

基于自适应粒子滤波的涡扇发动机 故障诊断

黄金泉^{1,2}, 冯 敏^{1,3}, 鲁 峰^{1,2,3}

- (1. 南京航空航天大学 能源与动力学院 江苏省航空动力系统重点实验室, 南京 210016;
2. 先进航空发动机协同创新中心, 北京 100191;
3. 中国航空工业集团公司 航空动力控制系统研究所, 江苏 无锡 214063)

摘 要: 针对涡扇发动机非线性、非高斯的特点, 提出了一种自适应的粒子滤波算法用于涡扇发动机气路部件突变故障的诊断. 为了减小算法的计算量并且保证滤波精度, 分析了滤波精度和样本数目的关系, 提出根据滤波过程中状态的方差自适应地调整粒子数, 在保证一定的滤波精度下可以有效地减少滤波过程中使用的粒子数, 提高了算法的实时性. 同时, 引入扩展卡尔曼滤波(EKF)用于更新粒子, 产生重要概率密度函数, 在一定程度上避免了粒子的退化. 通过某型涡扇发动机的仿真分析表明:改进的算法相比标准粒子滤波算法用于涡扇发动机气路部件故障诊断时, 参数估计的方均根误差减小了 50% 左右, 且算法的计算量减小了 30%.

关 键 词: 涡扇发动机; 故障诊断; 卡尔曼滤波; 粒子滤波; 自适应粒子滤波

中图分类号: V233.7

文献标志码: A

Turbo-fan engine fault diagnosis based on adaptive particle filtering

HUANG Jin-quan^{1,2}, FENG Min^{1,3}, LU Feng^{1,2,3}

- (1. Jiangsu Province Key Laboratory of Aerospace Power System, College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
2. Co-Innovation Center for Advanced Aero-Engine, Beijing 100191, China;
3. Aviation Motor Control System Institute, Aviation Industry Corporation of China, Wuxi Jiangsu 214063, China)

Abstract: An adaptive particle filter was proposed for the gas path component abrupt fault diagnosis of turbo-fan engine characterized by a nonlinear non-Gaussian system. In order to reduce the computational burden and ensure the filtering accuracy, the relation between the filtering accuracy and the sampling number was analyzed. The number of particles was adjusted in the filtering process according to the variance of the state variables. The proposed method could reduce the number of particles in the filtering process and computation time while guaranteed the filtering accuracy. The extended Kalman filter (EKF) was introduced to update the particles and generate the importance probability density function helping to avoid the particle degeneracy to some extent. A series of simulations on a turbo-fan engine indicates that the root mean square error of the improved particle filter for the turbo-fan engine fault diagnosis is reduced by 50% than the conventional particle filter, and the computational burden is also reduced by 30%.

收稿日期:2013-04-11

基金项目:国家自然科学基金(51276087);江苏省博后科学基金(201202063)

作者简介:黄金泉(1963-),男,江苏泰兴人,教授,博士,主要从事航空发动机建模、控制及故障诊断研究.

Key words: turbo-fan engine; fault diagnosis; Kalman filter; particle filter; adaptive particle filter

涡扇发动机结构复杂,工作环境恶劣多变,是一种多发故障机械.美国一项飞机调查结果显示,发动机故障占飞机总故障的36%,其中涡扇发动机气路部件故障约占涡扇发动机总体故障的90%以上.因此,为了使涡扇发动机安全可靠地运行,节省维修成本,就必须对关键部件实施在线监测与故障诊断^[1-3].涡扇发动机气路部件的效率、流量等性能参数的变化是涡扇发动机气路故障的状态特征,而这些性能参数的变化会直接导致发动机测量参数如转速、温度、压力等的变化,因此发动机气路部件故障诊断主要是通过测量参数的变化估计性能参数的变化,分析发动机气路部件的健康状况.主要有基于模型的方法(卡尔曼滤波算法^[4]、最小二乘算法等^[5])、基于数据的方法(神经网络^[6]、支持向量机^[7-8]等)和基于知识的方法(如专家系统).其中基于数据和基于知识的方法对发动机典型故障的数据和先验知识需求较多,而基于模型的气路部件故障诊断方法是以反映发动机气动热力学性质的物理方程为基础构建模型,在发动机整个性能变化空间能够实现较为精确的定量估计性能,相比于其他方法对故障数据的依赖性较小,因此在工程实际中得到了广泛的研究和应用.

