

文章编号: 1001-0920(2007)03-0273-05

粒子群优化粒子滤波方法

方正, 佟国峰, 徐心和

(东北大学 人工智能与机器人研究所, 沈阳 110004)

摘要: 针对粒子滤波方法存在粒子贫乏以及初始状态未知时需要大量粒子才能进行鲁棒状态预估等问题, 将粒子群优化思想引入粒子滤波中. 该方法将最新观测值融合到采样过程中, 并对采样过程利用粒子群优化算法进行优化. 通过优化, 可使粒子集朝后验概率密度分布取值较大的区域运动, 从而克服了粒子贫乏问题, 并极大地降低了精确预估所需的粒子数. 实验结果表明, 该算法具有较高的预估精度和较好的鲁棒性.

关键词: 粒子滤波; 粒子群优化; 状态预估; 移动机器人自定位

中图分类号: TP242

文献标识码: A

Particle swarm optimized particle filter

FANG Zheng, TONG Guofeng, XU Xinhe

(Institute of Artificial Intelligence and Robotics, Northeastern University, Shenyang 110004, China, Correspondent: FANG Zheng, E-mail: fangzheng81@163.com)

Abstract: To the problem of particle impoverishment and needing a large sample size for robust state estimation when initial state is unknown, particle swarm optimization (PSO) is introduced into generic particle filter. Particle swarm optimized particle filter (PSOPF) incorporates the newest observations into sampling process and also optimizes it. Through PSO, particles are moved towards regions where they have larger values of posterior density function. As a result, the impoverishment of particle filter is overcome and the sample size necessary for accurate state estimation is reduced dramatically. Experimental results show that PSOPF has higher estimation accuracy and better robustness.

Key words: Particle filter; Particle swarm optimization; State estimation; Mobile robot self-localization

1 引言

近年来, 粒子滤波方法^[1-4]在国内外备受关注, 与传统滤波方法相比, 该方法具有简单易行, 适用于非线性及非高斯噪声环境等优点, 因而被广泛应用于视觉跟踪、机器人定位、航空导航、故障检测等诸多领域.

粒子滤波方法采用带有权重值的粒子集来近似表示后验概率分布, 因此, 理论上该方法可以表示任意形式的概率分布. 然而, 因为常规粒子滤波方法采用了次优的重要性函数, 所以常规粒子滤波方法存在一些缺点, 如: 1) 粒子贫乏问题. 当观测值比较准确或似然函数位于先验概率分布尾部时, 在权重值更新之后很多粒子的权重值都变得很小. 经过重采样过程后, 样本集的多样性减少甚至只剩下一样本, 从而产生了粒子贫乏问题. 2) 计算效率问题. 常规的粒子滤波方法需要大量的粒子才能保证状态预

估的精度, 特别当系统初始状态未知时, 粒子滤波需要大量粒子才能保证粒子集的收敛性, 否则粒子集很容易发散从而导致预估失败.

为解决以上问题, 一些学者提出了解析的改进方法. Rudolph 等^[5]将 UKF (Unscented Kalman Filter) 方法引入粒子滤波中, 提出了 UPF (Unscented Particle Filter). UPF 算法的核心思想是在粒子滤波算法的基础上利用 UKF 得到比普通 PF 更好的重要性函数. 该方法将最新的观测值引入预测过程中, 因此提高了常规粒子滤波的性能, 但计算量也大大增加了. 还有一些学者试图用智能算法来改善粒子滤波算法的性能. Clapp 等^[6]将模拟退火思想引入粒子滤波中, 提出了模拟退火粒子滤波, 该算法引入退火重要性采样和中间分布的概念, 改善了出现先验尾部观测值时的算法性能. 由于遗传算法和序列蒙特卡罗重要性采样有些类似,

收稿日期: 2006-02-21; 修回日期: 2006-07-07.

基金项目: 国家自然科学基金项目(60475036).

作者简介: 方正(1981—), 男, 安徽寿县人, 博士生, 从事自主机器人、机器视觉等研究; 徐心和(1940—), 男, 河北山海关人, 教授, 博士生导师, 从事机器人、智能控制等研究.

