

基于改进余弦相似度的粒子滤波故障预报^①

蒋欣, 王开军, 陈黎飞

¹(福建师范大学 数学与计算机科学学院, 福州 350007)

²(福建师范大学 福建省网络安全与密码技术重点实验室, 福州 350007)

摘要: 现有的粒子滤波故障预报方法主要是通过粒子滤波算法得到对应时刻的预测值, 然后比较其与实际值的差值来对故障进行预报。从分析设备正常工作的时间序列数据与潜在故障引起的异常数据之间的相似性的新角度, 设计了系统正常度和系统异常度来判别设备是否正常运行, 进而对潜在的故障进行预测。实验结果验证了该方法的可行性, 并能及时准确地预报出系统故障。

关键词: 相似性度量; 正常度; 异常度; 粒子滤波; 故障预报

Particle Filter Fault Prediction Based on Improved Cosine Similarity

JIANG Xin, WANG Kai-Jun, CHEN Li-Fei

¹(Fujian Normal University, Mathematics and Computer Science College, Fuzhou 350007, China)

²(Fujian Normal University, Fujian Province Network Security and Cryptography Laboratory, Fuzhou 350007, China)

Abstract: The existing particle filter fault prediction method is the corresponding time's predictive value obtained from particle filter algorithm. The particle filter algorithm predicts the system fault by comparison of the predict value and actual value. This paper designs a new method identifying the function of system equipment. By analysis of the normal working equipment's time-series data and abnormal data, it can predict the potential system fault. Experimental results demonstrate the feasibility of this method and the accuracy of predicting system fault.

Key words: similarity measure; normal degree; abnormal degree; particle filter; fault prediction

1 引言

提前预报故障是避免设备发生故障而造成损失的重要措施。所谓故障预报即判断当前状态偏离正常态的程度, 以及预报故障发生时间^[1], 根据预报可以对设备提前进行维修。实际应用的许多设备大多结构复杂, 而且为非线性系统, 工作过程中会受到较强的噪声干扰, 针对这一问题, 采用粒子滤波算法, 其已被证明能有效的解决非线性非高斯系统的故障预测问题^[2]。目前粒子滤波已被广泛应用于诸多领域^[4], 在经济学领域, 它被应用在经济数据预测; 在军事领域已经被应用于雷达跟踪空中飞行器, 空对空、空对地的被动式跟踪; 在交通管制领域它被应用在对车或人视频监控。例如, 文献[5]针对粒子滤波算法在故障预报中

的计算量大和粒子退化问题, 提出一种基于随机摄动粒子滤波器的故障预报算法, 文献[6]基于粒子滤波算法采用状态变量当前时刻的后验分布进行迭代采样以及数据驱动的方法预测未来一段时间内对象系统的量测信息, 文献[7]基于粒子滤波提出了一种实时可靠性预测方法, 并由三容水箱系统仿真实验验证了预测方法的有效性, 文献[8]基于粒子滤波的框架进行在线故障诊断及预测, 演化计算剩余使用寿命, 并用于对飞行器的行星齿轮盘裂纹故障进行预报等。上述方法主要通过粒子滤波算法得到对应时刻的预测值, 然后比较其与实际值的差值来对故障进行预报。

本文在系统跟踪阶段, 通过设计的粒子滤波算法

① 基金项目: 国家自然科学基金项目(61175123); 福建省自然科学基金(2013J01223); 福建省高校服务海西建设重点项目

收稿时间: 2014-04-17; 收到修改稿时间: 2014-05-20

对目标进行跟踪预测;在故障预报阶段,不采用基于差值比较的方法,而是分析设备正常工作的时间序列数据与潜在故障引起的异常数据之间的相似性,通过余弦相似度公式设计了正常度和异常度来进行故障预报,以实现进一步提高故障预报的准确性和及时性。

2 相关理论

在设备运行期间,可以得到设备运行的实际数据,利用当前设备运行的实际数据,采用粒子滤波算法对目标进行跟踪预测,可以得到设备运行下一段时间的预测数据。

2.1 经典粒子滤波算法

粒子滤波是一种顺序重要性采样方法,其核心思想是通过一组在状态空间传播的随机样本(粒子)对概率密度函数进行近似。由于粒子滤波算法是采用一些具有权值的随机样本(粒子)来表示所需的后验概率密度,而不是采用线性变换的传统方式,从而得到基于物理模型的近似最优解,其具有精度高、收敛速度快等优点。

