

文章编号: 1001-0920(2011)08-1253-06

基于分层转移的粒子滤波 MCMC 重采样算法

田 隽^{1,2}, 钱建生¹, 李世银¹

(1. 中国矿业大学 信息与电气工程学院, 江苏 徐州 221008;
2. 徐州工程学院 电子与信息工程学院, 江苏 徐州 221009)

摘要: 针对粒子滤波中如何设计重采样策略以解决“权值蜕化”, 同时又可避免“样本贫化”的问题, 提出一种基于分层转移的 Monte Carlo Markov 链 (MCMC) 重采样算法. 当样本容量检测出现“蜕化”时, 将样本集按权值蜕化程度进行分层, 利用提出的变异繁殖算法, 将其与 PSO 融合产生 MCMC 转移核, 并施以分层子集; 然后通过 Metropolis-Hastings 算法进行接收-拒绝采样, 由此构建的 Markov 链可收敛到与目标真实后验等价的平稳分布. 数值仿真结果表明, 所提出的算法能以更快的收敛速度和更小的估计误差贴近目标真实后验, 从而提高了估计精度.

关键词: 分层转移; 变异繁殖; 粒子群优化; Monte Carlo Markov 链; 重采样; 粒子滤波

中图分类号: TP391

文献标识码: A

Resampling algorithm for particle filter based on layered transacting MCMC

TIAN Jun^{1,2}, QIAN Jian-sheng¹, LI Shi-yin¹

(1. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou 221008, China; 2. School of Electronic and Information Engineering, Xuzhou Institute of Technology, Xuzhou 221009, China. Correspondent: TIAN Jun, E-mail: tian_jun2328@tom.com)

Abstract: To resolve weight degeneracy and avoid sample impoverishment in resampling algorithms of particle filter, a method, named layered transacting MCMC-resampling algorithm, is proposed. When the effective sample size is below a fixed threshold, particles are divided into two sample subsets according to their individual weights. Mutation operator and PSO, which are considered as transition kernels of MCMC, are applied to sample subsets respectively. Then an acceptance-rejection rule of Metropolis-Hastings algorithm is used to generate the Markov chain with the stationary distribution which is equivalent to target posterior density. The simulation results show that the proposed method is superior to other resampling algorithms both in accuracy and convergence speed.

Key words: layered transacting; mutation; particle swarm optimization; MCMC; resampling; particle filter

1 引言

粒子滤波 (PF) 是以带权样本近似 Bayesian 后验的一种数值逼近方法. PF 是以 sequential importance sampling (SIS) 和 sequential importance resampling (SIR) 为基础的序贯 Monte Carlo (MC) 方法, 也称 SMCPF^[1]. PF 以序贯 MC 方法解决 Bayesian 框架下非线性估计问题, 适用于任意的状态空间模型. Importance sampling (IS) 从易于采样的建议分布获得预测样本, SIS 为 IS 的递推实现. 由于算法经过多次迭代后大多数非归一的重要性权都趋于 0, 重要性权的方差必然随时间而递增, 即“权值蜕化”. 而 SIR, 作为 SIS 与重

采样算法的结合, 是解决蜕化问题的有效手段. 但由于在蜕化样本上施以丢弃小权值复制大权值样本的重采样算法, 致使样本多样性丧失, 带来“样本贫化”问题. 重采样后, 大量样本只是少数几个高权样本的复制, 样本集的大多数粒子所占据的仅是其父辈粒子在状态空间中的位置, 样本间强相关. 显然, 这少数几个高权粒子不足以准确表征目标真实后验状态的不确定性, 并最终导致滤波器发散.

目前, 对 PF 样本贫化问题的研究主要分为两类: 基于重采样前和基于重采样后样本多样性的恢复. 重采样前预处理: 文献 [2] 提出在重采样前进行权值排

收稿日期: 2010-05-28; 修回日期: 2010-09-17.

基金项目: 国家863计划项目(2008AA062200); 江苏省产学研联合创新基金项目(BY2009114).

作者简介: 田隽(1981—), 女, 讲师, 博士生, 从事计算机视觉及智能视觉监控的研究; 钱建生(1964—), 男, 教授, 博士生导师, 从事宽带网络技术、智能视觉等研究.