Ronghua 等^[7]提出了将遗传算法和粒子滤波相结合的方法,使得采样后的粒子的多样性更好. Torra^[8]将局部搜索的思想引入粒子滤波的采样过程中,可以解决观测比较准确情况下粒子滤波的贫乏问题.

本文在分析了粒子滤波方法不足的基础上,将粒子群优化算法引入粒子滤波方法中,改善了样本的分布,加速了粒子集的收敛,使得粒子滤波的性能得到很大的提高.该方法称为粒子群优化粒子滤波方法(PSOPF).

2 粒子滤波方法与存在问题分析

粒子滤波方法的理论基础来源于贝叶斯滤波原理.贝叶斯滤波原理的实质是试图利用已知信息来构造系统状态量度的后验概率密度,即用系统模型预测状态的先验概率密度,再使用最近的观测值进行修正,从而得到后验概率密度.

若概率密度初始值为 $p(X_0 / Y_0) = p(X_0)$,对于一阶马尔可夫过程,可得先验概率密度为

$$p(X_k / Y_{1:k-1}) = p(X_k / X_{k-1}) p(X_{k-1} / Y_{1:k-1}) dX_{k-1}. \quad (1)$$

当获得测量值 Y_k 后,通过贝叶斯公式更新先验值,得到后验概率密度为

$$p(X_k / Y_{1:k}) = \frac{p(Y_k / X_k) p(X_k / Y_{1:k-1})}{p(Y_k / Y_{1:k-1})}, \quad (2)$$

其中 $p(Y_k / Y_{1:k-1}) = \int p(Y_k / X_k) p(X_k / Y_{1:k-1}) dX_k$ 是归一化常量,它取决于似然函数 $p(Z_k / X_k)$ 及测量噪声的统计特性.

粒子滤波方法是一种通过蒙特卡罗模拟^[9]实现递推贝叶斯滤波的技术,其核心思想是利用一系列随机样本的加权和来表示所需的后验概率密度,进而得到状态的估计值.当样本点数增加至无穷大时,蒙特卡罗特性与后验概率密度的函数表示等价.

考虑粒子集数目为 N 的粒子滤波算法,迭代 $k-1$ 次后,从 $p(X_{k-1} / Y_{1:k-1})$ 得到近似粒子集 $\{x_{k-1}^i\}_{i=1, \dots, N}$,其中, X 为系统状态, $Y_{1:k-1}$ 表示至 $k-1$ 为止的观测值.先验概率分布 $p(X_k / Y_{1:k-1})$ 可近似为

$$p(X_k / Y_{1:k-1}) = 1/N \sum_{i=1}^N p_i(X_k). \quad (3)$$


假设 k 时刻状态概率密度分布为 $p_i(X_k)$,则由贝叶斯定理可得后验概率分布为

$$p(X_k / Y_{1:k}) = \sum_{i=1}^N p_i(X_k) p(Y_k / X_k). \quad (4)$$


粒子滤波采用 SIS(Sequential Importance Sampling) 方法^[9],根据重要性递归地进行采样得到后验概率的近似分布.但常规粒子滤波方法采用

的是次优重要性函数,因而存在一些问题.

常规粒子滤波的一个重要缺陷就是粒子贫乏问题.当似然函数特别窄,也就是观测信息很准确时,似然概率与先验概率分布之间的重叠部分很小,这时仅有一小部分粒子的权重值在更新后会增大,如图 1(a) 所示.另外,遇到观测概率位于先验分布尾部时也会产生问题,由于先验概率产生的粒子仅有小部分位于高似然区域,重采样的后验概率仅由相异很少的粒子表示,如图 1(b) 所示.因此,预估结果中很有可能失去重要粒子(好的假设).



(a) 似然函数很窄



(b) 似然函数位于先验概率尾部

图1 似然函数很窄或位于先验概率尾部

常规粒子滤波的另外一个问题就是当系统的初始状态未知时,需要大量的粒子才能实现系统的状态预估.如果粒子集数目比较小,那么很有可能没有粒子分布在真实状态附近,这样经过几次迭代后,粒子很难收敛到真实状态处.对于常规粒子滤波,要解决这个问题的办法就是增大初始状态的粒子数目.通常这种情况下需要的数目远远大于状态跟踪需要的粒子数目,这使得粒子滤波算法计算效率极大地降低,有时根本无法满足系统实时性要求.

