第45卷 第11期
2013年11月
哈尔滨工业大学学报
JOURNAL OF HARBIN INSTITUTE OF TECHNOLOGY
Vol. 45 No. 11
Nov. 2013

一种基于区间估计的粒子滤波算法

马 成, 朱 奕, 伞 冶

(哈尔滨工业大学 航天学院, 150080 哈尔滨)

摘 要: 针对非线性、非高斯系统的状态估计问题,本文提出了一种基于区间估计的粒子滤波算法.新算法从辅助粒子滤波算法的理论出发,首先对系统状态的期望值进行区间估计,然后在该区间上均匀采样,并利用当前观测信息进行修正,最后得出滤波结果.为了保证估计区间的有效性和算法计算效率,本文给出了区间扩展条件.由于算法直接在区间上均匀采样,不仅避免了重采样带来的样本贫化,而且保证了粒子的多样性.实验结果表明,该算法具有较高的滤波精度,明显优于一般的粒子滤波算法.

关键词: 贝叶斯滤波;粒子滤波;区间估计;均匀采样

中图分类号: TP391 **文献标志码**: A **文章编号**: 0367-6234(2013)11-0008-05

Particle filter algorithm based on interval estimation

MA Cheng, ZHU Yi, SAN Ye

(Simulation and Control Center, Harbin Institute of Technology, 150001 Harbin, China)

Abstract: To deal with non-linear, non-Gaussian state estimation problem, a kind of particle filter algorithm based on interval estimation was proposed. This paper analyzed the auxiliary particle filter at first. After interval estimating the expectation of the system states, the new algorithm sampled uniformly in the interval and updated the filter results using the new measurement. The interval extension conditions were proposed to ensure the validity of the estimated range and computational efficiency of the algorithm. Sampling uniformly in the interval avoids the particle degeneracy and improves the particle divergence. The experimental results show that the new particle filter is significantly better than the general particle filter.

Key words: bayesian filtering; particle filter; interval estimate; uniform sampling

非线性、非高斯随机系统的分析和处理在图像处理、计算机视觉、机器学习以及自动控制等领域有着广泛的应用.基于模型线性化和高斯假设的扩展卡尔曼滤波(Extended Kalman Filter, EKF)是在处理非线性滤波问题中常用的方法.但是在非线性、非高斯条件下,EKF 在估计系统状态及其方差时误差较大,甚至有可能发散.

处理非线性滤波问题的另一类方法是粒子滤波(Particle Filter,PF)算法.该算法是基于递推贝叶斯估计的统计滤波方法,并且摆脱了对系统为线性以及噪声为高斯特性的要求.粒子滤波利用分布在状态空间中的一些随机样本(粒子)来表示系统随机变量的后验概率分布,从而可以应用于任意非线性随机系统.在收到新的观测信息后,粒子滤波利用这些信息修正前一时刻的概率分布,通过调整后粒子值及其权值近似当前时刻的概率分布.Gordon 提出的 Bootstrap 滤波算法构建了粒子滤波的最早形式[1].在此基础上,研究者提出了许多改进算法,例如正则化粒子滤波[2]、无迹粒子滤波(Unscented Particle Filter, UPF)[3]、高斯粒子滤波(Gaussian Particle Filter, GPF)[4]等.此外,一些经典文献对粒子滤波进行了介绍和总结[5-7].

由 Pitt 和 Shephard 提出的辅助粒子滤波(Auxiliary Particle Filter, APF)算法引入辅助变量来近似后验概率密度[8].该算法的基本思想是

收稿日期: 2012-11-05.
基金项目: 国家自然科学基金资助项目(61074127).
作者简介: 马 成(1983—),男,博士研究生;
伞 冶(1951—),男,教授,博士生导师.
通信作者: 伞 冶,sanye@hit.edu.cn.

重采样在采样之前，利用当前时刻的信息，将前一时刻最有前途（预测似然度大）的粒子扩展到当前时刻，从而保证了粒子的多样性，减小了重要性权值的方差[9]. 也就是说，APF 算法利用表征先验函数的点估计值进行重采样，然后采样生成标准后验概率分布的粒子. 如果过程噪声较大时，单个点估计不能够合理表征先验函数[5]. 在这种情况下，APF 算法的估计精度较差.

