

文章编号: 1001-0920(2012)09-1331-06

基于自学习采样粒子滤波器的不完备故障空间交互诊断方法

余伶俐, 唐小林, 唐 璠

(中南大学 信息科学与工程学院, 长沙 410083)

摘要: 针对不完备空间混合系统, 提出一种基于自学习采样粒子滤波器(SLSPF)的交互诊断方法. 融入自学习采样机制, 利用自学习即时概率指导采样, 以摆脱粒子滤波器对转移概率的依赖; 结合自学习采样与诊断的动态交互方式调整模式空间, 使粒子滤波器采样粒子数动态减少; 同时给出了不完备信息空间的真实模式与未知模式阈值的决策条件. 实验结果表明, 尤其在多维状态空间下, SLSPF不仅可以保证粒子滤波器的诊断精度, 而且能够提高计算效率.

关键词: 故障诊断; 自学习采样; 粒子滤波器; 不完备空间

中图分类号: TP24

文献标志码: A

Interactive diagnosis in incomplete fault space based on self-learning sample particle filter

YU Ling-li, TANG Xiao-lin, TANG Jin

(School of Information Science and Technology, Central South University, Changsha 410083, China. Correspondent: TANG Xiao-lin, E-mail: xiaolin5789@126.com)

Abstract: To solve the problem of hybrid system fault diagnosis in incomplete space, a dynamical fault diagnosis method based on self-learning sample particle filter(SLSPF) is presented. With the mechanism of self-learning sampling and real-time distribution probability directed sampling, SLSPF can break out of the dependence on transition probability. The combination of self-learning sampling and dynamic interactive diagnosis mode makes the sampling number of the filter tend to decrease dynamically and adjusts the mode space. The threshold value decision-making condition of real mode and unknown mode in the incomplete information space is given. Experiment results show that even if in the higher-dimensional space, SLSPF can still guarantee the particle filter diagnose precision and computational efficiency.

Key words: fault diagnosis; self-learning sample; particle filter; incomplete space

1 引言

随着智能控制和机器人技术的不断发展, 人们对系统的可靠性和容错性的要求日益提高, 复杂混合系统的故障诊断技术越来越受重视. 所谓故障, 就是系统中发生了不希望的事件并导致系统模型变化. 混合系统同时包含离散故障模式和连续状态变量^[1], 不同故障模式与正常模式间的结构参数不同, 系统状态可以跳变也可以连续变化^[2], 具有非线性特性. 在不完备空间中, 除已知模式之外还有一部分信息未能建模, 即存在未知模式, 所以不完备空间故障系统可视为一种特殊的混合动态系统.

粒子滤波器是监视动态系统的Monte Carlo方法. 在非线性非高斯混合系统中, 基于粒子滤波的多

模型混合系统故障诊断得到了广泛研究^[3-4]. 目前, 国内外对基于粒子滤波器的故障诊断的研究已经取得一些成果^[5-7], 主要集中在如何提高滤波器诊断效果^[8]或滤波算法优化等方面^[9]; 而针对模型不完备故障诊断问题的相关研究并不多见^[10-11]. 文献[12]提出了一种无迹粒子滤波(UKF)算法, 利用测量值信息和UPF计算转移概率分布, 使状态估计的误差更小. 文献[13]通过引入风险权重值增加小概率故障状态权重, 利用风险敏感粒子滤波器解决低概率无粒子进入故障状态的问题. 这些研究均在改进粒子滤波器诊断性能方面做出了贡献.

近几年, 人们针对不完备系统的故障诊断提出了一种不完备模型粒子滤波算法(PFIM)^[10], 该算法依

收稿日期: 2011-03-30; 修回日期: 2011-07-07.

基金项目: 中国博士后科学基金项目(20110491272, 2010-2012); 中南大学博士后科研经费项目(2010-2012); 中央高校基本科研业务费专项资金项目(2012QNZT060).

作者简介: 余伶俐(1983-), 女, 讲师, 博士后, 从事智能机器人及智能车多传感器系统故障诊断的研究; 唐璠(1966-), 男, 教授, 博士生导师, 从事机器视觉、信息融合与容错控制等研究.

