200 m × 160 m, 包含 50 个路标; 图 4 中的环境地图为 400 m × 350 m, 包含 200 个路标; 其中 "*" 代表路标的实际位置, "·" 代表路标的估计位置. 仿真中机器人以 3 m/s 的速度、观测最远距离为 35 m、观测时间间隔为 200 ms 且控制量间隔为 25 ms 的初始状态开始移动, 并按照全局设定的目标点运动, 直至一个周期后到达目标点.

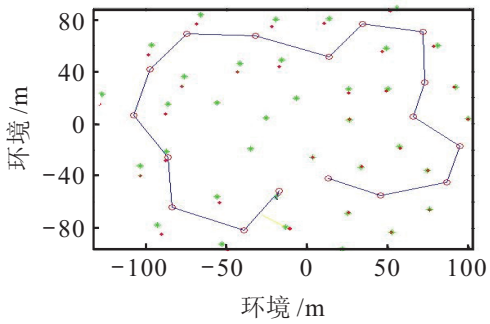

(a) 对比算法

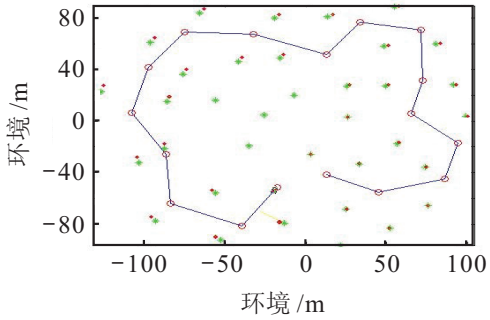

(b) 改进算法

图 3 简单环境下不同算法的实现结果

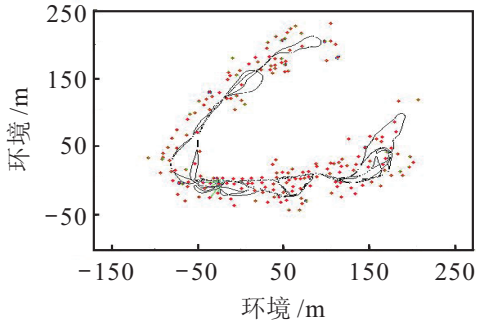

(a) 对比算法

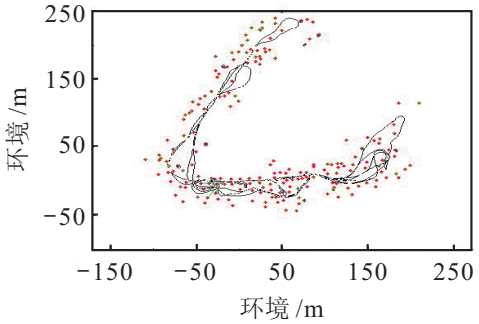

(b) 改进算法

图 4 复杂环境下不同算法的实现结果

针对上述仿真环境, 分别采用对比算法和改进算法对环境路标进行仿真估计. 图 3 和图 4 分别为两种算法的仿真结果.

简单环境下, 基于自适应重采样的 RBPF-SLAM 算法得到图 3(a) 中路标的估计位置与实际位置有一定差距. 通过对比可以看出, 改进算法得到的图 3(b) 中所示估计位置与实际位置重合度更高. 改进算法在估计路标位置时效果优于基于自适应重采样 RBPF-SLAM 算法, 即估计精度更高.

图 4 中的仿真环境相比图 3 较为复杂. 图 4(a) 中因基于自适应重采样 RBPF-SLAM 算法的重采样过程出现粒子匮乏问题而导致估计的路标个数不完全, 而图 4(b) 中基于高斯分布重采样 RBPF-SLAM 算法依旧能精确地估计所有设定的路标, 从而验证了改进算法的有效性.

为了分析改进算法的运算时间, 表 1 记录了两种环境下对比算法和改进算法运行主要步骤所需时间. 可以看出, 改进算法在重采样步骤上大大节省了运算时间, 有效提高了该算法的运算效率.

表 1 对比算法和改进算法计算时间 ms

步骤	简单环境		复杂环境	
	对比算法	改进算法	对比算法	改进算法
更新粒子	105	60	256	173
重采样	600	225	850	469

为了更加直观地分析改进算法的优势, 本文给出了改进算法与对比算法在仿真时间 60 s 下的位姿状态估计精确性对比曲线. 由图 5 的仿真结果可知, 改进算法对位姿估计的均方根误差远小于对比算法, 曲线趋势相对平滑. 因此, 改进算法的状态估计精度优于对比算法. 由于在提议分布中加入了激光测距仪的观测信息, 使得粒子分布在真实状态的附近, 由实验结果可知, 改进的 RBPF-SLAM 算法是收敛的.

