

采用双重采样的移动机器人 Monte Carlo 定位方法

李天成¹ 孙树栋¹

摘要 移动机器人 Monte Carlo 定位效率受限于大量粒子的权值更新运算. 本文提出一种实现粒子集规模自适应调整的双重采样方法: 第一层基于粒子权重的固定粒子数重采样, 有效减轻粒子权值退化并保证预测阶段粒子多样性; 第二层粒子稀疏化聚合重采样, 基于粒子空间分布合理性将粒子加权聚合, 从而减少参与权值更新粒子数. 该方法通过提高粒子预测能力保证滤波精度, 通过减少权值更新运算提高了粒子滤波效率. 仿真实验表明, 双重采样方法能够有效实现粒子集规模自适应调整, 采用双重采样的移动机器人 Monte Carlo 定位方法是高效、鲁棒的.

关键词 Monte Carlo 定位, 自适应粒子滤波, 双重采样, 移动机器人

DOI 10.3724/SP.J.1004.2010.01279

Double-resampling Based Monte Carlo Localization for Mobile Robot

LI Tian-Cheng¹ SUN Shu-Dong¹

Abstract The computational efficiency of Monte Carlo localization (MCL) for mobile robots mainly depends on the weight updating of particles. A double-resampling method which adapts the sample size in MCL is presented in this paper. The first resampling with fixed sample size mitigates the weight degeneracy and improves the diversity of particles for prediction. The second sparse resampling reduces the number of particles for updating using a particle merging technique based on rational distribution of spatial particles. Decreasing the weight updating computation and enhancing the prediction capability of particles, the double-resampling method improves the efficiency of the filtering while guarantees the accuracy of the estimation. Simulation and experiment results show that the double-resampling approach can adapt the sample size efficiently and that the double-resampling based MCL for mobile robot is highly efficient and robust.

Key words Monte Carlo localization (MCL), adaptive particle filter, double-resampling, mobile robot

移动机器人定位问题是机器人确定其在所处环境中自身位姿的过程, 属于非线性动态系统最优状态估计问题^[1]. 粒子滤波器 (Particle filter, PF) 利用带权重的粒子集描述状态量的概率分布, 用 Monte Carlo 方法来实现递推贝叶斯滤波 (Bayesian filter, BF), 是一种鲁棒、有效的非线性非高斯系统次优预估方法^[2]. 粒子滤波方法应用于移动机器人定位研究, 即 Monte Carlo 定位 (Monte Carlo localization, MCL) 方法, 近十年来受到了广泛关注. 而大量的粒子优化更新运算导致算法运行效率低是粒子滤波器主要的不足^[1], 也已成为移动机器人实时、在线 Monte Carlo 定位首要解决的问题之一.

提高粒子滤波效率最直接、最有效的方法是减少样本粒子数, 而粒子数过少往往引起对概率分布描述能力不足、滤波器过早收敛等问题, 以致滤波失败. 当前主要的研究思路是提高粒子集的微观能力和自适应调整能力, 即在满足滤波器有效性前提

下, 自适应调整粒子集规模. 文献 [3] 最早提出基于似然的自适应采样 (Likelihood-based adaptation) 思路. 文献 [4] 提出一种 KLD (Kullback-Leibler distance) 采样方法, 通过计算后验概率分布与粒子集最大似然概率分布之间的 K-L 距离实时计算滤波所需粒子数, 之后又出现了一系列的改进方法^[5-6]. KLD 自适应采样及其改进方法主要基于粒子权重采样, 粒子集调整方法缺乏考虑粒子空间分布. 另外的一些粒子集自适应调整研究^[7-11] 中, 提出一些减少所需采样粒子数的研究思路, 其实现方法上也没有考虑粒子空间分布的合理性. 文献 [12] 提出特征粒子概念减少多机器人协作 Monte Carlo 定位数据更新运算, 具有粒子空间分布的合理性. 然而直接选取栅格中心作为特征粒子缺乏对粒子权重的考虑, 为此, 其又通过变精度栅格划分实现计算资源按粒子权重分配的合理性, 而变精度栅格并不易于实时划分.

MCL 具有如下特性: 1) 采用样本粒子描述机器人位姿后验概率并迭代运算, 样本粒子的多样性决定滤波器的鲁棒性, 尤其表现在粒子集的预测能力上^[1, 9, 11]; 2) 滤波器迭代周期与采样粒子数成正比, 其中粒子集权值更新需要完成粒子特征提取与似然函数匹配^[1, 4, 13-14], 运算量占比最大; 3) 单纯基于粒子权重实现的 (重) 采样^[15] 调整粒子集规模方

收稿日期 2010-01-25 录用日期 2010-05-13
Manuscript received January 25, 2010; accepted May 13, 2010
国家高技术研究发展计划 (863 计划) (2007AA04Z187) 资助
Supported by National High Technology Research and Development Program of China (863 Program) (2007AA04Z187)

1. 西北工业大学机电学院 西安 710072
1. School of Mechatronic, Northwestern Polytechnical University, Xi'an 710072

法单一,不能保证粒子空间分布的合理性,难以最大程度有效利用有限的粒子.基于此,本文提出一种实现粒子集规模自适应调整的双重采样方法:第一层基于粒子权重的固定粒子数重采样,增加采样粒子数以增强粒子集预测能力;第二层粒子稀疏化聚合重采样,基于粒子空间分布控制粒子集规模,实现粒子集规模与粒子空间规模的一致性“自适应”,采样方法具有空间分布合理性.双重采样方法动态平衡预测阶段粒子多样性和更新阶段粒子集规模,计算资源的分配综合考虑粒子权重和空间分布的合理性.仿真与实验结果表明该方法能够有效实现粒子集自适应调整,采用双重采样的移动机器人 MCL 是高效、鲁棒的.