据粒子集的规格化因子及最大后验概率估计状态的信度,设计了未知故障模式的阈值逻辑.依赖先验转移概率密度函数对新观测值进行分析,需采集大量样本才能保证其估计的准确性;而故障诊断在系统可靠性和实时性方面的研究也至关重要^[14-15].为此,本文提出一种基于自学习采样粒子滤波器的不完备空间动态故障诊断方法.该方法通过结合自学习采样的方法,并采用采样与诊断交互进行的机制及不完备信息空间信度与概率边缘分布结合的决策条件来提高粒子滤波器的估计精度和效率,实现快速、准确地诊断.

2 故障诊断数学描述

故障诊断可归结为,随着时间的变化估计系统的不同离散状态(也可视为多模型混合系统状态估计问题),故障状态和运行模式同时作为系统状态出现.设给定系统模型在已知观测序列 $y_{1:t} = \{y_1, y_2, \dots, y_t\}$, 连续控制输入序列 $u_{1:t} = \{u_1, u_2, \dots, u_t\}$ 和连续状态序列 $x_{0:t-1} = \{x_1, x_2, \dots, x_t\}$ 的情况下,对 s_t 进行估计,则多模型混合故障系统可描述为

$$\begin{cases} \dot{x}_t = f(x_{t-1}, u_t, d_t) + w_t, \\ y_t = h(x_t, u_t, d_t) + v_t. \end{cases} \quad (1)$$

其中: $d_t \in D$ 为 t 时刻系统的离散(故障)模式,为离散时间、齐次、有限状态的一阶 Markov 链; D 为系统离散(故障)模式的集合; x_t 为 t 时刻系统的连续状态变量; y_t 为测量值; u_t 为连续的控制输入; w_t 为独立于时间的零均值系统噪声; v_t 为独立于系统和时间的观测噪声; $s_t = (d_t, x_t)$ 为系统的混合状态变量.

3 自学习采样粒子滤波器(SLSPF)算法

粒子滤波算法的计算复杂度一直是困扰其发展的重要因素之一,其中重要性采样对其计算效率的影响不可忽视;而采样部分的计算复杂性主要由采样方式和采样粒子数等因素决定.为了提高粒子滤波器的计算效率,在保证系统维持一定精度的前提下应尽可能减少粒子个数.为此,提出一种综合考虑采样方式和样本个数的自学习采样,以改善粒子滤波器的诊断性能.

3.1 自学习采样

粒子滤波器以转移先验概率密度函数 $p(d_t|d_{t-1})$ 作为重要性分布对各种模式进行混合采样.为了确保转移概率低的模式在一定程度上也被采样,需设计大量样本集.对于无法获得准确转移先验概率密度的模型,粒子滤波器会进行盲目采样,为此提出一种自学习采样的粒子滤波技术.利用经过学习后得到的即时概率分布作为采样信息指导采样,以摆脱对转移概率密度函数的依赖性.所谓即时概率分布,是指在

每次采样之前对每种模式提取样本,并计算各样本与真实模式之间的相似度,利用相似度决定即时概率分布.以上过程实质上是利用 $p(d_t|d_{t-1}, y_t)$ 作为重要性分布,使之更趋近于真实概率分布

$$p(x_t|y_1, \dots, t) = \sum_{i=1}^N \tilde{w}_t^i \delta(x_t - x_t^i), \quad (2)$$

$$p(d_t|y_1, \dots, t) = \sum_{i=1}^N \tilde{w}_t^i \delta(d_t - d_t^i). \quad (3)$$

通过式(2)和(3)计算后验概率密度的边缘分布 $p(x_t|y_1, \dots, t)$ 和 $p(d_t|y_1, \dots, t)$, 可以估计出系统的真实模式.

自学习采样不仅在采样指导信息方面有所改进,而且采样方式与一般粒子滤波器也不同.在获得即时概率分布之后,自学习采样按每种模式的即时概率大小对各种模式先后连续采样.每种模式采样粒子数相等,从而杜绝了小概率模式采样受限的情况,对提高诊断准确度具有重要意义;样本更加整齐有序,在计算后验概率边缘分布时分段计算,无需对每一模式的粒子逐一检索,减少了一定的计算量.