线性卡尔曼滤波器具有良好的处理高斯白噪声能力和计算量小的特点,已在发动机气路部件故障诊断中获得了应用,但在对于发动机非线性对象的线性化建模过程中,会不可避免的引入二次建模误差,而且实际过程中系统的过程与测量噪声是非高斯的,因此线性卡尔曼滤波器的应用存在一定的局限性.扩展卡尔曼滤波(EKF)和无迹卡尔曼滤波(UKF)是两种常用非线性滤波方法.EKF主要是对非线性模型进行1阶近似,采用线性滤波理论求解非线性滤波问题,当非线性较强时,线性化误差会导致滤波精度降低甚至滤波发散.UKF不需要对非线性模型进行线性化,而是对状态向量的概率密度函数进行近似化,它比EKF能更好地逼近状态方程的非线性特性,具有更高的估计精度^[9-10].但是EKF和UKF均不适用于非高斯分布的系统,而粒子滤波(PF)对噪声分布特性没有要求,更加适用于处理发动机这种处于复杂噪声影响之下的非线性较强的系统.

粒子滤波是一种基于蒙特卡罗方法和递推贝

叶斯估计的统计滤波方法.其基本思想是:首先依据系统状态向量的经验条件分布,在状态空间中产生一组随机的粒子,然后根据测量不断调整粒子的权重和位置,通过调整后的粒子信息修正最初的经验条件分布.实质就是用粒子及其权重组成的离散随机测度去近似状态后验概率分布,且这种近似会随着粒子的数目趋于无穷多时收敛于真实后验概率分布^[11-12].

但是粒子滤波算法存在粒子退化、计算量大的主要问题^[13-16],本文在标准粒子滤波算法的基础上,提出根据滤波过程中状态的方差自适应地调整粒子的数目,以减小计算量,提高算法的实时性.同时,利用EKF更新粒子,产生重要密度函数,以避免粒子的退化.本文以某型涡扇发动机为研究对象,研究气路突变故障的粒子滤波诊断方法,并验证算法的有效性.

1 粒子滤波基本原理

粒子滤波算法最先由Gordon提出,是指通过寻找一组在状态空间传播的随机样本对概率密度函数进行近似,以样本均值代替积分运算,从而获得状态最小方差的估计过程.假设系统的状态空间模型为

$$\begin{cases} x_{k+1} = f(x_k, u_k) + \omega_k \\ z_k = h(x_k, u_k) + \nu_k \end{cases} \quad (1)$$

式中 ω_k 和 ν_k 分别为系统的过程噪声和测量噪声, x_k 代表系统在 k 时刻的状态变量, u_k 为系统在 k 时刻的输入量, z_k 为系统在 k 时刻的测量值.

假设已知动态系统的状态先验条件概率密度 $p(x_0)$,利用 $\{x_{0,k}^i, \omega_k^i\}_{i=1}^N$ 描述 k 时刻目标状态 x_k 的后验概率密度分布 $p(x_{0,k} | z_{1:k})$, $\{x_{0,k}^i; i=0, \dots, N\}$ 是对应权值 $\{\omega_k^i; i=0, \dots, N\}$ 的粒子集,其中 $x_{0,k} = \{x_j, j=0, \dots, k\}$ 是0到 k 时刻的状态集, N 为采样粒子数.权值归一化为 $\sum_i \omega_k^i = 1$,则 k 时刻目标状态的后验概率密度分布可离散加权为

$$p(x_{0,k} | z_{1:k}) \approx \sum_{i=1}^N \omega_k^i \delta(x_{0,k} - x_{0,k}^i) \quad (2)$$

其中权值通过重要采样法选择

$$\omega_k^i = \omega_{k-1}^i \frac{p(z_k | x_k^i) p(x_k | x_{k-1}^i)}{q(x_k^i | x_{k-1}^i, z_k)} \quad (3)$$

标准粒子滤波算法选择最易于实现的先验概率密度作为重要密度函数,即

$$q(x_k^i | x_{k-1}^i, z_k) = p(x_k^i | x_{k-1}^i) \quad (4)$$

则重要性权值简化为

$$w_k^i = w_{k-1}^i p(z_k | x_k^i) \quad (5)$$

将权值 w_k^i 归一化,后验概率密度 $p(x_k | z_{1:k})$ 可表示为

$$p(x_k | z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_k - x_k^i) \quad (6)$$

式中 $\delta(\cdot)$ 计算公式如下:

$$\delta(x_k - x_k^i) = \begin{cases} 1 & x_k = x_k^i \\ 0 & x_k \neq x_k^i \end{cases} \quad (7)$$

可见当 $N \rightarrow \infty$ 时,由大数定理即可保证式(6)逼近真实后验概率 $p(x_k | z_{1:k})$.

标准粒子滤波算法归纳如下:

1) 初始化.由先验条件概率密度 $p(x_0)$ 产生粒子群 $\{x_0^i\}_{i=1}^N$,所有粒子的权值均为 $\frac{1}{N}$.