现假设电子设备的故障演化过程可用如下状态空间模型表示:

$$X_k = f(X_{k-1}, \theta_k, I_{k-1}) + w_{k-1} \quad (1)$$

$$Y_k = h(X_k, \theta_k) + u_k \quad (2)$$

其中 X_k 是系统的状态变量,它的值直接与设备的故障演化过程相关, Y_k 是系统的观测变量, θ_k 是模型的参数,一般用于表示设备故障演化导致的模型参数的变化, w_k 和 u_k 分别为系统噪声和观测噪声。

对于故障预测问题,可以把它看作一个已知系统从运行起始时刻 $t=1$ 至当前时刻 $t=n$ 的观测序列 $\{y_1, y_2, \dots, y_n\}$, 在系统缓变参数的限制条件下,估计未来某一个时刻 $n+p(p>0)$ 的系统状态变量 X_{n+p} 的值,并在一定的准则意义对故障进行预报的问题。

粒子滤波算法在本文中被我们用于对目标的跟踪预测,其基本过程描述如下:

1) 初始化

初始时刻 $T=0$ 时,抽样生成服从先验分布 $P(X_0)$ 的 N 个样本粒子 $\{x_0^1, x_0^2, \dots, x_0^N\}$, 每个粒子的权重值 w_0^i 设为 $1/N$ 。在 $T=k-1$ 时,抽样生成服从先验分布 $p(x_{k-1} | y_{1:k-1})$ 的 N 个样本粒子 $\{x_{k-1}^1, x_{k-1}^2, \dots, x_{k-1}^N\}$

2) 预测更新状态变量

采用 $k-1$ 时刻 N 个独立同分布的样本粒子计算 k

时刻的样本粒子值:

$$\tilde{x}_k^{(j)} = f(x_{k-1}^{(j)})$$

3) 计算权值并进行归一化

更新 k 时刻样本的权值: $w_k^{(j)} = \frac{w_{k-1}^{(j)} p(y_k | x_k^{(j)})}{\sum_{j=1}^N w_{k-1}^{(j)}}$

5) 输出滤波结果

计算出 k 时刻状态变量的值: $\tilde{x}_k = \sum_{j=1}^N w_k^j x_k^j$

6) $K=K+1$, 重复第 1 步至第 5 步

2.2 时间序列的相似性度量

假设存在两个等长时间序列向量 $X=(x_1, x_2, \dots, x_n)^T, Y=(y_1, y_2, \dots, y_n)^T$, 为了衡量两者之间的差异性, 我们可以通过余弦相似性度量公式(3)进行相似度量:

$$P_{xy} = \frac{\sum_{k=1}^n x_k y_k}{\left[\sum_{k=1}^n x_k^2 \sum_{k=1}^n y_k^2 \right]^{1/2}} \quad (3)$$

上式 P_{xy} 反应了两个序列之间的相似程度, 两个序列越相似则 P_{xy} 值越接近于 1, 当两个序列完全相等时, P_{xy} 值为 1。

2.3 正向推理和反向推理

粒子滤波方法跟踪设备当前实际数据, 可以对设备下一段时间数据进行预测, 若设备运行正常, 则预测值与实际观测值误差很小, 反之, 若设备运行故障, 则预测值与设备正常运行实际值偏差较大。当偏差触发一定的准则(本文采用比较正常度和异常度)时, 则预报可能发生故障。

根据上述假设, 需要对设备的正常工作状态进行研究, 并计算其正常度, 正常度低则可能发生故障, 这属于正向推理, 反之若设备发生故障, 需要研究设备的故障程度, 从反向时间轴方向描述其异常度, 异常度高则可能发生潜在故障, 这属于反向推理, 最终综合正向推理和反向推理对故障进行预报。

3 基于相似性度量的双向粒子滤波故障预测算法设计

假设设备初始是正常工作的状态, 随着工作时间的增加, 逐渐发展到故障状态。本文把设备的实际数据与预测数据采用相似性度量方法, 计算两者之间的相似性。如果实际数据与预测数据相接近, 相似性较大, 认为设备属于正常工作状态, 反之实际数据与预

测数据偏离较远, 相似性较小, 认为设备即将发生故障, 需要诊修.

3.1 算法思想

现已知观测变量 y 的当前时刻 k 及以前一段时间的数据 $\{y_1, y_2, \dots, y_{k-1}\}$, 根据粒子滤波算法进行 p 步向前预测, 得出预测值 \tilde{y}_{k+p} , 当时刻到达 $k+p$ 时, 根据提出的相似性度量公式计算两者之间的相似性, 从而计算出设备当前时刻的正常度.

