

复杂系统故障诊断的新型滤波方法研究*

秦录芳¹, 孙涛^{1,2}, 李军^{1,3}

(1. 徐州工程学院 江苏省大型工程装备检测与控制重点建设实验室, 江苏 徐州 221000; 2. 南京航空航天大学 机电工程学院, 南京 210000; 3. 兰州理工大学 电气工程与信息工程学院, 兰州 730050)

摘要: 针对复杂系统故障诊断问题, 采用一种相关噪声统计特性未知情况下的粒子滤波方法, 该方法给出了相关噪声的统计模型, 并详细推导了相关噪声统计特性的分布函数。在新方法的框架内采用噪声未知统计特性和系统故障状态的联合递推估计, 为复杂系统的故障诊断问题提供了一种新的思路。仿真实验验证了该方法对于复杂系统故障诊断中的有效性和精确性。

关键词: 故障诊断; 相关噪声; 噪声未知; 粒子滤波

中图分类号: TP391

文献标志码: A

文章编号: 1001-3695(2014)04-1016-04

doi:10.3969/j.issn.1001-3695.2014.04.014

New filtering method of complex system fault diagnosis

QIN Lu-fang¹, SUN Tao^{1,2}, LI Jun^{1,3}

(1. Jiangsu Key Laboratory of Large Engineering Equipment Detection & Control, Xuzhou Institute of Technology, Xuzhou Jiangsu 221000, China; 2. College of Mechanical & Electrical Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210000, China; 3. College of Electrical & Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: In order to solve the complicated system fault diagnosis problem, this paper adapted a new kind of particle filter with the relevant noise under unknown statistical properties. This method constructed the statistical model of the relevant noise, and gave the relevant noise statistical properties distribution function in detail. In the framework of the new method, this paper adopted the unknown noise statistics characteristic and the state of the system fault joint estimate recursively, and offered a new idea for the fault diagnosis problems of complex systems. Simulation results show that the method has higher precision and stability.

Key words: fault diagnosis; correlative noises; unknown noises; particle filter

0 引言

随着复杂机械设备故障诊断精度需求的不断提高, 基于非线性滤波技术的混合智能诊断技术已经成为该领域的热点研究方向之一, 受到相关研究人员的广泛关注^[1-3]。随着计算机运算能力的提高和存储成本的降低, 一种新的非线性滤波方法——基于递推贝叶斯滤波原理的序贯蒙特卡罗粒子滤波器 (particle filter, PF) 日益受到人们的重视, 并在众多研究领域获得了成功应用^[4-10]。其核心思想是采用一系列赋予相应权重信息的随机采样粒子以加权求和的方法近似系统的后验状态概率密度函数, 在最小均方误差的准则下实现系统状态的估计。与目前普遍采用的扩展卡尔曼滤波器 (extended Kalman filter, EKF) 和无迹卡尔曼滤波器 (unscented Kalman filter, UKF) 等采用线性近似技术的非线性滤波方法相比, 该算法摆脱了对系统线性、高斯特性的假设, 理论上可以适应任意的非线性非高斯系统。已经有学者将 PF 引入到非高斯噪声下的非线性系统故障诊断中。文献[1]给出一种基于 PF 和联合参数估计的方法进行故障诊断, 将所有可能会发生故障的参数都扩展为状态变量, 但状态维数的增加会导致粒子数的大量增

加, 影响诊断的实时性。文献[2]将进化策略和序贯概率比检验引入 PF 的基本框架实现故障的诊断与隔离, 其缺点在于缺乏对故障恢复后状态估计的自适应性。文献[3]则将似然比方法与粒子滤波器结合起来研究了故障诊断的方法。文献[10, 11]给出了一种基于代价评估的粒子滤波 (cost reference particle filter, CRPF), 避免对于噪声统计信息的依赖, 并且在算法实现上具有更强的可操作性、鲁棒性和灵活性。文献[12]基于以上分析, 通过将残差信息引入序贯概率比检验 (sequential probability ratio test, SPRT) 中, 提出一种新的在线残差似然比检验方法, 并实现其与 CRPF 和交互式多模型 (interacting multiple model, IMM) 的有机结合, 进而给出了一种基于 CRPF 的残差似然比检验故障诊断算法 (residual likelihood-CRPF, RL-CRPF)。

