

基于改进 K-SVD 字典训练的涡扇发动机
气路突变故障稀疏诊断方法

李 魁¹, 胡 宇^{1,2}, 孙振生¹, 张 寅¹, 周 伟¹

(1. 火箭军工程大学 导弹工程学院, 西安 710025;
2. 西安交通大学 机械工程学院, 西安 710049)

摘 要: 以典型气路突变故障信号的稀疏特性为基础,通过对涡扇发动机部件特征原子组进行分类,提出了改进 K-奇异值分解(K-singular value decomposition,K-SVD)字典训练的稀疏诊断方法,并结合气路典型突变故障开展了仿真实验研究。仿真结果表明:相比于拓展卡尔曼滤波(extended Kalman filter,EKF)和无迹卡尔曼滤波(unscented Kalman filter,UKF)方法,改进 K-SVD 方法对故障定位准确,无故障部件健康参数变化为 0,可有效提高故障部件辨识度,避免误诊断;计算耗时与 EKF 方法基本相等,仅为 UKF 方法的 0.3%,是一种有效的航空发动机气路突变故障在线诊断方法。

关 键 词: 涡扇发动机; 突变故障; 稀疏方法; 正交匹配追踪(OMP); K-奇异值分解(K-SVD)

中图分类号: V233.7 文献标志码: A

Turbofan engine abrupt gas path fault diagnosis method based on
improved K-SVD dictionary training and sparse theory

LI Kui¹, HU Yu^{1,2}, SUN Zhensheng¹, ZHANG Yin¹, ZHOU Wei¹

(1. School of Missile Engineering,
Rocket Force University of Engineering, Xi'an 710025, China;
2. School of Mechanical Engineering,
Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: The characteristic atomic group of turbofan engine components was classified and exploited to the K-SVD (K-singular value decomposition) based on the sparse characteristics of gas path abrupt fault signals, then an improved K-SVD dictionary training algorithm was proposed and used for abrupt fault diagnosis. The compared results with EKF (extended Kalman filter) and UKF (unscented Kalman filter) showed that the improved K-SVD method was accurate for fault location, and the change of health parameters of no fault components was 0, which can improve the identification of fault components effectively and avoid misdiagnosis; the calculation time was basically the same as EKF method; under similar accuracy, the time consumption of this method was only 0.3% of UKF method, which can be adapted for engine gas path parameter tracking and abrupt faults diagnosis.

收稿日期:2020-03-12

基金项目:国家自然科学基金重大专项(91952110); 国家自然科学基金(51905540);
西安市科技计划项目(201805048YD26CG32(2)); 陕西省自然科学基金(2019JM-186)

作者简介:李魁(1995—),男,硕士生,主要从事航空发动机故障诊断方法研究。

通信作者:胡宇(1984—),男,副教授,博士,主要从事航空发动机故障诊断方法研究。E-mail:huyu1222@163.com

引用格式:李魁,胡宇,孙振生,等.基于改进 K-SVD 字典训练的涡扇发动机气路突变故障稀疏诊断方法[J].航空动力学报,2020,35(9):2006-2016. LI Kui,HU Yu,SUN Zhensheng,et al. Turbofan engine abrupt gas path fault diagnosis method based on improved K-SVD dictionary training and sparse theory[J]. Journal of Aerospace Power,2020,35(9):2006-2016.

Key words: turbofan engine; abrupt fault; sparse method;
orthogonal matching pursuit (OMP);
K-singular value decomposition (K-SVD)

航空发动机长期服役在高温、高压、高转速、交变负载等条件下,因此发动机服役运行过程中的安全保障至关重要。据相关统计^[1],1952~1983年,在我国空军发生的战机等级事故中发动机质量问题占到48.3%,而发动机故障中,气路故障占比超过90%,为此,国内外学者对航空发动机气路故障参数的跟踪诊断开展了大量的研究。发动机故障诊断是利用实时采集气动热力学参数,如温度、压强和转速等,根据相应的故障跟踪算法来求解表征发动机部件状态的健康参数,分析判断发动机健康状态,为发动机控制调整提供基础和依据,从而保证发动机平稳安全运行^[2]。其中,故障诊断方法是实现发动机故障跟踪诊断的核心基础。卡尔曼滤波方法作为一种优化实时递推估计方法,广泛运用于发动机气路故障信号的跟踪诊断^[3]。考虑到航空发动机是一个非线性系统,采用传统卡尔曼滤波方法需要将非线性模型进行线性化处理,但模型线性化时会导致模型精度降低。为此,相关学者利用数据统计方法来近似发动机参数的非线性分布,提出了发动机气路故障诊断的非线性滤波方法^[4],有效提高了气路故障跟踪诊断的精度。同时,随着基于数据驱动和基于知识的智能故障诊断算法的不断涌现,如专家系统^[5],贝叶斯信念网络^[6]、模糊逻辑算法^[7-10]、粗集理论^[11]等,这些算法都广泛运用于气路故障的跟踪诊断问题研究。但这些方法是直接利用发动机输入输出数据来对非线性工作过程的气路故障进行诊断,难以形成对故障特性及变化规律的深入认识,并且在先验数据不足的情况下,算法的精度和可靠性会出现下降。

