

粒子滤波自适应机制研究综述*

于金霞^{1,2}, 汤永利^{1,3}, 刘文静¹

(1. 河南理工大学 计算机科学与技术学院, 河南 焦作 454003; 2. 南京邮电大学 江苏省图像处理与图像通信重点实验室, 南京 210003; 3. 清华大学 计算机科学与技术系, 北京 100084)

摘 要: 针对粒子滤波固有的缺陷, 结合移动机器人领域的研究应用成果, 分别从样本数目自适应、重采样自适应、建议分布自适应、运动/似然模型自适应以及与其他方法的集成等几个方面对粒子滤波自适应机制当前研究的关键技术进行了归纳总结, 并且对该研究领域需要解决的研究难点进行了总结, 对进一步研究的方向进行了展望。

关键词: 粒子滤波; 自适应机制; 样本数目; 重采样; 建议分布; 运动/似然模型

中图分类号: TP24 文献标志码: A 文章编号: 1001-3695(2010)02-0417-06

doi: 10.3969/j.issn.1001-3695.2010.02.005

Survey on adaptive mechanisms of particle filter

YU Jin-xia^{1,2}, TANG Yong-li^{1,3}, LIU Wen-jing¹

(1. College of Computer Science & Technology, Henan Polytechnic University, Jiaozuo Henan 454003, China; 2. Jiangsu Provincial Key Laboratory of Image Processing & Image Communication, Nanjing University of Posts & Communication, Nanjing 210003, China; 3. Dept. of Computer Science & Technology, Tsinghua University, Beijing 100084, China)

Abstract: Aimed at the inherent deficiency in particle filter and combined with the up-to-date research and application in the mobile robot field, this paper summarized some key technologies in current study from the adaptive mechanism of sample size respectively, the resampling strategy, proposal distribution, motion/likelihood model and the integration with other methods. At the same time, concluded the main challenges that needed to be solved in this field and also presented some future trends about the technology of these difficulties.

Key words: particle filter; adaptive mechanisms; sample size; resampling; proposal distribution; motion/likelihood model

0 引言

粒子滤波(PF)也称序列蒙特卡罗(sequential Monte Carlo, SMC), 源于 Gordon 等人^[1]提出的一种基于序列重要性采样(sequential importance sampling, SIS)的自举(bootstrap)非线性滤波方法。PF 的核心思想是用随机加权的样本(也称粒子)集合来近似表征后验概率密度函数。原则上, PF 可以用于任意非线性非高斯动态系统的状态递推估计或概率推理研究, 近年在移动机器人领域如定位^[2]、目标跟踪^[3]、并发定位与地图创建^[4]以及故障诊断^[5]得到成功应用。

基于 SIS 的 PF 算法潜在的问题是样本退化问题(degeneracy), 也即在滤波过程中经过几次迭代, 除了一个样本外其余样本的重要性权重均很小。文献[6]指出: 重要性权重的方差随着时间增长而增大, 因而样本退化是不可避免的。这样, 大量的计算时间浪费在更新权重较小的样本上。针对样本退化问题, 可以增加样本大小至无穷来解决, 但很低效。

为了解决样本退化问题, 采样重要性重采样(sampling-importance resampling, SIR)被引入 PF 中。但是 SIR 带来新的问题^[7], 由于权值越大的样本子代越多, 相反则子代越少甚至无

子代。这样重采样后样本集中样本多样性丧失, 从而不足以用来近似表征后验密度, 尤其是在过程噪声较小时问题更严重。最糟糕的情形就是新的样本集实际都是某一个最健壮样本的子代, 这就是样本枯竭(impoverishment)问题。

为解决这些问题, 国内外大量文献对此进行了深入剖析^[7~13], 提出的主要解决办法有建议分布的选择、重采样策略的改进、有效推理的执行、自适应机制的引入以及与其他方法的集成。其中, 引入自适应机制的 PF 称为自适应粒子滤波。由于在对整个状态空间处理中, 概率密度可能会随着时间的变化发生巨大改变。在 PF 中引入自适应机制, 可改进 PF 执行和计算的有效性从而降低计算误差。在 PF 自适应机制研究方面, 目前主要提出了样本数目自适应^[14~27]、重采样自适应^[6, 28~33]、建议分布自适应^[28, 34~37]、运动/似然模型自适应^[38~41]以及结合其他机制的自适应方法^[42~46]。

对于非线性、非高斯及多模分布的递归 Bayesian 状态估计问题, 基于自适应机制的 PF 研究尽管只有十多年, 但是已经成为研究热点问题。为此, 国内外学者展开了诸多研究, 提出了许多研究思路和实用算法。在此基础上, 本文针对粒子滤波固有的缺陷, 对 PF 自适应机制所开展的研究进行综述。首先介绍了 PF 的基本算法及其当前依然存在的问题; 然后结合

收稿日期: 2009-06-01; 修回日期: 2009-07-20 基金项目: 河南省教育厅自然科学基金资助项目(2008B520015, 2009B520013); 河南理工大学博士基金资助项目(B2008-61, B2009-91); 江苏省图像处理与图像通信重点实验室开放研究课题(ZK208002)

作者简介: 于金霞(1974-), 女, 河南博爱人, 副教授, 博士, 主要研究方向为人工智能、移动机器人环境建模与定位技术(melissa2002@163.com); 汤永利(1972-), 男, 助理研究员, 在站博士后, 主要研究方向为信息安全; 刘文静(1982-), 女, 硕士研究生, 主要研究方向为人工智能。

移动机器人领域的研究应用成果,对于当前 PF 自适应机制研究的关键技术进行了归纳总结;最后通过对该研究领域需要解决的研究难点进行分析,对进一步研究的方向进行了展望。

1 PF 基本算法

1.1 PF 基本算法

不失一般性,假定系统的状态方程和测量方程描述如下:

$$\begin{cases} x_t = f(x_{t-1}, u_{t-1}) + w_t \\ z_t = h(x_t) + v_t \end{cases}$$

(1)

(2)