虽然以上方法都在一定程度上提升了系统故障诊断的精度, 但是这些方法都存在一个共同的缺陷, 即所有的研究均是在假设被检测系统与量测噪声相互独立且统计特性先验已知的情况下展开。由于 PF 算法采用的是离散化和近似的思想, 对观测信息的离散化处理加强了系统噪声与量测噪声的相关性; 加之系统的外界干扰及复杂背景下多噪声的融合影响, 导

收稿日期: 2013-06-04; 修回日期: 2013-08-09 基金项目: 江苏省大型工程装备检测与控制重点建设实验室重点项目 (JSKLEDC201202)

作者简介: 秦录芳 (1979-), 女, 河南新乡人, 讲师, 工学硕士, 主要研究方向为机电一体化 (lu_fangqing@163.com); 孙涛 (1980-), 男, 安徽蚌埠人, 讲师, 博士, 主要研究方向为故障诊断; 李军 (1980-), 男, 甘肃兰州人, 讲师, 博士, 主要研究方向为智能目标跟踪方法。

致噪声的统计特性是无法精确先验获取的,这些都限制了当前方法的应用范围。基于此,本文通过建立噪声相关情况下的状态模型,详细推导了相关噪声统计特性的分布函数,最后给出了噪声相关情况下噪声统计特性与状态的联合估计方程,并通过计算机仿真对所提方法进行了仿真。

1 算法分析

1.1 相关噪声联合分布函数

在非线性系统中,噪声特性通常满足高斯假设,针对高斯噪声未知特性的分布情况建立相关噪声情况下的系统分布模型如下:

$$\begin{cases} x_k = f(x_{k-1}) + v_k \\ y_k = h(x_k) + e_k \end{cases} \quad (1)$$

式中: $x_k \in \mathbb{R}^{n_v}$, $y_k \in \mathbb{R}^{n_e}$ 为 k 时刻的状态与观测信息; v_k 和 e_k 为相应的过程噪声与观测噪声。

根据文献[13]的研究,噪声相关性主要表现在时间的前后关联上,具体的关联关系如图1所示。




图1 噪声相关性示意图

处理相关噪声的关键就是寻找噪声联合概率密度函数 $p(v_i, e_j)$ 的适当分解形式。假设噪声向量序列 $(v_{k-1}, e_{k-1})^T$ 是独立的,有

$$p(x_k | X_{k-1}, Y_{k-1}) = p(x_k | x_{k-1}, y_{k-1}) \quad (2)$$

$$p(y_k | X_k, Y_{k-1}) = p(y_k | x_k) \quad (3)$$

则过程与量测噪声联合概率密度函数可以分解为

$$p(v_{k-1}, e_{k-1}) = p(v_{k-1} | e_{k-1}) p(e_{k-1}) \quad (4)$$

1.2 相关噪声统计特性分布模型及推导

根据前面分析的过程与观测噪声,定义两者的联合变量为 ω_k , 即

$$\omega_k = \begin{pmatrix} v_k \\ e_k \end{pmatrix} \quad (5)$$

$$\omega_k \in \mathbb{R}^d (d = n_v + n_e) \quad (6)$$

则 ω_k 是均值为 u_k 、方差为 Σ_k 的条件高斯分布,在模型建立不精确或者是模型失配的情况下,参量 (u_k, Σ_k) 是随着时间缓慢变化的,则可将 ω_k 的条件分布表示为

$$\omega_k \sim N(u_k, \Sigma_k) \quad (7)$$

式中:

$$u_k = [u_{v,k}^T, u_{e,k}^T]^T \quad (8)$$

$$\Sigma_k = \begin{bmatrix} \Sigma_{vv,k} & \Sigma_{ve,k} \\ \Sigma_{ev,k}^T & \Sigma_{ee,k} \end{bmatrix} \quad (9)$$

本文的主要任务就是结合最新观测信息,对噪声的位置参量 $\theta_k = (u_k, \Sigma_k)$ 进行实时估计。通常情况下高斯噪声特性的联合分布具有正态—逆 Wishart 分布特性^[9],具体形式如下:

$$(u_k, \Sigma_k) \sim NiW(v_k, V_k) \quad (10)$$

式中:

$$\begin{cases} u_k | \Sigma_k \sim N(\hat{u}_k, \hat{\Sigma}_k) \\ \Sigma_k \sim iW(v_k - d - 1, \Lambda_k) \end{cases} \quad (11)$$

