航空发动机传感器故障与部件故障诊断技术

李业波 李秋红 黄向华 赵永平

(南京航空航天大学 能源与动力学院, 南京 210016) (南京理工大学 机械工程学院, 南京 210094)

摘 要: 结合局部学习思想与集成学习技术,提出了一种基于支持向量机-极端学习机-卡尔曼滤波器(SVM-ELM-KF,Support Vector Machine-Extreme Learning Machine-Kalman Filter)的航空发动机传感器故障与突发性部件故障诊断的方法. 将改进的迭代约简最小二乘支持向量回归机训练技术推广到分类机中,用于区分传感器故障与部件故障,使得该分类机具有一定的稀疏性. 对于传感器故障,利用 ELM 分类机对故障进行定位. 对于部件故障,利用改进的卡尔曼滤波器对发动机各部件的健康参数进行估计,从而对部件故障进行定位. 仿真结果表明,提出的故障诊断方法能够准确地区分传感器故障和部件故障,实现故障的有效定位,验证了方法的可行性.

关 键 词: 航空发动机; 传感器故障; 部件故障; 支持向量机; 极端学习机; 卡尔曼滤波器

中图分类号: V 231.3

文献标识码: A **文 章 编 号**: 1001-5965(2013)09-1174-07

Fault diagnosis for sensors and components of aero-engine

Li Yebo Li Qiuhong Huang Xianghua

(College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Zhao Yongping

(School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: According to local learning and ensemble learning technologies, a method for sensors fault and abrupt components fault diagnosis of aero-engine was proposed based on support vector machine-extreme learning machine-Kalman filter (SVM-ELM-KF). The training approach of improved recursive reduced-least squares support vector regression (IRR-LSSVR) was extended to classification machine to distinguish sensor faults and component faults. The training method makes the classification machine have better sparsity. Considering sensors fault, the ELM was used for fault location. For components fault, the improved KF was adopted for health parameters estimation and fault location. Simulation results show that the proposed method for fault diagnosis can distinguish sensor faults and abrupt component faults accurately, and locate the faults effectively. That is, the proposed method is valid.

Key words: aero-engine; sensor fault; component fault; support vector machine; extreme learning machine; Kalman filter

航空发动机是飞机的心脏,其性能与可靠性是飞机性能与飞行安全的重要保证. 由于航空发动机结构复杂,并且经常工作在高温高速、大应力的恶劣环境下,使得发动机本身成为故障多发系统[1]. 在服役过程中,除部件性能会发生缓慢退化外,还会出现突发性部件健康参数退化. 与此同

收稿日期: 2012-10-17; **网络出版时间**: 2013-09-27 09:19

网络出版地址: www.cnki.net/kcms/detail/11.2625.V.20130927.0919.002.html

基金项目: 国家自然科学基金资助项目(51006052); 航空科学基金资助项目(20110652003); 中央高校基本科研业务费专项基金资助项目(NZ2012104); 江苏省 2012 年度普通高校研究生科研创新计划(CXZZ12_0169)

作者简介: 李业波(1985-),男,安徽颍上人,博士生,liyebo1985@163.com.

时,随着控制变量的不断增加,所需要的传感器也越来越多,由于其工作环境的恶劣,传感器也是故障易发元件之一[2]. 两种故障同时以不同的方式影响发动机的性能与可靠性.

对航空发动机传感器故障与部件故障的诊断是航空发动机控制系统的一个重要方面,国内外在传感器和部件故障诊断方面开展了大量研究[3]. 目前,部件故障诊断方法基本可以分为3 个主要分支:基于模型的故障诊断技术;基于数据驱动的故障诊断技术;基于知识规则的故障诊断技术. 其中基于模型和数据驱动的故障诊断方法研究和使用最为广泛. 比较典型的基于模型的故障诊断方法有:基于观测器和卡尔曼滤波器的方法[4-5]. 基于数据驱动的方法包括基于神经网络、支持向量机等人工智能方法[6-7]. 这些方法既适用于部件故障诊断,也适用于航空发动机传感器故障的诊断. 但是采用以上方法对部件故障和传感器故障进行诊断时,大部分研究都假设已知故障类型. 这种假设显然不合理. 在实际的系统中是不可能事先已知故障类型的. 因此,当发动机出现故障时,首先要识别其故障类型.