其中: x_t 表示 t 时刻的系统状态; u_{t-1} 表示 $t-1$ 时刻的系统输入; z_t 表示 t 时刻的系统测量; w_t 和 v_t 分别表示 t 时刻的过程噪声和测量噪声(它们独立同分布)。状态方程式(1)刻画了系统的状态转移概率 $p(x_t | x_{t-1}, u_{t-1})$, 测量方程式(2)刻画了似然概率 $p(z_t | x_t)$ 。

从贝叶斯滤波角度,在给定系统输入 $u_{1:t-1} = u_1, \dots, u_{t-1}$ 和测量数据 $z_{1:t} = z_1, \dots, z_t$, 问题求解的核心是估计后验分布 $p(x_t | z_{1:t}, u_{0:t-1})$ 。假设 x_t 服从一阶 Markov 过程,且初始状态 x_0 的概率分布 $p(x_0 | z_0) \equiv p(x_0)$, 则后验分布 $p(x_t | z_{1:t}, u_{0:t-1})$ 的估计分为预测/更新递归执行。

a) 预测。依据前一时刻状态的后验信度 $\text{Bel}(x_{t-1})$ 也即概率分布 $p(x_{t-1} | z_{1:t-1}, u_{0:t-2})$, 结合状态方程式(1)来预测当前 t 时刻状态 x_t 的先验信度 $\text{Bel}^-(x_t)$ 。

Bayes规则

$$\text{Bel}^-(x_t) = p(x_t | z_{1:t-1}, u_{0:t-1}) =$$

Markov假设

$$\int p(x_t | x_{t-1}, z_{1:t-1}, u_{0:t-1}) p(x_{t-1} | z_{1:t-1}, u_{0:t-2}) dx_{t-1} =$$

$$\int p(x_t | x_{t-1}, u_{t-1}) p(x_{t-1} | z_{1:t-1}, u_{0:t-2}) dx_{t-1} =$$

状态方程

后验信度

$$\int \underbrace{p(x_t | x_{t-1}, u_{t-1})}_{\text{状态方程}} \underbrace{\text{Bel}(x_{t-1})}_{\text{后验信度}} dx_{t-1} =$$

(3)

b) 更新。利用测量方程式(2),结合当前的感知测量信息 z_t 来更新当前 t 时刻状态 x_t 的后验信度 $\text{Bel}(x_t)$ 。

Bayes规则

$$\text{Bel}(x_t) = p(x_t | z_{1:t}, u_{0:t-1}) =$$

Markov假设

$$\frac{p(z_t | x_t, z_{1:t-1}, u_{0:t-1}) p(x_t | z_{1:t-1}, u_{0:t-1})}{p(z_t | z_{1:t-1}, u_{0:t-1})} =$$

$$\frac{p(z_t | x_t) p(x_t | z_{1:t-1}, u_{0:t-1})}{p(z_t | z_{1:t-1})} =$$

标准化因子

测量方程

先验信度

$$\eta \underbrace{p(z_t | x_t)}_{\text{测量方程}} \underbrace{\text{Bel}^-(x_t)}_{\text{先验信度}} \quad (4)$$

其中: 标准化因子 $\eta^{-1} = p(z_t | z_{1:t-1}) = \int p(z_t | x_t) p(x_t | z_{1:t-1}, u_{0:t-1}) dx_t$ 。

粒子滤波是贝叶斯滤波的变种,它采用 N_s 个随机加权的样本集合 $\{x_t^i, w_t^i\}_{i=1, \dots, N_s}$ 来近似表征后验概率密度函数 $p(x_t | z_{1:t}) = \sum_{i=1}^{N_s} w_t^i \delta(x_t - x_t^i)$ 。因而,式(3)中求解 $\text{Bel}^-(x_t)$ 的积分运算可以转换为样本的求和运算,即

$$\text{Bel}^-(x_t) = \sum_{i=1}^{N_s} p(x_t | x_{t-1}^i, u_{t-1}) \text{Bel}(x_{t-1}^i) =$$

$$\sum_{i=1}^{N_s} w_{t-1}^i \delta(x_t - x_t^i) \text{Bel}(x_{t-1}^i) \quad (5)$$

其中: $\delta(\cdot)$ 表示 Dirac delta 函数,权重满足归一化条件 $\sum_{i=1}^{N_s} w_t^i = 1$ 。当 $N_s \rightarrow \infty$ 时,利用式(4)(5)的样本可以近似达到真实后验分布 $p(x_t | z_{1:t}, u_{0:t-1})$ 。

PF 算法开始时从初始信度 $p(x_0)$ 采样,接着对每个时间步执行预测—更新—重采样递归循环过程。式(6)为形式化 PF 的执行步骤,它源于应用 Bayes 规则到后验概率中,接着使用 Markov 假设,该公式从右到左执行。

$$p(x_t | z_{1:t}, u_{0:t-1}) =$$

当前的PDF

重采样

测量方程

$$\eta \underbrace{p(z_t | x_t)}_{\text{标准化因子}} \underbrace{p(x_t | x_{t-1}, u_{t-1})}_{\text{状态方程}} \underbrace{p(x_{t-1} | z_{1:t-1}, u_{0:t-2})}_{\text{先前的PDF}}$$

更新

状态方程

预测

(6)

1.2 存在的问题

现有的粒子滤波算法大多使用固定大小的样本数目^[2],这显然非常低效,但是样本数目增大在导致近似误差减少的同时增加了计算复杂度。文献[1]指出,样本数目与状态空间维数、建议分布与后验分布的重合程度、规定的时间步长有关。

重采样技术是为了解决 SIS 算法的退化而引入的,但是重采样不仅引入了额外的蒙特卡罗误差,而且可能导致样本多样性丧失出现样本耗尽问题。针对这些问题,一种解决途径就是限制重采样的次数,以避免在不确定条件下滤波太快地收敛到最大似然状态,但是过少的重采样将导致滤波器发散。