式中: $iW(\cdot)$ 代表正态—逆 Wishart 分布;参量 v_k 和 V_k 表示分布的统计特性,能够递归地更新估计,其数学定义为

$$V_k = \begin{pmatrix} V_{\omega_k \omega_k, k} & V_{1\omega_k, k} \\ V_{\omega_k 1, k} & V_{11, k} \end{pmatrix} \quad (12)$$

$$\hat{u}_k = V_{11, k}^{-1} V_{1\omega_k, k} \quad (13)$$

$$\hat{\Sigma}_k = \Sigma_k V_{11, k}^{-1} \quad (14)$$

$$\Lambda_k = V_{\omega_k \omega_k, k} - V_{1\omega_k, k} V_{11, k}^{-1} V_{\omega_k 1, k} \quad (15)$$

式中: $V_{\omega_k \omega_k, k}$ 是 V_k 左上方定义的 $d \times d$ 的子矩阵块, $V_k \in \mathbb{R}^{(d+1) \times (d+1)}$, 则 (u_k, Σ_k) 的联合密度可以表示为

$$p(u_k, \Sigma_k) = NiW(v_k, V_k) = \frac{1}{c} |\Sigma_k|^{-\frac{v_k}{2}} \times \exp\left(-\frac{1}{2} \text{tr}(\Sigma_k^{-1} [-I_d, u_k] V_k [-I_d, u_k]^T)\right) \quad (16)$$

式中: c 是归一化的常量,则 ω_k 的预测分布可以表示为

$$p(\omega_k) = t_{v_k}(\tilde{u}_k, \tilde{\Sigma}_k) = \frac{\Gamma(\frac{\tilde{v}_k + d}{2})}{\Gamma(\frac{\tilde{v}_k}{2})} \frac{|\tilde{\Sigma}_k|^{-\frac{1}{2}}}{(\tilde{v}_k \pi)^{\frac{d}{2}}} \times \left[1 + \frac{1}{\tilde{v}_k} (\omega_k - \tilde{u}_k)^T \tilde{\Sigma}_k^{-1} (\omega_k - \tilde{u}_k)\right]^{-\left(\frac{\tilde{v}_k + d}{2}\right)} \quad (17)$$

式中: 自由度 $\tilde{v}_k = v_k - d + 1$, t 分布的位置和尺度参数为 $\tilde{u}_k =$

$$u_k, \tilde{\Sigma}_k = \frac{1 + V_{11, k}}{(v_k - d + 1) V_{11, k}} \Lambda_k, \Gamma(\cdot) \text{ 被称为 Gamma 函数。}$$

如果将 ω_k 按照 v_k 和 e_k 的组成原则进行分解,则有

$$\begin{cases} v_k \sim t_{v_k}(\tilde{u}_{v, k}, \tilde{\Sigma}_{vv, k}) \\ e_k \sim t_{v_k}(\tilde{u}_{e, k}, \tilde{\Sigma}_{ee, k}) \end{cases} \quad (18)$$

则相关噪声的条件分布 $p(e_k | v_k)$ 可以表示为

$$p(e_k | v_k) \sim t_{(\tilde{v}_k + d_e)}(\tilde{u}_{e|v, k}, \tilde{\Sigma}_{e|v, k}) \quad (19)$$

$$\tilde{u}_{e|v, k} = \tilde{u}_{e, k} + \tilde{\Sigma}_{ee, k}^T \tilde{\Sigma}_{vv, k}^{-1} (v_k - \tilde{u}_{v, k}) \quad (20)$$

$$\tilde{\Sigma}_{e|v, k} = h_{e|v, k} (\tilde{\Sigma}_{ee, k} - \tilde{\Sigma}_{ee, k}^T \tilde{\Sigma}_{vv, k}^{-1} \tilde{\Sigma}_{ve, k}) \quad (21)$$

$$h_{e|v, k} = \frac{1}{(\tilde{v}_k + d_v)} \times [\tilde{v}_k + (v_k - \tilde{u}_{v, k})^T \tilde{\Sigma}_{vv, k}^{-1} (v_k - \tilde{u}_{v, k})] \quad (22)$$