而航空发动机气路部件如压气机、涡轮的故障形式一般可分为由于腐蚀、侵蚀等因素造成的渐变故障和由于内、外物吸入以及腐蚀、侵蚀等量变因素积累引起突变故障。其中渐变故障参数变化呈现出线性特性,常规算法可以实现对其跟踪诊断;突变故障通常是由发动机喘振、吸鸟或金属疲劳累积导致结构失稳或断裂引起的发动机性能突然下降。突变故障对航空发动机更具安全威胁,但由于突变故障具有强烈的突变性和随机性,常规方法难以实现对其准确实时跟踪。为此,国内外学者尝试采用奇异值分解(singular value

decomposition, SVD)^[9],频谱分析(frequency spectrum, FS),小波变换(wavelet transform, WT)^[12],经验模式分解(empirical mode decomposition, EMD)^[13]等方法对突变故障开展了研究,取得了一定的成果,但这些方法在应对突变故障时仍存在诊断结果不直观、响应速度慢、不适于在线诊断等问题。考虑到发动机气路部件发生突变故障时,往往只有表征故障部件的健康参数发生突变,而其他参数几乎不会变化,这使得表征突变故障的健康参数矩阵具有较强的稀疏特性^[14-15]。这种稀疏特征可为气路典型突变故障参数变化跟踪与诊断问题提供一种解决途径。稀疏理论目前主要运用于信号处理和图像压缩感知等领域^[16]。而针对航空发动机气路突变故障问题,鲜有学者利用稀疏相关理论方法对其开展研究。实际上利用稀疏理论方法实现突变故障诊断将涉及到突变故障信号准确表征和稀疏求解两个方面的关键问题。其中,过完备字典的构造可实现对突变故障信号准确表征,是实现突变故障诊断的关键和前提。目前,过完备字典构造方法大体可分为固定字典和学习字典两大类。固定的基字典具有较好的通用性对于某些特定类型信号的处理效果往往难以满足要求^[17]。而学习字典主要是针对特定信号空间对初始字典进行训练得到的专用过完备字典,学习字典可根据信号特点调整其字典结构,可有效提升求解算法的稀疏性,从而得到了广泛的运用。学习字典根据学习过程的不同又可分为监督学习字典和非监督学习字典。两者的区别在于监督字典需要利用大量数据分析或者经验预设信号的分类信息以实现精细化的分类求解,在特征信号提取方面具有明显优势,其典型代表是label consistent K-singular value decomposition(LCK-SVD)算法^[18]。这种算法虽然精度更高,但是过度依赖于大量数据和检验前提下建立的合理预设分类信息,显然难以适应数据量相对缺乏的航空发动机气路故障分析。相比而言,非监督字典对样本信号不做处理的直接参与训练,训练过程的精度控制参数由操作人员事先给定,使得其具有对简单信号处理方便,匹配精度较高的显著特点^[19]。这对于航空发动机气路测量数据较少,且不同发动机状态训练参数通用性往

往不强的突变故障问题将具有更好的优势。K-SVD^[19]作为一种典型的非监督字典训练算法,其特点是经过训练后所得到的字典具有良好的稀疏性,但其训练过程中只考虑编码的总体稀疏性,对稀疏系数的物理意义往往是不明确的。而对于发动机气路故障诊断的测量参数来说,每个对应参数都是具有特定的含义,必须根据其具体含义对其进行分类训练,因此,常规 K-SVD 训练算法是难以满足发动机气路故障跟踪诊断要求的。为此,本文将结合涡扇发动机气路突变故障信号稀疏特征对常规 K-SVD 算法进行适应性改进,研究赋予稀疏矩阵对应数值物理意义,提出了基于改进 K-SVD 字典训练的涡扇发动机气路突变故障稀疏诊断方法,并通过气路典型的突变故障仿真实验验证方法的有效性。

1 涡扇发动机及气路突变故障

为实现气路突变故障模式的有效表征,建立了双转子分开排气涡扇发动机的非线性气动热力学数学模型,涡扇发动机结构及各截面示意图如图 1 所示,图中数据代表截面编号。




图 1 分开排气涡扇发动机典型结构及截面示意图
Fig. 1 Diagram of typical structure and cross section of separated exhaust turbofan engine

涡扇发动机部件健康状况可通过效率系数和流量系数来进行表征^[20]。发动机气路核心部件包括风扇(fan)、压气机(high pressure compressor, HPC)、高压涡轮(high pressure turbine, HPT)、低压涡轮(low pressure compressor, LPT),各部件参数下标分别为 fan、hpc、hpt、lpt。考虑到燃烧室的效率不易发生变化且影响因素复杂,因此,在分析过程中主要定义风扇效率系数蜕化量 $\Delta\eta_{\text{fan}}$ 和流量系数蜕化量 Δm_{fan} 、压气机效率系数蜕化量 $\Delta\eta_{\text{hpc}}$ 和流量系数蜕化量 Δm_{hpc} 、低压涡轮效率系数蜕化量 $\Delta\eta_{\text{lpt}}$ 和流量系数蜕化量 Δm_{lpt} 、高压涡轮效率系数蜕化量 $\Delta\eta_{\text{hpt}}$ 和流量系数蜕化量 Δm_{hpt} 作为气路部件的健康指标进行分析,按式(1)、式(2)计算。

$$\Delta\eta_i = \frac{\eta_i - \eta_i^*}{\eta_i^*} \tag{1}$$

$$\Delta m_i = \frac{m_i - m_i^*}{m_i^*} \tag{2}$$

式中 η_i 、 m_i 分别表示气路部件效率系数和流量系数的实际值, η_i^* 、 m_i^* 分别表示气路部件效率系数和流量系数未发生蜕化情况下的理想值,下标 i 指代 fan、hpc、hpt、lpt。