建议分布(也称重要性密度) $q(\cdot)$ 是指概率分布与 p 相同,概率密度分布已知且容易采样的分布函数。由于很难直接从后验概率分布 $p(x_t | z_{1:t}, u_{0:t-1})$ (简称为 p) 采样,样本采集需要借助建议分布 q 来实现。选择一个好的建议分布能够有效地防止样本退化。在一些粒子滤波的应用中,运动模型 $p(x_t | x_{t-1}, u_t)$ 被用做建议分布在粒子滤波预测步中执行采样;此外,似然模型 $p(z_t | x_t)$ 在粒子滤波更新步中起着重要的作用。因而,针对运动/似然模型提出的自适应机制有运动模型自适应以及似然模型自适应。

针对 PF 固有的缺陷及不足,可以考虑集成其他方法来改进。针对引入重采样技术所造成的样本多样性的丧失,目前粒子滤波研究的一个方向是与进化机制相结合来改善样本集的多样性。针对状态自身的不确定性,自适应产生的新样本可能具有较低的权重,因而模糊自适应粒子滤波也被提出。

2 关键技术研究

在对整个状态空间处理过程中,概率密度可能会随时间的变化发生巨大改变。在粒子滤波中引入自适应机制,可以改进粒子滤波执行和计算的有效性,从而有效地降低误差。

2.1 样本数目自适应

目前还没有方法定量地确定样本数目,已提出的自适应调整样本数目的方法有 Koller 等人^[14]提出的基于似然度自适应法、Fox^[15]提出的 KLD 采样法、Karlsson 等人^[16]提出的样本数目控制器、段琢华等人^[17]提出的复合样本数目自适应调整方法。

1) 基于似然度的自适应方法 粒子滤波算法在重采样时,由于只有现有的样本作为下个采样周期的基础,没有开采样本空间新的部分。为了从样本空间未采样的区域产生样本,Koller 等人^[14]提出了基于似然度的样本数目自适应方法(likelihood-based adaptation)。该方法利用观测的似然度 $p(z_t | x_t)$ 来决定样本数目,即所需的粒子数应能保证非归一化似然度的和

超过某一预定的门限。相对于固定样本数目的粒子滤波, 基于似然度的自适应方法显示了其优越性, 并已应用于动态贝叶斯网络^[14]、移动机器人定位^[18]、目标跟踪^[19]。但是, 由于基于似然度的自适应方法直接与重要性样本的方差属性关联, 也即重要性样本的方差是建议分布与目标分布的误匹配函数, 对于高似然性的环境或对称性的环境而言, 该方法将失效。

2) KLD 采样方法 Fox 等人^[18] 首先将基于似然度的自适应方法应用于移动机器人定位中, 在此研究基础上又提出了 KLD 采样方法 (Kullback-Leiber divergence sampling)^[15,20,21]。KLD 采样方法是样本数目自适应中的主流方法, 通过假定真实后验是离散、分段、恒定的分布诸如离散密度树或多维的直方图, 引进 KL 距离 $K(p, q) = \sum_x p(x) \log(p(x)/q(x))$ 来评估基于采样的最大似然估计 p 与真实后验分布 q 之间的概率密度差异。如果选择样本数为 $N = (1/2\varepsilon) \chi^2_{k-1, 1-\delta}$ 则近似分布与真实分布的 KL 距离以 $1-\delta$ 的概率小于或等于 ε 。其中, $\chi^2_{k-1, 1-\delta}$ 表示具有 $k-1$ 个自由度的卡方分布的 $1-\delta$ 分位数。KLD 采样方法已用于动态贝叶斯网络^[22]、移动机器人定位^[20, 23~26]。

KLD 采样方法使用经验分布推导误差边界, 隐含地假设样本从真实分布抽取。尽管考虑了有关真实后验分布复杂性的信息, 却没有考虑真实与建议分布之间的差异。为克服这一问题, Soto 对 KLD 采样方法进行了改进^[27]。其核心思想是计算从建议分布采样的样本数目 N_{IS} , 使得其与从真实分布采样 (蒙特卡罗采样) 的样本数目 N 有相同的近似精度, 即 $N_{IS} = \frac{\sigma_{IS}^2}{\text{var}(x)} \cdot \frac{1}{2\varepsilon} \chi^2_{k-1, 1-\delta}$ 其中: σ_{IS} 和 $\text{var}(x)$ 使用蒙特卡罗积分估计。

3) 样本数目控制器 与 KLD 采样方法不同, Karlsson 等人^[16] 根据不同样本数目的两个粒子滤波器表示的近似分布之间的差异, 在重采样步利用样本数目控制器 (particle number controller) 对样本数目进行调整。这种差异利用粒子滤波器的某种统计量的差异 $\xi = \mu_t^{(1)} - \mu_t^{(2)}$ 来刻画, 如均值、概率密度函数 (probability density function) 及累积密度函数 (cumulative density function)。其代价是一个额外的粒子滤波器的时间以及空间开销。

4) 复合样本数目自适应调整方法 结合 KLD 采样方法和样本数目控制器, 段琢华等人^[17] 提出一种复合粒子数目自适应调整方法。其基本思想为在重采样阶段抽取样本数目不同的两个样本集 (代表同一分布的两种近似), 根据两个近似分布的 KL 距离自适应地调整粒子数目。若 KL 距离较大, 则增加粒子数目, 反之则减少粒子数目。该方法有以下两方面的改进: a) 不增加额外的粒子滤波器, 而是额外地抽取一个粒子数目不同的粒子集; b) 利用粒子数目不同的两个粒子集表示近似分布的 KL 距离描述两者的差异。

2.2 重采样自适应

目前, 针对重采样提出的自适应机制有: Doucet 等人提出的基于有效样本大小的重采样自适应^[6,28~30]、Lenser 等人提出的基于传感器的重采样自适应^[31,32]、梁志伟等人提出的基于归一化前后权重校验的重采样自适应^[33]。