2 滤波推导及算法实现

2.1 未知相关噪声滤波原理分析

本文的主要目的就是根据最新量测信息递归地估计 $p(x_k | Y_k)$ 和 $p(\theta_k | Y_k)$ 。假设在 $k-1$ 时刻,已经通过赋予相应权值的先验粒子近似给出 $p(x_{k-1} | Y_{k-1})$,对于标准 PF 而言^[14],有

$$p(X_{k-1} | Y_{k-1}) \approx \sum_{i=1}^N \omega_{k-1}^{(i)} \delta_{X_{k-1}}^{(i)}(X_{k-1}) \quad (23)$$

$$p(X_k | Y_k) \approx \sum_{i=1}^N \omega_k^{(i)} \delta_{X_k}^{(i)}(X_k) \quad (24)$$

$$\omega_k^{(i)} = \omega_{k-1}^{(i)} \frac{p(y_k | X_k^{(i)}, Y_{k-1}) p(x_k^{(i)} | X_{k-1}^{(i)}, Y_{k-1})}{q(x_k^{(i)} | \cdot)} \quad (25)$$

为了获得新的权重信息,需要递归地计算 $p(y_k | X_k, Y_{k-1})$ 和 $p(x_k | X_{k-1}, Y_{k-1})$,由上面的分析,可以通过式(1)和(18)联合得到

$$p([x_k - f(x_{k-1})] | X_{k-1}, Y_{k-1}) = p(v_k) \quad (26)$$

$$(x_k | X_{k-1}, Y_{k-1}) \sim t_{(\tilde{v}_k + d_v)}(\tilde{u}_{v, k}^*, \tilde{\Sigma}_{vv, k}^*) \quad (27)$$

式中: $\tilde{u}_{v, k}^* = \tilde{u}_{v, k} + f(x_{k-1})$ 。类似地,通过式(19)有

$$p([y_k - h(x_k)] | X_k, Y_{k-1}) = p(e_k | v_k) \quad (28)$$

可知 $p(y_k | X_k, Y_{k-1})$ 也是一个 t 分布特性,均值可以表示为

$$\tilde{u}_{e|v, k}^* = \tilde{u}_{e|v, k} + h(x_k) \quad (29)$$

按照式(20)的表示,可以将相应的边缘分布表示为

$$p(x_k | Y_k) \approx \sum_{i=1}^N \omega_k^{(i)} \delta_{x_k^{(i)}}(x_k) \quad (30)$$

可以看出,PF算法提供了一种递归的近似联合平滑分布的方法。由式(1)的表示,在知道\$(X_{k-1}, Y_{k-1})\$序列的情况下,可以获得观测噪声序列\$\omega_{1:k-1}\$的完整信息。按照前面分析的正态-逆 Wishart 分布特性有

$$p(\theta_{k-1} | X_{k-1}, Y_{k-1}) = p(\theta_{k-1} | \omega_{k-1}) = NiW(v_{k-1}, V_{k-1}) \quad (31)$$

由于参数\$(u_k, \Sigma_k)\$是随着时间缓慢变化的,利用指数遗忘原则^[15]可以近似获取时间更新步骤为

$$p(\theta_{k-1} | X_{k-1}, Y_{k-1}) = p(\theta_{k-1} | \omega_{k-1}) = NiW(\lambda v_{k-1}, \lambda V_{k-1}) \quad (32)$$

式中:\$\lambda \in (0, 1)\$是遗忘因子。

利用贝叶斯准则的共轭特性可知后验概率密度\$p(\theta_k | X_k, Y_k)\$也是一个正态-逆 Wishart 分布,其分布函数可以表示为

$$p(\theta_k | X_k, Y_k) = p(\theta_k | \omega_k) = NiW(v_k, V_k) \quad (33)$$

$$\text{式中: } V_k = \lambda V_{k-1} + \begin{pmatrix} \omega_k \\ 1 \end{pmatrix} \begin{pmatrix} (\omega_k)^T & 1 \end{pmatrix} \quad (34)$$

$$v_k = \lambda v_{k-1} + 1 \quad (35)$$

$$\text{式中: } \omega_k = \begin{pmatrix} v_k \\ e_k \end{pmatrix} = \begin{pmatrix} x_k - f(x_{k-1}) \\ y_k - h(x_k) \end{pmatrix} \quad (36)$$

$$\text{这里定义 } T_k(x_k) = p(\theta_k | x_k, Y_k) \quad (37)$$

$$\text{则有 } T_k(x_k) = \iint p(\theta_k | X_k, Y_k) p(X_{k-1} | Y_{k-1}, x_k) dX_{k-1} \quad (38)$$

