

航空发动机气路故障诊断的 SANNWA-PF 算法

许梦阳¹, 黄金泉^{1,2}, 鲁 峰^{1,2}

- (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)

摘 要: 针对航空发动机非线性、非高斯的特点,提出一种用于航空发动机气路故障诊断的自适应神经网络权值调整粒子滤波(SANNWA-PF)算法。该算法根据粒子分布情况确定分裂和调整的粒子数目,进而根据粒子权重采用正态分布的方式进行分裂,采用反向传播(BP)神经网络进行权值调整,缓解了粒子的退化和贫化,具有更强的自适应性能和跟踪能力。通过一维非线性跟踪模型和航空发动机气路故障诊断仿真研究表明:SANNWA-PF 算法具有良好的非高斯性能,相对粒子滤波一维非线性追踪模型估计精度提高约 21%,航空发动机气路故障诊断在高斯噪声和非高斯噪声下分别提高约 30%和 26%,诊断速度分别提高约 7 倍和 10 倍。

关 键 词: 航空发动机; 故障诊断; 粒子滤波; 自适应; 神经网络; 非高斯噪声

中图分类号: V233.7

文献标志码: A

SANNWA-PF algorithm of aero-engine gas path fault diagnosis

XU Mengyang¹, HUANG Jinquan^{1,2}, LU Feng^{1,2}

- (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. Collaborative Innovation Center for Advanced Aero-Engine, Beijing 100191, China)

Abstract: A self-adaptive neural network weight adjustment particle filter algorithm was proposed for aero-engine gas path fault diagnosis of the nonlinear and non-Gaussian properties of aero-engine. Number of particles split and adjusted was determined by the distribution of particles. Then particles were split by the way of normal distribution and adjusted by back propagation (BP) neural network, which avoided the degradation and impoverishment of particles and had stronger self-adaptive and tracking ability. The simulation results of one-dimensional nonlinear tracking model and aero-engine gas path fault diagnosis show that self-adaptive neural network weight adjustment-particle filter (SANNWA-PF) algorithm has a good non-Gaussian performance. Compared with normal particle filter, SANNWA-PF improved 21% in accuracy of one-dimensional nonlinear tracking model, 30% with

收稿日期:2016-03-07

基金项目:国家自然科学基金(51276087); 国家自然科学基金青年基金(61304133);
南京航空航天大学研究生创新基地(实验室)开放基金(kfj20160211)

作者简介:许梦阳(1991—),男,硕士,主要从事航空发动机控制与故障诊断研究。

通讯作者:黄金泉(1963—),男,教授、博士生导师,博士,主要从事航空发动机建模、控制及故障诊断研究。

引用格式:许梦阳,黄金泉,鲁峰.航空发动机气路故障诊断的 SANNWA-PF 算法[J].航空动力学报,2017,32(10):2516-2525. XU Mengyang, HUANG Jinquan, LU Feng. SANNWA-PF algorithm of aero-engine gas path fault diagnosis[J]. Journal of Aerospace Power, 2017, 32(10): 2516-2525.

Gaussian noise and 26% with non-Gaussian noise in aero-engine gas path fault diagnosis; and the diagnosis speed improved about 7 times with Gaussian noise and 10 times with non-Gaussian noise.

Key words: aero-engine; fault diagnosis; particle filter; self-adaptive; neural network; non-Gaussian noise

在航空发动机故障中,气路故障占 90% 以上。因此,气路故障诊断在发动机健康管理中占有重要地位^[1-2]。航空发动机气路故障诊断通常有 3 种途径:基于模型的故障诊断^[3-5],基于数据的故障诊断^[6]和基于知识的故障诊断。后两者需要较多先验知识,而基于模型的故障诊断方法以反映发动机气动热力过程的模型为基础,相对另外两种途径需要先验知识较少,因此得到了广泛的研究。