本文以辅助粒子滤波算法的理论作为基础，采用区间估计代替已有算法中的点估计. 点估计值是一个随机变量，因样本而异，也就表明受噪声的影响较大. 因此，本文提出了基于区间估计的粒子滤波（Particle Filter based on Interval Estimation，PF-IE）. PF-IE 算法对样本点的期望值进行区间估计，并利用当前观测信息对区间上的均匀样本点进行修正，最终得出滤波结果. 此外，本文还给出了区间扩展条件，从而保证估计区间的有效性和算法的计算效率. 该算法不需要进行重采样，因而运行时间要少于 APF. 本文通过一个仿真实例以及同其他算法的比较，结果表明了所提出算法的可行性和有效性.

1　问题描述和辅助粒子滤波

1.1　问题描述

考虑如下的非线性、非高斯动态状态空间模型：

$$\begin{cases} \boldsymbol{x}_k = \boldsymbol{f}(\boldsymbol{x}_{k-1}) + \boldsymbol{v}_{k-1}, \\ \boldsymbol{y}_k = \boldsymbol{h}(\boldsymbol{x}_k) + \boldsymbol{n}_k. \end{cases} \tag{1}$$

其中：$\boldsymbol{x}_k \in \mathbf{R}^{n_x}$ 表示系统的状态向量，且服从 Markov 随机过程；$\boldsymbol{y}_k \in \mathbf{R}^{n_y}$ 是观测向量；$\boldsymbol{v}_k \in \mathbf{R}^{n_v}$ 和 $\boldsymbol{n}_k \in \mathbf{R}^{n_n}$ 分别是独立同分布的过程噪声和测量噪声. $\boldsymbol{f}_k: \mathbf{R}^{n_x} \times \mathbf{R}^{n_v} \mapsto \mathbf{R}^{n_x}$ 是非线性函数，代表了状态转移过程；$\boldsymbol{h}_k: \mathbf{R}^{n_x} \times \mathbf{R}^{n_n} \mapsto \mathbf{R}^{n_y}$ 代表了测量过程. 初始状态服从 $p(\boldsymbol{x}_0)$ 分布.

为了进行滤波，一般假设状态的初始分布 $p(\boldsymbol{x}_0)$，函数 $\boldsymbol{f}_k$ 和 $\boldsymbol{h}_k$ 都是已知的. 同时，可利用的信息还包括一组测量值 $\boldsymbol{y}_{1:k} = \{\boldsymbol{y}_1, \boldsymbol{y}_2, \cdots, \boldsymbol{y}_k\}$. 基于以上信息，就能通过预测和更新以递归方式估计出系统状态的后验概率密度 $p(\boldsymbol{x}_{0:k} \mid \boldsymbol{y}_{1:k})$，特别是边缘概率分布 $p(\boldsymbol{x}_k \mid \boldsymbol{y}_{1:k})$，其中 $\boldsymbol{x}_{0:k} = \{\boldsymbol{x}_0, \boldsymbol{x}_1, \cdots, \boldsymbol{x}_k\}$.

1.2　粒子滤波

粒子滤波是一类随机模拟滤波器，其基本思想是利用样本集 $\{\boldsymbol{x}_k^i, w_k^i, i = 1, 2, \cdots, N\}$ 描述 k 时刻目标状态 $\boldsymbol{x}_k$ 的后验概率密度分布 $p(\boldsymbol{x}_k \mid \boldsymbol{y}_{1:k})$. 其中，$\{\boldsymbol{x}_k^i, i = 1, 2, \cdots, N\}$ 是一组支撑点，其对应的权值是 $\{w_k^i, i = 1, 2, \cdots, N\}$，同时这些权值满足 $\sum_{i=1}^{N} w_k^i = 1$. 于是 k 时刻系统状态的后验概率密度分布可表示为

$$p(\boldsymbol{x}_k \mid \boldsymbol{y}_{1:k}) \approx \sum_{i=1}^{N} w_k^i \, \delta(\boldsymbol{x}_k - \boldsymbol{x}_k^i). \tag{2}$$

其中 $\delta(\,)$ 是 Dirac-delta 函数. 由大数定律可知，当 $N \to \infty$ 时，式（2）逼近真实后验概率密度.