1 Monte Carlo 定位与重采样

机器人位姿^[1]一般描述为三维状态空间变量 $x_t = (x, y, \theta)$, 其中 (x, y) 表示 Cartesian 坐标系中机器人位置, θ 表示机器人朝向角. 贝叶斯滤波器求解机器人位姿的主要思路是: 在机器人所处动态系统中, 根据机器人初始状态概率分布 $p(x_0)$ 、截止到时刻 t 对机器人的控制序列 $u_{1:t} = \{u_k | k = 1, 2, \dots, t\}$ 和机器人对环境的感知序列 $o_{1:t} = \{o_k | k = 1, 2, \dots, t\}$, 递归估计状态空间后验边缘概率密度 $p(x_t | o_{1:t}, u_{1:t-1})$. 基于这一思路, 粒子滤波器通过寻找一组在状态空间中传播的随机样本 $S_t = \{x_t^i, w_t^i\}_{i=1,2,\dots,N_t}$ 对状态估计量 x_t 的概率密度函数 $p(x_t | o_{1:t})$ 进行近似并迭代更新:

$$p(x_t | o_{1:t}) \approx \sum_{i=1}^{N_t} w_t^i \delta(x_t - x_t^i) \quad (1)$$

式中, N_t 为 t 时刻样本粒子总数, 权重 w_t^i 表征每个样本 x_t^i 的重要性, 满足所有粒子权重之和为 1, $\delta(\cdot)$ 表示在 x_t^i 处的狄拉克 Delta 函数.

粒子滤波递归迭代过程可分为两个阶段:

1) 预测. 根据运动模型 $p(x_t | x_{t-1}, u_{t-1})$ 、上一时刻状态 x_{t-1} 和控制输入 u_{t-1} 预测当前状态 x_t :

$$p(x_t | o_{1:t-1}, u_{1:t-1}) = p(x_t | x_{t-1}, u_{t-1}) \times p(x_{t-1} | o_{1:t-1}, u_{1:t-2}) \quad (2)$$

2) 更新. 根据感知模型 $p(o_t | x_t)$ 及当前获得的感知信息 o_t , 更新当前状态 x_t :

$$p(x_t | o_{1:t}, u_{1:t-1}) = \frac{p(o_t | x_t) p(x_t | o_{1:t-1}, u_{1:t-1})}{p(o_t | o_{1:t-1}, u_{1:t-1})} \quad (3)$$

式中, $p(o_t | x_t)$ 完成感知信息与系统模型的似然函数匹配, 移动机器人感知信息通常来自于声纳^[1,4]、激光雷达^[4,13]、视觉传感器^[14] 等.

粒子滤波的理论基础之一是序贯重要性采样 (Sequential importance sampling, SIS), 而 SIS 存在权值退化 (Weight degeneracy) 的严重缺陷, 即滤波器过早收敛. 一个有效的改进方法是对粒子和相应权表示的概率密度函数重新采样^[15]: 抑制或剔除小权值粒子, 对于大权值粒子则依其权值大小进行复制, 从而把计算资源按照粒子权重进行分配, 得到等权重粒子集. 重采样结合 SIS 就构成通常的采样重要性重采样 (Sampling importance resampling, SIR) 或 (Sequential importance sampling and resampling, SISR), 基于 SIR 的粒子滤波器粒子迭代周期可描述如图 1, 其中箭头符号示意粒子在状态空间的传播.

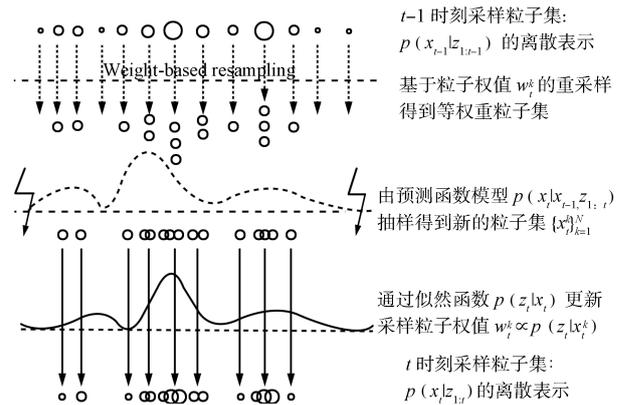


图 1 基于序贯重要性重采样的粒子集迭代周期

Fig. 1 The iteration of particle set in SIR

2 双重采样方法

2.1 粒子稀疏化聚合重采样

随着机器人位姿估计的逐渐收敛, 粒子空间分布也呈收敛、聚簇趋势, 粒子的空间区分度远小于机器人对环境辨识能力, 以至粒子显得“冗余”而造成粒子集权值更新耗费过多的计算资源. 因此, 本文在粒子集进行权值更新之前, 基于粒子空间尺度网格划分对粒子稀疏化加权聚合, 以缩减粒子集规模, 称之为粒子稀疏化聚合重采样.

首先给出划分状态空间网格的有关定义:

定义 1 (n 维空间). 设 $A = D_1, D_2, \dots, D_n$ 是 n 个有界定义域, 则 $S = D_1 \times D_2 \times \dots \times D_n$ 就是一个 n 维空间, 并称 D_1, D_2, \dots, D_n 为 S 的维.

定义 2 (网格单元). 若将 n 维空间 S 的第 i 维分成长度相等的 m_i 个左闭右开区间, 从而将整个空间 S 划分为 $m_1 \times m_2 \times \dots \times m_n$ 个不相交的 n 维网格单元 g^n .

定义 3 (网格密度). 用空间上隶属于网格单元 g_i 内的样本粒子数表示 g_i 的网格密度, 记为 $den(g_i)$. 当 $den(g_i) = 0$ 时, 称 g_i 为空; 否则, 称 g_i

非空.