序、裂变繁殖的预处理,以平滑权值差异使得更多的样本获得重采样,实质是以平滑权值后的部分样本代替蜕化样本,虽能延迟贫化时间,但不能避免贫化.重采样后置入多样性:文献[3-4]通过正则化方法恢复多样性,以一系列Epanechnikov或Gaussian核来产生与目标后验在广义上保持同分布的连续分布,从该连续分布上采样并置入重采样后样本集.正则化实现的困难在于正则化核的设计既要置入适量多样性,又要保留目标后验分布的非线性、非高斯等复杂本质.

文献[5]将遗传进化算法用于PF重采样,利用遗传算法的选择、交叉和变异算子,对贫化样本集中的高权样本进行变异繁殖以及权值的再分配,以高权值变异子代取代蜕化样本.GA算法强调通过“竞争”淘汰蜕化样本,经多次迭代后样本多样性的丧失仍无可避免.文献[6]对重采样后每个粒子施以MCMC移动,历经足够的转移步数和烧穿时间后构建的Markov链将收敛到与目标后验等价的平稳分布.MCMC准则确保了重采样后粒子都能异步收敛到Bayesian后验^[4],但收敛需要较长烧穿时间.

上述重采样策略均是对重采样后贫化样本置入多样性,虽能改善贫化,但不能避免贫化,对于已经贫化的样本不具有恢复能力.对此,本文提出一种基于分层转移的MCMC重采样算法.该算法打破了传统重采样丢弃小权值复制大权值,牺牲多样性,从而导致“样本贫化”的思路.在MCMC准则下,粒子被调整到状态空间中的高似然区域,由Markov链平稳分布存在且唯一性质,确保了移动后粒子集对Bayesian后验的逼近.但MCMC为达到平稳分布所需的转移步数直接影响了PF-MCMC算法的收敛速度,MCMC对每个样本施以转移核并通过足够烧穿时间达到平稳分布的过程,等效于在不提供全局模型的前提下搜索空间的寻优过程.因此,受PSO通过个体最优值和全局最优值更新粒子状态和速度的启发,MCMC转移核的设计充分利用了样本间交互信息,获得了更快的收敛速度.但搜索空间为多峰值时PSO易陷入局部极值,且粒子速度与状态更新具有对PSO参数变化敏感的特性,使其不宜成为分布在高似然区域附近大权值粒子的MCMC转移核.因此本文提出对样本集按权值蜕化程度分层,分别采用变异繁殖和PSO移动作为MCMC转移核,直至收敛;再采用Metropolis-Hastings算法进行接收-拒绝采样,所构建的Markov链收敛到与目标真实后验等价的平稳分布.仿真实验表明,当状态值强跳变时,本文算法能以更快的收敛速度和更小的估计误差贴近目标真实后验,与传统重采样后MCMC移动算法相比,估计准确率提高了42.59%.

2 SIR 以及问题描述

PF用一组加权样本表征后验,以数值逼近的方法实现对非线性Bayesian滤波的优化近似.由于从状态后验 $p(x_k|y_{1:k})$ 直接采样难以实现,人们提出了重要性采样IS,SIS则是IS的递推实现.但SIS不可避免地出现“权值蜕化”问题,即重要性权的方差随时间递增.文献[7]从理论上证明了递推的重要性函数出现蜕化的必然性.事实上,算法经历多次迭代后,大多数非归一化的重要性权都趋于0,而大量的计算都浪费在对最终后验估计贡献近乎为0的样本及权值的更新上.为避免蜕化问题,引入了重采样算法,SIR即是SIS与重采样算法的结合,实现过程如下^[1]:

1) 重要性采样

① For $i = 1, \dots, N$, 采样 $\tilde{x}_k^{(i)} \sim \pi(x_k|x_{0:k-1}^{(i)}, y_{0:k})$ 且有 $\tilde{x}_{0:k}^{(i)} \triangleq (x_{0:k-1}^{(i)}, \tilde{x}_k^{(i)})$;

② For $i = 1, \dots, N$, 计算重要性权

$$\omega_k^{*(i)} = \omega_{k-1}^{*(i)} \frac{p(y_k|\tilde{x}_k^{(i)})p(\tilde{x}_k^{(i)}|\tilde{x}_{k-1}^{(i)})}{\pi(\tilde{x}_k^{(i)}|\tilde{x}_{0:k-1}^{(i)}, y_{0:k})},$$

归一化

$$\tilde{\omega}_k^{(i)} = \omega_k^{*(i)} / \sum_{j=1}^N \omega_k^{*(j)};$$

③ 计算有效样本容量

$$\hat{N}_{\text{eff}} = 1 / \sum_{i=1}^N (\tilde{\omega}_k^{(i)})^2.$$

2) 重采样

① 若 $\hat{N}_{\text{eff}} \geq N_{\text{th}}$, 则 $x_{0:k}^{(i)} = \tilde{x}_{0:k}^{(i)}$, For $i = 1, \dots, N$; 否则, For $i = 1, \dots, N$, 从 N 个粒子中采样 $j(i)$, 其分布满足 $\Pr\{j(i) = l\} = \tilde{\omega}_k^{(l)}$, For $l = 1, \dots, N$.