在很多情况下，上述后验概率密度可能是非标准、非解析的，直接从这样的概率分布中采样是非常困难的. 因此粒子滤波利用重要性采样产生粒子，即样本点实际上是从容易采样的重要性密度函数中得到的. 重要性密度函数一般选择先验概率密度，即 $p(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1})$. 实际上，这就是粒子滤波的最基本形式：序贯重要性采样（Sequential Importance Sampling，SIS）滤波.

在 SIS 滤波中，最常见的问题是粒子退化现象. 该现象的直接表现是经过多次迭代后，仅有一个粒子的权值接近于 1，而其余粒子的权值趋于 0 且几乎可以忽略. 这意味着大量递推运算浪费在无效粒子的更新上，从而产生退化分布. 缓解退化现象的常用方法是重采样和选取好的重要密度. 重采样技术的基本思想就是剔除小权值粒子，对大权值粒子依照其权值大小进行复制. 重采样带来的新问题是样本枯竭，即权值较大的粒子被多次选择，从而降低了粒子的多样性. SIS 算法和重采样技术构成了标准粒子滤波算法.

重要性密度函数的选择不仅影响到算法效率，还关系到权值的退化速度[10]. 因此，选择合理的重要性密度函数是粒子滤波的关键步骤之一. Doucet 从理论上给出了在给定 $\{\boldsymbol{x}_k^i, w_k^i, i = 1, 2, \cdots, N\}$ 和 $\boldsymbol{y}_{1:k} = \{\boldsymbol{y}_1, \boldsymbol{y}_2, \cdots, \boldsymbol{y}_k\}$ 的情况下使重要性权值的方差达到最小的最优重要性密度函数是[5,10]

$$q(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1}, \boldsymbol{y}_k) = p(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1}, \boldsymbol{y}_k). \tag{3}$$

在实际情况中，得到上式的困难程度几乎等同于直接从后验概率分布中采样. 但该式表明在产生预测样本时，合理的重要性密度函数应同时考虑已有的样本和最新的观测数据.

1.3　辅助粒子滤波

辅助粒子滤波算法是一种逼近最优重要性密度函数的方法. 与常见的 PF 算法不同，APF 将粒子采样与重采样步骤颠倒. 也就是说，APF 先进行重采样，利用当前时刻最新的观测信息对前一时刻的粒子进行评估，保留最有前途（预测似然度大）的粒子，从而增加了粒子的多样性. APF 引入

辅助变量 ζ 表示 $k-1$ 时刻粒子索引,选择重要性函数,满足:

$$q(\boldsymbol{x}_k,\zeta_{k-1}^i \mid \boldsymbol{y}_k) \propto p(\boldsymbol{y}_k \mid \boldsymbol{u}_{k|k-1}^i)p(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1}^i)w_{k-1}^i. \quad (4)$$

其中辅助变量 $\boldsymbol{u}_{k|k-1}^i$ 可以是均值、模式、或者是与 $p(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1}^i)$ 相关的某些统计信息. 也就是说 $\boldsymbol{u}_{k|k-1}^i = E[\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1}^i]$, 或样本点 $\boldsymbol{u}_{k|k-1}^i \sim p(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1}^i)$[5].

APF 首先获取每个粒子的辅助变量 $\boldsymbol{u}_{k|k-1}^i$,计算其对应的权值并归一化. 然后根据归一化权值对粒子集进行重采样, 得到其对应的粒子序号 ζ_{k-1}^i.最后从联合概率密度 $q(\boldsymbol{x}_k,\zeta_{k-1}^i \mid \boldsymbol{y}_k)$ 中采样之后,得到粒子集 $\{(\boldsymbol{x}_k,w_k^i)\}_{i=1}^N$,其中权值为

$$w_k^i \propto \frac{p(\boldsymbol{x}_k,\zeta_{k-1}^i = i \mid \boldsymbol{y}_{1:k})}{q(\boldsymbol{x}_k,\zeta_{k-1}^i \mid \boldsymbol{y}_{1:k})} = \frac{P(\boldsymbol{y}_k \mid \boldsymbol{x}_k^i)}{P(\boldsymbol{y}_k \mid \boldsymbol{u}_{k|k-1}^i)}. \quad (5)$$