2) 更新.在 k 时刻,更新粒子权值,并且归一化

$$w_k^i = w_{k-1}^i p(z_k | x_k^i); i = 1, 2, \dots, N \quad (8)$$

$$w_k^i = w_k^i / \left(\sum_{j=1}^N w_k^j \right) \quad (9)$$

则可得 k 时刻未知参数 x 的最小均方估计为

$$\hat{x}_k \approx \sum_{i=1}^N w_k^i x_k^i \quad (10)$$

3) 重采样.计算有效粒子数 $N_{\text{eff}} = \frac{1}{\sum_{i=1}^N (w^i)^2}$

判断是否进行重采样,当 $N_{\text{eff}} < N_{\text{th}}$,则进行重采样,否则直接进行下一步,不进行重采样, N_{th} 为阈值.

由于标准粒子滤波算法选择先验概率密度作为重要密度函数,没有考虑当前的测量值,从重要密度函数中取样得到的样本与从真实后验概率密度中采样得到的样本有较大偏差,在递推过程中,可能只有一个粒子有非零权值,其他粒子的权重很小,可以忽略,从而引起粒子退化现象,而且使用固定粒子数采样,算法计算量也较大.因此本文采用 EKF 产生建议分布,更新粒子,获得一个更好的重要密度函数,同时在分析样本数目和滤波精度关系的基础上,根据滤波过程中状态的方差自适应地调整粒子的数目,在保证滤波精度的前提下减小算法的计算量.

2 改进的粒子滤波算法

2.1 滤波精度和样本数的关系

为了得到滤波精度和样本数的关系,令滤波

过程中样本数为 N ,令 $X = \{x^i\}_{i=1}^N \sim p$ 为采样自量测概率的样本集,则基于样本 X 函数 f 的经验均值为

$$\hat{E}[f; X] = \frac{1}{N} \sum_{i=1}^N f(x^i) \quad (11)$$

假设 $f(x^i) \sim N(E_p[f(x)], \sigma^2(f, X))$, $\hat{E}[f; X]$ 为 $E_p[f(x)]$ 的无偏估计, $\sigma^2(f, X)$ 的无偏方差估计可表示为

$$\sigma_N^2(f, X) = \frac{1}{N} \sum_{i=1}^N [f(x^i) - \bar{f}]^2 \quad (12)$$

式中 $\bar{f} = \frac{1}{N} \sum_{i=1}^N f(x^i)$. 则

$$\frac{\hat{E}[f; X] - E_p[f(x)]}{\sigma_N(f, X) / \sqrt{N-1}} \sim t(N-1) \quad (13)$$

式中 $t(N-1)$ 为具有 $N-1$ 个自由度的 t 分布.给定正整数 N 和概率值 $1-\alpha$,可得到 $t_{\alpha/2}(N-1)$ 使得

$$P\left\{ \left| \frac{\hat{E}[f; X] - E_p[f(x)]}{\frac{\sigma_N(f, X)}{\sqrt{N}} t_{\alpha/2}(N-1)} \right| \geq 1 - \alpha \right\} \quad (14)$$

区间 $\left[E_p[f(x)] - \frac{\sigma_N(f, X)}{\sqrt{N}} t_{\alpha/2}(N-1), E_p[f(x)] + \frac{\sigma_N(f, X)}{\sqrt{N}} t_{\alpha/2}(N-1) \right]$ 为拥有从经验均

值 $\hat{E}[f; X]$ 中采样的概率为 $1-\alpha$ 的随机区间.当 $N \geq 45$ 时, $t_{\alpha/2}(N-1)$ 可以近似用正态分布的分位点 $r_{\alpha/2}$ 代替, $r_{\alpha/2}$ 可以从标准正态分布表里查取获得,则置信区间的长度为 $L = \frac{2\sigma_N(f, X)}{\sqrt{N}} r_{\alpha/2}$,由此可见,在特定的方差和置信度下,随着 N 的增加, L 是减小的.粒子数的下界可表示如下:

$$N \geq \frac{\sigma_N(f, X)}{(L/2r_{\alpha/2})^2} \quad (15)$$

由式(15)可知,粒子数 N 与函数 f 的方差成正比,而与 $(L/2r_{\alpha/2})^2$ 成反比,即给定参数 L, α 以及 k 时刻的方差,就可以得到粒子数的下限.

2.2 自适应粒子滤波算法

EKF 是一种常用的非线性滤波方法,主要通过原来的非线性系统进行 1 阶泰勒近似,得到近似线性化模型,然后用常规卡尔曼滤波方法进行滤波估计. EKF 结合最新时刻得到的测量值,通过高斯近似不断更新后验分布来实现递推估计,即在每一时刻按如下方式对后验概率密度进行近似

$$p(x_k | z_k) \approx N(\hat{x}_k, \hat{P}) \quad (16)$$

式中 \hat{x}_k 为 k 时刻的状态估计值, \hat{P} 为 k 时刻估计方差. 在粒子滤波算法中, 可以用 EKF 对每个粒子进行更新, 将最后得到的近似后验密度作为重要密度函数, 即

$$q(x_k^i | x_{k-1}^i, z_k) = N(\hat{x}_k^i, \hat{P}_k^i) \quad (17)$$

然后从重要密度函数中产生新的粒子, 进行权重更新后对粒子集进行重采样步骤, 这就是扩展卡尔曼粒子滤波(EKPF).