目前,国内外对传感器故障和部件故障的区分已开展了相应的研究,其中文献[8]就提出一种基于云关联度的航空发动机传感器、部件故障识别技术. 该方法利用云模型描述各种故障模式特征序列,并对特征序列计算云关联度,通过比较关联度可以很好的区分这两种故障类型,并对故障进行定位. 但是,这种方法在对这两种故障进行区分的同时还对传感器故障进行定位,使得算法需要具有很高的精度,如果精度不够,就容易造成误诊,其仿真结果存在误诊也说明了这一点.

支持向量机等机器学习算法具有很好的分类能力,因此本文利用机器学习算法来设计故障分类器,对传感器故障和部件突发故障进行识别和定位. 如果期望利用一个分类机同时实现故障的识别与定位,就要求该分类机具有非常高的学习精度,难以实现. 为了实现高效的故障识别和定位,本文结合局部学习思想[9]和集成学习技术[10],提出一种基于支持向量机-极端学习机-卡尔曼滤波器(SVM-ELM-KF, Support Vector Machine-Extreme Learning Machine-Kalman Filter)的航空发动机传感器故障与部件突发故障诊断方法. 根据集成学习技术,对于给定的学习对象,采用一组精确且尽可能具有不同性质的分类机可以得到更好的分类效果,为此本文采用 SVM 分类机对故障进行识别, 极端学习机(ELM)分类机和卡尔曼滤波器(KF)对故障进行定位,使得故障分类与定位更加准确易于实现.

本文采用 SVM 实现传感器故障和部件故障的识别. SVM 是由文献[11]提出的一种基于统计学理论和结构风险最小化原则的机器学习方法. 和传统的机器学习方法相比,它有良好的泛化能力和不陷入局部最优解的优势. 但是在建立支持向量机的过程中,由于要实现二次优化求解,因而其训练代价比较高. 为了降低计算的复杂度,文献[12]提出了最小二乘支持向量机(LSSVM, Least Square Support Vector Machine),它用等式约束代替不等式约束,最终归结为求线性方程组,大大降低了计算的复杂度. 但是标准的 LSSVM 是不具有稀疏性的,而文献[13]结合约简技术和迭代策略,提出了改进的迭代约简最小二乘支持向量回归机(IRR-LSSVR, Improved Recursive Reduced Least Squares Support Vector Regression),增强了算法的稀疏性. 本文将 IRR-LSSVR 算法推广到分类机,即得到用于分类的改进迭代约简最小二乘支持向量机(IRR-LSSVM, Improved Recursive Reduced Least Squares Support Vector Machine). ELM 是由文献[14]提出的一种新颖的单隐含层前馈神经网络. ELM 用求解线性方程组替代传统的神经网络参数优化的迭代过程,利用矩阵的 Moore-Penrose 广义逆理论解得具有最小范数的最小二乘解作为单输出层权值,相对于传统的网络训练算法,ELM 的训练速度获得了显著提升. 本文 ELM 被用来对传感器故障进行定位.

本文提出首先采用 IRR-LSSVM 对故障类型进行识别. 如果是传感器故障,再利用 ELM 算法对故障进行定位;如果是部件故障,就采用卡尔曼滤波的方法对健康参数进行估计,从而实现对故障的定位,同时又可以通过健康参数反映发动机部件发生故障的程度.