卡尔曼滤波作为一种线性高斯滤波方法,用于非线性系统状态估计,需要将模型线性化,建模误差会影响估计精度,具有一定的局限性。为了提高滤波精度,在卡尔曼滤波的基础上提出了扩展卡尔曼滤波(EKF)和无迹卡尔曼滤波^[7](UKF)两种非线性滤波方法,EKF 对非线性模型进行近似处理,UKF 不对模型进行近似处理,对状态向量的概率密度进行近似处理,具有更高的滤波精度,但是两者都是针对高斯系统设计的,对于非高斯系统滤波精度会大幅下降^[8-9]。粒子滤波算法作为一种非线性、非高斯滤波算法能够较好地应用于非线性、非高斯系统的状态估计问题。Hammersley、Gordon 等为了克服序贯重采样方法样本退化的问题,引入了重采样技术,提出了基本粒子滤波算法^[10-11]。基本粒子滤波算法存在粒子退化、贫化,重要密度函数中没有观测信息等问题^[12-14],针对粒子退化等缺点神经网络权值调整粒子滤波(NNWA-PF)算法增加了分裂和调整两个操作,在一定程度上避免了粒子退化,部分粒子使用了观测信息,但是其操作个数一定,不具有自适应性,且复制操作会加剧粒子贫化^[15-16]。

本文针对粒子滤波算法存在退化和贫化、重要密度函数没有观测信息,对航空发动机突变故障反应迟缓和 NNWA-PF 算法不具有自适应性及粒子贫化等问题,提出一种自适应神经网络权值调整粒子滤波算法,通过一维非线性跟踪模型和航空发动机气路故障诊断验证算法的有效性。

1 神经网络权值调整粒子滤波原理

粒子滤波采用序贯 Monte Carlo 方法来解决

非线性非高斯动态系统的状态估计问题,其思想是用一组加权随机样本来逼近待估计状态的后验概率密度函数。动态系统的状态空间描述如下:

$$\begin{cases} \mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \boldsymbol{\omega}_{k-1} \\ \mathbf{z}_k = h(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k \end{cases} \quad (1)$$

式中 $f(\cdot)$ 、 $h(\cdot)$ 均为非线性函数; $\mathbf{u}_k$ 、 $\mathbf{x}_k$ 、 $\mathbf{z}_k$ 分别为 k 时刻的系统输入、系统状态及观测值; $\boldsymbol{\omega}_k$ 、 $\mathbf{v}_k$ 分别为 k 时刻的过程噪声和观测噪声。

从贝叶斯估计的角度来看,状态估计问题实质上是概率推理过程,利用贝叶斯公式求解后验概率密度 $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ 。贝叶斯滤波包含预测和更新两个过程,预测是采用起始时刻到 $k-1$ 时刻的观测值 $\mathbf{z}_{1:k-1}$ 来推导先验概率密度函数 $p(\mathbf{x}_k | \mathbf{z}_{1:k-1})$,更新过程采用当前时刻的观测值对预测过程得到的先验概率密度函数进行修正,得到 k 时刻的后验概率密度函数 $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ 。这两个过程构成了一个由 $k-1$ 时刻后验概率密度函数计算 k 时刻后验概率密度函数 $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ 的递推过程。由于求解概率密度函数的积分运算很难实现,不易得到解析解。粒子滤波则将 Monte Carlo 方法引入贝叶斯估计形成序贯 Monte Carlo 方法,通过一系列加权粒子来近似状态的后验概率密度函数。

基本粒子滤波存在权值退化和粒子贫化等缺点,对估计精度存在较大的影响。神经网络权值调整粒子滤波算法在基本粒子滤波算法的基础上增加了分裂和调整两个操作,其算法流程如下:

- 1) 初始化。对于 $i=1, 2, \dots, N$, 由先验信息 $p(\mathbf{x}_0)$ 初始化等权值粒子状态 $\{\mathbf{x}_0^i, \mathbf{w}_0^i\}_{i=1}^N$, 其中 $\mathbf{w}_0^i = 1/N$ 。
- 2) 重要性采样。对于 $i=1, 2, \dots, N$, 从重要性密度函数 $q(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{z}_k)$ 中采样获得新粒子 $\{\mathbf{x}_k^i, \mathbf{w}_k^i\}_{i=1}^N$ 。
- 3) 权值更新。根据当前观测值 y_k 计算粒子权值

$$\mathbf{w}_k^i = \mathbf{w}_{k-1}^i \frac{p(\mathbf{z}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_k)} \quad (2)$$

基本粒子滤波中重要密度函数选取为

$$q(\mathbf{x}_k | \mathbf{x}_{k-1}^i, y_k) = p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i) \quad (3)$$