辅助变量 $\boldsymbol{u}_{k|k-1}^i$ 的构建对于 APF 算法非常重要.一方面 APF 算法通过辅助变量 $\boldsymbol{u}_{k|k-1}^i$ 计算得到粒子的似然度值,然后才能确定 $k-1$ 时刻的粒子是否保留.另一方面,目标粒子集的权值计算也必须有辅助变量 $\boldsymbol{u}_{k|k-1}^i$ 的参与.已有的 APF 算法采用对辅助变量 $\boldsymbol{u}_{k|k-1}^i$ 进行点估计的方法.参数点估计的不足是依赖于样本点的选取,因而受噪声的影响较大.如果过程噪声较大时,APF 算法的滤波效果不如标准粒子滤波[11],其原因是此时 APF 算法对辅助变量 $\boldsymbol{u}_{k|k-1}^i$ 的估计较差.

2 基于区间估计的粒子滤波

类似于 APF,基于区间估计的粒子滤波算法依赖于与 $p(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1}^i)$ 相关的某些统计信息的获取.也就是说,PF-IE 算法从先验概率密度中采样,即 $\hat{\boldsymbol{x}}_k^i \sim p(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1})$,然后获取其期望值信息. 不同之处是,APF 算法是对辅助变量的点估计.而 PF-IE 算法是对采样粒子 $\hat{\boldsymbol{x}}_k^i$ 的期望值 $E[\hat{\boldsymbol{x}}_k^i]$ 进行区间估计.

基于区间估计的粒子滤波算法的关键是对 $\hat{\boldsymbol{x}}_k^i$ 进行区间估计,并在该区间上利用最新的观测信息修正,从而实现滤波.对期望值 $E[\hat{\boldsymbol{x}}_k^i]$ 进行区间估计,就是对真实状态值 $\boldsymbol{x}_k$ 以较大概率可能存在区间的预测,也就是其似然度值较高的区间.结合当前的观测信息对其进行区间估计,就可以得出 $\hat{\boldsymbol{x}}_k^i$ 以较大概率可能出现的区间,也就是其似然度值较高的区间.则在这个估计区间上均匀采样得到的粒子有较大概率就是状态真值.再次利用最新的观测信息计算这些粒子的似然度值,并对粒子值进行修正,从而得出滤波结果.

对采样粒子 $\hat{\boldsymbol{x}}_k^i$ 进行区间估计,已有的信息包括 $\{\hat{\boldsymbol{x}}_k^i, w_{k|k-1}^i, i = 1,2,\cdots,N\}$.但是不知道 $\hat{\boldsymbol{x}}_k^i$ 服从什么分布,且分布的参数 μ 和 σ^2 也未知.本文首先分析当服从正态分布时,置信概率为 $1-\alpha$ 时总体均值 μ 的置信区间,然后对非正态分布情况进行说明.

假设 $\hat{\boldsymbol{x}}_k^i \sim N(\mu,\sigma^2)$,则 μ 和 σ 的点估计分别是

$$\bar{\boldsymbol{x}} = \sum_{i=1}^N \hat{\boldsymbol{x}}_k^i w_{k|k-1}^i, \quad (6)$$

$$\frac{s}{\sqrt{N}} = \sqrt{\sum_{i=1}^N w_{k|k-1}^i (\hat{\boldsymbol{x}}_k^i - \bar{\boldsymbol{x}})^2}. \quad (7)$$

由数理统计的知识可以得出,统计量 $T = (\bar{\boldsymbol{\mu}} - \hat{\boldsymbol{x}}_k^i)/(s/\sqrt{N}) \sim t(N-1)$,并且总体均值 μ 的置信概率为 $1-\alpha$ 的置信区间为[12]

$$\left[\bar{\boldsymbol{x}} - t_\alpha \frac{s}{\sqrt{N}}, \bar{\boldsymbol{x}} + t_\alpha \frac{s}{\sqrt{N}}\right]. \quad (8)$$

其中 t_α 称为显著水平 α 下的临界值.