1　改进的迭代约简最小二乘支持向量机(IRR-LSSVM)

给定训练样本(x_i,t_i),$i=1,2,\cdots,N$,其中$x_i\in \boldsymbol{R}^n$,$t_i\in[1\quad -1]$,通过把不等式约束变成等式约束,文献[12]提出了如下最小二乘支持向量分类机的数学模型:

$$\min_{\boldsymbol{w},\boldsymbol{e}} J(\boldsymbol{w},\boldsymbol{e})=\frac{1}{2}\boldsymbol{w}^{\mathrm{T}}\boldsymbol{w}+\frac{C}{2}\sum_{i=1}^{N}e_i^2$$

$$\text{s.t. } t_i(\boldsymbol{w}\cdot\varphi(\boldsymbol{x}_i)+b)=1-e_i \qquad (1)$$

其中,$C\in\boldsymbol{R}^+$是正则化因子;$\boldsymbol{e}=[e_1,e_2,\cdots,e_N]^{\mathrm{T}}$;

$\varphi(\cdot)$ 是一个非线性映射,能把 $\boldsymbol{x}_i$ 从输入空间映射到高维的特征空间,从而实现把输入空间中的非线性问题转化为高维空间中的线性问题. 通过构造 Lagrange 函数可以把式(1)的约束优化转化为无约束优化:

$$L(\boldsymbol{w},b,\boldsymbol{e},\alpha) = J(\boldsymbol{w},\boldsymbol{e}) - \sum_{i=1}^{N}\alpha_i[\boldsymbol{w}\cdot\varphi(\boldsymbol{x}_i) + b - 1 + e_i] \tag{2}$$

其中,$\boldsymbol{\alpha}=[\alpha_1,\alpha_2,\cdots,\alpha_N]^{\mathrm{T}}$ 为 Lagrange 乘子. 由 Karush-Kuhn-Tucker(KKT)条件可知:

$$\frac{\partial L}{\partial \boldsymbol{w}} = 0 \rightarrow \boldsymbol{w} = \sum_{i=1}^{N}\alpha_i t_i \varphi(\boldsymbol{x}_i) \tag{3a}$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^{N}\alpha_i t_i = 0 \tag{3b}$$

$$\frac{\partial L}{\partial \boldsymbol{e}} = 0 \rightarrow \alpha_i = Ce_i, i = 1,2,\cdots,N \tag{3c}$$

$$\frac{\partial L}{\partial \alpha_i} = 0 \rightarrow t_i(\boldsymbol{w}\cdot\varphi(\boldsymbol{x}_i) + b) - 1 + e_i = 0$$

$$i = 1,2,\cdots,N \tag{3d}$$

把式(3a) ~式(3c)代入式(3d),可得如下线性方程:

$$\begin{bmatrix}0 & \boldsymbol{T}^{\mathrm{T}}\\ \boldsymbol{T} & \boldsymbol{\Omega}+\boldsymbol{I}/C\end{bmatrix}\begin{bmatrix}b\\ \boldsymbol{a}\end{bmatrix} = \begin{bmatrix}0 & \boldsymbol{T}^{\mathrm{T}}\\ \boldsymbol{T} & \boldsymbol{Z}\boldsymbol{Z}^{\mathrm{T}}+\boldsymbol{I}/C\end{bmatrix}\begin{bmatrix}b\\ \boldsymbol{a}\end{bmatrix} = \begin{bmatrix}0\\ \boldsymbol{I}\end{bmatrix} \tag{4}$$

其中

$$\boldsymbol{Z} = \begin{bmatrix}t_1\varphi(x_1)\\ \vdots\\ t_N\varphi(x_N)\end{bmatrix}$$

$$\boldsymbol{T} = [t_1,t_2,\cdots,t_N]^{\mathrm{T}}$$

$$\boldsymbol{I} = [1,1,\cdots,1]^{\mathrm{T}}$$

$$\boldsymbol{\Omega} = \boldsymbol{Z}\boldsymbol{Z}^{\mathrm{T}} = [t_i t_j k(x_i,x_j)]_{N\times N}\cdot k(x_i,x_j) = \varphi(x_i)\cdot\varphi(x_j), i,j = 1,2,\cdots,N$$

是满足 Mercer 条件的高斯核函数.