归一化如下：

$$\tilde{w}_k^i = w_k^i / \sum_{i=1}^N w_k^i \quad (4)$$

4) 粒子分裂。将粒子集中的粒子按权值大小进行降序排列,记排序后的粒子集为 $\{x_k^i, \tilde{w}_k^i\}_{i=1}^N$,分裂操作是将权值最大的 m 个粒子分裂,权值减半,同时为了保持粒子数目不变,剔除 m 个权值最小的粒子,分裂后的粒子集则为

$$\left\{x_k^i, \frac{1}{2}\tilde{w}_k^i\right\}_{i=1}^m \cup \left\{x_k^i, \frac{1}{2}\tilde{w}_k^i\right\}_{i=1}^m \cup \{x_k^i, \tilde{w}_k^i\}_{i=m+1}^{N-m} \quad (5)$$

5) 神经网络权值调整。对粒子集中权值最小的 m 个粒子采用反向传播(BP)神经网络进行权值调整。设误差能量定义为

$$\epsilon = \frac{1}{2} \sum_{i=1}^m (z_i - y_i)^2 = \frac{1}{2} \sum_{i=1}^m e_i^2 \quad (6)$$

式中 $i=1,2,\cdots,m$ 。 m 为输入/输出神经元数量; z_i 为目标值,即系统在该时刻的量测值; y_i 为神经网络输出。

调整结构如图 1 所示,图中 r 为状态维数, n 为测量输出维数,输入数据为具有较小权值的粒子,其较小的权值被设定为 BP 神经网络的输入,粒子的状态值作为神经网络的初始权值,其余粒子状态值作为相应神经元的偏移,样本学习函数为系统的量测方程。




图 1 神经网络权值调整结构图

Fig. 1 Structure of neural network weight adjustment

6) 再次利用式(4)对权值进行归一化。

7) 状态估计 估计表达式为

$$\hat{x}_k = \sum_{i=1}^N \tilde{w}_k^i x_k^i \quad (7)$$

8) 重采样 计算有效粒子数 N_{eff}

$$N_{\text{eff}} = \frac{1}{\sum_{i=1}^N \tilde{w}_k^{i2}} \quad (8)$$

如有必要进行重采样。

2 自适应神经网络权值调整算法

NNWA-PF 算法通过分裂和调整两个操作使粒子分布更接近真实状态,但是分裂操作对粒子进行简单的复制和权值减半,改变了粒子相对权值大小,降低了最接近真实状态的粒子在状态估计中的贡献,同时也降低了粒子的多样性,在一定程度上会加剧粒子的退化,复制操作降低了粒子的多样性,加剧了粒子的贫化。此外,该算法在每个时刻分裂和调整的粒子个数一定,但是粒子在每个时刻分布的情况不尽相同,粒子权值分布特别均匀和特别分散时,调整操作不会大幅提高小权值粒子的权值,这两种情形下操作效果均不明显,增大了计算量。

2.1 自适应确定操作粒子数

由于粒子总数目一定,且在进行操作之前对权值进行了归一化,为了使每一步的计算更具有针对性,设置能反映粒子权值分布的小权值阈值 w_{th} 和操作粒子数目上限 m_{max} 来计算操作粒子数目,在每一时刻进行两个操作前,先统计粒子集中权值满足 $w_k^i < w_{\text{th}}$ 的个数 m_0 ,则操作粒子数目根据下式确定:

$$m_k = \begin{cases} m_0 & m_0 < m_{\text{max}} \\ m_{\text{max}} & m_0 \geq m_{\text{max}} \end{cases} \quad (9)$$

式中 m_k 为 k 时刻操作粒子数目。

2.2 正态分布分裂粒子

重采样和复制操作两者本质上都简单复制高权值粒子,难免使得粒子的多样性降低,带来了粒子贫化的问题。由于权值大的粒子更接近真实状态,为了提高粒子的多样性,区分每个操作粒子与真实状态的接近程度,本文根据权值大小确定每个粒子分裂的粒子数目,并采取正态分布的方式进行分裂。