② For $i = 1, \dots, N$, $x_{0:k}^{(i)} = \tilde{x}_{0:k}^{(j(i))}$ 且 $\omega_k^{(i)} = 1/N$.

重采样算法的基本思想是,去除小权值粒子,复制大权值粒子.重采样解决“权值蜕化”的实质是在重采样后的等权新样本集中,以之前大权值粒子的子代代替蜕化的小权值粒子.因此“样本贫化”问题的根源是在权值蜕化样本集上的重采样.理论上,一次重采样后,样本集不再统计独立,之前样本收敛的结果也不再成立;重采样限制了样本平行化的机会,因为重采样后样本相关性较强,且具有大权值的样本在统计上被多次选择,大量样本实际上相等,多样性丧失.

解决权值蜕化并保持样本多样性的方法需要平衡产生预测样本的建议分布与目标分布的关系^[4],建议分布必须使大量样本准确处于状态空间中的高似然区域,这样,目标分布才能为大多数样本分配到不可忽略的权值.因此重采样算法的设计应是引导样本集向状态空间高似然区域移动,而非用大权值样本的

子代代替小权值样本。

3 Monte Carlo Markov 链

MCMC的基本思想是假设从目标分布 $f(x)$ 中采样样本,设计一个Markov链,使其经历足够的烧穿时间后收敛到与 $f(x)$ 等效的平稳分布,即此时平稳的Markov链中采样样本与 $f(x)$ 中采样等效。根据建立Markov链方法的不同,产生两类不同的MCMC采样方法:Metropolis-Hastings(M-H)和Gibbs sampling。M-H是MCMC中最常用的采样算法,M-H采用条件密度函数 $T(\cdot)$ 来产生具有目标分布 $f(\cdot)$ 的Markov链。M-H算法描述如下^[8]:

1) 以 S_t^{i*} 表示粒子 x_t^i 由状态 S_t^i 经转移核 $T(\cdot)$ 移动到的新状态。

2) 取 $\mu \sim \mathcal{U}[0, 1]$, α 为接受移动概率,即

$$\alpha = \min \left\{ 1, \frac{f(S_t^{i*})T(S_t^i|S_t^{i*})}{f(S_t^i)T(S_t^{i*}|S_t^i)} \right\}.$$

3) 若 $\mu \leq \alpha$,则接受移动, $S_{t+1}^i = S_t^{i*}$;否则, $S_{t+1}^i = S_t^i$ 。

MCMC准则确保了在有限粒子集上,重采样后粒子都能异步收敛到Bayesian后验^[4]。基于MCMC移动的PF性能取决于MCMC转移核的选择,同时转移核的设计决定了Markov链的烧穿时间。

4 粒子群优化算法

粒子群优化算法(PSO)^[9]模拟鸟集群飞行觅食的行为,通过个体间协作使群体达到最优目的地,是一种基于群智能的优化方法。PSO以最大适应度值粒子表示搜索空间中最优点值,以缩小粒子与全局极值和个体极值的差距作为运动机制,并不断更新粒子在搜索空间中的速度和位置。PSO基于群智能的思想,为在没有集中控制且不提供全局模型的前提下寻找复杂分布式问题的求解奠定了基础。

PSO数学描述如下^[9]:个体极值为第 i 个粒子 t 次迭代中的历史最优值 P_i ,全局极值为 n 个粒子的迭代历史中最优值 P_g (为所有 P_i 中的最优)。粒子 $t+1$ 次迭代中速度与位置更新如下:

$$V_i(t+1) = \omega * V_i(t) + c_1 * \text{rand}() * [P_i(t) - X_i(t)] + c_2 * \text{rand}() * [P_g(t) - X_i(t)], \quad (1)$$

$$X_i(t+1) = X_i(t) + V_i(t+1). \quad (2)$$

其中: c_1, c_2 为加速因子; $\text{rand}()$ 为 $[0, 1]$ 之间的随机数; ω 为惯性因子。

由于PSO充分利用群智能中个体间信息交互能力,总能取得比仅依靠个体先验信息的搜索寻优算法更快的收敛速度。但标准PSO存在局部搜索能力不足的问题,特别当搜索空间为多峰值状态时,PSO易陷入局部极值。由于PF中未出现蜕化的大权值粒子多