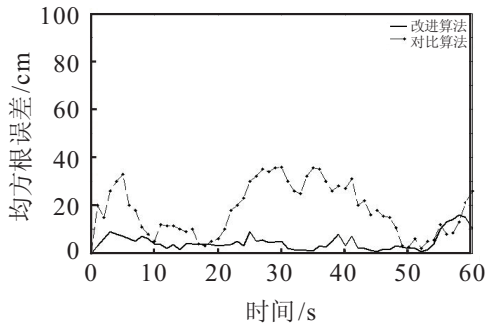

图 5 状态估计误差对比曲线

3.2 ROS 上改进 RBPF-SLAM 实现

2010 年 Willow Garage 公司发布了开源机器人操作系统 (ROS), 由于其具有点对点设计、不依赖编程语言、开源等优点, 很快在机器人领域展开学习和使用 ROS 的热潮[10]. 在 ROS 中, Griseti 等[11]的 RBPF-SLAM 算法被制作成一个名为 Gmapping 的功能包[12], 使用激光测距仪可以建立精度较高的二维栅格地图.

实验平台由装载 URG-04LX 激光测距仪的 Pioneer 3-DX 机器人, 配有英特尔酷睿双核, 主频 2.9 GHz, 内存 4 G 的笔记本电脑组成. 笔记本电脑安装

Ubuntu 12.04 操作系统及 Hydro 版本的 ROS. 由操纵杆控制机器人运动. 实验环境为重庆邮电大学信息科技大厦一楼.

本实验环境地图近似 40 m × 25 m. 分别用基于自适应重采样的 RBPF-SLAM 算法和基于高斯分布重采样的 RBPF-SLAM 算法进行地图构建. 图 6(a) 是由基于自适应重采样的 RBPF-SLAM 算法创建的地图, 采用了 20 个采样粒子. 可以看出, 由于该算法采样粒子匮乏, 图中所标①、② 和③ 位置的地图出现不一致; 图 6(b) 是基于高斯分布重采样的 RBPF-SLAM 算法创建的相同环境下的地图, 只用了 5 个采样粒子, 但创建的地图比图 6(a) 更精确.

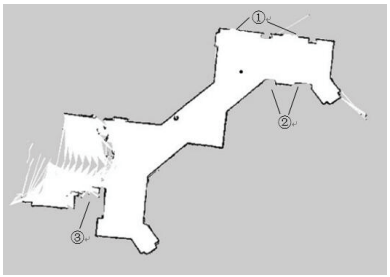

(a)　对比算法

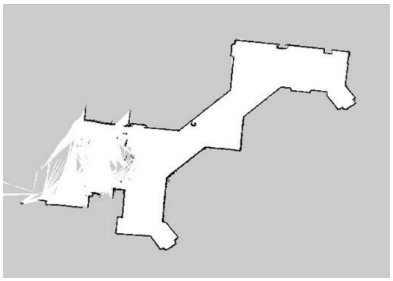

(b)　改进算法

图 6　不同算法创建的地图 (1)

图 7 的实验是通过创建环形地图来验证改进算法的有效性和鲁棒性. 环形闭合指的是移动机器人沿不同路径回到已创建的地图区域时, 由于累计误差而无法确认该区域为以前观测过的区域. 本实验地图的有效面积为 60 m × 50 m. 机器人绕该环境地图运动 4 圈. 图 7(a) 是基于自适应重采样的 RBPF-SLAM 算法使用 50 个采样粒子所创建的环形地图, 由于该算法中粒子匮乏问题较严重, 导致创建的地图出现了 "假墙" 现象 (如①～④ 标出); 图 7(b) 是基于高斯分布重采样的 RBPF-SLAM 算法创建相同的地图, 仅使用 10 个采样粒子便创建出高精度的地图.

3.3　实验结果分析

由图 6 和图 7 的两组对比实验可以看出, 与基于自适应重采样的 RBPF-SLAM 算法相比, 改进算法能以更少的采样粒子个数创建出一致性更高、效果更好的地图. 这是因为改进算法采用高斯分布重采样来获

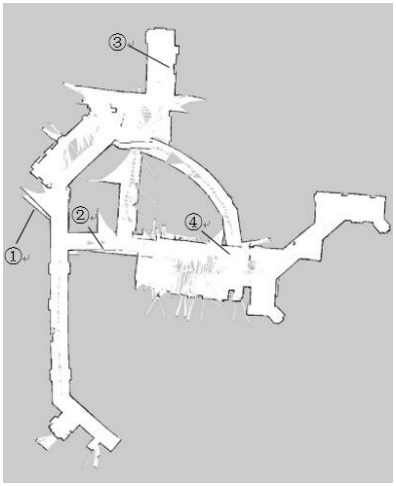

(a)　对比算法

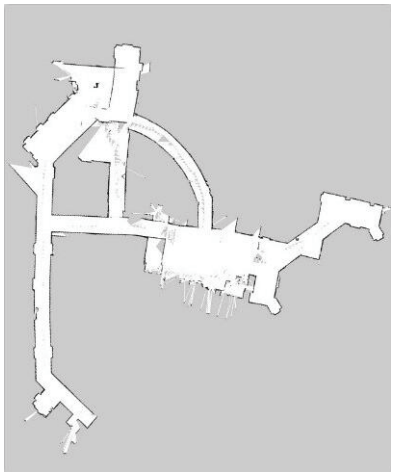

(b)　改进算法

图 7　不同算法创建的地图 (2)

得分布较广的新粒子, 改善了粒子匮乏问题, 以较少的粒子数构建出高精度的地图.