在确定 m_k 后,取权值最大的 $q_k = \left\lceil \frac{m_k}{2} \right\rceil$ (其中 $\lceil \cdot \rceil$ 表示向上取整)个粒子采取正态分布的方式按照权值大小进行分裂^[17],相应地剔除权值最小的 q_k 个粒子。首先将权值最大的 q_k 个粒子权值归一化

$$v_k^i = w_k^i / \sum_{j=1}^{q_k} w_k^j; \quad i = 1, 2, \cdots, q_k \quad (10)$$

计算每个粒子待分裂的粒子个数

$$c_k^i = \lceil m_k v_k^i \rceil; \quad i = 1, 2, \cdots, q_k \quad (11)$$

式中 $\lceil \cdot \rceil$ 表示四舍五入取整。

对于每一个粒子,按下式正态分布的方式进行分裂

$$\{x_{ki}^j\}_{j=1}^{c_i} \sim N(x_k^i, \delta^2); \quad i = 1, 2, \dots, q_k \quad (12)$$

在得到 m_k 个分裂后的粒子后需要重新计算它们的权值,这部分粒子组成的集合为 $\{x_{ki}^j, w_{ki}^j\}_{j=1}^{c_i}, i = 1, 2, \dots, q_k$, 此时粒子集合为 $\{x_k^j, w_k^j\}_{j=1}^{N-m} \cup \{x_{ki}^j, w_{ki}^j\}_{j=1}^{c_i}, i = 1, 2, \dots, q_k$ 。重新将权值进行归一化,进行状态估计。SANNWA-PF 算法流程图如图 2 所示。



图 2 SANNWA-PF 算法流程图

Fig. 2 Flow diagram of SANNWA-PF algorithm

3 算例仿真及讨论

3.1 一维非线性追踪模型仿真

一维非线性追踪模型作为一个具有很强非线性的模型,通常用于检验非线性滤波算法^[15]。其状态方程和测量方程为

$$\begin{cases} x_{k+1} = 0.5x_k + \frac{25x_k}{1+x_k^2} + 8\cos[1.2(k-1)] + \omega_k \\ y_{k+1} = \frac{(x_{k+1})^2}{20} + v_{k+1} \end{cases} \quad (13)$$

式中过程噪声 $\omega_k \sim N(0, 1)$, 测量噪声 $v_k \sim N(0, 1)$ 。

分别采用 PF 算法、NNWA-PF 算法和本文提出的 SANNWA-PF 算法取 100 个时刻进行仿真,粒子数目 N 均取 50;在 NNWA-PF 算法中,操作粒子数目取 7;在 SANNWA-PF 算法中,权值阈值 w_{th} 取 0.005,操作粒子数目上限 m_{max} 取 10,取 $x_0 = 0$ 。仿真结果如图 3 所示,通过图 3 可以看出 PF 算法在第 20 时刻到第 30 时刻估计结果不佳,而 NNWA-PF 算法和 SANNWA-PF 算法估计结果较好。




图 3 一维非线性追踪模型估计结果

Fig. 3 Simulation results of one-dimensional nonlinear tracking model

表 1 从计算时间、均方误差和平均有效粒子数 3 个方面对上述 3 种算法进行比较。均方误差和平均有效粒子数的定义分别为

$$E_{rms} = \left[\frac{1}{M} \sum_{i=1}^M (x_i - \hat{x}_i)^2 \right]^{1/2} \quad (14)$$

$$N_{eff} = \frac{1}{M} \sum_{i=1}^M \frac{1}{\sum_{j=1}^N (w_j^i)^2} \quad (15)$$

表 1 3 种算法比较

Table 1 Comparison of three algorithms

算法	计算 时间/ms	E_{rms}	平均有效 粒子数
PF	47.83	4.044 0	29.070 8
NNWA-PF	59.98	3.671 2	34.336 1
SANNWA-PF	62.86	3.352 5	32.563 9

式中 E_{rms} 为方均误差, M 为采样点个数, N_{eff} 为平均有效粒子数, N 为粒子数目, w_i^j 为 i 时刻第 j 个粒子的权值。平均有效粒子数目越小, 表明粒子退化越严重。