定义 4 (网格集). 当前网格及其 l ($l \leq n$) 维方向上的相邻网格, 组成一个当前网格对应的 3^l 规模的网格集 (合), 本文对网格集相关变量采用 “#” 标记, 网格 g_i 对应的 l 维网格集记为 $\#g_i^l$. $l = n$ 时, 称 $\#g_i^l$ 为全维网格集; $l < n$, 称 $\#g_i^l$ 为不全维网格集.

定义 5 (粒子聚合). 基于样本粒子权重, 将单位空间内的全部粒子加权平均, 得到一个 “聚合粒子”, 该单位空间称为聚合单元. 本文以网格集作为聚合单元实现的粒子聚合方法称为交叉聚合.

本文实施粒子稀疏化聚合重采样步骤如下:

步骤 1. 划分网格. 粒子空间划分为 K 个非空网格单元 (对应 K 个网格集). 含有 N_k 个粒子的网格单元可描述为 $g_k: \{(x_k^i, w_k^i) \mid i = 1, 2, \dots, N_k\}$, 其中 $k = 1, 2, \dots, K$, x_k^i 表示粒子状态, w_k^i 表示粒子权重. 对应的, l 维网格集 $\#g_k^l: \{(x_k^i, w_k^i) \mid i = 1, 2, \dots, \#N_k\}$, $\#N_k^l$ 为聚合单元 $\#g_k^l$ 含有的粒子数.

步骤 2. 交叉聚合. 以网格集作为聚合单元, 聚合单元内的全部粒子加权合并, 得到中心网格的 “聚合粒子”, 聚合方程式:

$$\begin{cases} \hat{x}_t^k = \frac{\sum_{i=1}^{\#N_k^l} x_k^i w_k^i}{\sum_{i=1}^{\#N_k^l} w_k^i} \\ \hat{w}_t^k = \frac{\sum_{i=1}^{\#N_k^l} w_k^i}{3^l} \end{cases} \quad (4)$$

式中, $(\hat{x}_t^k, \hat{w}_t^k)$ 表示第 k 个网格对应的聚合粒子. 考虑到状态量的维数对运算量的影响, 可根据粒子分布特性采用全维网格集和不全维网格集两种聚合单元. 一种思路是粒子区分度很小的维度方向不必划分, 如机器人的角度感知相对精确时, 不作朝向角 θ 维度的划分, 只划分二维位置网格.

聚合方程式实现粒子集规模与粒子空间规模的 “自适应” 一致, 采样方法具有空间分布合理性. 同时, 聚合粒子空间分布上表现为高权重的粒子影响更大, 具有计算资源按粒子权重分配的合理性. 另一方面: 1) 与文献 [12] 提出的特征粒子相比, 粒子交叉聚合过程, 每个粒子 (尤其是高权重粒子) 平均加权到 3^l 个聚合粒子, 在一定程度上 “均化” 了粒子分布, 能够有效地缓解权重过于集中到单个粒子引起的权重退化问题; 2) 聚合方程式运算复杂度也要小于基于阈值参数的栅格划分、占据栅格的半径搜索等^[12] 分析运算; 3) 与 KLD 采样方法^[4-6] 相比,

粒子聚合重采样不会摒弃小权值粒子, 同时增加预测阶段粒子集规模, 可以避免单纯基于粒子权重采样引起的粒子多样性匮乏现象.

式 (4) 将空间相近粒子聚合为具有区域空间特征的聚合粒子, 控制粒子集规模以提高粒子集更新效率. 为避免粒子数减少引起粒子多样性匮乏及 “预测能力” 不足, 本文在粒子预测更新之前, 采用传统基于权重的固定粒子数重采样, 增加预测阶段粒子数. 这样就通过两次重采样 (双重采样) 实现了预测和更新两阶段粒子集规模自适应调整. 采用双重采样 (Sampling importance double-resampling, SIRR) 的粒子滤波器粒子迭代过程可描述如图 2.

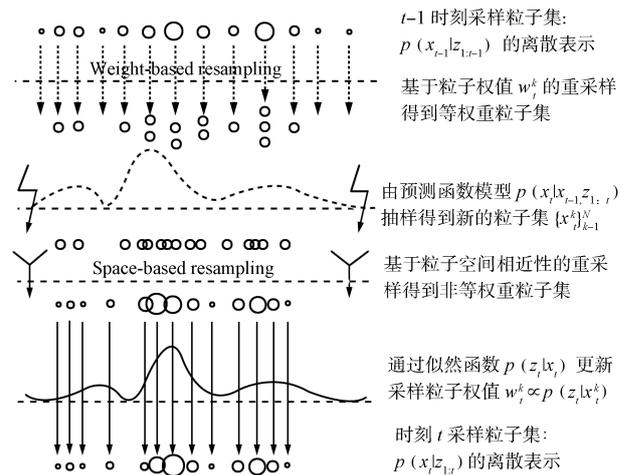


图 2 采用双重采样的粒子集迭代周期

Fig. 2 The iteration of particle set in SIRR

基于预先划分的网格空间和聚合方程式 (4) 进行粒子稀疏化聚合重采样, 主要是粒子状态量的比较和加权运算, 复杂度为 $O(N)$, N 为粒子数, 等同于通常的基于粒子权重实现的重采样^[15]. 重采样过程无需复杂运算或智能分析, 计算代价远小于涉及粒子特征提取、关联与匹配运算的权重更新运算. 由此可见, 增加一层重采样以减少粒子权重更新运算次数从而提高算法的实时性是可行的.