3.2 自学习采样与诊断机制动态交互优化粒子数

对于诊断为随机时变系统的离散故障状态估计问题,故障状态和运行模式作为系统的混合状态同时出现.若能优先检测出真实模式,则可以免去对其他模式的采样分析,此时采样总粒子数会呈现一种动态缩减状态,并保证了诊断效率.为此,本文根据有效的即时概率学习信息,提出了自学习采样和诊断动态交互的故障诊断,形成一种形如二叉树的粒子滤波器故障诊断,其结构简图如图1所示.

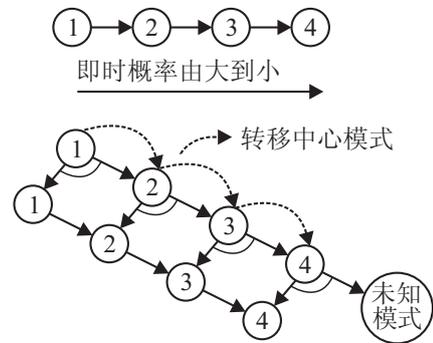


图1 二叉树采样简图

假设有4种故障模式,根据 t 时刻即时概率对各种模式进行降序排列,将即时概率最大的模式确定为中心模式(根模式),再对中心模式及其右支模式采样,右支模式的即时概率仅次于中心模式.若采样后诊断为不是中心模式,则将中心模式转移至其右支上,继续寻找真实的故障模式.整个交互机制的动态流程如图2所示.

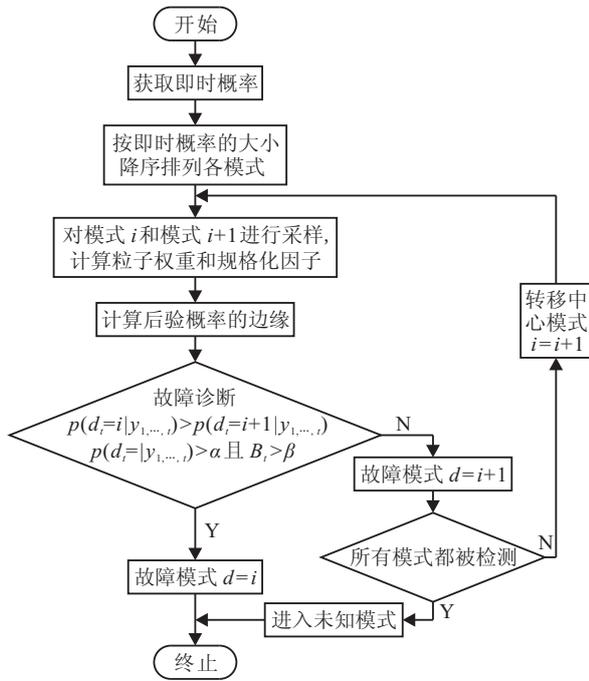


图2 采样与诊断交互的流程图

4 基于边缘分布与信度的故障决策条件及其数学依据

定义 1 信息空间包含已建模式和未建模式两种模式. 其中不完备故障空间泛指故障空间中有部分故障信息模式尚未建模, 且不完备故障空间中未建模式具有与已知模式明显不同的行为.

定义 2 已知故障空间. 是指所有已建模故障模式, 又称已知故障模式集合, 包含正常模式.

定义 3 未知故障模式. 泛指与已知故障模式具有不同动态行为的故障模式, 未知故障模型空间是所有未知故障模式的集合, 由其确定的系统动态模型是未知的.

未知故障模式具有与已知故障模式明显不同的行为, 这是未知模式唯一可用信息. 当系统进入未知故障模式时, 采样粒子不能表征这种模式下的状态, 将导致粒子权重变得非常小.

本文将不完备故障空间设计为自调整模式空间. 自调整故障空间仅将粒子滤波器已采样故障模式设置在已知故障空间, 其他故障模式与未知故障模式设置在未知故障空间. 利用信度与边缘分布的决策条件, 在已知故障空间中寻找真实故障模式. 若存在某一故障模式符合决策条件, 则确定该模式为真实模式; 否则, 扩展已知故障空间, 在新已知故障空间中寻找真实模式. 若所检测的模式均不满足决策条件, 则该模式为未知故障模式.