表 2 比较了改进算法和基于自适应重采样的 RBPF-SLAM 算法在图 6 和图 7 的实验中, 创建相同复杂度地图所需要的粒子数. 两组实验在分别设定的粒子数下重复进行 10 次, 总共进行 40 次实验. 从表 2 中可以看出, 改进算法由于采样的准确性而大大减少了所需粒子数.

表 2　创建一致性地图所需的粒子个数

实验	图 6 实验粒子数	图 7 实验粒子数
对比算法	20	50
改进算法	5	10

表 3 比较了改进算法和对比算法在有效采样粒子个数下的重采样次数.

表 3　创建一致性地图重采样次数

实验	图 6 实验重采样	图 7 实验重采样
对比算法	67	152
改进算法	45	86

由于重采样过程需要拷贝地图数据, 该步骤会消耗大量的计算时间, 而使用栅格地图表示方法的地图数据量非常大. 改进算法使用了高斯分布重采样策略, 通过分散高权重粒子, 使重采样之后的新粒子有较广的分布, 因而能通过较少粒子个数进行重采样, 使得重采样发生次数减少, 从而提高了算法的效率.

4 结 论

本文提出了一种基于高斯分布重采样的Rao-Blackwellized粒子滤波SLAM算法, 在进行粒子重采样过程中使用高斯分布分散高权重粒子重新获得采样后粒子分布, 从而避免了粒子匮乏问题, 改善了因缺乏粒子多样性而造成的估计不精确问题. 最后, 通过实验验证了改进算法的有效性和创建地图的精确性. 后续工作将针对有环形闭合的大环境的地图构建实时效率问题进行研究.

参考文献(References)

[1] Montemerlo M, Thrun S. Simultaneous localization and mapping with unknown data association using FastSLAM[C]. Proc of the 2003 IEEE Int Conf on Robotics and Automation. Taipei, 2003, 2: 1985-1991.

[2] Murphy K, Russell S. Rao-Blackwellised particle filtering for dynamic Bayesian networks[C]. Sequential Monte Carlo Methods in Practice. New York: Springer, 2001: 499-515.

[3] Montemerlo M, Thrun S, Koller D, et al. FastSLAM: A factored solution to the simultaneous localization and mapping problem[C]. Proc of Eighteenth National Conf on Artificial Intelligence. California, 2002: 593-598.

[4] 宋宇, 李庆玲, 康轶非, 等. 平方根容积Rao-Blackwillised粒子滤波SLAM算法[J]. 自动化学报, 2014, 40(12): 357-367.
(Song Y, Li Q L, Kang Y F, et al. SLAM with square-root cubature Rao-Blackwellized particle filter[J]. Acta Automatica Sinica, 2014, 40(12): 357-367.)

[5] Djuric P M, Kotecha J H, Zhang J, et al. Particle filtering[J]. Signal Processing Magazine of IEEE, 2003, 20(5): 19-38.

[6] Del Moral P, Doucet A, Jasra A. On adaptive resampling strategies for sequential Monte Carlo methods[J]. Bernoulli, 2012, 18(1): 252-278.

[7] Pei F, Wu M, Zhang S. Distributed SLAM using improved particle filter for mobile robot localization[J]. Scientific World J, 2014: 278-279.

[8] Smith A. Sequential Monte Carlo methods in practice[M]. New York: Springer Science and Business Media, 2013: 499-515.

[9] Bailey T. SLAM simulations[EB/OL]. [2012-09-02]. http：//www.personal.acfr.usyd.edu.au/tbailey/software/.

[10] 张建伟, 张立新, 胡颖, 等. 开源机器人操作系统——ROS[M]. 北京: 科学出版社, 2012: 1-6.
(Zhang J W, Zhang L X, Hu Y, et al. Open-source robot operating system — ROS[M]. Beijing: Science Press, 2012: 1-6.)

[11] Grisetti G, Stachniss C, Burgard W. Improved techniques for grid mapping with Rao-Blackwellized particle filters[J]. IEEE Trans on Robotics, 2007, 23(1): 34-46.

[12] Gerkey B. Gmapping in ROS[EB/OL]. [2010-08-05]. http：//www.wiki.ros.rog/slam/gmapping/.

(责任编辑：李君玲)

下 期 要 目

时间序列数据挖掘的相似性度量综述 · · ·