航空发动机气路部件的健康参数蜕化情况一般可根据经验和大量飞行数据来获得,依据文献[21],梳理得到了气路各部件健康参数的精度与蜕化范围如表 1 所示,其中 η_{fan} 、 m_{fan} 表示风扇效率系数和流量系数, η_{hpc} 、 m_{hpc} 表示压气机效率系数和流量系数, η_{hpt} 、 m_{hpt} 表示高压涡轮效率系数和流量系数, η_{lpt} 、 m_{lpt} 表示低压涡轮效率系数和流量系数。当风扇和压气机发生故障时,效率系数和流量系数均降低;当高压涡轮和低压涡轮发生故障时,效率系数降低而流量系数上升^[22-23]。

表 1 健康参数的精度与蜕化范围

Table 1 Health parameters' accuracy and degenerate ranges

健康参数	设定值/%	标准偏差量/%	蜕化范围/%
η_{fan}	1	0.05	-7~-1
m_{fan}	1	0.05	-7~-1
η_{hpc}	1	0.05	-7~-1
m_{hpc}	1	0.05	-7~-1
η_{hpt}	1	0.05	-7~-1
m_{hpt}	1	0.05	1~7
η_{lpt}	1	0.05	-7~-1
m_{lpt}	1	0.05	1~7

2 基于改进 K-SVD 字典训练的突变故障诊断方法

利用改进 K-SVD 字典训练算法对气路突变故障进行跟踪诊断,可分为字典训练和在线故障诊断两个部分,该算法的流程如图 2 所示。 $\Delta\eta_i^*$ 、 Δm_i^* 分别表示部件实际效率系数蜕化量和流量系数蜕化量。 $\hat{\Delta\eta}_i$ 、 $\hat{\Delta m}_i$ 分别表示对各部件效率系数蜕化量和流量系数蜕化量的仿真诊断结果。

在字典训练部分,利用发动机气路部件故障的样本热力学参数对字典进行训练,从而获取适用于涡扇发动机突变故障的过完备字典。在故障诊断部分,利用训练出的过完备字典作为稀疏求




图 2 气路突变故障稀疏诊断流程

Fig. 2 Abrupt gas path fault diagnosis algorithm with sparse method

解算法的匹配字典,以采集的发动机气路部件故障的样本热力学参数为基础,通过稀疏求解算法跟踪求解表征发动机各气路部件健康状态的参数,并将为跟踪的健康参数与预设实际的部件健康参数进行对比分析,检验算法的准确性和有效性。

2.1 气路突变故障稀疏诊断

航空发动机气路承受的高温高压等恶劣工作条件,导致气路测量参数是极其有限的,会造成需要监控的气路部件健康参数大于可测量参数的典型欠定性问题

$$Y = Ax \tag{3}$$

式中 $Y \in R^n$ 表示热力学参数测量量矩阵, $x \in R^m$ 为发动机健康参数矩阵, $A \in R^{m \times n}$ 为系数矩阵,在稀疏求解理论中通常称其为过完备字典,其中 $m < n$ 。

对于该欠定性方程,通常有无穷多个解。为了评价这些解的优良性,引入了稀疏度指标进行评价。对于需要监控的健康参数,其稀疏度 S 可以用其的 0 范数表示,即

$$S = \|x\|_0 \tag{4}$$

该稀疏度表示的是健康参数中非零元素的个数。基于稀疏度优化的发动机故障诊断的目标函数如下式:

$$\begin{aligned} x = \operatorname{argmin}(Y - Ax) \\ \text{s. t. } \|x\|_0 \leq S_0 \end{aligned} \tag{5}$$

上述问题是一个多项式复杂程度的非确定性

(non-deterministic polynomial complete, 记为 NP)问题,为进一步提升求解效率,经过证明,式(5)中的限定条件可以放松至 1 范数^[24],从而将整个问题转化为如下凸优化问题:

$$\begin{aligned} x = \operatorname{argmin}(\|x\|_1) \\ \text{s. t. } \|Y - Ax\|_2 < r \end{aligned} \tag{6}$$

式中 Y 为测量参数,在固定状态和部件故障模式下是确定不变的; x 为需求解的未知健康参数; A 是过完备字典; r 为人工设置的最大匹配残差。不同过完备字典将导致稀疏求解算法计算效率和精度会有所不同,因此,需要对系数矩阵进行选择。同时,目前求解上述凸优化问题可采用匹配追踪(matching pursuit, MP)和正交匹配追踪算法(orthogonal matching pursuit, OMP)^[25]为代表的贪婪算法,这些算法具有原理简单、收敛快的特点,在稀疏求解方面具有广泛的应用,为此,本文将直接采用 OMP 算法进行稀疏求解。