分布在高似然区域附近,向状态空间最优值移动距离较小,迭代过程中适应度值相对接近,PSO参数的细微变化或随机扰动都将对粒子寻优造成影响,使大权值粒子移出状态空间最优值区域(脱离高似然区域成为蜕化粒子)。

5 分层转移的PF-MCMC重采样算法

本文提出以分层转移策略设计MCMC转移核以构建Markov链。将样本集划分为高权值子集 S_H 和权值蜕化子集 S_D 。对 S_H 进行变异繁殖,为最大程度保留大权值粒子表征状态,变异繁殖算子实质上是以大权值粒子为均值对其进行高斯采样,使其变异子代仍分布在高似然区域附近。为避免同父辈的子代粒子被多次采样,构建同源子集 SS_{mutation} (由父粒子与其繁殖子代构成),在 SS_{mutation} 上按适应度值采样,产生更接近目标真实后验的粒子样本。对 S_D 进行PSO优化,通过融入最新观测的适应度值实现对粒子速度更新的调整,驱使粒子群向更贴近目标真实后验的高似然区域移动,直至 $P_{g\text{best}}$ 全局最优值低于阈值 ξ 时,PSO停止搜索寻优。采用M-H采样算法计算Acceptance-ratio,输出样本集是以目标后验分布为平稳分布的Markov链。

对后验样本 $\{x_k^i\}_{i=1, \dots, N}$ 样本进行容量检测。若 $N_{\text{eff}} \leq N_{\text{th}}$,则进入分层PSO优化MCMC重采样算法。其中,变量定义并初始化为: $n=0$, n 为MCMC迭代次数; $X_{k,n}^i$ 为第 n 次MCMC迭代的 x_k^i , $V_{k,n}^i$ 为第 n 次MCMC迭代的PSO移动速度, $X_{k,0}^i = x_k^i$, $V_{k,0}^i = 0$; $\{\mu_{k,n}^i\}_{n=0, \dots, J}$ 为 J 次MCMC迭代 $X_{k,n}^i$ 权值集合。算法实现过程如下:

Step 1: 将 t 时刻后验样本 $\{x_k^i\}_{i=1, \dots, N}$ 根据权值蜕化程度划分为两个子集:PSO-high weighted高权值子集 S_H ,PSO-weight degenerated蜕化子集 S_D 。

Step 2: 对子集 $S_H = \{X_{k,n}^i\}_{i=0, \dots, M-1} (M < N)$ 进行变异繁殖:

1) 以 $X_{k,n}^i$ 为均值对其进行高斯采样,变异子代样本数与其父粒子权值大小成正比, $X_{k,n+1}^{\text{mutation},i} = f(X_{k,n}^i) \sim \mathcal{N}(\mu_k^i, \sigma_k^{(i^2)})$,得到变异移动后样本: $\{X_{k,n+1}^{\text{mutation},i}\}_{i=0, \dots, 2M-1}$ 。

2) 计算 $SS_{\text{mutation}} = \{X_{k,n}^i, X_{k,n+1}^{\text{mutation},j}\}_{i=0, \dots, M-1, j=0, \dots, B_i}$ 适应度值 $f_{k,n}^i$: $f_{k,n}^i = \exp[-(1/2)Q_k^i(z_k^i - y_k^i)^2]$ 。其中: B_i 为 $X_{k,n}^i$ 产生子代数, $y_k^i \in SS_{\text{mutation}}$, Q_k^i 为观测噪声方差, z_k^i 为 x_k^i 观测值。

3) 据 $f_{k,n}^i$ 排序,将前 M 个样本作为输出,即

$$\{\hat{X}_{k,n+1}^i\}_{i=0, \dots, M-1}^{\text{mutation}}$$

Step 3: 对子集 $S_D = \{X_{k,n}^i\}_{i=0, \dots, N-M-1}$ 进行PSO优化:

1) 确定全局极值 P_{gbest} (S_D 子集中具有最大权值的粒子状态) 和局部极值 P_{pbest}^i ($X_{k,n}^i$ 在 J 次 MCMC 迭代中最大权值对应的粒子状态), 即

$$P_{\text{gbest}} = F(\max(\{\mu_{k,n}^i\}_{i=0,\dots,N-M-1})),$$

$$P_{\text{pbest}}^i = F(\max(\{\mu_{k,n}^i\}_{n=0,\dots,J})),$$

其中 $\mu_{k,n}^i$ 为 $X_{k,n}^i$ 粒子权值.