3 粒子群优化粒子滤波方法

为了克服常规粒子滤波存在的缺点,本文将粒子群优化思想引入粒子滤波中以改善采样过程.由于粒子群优化思想和粒子滤波算法存在很多相似性,可将两者结合起来得到更加有效的粒子滤波方法.

3.1 粒子群优化和粒子滤波

粒子群优化是由 Kennedy 和 Eberhart 等^[10]于 1995 年提出的一类模拟群体智能行为的优化算法.粒子群优化算法(PSO)可表述为:随机初始化一个粒子群(数量为 m),其中第 i 个粒子在 n 维空间的位置表示为 $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$,速度为 $V_i = (v_{i1},$

v_{i2}, \dots, v_{in}). 每一次迭代, 粒子通过两个极值来更新自己的速度和位置. 一个是粒子本身从初始到当前迭代次数搜索产生的最优解, 称为个体极值 $P_i = (p_{i1}, p_{i2}, \dots, p_{in})$. 另一个是种群目前的最优解, 称为全局极值 $G = (g_1, g_2, \dots, g_n)$. 在找到这两个最优值后, 每个粒子根据下式来更新其速度和位置:

$$V_i = w * V_i + c_1 * \text{Rand}() * (P_i - X_i) + c_2 * \text{Rand}() * (G - X_i),$$

$$X = X_i + V_i. \tag{5}$$

其中: Rand 是介于 $(0, 1)$ 区间的随机数, w 称为惯性系数, c_1 和 c_2 统称为学习因子, 一般学习因子 $c_1 = c_2 = 2$. 通常, w 较大则算法具有较强的全局搜索能力, w 较小则算法倾向于局部搜索.

通过以上描述可以看出, 粒子滤波与粒子群优化有很多相似性. 首先, 粒子群优化通过不断更新粒子在搜索空间中的速度和位置来寻找最优值; 而粒子滤波方法通过不断更新粒子的位置和权重值来逼近系统的真实后验概率分布. 其次, 在粒子群优化算法中具有最大适应度值的粒子表示的是搜索空间中的最优值点; 而在粒子滤波算法中, 具有最大权重值的粒子表示的是系统最可能处于的状态. 第 3, 粒子群优化算法和粒子滤波方法都有各自的运动机制. 在粒子群优化算法中, 粒子通过追寻个体最优值和全局最优值来不断更新自己的位置和速度; 在粒子滤波算法中, 每个粒子首先通过运动模型来更新自己的位置, 然后通过观测模型来更新自己的权重值.

基于以上的相似点, 可以想象利用粒子群优化算法能够改善常规粒子滤波方法的性能.

3.2 融合粒子群优化与粒子滤波

如第 2 部分中介绍的, 常规的粒子滤波采用了次优的重要性函数, 因此, 粒子的重要性采样过程是次优的. 为了优化粒子滤波的采样过程, 本文将粒子群优化算法融入粒子滤波中.

首先, 将最新的观测值引入采样过程, 并定义适应度函数为

$$\text{fitness} = \exp\left[-\frac{1}{2R_k}(y_{\text{New}} - y_{\text{Pred}})^2\right]. \tag{6}$$

其中: R_k 是观测噪声方差, y_{New} 是最新的观测值, y_{Pred} 是预测观测值. 粒子群优化算法通过计算适应度值将所有的粒子向最优粒子移动. 但有时经典的粒子群优化算法的最大速度等参数很难确定, 因此本文采用一种改进的粒子群优化算法, 即高斯粒子群优化算法^[11]. 该方法基于一个高斯分布来不断更新粒子的速度, 其收敛性好于经典的粒子群优化算法.