如果当前检测模式的后验概率边缘分布 $p(d_t|y_{1,...,t})$ 小于阈值 α , 则判断当前系统的真实模式为未知故障模式. 判定条件如下:

$$\alpha = \frac{N}{(2\pi)^{d/2}|\Sigma|^{1/2}} \exp\left(-\frac{1}{2}\text{dis}^2\right). \quad (4)$$

在进行模式匹配时, 确定期望值与测量值之间的马氏距离上限 dis 至关重要. 设已知 x 的概率密度为 $p(x)$, 任意函数 $f(x)$ 的期望值可由下式计算得到:

$$E(f(x)) = \int p(x)f(x)dx. \quad (5)$$

假设可以产生服从分布 $p(x)$ 的 N 个独立同分布的随机样本 $x^i, i = 1, 2, \dots, N$, 则可由下式近似:

$$\int p(x)f(x)dx = \frac{1}{N} \sum_i f(x^i) = \bar{E}(f(x)), x^i \sim p(x). \quad (6)$$

根据大数定理, 当 N 足够大时, $\bar{E}(f(x))$ 绝对收敛于 $E(f(x))$. 即, 若方差

$$\sigma^2 = \int (f(x) - E(f(x)))^2 p(x)dx = \int f^2(x)p(x)dx - E^2(f(x)), \quad (7)$$

则式(6)有界. 由中心极限定理可得

$$\lim_{x \rightarrow \infty} (\bar{E}(f(x)) - E(f(x))) \sim N(0, \sigma^2/N), \quad (8)$$

其中 $N(0, \sigma^2/N)$ 为均值为 0, 方差为 σ^2/N 的正态分布. 同样, 由中心极限定理可知

$$|\bar{E}(f(x)) - E(f(x))| \leq \varepsilon = \frac{\lambda\alpha\sigma}{\sqrt{N}}. \quad (9)$$

不等式(9)以概率 α 成立. 由 3σ 准则可知, 当取 $\varepsilon = (3\sigma)/\sqrt{N}$, 即 $\lambda_a = 3$ 时, $\alpha = 0.9974$, $f(x)$ 落在区间 $(\bar{E}(f(x)) - (3\sigma)/\sqrt{N}, \bar{E}(f(x)) + (3\sigma)/\sqrt{N})$ 内的概率几乎接近于 1. 综上所述, 可以令 d 为 $\varepsilon = 3\sigma$ 时对应的 Mahanobis 距离. 本文引入检测当前模式是否为真实模式的判断依据之一, 即信度 $^{[10]}B_t > \beta$. 确定模式决策条件为: 当 $p(d_t|y_{1,...,t}) > \alpha$ 且 $B_t > \beta$ 时, 判断当前检测模式为真实模式; 否则, 判断系统的真实模式在等效的未知空间内, 需进一步检测其他模式.

5 基于自学习采样粒子滤波器的不完备空间动态交互故障诊断算法步骤

Step 1: 初始化.

Step 1.1: $t = 0, i = 1 : N, N$ 为样本数, 计算初始 α ;

Step 1.2: 通过先验分布 $p(d_0)$, 采样离散模式 $d_0^i \sim p(d_0), i = 1 : N$;

Step 1.3: 通过先验分布 $p(x_0|d_0)$, 采样连续状态 $x_0^i \sim p(x_0|d_0), i = 1 : N$;

Step 1.4: 初始化权值 $w_0^i = 1/N$, 得到等加权粒子集 $\{d_0^i, x_0^i, 1/N\}_{i=1}^N, i = 1 : N$.

Step 2: 学习 t 时刻的即时概率分布.

Step 3: 状态预测.

Step 3.1: 基于 d_{t-1}^i 和 $p(d_t|y_t, x_t^d, d_t^i)$, 在未被检测的模式中取出对应 $p(d_t)$ 值最大的模式 d_0 和次大的模

式 d_1 , 分别作为中心模式和分支模式;

Step 3.2: 根据状态方程对模式 d_0 和模式 d_1 采样 $x_t^i \sim p(x_t|x_{t-1}, d)$, 生成粒子集 $\{d, x_t^i\}_{i=1}^N$.