通过表 1 可以看出 NNWA-PF 算法相对 PF 算法来说虽然计算量有所增加, 但其估计精度也有较大提高, 提高了约 21%, 而 SANNWA-PF 算法相对 NNWA-PF 算法来说计算量增加很小, 但是精度有较大幅度的提高。在 SANNWA-PF 算法中, 100 个时刻的操作粒子数目均值为 6.970, 和 NNWA-PF 算法中固定的操作粒子数目十分接近, 因此计算量没有大幅度提高。此外, SANNWA-PF 算法和 NNWA-PF 算法相对 PF 算法有效粒子数目有所提高, 表明改进算法在一定程度上缓解了粒子退化的程度。

3.2 参数选取讨论

3.2.1 粒子数与均方误差的关系

对于 3 种算法, 分别选取粒子数目 N 为 25、50、75 和 100 进行仿真, 比较其均方误差, 结果如图 4 所示。




图 4 不同粒子数下 3 种算法 RMSE 比较
Fig. 4 RMSE comparison of three algorithms with different numbers of particles

通过图 2 可以看出, PF 算法在粒子数目增加到 100 时的估计精度仍然不如 SANNWA-PF 算法粒子数目为 50 时的估计精度, 进一步说明了该算法的优越性, 虽然每一步的计算时间有所增加, 但是其估计精度提高幅度很大。此外, 随着粒子数目增加, 滤波精度提高, 但是粒子数目越多, 提高幅度越小。

3.2.2 m_{max} 与估计精度和计算时间的关系

前文 SANNWA-PF 算法中操作粒子数目上限 m_{max} 均取 10, 本节研究不同的 m_{max} 与均方误差

的关系。操作粒子数目上限 m_{max} 分别为 6、8、10、12 和 14 进行仿真研究, 结果如图 5 所示。




图 5 SANNWA-PF 算法中 RMSE 和计算时间随 m_{max} 变化曲线
Fig. 5 Variation curve of RMSE and computation time with m_{max} of SANNWA-PF

通过图 3 可以看出, 随着 m_{max} 的增加, 计算时间增加, 相应地, 估计精度也有所提高, 但是当 m_{max} 越大时, 估计精度随 m_{max} 的提高程度变小。因此, 在实际应用中并不是 m_{max} 越大越好, 需要综合计算时间和估计精度两方面确定 m_{max} 。

4 航空发动机气路故障诊断

4.1 诊断原理

在对航空发动机气路故障进行评估过程中, 对风扇、压气机和高低压涡轮 4 个旋转部件设置流量和效率参数, 用下式的健康参数来描述气路部件的健康状态:

$$\begin{cases} S_{ei} = \eta_i / \eta_i^* \\ S_{wi} = W_i / W_i^* \end{cases} \quad i = 1, 2, 3, 4 \quad (16)$$

式中 η_i 、 W_i 分别为部件效率和流量的实际值; η_i^* 、 W_i^* 分别为部件没有发生故障时的效率和流量。无故障时, 健康参数为 1, 当健康参数不为 1 时, 表明相关气路部件产生性能蜕化。由于发动机的性能蜕化无法直接测量, 故将式(15)中的健康参数作为状态量进行建模, 采用滤波估计的手段进行气路故障诊断。

本文以某型涡扇发动机为研究对象, 选取 4 个旋转部件的效率和流量变化系数 8 个性能参数, 分别在高斯噪声和非高斯噪声下比较上述 3 种算法和扩展卡尔曼滤波算法的估计性能。基于粒子滤波的航空发动机气路故障诊断原理如图 6 所示, 通过涡扇发动机的输出值与模型预测值的残差对部件性能参数变化进行估计, 将航空发动




图 6 基于 SANNWA-PF 算法的航空发动机气路故障诊断原理图

Fig. 6 Principle diagram of aero-engine gas path fault diagnosis based on SANNWA-PF

机气路故障诊断转化为部件性能参数变化的状态估计问题^[3-5]。

为了基于图 6 实现航空发动机气路故障诊断,需要建立状态量包含健康参数的数学模型,设置状态量为 $\mathbf{x}=[\mathbf{x}_1^T \quad \mathbf{x}_2^T]^T$,其中 $\mathbf{x}_1=[N_1 \quad N_h]^T$ 分别表示低、高压转子转速, $\mathbf{x}_2=[S_{e1} \quad S_{w1} \quad S_{e2} \quad S_{w2} \quad S_{e3} \quad S_{w3} \quad S_{e4} \quad S_{w4}]^T$ 分别表示风扇、压气机及高、低压涡轮 4 个旋转部件的效率和流量变化系数,诊断模型描述为

$$\begin{cases} \mathbf{x}_k = [f^T(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) & \mathbf{x}_{2,k-1}^T]^T + \boldsymbol{\omega}_{k-1} \\ \mathbf{z}_k = g(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k \end{cases} \quad (17)$$