根据滤波过程中状态的方差自适应地调整粒子的数目, 需要考虑几种特殊情况:

1) 状态方差过小或者过大的情况. 考虑到不确定性, 状态方差过小时, 粒子数目就会变得很小, 此时利用蒙特卡罗方法进行仿真, 就会得到较差的滤波结果. 因此可以通过设定粒子数的下限来保证不会因为粒子数过小而导致算法性能变差, 例如设定 $N \geq 45, N_{\text{bottom}} = 45$. 同样, 状态方差过大时, 可以设定粒子数的上限为 N_{top} , 来保证粒子数不会趋向于无穷大.

2) 初始样本数的选择. 给定一个系统, 一旦噪声形式确定, 系统估计的偏差就确定了, 也就是说, 状态噪声会直接造成真值和实际测量值间的偏差, 随着时间的递推, 要使系统保持一定的滤波精度, 样本的数目必须自适应对应于各个状态的方差. 如果初始系统状态方差很大, 而初始样本数较小, 自适应调节过程会需要一个较长的时间. 因此, 考虑系统非线性特性和噪声形式, 初始样本数不宜过小.

利用 EKF 更新粒子, 根据状态方差自适应调节粒子数的粒子滤波算法(AEKPF)描述如下:

1) 参数初始化. 给出置信区间长度 L , 置信概率 α , 初始样本数 N_0 , 样本数的上下界 $N_{\text{top}}, N_{\text{bottom}}$. 从先验分布中产生样本 $x_k^i \sim p(x_0), \hat{p}_0^i = \text{var}(x_0), \omega_0^i = \frac{1}{N}; i = 1, 2, \dots, N_0$.

2) 用 EKF 更新粒子.

$$\begin{aligned} x_{k|k-1}^i &= f(x_{k-1}^i) \\ P_{k|k-1}^i &= F_k^i \hat{P}_{k-1}^i (F_k^i)^T + Q_{k-1} \\ K_k &= P_{k|k-1}^i (H_k^i)^T [H_k^i P_{k|k-1}^i (H_k^i)^T + R_k]^{-1} \\ \hat{x}_k^i &= \hat{x}_{k|k-1}^i + K_k [z_k - h(x_{k|k-1}^i)] \\ \hat{P}_k^i &= P_{k|k-1}^i - K_k H_k^i P_{k|k-1}^i \end{aligned} \quad (18)$$

更新产生粒子: $x_k^i \sim q(\hat{x}_k^i | x_{k-1}^i, z_k) = N(\hat{x}_k^i, \hat{P}_k^i)$

3) 计算重要性权重, 并且归一化权重.

$$\omega_k^i = \omega_{k-1}^i \frac{p(z_k | \hat{x}_k^i) p(\hat{x}_k^i | x_{k-1}^i)}{q(\hat{x}_k^i | x_{k-1}^i, z_k)}$$

$$\tilde{\omega}_k^i = \omega_k^i \left(\sum_{j=1}^{N_k} \omega_k^j \right)^{-1} \quad (19)$$

4) 重采样. 重采样策略可以提高样本有效数目, 在选择合适调整样本数的情况下, 重采样步骤对粒子滤波性能不会有很大影响, 这里选择多项式重采样.

5) 状态估计.

$$\hat{x}_k = \sum_{i=1}^N \tilde{\omega}_k^i x_k^i \quad (20)$$

6) 预测样本数. 计算状态的方差, 根据式(15)来计算样本数量 N_{k+1} . 转到第 2) 步.

3 基于粒子滤波的发动机故障诊断

以某型涡扇发动机为研究对象, 选取了风扇、压气机、高低压涡轮 4 个部件的效率和流量的变化系数共 8 个性能参数验证本文算法的估计性能. 基于粒子滤波算法的气路部件故障诊断原理如图 1 所示. 诊断原理实质就是通过涡扇发动机的输出值与模型预测值之间的残差对部件性能参数变化进行估计, 将涡扇发动机气路部件故障诊断转化为部件性能参数变化的状态估计问题.