2.2 基于改进 K-SVD 的突变故障字典训练

过完备字典在稀疏匹配过程中发挥着重要作用,必须设计合理的过完备字典才能保证计算结果的正确性。

常规 K-SVD 字典训练算法流程如图 3 所示。算法中,选取初始字典作为匹配字典,将该匹配字典带入稀疏求解算法中得到字典匹配结果,根据匹配结果选择更新列,并采用 K-SVD 算法计算更新矩阵,逐个更新对应原子得到新的匹配字典,从而最终得到训练完成的过完备字典。该字典训




图 3 K-SVD 字典训练流程

Fig. 3 K-SVD dictionary training algorithm

训练算法的核心是采用迭代更新的方式每次更新一个原子更新过程中,定义字典训练目标函数为

$$\hat{\mathbf{A}}, \hat{\mathbf{x}} = \operatorname{argmin}(\|\mathbf{Y} - \mathbf{A}\mathbf{x}\|_2^2) \quad (7)$$

s. t. $\|\mathbf{x}\|_0 \leq S$

单次更新时,将现有字典带入训练目标函数求解出匹配结果 $\mathbf{x}$,根据匹配结果确定对应于原子的更新矩阵,并对相应原子进行更新。其中,目标函数的各元素可用向量表示

$$\begin{aligned} \mathbf{A} &= [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_{n-1}, \mathbf{a}_n], \\ \mathbf{x} &= [x_1, x_2, \dots, x_{n-1}, x_n]^T, \\ \mathbf{Y} &= [y_1, y_2, \dots, y_{n-1}, y_n]^T \end{aligned}$$

从而式(7)化为

$$\hat{\mathbf{A}}, \hat{\mathbf{x}} = \operatorname{argmin}(\|\mathbf{Y} - \sum_{i=1}^n \mathbf{a}_i x_i\|_2^2) \quad (8)$$

在对第 k 个原子进行训练时,将式(5)中的 $\mathbf{Y} - \sum_{i=1}^n \mathbf{a}_i x_i$ 部分中的第 k 个原子分离出来,将其余部分表示为一个整体,可以得到

$$\hat{\mathbf{a}}_k, \hat{\mathbf{x}}_k = \operatorname{argmin}(\mathbf{R}_k - \mathbf{a}_k x_k) \quad (9)$$

其中 $\mathbf{R}_k = \mathbf{Y} - \sum_{i=1}^{k-1} \mathbf{a}_i x_i - \sum_{j=k+1}^n \mathbf{a}_j x_j$ 。

利用该流程得到的新向量 $\hat{\mathbf{a}}_k$ 可替换原字典原子 $\mathbf{a}_k$,当所有原子均采用上述算法完成更新后,字典训练完成。

常规 K-SVD 字典训练算法在选取字典时通常仅考虑其冗余性,并且在实际应用中着重考虑编码结果的总体稀疏性。但对于航空发动机来说,其表征气路部件故障的健康参数具有明确的物理意义且变化具有一定规律性^[26],直接采用常规 K-SVD 算法获得匹配字典难以对不同部件突变故障模式进行准确表征。为此,本文结合了发

动机气路突变故障信号的变化特征,提出采用特征原子组训练对 K-SVD 字典训练算法进行改进,具体流程如图 4 所示。




图 4 特征原子组训练

Fig. 4 Training the feature atoms team

在训练字典时,将定义的 4 个部件的健康参数即 8 个原子按照部件进行分类,2 个为 1 组进行训练,每组的 2 个原子分别对应风扇、高压压气机、高压涡轮、低压压气机的效率系数和流量系数,这些组称为对应部件的特征原子组。为获取各部件特征原子组,有发动机模型获得各部件故障气路参数样本 $\mathbf{Y}^*$,将对应样本代入 K-SVD 字典训练法进行字典训练,再使用训练结果进行稀疏匹配,匹配结果中非零项对应的原子即为该设计故障对应的特征原子组 $\{\mathbf{a}_\eta, \mathbf{a}_m\}$ 。当所有部件故障的特征原子组均训练完成后,所有特征原子组即可构成匹配字典。

单部件特征原子组训练具体可分为特征原子定位和数值放缩两部分。特征原子定位以高压压气机效率系数和流量系数为例进行分析,如图 5 所示。图中 $\mathbf{x}$ 为求解得到的系数矩阵,其中的非零项由彩色标出, $\mathbf{A}$ 为训练结果,其中的彩色带为选择的原子, x_1, x_5 对应风扇效率系数和流量系数; x_2, x_6 对应高压压气机效率系数和流量系数; x_3, x_7 对应高压涡轮效率系数和流量系数; x_4, x_8 对应低压涡轮效率系数和流量系数, $\mathbf{y}$ 为训练样本。训练样本由改进 K-SVD 算法训练得到字典,采用多组样本数据以及随机初始字典进行反复迭代,根据匹配结果非零项的位置,以选中原子线性不相关为迭代终止条件,最终选取最佳组合,确定对应原子对应的高压压气机的健康参数。特征原子定位过程中,可按图 5 所示方法移动相应原子,

等式仍然成立,对每个部件都进行定位后即可将对
应参数的特征原子定位到对应位置上。经过特征
原子定位后,训练样本与原子间的关系可表示为

$$\mathbf{y} = \Delta \hat{\eta}_{\text{hpc}} \mathbf{a}_2 + \Delta \hat{m}_{\text{hpc}} \mathbf{a}_6 \tag{10}$$