定义 1. (序列模长) 一个时间序列向量 $X=(x_1, x_2, \dots, x_n)^T$ 代入如下公式(4)得出的值, 称为该序列的模长.

$$|X| = \sqrt{\sum_{i=1}^n x_i^2} \quad (4)$$

针对余弦相似性不考虑序列向量的绝对长度, 只从方向上判断两个序列的相似性的问题, 提出如下式(5)相似性度量公式.

定义 2. (相似系数) 两个序列 $X=(x_1, x_2, \dots, x_n)^T, Y=(y_1, y_2, \dots, y_n)^T$ 代入如下公式(5)得出的值, 称为相似系数.

$$P_{xy} = \frac{\sum_{k=1}^n x_k y_k}{\left[\sum_{k=1}^n x_k^2 \sum_{k=1}^n y_k^2 \right]^{1/2}} \cdot \frac{\min(|X|, |Y|)}{\max(|X|, |Y|)} \quad (5)$$

在公式(5)中, X, Y 分别对应真实值和预测值序列, 其中 $|X|$ 和 $|Y|$ 表示序列 X, Y 的模长, $\min(|X|, |Y|)$ 表示取序列 X, Y 模长中的小者, $\max(|X|, |Y|)$ 表示取序列 X, Y 模长中的大者, 采用两个序列模长的比值可以从其长度上衡量两个序列相似性. 因此上式(5)可以从序列的方向及其模长两方面综合度量两个序列之间的相似性. 当序列 X 和序列 Y 越接近, 两个序列向量的方向和长度的比值也会越接近, P_{xy} 值越接近于 1, 当两个序列完全相等时, 其方向和长度都相等, P_{xy} 的值为 1, 反之两个序列 X 和序列 Y 越不接近, P_{xy} 值越接近于 0.

在设备故障预测中, 常规的做法是比较当前时刻预测值与实际值的差值, 从而在一定准则意义下进行故障预报, 但该方法受到个别异常点影响很大. 本文采用比较一段预测值和实际值的相似程度, 从而来实际故障的诊断, 可使最终的故障预测更为合理.

假设设备故障发展初期系统工作状态正常, 根据预测值和实际值可以计算得出一个正常状态下的相似系数, 其值应该接近于 1, 随着时间的推移和潜在故障的发展, 实际值和预测值偏离越来越大, 相似系数值

越来越小, 健康程度逐步变低, 故障概率则逐步变大.

定义 3. (正常度) 在时刻 t , 系统的正常度定义如下:

$$H_t = e^{10(p(t)-1)} \quad (6)$$

其中, $p(t)$ 是将正向推理计算出的 t 时刻实际值序列和预测值序列代入定义 2 得出的相似系数. 理想状态下, 实际值和预测值应完全相等, 其相似系数为 1. 上式中若系统运行正常, 则时刻 t 的相似系数非常接近完全正常工作状态的相似系数 1, 从而正常度接近于 1, 反之系统运行发生故障, 相似系数远离正常工作状态的相似系数 1, 正常度则远离 1.

定义 4. (异常度) 在时刻 t , 系统的异常度定义如下:

$$F_t = 1 - e^{10(q(t)-1)} \quad (7)$$

同理 n 表示实际值序列和预测值序列的长度, $q(t)$ 是将反向推理计算出的 t 时刻实际值序列和预测值序列代入定义 2 得出的相似系数. 若系统运行正常, 则时刻 t 的相似系数会非常接近正常工作状态的相似系数, 从而异常度远离 1, 反之系统运行发生故障, 相似系数远离正常工作状态的相似系数, 异常度接近于 1.

3.2 故障预测算法步骤

Step 1: 设备故障发展初期, 系统处于正常状态, 测量获得数据 $\{y_t\} (t=1, 2, 3, \dots)$, 通过公式(1)和(2)以及粒子滤波算法计算出预测值 $\{\tilde{y}_t\}$.

Step 2: 当时间 $t=k(1, 2, \dots, n)$ 时, 进行 p 步向前预测得到预测序列 $\{y_{k+1}, y_{k+2} \dots y_{k+p}\}$ (正向推理), 与实际值序列 $\{\tilde{y}_{k+1}, \tilde{y}_{k+2} \dots \tilde{y}_{k+p}\}$ 代入公式(5)计算其相似系数.

