

基于 Monte Carlo 方法的自适应多模型诊断

杨小军, 潘 泉, 张洪才

(西北工业大学自动化学院, 陕西 西安, 710072)

摘要: 多模型混合系统的模型切换服从有限状态的 Markov 链, 其转移概率通常假定是已知的. 当模型转移概率未知的时候, 本文基于 Monte Carlo 粒子滤波器给出了混合系统状态估计的一种自适应算法. 该算法假定未知的转移概率先验分布为 Dirichlet 分布, 首先通过采样得到一组模型序列的随机样本, 利用其中状态的转移次数计算先验转移概率, 使用量测信息对样本更新选择后, 获得模型转移概率的一种迭代的后验估计值, 同时由粒子滤波器得到系统状态和模型概率的后验估计. 将该方法用于混合系统的状态监测和故障诊断, 仿真结果表明了算法的有效性.

关键词: 多切换动态模型; 混合估计; 粒子滤波器; 转移概率矩阵; 自适应滤波

中图分类号: TP202 **文献标识码:** A

Adaptive multi-model diagnosis using Monte Carlo method

YANG Xiao-jun, PAN Quan, ZHANG Hong-cai

(College of Automation, Northwestern Polytechnical University, Xi'an Shaanxi 710072, China)

Abstract: Commonly, the models of hybrid system switch according to a finite state Markov chain with known transition probabilities. For state estimation of hybrid system with unknown transition probabilities, an adaptive estimation algorithm is proposed based on Monte Carlo particle filtering. The proposed algorithm assumes that the prior distribution of unknown transition probabilities follows Dirichlet distribution. First, a set of random samples of model sequence is achieved by sampling. Second, the prior transition probabilities are calculated by the frequency of model transitions in model sequence samples. Third, the posterior estimation of transition probabilities is achieved via measurement update and selection. Finally, the posterior estimation of state and model probability is obtained by particle filtering. In the state monitoring and multiple faults diagnosis of a class of hybrid system, the proposed method has been proved to be very effective.

Key words: multiple switching dynamic models; hybrid estimation; particle filtering; transition probability matrix; adaptive filtering

1 引言 (Introduction)

对于机动目标跟踪, 故障诊断这样的一类复杂系统, 系统状态在连续变化的同时, 还存在由于各种模式的切换带来的突变. 这类系统由一组代表工作模式的离散值模型状态, 和一组代表系统动态的连续值状态构成, 模型的切换服从 Markov 链, 称为多模型混合系统. 混合系统的状态估计要求同时估计连续和离散状态, 经典的多模型估计算法有通用伪 Bayes 算法 (GPB)^[1] 和交互式多模型算法 (IMM)^[2,3], 但这些算法依赖于模型的线性高斯假设或线性高斯逼近. 最近几年发展起来的粒子滤波器^[4,5], 由于能对付任意非线性非高斯模型而得到广泛应用^[6,7]. 混合系统的模型转移概率矩阵通

常是由先验信息设计好的^[1], 但对许多实际问题, 先验信息是不充分的, 导致了估计性能的退化, 因此如何估计转移概率是目前的一个研究方向. 对线性高斯系统, 文献[8]提出了转移概率的最大似然估计, 文献[9]利用模型似然度提出了转移概率的 Bayes 估计算法. 在转移概率先验为 Dirichlet 分布的假设下, 文献[10]将转移概率作为未知参数积分出去, 得到状态和模型概率的后验估计. 本文基于粒子滤波器, 对转移概率未知的混合系统, 用状态空间的一组随机样本(粒子)在线同时估计转移概率, 系统状态和模型, 得到一种自适应的估计算法, 并用于混合系统的状态监测和故障诊断问题, 本算法适用于具有状态突变的任意非线性非高斯系统, 仿真结果表明

了算法的有效性.