其中 $\Delta \hat{\eta}_{\text{hpc}}$ 、 $\Delta \hat{m}_{\text{hpc}}$ 分别为由当前字典计算得到的
高压压气机效率系数和流量系数蜕化量。 $\mathbf{a}_2$ 、 $\mathbf{a}_6$
为当前所选择的原子。




图 5 特征原子定位
Fig. 5 Feature atom location

完成特征原子定位后,还需要对原子进行缩
放,以保证定位后的原子与对应部件故障程度
之间相互匹配,具体方法如图 6 所示。同样以高压
压气机为例,高压压气机设计的故障模式中,其效
率系数蜕化量为 $\Delta \eta_{\text{hpc}}$,流量系数蜕化量为 Δm_{hpc} ,
测量参数 y 与效率系数和流量系数之间关系为

$$\mathbf{y} = \Delta \eta_{\text{hpc}} \hat{\mathbf{a}}_2 + \Delta m_{\text{hpc}} \hat{\mathbf{a}}_6 = \Delta \eta_{\text{hpc}} \frac{\Delta \hat{\eta}_{\text{hpc}}}{\Delta \eta_{\text{hpc}}} \mathbf{a}_2 + \Delta m_{\text{hpc}} \frac{\Delta \hat{m}_{\text{hpc}}}{\Delta m_{\text{hpc}}} \mathbf{a}_6 \tag{11}$$

由于特征原子定位流程中已保证了原子之间
线性不相关,根据初始健康参数和求解的系数可
得到特征原子分别为

$$\hat{\mathbf{a}}_2 = \frac{\Delta \hat{\eta}_{\text{hpc}}}{\Delta \eta_{\text{hpc}}} \mathbf{a}_2 \quad \hat{\mathbf{a}}_6 = \frac{\Delta \hat{m}_{\text{hpc}}}{\Delta m_{\text{hpc}}} \mathbf{a}_6 \tag{12}$$

经过特征原子定位和数值放缩后得到的结果
将与设计结果一致,即完成了本部件特征原子组




图 6 数值放缩
Fig. 6 Numerical scaling

的训练。对于其他部件特征原子组训练,均按照
此流程进行。

综上所述,改进 K-SVD 算法中,通过引入特
征原子组训练能有效克服传统稀疏匹配算法中匹
配过程的盲目性,为对应位置的匹配结果赋予相
应的物理意义,有利于提升匹配精度。

3 仿真结果与分析

为了验证算法的有效性,通过设计涡扇发动
机不同气路部件发生不同程度的突变故障对过完
备字典与诊断结果进行仿真验证。仿真平台基本
配置参数如表 2 所示。

表 2 仿真平台参数	
Table 2 Simulation platform parameters	
项目	规格
处理器	Intel Core i5-4210M 2.6 GHz
内存	8G * 2 DDR3L 1600 MHz
操作系统版本	Windows 10 1806
软件版本	Matlab R2018b

3.1 过完备字典训练

为了给气路突变故障跟踪诊断提供具有足够
稀疏度的字典形式,结合表 1 健康参数蜕化选取
训练样本,分别对各部件的特征原子组进行训练。
训练过程中具体样本参数设置如下:各部件特征
原子组训练共选取 3 组故障模式:效率系数下降
2%,流量系数下降(涡轮部件为上升)2%;效率系
数下降 1%,流量系数下降(涡轮部件为上升)
3%;效率系数下降 3%,流量系数下降(涡轮部件
为上升)1%;按上述故障模式通过发动机非线性
模型分别计算得到对应的气路热力学参数,并利
用字典特征原子组流程对字典进行训练。在特征
原子组定位过程中,初始字典为随机生成的过完
备字典 $\mathbf{A}_0 \in \mathbf{R}^{6 \times 8}$,风扇特征原子组迭代 14 次后
达到收敛条件;高压压气机特征原子组迭代 17

次;高压涡轮特征原子组迭代 26 次;低压涡轮特征原子组迭代 23 次。特征原子定位完成后,按照

$$\mathbf{A} = \begin{bmatrix} 0.291 & -0.026 & -0.169 & 0.001 & -0.186 & 0.049 \\ 0.07 & -0.016 & -0.07 & 0 & -0.078 & 0.02 \\ 0.094 & 0.006 & 0.616 & -0.048 & 0.784 & -0.821 \\ 0.01 & -0.003 & -0.065 & -0.065 & 0.342 & -0.336 \\ 0.082 & -0.011 & 0.461 & -0.024 & 0.545 & -0.139 \\ -0.101 & -0.014 & -0.862 & 0.039 & -1.01 & 0.241 \end{bmatrix}$$

为了验证气路突变故障过完备字典训练的精度,设计风扇、高压压气机、高压涡轮和低压涡轮的效率系数和流量系数分别下降 1%,将改进 K-SVD 字典训练方法所得字典运用于稀疏求解方法中,对气路部件的健康参数进行跟踪。跟踪的健康参数与设计故障参数绝对误差对比如表 3 所示。从对比误差可以看出,该训练字典对预设训练样本的健康参数还原效果较好,误差量级在 10^{-9} ,该训练字典具有较好性能。

表 3 过完备字典对故障样本的诊断误差

Table 3 Over-complete dictionary's diagnosis error on the fault samples		
故障部件	效率系数诊断 误差/ 10^{-13}	流量系数诊断 误差/ 10^{-13}
风扇	1.8	34 000
高压压气机	1.9	12
高压涡轮	190	2.6
低压涡轮	4.2	8.3