通过求解线性方程组式(3)可以得到 α 和 b 的最优解 $\boldsymbol{\alpha}^*=[\alpha_1^*,\cdots,\alpha_N^*]^{\mathrm{T}}$ 和 b^*,从而可以得到决策函数:

$$f(\boldsymbol{x}) = \mathrm{sign}\left(\sum_{i=1}^{N}\alpha_i^* t_i k(\boldsymbol{x},x_j) + b^*\right) \tag{5}$$

由式(3a)可知,$\boldsymbol{w}$ 与整个训练样本集都有关系,这也就造成了标准的 LSSVM 的解缺乏稀疏性的缺陷. 利用约简技术,强制令 $\boldsymbol{w}=\sum_{i\in S}\alpha_i t_i\varphi(\boldsymbol{x}_i)$,其中 $\{(x_i,t_i)\}_{i\in S}\subset\{(x_i,t_i)\}_{i=1}^{N}$,$S$ 为选择子集索引的集合,代入式(1)得:

$$\min\left\{L(b,\boldsymbol{\alpha}_S) = \frac{1}{2}\boldsymbol{\alpha}_S^{\mathrm{T}}\boldsymbol{K}\boldsymbol{\alpha}_S + \frac{C}{2}\sum_{i=1}^{N}\left(1 - \sum_{j\in S}\alpha_j t_i t_j\varphi(\boldsymbol{x}_j)\varphi(\boldsymbol{x}_i) - t_i b\right)^2\right\} \tag{6}$$

其中,$\boldsymbol{K}_{ij}=t_i t_j k(x_i,x_j)$, $i,j\in S$. 将式(6)写成矩阵形式:

$$\min\left\{L = [b \quad \boldsymbol{\alpha}_S]\left(\begin{bmatrix}0 & \boldsymbol{0}^{\mathrm{T}}\\ \boldsymbol{0} & \boldsymbol{K}/C\end{bmatrix} + \begin{bmatrix}\boldsymbol{T}^{\mathrm{T}}\\ \hat{\boldsymbol{K}}\end{bmatrix}[\boldsymbol{T} \quad \hat{\boldsymbol{K}}^{\mathrm{T}}]\right)\begin{bmatrix}b\\ \boldsymbol{\alpha}_S\end{bmatrix} - 2\left(\begin{bmatrix}\boldsymbol{T}^{\mathrm{T}}\\ \hat{\boldsymbol{K}}\end{bmatrix}\boldsymbol{I}\right)^{\mathrm{T}}\begin{bmatrix}b\\ \boldsymbol{\alpha}_S\end{bmatrix}\right\} \tag{7}$$

令 $\frac{\partial L}{\partial b}=0$ 和 $\frac{\partial L}{\partial \boldsymbol{\alpha}_S}=0$,可得

$$(\boldsymbol{R} + \boldsymbol{Z}\boldsymbol{Z}^{\mathrm{T}})\begin{bmatrix}b\\ \boldsymbol{\alpha}_S\end{bmatrix} = \boldsymbol{Z}\boldsymbol{I} \tag{8}$$

其中,$\boldsymbol{R} = \begin{bmatrix}0 & \boldsymbol{0}^{\mathrm{T}}\\ \boldsymbol{0} & \boldsymbol{K}/C\end{bmatrix}$; $\boldsymbol{Z} = \begin{bmatrix}\boldsymbol{T}^{\mathrm{T}}\\ \hat{\boldsymbol{K}}\end{bmatrix}$; $\hat{\boldsymbol{K}}_{ij} = t_i t_j k(x_i,x_j)$, $i\in S, i=1,2,\cdots,N$.