1) 基于有效样本大小的重采样自适应 由于频繁/过少重采样均会出现负面效应, 为保证能够有合适的重采样次数,

Liu 提出了有效样本大小 (efficient sample size, ESS) 的概念^[47]。基于有效样本大小 ESS 估计值 $\hat{N}_{\text{eff}}$, Doucet 等人^[6] 提出了重采样自适应, 也即 $\hat{N}_{\text{eff}}$ 小于固定阈值 N_{th} , 则在 SIS 算法中执行重采样, 否则不执行。该方法在机器人领域得到了有效的应用^[28, 29]。

ESS 考虑样本权重的分布, 却没有考虑 PF 中样本可能相同。为处理这一问题, 浓缩有效样本数 (condensed number of effective particles) N_{effc} 被提出^[30]。 N_{effc} 定义为 $N_{\text{effc}}(P^c)$, 其中 P^c 表示对于样本集 P 中相同样本只有一个备份的样本集, 且 $w_i^c = \sum_{j \text{ s. t. } p_i = p_j} w_j$ 。

2) 基于传感器的重采样自适应 Lenser 等人^[31] 提出了基于传感器的重采样技术 (sensor based resampling), 其基本思想是场所样本的平均概率是与那些覆盖机器人真实位置空间的场所样本成比例的。如果样本表示的场所概率小于来自传感器的读数, 那么这些样本将重新对传感器的概率密度 $p(z_t|x_t)$ 进行采样。在此基础上计算新样本数目 $ns = n \times \max(0, 1 - \bar{p}/p_{\text{th}})$ 。其中: $\bar{p} = \sum_i p(z_t|x_i)/n$ 是所有样本基于观测值的概率均值; n 是样本数目; p_{th} 是人为设定的阈值。

在此研究基础上, 高庆吉等人^[32] 提出了自适应感知复位定位算法 (adaptive sensor resetting localization, ASRL), 并将 p_{th} 改为 μ_t^{2m} , m 表示观测信息的数量, μ 为调整系数, p_t 是人为设定阈值。当 $\bar{p} > \mu_t^{2m}$ 时, 不产生样本; 当 $\bar{p} \leq \mu_t^{2m}$ 时, 从 $p(z_t|x_t)$ 的概率分布中抽样替代原样本集中的一些样本。

3) 基于归一化前后权重校验的重采样自适应 梁志伟等人^[33] 提出了一种分布式感知协作的扩展 Monte Carlo 定位方法。该方法在感知更新后, 对于未归一化和归一化后的权重进行如下两个检验过程, 以采用不同的重采样方法进行位姿的估计:

a) 归一化后权重的过收敛检验过程。不管信息熵如何变化, 当有效样本大小 ESS 低于某一阈值时 (采样数目的百分比 k), 则引入新采样的数目为 $n = C(N - \text{ESS})$, 其中 C 为常数; 否则, 当信息熵的变化量超过一定的阈值, 就需要引入新的采样, 引入新采样的数目为 $n = (1 - \lambda)(N - \text{ESS})$ 。其中 λ 为 $(0, 1)$ 内的数。

b) 未归一化权重的均匀性检验过程。由于预测更新后的采样为均匀分布, 而感知更新过程只是重新对采样赋权重, 因此权重之和为 $W = (1/N_t) \sum_{i=1}^{N_t} p(z_t|x_t^{(i)})$ 。 W 小于设定的阈值 W_{th} 表明采样集与感知信息的偏差较大, 设置重采样数目为整个采样集数目, 并利用环境传感器的检测模型进行重采样; 否则, 表明当前采样分布为位姿分布的较好估计, 执行重要性重采样过程。

2.3 建议分布自适应

目前, 针对建议分布提出的自适应机制有 West^[34] 提出的根据样本信息逐步修正的建议分布自适应、Gresetti 等人^[28] 提出的高斯近似建议分布自适应、Beeson 等人^[35] 提出的收缩/增长建议分布自适应以及结合其他方法的建议分布自适应^[36, 37]。

1) 根据样本信息逐步修正的建议分布自适应 West^[34] 提出了一种根据样本信息逐步修正建议分布的自适应方法。其基本思路为: a) 选择一个初始建议分布 $g_0(\theta)$, 采样 n_0 个样本

并计算其权重,样本信息为 $\Gamma_0 = \{g_0, n_0, \Theta_0, \Omega_0\}$ 。其中: $\Theta_0 = \{\theta_{0,j}, j = 1, \dots, n_0\}$ 为样本集合; $\Omega_0 = \{w_{0,j}, j = 1, \dots, n_0\}$ 为对应样本的权重。计算 $p(\theta)$ 均值和方差的估计值 $\bar{\theta}$ 和 V_0 。b) 构造修改的建议分布 $g_1(\theta) = \sum_{j=1}^{n_0} w_{0,j} d(\theta | \theta_{0,j}, V_0 h^2)$ 。其中 $d(\theta | m, M)$ 表示模式为 m 、尺度矩阵为 M 的变量椭圆对称密度函数。通过 $g_1(\theta)$ 采样更大数目 n_1 的样本,用 $\Gamma_1 = \{g_1, n_1, \Theta_1, \Omega_1\}$ 代替 Γ_0 。据此类推,根据需要进行进一步修改建议分布。该方法不足在于计算开销大,且会导致复杂的混合分布。

2) 高斯近似建议分布自适应 建议分布的最优选择和样本权重的方差相关^[48], Gresetti 等人^[28] 据此提出高斯近似建议分布自适应方法。考虑机器人利用激光雷达进行环境建模时,似然函数 $p(z_t | m_{t-1}^{(i)}, x_t)$ 决定 $p(z_t | m_{t-1}^{(i)}, x_t) p(x_t | x_{t-1}^{(i)}, u_t)$ 。这里利用步长 $L^{(i)} = \{x | p(z_t | m_{t-1}^{(i)}, x) > \vartheta\}$ 决定的常量 k 近似 $p(x_t | x_{t-1}^{(i)}, u_t)$ 。采用高斯近似建议分布的最大似然函数 $p(x_t | m_{t-1}^{(i)}, x_{t-1}^{(i)}, z_t, u_t) \cong N(\mu^{(i)}, \Sigma^{(i)})$ 。在这种近似下,可以获得最适合采样的形式。对于每个样本, $\mu^{(i)}$ 、 $\Sigma^{(i)}$ 可以通过评估样本集的最大似然函数获得,样本集中的样本 $\{x_j\}$ 对应扫描匹配中的局部最大化。对于每个样本都执行 $\mu^{(i)}$ 和 $\Sigma^{(i)}$ 的计算以及扫描匹配过程,样本 $\{x_j\}$ 被选择来覆盖依靠里程计最新读数不确定的区域 $x_j = \{x_t | p(x_t | x_{t-1}, u_t) > \chi\}$, 密度依靠地图的精度。