2) PSO 更新速度与状态分别为

$$V_{k,n+1}^i = V_{k,n}^i + \phi_1(P_{\text{pbest}}^i - X_{k,n}^i) +$$

$$\phi_2(P_{\text{gbest}} - X_{k,n}^i),$$

$$\hat{X}_{k,n+1}^i = X_{k,n}^i + V_{k,n+1}^i.$$

其中: $X_{k,n}^i \in S_D$, ϕ_1 和 ϕ_2 为服从 Gauss 分布的随机数, 输出 $\{\hat{X}_{k,n+1}^i\}_{i=0,\dots,N-M-1}^{\text{PSO}}$.

Step 4: 计算 Metropolis-Hastings 接受率

$$\alpha = \frac{P(\hat{X}_{k,n+1}^i | z_{1:k})q(X_{k,n}^i; \hat{X}_{k,n+1}^i)}{P(X_{k,n}^i | z_{1:k})q(\hat{X}_{k,n+1}^i; X_{k,n}^i)}.$$

Step 5: $\rho \sim \mathcal{U}(0, 1)$, 若 $\rho \leq \min(1, \alpha)$, 则接受移动 $X_{k,n+1}^i = \hat{X}_{k,n+1}^i$; 否则, 拒绝移动 $X_{k,n+1}^i = X_{k,n}^i$.

Step 6: 判断收敛条件. 若 $P_{\text{gbest}} \leq \varepsilon$, 则停止优化, 转 Step 8.

Step 7: 计算移动后粒子权值

$$\mu_{k,n+1}^i = P(z_k^i | X_{k,n+1}^i),$$

$n++$, 返回 Step 2;

Step 8: 输出重采样样本集

$$\{X_k^i | X_k^i = X_{k,n+1}^i\}_{i=0,\dots,N-1},$$

权值归一化 $\omega_k^i = 1/N$, 进入建议分布样本预测.

6 实验结果与分析

为了验证本文算法在非线性系统中的估计性能, 采用文献 [2] 中的经典算例进行数值仿真. 将 SIR-PF (SIR), 重采样后遗传算法置入多样性-PF (RGA-PF), 重采样后 MCMC-PF (RMH-PF), 以 PSO 为转移核的 MCMC 重采样-PF (PSO MH-PF), 与本文算法 (Muta & PSO MH-PF) 分别作 60 次 MC 仿真. 其中: SIR, RGA-PF 和 RMH-PF 中采用残差重采样; RMH-PF 中采用随机走步 RWM 作为 Metropolis-Hastings 算法的转移核. 下面将从估计精度和收敛速度两方面进行比较说明.

仿真系统模型与观测模型如下:

$$x_k = c_1 x_{k-1} + c_2 \frac{x_{k-1}}{1 + x_{k-1}^2} + c_3 \cos(1.2(k-1)) + \omega_k, \quad (3)$$

$$y_k = \frac{x_k^2}{20} + v_k. \quad (4)$$

其中: $c_1 = 1$, $c_2 = 12$, $c_3 = 7$, 状态噪声 $\omega_k \sim \mathcal{N}(0, \sigma_\omega^2)$, 观测噪声 $v_k \sim \mathcal{N}(0, \sigma_v^2)$, $\sigma_\omega = \sigma_v = 2$.

进行 60 次 MC 仿真. 粒子数 $N_s = 200$, $N_{\text{eff}} \leq N_s/3$ 时进入重采样, 初始状态 $x_0 = 0$, 状态转移概率 $p(x_{t+1}|x_t)$ 为建议分布以实现样本预测. 当 $y_k > 0$ 时, 状态后验为双峰, 状态模型中存在一项与状态无关的时间正弦函数, 可视为状态噪声中的时变部分. 此模型是较为复杂的递推非线性滤波, 其精确解析解并不存在, 因此采用上述 5 种不同重采样策略的 PF 对其进行状态逼近.