2 问题描述(Problem fomulation)

具有模型切换的混合系统定义为

$$\begin{cases} x_t = f(x_{t-1}, r_t, \omega_t), \\ y_t = h(x_t, r_t, v_t). \end{cases} \quad (1)$$

其中 $x_t \in \mathbb{R}^n$ 为未知的连续值基本状态, r_t 为未知的离散值模型状态, $y_t \in \mathbb{R}^m$ 为系统量测. 设过程噪声 ω_t 和量测噪声 v_t 为相互独立的白噪声序列. 设初始状态 $x_0 \sim P(x_0)$, x_0, ω_t, v_t 相互独立. 模型 r_t 为离散时间、齐次、有限状态的一阶 Markov 链, 状态空间为 $S = \{1, 2, \dots, s\}$, 初始概率分布为 $u_i = p\{r_0 = i\}$, $i \in S$, 转移概率为 $\pi_{ij} = p\{r_{t+1} = j | r_t = i\}$, $i, j \in S$, 转移概率矩阵为 $\Pi = [\pi_1 \ \pi_2 \ \dots \ \pi_s]^T$, $\pi_i = [\pi_{i1} \ \dots \ \pi_{is}]^T$, 且 $\sum_{j=1}^s \pi_{ij} = 1$. 设

$$x_{0:t} = [x_0 \ \dots \ x_t], r_{0:t} = [r_0 \ \dots \ r_t], \\ y_{1:t} = [y_1 \ \dots \ y_t].$$

当模型转移概率矩阵 Π 未知时, 设转移概率 π_i 为未知的随机变量, 由于 $\sum_{j=1}^s \pi_{ij} = 1$, 可以用 Dirichlet 分布描述转移概率 π_i 的分布

$$\pi_i = [\pi_{i1} \ \dots \ \pi_{is}]^T \sim D(\alpha_{i1}, \alpha_{i2}, \dots, \alpha_{is}) = \frac{\Gamma(\sum_{j=1}^s \alpha_{ij})}{\Gamma(\alpha_{i1})\Gamma(\alpha_{i2})\dots\Gamma(\alpha_{is})} \prod_{j=1}^s \pi_{ij}^{\alpha_{ij}-1}. \quad (2)$$

其中 $\Gamma(\cdot)$ 为 Gamma 函数, 并设 π_1, \dots, π_s 相互独立. Dirichlet 分布的参数 $\alpha_i = (\alpha_{i1}, \dots, \alpha_{is})$ 的物理意义表示由模型 i 转移到其他各个模型的先验观测频率. 如果没有 Π 的先验信息, 可以取所有参数 $\alpha_{ij} = 1$, 相当于 $\pi_i = (\pi_{i1}, \dots, \pi_{is})$ 平均取值, $\pi_{ij} = 1/s$.

3 转移概率自适应的 Monte Carlo 混合状态估计(Hybrid state estimation using Monte Carlo method with transition probability adaptation)

近几年发展起来的 Monte Carlo 粒子滤波方法主要包括序贯重要性采样和重采样^[4,5], 首先从某个重要性分布 $q(x_{0:t}, r_{0:t} | y_{1:t})$ 中抽取样本 $\{\tilde{x}_i^{(k)}, \tilde{r}_i^{(k)}\}_{k=1}^N$, 并对每个样本赋重要性权 $\omega_i^{(k)} = \frac{p(x_{0:t}, r_{0:t} | y_{1:t})}{q(x_{0:t}, r_{0:t} | y_{1:t})}$, 然后用重要性权 $\omega_i^{(k)}$ 从样本集 $\{\tilde{x}_i^{(k)}, \tilde{r}_i^{(k)}\}_{k=1}^N$ 中重新选择 N 个粒子 $\{x_i^{(k)}, r_i^{(k)}\}_{k=1}^N$. 状态的后验概率分布 $p(x_t, r_t | y_{1:t})$ 逼近为

$$\hat{p}_N(x_t, r_t | y_{1:t}) = \sum_{i=1}^N \omega_i^{(i)} \delta_{x_i^{(i)}, r_i^{(i)}}(x_t, r_t). \quad (3)$$

最常用的重要性分布是转移先验分布 $p(x_t, r_t | x_{t-1}, r_{t-1}) = p(x_t | x_{t-1}, r_t)p(r_t | r_{t-1})$, 采样 $r_t^{(k)} \sim p(r_t | r_{t-1}^{(k)})$, $x_t^{(k)} \sim p(x_t | x_{t-1}^{(k)}, r_t^{(k)})$, 重要性权为量测似然度 $\omega_i^{(k)} \propto \omega_{i-1}^{(k)} p(y_t | x_i^{(k)}, r_t^{(k)})$. 状态的各种估计值可以从后验概率分布(PDF) $p(x_{0:t}, r_{0:t} | y_{1:t})$ 中得到.