式中 $g(\cdot)$ 为航空发动机非线性模型;控制量 $\mathbf{u}=[W_{fb} \quad A_8]^T$ 分别为主燃油量和尾喷面积;测量值 $\mathbf{z}=[N_1 \quad N_h \quad T_{22} \quad p_{22} \quad T_3 \quad p_3 \quad T_{43} \quad p_{43} \quad T_5 \quad p_5]^T$ 分别为低压转子、高压转子转速、风扇出口总温总压、压气机出口总温总压、高压涡轮出口总温总压和低压涡轮出口总温总压; $\boldsymbol{\omega}$ 和 $\mathbf{v}$ 分别为过程噪声和测量噪声。采用 SANNWA-PF 算法对式(16)的模型中的状态进行估计,实时跟踪健康参数,通过对健康参数变化情况的分析达到

航空发动机气路故障诊断的目的。

4.2 高斯噪声下的故障诊断

本文选取两种故障模式进行仿真研究,模式 1 为 2 s 时刻压气机的单部件故障,表现为 S_{w2} 下降 8%;模式 2 为 2 s 时刻风扇、压气机和高压涡轮同时发生的多部件故障,表现为 S_{w1} 下降 2%、 S_{w2} 下降 8%以及 S_{w3} 增加 1%^[18]。 $\boldsymbol{\omega}$ 和 $\mathbf{v}$ 为互不相关的高斯白噪声, $\boldsymbol{\omega} \sim N(0, \mathbf{Q})$, $\mathbf{v} \sim N(0, \mathbf{R})$,取 $\mathbf{Q}=0.004^2 \mathbf{I}$, $\mathbf{R}=0.003^2 \mathbf{I}$ ^[19]。

表 2 给出了 EKF 算法、PF 算法、NNWA-PF 算法和 SANNWA-PF 算法的均方误差、计算时间和故障诊断时间。采用 4 种算法进行仿真,仿真步长为 0.025 s,仿真时间为 10 s,故障模式 1、故障模式 2 的仿真结果分别如图 7、图 8 所示。故障诊断时间的计算如下:

$$\Delta t = t_s - t_f \quad (18)$$

式中 Δt 为故障诊断时间, t_s 为估计值连续两个采样点在故障状态 ± 0.005 以内的时刻, t_f 为故障发生时刻。

表 2 高斯噪声下 4 种算法故障诊断结果对比

Table 2 Comparisons of fault diagnosis with Gaussian noise based on four algorithms

算法	故障模式 1			故障模式 2		
	E_{rms}	计算时间/s	故障诊断时间/s	E_{rms}	计算时间/s	故障诊断时间/s
EKF	0.0478	0.14	0.125	0.0482	0.14	0.150
PF	0.0503	6.81	1.200	0.0506	6.79	1.250
NNWA-PF	0.0445	8.07	0.850	0.0452	8.05	0.825
SANNWA-PF	0.0386	9.42	0.175	0.0394	9.48	0.150