Step 4: 权值更新.

计算每个样本的重要性权值

$$\tilde{w}_t^{[i]} = \tilde{w}_{t-1}^{[i]} p(d_t|y_t^{[i]}, x_t^{[i]}).$$

Step 5: 计算边缘概率分布、规格化权重

$$p(d_t|y_1, \dots, y_t) = \sum_{i=1}^N \tilde{w}_t^{[i]} \delta(d_t^i - d_t),$$

$$W_t = \sum_{i=1}^{2N} \tilde{w}_t^{[i]},$$

$$w_t^i = \frac{\tilde{w}_t^i}{W_t}.$$

Step 6: 故障检测.

如果 $p(d_t = m|y_1, \dots, y_t) > p(d_t = m'|y_1, \dots, y_t)$, 则 t 时刻系统处于离散状态 m , 其中 $m \neq m', mm' \in D$. 对于信度

$$B_t = \sum_{i=1}^N w_t^{[i]} \delta(d_t^{[i]} - d_t),$$

若 $p(d_t = m|y_1, \dots, y_t) > \alpha$ 且 $B_t > \beta$, 则判断当前检测的模式 m 为真实模式; 否则, 无法确认是否可判断为真实模式, 而且如果还有未被检测的模式, 则转移中心模式至其右支模式, 跳至 Step 3; 如果所有模式都被检测, 则判断进入了未知模式.

Step 7: 利用系统采样算法对所有粒子进行重采样, 重采样后粒子总数保持为 N .

Step 8: $t = t + 1$, 返回 Step 2.

SLPF 算法与普通粒子滤波器 GPF 算法相比, 在 Step 6 上有所不同, SLPF 运用边缘概率分布来估计真实模式, 并用它与规格化因子相结合作为诊断的决策条件, 构成一种动态循环, 使每次采样的粒子数动态地趋于最小.

6 实验分析

6.1 非线性故障诊断模型实验

文献 [11] 给出了典型强非线性增长模型描述, 其系统状态和量测方程分别为

$$\begin{cases} x_t = 0.5x_{t-1} + \frac{25x_{t-1}}{1+x_{t-1}^2} + 8 \cos(1.2t) + w_t, \\ y_t = \frac{x_t^2}{20} + v_t; \end{cases} \quad (10)$$

$$\begin{cases} x_t = 0.5x_{t-1} + \frac{25x_{t-1}}{1+x_{t-1}^2} + 8 \cos(1.2t) + 2 + w_t, \\ y_t = \frac{x_t^2}{20} + v_t; \end{cases} \quad (11)$$

$$\begin{cases} x_t = \frac{25x_{t-1}}{1+x_{t-1}^2} + 8 \cos(1.2t) + w_t, \\ y_t = \frac{x_t^2}{20} + v_t. \end{cases} \quad (12)$$

该模型共有 3 种模式. 其中: 式 (10) 为模式 1, 表示正常状态, 用 S1 表示; 式 (11) 为模式 2, 表示故障 1 状态, 用 S2 表示; 式 (12) 为模式 3, 表示故障 2 状态, 用 S3 表示; w_t 为过程噪声; v_t 为测量噪声.

因为强非线性增长模型并不是建立在某一具体对象上的模型, 所以没有先验知识的转移概率可供参考. SLPF 诊断方法具有一定的自学习能力, 对不具先验知识的模型具有较强的诊断效率和估计精度. 对非线性单变量故障模型设计诊断实验, 设过程噪声的均方差 $\sigma_{w_t} = 0.1$, 测量噪声的均方差 $\sigma_{v_t} = 0.1$. 在保证诊断准确度的前提下, 利用自学习采样和诊断动态交互机制优化粒子数, 实验中 SLPF 所采用的采样粒子数只有 20, 而 GPF 采样粒子数为 80, 诊断效果如图 3 所示.