当 Π 已知时, 由 Bayes 公式

$$p(x_{0:t}, r_{0:t} | y_{1:t}, \Pi) = p(x_{0:t-1}, r_{0:t-1} | y_{1:t-1}) \cdot \frac{p(y_t | x_t, r_t)p(r_t | r_{t-1}, \Pi)p(x_t | x_{t-1}, r_t)}{p(y_t | y_{t-1})}. \quad (4)$$

采用粒子滤波方法在 t 时刻采样 $r_t^{(i)} \sim p(r_t | r_{t-1} = r_{t-1}^{(i)}) = \pi_{r_{t-1}^{(i)} r_t}^{(i)}$, $x_t^{(i)} \sim p(x_t | x_{t-1}^{(i)}, r_t^{(i)})$, 并赋权值 $\omega_i^{(i)} \propto p(y_t | x_t^{(i)}, r_t^{(i)})$, 得到一组带权的随机样本 $\{x_t^{(i)}, r_t^{(i)}, \omega_i^{(i)}\}$ 逼近状态的后验概率分布, 当每个模型子系统是线性高斯时, 通过 Rao-Blackwell 方法还可以进一步改进估计精度^[6,7].

引理^[10] 设 Markov 链的转移概率 π_1, \dots, π_s 为随机变量, 满足 $p(\pi_1, \pi_2, \dots, \pi_s) = \prod_{i=1}^s p(\pi_i)$, 并且 π_i 的先验分布为 Dirichlet 分布, 即 $\pi_i \sim D(\alpha_{i1}, \alpha_{i2}, \dots, \alpha_{is})$, 则转移概率矩阵可表示为

$$p(r_t = j | r_{0:t-2}, r_{t-1} = i) = \frac{n_{ij}(r_{0:t-1}) + \alpha_{ij}}{\sum_{l=1}^s (n_{il}(r_{0:t-1}) + \alpha_{il})}, \quad (i, j = 1, 2, \dots, s), \quad (5)$$

其中 $n_{ij}(r_{0:t-1}) = \sum_{k=1}^{t-1} \delta(r_{k-1}, i)\delta(r_k, j)$, $\delta(r_k, j) = \begin{cases} 1, & r_k = j, \\ 0, & \text{否则.} \end{cases}$ $n_{ij}(r_{0:t-1})$ 表示序列 $r_{0:t-1}$ 中从状态 i 转移到 j 的次数, 可以迭代计算

$$n_{ij}(r_{0:t-1}) = n_{ij}(r_{0:t-2}) + \delta(r_{t-2}, i)\delta(r_{t-1}, j). \quad (6)$$

注 公式(5)表明模型的转移概率可以从过去模型序列的转移次数以及先验观测频率估计, 利用(5)式计算转移概率需要知道模型序列, 而实际中模型状态未知, 是待估计的.

根据 Bayes 公式,

$$p(x_{0:t}, r_{0:t} | y_{1:t}) \propto p(x_{0:t}, r_{0:t}, y_t | y_{1:t-1}) = p(x_{0:t-1}, r_{0:t-1} | y_{1:t-1})p(x_t, r_t | x_{0:t-1}, r_{0:t-1}, y_{1:t-1})p(y_t | x_{0:t}, r_{0:t}, y_{1:t-1}) = p(x_{0:t-1}, r_{0:t-1} | y_{1:t-1})p(r_t | r_{0:t-1})$$

$$p(x_t | x_{t-1}, r_t) p(y_t | x_t, r_t). \quad (7)$$

当 Π 未知时,不能直接从 $p(r_t | r_{t-1}^{(i)})$ 采样,本文使用粒子滤波器对模型的转移概率进行在线迭代估计,利用在采样过程中得到的一组模型序列样本 $r_{0:t-1}^{(i)}$, 代入式 (5) 对转移概率矩阵 $p(r_t | r_{0:t-2}^{(i)}, r_{t-1})$ 进行估计,由于量测 y_t 的似然度代表着传感器对系统状态和模型的响应,经过量测更新/选择后得到转移概率矩阵的后验估计值 $\hat{p}(r_t | r_{t-1})$,再从估计值中采样 $r_t^{(i)} \sim \hat{p}(r_t | r_{t-1} = r_{t-1}^{(i)})$ 得到后继模型。

混合系统状态估计的自适应粒子滤波算法步骤如下:

1) 初始化.

对 $k = 1, 2, \dots, N$, 采样 $r_0^{(k)} \sim p(r_0)$, $x_0^{(k)} \sim p(x_0)$, 令 $\omega_0^{(k)} = 1/N$.