2.2 双重采样 Monte Carlo 定位

将双重采样方法应用于机器人 Monte Carlo 定位, 首要解决的问题是确定粒子稀疏化聚合网格单元大小. 本文解决思路是: 假设机器人感知系统在第 i 维 (距离 x 、 y 或角度 θ) 的误差是 e_i , 粒子聚合近似过程, 相同网格集内的所有粒子加权聚合为一个聚合粒子, 而同一个粒子又属于相邻的不同网格集, 这样 “聚合” 造成的第 i 维的近似误差应小于 e_i , 网格单元第 i 维划分间距:

$$L_i = \frac{\xi \times e_i}{3}, \quad \xi \in (0, 1) \quad (5)$$

式中, 聚合维 $i \in \{x, y, \theta\}$, ξ 为定位精度系数, e_i 值采用经验预估的办法确定. 同时, 为保证聚合粒子的有效性, 设定网格密度阈值 $Minden$, 仅对 $den(g_i) \geq Minden$ 的网格 g_i 进行聚合重采样.

采用双重采样的 MCL 过程可描述如下.

SIRR-MCL 算法

输入. $t - 1$ 时刻的带权粒子集 $S_{t-1} = \{x_{t-1}^k, w_{t-1}^k\}_{k=1, \dots, N_{t-1}}$, 机器人控制输入 u_{t-1} , 实时观测 o_t , 参数 $Minden, L = [L_x, L_y, L_\theta]$

输出. t 时刻的带权粒子集 S_t

步骤 1. S_t 置空;

步骤 2. 基于粒子权值 w_{t-1} 重采样, 生成等权重粒子集 $\hat{S}_{t-1} = \{x_{t-1}^i, w_{t-1}^i\}_{i=1, 2, \dots, N_p}$ ($N_p > N_{t-1}$, N_p 设为较大值);

步骤 3. 按预测模型 $p(x_t^i | x_{t-1}^i, u_{t-1})$ 预测 t 时刻粒子集 $\tilde{S}_t = \{x_t^i, w_t^i\}_{i=1, 2, \dots, N_p}$;

步骤 4. 根据网格规模 L , 划分状态网格子空间: $\{g_k | k = 1, 2, \dots, K_t\}$, 并计算网格密度;

步骤 5. 参考 $Minden$ 进行粒子稀疏化聚合重采样, 生成聚合粒子集 $\hat{S}_t = \{x_t^k, w_t^k\}_{k=1, 2, \dots, N_t}$ (一般的, $N_t < N_p$);

步骤 6. 按更新模型 $p(o_t | x_t)$ 更新聚合粒子权值 $w_t^k |_{k=1, 2, \dots, N_t}$;

步骤 7. 粒子权值 w_t^i 归一化, 将 $\{x_t^k, w_t^k\}_{k=1, 2, \dots, N_t}$ 加入 S_t ;

步骤 8. 返回 S_t .

3 双重采样有效性分析

双重采样 SIRR 较通常的 SIR 主要增加一层粒子稀疏化聚合重采样. 因此有必要分析聚合粒子的有效性以及双重采样方法的有效性.

3.1 粒子聚合前后样本均值与方差比较

以粒子作为样本, 将频数定义扩展至实数域, 粒子权重即为样本出现频数. 粒子稀疏化聚合重采样前后的粒子样本分别称为原始粒子样本和聚合粒子样本. 则有:

结论 1. 原始粒子分布和聚合粒子分布样本均值相等, 样本方差后者偏小.

证明. 设 e, η 分别为原始粒子样本均值和方差, $\hat{e}, \hat{\eta}$ 为聚合粒子样本均值和方差. 两粒子集样本均值相等是显然的:

$$\hat{e} = \sum_{k=1}^K \hat{x}_t^k \hat{w}_t^k = \sum_{k=1}^K \frac{\sum_{i=1}^{\#N_k^l} x_{k,t}^i w_{k,t}^i}{3^l} = \sum_{k=1}^K \sum_{i=1}^{N_k} x_{k,t}^i w_{k,t}^i = e \tag{6}$$

对于聚合粒子分布方差, 根据聚合方程式 (4),

有:

$$\hat{\eta} = \sum_{k=1}^K (\hat{x}_t^k - \hat{e})^2 \hat{w}_t^k = \sum_{k=1}^K \frac{\left[\left(\frac{\sum_{i=1}^{\#N_k^l} x_{k,t}^i w_{k,t}^i}{\sum_{i=1}^{\#N_k^l} w_{k,t}^i} \right)^2 - 2e \frac{\sum_{i=1}^{\#N_k^l} x_{k,t}^i w_{k,t}^i}{\sum_{i=1}^{\#N_k^l} w_{k,t}^i} + e^2 \right] \sum_{i=1}^{\#N_k^l} w_{k,t}^i}{3^l} \tag{7}$$

再由 Cauchy-Schwarz 不等式整理:

$$\hat{\eta} \leq \sum_{k=1}^K \frac{\sum_{i=1}^{\#N_k^l} (x_{k,t}^i - e)^2 w_{k,t}^i}{3^l} = \sum_{k=1}^K \sum_{i=1}^{N_k} (x_{k,t}^i - e)^2 w_{k,t}^i = \eta \tag{8}$$

当且仅当聚合网格单元足够小, 以致每个网格集最多只包含一个粒子时等号成立. \square

3.2 同分布检验

本节采用斯米尔诺夫检验^[16] 方法检验聚合前后样本分布一致性, 其基本思路是: 对顺序分类的两组观测 (样本) 的经验分布进行比较, 求出其偏离值的上确界作为统计量, 然后在给定的显著性水平上检验这种偏离值是否是偶然出现的, 以验证两组观测是否来自同一分布. 为保证粒子多样性, 通常要求 $n_1, n_2 > 50$, 满足斯米尔诺夫检验的前提条件. 要检验的两组样本为: 原始粒子样本记为 $(X_1, X_2, \dots, X_{n_1})$, 设为来自连续分布函数 $F(x)$ 的总体 X 的样本; 聚合粒子样本记为 $(Y_1, Y_2, \dots, Y_{n_2})$, 设为来自连续分布函数 $G(x)$ 的总体 Y 的样本. 假定两组样本是相互独立的 (以检验其相关性), 检验聚合前后粒子是否同分布, 即判断 $F(x) = G(x)$ 是否成立.