Step 3: 将相似系数代入公式(6)求得其正常度.

Step 4: 在时刻 $t=k(k>p)$, 反向使用公式(1)和公式(2)可得出预测值序列 $\{\tilde{y}_1, \tilde{y}_2 \dots \tilde{y}_{k-1}\}$, 将预测值序列 $\{\tilde{y}_1, \tilde{y}_2 \dots \tilde{y}_m\}$ 与设备前期正常工作状态的 ($t \leq m$) 的实际值序列 $\{y_1, y_2 \dots y_m\}$ 代入公式(5)计算其相似系数.

Step 5: 将相似系数代入公式(7)求得其异常度.

Step 6: 当时刻 $t=q$ 时, 若异常度连续两次大于正常度, 则预报出现故障, 设备需诊修.

4 实验结果与分析

本节通过实验检测本文方法的有效性, 性能评价考察在故障发生后多长时间预报故障, 并与基于随机

摄动粒子滤波器的故障预报算法^[5]和基于粒子滤波的 FDI 方法^[8]进行对比. 仿真实验采用文献[5]中德国 Amira 公司制造的三容水箱系统, 如图 1 所示. 在此装置中, 有 3 个垂直放置并且大小一致的玻璃圆筒 T1、T2、T3, 圆筒横截面积均为 A, 各圆筒由横截面为 S_n 的圆管相连接, 圆筒 T2 下方的出水阀可控制水流到下方的玻璃水箱中, 同时圆筒 T1、T2、T3 下方各有一个泄漏阀(截面积都为 S_1). 两台水泵分别向圆筒 T1、T2 输入流量为 Q_1 、 Q_2 的循环水, 它们是系统的输入, 系统状态变量为三个圆筒水槽 T1、T2、T3 的液位 h_1 、 h_2 、 h_3 . 若出现故障, 圆筒 T2 的液位 h_2 将不能保持初始值而大幅下降. 有关该水箱系统的更多细节参见文献[5].




图 1 三容水箱系统

在实验中, 设计系统的仿真运行时间是 $200\Delta t$, 仿真系统在 20 个抽样间隔($20\Delta t$)后开始逐渐出现故障, 故障使得圆筒 T2 的液位 h_2 不能保持初始值而大幅下降. 采用粒子规模 N 为 1000, $p=5$, 初始粒子满足 $x_0 \sim N([h_1^0 \ h_2^0 \ h_3^0]^T, 10^{-2})$. 系统初期是正常工作状态($t \leq 20$), 本文方法监测圆筒 T2 的液位, 每隔一个时间点进行 p 步向前预测计算其正常度, 同时反向预测与前期设备正常工作状态实际历史序列 $\{y_2, y_3, y_4, y_5, y_6\}$ 代入公式(5)和(7)计算其异常度, 当出现异常度连续两次大于正常度, 则预报出现故障. 实验结果参见表 1 和图 3, 表 2 中对比方法的实验结果来自文献[5]. 为比较本文故障预报方法和标准粒子滤波故障预报方法的计算量, 分别在 $N=1000, 2000, 3000, \dots, 5000$ 时对两种算法分别运行 10 次, 其平均运行时间 t_1 (本文方法)和 t_2 (标准粒子滤波算法)见表 3.

表 1 本文方法仿真实验的故障预报结果

时间点 t	54	55	56	57	58
T2 液位	0.2974	0.2961	0.2943	0.2922	0.2881

正常度 H	0.6681	0.6650	0.6523	0.6524	0.6392
异常度 F	0.5271	0.5106	0.5468	0.5461	0.5820
预报故障	无	无	无	无	无
时间点 t	59	60	61	62	63
T2 液位	0.2842	0.2808	0.2768	0.2712	0.2648
正常度 H	0.6253	0.6065	0.6017	0.5859	0.5850
异常度 F	0.5865	0.6166	0.6024	0.6408	0.6548
预报故障	无	/	有	有	有

表 2 对比方法仿真实验的故障预报结果

时间点 k	62	63	64	65	66
T2 液位	0.2783	0.2742	0.2761	0.2723	0.2742
故障概率	0.3709	0.4526	0.5250	0.5734	0.6425
预报故障	无	无	有	有	有
时间点 k	67	68	69	70	71
T2 液位	0.2705	0.2717	0.2685	0.2698	0.2666
故障概率	0.7211	0.7133	0.8326	1.0000	1.0000
预报故障	有	有	有	有	有

表 3 平均运行时间(s)

粒子数 N	1000	2000	3000	4000	5000
t_1	16.02	30.07	44.35	56.91	73.89
t_2	16.54	31.49	46.87	59.73	77.36

图 2 表示圆筒 T1、T2、T3 实际液位及粒子滤波跟踪预测值的变化情况, 从图 2 可以看出粒子滤波算法对圆筒 T1、T2、T3 实际液位跟踪效果较好.