初始转移次数: $n_{ij}(r_0^{(k)}) = 0 (i, j = 1, 2, \dots, s)$.

转移概率矩阵初始估计值: $\hat{p}(r_1 = j | r_0 = i) =$

$$\alpha_{ij} / \sum_{l=1}^s \alpha_{il}, (i, j = 1, 2, \dots, s), t = 1.$$

2) 预测.

对 $k = 1, 2, \dots, N$, 从转移概率矩阵估计值中对应后继模型采样 $\tilde{r}_t^{(k)} \sim \hat{p}(r_t | r_{t-1} = r_{t-1}^{(k)})$, 连续值状态采样 $\tilde{x}_t^{(k)} \sim p(x_t | x_{t-1}^{(k)}, \tilde{r}_t^{(k)})$.

计算每个样本对应的转移次数: $n_{ij}(\tilde{r}_{0:t}^{(k)}) = n_{ij}(r_{0:t-1}^{(k)}) + \delta(r_{t-1}^{(k)}, i) \delta(\tilde{r}_t^{(k)}, j), (i, j = 1, 2, \dots, s)$.

计算每个样本对应的转移概率矩阵: $p(r_{t+1} =$

$$j | r_{0:t-1}^{(k)}, r_t = i) = \frac{n_{ij}(\tilde{r}_{0:t}^{(k)}) + \alpha_{ij}}{\sum_{l=1}^s (n_{il}(\tilde{r}_{0:t}^{(k)}) + \alpha_{il})}, (i, j = 1, 2, \dots, s).$$

3) 量测更新(重采样/选择).

利用量测 y_t 计算重要性权 $\tilde{\omega}_t^{(k)} = \omega_{k-1}^{(k)} p(y_t | \tilde{x}_t^{(k)}, \tilde{r}_t^{(k)})$, 归一化得 $\omega_t^{(k)} = \tilde{\omega}_t^{(k)} / \sum_{k=1}^N \tilde{\omega}_t^{(k)}$. 用 $\omega_t^{(k)}$ 从粒子集 $(\tilde{x}_t^{(k)}, \tilde{r}_t^{(k)})$ 以及相应的 $n_{ij}(\tilde{r}_{0:t}^{(k)})$ 和 $p(r_{t+1} = j | r_{0:t-1}^{(k)}, r_t = i)$ 中重新采样得到 N 个粒子 $(x_t^{(k)}, r_t^{(k)})$ 及相应的 $n_{ij}(r_{0:t}^{(k)})$ 和 $p(r_{t+1} = j | r_{0:t-1}^{(k)}, r_t = i)$, 并重新赋权值 $\omega_t^{(k)} = 1/N$.

4) 输出.

基本状态 x_t 的最小均方误差估计: $\hat{x}_t =$

$$\sum_{k=1}^N \omega_t^{(k)} x_t^{(k)};$$

模型状态 r_t 的后验概率估计: $\hat{p}_j = p(r_t = j | y_{1:t}) = \frac{1}{N} | r_t^{(k)} = j, k = 1, \dots, N |, (j = 1, \dots, s)$;

模型转移概率矩阵的后验估计值: $\hat{p}(r_{t+1} = j | r_t = i) = \sum_{k=1}^N \omega_t^{(k)} p(r_{t+1} = j | r_{0:t-1}^{(k)}, r_t = i), (i, j = 1, 2, \dots, s)$, 令 $t = t + 1$, 返回 2)。

其中 $|\cdot|$ 代表集合的势(即元素个数). 算法的实现如下: 采样 $\tilde{x}_t^{(k)} \sim p(x_t | x_{t-1}^{(k)}, \tilde{r}_t^{(k)})$ 可以通过从过程噪声分布 $p(\omega_t)$ 中采样 $\omega_t^{(k)}$, 令样本 $\tilde{x}_t^{(k)} = f(x_{t-1}^{(k)}, \tilde{r}_t^{(k)}, \omega_t^{(k)})$. 采样 $\tilde{r}_t^{(k)} \sim p(r_t | r_{t-1} = r_{t-1}^{(k)})$ 可以这样实现, 首先从 $[0, 1]$ 上的均匀分布采样 u , 则 $\tilde{r}_t^{(k)} = m, m$ 满足: $\sum_{j=0}^{m-1} \pi_{ij} < u \leq \sum_{j=0}^m \pi_{ij}$, 其中 $i = r_{t-1}^{(k)}, \pi_{ij}$ 为转移概率($\pi_{i0} = 0$). 由粒子滤波器的收敛性结论^[11], 当粒子个数趋于无穷大时, 状态的最小均方误差估计收敛于真实状态的后验均值。