图 7 高斯噪声下单部件故障诊断结果

Fig. 7 Single component fault diagnosis results with Gaussian noise




图 8 高斯噪声下多部件故障诊断结果

Fig. 8 Multiple components fault diagnosis results with Gaussian noise

通过图 7、图 8 和表 2 可以看出,在高斯噪声下,对于单部件故障,4 种算法都可以进行较好的诊断,但是对于多部件故障来说,EKF 算法中参数波动较大,PF 算法中高压涡轮效率漂移比较严重。从估计精度的角度上来说,EKF 算法和 PF 算法的均方误差较大,NNWA-PF 算法次之,SANNWA-PF 算法的均方误差最小,估计精度相对 PF 提高了约 30%,因为 EKF 算法虽然是一种非线性滤波方法,但其在对非线性模型线性化的过程中采用泰勒展开忽略高阶项,带来了一定的建模误差,进而影响估计精度,而 PF 算法存在比较严重的粒子退化和贫化,对估计精度造成影响,NNWA-PF 算法由于部分粒子的两个操作使得粒子退化和贫化得到缓解,提高了估计精度,SANNWA-PF 算法则具有自适应特性且采用正态分布的方式取代直接复制的方式进行分裂,进一步缓解了粒子的退化和贫化;从故障诊断时间角度来说,EKF 算法和 SANNWA-PF 算法的故障诊断时间较短,能够较快地诊断出气路部件的突变故障,而 PF 算法的故障诊断时间最长,这是由于 PF 算法的重要密度函数为状态转移函数,不包含最新观测信息,在发生突变故障的时刻,粒子只能逐步接近真实状态,而不能根据观测信息快速接近真实状态,NNWA-PF 算法中一部分粒子在神经网络权值调整环节加入了观测信息,加快了粒子转移速度,进而加快了突变故障诊断速度,在突变故障时刻,粒子退化十分严重,SANNWA-PF 算法则可以通过判断粒子分布情况对更多粒子进行操作,进一步提高突变故障诊断速度。在计算时间方面,SANNWA-PF 算法由于两个操作的引入使得计算复杂度有所增加,但是仍

然满足实时性要求,可以用于航空发动机气路故障在线诊断。

4.3 非高斯噪声下的故障诊断

航空发动机是一个复杂的非线性、非高斯系统,其过程噪声和测量噪声通常包含高斯白噪声和有色噪声。为了研究非高斯噪声下各滤波算法的诊断效果,本文选取均值为 0.5,方差为 1 的伽马分布函数来模拟航空发动机真实工作状态下的噪声情况,取 $\omega \sim Q * \Gamma(0.25, 0.50)$, $v \sim R * \Gamma(0.25, 0.50)$ 。伽马分布的概率密度函数为

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

(19)

式中,尺度参数 λ^{-1} 和形状参数 r 均为正实数,期望为 $r\lambda^{-1}$,方差为 $r\lambda^{-2}$ 。采用 EKF 算法、PF 算法、NNWA-PF 算法和 SANNWA-PF 算法共 4 种算法对文中第 4.2 节中的故障模式 1、故障模式 2 进行仿真研究,其中方均误差(RMSE)、计算时间和故障诊断时间对比如表 3 所示。两种模式仿真结果如图 9、图 10 所示。

通过图 9、图 10 及表 3 可以看出,非高斯噪声下的诊断结果相对高斯噪声下的诊断结果不同主要在于 EKF 算法的估计精度大幅降低,这是由于 EKF 算法作为一种高斯滤波方法,适用于高斯系统,对于非高斯系统估计效果不佳,而另外 3 种方法作为非高斯滤波方法,当噪声由高斯噪声变成非高斯噪声时,其估计精度变化不明显,说明这类方法能够较好地适用于非高斯系统。同样,SANNWA-PF 算法保持了较高的精度,相对 PF 提高了约 26%,对突变故障反应较快,体现了该算法在航空发动机气路故障诊断中的优越性。

表 3 非高斯噪声下 4 种算法故障诊断结果对比

Table 3 Comparisons of fault diagnosis with non-Gaussian noise based on four algorithms

算法	故障模式 1			故障模式 2		
	E_{rms}	计算时间/s	故障诊断时间/s	E_{rms}	计算时间/s	故障诊断时间/s
EKF	0.0534	0.14	0.400	0.0568	0.14	0.375
PF	0.0494	6.78	1.225	0.0498	6.80	1.550
NNWA-PF	0.0451	8.01	0.975	0.0451	7.99	0.750
SANNWA-PF	0.0391	9.47	0.125	0.0395	9.46	0.125




图 9 非高斯噪声下单部件故障诊断结果

Fig. 9 Single component fault diagnosis results with non-Gaussian noise




图 10 非高斯噪声下多部件故障诊断结果

Fig. 10 Multiple components fault diagnosis results with non-Gaussian noise

5 结 论

本文针对航空发动机非线性、非高斯的特点,提出一种可用于航空发动机气路故障诊断的 SANNWA-PF 算法。结论如下:

1) SANNWA-PF 算法中正态分布分裂操作在一定程度上缓解了粒子贫化,BP 神经网络权值调整操作在一定程度上缓解了粒子退化,两个操作大幅提高了算法的估计精度,较好地解决了 PF 算法中存在的问题。

2) SANNWA-PF 算法根据粒子在不同时刻分布情况的不同实时确定操作粒子数目,具有较好的自适应性能,同时由于神经网络权值调整操作中加入了当前观测信息,使得算法对航空发动机突变故障具有较快的反应速度。

3) SANNWA-PF 算法对于非高斯系统具有较好的性能,受噪声性质影响不大,能够更好地适用于非线性、非高斯系统的参数估计,相对于传统的高斯滤波方法能够更好地处理实际工作状态下的噪声。

4) SANNWA-PF 算法的计算复杂度有所增加,但其仍可以满足航空发动机气路故障诊断的实时性,具有工程应用价值。

参考文献:

[1] MERCER C R, SIMON D L, HUNTER G W, et al. Fundamental technology development for gas-turbine engine health management[R]. NASA/TM-2007-0022364, 2007.

[2] LITT J S, SIMON D L, GARY S, et al. A survey of intelligent control and health management technologies for aircraft propulsion systems [R]. NASA/TM-2005-213622, 2005.

[3] LUPPOLD R H, GALLOPS G W, KERR L J, et al. Estimating in-flight engine performance variations using Kalman filter concepts[R]. AIAA 89-2584, 1989.

[4] SIMON D L, LITT J S. Application of a constant gain extended Kalman filter for in-flight estimation of aircraft engine performance parameters [R]. NASA/TM-2005-213865, 2005.

[5] LU F, HUANG J Q, LÜ Y Q. Gas path health monitoring for a turbofan engine based on a nonlinear filtering approach[J]. Energies, 2013, 6(1): 492-513.

[6] 王修岩, 李萃芳, 高铭阳, 等. 基于 SVM 和 SNN 的航空发动机气路故障诊断[J]. 航空动力学报, 2014, 29(10): 2493-2498.

WANG Xiuyan, LI Cuifang, GAO Mingyang, et al. Fault

diagnosis of aero-engine gas path based on SVM and SNN [J]. Journal of Aerospace Power, 2014, 29(10): 2493-2498. (in Chinese)

[7] MERWE R V D, DOUCET A, FREITAS N D, et al. The unscented particle filter[R]. Cambridge, UK: Cambridge University, CUED/F-INPENG/TR 280, 2000.

[8] 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, 2005.

[9] JULIER S J, UHLMANN J K. Unscented filtering and nonlinear estimation[J]. Proceedings of the IEEE, 2004, 92(3): 401-422.

[10] HAMMERSLEY J M, MORTON K W. Symposium on Monte Carlo methods: poor man's Monte Carlo[J]. Journal of the Royal Statistical Society, 1954, 16(1): 23-38.

[11] GORDON N J, SALMOND D J, SMITH A F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation[J]. Radar and Signal Processing, 2002, 140(2): 107-113.

[12] DOUCET A. On sequential Monte Carlo methods for Bayesian filtering[J]. Statistics and Computing, 1998, 10(3): 197-208.

[13] ARULAMPALAM M S, MASKELL S, GORDON N, et al. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking[J]. IEEE Transaction Signal Processing, 2002, 50(2): 174-188.

[14] ADALI T, HAYKIN S. Adaptive signal processing: next generation solutions[M]. New York: Wiley, 2010.

[15] 朱志宇. 粒子滤波算法及其应用[M]. 北京: 科学出版社, 2010.

[16] PANG Z, LIU D, JIN N, et al. Neural network strategy for sampling of particle filters on the tracking problem[R]. Orlando: International Joint Conference on Neural Networks, 2007.

[17] MAHTAB S S, ABDOLAH R, NASER P. Classifying the weights of particle filter in nonlinear systems[J]. Communications in Nonlinear Science and Numerical Simulation, 2015, 31(1): 69-75.

[18] BORGUET S, LÉONARD O. Comparison of adaptive filters for gas turbine performance monitoring[J]. Journal of Computational and Applied Mathematics, 2010, 234(7): 2202-2212.

[19] 李文峰, 王永生, 杨纪明, 等. 航空发动机测试信号噪声特性分析[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)