为测试权值蜕化下不同重采样策略对状态估计性能的影响, 在上述系统模型下, 以样本均值 $\bar{x}_t = \frac{1}{N} \sum_{i=1}^N \omega_t^i x_t^i$ 作为输出, 对上述 5 种 PF 进行样本均值 RMSE 比较, 其中定义

$$\text{RMSE}(\hat{x}_k) = \left[\frac{1}{N_{\text{MCMC}}} \sum_{i=1}^{N_{\text{MCMC}}} (x_k - \hat{x}_k^i)^2 \right]^{1/2}.$$

当 $k = 30$ 时, 使状态值 x_t 发生强跳变, 由于没有预测样本分布在强跳变状态值附近, 5 种 PF 均出现了不同程度的权值蜕化 (以 RMH-PF 为例, 图 1(a) 中 $t = 8$, 此时未出现权值蜕化; 而图 1(b) 中 $t = 30$, 此时出现了严重的权值蜕化), 此时满足 $N_{\text{eff}} \leq N_s/3$ 条件, 5 种 PF 进入重采样. 图 2 为状态值强跳变后, 5 种 PF 状态估计与状态真值的偏离情况.

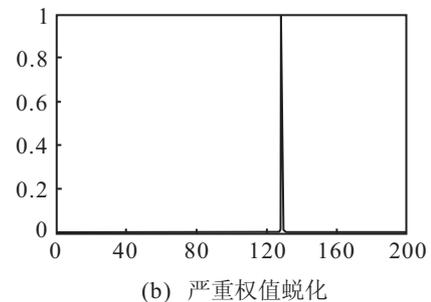
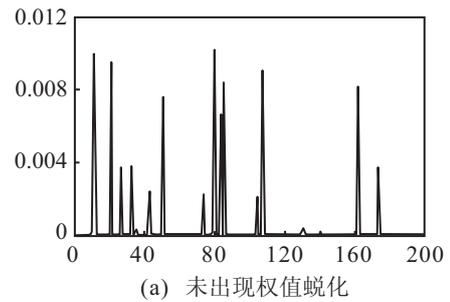


图 1 RMH-PF 样本权值

SIR 在状态值出现强跳变后估计误差最大, 如图 2(a) 所示. 由于 SIR 在权值蜕化时采用残差重采样, 以极少数高权样本子代替换大量蜕化样本, 以牺牲样本的多样性来解决权值蜕化问题, 经多次迭代后, 大量样本聚集在状态空间中少数几个离散点, 此时贫化的样本集不足以表征状态后验不确定性, 与真实状态出现了较大偏离, 直至滤波器发散.

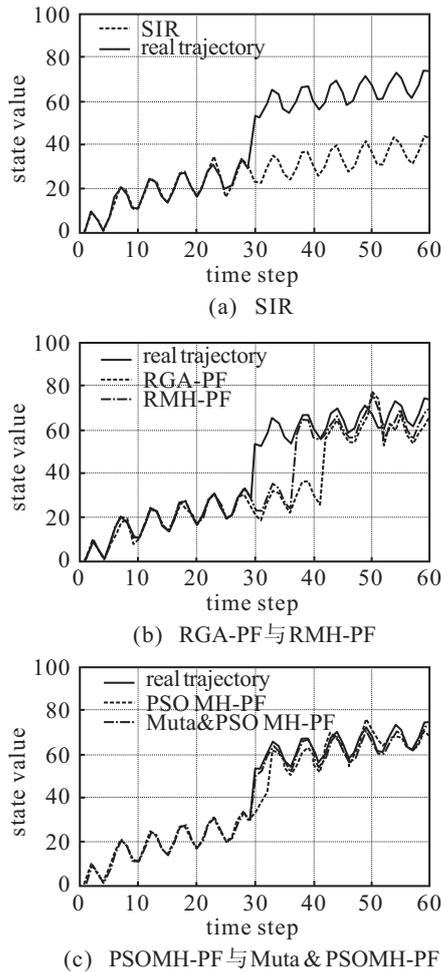


图 2 状态值强跳变时 5 种 PF 状态估计性能比较

图 2(b) 为 RGA-PF 与 RMH-PF 的比较。后者在 MCMC 准则下调整重采样后粒子到状态空间中的高似然区域, 确保了移动后粒子集对 Bayesian 后验的逼近。当状态值出现强跳变时, 相对于 RGA-PF, RMH-PF 能更快地收敛到状态真值附近。两者同属于重采样后置入多样性, 在状态值发生强跳变后一度失去对目标的定位, 但经几步迭代后便可恢复, 在估计精度上均优于 SIR。但多次迭代后, 样本贫化仍不可避免, 且对于已经贫化的样本不具有恢复性, 由贫化导致的估计精度下降在所难免, 图 2(b) 中 $t > 50$ 后, 估计精度明显下降。