3.2 气路故障诊断结果

为验证该算法获得的字典对涡扇发动机气路突变故障的诊断能力,设计了如表 4 所示的 4 个仿真实验。将仿真实验结果与基于 EKF 的故障诊断算法和基于 UKF 的故障诊断算法^[14]结果进行对比分析,对比结果如图 7~图 10 所示。其横坐标表示仿真时间序列。

在时间 $t=2\text{ s}$ 时,风扇发生突变故障,风扇效率系数蜕化 1%和流量系数蜕化 2%,其他部件健康参数不发生变化。图 7(a)~图 7(c)分别表示采用 UKF、EKF 和改进 K-SVD 算法对风扇突变故障健康参数跟踪变化情况,其中纵坐标表示健康参数的绝对值;图 8(a)~图 8(c)分别表示对应 3 种算法跟踪过程健康参数的绝对误差。从图中可以看出,3 种算法均能较好实现对风扇突变故障健康参数的有效跟踪。其中,由于 UKF 算法采

初始设定的健康参数蜕化值对原子进行数值放缩过程,最终得到过完备字典如下:

表 4 故障部件健康参数蜕化

Table 4 Preinstalling degradation of the health parameters of failed components		
故障部件	效率系数 蜕化值/%	流量系数 蜕化值/%
风扇	-1	-2
高压压气机	-2	-2
高压涡轮	-2	4
低压涡轮	-1	2

用精度较高的非线性模型,能够准确地反映发动机的动态变化过程,该算法的跟踪精度最高;而 EKF 算法采用的线性化模型不可避免存在建模误差,使得跟踪诊断精度相对较低。同时,基于模型的 UKF 和 EKF 算法对表征同一部件故障的气路测量参数之间存在一定相关性,这种相关性会导致健康参数跟踪结果之间必然存在相互影响关系,模型精度越低,相应的影响程度越剧烈,因此,EKF 算法健康参数相互影响程度高于 UKF 算法。如风扇效率系数和流量系数发生突变性蜕化时,EKF 算法中高压涡轮效率系数蜕化量最大可达到 0.085,如图 8(b)所示;而 UKF 算法中高压涡轮效率系数蜕化量几乎等于 0,如图 8(a)所示。相比较而言,改进 K-SVD 算法的跟踪精度介于 UKF 算法和 EKF 算法之间。该算法在稀疏求解突变信号时,由于故障发生的突发性会造成拟合残差出现局部堆积现象,该现象将导致故障发生初期产生了一个明显的尖峰,如图 7(c)和图 8(c)所示,尖峰持续时间一般较短,参数恢复正常值较快,为 0.5~1 s,一般不会对求解过程产生过多影响。与此同时,由于改进 K-SVD 算法对字典训练时得到了具有较强稀疏特性的系数矩阵,将有效降低跟踪的健康参数之间的相互影响,如跟踪风扇突变故障时,改进 K-SVD 算法跟踪结果中仅风扇效率系数和流量系数发生突变,其他健康参数基本保持不变,这种稀疏特性对提高

气路部件故障诊断的辨识度将发挥重要的作用。图 9 表示高压压气机发生突变故障时,效率系数和流量系数分别蜕化 2%,其他部件健康参数不发生改变情况下,采用 UKF、EKF 和改进 K-SVD 算法对健康参数跟踪结果,图 10 表示对应 3 种算法跟踪过程健康参数的绝对误差。从高压压气机突变故障健康参数跟踪和误差结果分析来看,基本能够得到与风扇发生突变故障相一致的结论。

对于高压涡轮和低压涡轮发生突变故障的情况,通过仿真得到了 UKF、EKF 和改进 K-SVD 算法对健康参数跟踪的结果,其匹配误差记录在表 5 中。表 5 表示在不同部件故障模式下跟踪的健康参数绝对误差的平均值。从误差平均值也可以看出,UKF 算法精度最高,其次为改进 K-SVD 和 EKF 算法。改进 K-SVD 算法由于误差的局

部堆积现象在故障发生初期会产生尖峰现象,导致其误差平均值将高于 UKF 算法,但尖峰恢复后其误差水平与 UKF 算法基本一致。其次,UKF 和 EKF 算法跟踪结果中健康参数之间存在相互影响,而改进 K-SVD 算法跟踪结果具有明显的稀疏特性,这将有利于提高突变故障诊断的辨识度。

为验证不同算法计算效率,在表 2 所示的实验条件下,利用 3 种算法分别对 4 种故障模式重复 10 次仿真计算取平均耗时,得到如表 6 所示不同故障模式下 3 种算法的计算效率。表 6 中结果表明,由于 UKF 算法采用的发动机非线性模型计算过程比较复杂,导致该算法的计算耗时量最长,高达 280s,因此,UKF 算法大多用于离线分析;而 EKF 算法直接采用线性化模型,其计算




图 7 UKF、EKF 和改进 K-SVD 算法对风扇突变故障跟踪诊断结果

Fig. 7 Tracking results of fan abrupt fault based on UKF、EKF and improved K-SVD




图 8 UKF、EKF 和改进 K-SVD 算法对风扇突变故障跟踪的绝对误差

Fig. 8 Errors of fan abrupt fault based on UKF、EKF and improved K-SVD




图 9 UKF、EKF 和改进 K-SVD 算法对高压压气机突变故障跟踪诊断结果
Fig.9 Tracking results of HPC abrupt fault based on UKF、EKF and improved K-SVD