4 混合系统的故障监测和诊断(Failure monitoring and diagnosis of hybrid system)

故障检测和诊断(FDD)对系统的可靠性, 安全性是非常重要的. 通常的故障检测方法依赖于系统是线性高斯模型, 由滤波残差判断故障的发生^[12]. 具有多模型切换的混合系统能够很好地描述经历多种故障的系统, 其中每个模型代表系统的一个故障模式, 而被用于 FDD^[7, 12, 13], 由于 IMM 算法对强非线性非高斯问题, 估计效果很差甚至发散, 而 Monte Carlo 粒子滤波器通过一组样本得到状态的完全后验概率分布, 能对付任意非线性非高斯问题, 并且能同时对状态和模型进行估计, 监测和诊断。

设被监测的系统的正常模式和所有可能的故障模式能描述为一个齐次、有限状态的一阶 Markov 链, 由于故障发生的概率及各种模式之间的转移概率与其出现的次数有关, 以上估计转移概率的算法适合于故障的监测和诊断, 模型后验概率暗示了系统所处的模式, 利用模型后验概率提供的信息, 可以进行故障检测和诊断, 故障决策为^[13]:

设 $\hat{p}_j = \max_i p(r_t = i | y_{1:t})$, 如果 $\hat{p}_j > \epsilon$, 则认为故障 j 发生, 否则认为系统正常, 其中 ϵ 为阈值。

考虑如下具有参数突变的非线性动态系统, 状态空间方程为

$$\begin{pmatrix} x_1(t+1) \\ x_2(t+1) \end{pmatrix} = \begin{pmatrix} \frac{x_1(t)}{1+x_2^2(t)} \\ x_1(t) + \cos(x_2(t)) \end{pmatrix} + \begin{bmatrix} 50 \\ 10 \end{bmatrix} [a(t+1) + \omega(t)],$$

$$y(t) = \sqrt{e^{x_2(t)}} + v(t).$$

其中 $\omega(t) \sim N[0, 2^2], v(t) \sim N[0, 10^2]$ 为零均值高斯白噪声, 初始状态, $x_1(0) \sim N[80000, 100^2], x_2(0) \sim N[400, 100^2]$, 参数序列 $a(t)$ 为 Markov 链, 具有 3 个切换状态, $a_1 = 0$ 对应于正常模式 1, $a_2 = 20, a_3 = -20$ 分别对应两个故障模式 2 和 3, Markov 链的初始概率为 $u_1 = 0.8, u_2 = 0.1, u_3 = 0.1$, 转移概率矩阵 (TPM) 未知.

设实际系统的一个故障模型序列为在 $t = 1$ 到 $t = 10$ 之间处于正常模式, 在 $t = 11$ 到 $t = 20$ 处于故障模式 2, 在 $t = 21$ 到 $t = 30$ 处于故障模式 3, 在 $t = 31$ 到 $t = 40$ 处于正常模式, 在 $t = 41$ 到 $t = 50$ 处于故障模式 3. 在仿真中, 使用 $N = 3000$ 个粒子, 重复进行 50 次 Monte Carlo 仿真实验, 由于没有模型转移概率先验信息, 假设转移概率先验分布均匀取值 $\pi_{ij} = 1/3, (i, j = 1, 2, 3)$. 为了说明本文算法能改善状态估计和故障诊断的性能, 对两种粒子滤波算法做对比仿真, 算法 1 使用本文提出的自适应粒子估计算法, 对转移概率在线迭代估计和修正, 算法 2 采样已有的粒子方法, 转移概率是固定的 $\pi_{ij} = 1/3, (i, j = 1, 2, 3)$, 从均匀转移概率分布中对模型采样. 图 1 和图 2 分别给出算法 1 和算法 2 对模型后验概率的估计, 从模型后验概率可以进行故障的检测和诊断, 算法 1 正确检测出了故障, 算法 2 出现了误判. 图 3 给出算法 1 和算法 2 对状态 $x_1(t)$ 估计的平均绝对误差, 图 4 给出两种算法对状态 $x_2(t)$ 估计的平均绝对误差, 从中可以看出算法 1 对状态估计的性能明显优于算法 2. 图 5 给出了算法 1 对模型转移概率矩阵的后验估计值. 从仿真中可以看出, 对先验分布相同的模型转移概率, 由于算法 1 含有转移概率的在线估计修正, 转移概率逐渐接近真实分布, 从而采样所得的模型粒子的个数分布更加合理, 对故障的检测更准确, 对状态的估计精度更高, 而且从图 5 可以看出转移概率的估计值具有较快的收敛性.