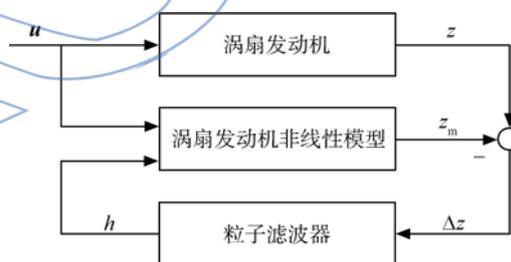


图 1 基于粒子滤波的涡扇发动机气路部件性能分析
Fig. 1 Turbo-fan engine gas path characteristics analysis based on particle filter

涡扇发动机非线性数学模型为

$$\begin{aligned} x_{k+1} &= f(x_k, u_k) + \omega_k \\ z_k &= h(x_k, u_k) + \nu_k \end{aligned} \quad (21)$$

式中控制量 $u = [W_f \ A_3]^T$, 分别为燃油量和尾喷管喉道面积. 状态量 $x = [N_1 \ N_h \ \Delta E_1 \ \Delta W_1 \ \Delta E_2 \ \Delta W_2 \ \Delta E_3 \ \Delta W_3 \ \Delta E_4 \ \Delta W_4]^T$, N_h, N_1 分别为涡扇发动机高低压转子转速, $\Delta E_1, \Delta W_1, \Delta E_2, \Delta W_2, \Delta E_3, \Delta W_3, \Delta E_4, \Delta W_4$ 分别为风扇、压气机、高低压涡轮 4 个部件的效率和流量的变化系数, 定义如下:

$$\begin{aligned} \Delta E_i &= \frac{E_i}{E_i^*} - 1 \quad i = 1, 2, 3, 4 \\ \Delta W_j &= \frac{W_j}{W_j^*} - 1 \quad j = 1, 2, 3, 4 \end{aligned} \quad (22)$$

式中 E_i, W_j 分别为各部件实际的效率和流量值, E_i^*, W_j^* 分别为各部件效率和流量的理想值. 测量值 $z = [N_1 \ N_h \ T_{22} \ p_{22} \ T_3 \ p_3 \ p_{43} \ T_5 \ p_5 \ p_6]^T$, 依次为低压转子转速、高压转子转速、风扇出口总温总压、压气机出口总温总压、高压涡轮出口总压、低压涡轮出口总温总压和内涵出口总压. ω_k 和 ν_k 假设都是服从高斯分布的白噪声, 即 $\omega \sim N(0, R), \nu \sim N(0, Q)$, 其中 $Q = 0.16 \times 10^{-4} I_{10 \times 10}, R = 0.09 \times 10^{-4} I_{10 \times 10}$. 工程实际中, 由于涡扇发动机工作环境复杂多变, 可能存在内部的干扰或者外部的入侵噪声^[17], 因此测量噪声和系统噪声不一定是高斯白噪声, 噪声的均值也不一定为零. 为了模拟这种形式的噪声, 本文选取了一种均值为 0.5, 方差为 1 的伽马分布的函数来模拟噪声, 即 $\omega \sim R * \Gamma(0.25, 0.50), \nu \sim Q * \Gamma(0.25, 0.50)$.

伽马分布的概率密度函数如下所示:

$$f(x) = \begin{cases} \lambda^r x^{r-1} e^{-\lambda x} [\Gamma(r)]^{-1} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

其中尺度参数 λ^{-1} 与形状参数 r 均为正实数, 其均值和方差分别为 $r\lambda^{-1}, r\lambda^{-2}$. 下面的仿真分析将分别在 Gaussian 噪声和非 Gaussian 噪声情况下验证算法的性能.

4 仿真与分析

在涡扇发动机地面工作点 $H=0, Ma=0, W_f=2.48 \text{ kg/s}, A_8=0.2597 \text{ m}^2$ 进行仿真验证, 分

别模拟涡扇发动机单部件故障和多部件同时故障的情况, 验证粒子滤波器的状态估计性能. 故障模式参考文献[18]. 单部件故障为在 2s 时压气机发生故障, E_2 下降 5% 同时 W_2 下降 8%. 多部件同时故障为 2s 时, E_1 下降 3%, W_2 下降 8% 同时 W_3 下降 2%. 分别采用 EKF, PF, AEKPF 对系统进行状态估计, 其中粒子滤波仿真的粒子数 N 取 100. AEKPF 仿真的初始粒子数取 100, 粒子数下限取 45, 粒子数上限取 150, α 取 0.05, 从标准正态分布表中查得 $r_{\alpha/2} = 1.96, L$ 经过多次仿真取 0.008 较合适. 仿真结果如图 2~图 3 所示, 估计精度与计算时间比较如表 1 所示, 限于篇幅, 仅给出一组粒子数的变化趋势图, 其中方均根误差 (root mean square error) 计算公式为

$$R_{\text{mse}} = \left[\frac{1}{S} \sum_{i=1}^S (x_i - \hat{x}_i)^2 \right]^{1/2}$$

S 为仿真步数.