3) 收缩/增长建议分布自适应 在此研究基础之上, Beeson 等人^[35] 提出两种方法来实现建议分布自适应: a) 收缩建议分布。当建议分布过高估计真实后验分布的方差,通过利用由 Grisetti 等人^[28] 提出的建议分布自适应方法来实现较好的定位。为了获得新的建议的最佳形式,基于似然峰值的分布利用高斯进行近似,高斯分布的均值和方差利用加权样本的均值和方差来评估,其中样本从原始建议中采样,利用规格化似然进行加权。b) 增长建议分布。当建议分布过低评估真实后验分布,通过似然度分值,即非规格化权重 $p(o | x_j', m)$ 确定如何增长建议分布来搜索高似然度。通过设置最大似然度分值的较低阈值,如果所有似然度分值小于该阈值,通过增加当前建议分布三个维度的标准方差 σ 的 2~5 倍产生新的建议分布。

4) 结合其他方法的建议分布自适应 针对 UKF(unscented Kalman filter) 作为建议分布进行状态估计的缺点,邓小龙等人^[36] 通过融合 UKF 和强跟踪滤波器 STF(strong tracking filter) 提出一种新的自适应建议分布。该方法通过 UKF 构造粒子群,粒子群中每个粒子的每个抽样样本点(Sigma 点)用 STF 来更新,即用 STF 算法在线调节因子来相应调整滤波增益,从而使算法具有自适应性。

针对 SIR 算法从建议分布中采样时没有考虑当前观测值的不足,结合 Pitt 等人^[49] 的辅助粒子滤波(auxiliary particle filter) 算法, Cornebise 等人^[37] 通过考虑当前观测前后的辅助建议分布 μ_N^{aux} 和改进建议分布 π_N^{aux} 之间的 KLD 或卡方(Chi-square distance, CSD) 距离最小化来实现建议分布自适应,即 $|d_{KLD}(\mu_N^{aux}, \pi_N^{aux}) - \xi \{ \{\tilde{\omega}_{N,i}\}_{i=1}^{\tilde{M}_N} \}| \rightarrow 0$, $|d_{\chi^2}(\mu_N^{aux}, \pi_N^{aux}) - CV^2(\{\tilde{\omega}_{N,i}\}_{i=1}^{\tilde{M}_N})| \rightarrow 0$ 。其中, $\xi(\cdot)$ 和 $CV^2(\cdot)$ 分别表示其经验估计值, $\tilde{\omega}_{N,i}$ 表示标准化权重。

2.4 运动/似然模型自适应

1) 运动模型自适应 Milstein 等人^[38] 针对路面的变化对运动模型造成的误差进行分析,获得运动模型的方差参数来动

态更新运动模型。将差分驱动的移动机器人的运动模型依靠三个参数标志,即距离误差、转动误差和漂移误差(k_r, k_θ, k_d)。用 r, θ 分别表示增量距离与转角, $\underline{r}, \underline{\theta}$ 则表示依据运动模型获得的预测值,那么运动模型的误差分布表示为 $r = N(r, k_r \cdot r)$, $\theta = N(\theta, k_\theta \cdot \theta + k_d \cdot r)$, 其中每个分布都是单一高斯分布。在 MCL 中通过给定一组 $\underline{r}, \underline{\theta}, \underline{r}, \underline{\theta}$ 来优化运动模型误差参数(k_r, k_θ, k_d)。

Kaboli 等人^[39] 依据 Bayesian 方法,提出了 MCL 中运动和传感器模型的自调整方法。首先利用专家知识编码进行模型参数的先验分布,给出训练数据 $D = (u_{1:t}, z_{1:t})$ 和模型参数的先验分布 $Pr(\theta)$, 目标就是从机器人采集的数据中计算相对应模型参数的后验分布 $Pr(\theta | D)$; 利用混合 MCMC(Markov chain Monte Carlo) 过程对模型后验分布实现精确的模型参数采样 θ 。对于采集到的模型样本 θ , 利用样本均值 θ_{mean} 和最大化后验样本 θ_{MAP} 作为参数矢量来构建后验运动模型和传感器模型。

Lee^[40] 提出一种运动模型过程噪声自适应 UKF 方法。假设 t 时刻状态 s_t 的均值 $\hat{s}_t$ 和方差 P_t , 运动模型 $p(s_t | s_{t-1}, u_{t-1}) = F(s_{t-1}, u_{t-1}) + W(t)$ 的随机噪声 $W(t)$ 服从高斯分布 $(0, Q_t)$, 初始化状态变量及协方差矩阵,设置自适应因子 $factor_{anneal}$ 以及过程噪声 Q_t 允许的最小方差 $\min Q_t$, $s_t^\alpha = [s_t]$, $P_t^\alpha = \begin{bmatrix} P_t & P_t^{sw} \\ P_t^{sw} & Q_t \end{bmatrix}$ 。其中 P_t^{sw} 是状态评估误差和过程噪声间的关联方差。利用自适应算法对于过程噪声 Q_t 进行自适应预测评估 $\hat{Q}_{t+1}^+ = \max(factor_{anneal} \times \hat{Q}_{t+1}^-, \min Q_t)$ 。其中 $\hat{Q}_{t+1}^-$ 表示 $t+1$ 时刻的状态噪声协方差的期望值。