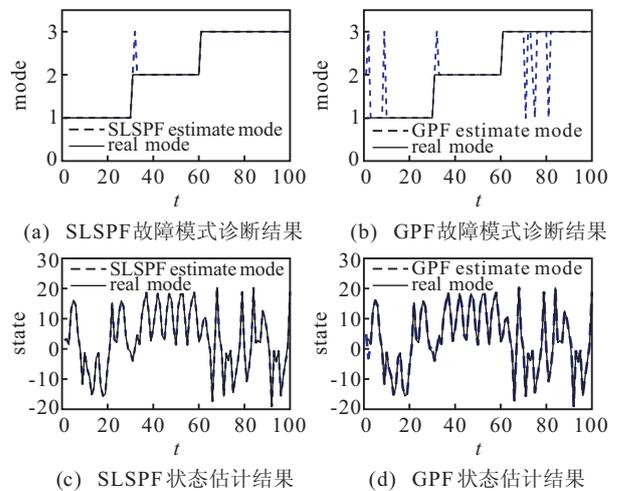


图 3 非线性故障诊断模型中 SLPF 与 GPF 算法效果对比

实验中 SLPF 所用粒子数明显少于 GPF, 但其诊断准确度并没有降低. 为了进一步验证 SLPF 算法的优越性, 对 SLPF 和 GPF 每一时刻状态估计的平均绝对误差进行了统计, 结果如图 4 所示. 由图 4 可以看出, SLPF 每一时刻平均绝对误差小于 2 的粒子超过 80%; 而 GPF 每一时刻平均绝对误差小于 2 的粒子不到 60%, 说明 SLPF 对状态的估计精度高于 GPF.

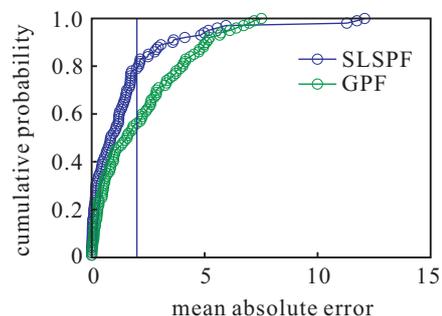


图 4 两种算法每一时刻状态估计的平均绝对误差统计对比

表1对10次独立实验运行时间进行了统计. 由表1的统计结果可以看出, SLSPF的诊断效率高于GPF.

表1 10次独立实验运行时间统计

算法	GPF	SLSPF
1	0.704	0.313
2	0.687	0.313
3	0.688	0.297
4	0.688	0.312
5	0.687	0.312
6	0.703	0.313
7	0.687	0.328
8	0.687	0.313
9	0.703	0.312
10	0.688	0.313
平均值/s	0.6922	0.3126

上述结果均明了SLSPF算法诊断的精确性和高效性.

6.2 航迹推算混合系统模型故障诊断实验

航机推算系统为机器人导航的重要传感器系统, 包括左前轮编码器、右前轮编码器、左后轮编码器、右后轮编码器及陀螺仪. 编码器分别测量左右驱动轮前后的角速度, 陀螺仪测量机器人偏航率. 其混合系统故障诊断建模及参数详见文献[9-10], 故障模式共有 $2^5 = 32$ 种. 图5为左右两侧驱动轮速度和陀螺仪实际测量数据, 其中mode纵坐标代表故障模式.