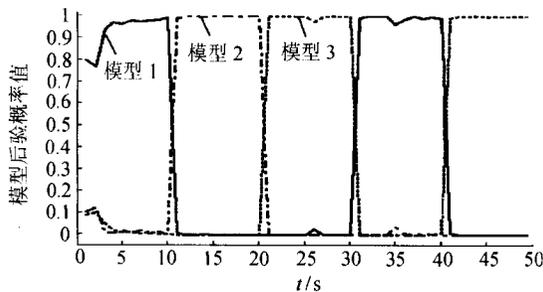


图 1 算法 1 模型后验概率估计

Fig. 1 Model posterior probability estimation of algorithm 1

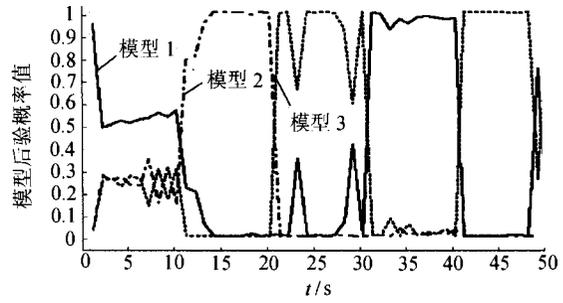


图 2 算法 2 模型后验概率估计

Fig. 2 Model posterior probability estimation of algorithm 2

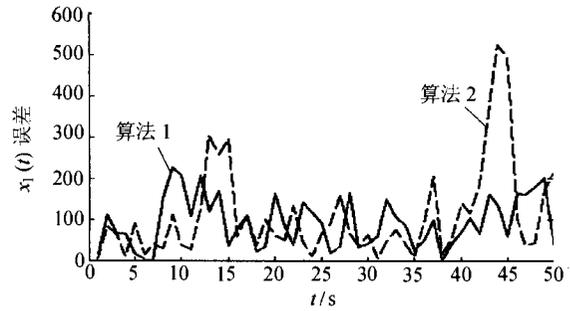


图 3 状态的平均绝对估计误差

Fig. 3 Mean absolute estimation error of state

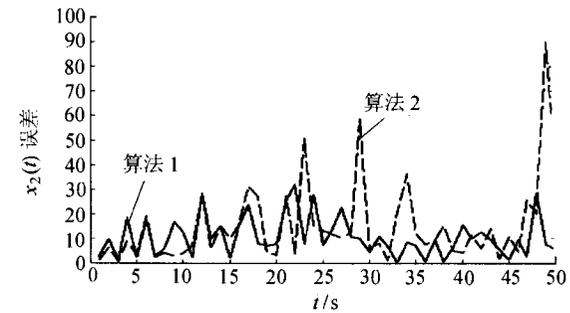


图 4 状态的平均绝对估计误差

Fig. 4 Mean absolute estimation error of state

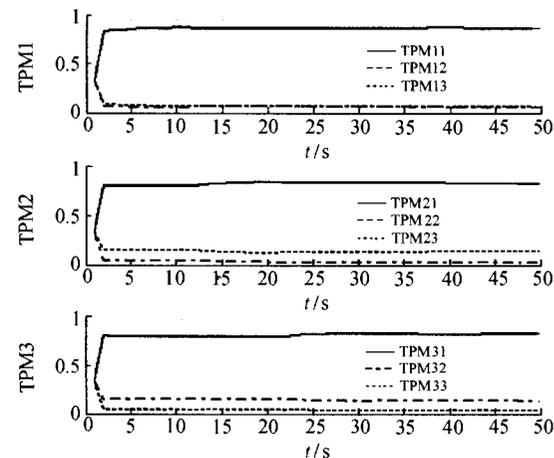


图 5 转移概率后验估计值

Fig. 5 Posterior estimation of transition probability

由于粒子算法的随机性,对如下的整体性能指标(均方根误差),比较两种算法的性能

$$\text{RMS} = \sqrt{\frac{1}{MT} \sum_{m=1}^M \sum_{t=1}^T (\hat{x}(m, t) - x(t))^2}$$