图 2 圆筒 T1、T2、T3 液位变化

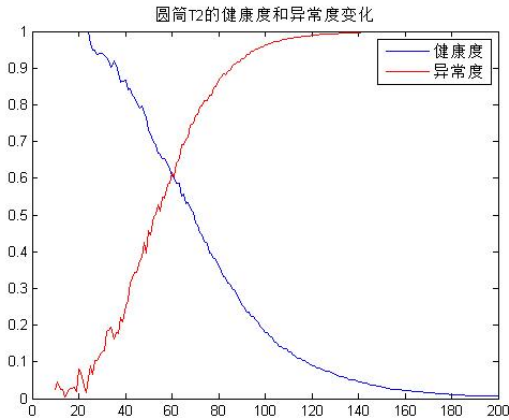


图 3 三容水箱实验的仿真故障预报结果

从表 1 可以看出, 本文采用方法在 $t=61\Delta t$ 预报故障, 对比的故障预报方法提早了 3 个时间点.

实验二是对 H-60 行星齿轮盘的裂纹故障进行预报, 目标是发现该裂纹何时开始增大. 反映裂纹长度变化的特征是观测到的震动信号谱中的谐波与边频带的比率数据, 该数据有 251 个时间点一维样本. 该系统离散化的状态空间模型为:

$$\begin{cases} x(k+1) = x(k) + \beta \cdot x(k) \cdot z(k) + u(k) \\ y(k) = x(k) + v(k) \end{cases} \quad (8)$$

其中, $z(k)$ 为系统健康和故障状态, 系统的状态变量 x 与裂纹长度相关, 高斯系统噪声满足 $u \sim N(0, 1 \times 10^{-4})$, β 是与行星齿轮盘相关的时变参数, 设置为 $(\sin(0.2k)+1)/2$, y 为观测变量, 高斯观测噪声满足 $v \sim N(0, 1 \times 10^{-2})$.

在实验中, 仿真时间是 $251\Delta t$, 粒子规模为 500, $p=10$, 初始粒子满足 $x_0 \sim N(3.4, 0.64)$. 设备故障发展初期是正常工作状态, 每隔 $10\Delta t$ 进行 p 步向前预测计算其正常度, 同时反向预测过去的状态得出预测值序列, 使用该预测序列中的 $\{\tilde{y}_2, \tilde{y}_3, \tilde{y}_4, \tilde{y}_5, \tilde{y}_6\}$ 与对应时间点的设备正常工作状态的观测序列 $\{y_2, y_3, y_4, y_5, y_6\}$ 计算异常度. 当出现异常度连续两次大于正常度的情况, 则预报出现故障, 实验结果参见表 4 和图 4, 并与基于粒子滤波的 FDI 方法^[8]的实验结果(图 5)进行对比.

表 4 本文方法仿真实验的故障预报结果

时间点 t	90	100	110	120	130	140
正常度H	0.7048	0.8212	0.6261	0.5659	0.5959	0.6378
异常度F	0.4758	0.4329	0.4819	0.6959	0.6786	0.6624
预报故障	无	无	无	/	有	有