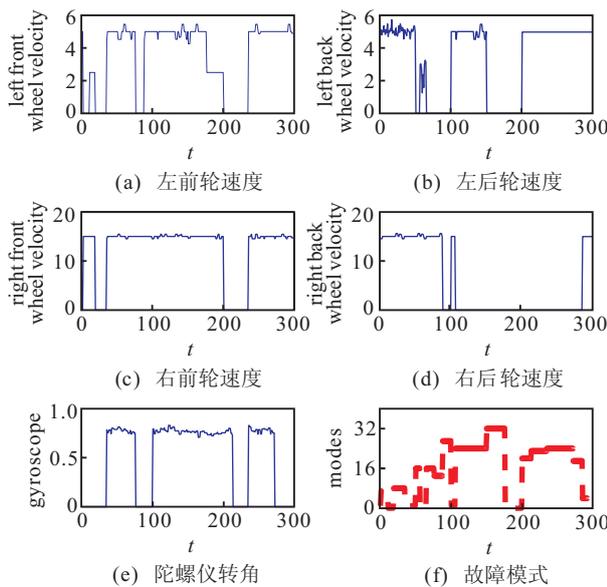


图5 航迹推算系统故障诊断实验数据

当系统检测出未知故障模式时, 用模式0表示(如图6的4个分图中, 纵坐标对应为0的状态), 以示区别于其他已建模故障模式(如图6中的4个分图中, 纵坐标 $i = 1, 2, \dots, 32$). 运用SLSPF算法时, 每次采样粒子数为10, 总粒子数动态调整, 得到图6(a)的诊断结果, SLSPF能有效准确地诊断出故障; 运用PFIM算法^[10]时, 取 $N = 130$ 得到的结果如图6(b)所示, 取 $N = 150$ 得到的结果如图6(c)所示, 两图均存在一定程度的误判. 为了保证准确度, 运用PFIM算法时, 取 $N = 180$ 得到的结果, 如图6(d)所示.

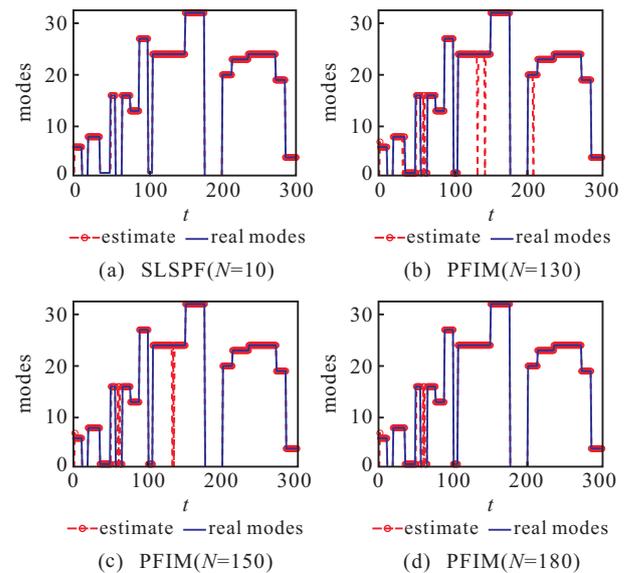


图6 两种算法诊断效果及粒子数对比

相对而言, SLSPF诊断的准确率较高. 对两种算法进行10次统计, 每次运行时两种算法的误诊断次数如表2所示, 同样可以得到SLSPF算法具有更高诊断准确率的结论. 在此基础上, 对两种算法的时间复杂度也进行了比较. 由表3可知, 当故障空间增大时, PFIM的时间复杂度比SLSPF的时间复杂度增加率大. 由表3可以看出, 在两种算法准确率一定的前提下, SLSPF算法明显比PFIM效率更高, 在处理复杂系统和高维状态空间时SLSPF算法更具有优势.

表2 两算法误诊断次数比较

算法	1	2	3	4	5	6	7	8	9	10	平均值/次数
SLSPF	1	3	3	2	1	1	0	1	0	2	1.4
PFIM	3	4	6	4	7	8	4	8	5	4	5.3

表3 32种模式下两算法运行时间比较

算法	PFIM	SLSPF
1	13.98	2.078
2	13.96	2.078
3	13.96	2.078
4	13.96	2.078
5	14.14	2.014
6	14.09	2.093
7	14.01	2.078
8	14.01	2.078
9	14.04	2.078
10	14.03	2.078
平均值/s	14.02	2.073

7 结论

SLSPF将完备系统和不完备系统统一对待, 使未知故障和各种已知故障具有基于边缘分布和信度的决策判定条件, 从而使粒子滤波器不仅能够诊断出

已知故障,而且在遇到未知故障时滤波器中的粒子不会发散,能有效地检测出不完备空间中的各类故障.因此,SLSPF既可以保证诊断效果又能够提高诊断效率,尤其在高维状态空间下依然能保证粒子滤波器的诊断效率.但是,若各模式之间的差异不明显,则自学习采样粒子滤波器对不完备空间故障诊断有时也可能会出现误诊,这一点需进一步深入研究.