图 2(c) 为 PSO MH-PF 与 Muta & PSO MH-PF 的比较。两者同属于 MCMC-PF 类(以 MCMC 转移代替传统重采样), 在 MCMC 转移核上采用了不同算法。此类算法突破了传统重采样算法复制大权值丢弃小权值粒子的基本思想, 在 MCMC 框架下引导蜕化样本向高似然区域移动, 扩大了预测样本与高似然区重叠区域, 从而在解决权值蜕化的同时避免了多样性的丧失, 与重采样后置入多样性算法比较, 此类算法获得了更高的估计精度, 能以更小的估计误差贴近真实目标状态。

由图 2(c) 可见, 当状态值强跳变时, 两种算法均

能保持对目标真实状态的贴近。其中, PSO MH-PF 对于所有样本均采用 PSO 作为转移核, 忽略了大权值粒子的特殊性。PF 中未出现蜕化的大权值粒子多分布在高似然区域附近, 向状态空间最优值移动距离较小, 迭代过程中适应度值相对接近。此时, 粒子状态更新对于 PSO 参数的变化敏感, PSO 参数较小变化或者随机扰动都会使部分大权值粒子移出状态空间最优值区域。如图 2(c) 中多个状态峰值点出现了与真实状态后验较大的偏离。

本文算法对样本集按蜕化程度进行分层, 分别采用变异繁殖和 PSO 作为转移核, 充分利用样本间交互信息以获得更快的收敛速度, 同时又避免了 PSO 算法对高权粒子进行 MCMC 转移时存在的不足。从图 2(c) 不难看出, 状态强跳变时, 由于对高权粒子的变异繁殖为一步采样过程, 避免了 PSO 迭代寻优, 本文算法比 PSO MH-PF 取得了更快的收敛速度, 在多个状态峰值点, 取得了更小的估计误差, 以近似 0 误差贴近目标真实状态。

表 1 估计精度与计算耗时

方法	RMSE-mean	average of execution time
SIR	5.075 2	0.328 0
RGA-PF	4.749 8	0.675 3
RMH-PF	3.674 2	0.740 2
PSO MH-PF	2.873 2	0.451 7
Muta & PSO MH-PF	2.109 1	0.390 3

从表 1 可以看出, 本文算法在提高估计精度的同时, 保留了低计算开销的优势, 平均运行时间低于同类 MCMC-PF 算法中的 PSO MH-PF (本文算法对部分粒子变异繁殖避免了 PSO 迭代寻优)。本文算法运行时间与有效样本容量的选择有关, 有效样本容量值越大, 表明高权粒子在样本集中所占比例越大, 即样本被施以变异繁殖一步采样的概率越大。在本算例非线性系统模型中, 本文算法在解决权值蜕化的同时避免了样本贫化, 对状态估计准确率明显优于其他 PF 算法, 与 RMH-PF 比较, 总体准确率提高 42.59%。

7 结 论

根据本文提出的以变异繁殖和 PSO 进行分层转移的 MCMC 重采样算法 (Muta & PSO MH-PF), 对上述非线性系统模型进行了数值仿真, 并将本文算法与 SIR, RGA-PF, RMH-PF 和 PSO MH-PF 进行了 RMSE 和状态真值偏离度比较, 同时对算法的估计精度和收敛速度进行了分析, 得到如下结论:

1) 由于传统的解决 PF 样本贫化问题的方法一般是重采样后置入多样性, 如 RGA-PF 和 RMH-PF, 对已经贫化的样本不具有恢复能力, 且随着迭代次数的增加, 样本贫化不可避免。本文重采样算法设计的思路

是, 引导蜕化样本集向状态空间高似然区域移动, 增加预测样本与高似然区的重叠区域, 而非传统重采样中以高权粒子副本替换蜕化粒子, 以牺牲样本的多样性解决样本蜕化问题。

2) 类 MCMC 重采样算法, 如 RMH-PF, PSO MH-PF 和 Muta & PSO MH-PF, 总能取得更贴近目标真实状态的后验估计, 说明 MCMC 准则下粒子被调整到状态空间中的高似然区域, 由 Markov 链平稳分布存在且唯一性质, 确保了移动后粒子集对 Bayesian 后验的逼近。