2) 似然模型自适应 Pfaff 等人^[41] 认为似然模型 $p(z | x)$ 在粒子滤波更新步中起着重要的作用,通过研究提出动态似然模型方法。a) 基于距离传感器建立似然模型,其核心思想是混合使用四种不同的建议分布来近似距离传感器的噪声和误差特性:使用高斯分布 $p_{hit}(z | d)$ 对在测量方向上邻近物体的激光束的似然度建模;使用一致分布 $p_{rand}(z | d)$ 表示随机测量;使用指数分布 $p_{short}(z | d)$ 对地图中没有的物体或者不同传感器间交互作用进行建模;使用一致分布 $p_{max}(z | d)$ 表示最大测距造成的检测误差。这四种建议分布进行加权平均,且加权系数需要满足一定的约束条件。b) 自适应调整服从高斯概率分布 $p_{hit}(z | d)$ 的方差,其核心思想是对 k -近邻障碍的密度进行评估时利用自适应方差测量,实现每个样本 i 覆盖空间的近似计算。

2.5 结合其他机制的自适应方法

1) 自适应进化粒子滤波 厉茂海等人^[42] 提出了基于自适应进化策略的粒子滤波:将 $p(z_t | x_t)$ 定义为适应度函数,利用进化操作中的交叉和变异对样本表示的系统状态进行优化,并采用 Metropolis 算法确保经过进化的粒子仍能准确近似后验。其中,交叉和变异操作分别以概率 p_c 和 p_m 自适应进行,当个体适应度趋于一致或趋于局部最优时, p_c 和 p_m 增加;当适应度比较分散时,令 p_c 和 p_m 减少。

Duan 等人^[43] 将变异算子引入自适应粒子滤波器,构造自适应进化粒子滤波器算法。其主要思想为根据样本的未归一化权重调整变异参数。首先从 $\{x_t^{[i]}, w_t^{[i]}\}_{i=1}^N$ 重采样 N 个粒子 $\{\tilde{x}_t^{[i]}, 1/N\}_{i=1}^N$ 。设粒子 $\tilde{x}_t^{[i]}$ 从 $x_t^{[j]}$ 采样得到, $x_t^{[j]}$ 的非规格化权

为 $w_t^{[j]}$ W_t (规格化因子乘以规格化权重), $\tilde{x}_t^{[ij]}$ 通过以下步骤变异: $\hat{x}_t^{[i]} \sim N(\tilde{x}_t^{[i]}, (\sigma_t^x)^2)$, $\hat{y}_t^{[i]} \sim N(\tilde{y}_t^{[i]}, (\sigma_t^y)^2)$, $\hat{\theta}_t^{[ij]} \sim N(\tilde{\theta}_t^{[ij]}, (\sigma_t^\theta)^2)$ 。其中, 变异参数 σ_t^x 、 σ_t^y 、 σ_t^θ 设置为 $\sigma_t^x = c_x(1 - W_t w_t^{[j]})$, $\sigma_t^y = c_y(1 - W_t w_t^{[j]})$, $\sigma_t^\theta = c_\theta(1 - W_t w_t^{[j]})$, c_x 、 c_y 、 c_θ 为常量因子。

2) 模糊自适应粒子滤波 Duan 等人^[44] 针对移动机器人航迹推算系统传感器故障诊断问题, 提出了一种模糊自适应粒子滤波器方法。首先利用模糊逻辑表示领域知识, 根据领域知识将状态空间自适应地约束到全状态空间的某一模糊子集。移动机器人可能处于静止(M_1)、直线运动(M_2)、绕左轮转动(M_3)、绕右轮转动(M_4) 及其他转动模式(M_5)。采用模糊集合表示移动机器人的运动状态, 并定义其相应的隶属度函数 μ_n 。结合上述领域知识计算条件转移概率 $p(s_{t+1} = j | s_t = i, u_t^L, u_t^R)$ 。此后结合前面提出的复合样本数目自适应方法^[17], 构造了一种模糊自适应粒子滤波方法。

Kim 等人^[45] 提出一种模糊自适应粒子滤波方法。该方法通过利用观测的概率密度函数, 结合模糊逻辑方法计算其梯度信息, 沿着梯度递减方向在高似然区域基于似然度的自适应方法产生新样本。首先定义观测的概率密度函数的梯度信息 $\Delta q = q(x_t) - q(x_{t-1})$; 接着利用模糊逻辑方法产生新样本 $x_t^{i+N} = x_t^i + \alpha y$ 。其中: α 表示步长参数; N 表示粒子滤波器在 t 时刻的样本数; y 表示依据模糊规则定义的输出变量, 该规则的输入变量分别是当前观测的概率密度函数 $q(x_t)$ 和梯度函数 Δq 。

石旭生等人^[46] 根据量测信息实时地重新调整粒子数, 通过监测残差来验证滤波器是否工作得很好。残差定义为 $r_t = z_t - \tilde{z}_t$ 。其中 z_t 和 $\tilde{z}_t$ 为 t 时刻实际的测量值和滤波器估计的值。估计的平均误差 $e_{M,t} = \frac{1}{M} \sum_{i=t-M+1}^t r_i^T r_i$, 通过调整粒子数的大小来使定义的平均误差最小。基于模糊逻辑的自适应粒子滤波主要思想是动态地调整 N , 使得实际的测量和滤波后得到的测量值估计之间的残差减少, 如果残差处于一个预先设定好的取值范围内, 滤波器工作得很好, 则不需要改变 N 值。如果残差大于期望值时, 则增大 N 值; 另一方面, 如果估计误差小于一个阈值, 则减少 N 值。