可以建立\$T_k(x_k)\$的递归关系式:

$$T_k(x_k) = \iint \frac{p(\theta_k | X_k, Y_k) p(\theta_{k-1} | X_{k-1}, Y_{k-1})}{p(\theta_{k-1} | X_{k-1}, Y_{k-1})} \times p(X_{k-2} | Y_{k-2}, x_{k-1}) p(x_{k-1} | Y_{k-1}, x_k) dX_{k-2} dx_{k-1} = \iint \frac{p(\theta_k | X_k, Y_k)}{p(\theta_{k-1} | X_{k-1}, Y_{k-1})} \times T_{k-1}(x_{k-1}) p(x_{k-1} | Y_{k-1}, x_k) dx_{k-1} \quad (39)$$

由前面的PF算法原理,则有

$$p(x_{k-1} | Y_{k-1}, x_k) \approx \frac{\sum_{j=1}^N \omega_{k-1}^{(j)} p(x_k | x_{k-1}^{(j)}) \delta_{x_{k-1}^{(j)}}(x_{k-1})}{\sum_{l=1}^N \omega_{k-1}^{(l)} p(x_k | x_{k-1}^{(l)})} \quad (40)$$

通过式(40)的表示,可以将式(39)近似为

$$T_k(x_k^{(i)}) = \sum_{j=1}^N \frac{NiW(v_k^{(ij)}, V_k^{(ij)})}{NiW(v_{k-1}^{(j)}, V_{k-1}^{(j)})} \times T_{k-1}(x_{k-1}^{(j)}) \frac{\omega_{k-1}^{(j)} p(x_k^{(i)} | x_{k-1}^{(j)})}{\sum_{l=1}^N \omega_{k-1}^{(l)} p(x_k | x_{k-1}^{(l)})} \quad (41)$$

$$\text{式中: } V_k^{(ij)} = \lambda V_{k-1}^{(j)} + \begin{pmatrix} \omega_k^{(ij)} \\ 1 \end{pmatrix} \begin{pmatrix} (\omega_k^{(ij)})^T & 1 \end{pmatrix} \quad (42)$$

$$v_k^{(ij)} = \lambda v_{k-1}^{(j)} + 1 \quad (43)$$

$$\omega_k^{(ij)} = \begin{pmatrix} x_k^{(i)} - f(x_{k-1}^{(j)}) \\ y_k - h(x_k^{(i)}) \end{pmatrix} \quad (44)$$

最后,通过式(31)和(39)可以得到

$$p(\theta_k | Y_k) = \int T_k(x_k) p(x_k | Y_k) dx_k = \sum_{i=1}^N \omega_k^{(i)} T_k(x_k^{(i)}) \quad (45)$$

2.2 算法步骤

结合前面的理论分析,噪声特性未知情况下的非线性滤波的具体实现步骤为:

a) 在\$(k-1)\$时刻通过预先赋予相应的采样粒子集合\$\{x_{k-1}^{(i)}, \omega_{k-1}^{(i)}, T_{k-1}(x_{k-1}^{(i)})\}_{i=1}^N\$,则有

$$p(x_{k-1} | Y_k) \approx \sum_{i=1}^N \omega_{k-1}^{(i)} \delta_{x_{k-1}^{(i)}}(x_{k-1}) \quad (46)$$

$$p(\theta_{k-1} | Y_k) = \sum_{i=1}^N \omega_{k-1}^{(i)} T_{k-1}(x_{k-1}^{(i)}) \quad (47)$$

b) 在\$k\$时刻,新的观测信息到来以后,通过\$x_k^{(i)} \sim q(x_k | \cdot)\$

产生新的粒子,获得新的粒子以后,通过式(23)~(25)进行相应权值的更新。同时,利用式(39)~(44)递归地计算\$T_k(x_k^{(i)})\$。

c) 估计检测系统整体统计特性:

$$p(\theta_k | Y_k) = \sum_{i=1}^N \omega_k^{(i)} T_k(x_k^{(i)}) \quad (48)$$

3 实验及分析

3.1 实验场景

为充分验证本文算法的有效性,实验中对式(49)~(52)所示的系统状态进行仿真,并将实验场景分为定常噪声和时变噪声两种情况:

$$x_k = F_k x_{k-1} + G v_k \quad (49)$$

$$z_k = \begin{bmatrix} r_k \\ \theta_k \end{bmatrix} = \begin{bmatrix} (x_k^2 + y_k^2)^{\frac{1}{2}} \\ \tan^{-1}(y_k / x_k) \end{bmatrix} + \omega_k \quad (50)$$