从仿真结果可以看出, 在 Gaussian 噪声下, EKF 具有较高的估计精度, 改进后的粒子滤波算法比 PF 和 EKF 具有更高的估计精度. 粒子数自适应取得了良好的效果, 在状态方差较大时, 增大采样粒子数, 反之减小采样粒子数, 计算时间减小了 35% 左右, 计算时间指的是整个仿真过程 (共 500 个采样周期, 采样步长为 0.02s) 状态估计所需的时间. 粒子数的自适应能够使算法在保证一定的

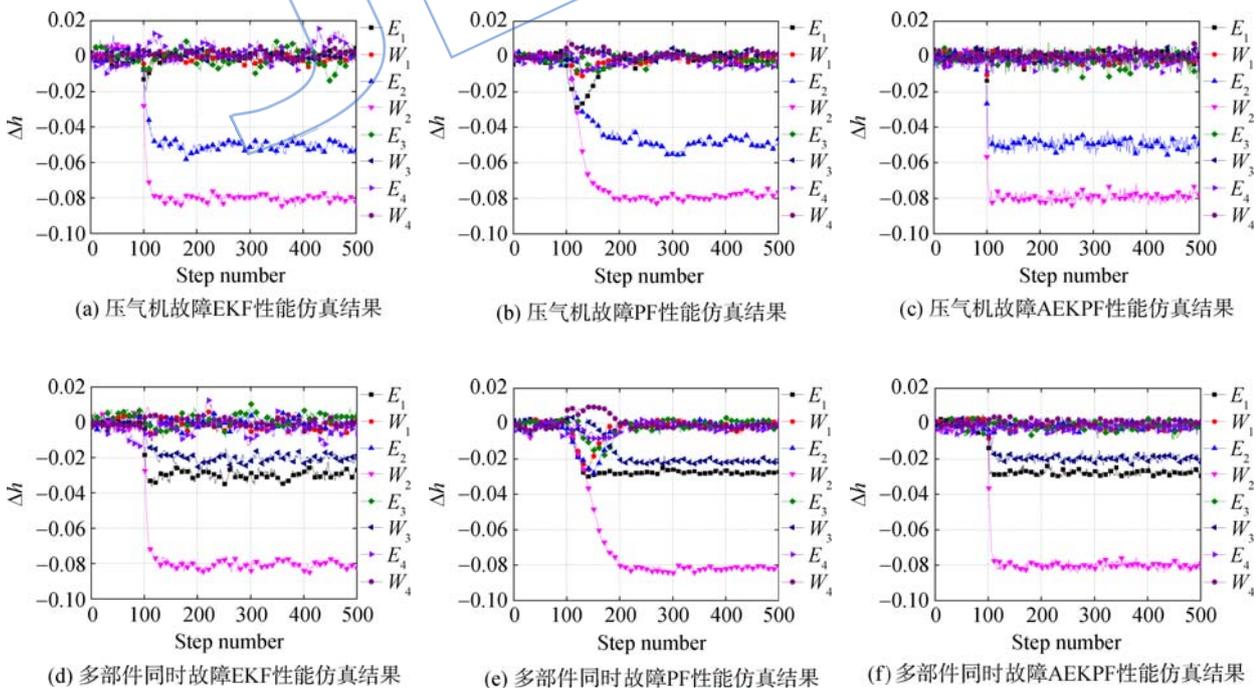


图 2 高斯噪声下地面工作点处 3 种算法的仿真结果

Fig. 2 Simulation results of three algorithms with Gaussian noise at the ground point

滤波精度下,根据滤波过程中状态的方差自适应的调整采样粒子的数目,从而有效地减小了算法的计算量,引入了 EKF 更新粒子,产生更好的重要密度函数,使先验条件概率密度分布朝着高似然度区域移动,提高了估计精度,而且估计出性能的突变几乎没有延迟,在故障发生后的 0.2 s 内就能检测出来,比 EKF 和 PF 都要快速,EKF 大约需要 0.4 s,粒子滤波则需要将近 2 s,进一步仿真表明,在本文假设的噪声基础上,部件性能发生 1% 以上的突变,算法能够很好地估计出性能的变化.但是和 EKF 相比,AEKPF 计算量仍然很大,在目前的硬件水平下,难以用于在线的故障诊断.

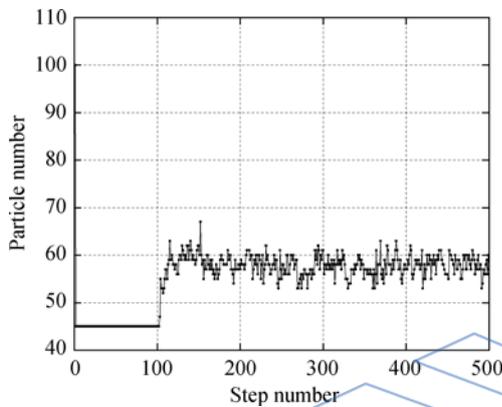


图 3 压气机故障下 AEKPF 估计过程中粒子数变化
Fig. 3 Trend of particle number during the estimation of compressor fault by AEKPF

表 1 高斯噪声下地面工作点处 3 种算法的性能对比
Table 1 Performance comparison of three algorithms with Gaussian noise at the ground point

算法	压气机故障		多部件同时故障	
	R_{mse}	计算时间/s	R_{mse}	计算时间/s
EKF	0.0293	1.15	0.0279	1.25
PF	0.0489	121	0.0503	118
AEKPF	0.0202	79	0.0203	69

为了验证算法在非高斯噪声下的性能,模拟同样的故障进行仿真验证.估计精度与计算时间比较如表 2 所示,仿真结果如图 4 所示.