参考文献(References)

- [1] 段琢华,蔡自兴,于金霞.未知环境中移动机器人故障诊断与容错控制技术综述[J].机器人,2005,27(4):373-379.
(Duan Z H, Cai Z X, Yu J X. Fault diagnosis and fault tolerant control of mobile robots in unknown environments: A survey[J]. Robot, 2005, 27(4): 373-379.)
- [2] 萧德云,莫以为.基于混合系统状态估计的故障诊断[J].自动化学报,2004,30(6):980-985.
(Xiao D Y, Mo Y W. Fault diagnosis based on hybrid state estimation[J]. Acta Automatica Sinica, 2004, 30(6): 980-985.)
- [3] Liu Y T, Jiang J P. Fault diagnosis and prediction of hybrid system based on particle filter algorithm[C]. Proc of IEEE Int Conf on Automation and logistics. Qingdao, 2008: 1491-1495.
- [4] Michael W Hofbauer, Johannes Kob, Gerald Steinbauer, et al. Improving robustness of mobile robots using model based reasoning[J]. J of Intelligent and Robotic Systems, 2007, 48(1): 37-54.
- [5] Ping L, Kadirkamanathan V. Particle filtering based likelihood ratio approach to fault diagnosis in nonlinear stochastic systems[J]. IEEE Trans on Systems, Man, and Cybernetics, Part C: Applications and Reviews, 2001, 31(3):337-343.
- [6] Qi Ch, Varshney P K, Belcastro C M. Fault detection in dynamic systems via decision fusion[J]. IEEE Trans on Aerospace and Electronic Systems, 2008, 44(1): 227-242.
- [7] 莫以为,萧德云.基于进化粒子滤波器的混合系统故障诊断[J].控制与决策,2004,19(6):611-615.
(Mo Y W, Xiao D Y. Fault diagnosis of hybrid systems based on the evolutionary particle filter[J]. Control and Decision, 2004, 19(6): 611-615.)
- [8] Tafazoli S, Sun X H. Hybrid system state tracking and fault detection using particle filters[J]. IEEE Trans on Control Systems Technology, 2006, 14(6): 1078-1087.
- [9] 余伶俐,蔡自兴,谭平,等.基于多模态进化Rao-Blackwellized粒子滤波器的移动机器人航迹推算系统的故障诊断[J].控制与决策,2010,25(12):1787-1792.
(Yu L L, Cai Z X, Tan P, et al. Fault diagnosis for mobile-robot dead reckoning system based on multimodality evolutionary Rao-Blackwellized particle filter[J]. Control and Decision, 2010, 25(12): 1787-1792.)
- [10] 段琢华,蔡自兴,于金霞.不完备多模型混合系统故障诊断的粒子滤波算法[J].自动化学报,2008,34(5):581-587.
(Duan Z H, Cai Z X, Yu J X. Particle filtering algorithm for fault diagnosis of multiple model hybrid systems with incomplete models[J]. Acta Automatica Sinica, 2008, 34(5): 581-587.)
- [11] Siamak Tafazoli, Sun X H. Hybrid system state tracking and fault detection using particle filter[J]. IEEE Trans on Control System Technology, 2006, 14(6): 1078-1087.
- [12] Song Sh M, Wei X Q, Peng L, et al. Unscented particle filter with estimation windows in submarine tracking[C]. Proc of World Congress on Intelligent Control and Automation. Jinan, 2010: 137-140.
- [13] Umut Orguner, Fredrik Gustafsson. Risk-sensitive particle filters for mitigating sample impoverishment[J]. IEEE Trans on Signal Processing, 2008, 56(10): 5001-5012.
- [14] Canh Ly, Kwok Tom, Carl S Byington, et al. Fault diagnosis and failure prognosis for engineering systems: A global perspective[C]. Proc of IEEE Int Conf on Automation Science and Engineering. Bangalore, 2009: 108-115.
- [15] Wang X Zh, Yu Zh G, Chen X Ch. Controller design and real-time fault diagnosis for a humanoid robot[C]. Proc of IEEE Int Conf on Automation and Logistics. Hong Kong, 2010: 480-485.