如果粒子集都分布在真实状态附近, 那么粒子

群中每个粒子的适应度都很高. 反之, 如果粒子群中每个粒子的个体最优值以及粒子群的全局最优值都很低, 则说明粒子没有分布在真实状态附近. 此时粒子集利用粒子群优化算法, 不断根据最优值并利用下式来更新每个粒子的速度与位置, 使得粒子不断地向真实状态靠近:

$$v_k^i = / \text{rand} n / (p_{\text{pbest}} - x_k^i) + / \text{Rand} n / (p_{\text{gbest}} - x_k^i),$$

$$x_{k+1}^i = x_k^i + v_k^i, \tag{7}$$

其中 $/ \text{rand} n /$ 和 $/ \text{Rand} n /$ 是正的高斯分布的随机数, 可由 $\text{abs}[N(0, 1)]$ 产生.

通过移动粒子群向最优粒子 p_{gbest} 靠近, 粒子群优化算法实质是驱动所有的粒子向高似然概率区域运动. 当粒子群的最优值符合某阈值时, 说明粒子群已经分布在真实状态附近, 那么粒子群将停止优化. 此时再对粒子集利用最新观测值通过下式进行权重更新并进行归一化处理:

$$w_i^k = w_i^{k-1} p(y^k / x_i^k),$$

$$w_i^k = \frac{w_i^k}{\sum_i w_i^k}. \tag{8}$$

为了解决粒子滤波的退化问题^[9], 需要选择和复制权重值较大的粒子, 即对粒子集进行重采样

$$\{x_i^k, \frac{1}{N}\}_{i=1}^N = \{x_i^k, w_i^k\}_{i=1}^N. \tag{9}$$

在重采样之后, 真实状态附近的粒子权重值将会增大.

通过以上的优化过程, 使得粒子集在权重值更新前更加趋向于高似然区域, 如图 2 所示, 从而解决了粒子贫乏问题. 同时, 优化过程使得远离真实状态的粒子趋向于真实状态出现概率较大的区域, 提高了每个粒子的作用效果. 于是, 粒子滤波需要大量粒子才能进行精确状态预估的问题也被削弱了, 尤其当初始状态未知时.




图 2 粒子群优化过程

4 实验验证

4.1 非线性系统状态预估

首先将粒子群优化粒子滤波算法的性能与常规粒子滤波器以及无迹粒子滤波算法 (Unscented Particle Filter) 等其他非线性系统预估算法进行比

较.为了统一比较标准,本文采用文献[5]中的非线性系统.

系统的状态方程为

$$x_{t+1} = 1 + \sin(\omega t) + \phi x_t + v_t. \quad (10)$$

其中: v_t 是一个 $a(3,2)$ 的随机变量,表示系统模型噪声; $\omega = 4e - 2$ 和 $\phi = 0.5$ 是尺度参数.

非静态观测方程为

$$y_t = \begin{cases} \phi_1 x_t^2 + n_t, & t \leq 30; \\ \phi_2 x_t - 2 + n_t, & t > 30. \end{cases} \quad (11)$$

其中: $\phi_1 = 0.2, \phi_2 = 0.5$,观测噪声 n_t 是符合 $N(0, 0.00001)$ 分布的高斯噪声.给定观测噪声,对时刻 $t = 1, \dots, 60$,利用不同的滤波器对系统状态进行预估,预估结果如图3所示.可以看出,PSOPF算法的预估性能明显高于常规PF方法以及PF-EKF方法,接近UPF方法.但PSOPF算法的实时性却明显高于UPF方法,如表1所示.因此,PSOPF的综合性能要好于其他非线性滤波器.




图3 各种不同滤波器预估结果

表1 各种不同滤波器运算时间

算 法	MSE 平均	时间 / s
PF	0.378 3	4.047
PF-EKF	0.474 3	9.532
PF-UKF	0.057 261	17.297
PF-PSO	0.074 377	4.672

4.2 移动机器人全局定位问题

本文利用机器人全局定位问题^[12]来测试粒子群优化粒子滤波方法在初始状态未知情况下的预估性能,并与常规粒子滤波方法进行比较.整个实验环境为 10×10 m 大小,地图被划分为 100×100 个网格.在图4中,粗线表示墙壁,小车代表移动机器人的真实位姿.