如果 $\boldsymbol{R}+\boldsymbol{Z}\boldsymbol{Z}^{\mathrm{T}}$ 是奇异的,可以对其进行正则化,使得式(8)有解. 从而可以得到具有稀疏性的决策函数:

$$f(\boldsymbol{x}) = \mathrm{sign}\left(\sum_{i\in S}\alpha_i t_i k(x,x_j) + b\right) \tag{9}$$

式(9)就是约简最小二乘支持向量分类机,和标准的最小二乘支持向量分类机式(5)比较,明显具有稀疏性. 由式(9)可知,$\{(x_i,t_i)\}_{i\in S}$并不知道,如果随机选择,就可能导致分类机的稀疏性不够或者泛化能力下降. 因此本文利用文献[13]中的迭代方法选择支持向量.

将式(8)展开如下:

$$\left(\begin{bmatrix}0 & \boldsymbol{0}^{\mathrm{T}}\\ \boldsymbol{0} & \boldsymbol{K}/C\end{bmatrix} + \begin{bmatrix}\boldsymbol{T}^{\mathrm{T}}\boldsymbol{T} & \boldsymbol{T}^{\mathrm{T}}\hat{\boldsymbol{K}}^{\mathrm{T}}\\ \hat{\boldsymbol{K}}\boldsymbol{T} & \hat{\boldsymbol{K}}\hat{\boldsymbol{K}}^{\mathrm{T}}\end{bmatrix}\right)\begin{bmatrix}b^n\\ \boldsymbol{\alpha}_S^n\end{bmatrix} = \begin{bmatrix}\boldsymbol{T}^{\mathrm{T}}\\ \hat{\boldsymbol{K}}\end{bmatrix}\boldsymbol{I} \tag{10}$$

将式(10)代入式(7),可得如下方程:

$$L^n = -\begin{bmatrix}b^n\\ \boldsymbol{\alpha}_S^n\end{bmatrix}\begin{bmatrix}\boldsymbol{T}^{\mathrm{T}}\\ \hat{\boldsymbol{K}}\end{bmatrix}\boldsymbol{I} \tag{11}$$

其中

$$\begin{bmatrix}b^n\\ \boldsymbol{\alpha}_S^n\end{bmatrix} = \boldsymbol{U}^n\begin{bmatrix}\boldsymbol{T}^{\mathrm{T}}\\ \hat{\boldsymbol{K}}\end{bmatrix}\boldsymbol{I} \tag{12}$$

$$\boldsymbol{U}^n = \left(\begin{bmatrix}0 & \boldsymbol{0}^{\mathrm{T}}\\ \boldsymbol{0} & \boldsymbol{K}/C\end{bmatrix} + \begin{bmatrix}\boldsymbol{T}^{\mathrm{T}}\boldsymbol{T} & \boldsymbol{T}^{\mathrm{T}}\hat{\boldsymbol{K}}^{\mathrm{T}}\\ \hat{\boldsymbol{K}}\boldsymbol{T} & \hat{\boldsymbol{K}}\hat{\boldsymbol{K}}^{\mathrm{T}}\end{bmatrix}\right)^{-1}$$

如果训练样本 x_q 在第 $n+1$ 次迭代被选为支持向量,则

$$\boldsymbol{U}^{n+1} = \left(\begin{bmatrix}0 & \boldsymbol{0}^{\mathrm{T}} & 0\\ \boldsymbol{0} & \boldsymbol{K}/C & \boldsymbol{k}_q/C\\ 0 & \boldsymbol{k}_q^{\mathrm{T}}/C & k_{qq}/C\end{bmatrix} +$$

$$\left.\begin{bmatrix} \boldsymbol{T}^{\mathrm{T}}\boldsymbol{T} & \boldsymbol{T}^{\mathrm{T}}\hat{\boldsymbol{K}}^{\mathrm{T}} & \boldsymbol{T}^{\mathrm{T}}\hat{\boldsymbol{k}}_q \\ \hat{\boldsymbol{K}}\mathrm{T} & \hat{\boldsymbol{K}}\hat{\boldsymbol{K}}^{\mathrm{T}} & \hat{\boldsymbol{K}}\hat{\boldsymbol{k}}_q \\ \hat{\boldsymbol{k}}_q^{\mathrm{T}}\boldsymbol{T} & \hat{\boldsymbol{k}}_q^{\mathrm{T}}\hat{\boldsymbol{K}}^{\mathrm{T}} & \hat{\boldsymbol{k}}_q^{\mathrm{T}}\hat{\boldsymbol{k}}_q \end{bmatrix}\right)^{-1} \tag{13}$$