表 2 非高斯噪声下地面工作点处 3 种算法的性能对比
Table 2 Performance comparison of three algorithms with non-Gaussian noise at the ground point

算法	压气机故障		多部件同时故障	
	R_{mse}	计算时间/s	R_{mse}	计算时间/s
EKF	0.0411	1	0.0417	1.15
PF	0.0504	118	0.0524	128
AEKPF	0.0213	78	0.0197	66

分析仿真结果可以看出:在非高斯噪声下,EKF 的估计精度明显下降,个别性能参数的估计存在较大的误差,均方根误差增加了 35% 左右,

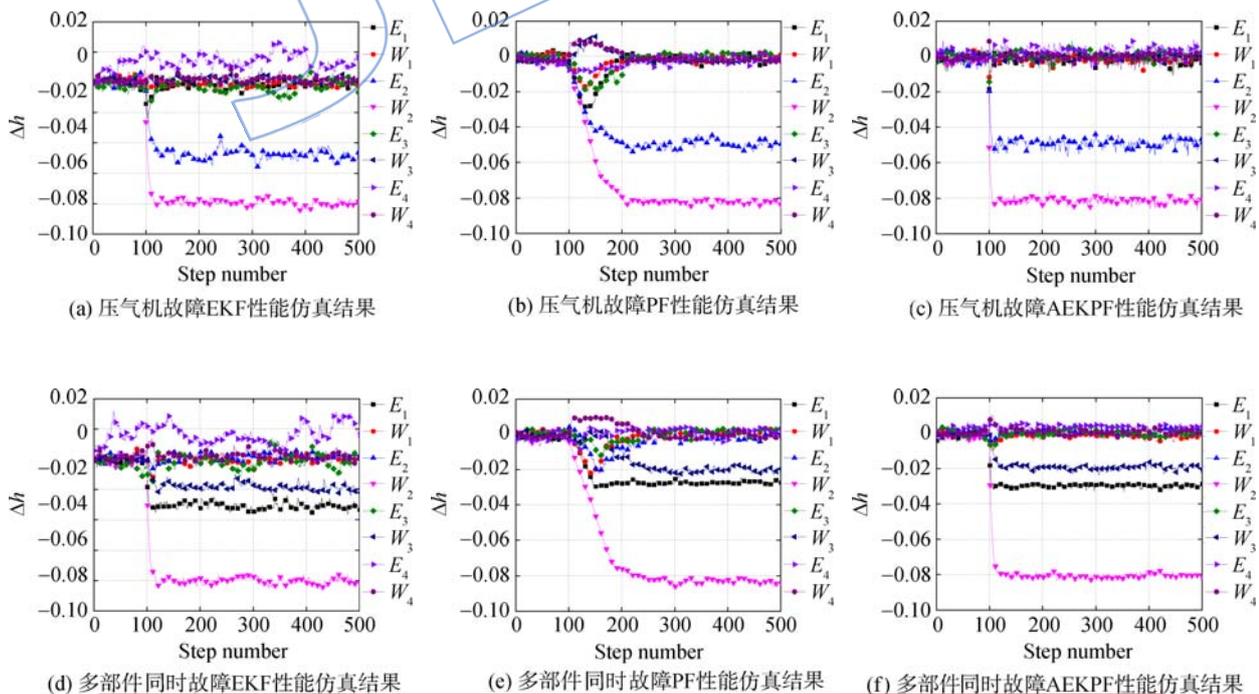


图 4 非高斯噪声下地面工作点处 3 种算法的仿真结果

Fig. 4 Simulation results of three algorithms with non-Gaussian noise at the ground point

而粒子滤波的估计精度略有下降,AEKPF 仍然保持着很高的估计精度,且计算时间较粒子滤波相比大幅缩短,说明本文提出的算法在非高斯噪声下仍然具有较好的适用性.进一步的仿真表明算法在高空工作点仍然具有良好的性能.

5 结论

1) 提出一种基于非线性模型的粒子滤波方法用于涡扇发动机气路突变故障的诊断.