1) 建立检验假设

$$H_0 : F(x) = G(x) \leftrightarrow H_1 : F(x) \neq G(x), \quad -\infty < x < \infty$$

2) 构造统计量

设 $F_{n_1}(x) = G_{n_2}(x)$ 分别为两组样本所对应的经验分布函数, 并按照网格空间顺序进行样本排序, 构造统计量:

$$D_{n_1, n_2} = \sup_{-\infty < x < \infty} |F_{n_1}(x) - G_{n_2}(x)| \tag{9}$$

式中, \sup 为上确界, 统计量 D_{n_1, n_2} 即两样本分布最大偏离值, 斯米尔诺夫检验有如下引理:

引理 1. 如果 $F(x) = G(x)$, 且 $F(x)$ 为连续函数, 则

$$\lim_{n_1 \rightarrow \infty, n_2 \rightarrow \infty} p \left\{ \sqrt{\frac{n_1 n_2}{n_1 + n_2}} D_{n_1, n_2} < x \right\} = K(x) = \begin{cases} 0, & x \leq 0 \\ \sum_{k=-\infty}^{\infty} (-1)^k e^{-2k^2 x^2}, & x > 0 \end{cases} \quad (10)$$

3) 显著水平和拒绝域

对于给定的显著水平 α , 可由文献 [16] 附表 7 查得 $\lambda_{1-\alpha}$, 令 $n = n_1 n_2 / (n_1 + n_2)$, 可得参考值 $D_n \approx \lambda_{1-\alpha} / \sqrt{n}$. 比较 D_{n_1, n_2} 与 D_n : 若 $D_{n_1, n_2} < D_n$, 则接受原假设 H_0 , 否则拒绝 H_0 , 接受 H_1 . 接受原假设 H_0 即意味聚合粒子样本和原始粒子样本分布相同, 结合结论 1, 则理论上证明聚合重采样能够保证粒子分布的整体特性, 聚合粒子是原始粒子分布的方差偏小的无偏相合估计.

4) 检验

结论 2. 基于定义式 (9), 两组样本经验分布的最大偏离值 D_{n_1, n_2} 出现在最大权重聚合粒子处, 且为其权重值的一半.

证明. 按网格空间顺序进行样本排序, 由聚合方程式 (4) 知, 聚合粒子分布和原始粒子分布在对应聚合单元空间内的样本容量是相等的. 这样以聚合单元作为样本分组 (统计离散化), 则聚合前后粒子样本经验分布是无偏离的. 两组样本仅在组 (聚合单元) 内发生偏离, 而由聚合单元定义, 聚合粒子样本集在组内仅有一个聚合粒子, 处于组内原始粒子群加权中心, 所以组内最大偏离值出现在聚合粒子处, 且为聚合粒子权重一半. 继而推知, 两组样本经验分布的最大偏离值 D_{n_1, n_2} 也就出现在最大权重聚合粒子处, 且为最大权重的一半. \square

结论 2 说明 D_{n_1, n_2} 的理论值是不依赖于样本分组的. 记聚合粒子最大权重为 w_0 , 则取到 $D_{n_1, n_2} = w_0/2$. 若满足 $D_{n_1, n_2} < D_n$, 则原假设 H_0 成立, 即

$$\frac{w_0}{2} < D_n \quad (11)$$

上式是从非参数假设检验出发给出一个聚合粒子和原始粒子同分布的充要条件, 限定了聚合粒子最大权值, 可作为网格划分规模的参考因素. 若取斯米尔诺夫同分布假设检验显著水平 $\alpha = 0.05$, $n = 100$, 由文献 [16] 附表 7 查得 $\lambda_{1-\alpha} = 1.36$, 再得 $D_n < 0.136$, 或者直接查附表 6 得 $D_n = 0.134$, 代入式 (11) 分别得到 $w_0 < 0.272$, $w_0 < 0.268$, 这是可以 95% 的可信度认为粒子聚合前后同分布的一个充分条件.

3.3 粒子聚合重采样饱和

按式 (4) 进行粒子聚合, 聚合粒子集规模取决于粒子空间规模和网格划分, 并不与原始粒子集规模成一定线性关系, 称之为粒子聚合重采样饱和. 基于此, SIRR 第一层重采样可以选择“较大”的粒子集规模 (第 2.2 节中 N_P), 进一步增强粒子多样性及预测描述能力, 从而提高滤波器鲁棒性. 这是考虑到粒子滤波器收敛过程, 粒子空间规模是逐渐趋于稳定的, 因此第二层粒子稀疏化聚合重采样能够控制聚合粒子集规模, 不会明显降低滤波效率. 这说明聚合采样方法不会受限于环境规模, 双重采样方法对于大范围空间的 Monte Carlo 定位也是有效的. 这也表明, 双重采样方法和移动机器人 MCL 效率主要取决于粒子集权值更新, 而其有效性及鲁棒性依赖于粒子多样性和预测能力的特性相符合.

4 仿真与实验结果

4.1 双重采样粒子滤波器

为进一步验证双重采样方法的有效性, 本节通过仿真实验对比采用双重采样方法的自适应粒子滤波器 SIRR-PF 与通常的序贯重要性重采样粒子滤波器 SIR-PF, 着重测试双重采样方法的粒子集自适应调整能力及其对滤波精度影响. 仿真平台计算机 CPU 主频 1.86 GHz, 内存 1 GB, 仿真开发工具 Matlab 7.8. 采用预测模型 (12) 和观测更新模型 (13) 进行对比.

$$x_t = \frac{x_{t-1}}{2} + \frac{25x_{t-1}}{1+x_{t-1}^2} + 8 \cos(1.2t) + e_t \quad (12)$$

$$o_t = \frac{x_t^2}{20} + v_t \quad (13)$$

式中, e_t 是均值为 0、方差为 10 的高斯噪声, v_t 是均值为 0、方差为 1 的高斯噪声. 这是一个广泛用于滤波分析的非线性动态系统.