实验中,机器人利用激光传感器来感知外界环境信息.首先,比较了常规粒子滤波与粒子群优化粒子滤波的收敛性能.当采用相同粒子数(6 000 个粒子)时,粒子群优化粒子滤波方法很快地收敛到真实位姿附近,而常规粒子滤波方法却无法在较短时间内收敛,甚至最终发散.其次,比较了随着粒子数

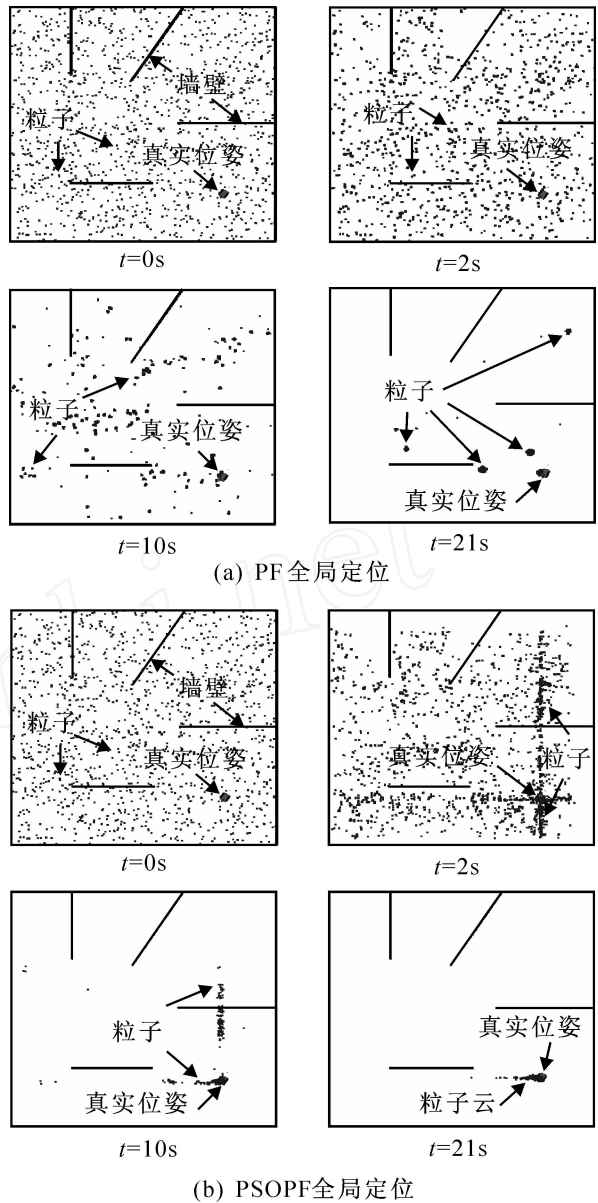


图4 移动机器人全局定位问题

下降情况下两种方法的性能.从实验结果表2可以看出,当粒子数低于一定数目时,常规粒子滤波无法收敛到真实位姿,而粒子群优化粒子滤波却可利用较少的粒子收敛到真实位姿附近.

表2 收敛效率对照表

样本大小	PF/ s	PSOPF/ s
6 000	350	30
2 500	发散	9
1 250	发散	2
800	发散	1

在本仿真实验系统中,对于位姿跟踪问题,由于机器人初始位姿已知,只需50个左右的粒子就可以实现精确的位姿跟踪,而常规粒子滤波方法大约需要100个以上.对于全局定位问题(10×10 m 大小的环境),改进的算法只需大约500个粒子就可以实

现鲁棒的自定位, 而从表 2 可以看出, 常规粒子滤波方法在粒子数目为 2 500 左右就已经发散了. 因此, 改进后算法的收敛性相比于常规方法有一定的提高.

5 结 语

在利用常规粒子滤波方法进行系统状态预估时, 通常粒子集数目不能太大, 否则系统的实时性很差. 另一方面, 如果粒子集的数目太小, 则系统的鲁棒性将会降低, 容易受到粒子贫乏现象的影响. 特别是在观测量较准确或似然概率位于先验概率尾部的情况下, 常规粒子滤波器的预估性能很差. 本文通过分析常规粒子滤波方法存在问题的原因, 将粒子群优化的思想引入粒子滤波中. 通过将最新的观测值引入采样分布中, 并利用粒子群优化算法对采样过程进行优化, 使得采样分布向后验概率较高的区域运动, 从而避免了粒子贫乏现象的产生, 同时提高了状态预估的精度. 此外, PSOPF 还可以解决系统初始状态未知情况下的预估问题, 并可明显地降低所需粒子数, 提高系统的鲁棒性. 实验结果表明了 PSOPF 算法的有效性.