其中，$\boldsymbol{k}_q = \begin{bmatrix} t_q t_i k(\boldsymbol{x}_q,\boldsymbol{x}_i) \\ \vdots \\ t_q t_i k(\boldsymbol{x}_q,\boldsymbol{x}_j) \end{bmatrix}$，$i, j \in S$，$\hat{\boldsymbol{k}}_q = \begin{bmatrix} t_q t_1 k(\boldsymbol{x}_q,\boldsymbol{x}_1) \\ \vdots \\ t_q t_i k(\boldsymbol{x}_q,\boldsymbol{x}_i) \end{bmatrix}$，$i=1,2,\cdots,N.$

假设 U^n 已知，运用 Sherman-Morrison 迭代公式可以得到下式：

$$U^{n+1} = \begin{bmatrix} U^n & \boldsymbol{0} \\ \boldsymbol{0}^{\mathrm{T}} & 0 \end{bmatrix} + \lambda \begin{bmatrix} \boldsymbol{\beta} \\ -1 \end{bmatrix} [\boldsymbol{\beta}^{\mathrm{T}} \quad -1] \tag{14}$$

其中

$$\boldsymbol{\beta} = U^n \begin{bmatrix} \boldsymbol{T}^{\mathrm{T}}\hat{\boldsymbol{k}}_q \\ \boldsymbol{k}_q/C + \hat{\boldsymbol{K}}\hat{\boldsymbol{k}}_q \end{bmatrix}$$

$$\lambda = (\boldsymbol{k}_{qq}/C + \hat{\boldsymbol{k}}_q^{\mathrm{T}}\hat{\boldsymbol{k}}_q - [\hat{\boldsymbol{k}}_q^{\mathrm{T}}\boldsymbol{T} \quad \hat{\boldsymbol{k}}_q^{\mathrm{T}}\hat{\boldsymbol{K}}^{\mathrm{T}} + \boldsymbol{k}_q^{\mathrm{T}}/C]\boldsymbol{\beta})^{-1}$$

根据式(14)，在第$(n+1)$步，$\boldsymbol{\alpha}_{\mathrm{S}}^{n+1}$ 和 b^{n+1}可以由下式得到

$$\begin{bmatrix} b^{n+1} \\ \boldsymbol{\alpha}_{\mathrm{S}}^{n+1} \\ \alpha_q^{n+1} \end{bmatrix} = U^{n+1} \begin{bmatrix} \hat{0} \\ \hat{\boldsymbol{t}}_{\mathrm{S}} \\ \hat{t}_q \end{bmatrix} =$$

$$\begin{bmatrix} U^n \begin{bmatrix} \hat{0} \\ \hat{t}_{\mathrm{S}} \end{bmatrix} \\ 0 \end{bmatrix} + \lambda \left(\boldsymbol{\beta}^{\mathrm{T}} \begin{bmatrix} \hat{0} \\ \hat{\boldsymbol{t}}_{\mathrm{S}} \end{bmatrix} - \hat{t}_q \right) \begin{bmatrix} \boldsymbol{\beta} \\ -1 \end{bmatrix} \tag{15}$$

其中，$\hat{0} = \sum_{i=1}^{N} t_i$；$\hat{\boldsymbol{t}}_{\mathrm{S}} = \hat{\boldsymbol{K}}\boldsymbol{I}$.