仿真实验共设计 6 组滤波器进行对比, 两组 SIR-PF 粒子数分别为 100、200, 4 组 SIRR-PF: 考虑到粒子聚合重采样饱和趋势, 第一层基于粒子权值重采样分别选取较 SIR-PF 更大的粒子数 $N_P = 200$, $N_P = 500$, 第二层粒子聚合重采样的网格规模分别为 $L = 0.2$, $L = 0.02$ (一维状态空间划分一维网格), 设定网格聚合的粒子密度阈值 $Minden = 1$, 即对全部网格均进行粒子聚合. 仿真共进行 1000 次迭代运算, 图 3 给出其中 100 步的滤波结果, 图 4 给出其中 10 步的粒子数波动, 其中粒子集迭代周期分别显示滤波器预测阶段和更新阶段粒子数. 表 1 给出 6 组滤波器滤波结果对比.

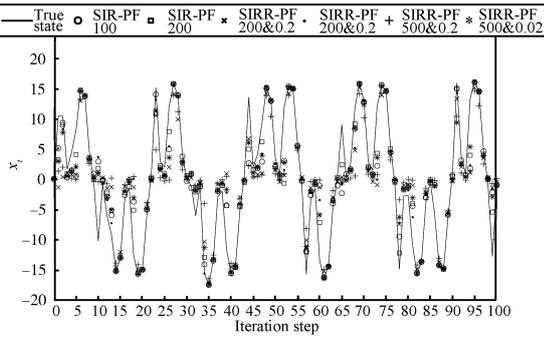


图3 粒子滤波器仿真结果

Fig. 3 Simulation results of particle filters

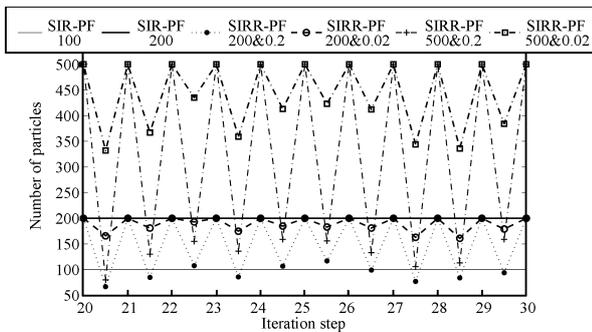


图4 滤波过程采样粒子数

Fig. 4 Numbers of particles in filtering

表1 粒子滤波器性能对比

Table 1 Particle filters performance reference table

滤波器	N_p	L	\bar{N}_u	RMSE	运行耗时 (s)
SIR-PF	100	-	100	5.1492	0.887
SIR-PF	200	-	200	4.9097	3.116
SIRR-PF	200	0.2	92	5.1189	3.457
SIRR-PF	200	0.02	178.3	4.9414	6.355
SIRR-PF	500	0.2	129.3	5.0435	9.751
SIRR-PF	500	0.02	379.8	4.8153	27.297

表1中, \bar{N}_u 为权值更新阶段平均粒子数, RMSE (Root mean square error) 为滤波估计的均方根差. 对比仿真结果, 可以得到如下结论: 1) SIR-PF 滤波过程粒子数固定, SIRR-PF 能够实现粒子集动态调整, 调整的幅度与预测阶段粒子数 N_p 以及网格划分 L 有关. 且 L 越大、 N_p 越小, 权值更新阶段粒子数越小, 滤波效率越高; 2) N_p 越大, 均方根误差 RMSE 越小, 这表明 SIRR-PF 通过增加预测阶段粒子数提高预测多样性和算法的鲁棒性, 能够有效保证滤波精度; 3) 双重采样方法并没有提高粒子滤波效率, 反而由于引入了粒子聚合重采样降低了滤波效率. 这是由于仿真中粒子滤波器采用的更新模型 (13) 简单, 其运算量尚不及预测模型 (12), 因此权值更新阶段减少粒子数并不能明显提高滤波效率. 而对于移动机器人 MCL 定位, 机

器人运动预测模型一般仅涉及数值加和运算及简单随机数生成运算, 运算量小. 而权值更新模型需要完成粒子特征提取、关联及匹配等计算, 运算量占比很大. 这时, 采用双重采样方法减少权值更新运算将能够大大提高粒子集更新效率, 我们采用实验验证这一点.

4.2 移动机器人定位实验

基于不完全确定环境进行移动机器人定位实验, 实验环境如图5和图6: 实验场地为西北工业大学创新中心三楼东段, 实验采用一台 ASR “能力风暴” 轮式机器人, 装配一个 SICK LMS200 激光雷达测距仪提供环境扫描信息. 它每隔 20 ms 扫描一次, 间隔 0.5 度, 共获取 361 个距离值. 将实验环境中的桌椅、盘栽以及偶然出现的人员走动作为未知障碍 (预先的机器人环境建模中并未包含, 由图5中灰色区域表示). 为进行对比, 我们基于 MFC 框架开发多线程程序, 基于 SIR 的基本 Monte Carlo 方法和本文提出的 SIRR-MCL 方法分配单独的线程, 并行定位运算, 并实时记录定位结果.