2) 针对标准粒子滤波存在的粒子退化和计算量较大的问题,本文将 EKF 和粒子滤波结合,使用 EKF 更新粒子,产生一个更好的重要密度函数,根据滤波过程中状态的方差自适应地调整采样的粒子数,在保证滤波精度的基础上,减小了算法的计算量,提高了算法的实时性,为进一步的工程应用奠定了基础.

3) 粒子滤波方法相比于 EKF 对于噪声分布更加不敏感,尤其在噪声呈非高斯分布下,粒子滤波方法优势明显,但是粒子滤波的计算量很大,目前硬件水平下难以用于发动机故障的在线实时诊断.

参考文献:

- [1] Link C. Recent advancements in aircraft engine health management (EHM) technologies and recommendations for the next step[R]. ASME Paper GT2005-68625, 2005.
- [2] 姜彩虹,孙志岩,王曦. 航空发动机预测健康管理系统设计的关键技术[J]. 航空动力学报, 2009, 24(11): 2589-2594. JIANG Caihong, SUN Zhiyan, WANG Xi. Critical technologies for aero-engine prognostics and health management systems development [J]. Journal of Aerospace Power, 2009, 24(11): 2589-2594. (in Chinese)
- [3] 黄伟斌,黄金泉. 航空发动机故障诊断的机载自适应模型[J]. 航空动力学报, 2008, 23(3): 580-584. HUANG Weibin, HUANG Jinqun. On board self-tuning model for aero-engine fault diagnostics[J]. Journal of Aerospace Power, 2008, 23(3): 580-584. (in Chinese)
- [4] Dorel D L. Interpretation of weight-least-squares gas path analysis results[J]. Journal of Engineering Gas Turbines Power, 2005, 125(3): 624-633.
- [5] Simon D L, Garg S. Optimal tuner selection for Kalman filter-based aircraft engine performance estimation [R]. NASA/TM-2010-216076, 2010.
- [6] 江传尚,樊丁,马冲. 小波网络在某型航空发动机故障诊断中的应用[J]. 航空动力学报, 2009, 24(4): 892-895. JIANG Chuanshang, FAN Ding, MA Chong. Application of the wavelet network in fault diagnosis for some kind of aero-engine[J]. Journal of Aerospace Power, 2009, 24(4): 892-895. (in Chinese)
- [7] 尉询楷,陆波,汪诚,等. 支持向量机在航空发动机故障诊断中的应用[J]. 航空动力学报, 2004, 19(6): 844-848. WEI Xunkai, LU Bo, WANG Cheng, et al. Application of support vector machines to aeroengine fault diagnosis[J]. Journal of Aerospace Power, 2004, 19(6): 844-848. (in Chinese)
- [8] 徐启华,师军. 基于支持向量机的航空发动机故障诊断[J]. 航空动力学报, 2005, 20(2): 298-302. XU Qihua, SHI Jun. Aero-engine fault diagnosis based on support vector machine[J]. Journal of Aerospace Power, 2005, 20(2): 298-302. (in Chinese)
- [9] Christophe B, Laurent T, Jean G. EKF and particle filter track to track fusion: a quantitative comparison from radar/lidar obstacle tracks[R]. Philadelphia, PA: 8th International Conference on Information Fusion (FUSION), 2005.
- [10] Simon J, Jeffrey K U. Unscented filtering and nonlinear estimation[J]. Proceedings of IEEE, 2004, 92(3): 401-422.
- [11] 朱志宇. 粒子滤波算法及其应用[M]. 北京: 科学出版社, 2010.
- [12] Gordon N J, Salmond D J, Smith A F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation[J]. Proceedings of IEEE, 1993, 140(2): 107-113.
- [13] LU Feng, HUANG Jinqun, LÜ Yiqiu. Gas path health monitoring for a turbofan engine based on nonlinear filtering approach[J]. Energies, 2013, 6(1): 492-513.
- [14] ZHANG Gongyuan, CHENG Yongmei, YANG Feng, et al. Design of an adaptive particle filter based on variance reduction technique[J]. Acta Automatica Sinica, 2010, 36(7): 1020-1024.
- [15] Jayesh H K, Petar M D. Gaussian particle filtering[J]. IEEE Transactions on Signal Processing, 2003, 51(10): 2592-2601.
- [16] Fox D. Adapting the sample size in particle filters through KLD-sample[D]. Washington: University of Washington, 2003.
- [17] 李文峰,王永生,杨纪明,等. 航空发动机测试信号噪声分析[J]. 航空动力学报, 2005, 20(5): 900-904. LI Wenfeng, WANG Yongsheng, YANG Jiming, et al. Noise characteristics analysis of aero-engine testing signals [J]. Journal of Aerospace Power, 2005, 20(5): 900-904. (in Chinese)
- [18] Borguet S, Leonard O. Comparison of adaptive filters for gas turbine performance monitoring[J]. Journal of Computational and Applied Mathematics, 2010, 234(7): 2202-2212.