图 10 UKF、EKF 和改进 K-SVD 算法对高压压气机突变故障跟踪的绝对误差
Fig.10 Errors of HPC abrupt fault based on UKF、EKF and improved K-SVD

表 5 UKF、EKF 和改进 K-SVD 算法气路部件突变故障跟踪的误差平均值

Table 5 Average error of gas path component abrupt faults based on UKF、EKF and improved K-SVD

故障部件	方法	$\Delta\eta_{\text{fan}}$	$\Delta\eta_{\text{hpc}}$	$\Delta\eta_{\text{hpt}}$	$\Delta\eta_{\text{lpt}}$	Δm_{fan}	Δm_{hpc}	Δm_{hpt}	Δm_{lpt}
风扇	UKF	2.18	0.26	1.21	2.75	1.45	0.23	1.23	1.27
	EKF	5.21	6.23	6.73	9.57	3.68	1.25	14.00	2.31
	改进 K-SVD	5.72	0	0	0	5.51	0	0	0
高压压气机	UKF	5.17	1.11	0.31	1.12	2.10	1.21	0.90	0.08
	EKF	1.49	2.86	1.10	2.54	2.25	3.54	1.04	0.50
	改进 K-SVD	0	2.87	0	0	0	2.14	0	0
高压涡轮	UKF	1.23	0.25	2.12	2.31	0.74	1.45	2.64	2.45
	EKF	7.31	6.84	3.04	3.14	1.25	2.41	34.70	1.25
	改进 K-SVD	0	0	4.80	0	0	0	2.54	0

续表									
故障部件	方法	$\Delta\eta_{fan}$	$\Delta\eta_{hpc}$	$\Delta\eta_{hpt}$	$\Delta\eta_{lpt}$	Δm_{fan}	Δm_{hpc}	Δm_{hpt}	Δm_{lpt}
低压涡轮	UKF	0.79	0.11	1.40	0.46	0.35	0.74	12.70	2.41
	EKF	8.34	6.25	5.45	5.10	0.78	2.35	12.40	3.21
	改进 K-SVD	0	0	0	9.32	0	0	0	6.75

表 6 3 种算法时耗对比
Table 6 Comparison of three algorithms for time consumption

故障部件	UKF 耗时/s	EKF 耗时/s	改进 K-SVD 耗时/s
风扇	284.86	0.60	0.62
高压压气机	258.63	0.56	0.48
高压涡轮	280.26	0.59	0.49
低压涡轮	295.52	0.48	0.49

耗时较低,可作为发动机在线故障分析的有效方法^[27];而本文提出的改进 K-SVD 算法与 EKF 算法耗时量基本相同,且避免了 EKF 算法线性化模型的建立过程,可直接根据采集的数据对气路故障进行在线诊断。

综上所述,改进 K-SVD 算法对气路突变故障的跟踪诊断基本达到了较为理想的精度和辨识度,且具有计算效率高的特点,可有效解决发动机气路突变故障诊断问题。

4 结 论

航空发动机气路突变故障具有的稀疏特性为气路部件典型突变故障跟踪诊断问题提供有效解决途径。本文根据发动机气路突变故障信号的稀疏特性,通过特征原子组分组训练对常规 K-SVD 字典训练算法进行适应性改进,赋予稀疏矩阵相应的数值物理含义,并运用于气路典型突变故障的跟踪诊断。仿真结果表明,基于改进 K-SVD 字典训练的气路突变故障诊断方法能够到达较为理想的跟踪精度,其稀疏特性有效提高了突变故障诊断的辨识程度,且该方法避免了模型的构造,计算效率较高,可作为发动机气路典型突变故障诊断的有效方法。除此之外,在实验过程中发现,当故障程度进一步加深,由于其重新建立新的稳态时间长,故障影响范围更广,故障的突变性和稀疏性都有所减弱,求解跟踪速度过慢,因此,求解中需要通过设定阈值、延长观察时间以及增加训练样本等手段才能获得正确的结论。同时,如何

对各原子进行误差分配,防止在突变故障发生时出现局部误差堆积也需要进一步研究。

参考文献:

[1] 宋兆泓. 航空发动机典型故障分析[M]. 北京:北京航空航天大学出版社,1993.

[2] RAUSCH R T,GOEBEL K F,EKLUND N H,et al. Integrated in-flight fault detection and accommodation;a model-based study[J]. Journal of Engineering for Gas Turbines and Power,2007,129(4):962-969.

[3] SÉBASTIEN J,BORGUET S. Variations on the Kalman filter for enhanced performance monitoring of gas turbine engines[D]. Liège,Belgique:University of Liège,2012.

[4] 张鹏,黄金泉. 航空发动机气路故障诊断的平方根 UKF 方法研究[J]. 航空动力学报,2008,23(1):169-173. ZHANG Peng, HUANG Jinquan. SRUKF research on aeroengines for gas path component fault diagnostics[J]. Journal of Aerospace Power, 2008, 23 (1): 169-173. (in Chinese)

[5] KOPYTOV E,LABENDIK V,YUNUSOV S. Expert systems for evaluating the aircraft power plants *technical condition[J]. Journal of Transport and Communication, 2010,11(1):31-37.