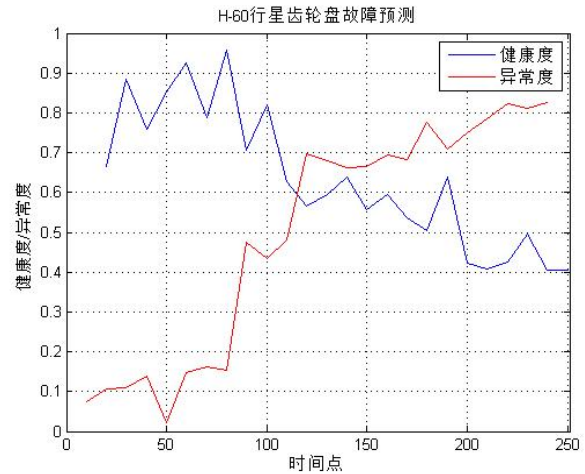


图 4 H-60 行星预报裂纹故障仿真结果




图 5 基于粒子滤波的 FDI 方法预报裂纹故障结果

从图 4 中可以看出, 设备故障发展初期正常度较高, 异常度较低, 随着时间推移和潜在故障的发展, 异常度逐步上升, 正常度逐步下降. 本文方法在 $t=130$ 时预报出现故障, 对比方法基于粒子滤波的 FDI 提早了 5 个时间点预报出现故障. 这些实验结果验证了本文方法能有效地对故障进行早期预报, 其性能高于对比方法. 本文方法分析设备正常工作的时间序列数据与潜在故障引起的异常数据之间的相似性, 相比常规比较预测值和实际值差值的方法受个别异常点影响较小, 更加合理可靠, 同时通过基于正向预测的正常度以及基于反向预测的异常度, 实时了解设备的运行状况, 判别设备是否正常运行, 并能更准确快速地预报故障.

5 总结

本文采用粒子滤波对目标系统进行跟踪预测, 通过相似性度量公式从正向及反向两个角度计算其正常度和异常度, 从而实现对故障的预报. 实验结果表明, 本文算法是有效的, 并能及时准确的预报出故障. 本文采用余弦相似性度量得出的正常度和异常度来进行故

障预报,后期可以设计其他有效的度量方式开展工作.

参考文献

- 1 Yang SK. A condition-based failure-prediction and processing -scheme for preventive maintenance. *IEEE Trans. on Reliability*, 2003, 52(3): 373-383.
- 2 刘志仓.基于粒子滤波的非线性系统故障诊断与预测方法研究[硕士学位论文].西安:西安电子科技大学,2013.
- 3 Kim DY, Jeon M. Spatio-temporal auxiliary particle filtering with L1-norm-based appearance model learning for robust visual tracking. *IEEE Trans. on Image Processing*, 2013, 22(2): 511-522.
- 4 胡士强,敬忠良.粒子滤波算法综述.控制与决策,2005, 20(4):362-365,371.
- 5 张琪,胡昌华,乔玉坤,蔡艳宁.基于随机摄动粒子滤波器的故障预报算法.控制与决策,2009,24(2):284-288.
- 6 张磊,李行善,于劲松,代京.一种基于高斯混合模型粒子滤波的故障预测算法.航空学报,2009,30(2):319-324.
- 7 Xu Z, Ji Y, Zhou D. A new real-time reliability prediction method for dynamic systems based on on-line fault prediction. *IEEE Trans. on Reliability*, 2009, 58(3): 523-538.
- 8 Orchard M, Vachtsevanos G. A particle filtering approach for on-line fault diagnosis and failure prognosis. *Trans. of the Institute of Measurement and Control*, 2009, 31(3-4): 221-246.
- 9 Freitas ND. Rao-blackwellised particle filtering for fault diagnosis. *IEEE Aerospace Conference Proc.* 2002, 4. 1767-1772.
- 10 Xie XQ, Zhou DH, Jin YH. Strong tracking filter based adaptive generic model control. *Journal of Process Control*, 1999, 9(4): 337-350.
- 11 Doucet A, Godsill SJ, Andrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering. *Statistics and Computing*, 2000, 10(3): 197-208.
- 12 Tao W, Huang YF, Chen P. Particle filtering for adaptive sensor fault detection and identification. *Proc. of the 2006 IEEE Int. Conf. on Robotics and Automation*. Orlando. 2006. 3807-3812.
- 13 Djuric PM, Kotecha JH, Zhang JQ, et al. Particle filtering. *IEEE Signal Processing Magazine*, 2003, 20(5): 19-38.
- 14 Mo YW, Xiao DY. Evolutionary particle filter and its application. *Control Theory and Application*, 2005, 22(2): 269-270.
- 15 Chang C, Ansari R. Kernel particle filter for visual tracking. *IEEE Signal Processing Letters*, 2005, 12(3): 242-245.
- 16 Box GEP.时间序列分析:预测与控制.北京:中国统计出版社,1997.
- 17 Guida G, Mauri G. Evaluation performance and quality of knowledge-based systems: Foundation and methodology. *IEEE Trans. on Knowledge and Data Engineering*, 1993,5: 204-224.
- 18 吕勇.非线性时间序列分析在设备故障诊断中的应用研究[博士学位论文].北京:北京科技大学,2004.