具体的检测场景如下:

$$\text{状态 1 } Q_k = \begin{bmatrix} 0.5^2 & 0 \\ 0 & 0.5^2 \end{bmatrix} \quad (51)$$

$$\text{状态 2 } Q_k = \begin{cases} \text{diag}\{0.2^2, 0.2^2\} & 0 \leq k \leq 40 \\ \text{diag}\{0.4^2, 0.4^2\} & 40 \leq k \leq 70 \\ \text{diag}\{0.8^2, 0.8^2\} & 70 \leq k \leq 100 \end{cases} \quad (52)$$

3.2 参数设定

假设整个检测系统的初始状态为\$x_0 = [200, 120, 2000, 1]^T\$,量测噪声方差为\$R = \text{diag}\{30^2, 0.01^2\}\$,先验噪声\$Q = \text{diag}\{0.1^2, 0.1^2\}\$,仿真时间为100 s,采样周期\$T\$为1 s。仿真实验的均方根误差(root mean square error, RMSE)定义为

$$E = \left(\frac{1}{N} \sum_{i=1}^N \| \hat{x}_k^i - x_k^i \|_2 \right)^{1/2} \quad (53)$$

式中:\$N\$代表仿真次数。

3.3 结果分析

仿真实验1 对两种情况的故障状态进行了一次独立估计预测实验,具体结果如图2、3所示。其中图2为定常噪声情况下系统的估计结果,图3为时变噪声情况下系统的估计结果。可以看出,在定常噪声情况下,三种方法均保持了较好的跟踪精度,但是在时变噪声情况下,本文方法和文献[12]的方法明显保持了更好的估计与预测效果。




图2 定常噪声下估计结果

图3 时变噪声下估计结果

仿真实验2 针对两种情况进行了100次PF采样实验,具体状态均方误差曲线如图4、5所示。由图可以看出,本文方法和文献[12]方法明显优于标准PF方法,主要原因是标准PF方法采用的建议分布函数主要依赖于精确的初始模型,随着噪声相关性的时间推移及时变噪声特性的影响,导致模型产生了较大偏移,误差增大,而本文方法和文献[12]方法对模型进行了实时更新处理,因此能够保持较好的精确性。但是文献[12]方法因为存在模型的转换问题,在噪声转换的时刻,其状态估计精度较本文方法有所降低。




图4 状态1的状态估计均方误差




图5 状态2的状态估计均方误差

4 结束语

针对复杂系统故障诊断问题,本文提出了一种噪声相关情况下的非线性滤波方法,概括起来讲,主要有以下三个特点:a)建立了噪声相关情况下的系统状态模型,并给出相关噪声联合概率密度的分解形式;b)推导了量测噪声与系统噪声的联合分布函数的具体表达式;c)详细推导了噪声统计特性和系统状态的联合估计表达式。理论分析和实验结果表明,本文算法为复杂系统的故障诊断问题提供了一个新的思路。但是本文仅限于单一传感信息的单一故障诊断问题,如何实现多故障的联合诊断问题是下一步的研究方向。

参考文献:

- [1] 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):612-615.
- [2] KADIRKAMANATHAN V, LI P. A sequential Monte Carlo filtering approach to fault detection and isolation in nonlinear systems[C]// Proc of IEEE Conference on Decision and Control. 2000:4341-4346.
- [3] KATSUJI U, TOSHIHARU H. Evolution strategies based particle filters for fault detection[C]// Proc of IEEE Symposium on Computational Intelligence in Image and Signal Processing. 2007:58-65.
- [4] DOUCET A, GORDON N J. Sequential Monte Carlo methods in practice[M]. New York: Springer-Verlag, 2001: 247-272.
- [5] DENG Xiao-long, XIE Jian-ying, NI Hong-wei. Improved particle filter for target tracking[J]. Chinese Journal of Aeronautics, 2005, 18(2):166-170.
- [6] 杜正聪,唐斌,李可. 混合退火粒子滤波器[J]. 物理学报,2006, 55(3):999-1004.
- [7] 朱志宇,杨官校. 基于 Stiefel 流形的粒子滤波器研究[J]. 物理学报,2010,59(12):8316-8321.
- [8] 程建. 基于粒子滤波与层级形状描述的红外目标跟踪[J]. 系统工程与电子技术,2011,33(6):1217-1236.
- [9] 张海洋,李谢华,江英. 基于假设检验的自适应粒子滤波红外目标跟踪[J]. 计算机工程,2012,38(11):153-159.
- [10] LI P, KADIRKAMANATHAN V. Fault detection and isolation in nonlinear stochastic systems-a combined adaptive Monte Carlo filtering and likelihood ratio approach[J]. International Journal of Control, 2004,77(12):1101-1114.
- [11] DJURIC P M, ZHANG Ze-jie, BUGALLO M F. Target tracking by a new class of cost-reference particle filters[C]//Proc of IEEE Aerospace Conference. 2008:1-9.
- [12] 胡振涛,潘泉,杨峰,等. 基于 CRPF 的残差似然比检验故障诊断算法[J]. 系统工程与电子技术,2009,31(12):3022-3025.
- [13] CAPPE O, GODSILL S J, MOULINES E. An overview of existing methods and recent advances in sequential Monte Carlo[J]. Proceedings of the IEEE, 2007,95(5): 899-924.
- [14] 刘金山,张国权. 正态-逆 Wishart 先验信息下多源线性模型的后验似然比检验[J]. 应用概率统计,2005,21(11):351-358.
- [15] WEI Qi, XIONG Zhang, LI Chao, et al. A robust approach for multiple vehicles tracking using layered particle filter[J]. International Journal of Electronics and Communications, 2011, 65(7):609-618.
- [16] 王志成,胡可云,胡学钢,等. 概念格上规则提取的一般和渐进式算法[J]. 计算机学报,1999,22(1):66-70.
- [17] 谢志鹏,刘宗田. 概念格与关联规则发现[J]. 计算机研究与发展,2000,37(12):1415-1421.
- [18] 胡可云,陆玉昌,石统一. 基于概念格的分类和关联规则的集成挖掘方法[J]. 软件学报,2000,11(11):1478-1484.
- [19] GODIN R. Incremental concept formation algorithm based on Galois (concept) lattices [J]. Computational Intelligence, 1995, 11(2):246-267.
- [20] 陈湘,吴跃. 基于约简概念格的关联规则提取改进算法[J]. 计算机应用研究,2011,28(4):1293-1295.
- [21] 梁吉业,王俊红. 基于概念格的规则产生集挖掘算法[J]. 计算机研究与发展,2004,41(8):1339-1344.
- [22] 张继福,张素兰,蒋义勇. 约束概念格的代数性质及其知识表示的完备性[J]. 模式识别与人工智能,2010,23(3):289-299.
- [23] 王慧,王京. FP-tree 上频繁概念格的无冗余关联规则提取[J]. 计算机工程与应用,2012,48(15):12-15.
- [24] HAN Jia-wei, KAMBER M. 数据挖掘概念与技术[M]. 范明,孟小峰,译. 2版. 北京:机械工业出版社,2011.
- [25] ISO 9223, Corrosion of metals and alloys corrosivity of atmosphere classification[S]. Geneva: ISO, 1992.

(上接第1015页)进一步比较不同支持度阈值下,两种算法的执行时间如表6所示。

表6 DFCLA 和 DFTFH 算法执行时间比较

比较项	支持度				
	1%	5%	10%	15%	20%
DFCLA 时间/ms	1561	1405	1330	1088	1015
DFTFH 时间/ms	1485	1170	1096	935	855
算法效率提高百分比/%	4.9	16.7	17.6	14.1	15.8

结果表明,在不同的支持度下,DFTFH 比 DFCLA 算法的执行效率均有提高。因为 DFTFH 算法只扫描 FP-tree 一次,且过滤掉了不满足约束条件的冗余节点,在进行约束关联规则挖掘的过程中,DFTFH 相对于 DFCLA 算法节省了重复遍历 FP-tree 的时间和冗余节点的概念格构造时间。

4 结束语

本文提出了一种基于 FP-tree 和约束概念格的规则挖掘算法,解决了现有基于 FP-tree 和概念格的规则挖掘算法中算法效率依赖于 FP-tree 频繁项目列表的问题,避免了现有算法在挖掘约束关联规则时概念格上产生冗余节点的不足。通过实际项目中大气腐蚀数据集进行算法实验,结果表明,提出的算法效率优于现有算法,并且能够通过不存在冗余节点的约束概念格提取出用户感兴趣的全部约束关联规则。

参考文献:

- [1] AGRAWAL R, IMIELINSKI T, SWAMI A, et al. Mining association rules between sets of items in large databases[C]// Proc of ACM SIGMOD International Conference on Management of Data. New