对于非正态分布,由中心极限定理可知,无论 $\hat{\boldsymbol{x}}_k^i$ 服从什么分布,只要样本容量 N 充分大,随机变量 $(\bar{\boldsymbol{\mu}} - \hat{\boldsymbol{x}}_k^i)/(s/\sqrt{N})$ 近似服从标准正态分布 $N(0,1)$. 只要样本容量满足大样本容量条件, $E(\hat{\boldsymbol{x}}_k^i) = \boldsymbol{\mu}$ 的置信区间仍可采用 $[\bar{\boldsymbol{x}} - t_\alpha(s/\sqrt{N}), \bar{\boldsymbol{x}} + t_\alpha(s/\sqrt{N}]$[12].

对 $\hat{\boldsymbol{x}}_k^i$ 进行区间估计之后,就可以利用最新观测信息对其进行修正.在该区间上,真实状态值 $\boldsymbol{x}_k$ 出现的概率是相同的.因此,在该区间上进行均匀采样 $\{\hat{\boldsymbol{x}}_k^i, i = 1,2,\cdots,N\}$,并对样本点计算其似然值 $\{\hat{w}_k^i, i = 1,2,\cdots,N\}$.

在上述区间估计公式中,如何选择 t_α 将对算法精度产生重要影响.如果选择较小的值,将无法保证真实状态值 $\boldsymbol{x}_k$ 位于这个区间.如果选择较大的值,虽然能够保证真实状态值 $\boldsymbol{x}_k$ 位于这个区间,但是将导致所需粒子数增加.因此,本文采用先在固定范围内采样,例如取固定值 $t_\alpha = 3$,并判断真实值是否在该区间上.如果不在该区间上,则将估计区间进行扩展.真实值 $\boldsymbol{x}_k$ 不在固定区间时,其表现形式是:均匀采样得到的粒子虽然彼此间差别较大,但其对应的是几乎相等权值.此时,算法应在该区间的相邻区间(即扩展后的区间) 生

成粒子，就能保证以近似于 1 的概率找到真实状态值. 因此，区间扩展的判断条件是

$$\min(\widehat{w}_k^i) == \max(\widehat{w}_k^i)\ \&\ \sigma' > k_\sigma. \tag{9}$$

其中参数 k_σ 是一个常数，用于判断标准差值大小. 根据 3σ 准则[12]，落在 $(\mu \pm 3\sigma)$ 范围内的可能值是所有值的 99.74%，几乎包含了所有可能的状态值. 因此将 $(\mu \pm 3\sigma)$ 作为区间估计的默认范围. 基于条件(9)，粒子的区间估计范围设置如下：

$$\begin{cases} \left[\bar{\boldsymbol{x}} - 3\dfrac{s}{\sqrt{N}}, \bar{\boldsymbol{x}} + 3\dfrac{s}{\sqrt{N}}\right], & \text{default}; \\ \left[\bar{\boldsymbol{x}} - 5\dfrac{s}{\sqrt{N}}, \bar{\boldsymbol{x}} - 3\dfrac{s}{\sqrt{N}}\right) \cup \left(\bar{\boldsymbol{x}} + 3\dfrac{s}{\sqrt{N}}, \bar{\boldsymbol{x}} + 5\dfrac{s}{\sqrt{N}}\right], \\ \quad \text{if } \min(\widehat{w}_k^i) == \max(\widehat{w}_k^i)\ \&\ \sigma' > k_\sigma. \end{cases} \tag{10}$$

综上所述，基于区间估计的粒子滤波算法如下：

1) 初始化：在 $k = 0$ 时刻，由先验概率 $p(\boldsymbol{x}_0)$ 产生粒子集 $\{\boldsymbol{x}_0^i\}_{i=1}^N$，且所有粒子的权值是 $\{w_0^i = 1/N\}_{i=1}^N$；