参考文献(References)

- [1] Bogdan K. Finding location using a particle filter and histogram matching [C]. Proc of Artificial Intelligence and Soft Computing. Poland: Springer, 2004: 786-791.
- [2] Doucet A. On sequential simulation based methods for Bayesian filtering [J]. Statistics and Computing, 1998, 10(3): 197-208.
- [3] Thrun S. Particle filters in robotics [C]. Proc of Uncertainty in AI. San Francisco: Morgan Kaufmann Publishers, 2002: 511-518.
- [4] Carpenter J, Clifford P, Fernhead P. An improved particle filter for non-linear problems [R]. Oxford: University of Oxford, 1997.
- [5] Van M R, Doucet A. The unscented particle filter [R]. Cambridge: Cambridge University, 2000.
- [6] Clapp T C. Statistical methods for the processing of communication data [D]. Cambridge: University of Cambridge, 2000.
- [7] Ronghua L, Bingrong H. Coevolution based adaptive monte Carlo localization [J]. Int J of Advanced Robotic Systems, 2004, 1(3): 183-190.
- [8] Peter T, Csaba S. LS-N-IPS: An improvement of particle filters by means of local search [C]. Proc Nonlinear Control Systems. Petersburg, 2001: 715-719.
- [9] Jun S L, Rong C, Tanya L. A theoretical framework for sequential importance sampling and resampling [C]. Sequential Monte Carlo in Practice. Doucet: Springer-Verlag, 2001: 225-246.
- [10] Kennedy J, Eberhart R. Particle swarm optimization [C]. Proc of the IEEE Int Conf on Neural Networks, Piscataway: IEEE Service Center, 1995: 1941-1948.
- [11] Krohling R A. Gaussian swarm: A novel particle swarm optimization algorithm [C]. Proc of the IEEE Conf on Cybernetics and Intelligent Systems. Singapore, 2004: 372-376.
- [12] Ioannis R. A particle filter tutorial for mobile robot localization [R]. Montreal, Quebec: McGill University, 2004.
- [12] Susmaga R. Experiments in incremental computation of reducts [C]. Rough Sets in Data Mining and Knowledge Discovery. Berlin: Springer-Verlag, 1998.
- [13] 刘宗田. 属性最小约简的增量式算法 [J]. 电子学报, 1999, 27(11): 96-98.
(Liu Z T. An incremental arithmetic for the smallest reduction of attributes [J]. Acta Electronica Sinica, 1999, 27(11): 96-98.)
- [14] Bazan B, Nguyen Hung Son, Nguyen Sinh Hoa. Rough set algorithms in classification problem [C]. Rough Set Methods and Applications. Heidelberg: Physica-Verlag, 2000: 49-88.
- [15] Wang Jue, Wang Ju. Reduction algorithms based on discernibility matrix: The ordered attributed method [J]. J of Computer Science and Technology, 2001, 11(6): 489-504.
- [16] Hu F, Wang G Y, Huang H, et al. Incremental attribute reduction based on elementary sets [C]. Lecture Notes In Artificial Intelligence 3641. Regina: Heidelberg, Physica-Verlag, 2005: 185-193.
- [17] 叶东毅, 陈昭炯. 一个新的差别矩阵及其求核方法 [J]. 电子学报, 2002, 30(7): 1086-1088.
(Ye D Y, Chen Z Y. A new discernibility matrix and the computation of a core [J]. Acta Electronica Sinica, 2002, 30(7): 1086-1088.)
- [18] 王国胤. 决策表核属性的计算方法 [J]. 计算机学报, 2003, 26(5): 611-615.
(Wang G Y. The computation method of core attribute in decision table [J]. Chinese J of Computer, 2003, 26(5): 611-615.)
- [19] Wang G Y, Zheng Z, Zhang Y. RIDAS —A rough set based intelligent data analysis system [C]. The 1st Int Conf on Machine Learning and Cybernetics. Beijing, 2002: 646-649.

(上接第 272 页)