3) 类 MCMC 重采样算法的状态估计准确率和收敛速度取决于 MCMC 转移核的设计。PSO MH-PF 以 PSO 作为转移核, 对于分布在高似然区域附近的高权粒子, 向状态空间最优值移动距离较小, 迭代过程中适应度值相对接近, 迭代中粒子状态更新对 PSO 参数变化敏感, 参数细微变化或者随机扰动均对粒子寻优造成影响, 使部分高权粒子脱离高似然区域, 从而导致与真实状态较大偏离。本文算法采用分层转移策略, 将变异繁殖与 PSO 分别作为高权子集与蜕化子集转移核, 在状态强跳变时, 仍保持对目标真实状态后验的贴近, 与传统重采样后 MCMC 移动算法比较, 估计准确率提高了 42.59%。

参考文献(References)

- [1] Doucet A, Godsill S, Andrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering[J]. *Statistics and Computing*, 2000, 10(3): 197-208.
- [2] 程水英, 张剑云. 裂变自举粒子滤波[J]. *电子学报*, 2008, 36(3): 500-504.
(Cheng S Y, Zhang J Y. Fission bootstrap particle filtering[J]. *Chinese J of Electronics*, 2008, 36(3): 500-504.)
- [3] Arulampalam M S, Maskell S, Gordon N, et al. A tutorial on particle filters for on-line nonlinear/non-gaussian Bayesian tracking[J]. *IEEE Trans on Signal Processing*, 2002, 50(2): 174-188.
- [4] Ristic B, Arulampalam S, Gordon N. *Beyond the Kalman filter: Particle filter for tracking application*[M]. Boston: Artech House, 2004.
- [5] Kwok N M, Gu F, Zhou W Z. Evolutionary particle filter: Re-sampling from the genetic algorithm perspective[C]. *Intelligent Robots and Systems 2005*. Edmonton, 2005: 2935-2940.
- [6] Zhai Y, Yeary M. Implementing particle filters with metropolis-hastings algorithms[C]. *Region 5th Conf: Annual Technical and Leadership Workshop*. Norman: IEEE Press, 2004: 149-152.
- [7] Kong A, Liu J S, Wong W H. Sequential imputations and bayesian missing data problems[J]. *J of the American Statistical Association*, 1994, 89(3): 278-288.
- [8] Berg B A. *Markov chain Monte Carlo simulations and their statistical analysis*[M]. Singapore: World Scientific, 2004.
- [9] Clerc M, Kennedy J. The particle swarm: Explosion, stability, and convergence in a multimentional complex space[J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(1): 58-73.
- [5] 岑健, 胥布工, 张清华, 等. 基于证据理论的免疫检测器在轴承故障诊断中的应用[J]. *轴承*, 2009(357): 42-45.
(Cen J, Xu B G, Zhang Q H, et al. Application of immune detector in bearing fault diagnosis based on Dempster-Shafer evidential theory[J]. *Bearing*, 2009(357): 42-45.)
- [6] 何友, 王国宏, 陆大淦, 等. 多传感器信息融合及应用[M]. 北京: 电子工业出版社, 2000.
(He Y, Wang G H, Lu D G, et al. *Multi-sensor information fusion and application*[M]. Beijing: Electronic Industry Press, 2000.)
- [7] MacMillan T R. Knowledge based route planning[C]. *Proc of IEEE NAECON*. Dayton, 1991: 1001-1007.
- [8] 岑健, 张清华, 胥布工, 等. 无量纲免疫检测器在缓变故障检测中的应用[J]. *华南理工大学学报*, 2009, 37(5): 64-67.
(Cen J, Zhang Q H, Xu B G, et al. Application of immune detector in bearing fault diagnosis based on Dempster-Shafer evidential theory[J]. *J of South China University of Technology*, 2009, 37(5): 64-67.)
- [9] 张清华, 钱宇, 胥布工, 等. 一种采用非己空间变异搜索的故障检测算法[J]. *计算机工程与应用*, 2007, 43(28): 92-95.
(Zhang Q H, Qian Y, Xu B G, et al. A kind of spatial variability has been searching non-fault detection algorithm[J]. *Computer Engineering and Applications*, 2007, 43(28): 92-95.)
- [10] Peter M, Adriel L, Marek R, et al. Immune programming[J]. *Information Sciences*, 2006, 176(8): 972-1002.

(上接第1252页)