[6] ROMESSIS C, MATHIOUDAKIS K. Bayesian network approach for gas path fault diagnosis[J]. Journal of Engineering for Gas Turbines and Power,2006,128(1):64-72.

[7] GANGULI R. Application of fuzzy logic for fault isolation of jet engines[J]. Journal of Engineering for Gas Turbines and Power,2003,125(3):617-623.

[8] DEMIRCI S,HAJIYEV C,SCHWENKE A. Fuzzy logic-based automated engine health monitoring for commercial aircraft[J]. Aircraft Engineering and Aerospace Technology,2008,80(5):516-525.

[9] PAN Qiang,LIU Ying,ZHOU Rui,et al. An automatic abrupt signal extraction method for fault diagnosis of aero-engines[J]. Journal of Mechanical Science and Technology,2019,33(4):1633-1640.

[10] OGAJI S O T,MARINAI S,SAMPATH S,et al. Gas-turbine fault diagnostics;a fuzzy-logic approach[J]. Applied Energy 2005,82(1):81-89.

[11] WANG Lihui. Rough set based gas turbine fault isolation study[D]. Bedfordshire,UK:Crandfield University,2010.

[12] MALLAT S,HWANG W L. Singularity detection and processing with wavelets[J]. IEEE Transactions on Information Theory,1992,38(2):617-643.

[13] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London: Series A Mathematical Physical and Engineering Sciences, 1998, 454(1971): 903-995.

[14] 胡宇, 张世英, 罗雷, 等. 基于自适应容积卡尔曼滤波方法的涡扇发动机气路部件故障诊断[J]. 航空动力学报, 2016, 31(5): 1260-1266.

HU Yu, ZHANG Shiyong, LUO Lei, et al. Turbofan engine gas path components fault diagnosis based on adaptive cubature Kalman filter[J]. Journal of Aerospace Power, 2016, 31(5): 1260-1266. (in Chinese)

[15] 胡宇, 杨月诚, 张世英, 等. 基于改进平方根无迹卡尔曼滤波方法的涡扇发动机气路状态监控[J]. 航空动力学报, 2014, 29(2): 441-450.

HU Yu, YANG Yuecheng, ZHANG Shiyong, et al. Turbofan engine gas path performance monitoring based on improved square root unscented Kalman filter[J]. Journal of Aerospace Power, 2014, 29(2): 441-450. (in Chinese)

[16] 尹宏鹏, 刘兆栋, 柴毅, 等. 压缩感知综述[J]. 控制与决策, 2013, 28(10): 1441-1445.

YIN Hongpeng, LIU Zhaodong, CHAI Yi, et al. Survey of compressed sensing[J]. Control and Decision, 2013, 28(10): 1441-1445. (in Chinese)

[17] 李虎, 徐岩. 基于 DSKSVD 字典学习的语音信号欠定盲源分离算法[J]. 计算机工程, 2018, 44(10): 252-257.

LI Hu, XU Yan. Underdetermined blind source separation algorithm for speech signal based on DSKSVD dictionary learning[J]. Computer Engineering, 2018, 44(10): 252-257. (in Chinese)

[18] JIANG Zhuolin, LIN Zhe, DAVIS L S. Label consistent K-SVD: learning a discriminative dictionary for recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(11): 2651-2664.

[19] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.

[20] 白磊, 杨磊, 胡骏, 等. 基于特征值和特征向量的测量参数选择[J]. 航空动力学报, 2019, 34(1): 195-200.

BAI Lei, YANG Lei, HU Jun, et al. Selection of measurement parameters based on eigenvalues and eigenvectors[J]. Journal of Aerospace Power, 2019 34(1): 195-200. (in Chinese)

[21] SALLEE G P. Performance deterioration based on existing (historical) data-JT9D jet engine diagnostics program[R]. NASA/CR-135448, 1978.

[22] FENG Lu, HUANG Jinquan, LÜ Yiqiu. Gas path health monitoring for a turbofan engine based on a nonlinear filtering approach[J]. Energies, 2013, 6(1): 492-513.

[23] SIMON D L, BIRD J, DAVISON C, et al. Benchmarking gas path diagnostic methods: a public approach[R]. ASME Paper GT-2008-51360, 2008.

[24] CHEN S S, SAUNDERS D M A. Atomic decomposition by basis pursuit[J]. Society for Industrial and Applied Mathematics (SIAM) Review, 2001, 43(1): 129-159.

[25] TROPP J, GILBERT A. Signal recovery from random measurements via orthogonal matching pursuit[J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655-4666.

[26] 石陆友, 朱杰堂, 胡宇, 等. 基于改进遗传算法的涡扇发动机气路传感器优化[J]. 西北工业大学学报, 2017, 35(增刊 1): 1-8.

SHI Luyou, ZHU Jietang, HU Yu, et al. Optimization of gas path sensors of turbofan engine based on improved genetic algorithm[J]. Journal of Northwestern Polytechnical University, 2019 35(Suppl. 1): 1-8. (in Chinese)

[27] 张鹏. 基于卡尔曼滤波的航空发动机故障诊断技术研究[D]. 南京: 南京航空航天大学, 2009.

ZHANG Peng. Aeroengine fault diagnostics based on Kalman filter[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2009. (in Chinese)

(编辑: 王碧琚)