其中 $M = 50$ 为仿真次数, $T = 50$ 为仿真拍数, $\hat{x}(m, t)$ 为第 m 次仿真中 t 时刻状态的最小均方误差估计, $x(t)$ 为 t 时刻真实状态,表 1 给出了两种算法的性能比较。

表 1 算法 1 和算法 2 的性能比较

Table 1 Performance comparison of two algorithms

	算法 1	算法 2
x_1 的 RMS	115.3172	184.5566
x_2 的 RMS	19.6196	28.6113

5 结论(Conclusion)

本文对转移概率矩阵未知时的多模型混合系统的状态估计和诊断问题,提出一种基于 Monte Carlo 粒子滤波方法的自适应估计算法,通过一组粒子对转移概率、系统状态和模型同时进行估计,由于 Monte Carlo 方法对系统模型和噪声不做任何限制,该方法适用于在连续变化的同时具有突然跳变的任意混合系统,不需要已知模型转移概率,并且讨论了该方法在故障监测和诊断中的应用,仿真结果表明了该算法的有效性。

参考文献(References):

- [1] BAR-SHALOM Y, LI X R. *Estimation and Tracking: Principles, Techniques and Software* [M]. Boston: Artech House, 1993.
- [2] BLOM H A P, BAR-SHALOM Y. The interacting multiple model algorithm for systems with Markovian switching coefficients [J]. *IEEE Trans on Automatic Control*, 1988, 33(8): 103 - 123.
- [3] 梁彦,贾宇刚,潘泉,等.具有参数自适应的交互式多模型算法[J].控制理论与应用,2001,18(5):653 - 656.
(LIANG Yan, JIA Yugang, PAN Quan, et al. Parameter identification in switching multiple model estimation and adaptive interacting multiple model estimator [J]. *Control Theory & Applications*, 2001, 18(5): 653 - 656.)

- [4] GORDON N J, SALMOND D J, SMITH A F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation [J]. *IEE Proc Radar and Signal Processing*, 1993, 140(2): 107 - 113.
- [5] 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.
- [6] DOUCET A, GORDON N J, KRISHNAMURTHY V. Particle filter for state estimation of Markov linear systems [J]. *IEEE Trans on Signal Processing*, 2001, 49(3): 613 - 624.
- [7] MO Yiwei, XIAO Deyun. Hybrid system monitoring and diagnosing based on particle filter algorithm [J]. *Acta Automatica Sinica*, 2003, 29(5): 641 - 648.
- [8] TUGNAIT J K. Adaptive estimation and identification for discrete systems with Markov jump parameters [J]. *IEEE Trans on Automatic Control*, 1982, 27(5): 1054 - 1065.
- [9] JILKOV V P, LI X R. Adaptation of transition probability matrix for multiple model estimators [C]// *Proc of 4th Int Conf on Information Fusion*. Montreal, Canada: ISIF Press, 2001, 2: 1 - 3.
- [10] DOUCET A, RISTIC B. Recursive state estimation for multiple switching models with unknown transition probabilities [J]. *IEEE Trans on Aerospace and Electronic Systems*, 2002, 38(3): 1098 - 1104.
- [11] CRISAN D, DOUCET A. A survey of convergence results on particle filtering methods for practitioners [J]. *IEEE Trans on Signal Processing*, 2002, 50(3): 736 - 746.
- [12] WILLSKY A S. A survey of design methods for failure detection in dynamic systems [J]. *Automatica*, 1976, 12(1): 601 - 611.
- [13] ZHANG Y M, LI X R. Detection and diagnosis of sensor and actuator failures using IMM estimator [J]. *IEEE Trans on Aerospace and Electronic Systems*, 1998, 34(4): 1293 - 1312.

作者简介:

杨小军 (1971—),男,讲师,博士研究生,分别在四川大学和西安电子科技大学获学士和硕士学位,目前研究方向为随机最优估计与控制,自适应滤波,信息融合,传感器网络, E-mail: yang_xj@sohu.com;

潘泉 (1961—),男,教授,博士生导师,国际信息融合协会(ISIF)会员,陕西省自动化学会副理事长,主要研究领域为随机最优估计与控制,多目标识别与跟踪,信息融合,图像处理,生物信息学等;

张洪才 (1938—)男,教授,博士生导师,主要研究方向为多目标跟踪,系统辨识,随机控制等。