将式(12)代入式(15)得

$$\begin{bmatrix} b^{n+1} \\ \boldsymbol{\alpha}_{\mathrm{S}}^{n+1} \\ \alpha_q^{n+1} \end{bmatrix} = \begin{bmatrix} b^n \\ \boldsymbol{\alpha}_{\mathrm{S}}^{n+1} \\ 0 \end{bmatrix} + \lambda \left(\boldsymbol{\beta}^{\mathrm{T}} \begin{bmatrix} \hat{0} \\ \hat{\boldsymbol{t}}_{\mathrm{S}} \end{bmatrix} - \hat{t}_q \right) \begin{bmatrix} \boldsymbol{\beta} \\ -1 \end{bmatrix} \tag{16}$$

将式(16)代入式(7)得

$$L^{n+1} = L^n - \lambda \left(\boldsymbol{\beta}^{\mathrm{T}} \begin{bmatrix} \hat{0} \\ \hat{\boldsymbol{t}}_{\mathrm{S}} \end{bmatrix} - \hat{t}_q \right)^2 \tag{17}$$

本文定义一个函数：

$$\xi_q^{n+1} = L^n - L^{n+1} = \lambda \left(\boldsymbol{\beta}^{\mathrm{T}} \begin{bmatrix} \hat{0} \\ \hat{\boldsymbol{t}}_{\mathrm{S}} \end{bmatrix} - \hat{t}_q \right)^2 \tag{18}$$

由此将式(18)作为选择支持向量的标准：

$$q = \underset{i \in \{1,2,\cdots,N\} \setminus S}{\arg\max}\, \xi_q^{n+1} \tag{19}$$

2　极端学习机(ELM)

给定训练样本(x_i, t_i)，$i=1,2,\cdots,N$，其中$x_i \in \boldsymbol{R}^n$，$\boldsymbol{t}_i = [t_{i1},\cdots,t_{im}]^{\mathrm{T}} \in \boldsymbol{R}^m$，并设激励函数为 $g(x)$，则含有 L 个隐含层节点的 ELM 的输出函数为

$$\sum_{i=1}^{L} \boldsymbol{\beta}_i g_i(\boldsymbol{x}_j) = \sum_{i=1}^{L} \boldsymbol{\beta}_i g(\boldsymbol{w}_i \cdot \boldsymbol{x}_j + b_i) = t_j \quad j = 1,2,\cdots,N \tag{20}$$

其中，$\boldsymbol{w}_i = [w_{i1}, w_{i2}, \cdots, w_{in}]^{\mathrm{T}}$ 是连接隐含层第 i 节点与输入层节点的权值；b_i 是隐含层第 i 节点的偏置；$\boldsymbol{\beta}_i = [\beta_{i1}, \cdots, \beta_{im}]^{\mathrm{T}}$ 是连接隐含层第 i 节点和输出层节点的权值.

式(20)的 N 个方程可以写为矩阵形式：

$$\boldsymbol{H}\boldsymbol{\beta} = \boldsymbol{T} \tag{21}$$

其中

$$\boldsymbol{H}(\boldsymbol{w}_i,\cdots,\boldsymbol{w}_L,b_1,\cdots,b_L,\boldsymbol{x}_1,\cdots,\boldsymbol{x}_N) = \begin{bmatrix} g(\boldsymbol{w}_1 \cdot \boldsymbol{x}_1 + b_1) & \cdots & g(\boldsymbol{w}_L \cdot \boldsymbol{x}_1 + b_L) \\ \vdots & \cdots & \vdots \\ g(\boldsymbol{w}_1 \cdot \boldsymbol{x}_N + b_1) & \cdots & g(\boldsymbol{w}_L \cdot \boldsymbol{x}_N + b_L) \end{bmatrix}_{N \times L} \tag{22}$$

$$\boldsymbol{\beta} = [\beta_1,\cdots,\beta_L]_{m\times L}^{\mathrm{T}}$$

$$\boldsymbol{T} = [t_1,\cdots,t_N]_{m\times N}^{\mathrm{T}}$$

式中，$\boldsymbol{H}$ 称为神经网络的输出层矩阵；$\boldsymbol{H}$ 的第 i 列是相对于输入 $\boldsymbol{x}_1,\cdots,\boldsymbol{x}_N$ 的第 i 个隐含层节点的输出向量. 输入权值 $\boldsymbol{w}_i$ 和隐含层节点偏差 b_i 是随机给定的，输出权值$\boldsymbol{\beta}$：

$$\boldsymbol{\beta} = \boldsymbol{H}^{\dagger}\boldsymbol{T} \tag{23}$$

其中 $\boldsymbol{H}^{\dagger}$ 是神经网络输出层矩阵 $\boldsymbol{H}$ 的 Moore-Penrose 广义逆.