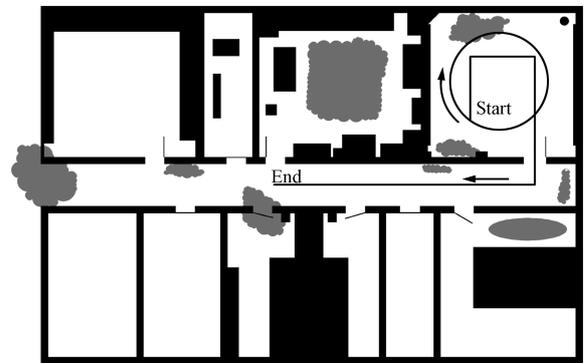


图5 室内实验环境与机器人运行路线

Fig. 5 Indoor experiment environment and planned path



图6 装配激光测距仪的实验机器人

Fig. 6 Experiment robot using a laser ranger

实验中, 机器人采用位置闭环精细运动控制, 机器人走廊运行速率设为 0.4 m/s, 室内运行速率设为 0.2 m/s, 原地转向轮速 0.1 m/s. SIR-MCL 采样粒子数设为 1000, 本文 SIRR-MCL 第一层基于权重

重采样设定粒子数为 2 000, 第二层基于粒子空间分布重采样设置网格规模为 $40\text{ mm} \times 40\text{ mm} \times 2^\circ$. 以单位时间内完成的定位次数作为定位效率, 以定位结果偏离路径大小作为定位误差. 如图 5 中箭头标示, 进行了直行和转向两类典型路径的定位实验: 实验 1, 机器人从实验室中走出到达另一个房间门口, 直线路径的定位过程如图 7, 定位误差分析如图 8; 实验 2, 机器人循环一个直径 3 m 圆形路径如图 9, 定位误差分析如图 10. 两次实验定位结果分析见表 2.

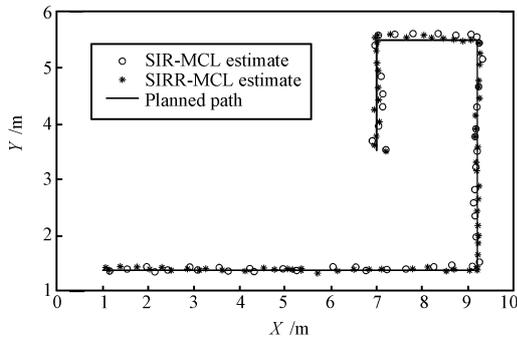


图 7 实验 1 中直行路径定位结果

Fig. 7 Localization result of a rectangular path in Experiment 1

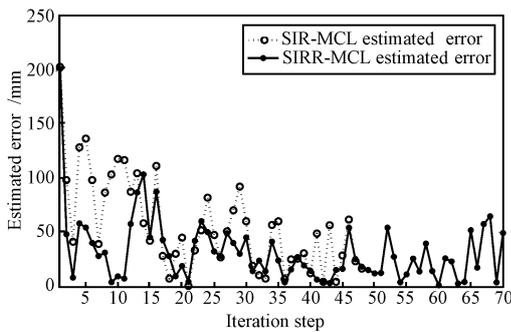


图 8 实验 1 中定位误差对比

Fig. 8 Comparison of localization errors in Experiment 1

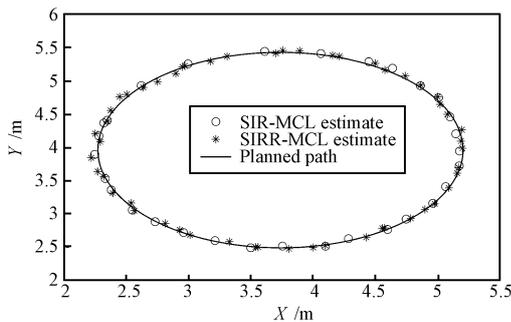


图 9 实验 2 中圆形路径定位结果

Fig. 9 Localization result of a circle path in Experiment 2

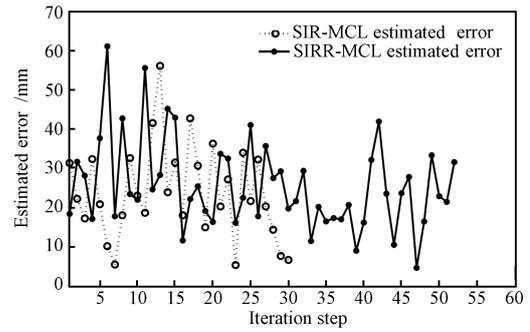


图 10 实验 2 中定位误差对比

Fig. 10 Comparison of localization errors in Experiment 2

表 2 实验结果对比

Table 2 Comparison of experiment results

定位算法	实验路径	\bar{N}_u	平均定位误差 /mm	定位次数
SIR-PF	实验 1	1 000	56.059	48
SIR-PF	实验 2	1 000	23.911	30
SIRR-PF	实验 1	413	31.716	70
SIRR-PF	实验 2	355	25.699	52

相同计算资源分配和系统状态下, 本文提出的 SIRR-MCL 与 SIR-MCL 实验结果对比如下: 1) 定位效率: 实验 1 和实验 2 中 SIRR-MCL 滤波定位效率分别提高了 37.5% 和 25.7%, 这主要是因为粒子稀疏化聚合重采样大大减少了参与权值更新运算的粒子数. 虽然 SIRR-MCL 预测阶段粒子数为 2 000, 而聚合粒子集规模平均在 400 ~ 600 范围, 实验 1 和实验 2 中更新阶段平均粒子数 (\bar{N}_u) 较 SIR-MCL 分别少了 58.7% 和 64.5%. 且随着位姿解的收敛 (进入位姿跟踪状态), 聚合粒子集规模趋于稳定. 2) 滤波定位精度: 双重采样方法由于引入了粒子聚合重采样以缩减需要更新运算的粒子数, 一定程度上影响了滤波定位精度, 如实验 1. 但 SIRR-MCL 增加了预测阶段粒子, 能够显著提高粒子预测的多样性和鲁棒性, 因此并不会明显降低定位精度. 尤其是在动态未知障碍物区域, 实验 2 中 SIRR-MCL 较 SIR-MCL 反而提高了滤波定位精度. 对比实验 1 和实验 2, 也说明在合理划分聚合网格的情况下, 双重采样不会明显降低定位精度, 并能够显著提高滤波器实时性和鲁棒性. 仿真与实验结果和理论分析相一致, 验证了本文提出的双重采样方法是鲁棒、高效的.