2) 重要性采样：在 k 时刻，进行重要性采样 $\widehat{\boldsymbol{x}}_k^i \sim q(\boldsymbol{x}_k \mid \boldsymbol{x}_{k-1}^i)$，更新其对应粒子的权值 $w_k^i = w_{k-1}^i\, p(\boldsymbol{y}_k \mid \widehat{\boldsymbol{x}}_k^i)$，并对权值进行归一化处理 $\bar{w}_k^i = w_k^i / \sum_{i=1}^N w_k^i$；

3) 状态估计输出：$\hat{\boldsymbol{x}} \approx \sum_{i=1}^N w_k^i \boldsymbol{x}_k^i$；

4) 利用式(6)、(7) 计算参数 $\widehat{\boldsymbol{x}}_k^i$ 的区间估计. 在该区间上进行均匀采样，并计算相应权值. 然后利用式(9)、(10) 判断和设置相应区间. 如果满足条件(9)，则在扩展区间上重新进行均匀采样和计算权值. 最后得到粒子集 $\{\boldsymbol{x}_k^i, w_k^i, i = 1, 2, \cdots, N\}$；

5) 时刻 $k = k + 1$，返回步骤 2).

3　应用实例与分析

为了对 PF-IE 算法进行性能验证，采用如下的非高斯、非线性系统[3]：

$$\begin{cases} x_k = 1 + \sin(0.4\pi x_{k-1}) + 0.5x_{k-1} + u_k, \\ y_k = \begin{cases} 0.2x_k^2 + v_k, & k \leqslant 30; \\ 0.5x_k - 2 + v_k, & k > 30. \end{cases} \end{cases} \tag{11}$$

其中 k 表示状态时刻，x_k 表示状态量，y_k 表示观测量，初始值是 $x_0 = 1.0$，状态噪声 $u_k \sim Gamma(3, 2)$，观测噪声 $v_t \sim N(0, 0.000\,01)$，初始化粒子集 $\{x_{k=1}\}_{i=1}^N \sim N(0, 5.0)$. 这是一个较为复杂的非线性递推 Bayesian 滤波问题，其最优的解析解是不存在的. 实验使用的粒子数 $N = 200$，时间间隔 $t = 1$ s，迭代步长 $T = 60$，$k_\sigma = 0.01$.

分别使用 PF、APF、UPF、GPF 以及本文所提出的 PF-IE 五种粒子滤波算法进行仿真实验. 图 1 是不同粒子滤波状态估计值曲线. 其中，PF-IE 的估计值最接近实际状态值.

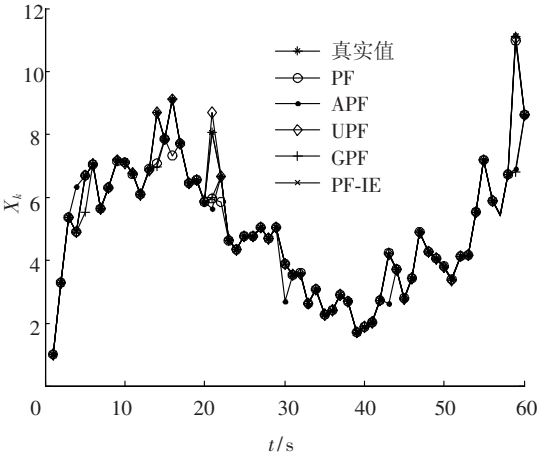

图 1　不同粒子滤波状态估计值曲线

为了进一步验证算法的性能，进行 100 次 Monte Carlo 仿真实验，以各算法估计状态的均方根误差(RMSE)为指标进行比较. 表 1 是估计结果的 RMSE 均值、方差和平均运行时间，图 2 是不同粒子滤波算法的 RMSE 误差曲线. 其中，一次独立实验的均方根误差 RMSE 定义为

$$R_{\text{RMSE}} = \left[\frac{1}{T}\sum_{k=1}^T (x_k - \hat{x}_k)^2\right]^{1/2}. \tag{12}$$

表 1　不同粒子滤波状态估计结果比较

滤波方法	RMSE 均值	RMSE 方差	运行时间 t/s
PF	0.445 9	0.054 1	0.464 9
APF	0.538 7	0.036 0	1.022 0
UPF	0.074 5	0.009 5	12.254 4
GPF	0.534 8	0.055 7	0.414 6
PF-IE	0.060 7	0.021 5	0.558 0