3 总结与展望

针对 PF 算法样本退化及枯竭问题, 引入自适应机制可改进执行和计算的有效性从而降低计算误差。自适应 PF 算法已经成为当前的研究热点, 但也存在着一些亟待解决的问题。

a) 收敛性问题。算法实现中收敛与否的正确判断以及用严格的数学方法给出其结论, 此外, 算法对状态评估要求具有一定的收敛速度。目前的研究成果对于算法收敛提供了一定的理论依据^[50~52]: 建议分布几乎肯定收敛于后验概率; 状态估计均方误差的收敛性。但是要求的条件依然很强, 只有样本数目 N_p 随时间增加而增加或者滤波器有能力忘记指数级增长的误差, 算法的一致收敛才能确保。目前, 关于收敛性研究大多集中于非线性滤波的误差极限研究上。关于这方面的研究还有待进一步深入下去。

b) 实时性问题。实时处理主要考虑的是传感器的高速数据率与处理器的有限处理能力的矛盾。因计算时间和粒子数

目直接相关, 故该问题也可归结为如何在估计精度和粒子数之间作适当折中。针对基于样本数目自适应的 PF 算法计算量繁重的问题, 文献[53, 54] 初步探讨了如何处理滤波器更新速率小于传感器采样速率, 以及如何自适应样本数目以便最优化计算资源等问题。在实际应用中, 尤其遭遇尺度问题时, 即空间纬度 N_x 成百上千地递增时如何维持合适的计算时间, 使估计精度满足要求, 仍有待于今后深入的研究。

c) 鲁棒性问题。由于在每个递归过程中样本的不精确性, 累积误差可能呈指数级增加。对于 SIS 或 SIR 滤波器而言, 偏差和方差都将随着时间增加而增加。这使得算法的鲁棒性话题极为重要。相关研究结果^[55] 显示, 即使混合建议分布也不能较好地处理目标分布的长尾行为, 异常可能造成滤波器发散或产生较差的滤波性能。鲁棒性改进的关键就是鲁棒的建议或似然模型的建立。如何在线自适应评估更精确的非线性, 动态模型和系统噪声特性, 值得进一步研究。这可以与相关性评估和统计学习一些严格的理论结果关联, 如度量熵、信息复杂度等。

d) 如何选择有效样本大小依旧缺乏严格的理论证明。有效样本数目依靠所选择的建议分布, 好的建议分布其误差随着样本数目 N_p 的增加呈线性变化减小到零; 差的建议分布则无论样本数目 N_p 多大, 误差均会随着空间维度 N_x 呈指数级增加^[56]。此外, 如何将其他方法与自适应机制集成以及将多种自适应机制结合仍然值得探讨。通过定性分析多种方法集成以及各种方法之间的相互影响、定量分析参数设置对效率和精度的影响, 以期有效地提高算法的精度和效率。

参考文献:

[1] ORDON N J, SALMOND D J, SMITH A F M. Novel approach to nonlinear/ non-Gaussian Bayesian state estimation[J]. IEEE Proceedings on Radar and Signal Processing, 1993, 140(2): 107-113.

[2] DELLAERT F, BURGARD W, FOX D, *et al.* Monte Carlo localization for mobile robots[C] // Proc of IEEE International Conference on Robotics and Automation. Detroit: IEEE Press, 1999: 1322- 1328.

[3] SCHULZ D, BURGARD W, FOX D, *et al.* Tracking multiple moving targets with a mobile robot using particle filters and statistical data association[C] // Proc of IEEE International Conference on Robotics and Automation. Seoul, Korea: IEEE Press, 2001: 1665- 1670.

[4] MONTEMERLO M, THRUN S, KOLLER D, *et al.* FastSLAM: a factored solution to simultaneous localization and mapping problem [C] // Proc of the National Conference on Artificial Intelligence. Edmonton, Canada: AAAI Press, 2002: 593- 598.

[5] VERMA V, GORDON G, SIMMONS R, *et al.* Particle filters for rover fault diagnosis[J]. IEEE Robotics & Automation Magazine Special Issue on Human Centered Robotics and Dependability, 2004, 11(2): 1- 4.

[6] DOUCET A, GODSILL S J, ANDRIEU C. On sequential Monte Carlo sampling methods for Bayesian filtering[J]. Statistics and Computing, 2000, 10(3): 197- 208.

[7] ARULAMPALAM M S, MASKELL S, GORDON N, *et al.* A tutorial on particle filters for online nonlinear/ non-Gaussian Bayesian tracking [J]. IEEE Trans on Signal Processing, 2002, 50(2): 174-188.

[8] CHEN Z. Bayesian filtering: from Kalman filters to particle filters, and beyond[R]. Hamilton: McMaster University, 2003.

[9] 胡士强, 敬忠良. 粒子滤波算法综述[J]. 控制与决策, 2005, 20(4): 361- 365, 371.

[10] 夏克寒, 许化龙, 张朴睿. 粒子滤波的关键技术及应用[J]. 光电与控制, 2005, 12(6): 1- 4, 19.

[11] 杨小军, 潘泉, 王睿, 等. 粒子滤波进展与展望[J]. 控制理论与应用, 2006, 23(2): 261- 267.

[12] 于金霞, 蔡自兴, 段琢华. 基于粒子滤波的移动机器人定位关键技术研究综述[J]. 计算机应用研究, 2007, 24(11): 9- 14.

[13] 程水英, 张剑云. 粒子滤波综述[J]. 宇航学报, 2008, 29(4): 1099- 1111.

[14] KOLLER D, FRATKINA R. Using learning for approximation in stochastic processes[C] //Proc of the 15th International Conference on Machine Learning. San Francisco: Morgan Kaufmann Publishers, 1998: 287- 295.

[15] FOX D. KLD-sampling: adaptive particle filters[J]. Advances in Neural Information Processing Systems, 2001, 14(1): 713- 720.

[16] KARLSSON R, GUSTAFSSON F. Monte Carlo data association for multiple target tracking[C] //Proc of IEEE Colloquium on Target Tracking: Algorithms and Applications. 2001: 1- 5.

[17] 段琢华, 蔡自兴, 于金霞. 移动机器人软故障检测与补偿的自适应粒子滤波算法[J]. 中国科学 E 辑: 信息科学, 2008, 38(4): 565- 578.