5 结论

本文提出一种双重采样方法, 其通过增加预测阶段粒子、减少权值更新粒子实现粒子集规模自适应调整. 双重采样方法在保证预测阶段粒子多样性、减轻粒子退化的前提下, 采用较少的聚合粒子完成

粒子集权值更新,从而在保证滤波精度前提下提高滤波效率.仿真与实验结果验证了双重采样方法的有效性,采用双重采样的移动机器人 Monte Carlo 定位方法是鲁棒、高效的,并能够保证定位精度.

基于粒子空间分布尺度划分实现的粒子聚合重采样能够保证粒子空间分布的合理性,且随着机器人位姿估计的收敛,聚合重采样能够显著提高求解效率.而在定位初始阶段及机器人遭遇绑架^[1]时粒子分布较为分散,聚合效果并不明显.最差的情况是划分的网格内最多只含有一个粒子,粒子聚合重采样之后,粒子数并不会减少,此时聚合重采样也不会影响定位结果.因此,选择适时地引入双重采样以及将双重采样方法和 KLD 采样等方法结合是值得进一步研究的课题.值得注意的是,作为对粒子滤波技术本身的一种改进,双重采样方法在更广泛的非线性动态系统(尤其是观测更新模型较为耗时)粒子滤波研究与应用中也是值得借鉴的.

References

- 1 Thrun S, Burgard W, Fox D. *Probabilistic Robotics*. London: MIT Press, 2005. 91–280
- 2 Doucet A, Johansen A M. A tutorial on particle filtering and smoothing: fifteen years later. *Handbook of Nonlinear Filtering*. London: Oxford University Press, 2009
- 3 Koller D, Fratkina R. Using learning for approximation in stochastic processes. In: *Proceedings of the 15th International Conference on Machine Learning*. Madison, USA: Morgan Kaufmann, 1998. 287–295
- 4 Fox D. Adapting the sample size in particle filters through KLD-sampling. *The International Journal of Robotics Research*, 2003, **22**(12): 985–1003
- 5 Kwok C, Fox D, Meila M. Real-time particle filters. *Proceedings of the IEEE*, 2004, **92**(3): 469–484
- 6 Soto A. Self adaptive particle filter. In: *Proceedings of the 19th International Joint Conferences on Artificial Intelligence*. Edinburgh, UK: Morgan Kaufmann, 2005. 1398–1406
- 7 Hong Bing-Rong, Luo Rong-Hua. Robust self-localization of mobile robot. *Journal of Harbin Institute of Technology*, 2003, **35**(9): 1047–1049
(洪炳榕, 罗荣华. 一种鲁棒移动机器人自主定位方法. 哈尔滨工业大学学报, 2003, **35**(9): 1047–1049)
- 8 Grisetti G, Stachniss C, Burgard W. Improving grid-based SLAM with Rao-Blackwellized particle filters by adaptive proposals and selective resampling. In: *Proceedings of the IEEE International Conference on Robotics and Automation*. Barcelona, Spain: IEEE, 2005. 2432–2437
- 9 Hu X L, Schon T B, Ljung J. A basic convergence result for particle filtering. *IEEE Transactions on Signal Processing*, 2008, **56**(4): 1337–1348
- 10 Shan C F, Tan T N, Wei Y C. Real-time hand tracking using a mean shift embedded particle filter. *Pattern Recognition*, 2007, **40**(7): 1958–1970
- 11 Pan P, Schonfeld D. Dynamic proposal variance and optimal particle allocation in particle filtering for video tracking. *IEEE Transaction on Circuits and Systems for Video Technology*, 2008, **18**(9): 1268–1279
- 12 Liu Jun-Cheng, Yuan Kui, Zou Wei, Zhu Hai-Bing. Monte Carlo self-localization based on characteristic particles. *Robot*, 2006, **28**(1): 30–35
(刘俊承, 原魁, 邹伟, 朱海兵. 基于特征粒子的 Monte Carlo 自定位方法. 机器人, 2006, **28**(1): 30–35)
- 13 Einsele T. *Localization in Indoor Environment Using a Panoramic Laser Range Finder* [Ph. D. dissertation], Technical University of Munich, Germany, 2001
- 14 Ramisa A, Tapus A, Aldavert D, Toledo R, de Mantaras R L. Robust vision-based robot localization using combinations of local feature region detectors. *Autonomous Robots*, 2009, **27**(4): 373–385
- 15 Bolic M, Djuric P M, Hong S. Resampling algorithms for particle filters: a computational complexity perspective. *EURASIP Journal on Applied Signal Processing*, 2004, **2004**(15): 2267–2277
- 16 Shi Yi-Min, Xu Wei, Qin Chao-Ying, Xu Yong. *Mathematical Statistics (Third Edition)*. Beijing: Science Press, 2009. 134–139
(师义民, 徐伟, 秦超英, 许勇. 数理统计(第三版). 北京: 科学出版社, 2009. 134–139)



李天成 西北工业大学机电学院博士研究生. 2008 年获得哈尔滨工程大学学士学位. 主要研究方向为移动机器人定位与导航, 多机器人协作. 本文通信作者.

E-mail: troy_jacy@live.cn

(**LI Tian-Cheng** Ph. D. candidate at the School of Mechatronics, Northwestern Polytechnical University. He

received his bachelor degree from Harbin Engineering University in 2008. His research interest covers mobile robot localization and navigation, multi-robot coordination. Corresponding author of this paper.)



孙树栋 西北工业大学教授. 主要研究方向为机器人及其智能控制, 现代集成制造系统和工业工程.

E-mail: sdsun@nwpu.edu.cn

(**SUN Shu-Dong** Professor at the School of Mechatronics, Northwestern Polytechnical University. His research interest covers robot intelligent control,

modern integrated manufacturing system, and industrial engineering.)