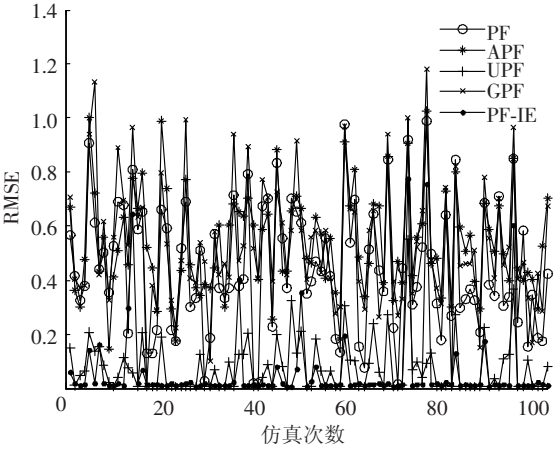

图 2　不同粒子滤波算法 RMSE 比较

从实验结果可以看出,本文提出的 PF-IE 算法的滤波精度要明显高于 PF,APF 和 GPF 算法,略优于 UPF 算法.在较大过程噪声的影响下,APF 算法的滤波精度要低于标准 PF 算法.同时,由于对于每个粒子需要计算两次似然函数和权值,APF 算法的运行时间较长.UPF 算法虽然精度较高,但是需要对确定性采样的 Sigma 点进行计算,从而导致运行时间过长,效率很低.GPF 算法的滤波精度低于标准 PF 算法是因为不满足高斯分布的假设.但是 GPF 算法不需要进行重采样,其运行时间要少于标准 PF 算法.PF-IE 算法利用区间估计代替点估计,降低了样本的影响,从而提高了滤波精度.同时,该算法虽然需要进行重复似然函数和权值的计算,但是不需要进行重采样,因此其运行时间接近于标准 PF 算法.此外,PF-IE 算法的 RMSE 方差值很小,表明该算法的稳定性较高.因此,本文给出的粒子滤波器状态估计效果最为理想.

4 结 论

本文针对非线性、非高斯动态系统的状态估计问题,提出一种基于区间估计的粒子滤波算法.新算法利用区间估计代替点估计,从而降低了样本对滤波精度的影响.由计算步骤可知,PF-IE 算法在估计区间上均匀采样,不需要进行重采样操作,一方面避免了样本枯竭问题,另一方面节省了时间.但是在计算过程中需要进行重复的似然函数和权值的计算,因此该算法的运行时间要略长于标准 PF 算法.仿真结果表明,PF-IE 算法的滤波精度要明显优于 PF,APF,UPF 和 GPF 算法.

参考文献

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

[2] MUSSO C, OUDJANE N, Le GLAND F. Improving Regularized Particle Filters[M]. Sequential Monte Carlo Methods in Practice. New York: Springer, 2001: 247-271.

[3] Van Der MERWE R, DOUCET A, De FREITAS N, *et al*. The Unscented Particle Filter[R]. Cambridge: Cambridge University Engineering Department, 2000.

[4] KOTECHA J H, DJURIC P M. Gaussian particle filtering[J]. IEEE Transactions on Signal Processing, 2003, 51(10): 2592-2601.

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

[6] CAPPE O, GODSILL S J, MOULINES E. An overview of existing methods and recent advances in sequential Monte Carlo[J]. Proceedings of IEEE, 2007, 95(5): 899-924.

[7] DOUCET A, JOHANSEN A M. A tutorial on particle filtering and smoothing: fifteen years later[C]//The Oxford Handbook of Nonlinear Filtering. Oxford: Oxford University Press, 2011.

[8] PITT M K, SHEPHARD N. Filtering via simulation: auxiliary particle filters[J]. Journal of American Statistical Association, 1999, 94(446): 590-599.

[9] 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.

[10] 朱志宇. 粒子滤波算法及其应用[M]. 北京:科学出版社, 2010.

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

[12] 周富臣,王生辉,易英,等. 常用数理统计方法及应用实例[M]. 北京:中国计量出版社, 2006.

(编辑 张 宏)