[18] FOX D, BURGARD W, DELLAERT F, *et al.* Monte Carlo localization: efficient position estimation for mobile robots[C] //Proc of the 16th National Conference on Artificial Intelligence. Orlando: AAAI Press, 1999: 343- 349.

[19] BOLIC M, SANGJIN H, DJURIC P M. Performance and complexity analysis of adaptive particle filtering for tracking applications[C] //Proc of the 16th Asilomar Conference on Signals, Systems, and Computers. Asilomar: IEEE Press, 2002: 853- 857.

[20] FOX D. KLD-sampling: adaptive particle filters and mobile robot localization[J]. Advances in Neural Information Processing Systems, 2001, 14(1): 26- 32.

[21] FOX D. Adapting the sample size in particle filters through KLD-sampling [J]. International Journal of Robotic Research, 2003, 22(12): 985- 1003.

[22] 陈栋梁, 王浩, 姚宏亮, 等. 基于自适应粒子滤波的动态贝叶斯网推理算法[J]. 计算机应用, 2007, 27(2): 369- 372.

[23] JIANG Zheng-wei, GU Yuan-tao. Novel adaptive particle filters in robot localization[J]. Acta Automatica Sinica, 2005, 31(6): 833- 838.

[24] 方正, 佟国峰, 徐心和. 一种鲁棒高效的移动机器人定位方法[J]. 自动化学报, 2007, 33(1): 48- 53.

[25] 张恒, 樊小平, 瞿志华. 基于多假设跟踪的移动机器人自适应蒙特卡罗定位研究[J]. 自动化学报, 2007, 33(9): 941- 946.

[26] XIA Yi-min, YANG Yi-min. Mobile robot localization method based on adaptive particle filter[C] //Lecture Notes in Artificial Intelligence. Berlin: Springer, 2008: 963- 972.

[27] SOTO A. Self adaptive particle filter[C] //Proc of International Joint Conference on Artificial Intelligence. Edinburgh, Scotland: Professional Book Center, 2005: 1398- 1406.

[28] GRISETTI G, STACHNISS C, BURGARD W. Improving grid-based SLAM with Rao-Blackwellized particle filters by adaptive proposals and selective resampling[C] //Proc of IEEE International Conference on Robotics and Automation. Barcelona, Spain: IEEE Press, 2005: 2443- 2448.

[29] LI Mao-hai, HONG Bing-rong, CAI Ze-su, *et al.* Novel Rao-Blackwellized particle filter for mobile robot SLAM using monocular vision [J]. International Journal of Intelligent Technology, 2006, 1(1): 63- 69.

[30] SULIVAN J, CAMPBELL M, LIPSON H. Particle filters as exploration tools for autonomous rovers[C] //Proc of the AIAA Guidance, Navigation and Control Conference. San Francisco: AIAA Press, 2005: 6447- 6458.

[31] LENSER S, VELOSO M. Sensor resetting localization for poorly modelled mobile robots[C] //Proc of IEEE International Conference on Robotics and Automation. San Francisco: IEEE Press, 2000: 1225- 1232.

[32] 高庆吉, 雷亚莉, 胡丹丹, 等. 基于自适应感知复位算法的移动机器人定位[J]. 电子学报, 2007, 35(11): 2166- 2171.

[33] 梁志伟, 马旭东, 戴先中. 分布式感知协作的扩展 Monte Carlo 定位算法[J]. 机器人, 2008, 30(3): 210- 216.

[34] WEST M. Mixture models, Monte Carlo, Bayesian updating and dynamic models[J]. Computing Science and Statistics, 1993, 24: 325- 333.

[35] BEESON P, MURARKA A, KUIPERS B. Adapting proposal distributions for accurate, efficient mobile robot localization[C] //Proc of IEEE International Conference on Robotics and Automation. Orlando: IEEE Press, 2006: 49- 55.

[36] 邓小龙, 谢剑英, 郭为忠. 用于状态估计的自适应粒子滤波[J]. 华南理工大学学报: 自然科学版, 2006, 34(1): 57- 61.

[37] CORNEBISE J, MOULINES E, OLSSON J. Adaptive methods for sequential importance sampling with application to state space models [J]. Statistics and Computing, 2008, 18(4): 461- 480.

[38] MILSTEIN A, WANG T. Localization with dynamic motion models- determining motion model parameters dynamically in Monte Carlo localization[C] //Proc of the 3rd International Conference on Informatics in Control, Automation and Robotics. 2006: 120- 127.

[39] KABOLI A, BOWLING M, MUSILEK P. Bayesian calibration for Monte Carlo localization[C] //Proc of the 21st National Conference on Artificial Intelligence. Boston: AAAI Press, 2006: 964- 969.

[40] LEE D J. Nonlinear Bayesian filtering with applications to estimation and navigation[D]. Texas: Texas A&M University, 2005.

[41] PFAFF P, BURGARD W, FOX D. Robust Monte-Carlo localization using adaptive likelihood models [C] //Proc of European Robotics Symposium. Berlin: Springer, 2006: 181- 194.

[42] 厉茂海, 洪炳熔, 罗荣华. 用改进的 Rao-Blackwellized 粒子滤波器实现移动机器人同时定位和地图创建[J]. 吉林大学学报: 工学版, 2007, 37(2): 401- 406.

[43] DUAN Zuo-hua, CAI Zi-xing. Evolutionary particle filter for robust simultaneous localization and map building with laser range finder [C] //Proc of the 4th International Conference on Natural Computation. Washington DC: IEEE Computer Society, 2008: 443- 447.

[44] DUAN Zuo-hua, CAI Zi-xing, YU Jin-xia. Fuzzy adaptive particle filter algorithm for mobile robot fault diagnosis[C] //Proc of the 13th International Conference on Neural Information Processing. Heidelberg: Springer, 2006: 711- 720.

[45] KIM Y J, WON C H, PARK J M, *et al.* Fuzzy adaptive particle filter for a positioning beacon system[C] //Proc of International Conference on Control, Automation and Systems. Seoul, Korea: IEEE Press, 2007: 1198- 1202.

(下转第 428 页)