对于输出层矩阵 $\boldsymbol{H} \in \boldsymbol{R}^{N\times L}$，假设 $N \geqslant L$ 并且 $\mathrm{rank}(\boldsymbol{H}) = L$，在这种条件下，求解方程(7)可以转化为求下面方程组的解：

$$(\boldsymbol{H}^{\mathrm{T}}\boldsymbol{H} + \boldsymbol{I}/C)\boldsymbol{\beta} = \boldsymbol{H}^{\mathrm{T}}\boldsymbol{T} \tag{24}$$

通过求解式(24)，可以得到方程组式(21)的最小二乘解：

$$\boldsymbol{\beta} = (\boldsymbol{H}^{\mathrm{T}}\boldsymbol{H} + \boldsymbol{I}/C)^{-1}\boldsymbol{H}^{\mathrm{T}}\boldsymbol{T} \tag{25}$$

因此，ELM 的决策函数为

$$f(\boldsymbol{x}) = \mathrm{sign}(h(\boldsymbol{x})\beta) = \mathrm{sign}(h(\boldsymbol{x})(\boldsymbol{H}^{\mathrm{T}}\boldsymbol{H} + \boldsymbol{I}/C)^{-1}\boldsymbol{H}^{\mathrm{T}}\boldsymbol{T}) \tag{26}$$

其中，$h(\boldsymbol{x}) = [g(\boldsymbol{w}_1 \cdot \boldsymbol{x} + b_1),\cdots,g(\boldsymbol{w}_L \cdot \boldsymbol{x} + b_L)]$.

3　传感器与部件故障诊断系统设计

当航空发动机发生传感器故障和部件突发性故障时，传感器输出信号所受到的影响是有所区

别的. 当传感器发生故障时,只有故障传感器的输出会发生变化,而其他传感器不受影响. 但是如果航空发动机部件发生故障,由于发动机各部件之间共同工作的要求,发动机的各输出参数均会受到影响,表现为即使不是装在故障部件位置的传感器,其输出也发生变化. 根据这一特征,可以利用模式识别的方法对航空发动机传感器故障和部件故障进行区分.

首先利用 IRR-LSSVM 设计一个传感器故障和部件故障的分类器,根据传感器的测量信号对两种故障进行区分. 当故障发生时,首先利用设计的 IRR-LSSVM 分类机对故障进行分类;如果是传感器故障,再利用 ELM 分类机对传感器故障位置进行定位;如果是部件故障,采用改进的卡尔曼滤波器对部件健康参数进行估计,从而实现对部件故障的定位. 基于 SVM-ELM-KF 的传感器故障与部件故障诊断系统如图 1 所示.

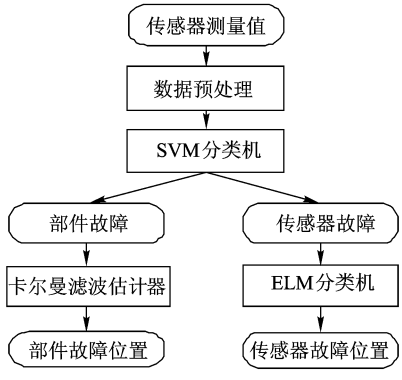

图 1 航空发动机传感器故障与部件故障诊断系统框图

鉴于常规卡尔曼滤波器在建模不确定情况下会存在稳态估计误差,而用于设计卡尔曼滤波器的状态变量模型和非线性部件模型或真实发动机之间必然存在建模误差,为此本文采用改进的卡尔曼滤波器来估计健康参数. 改进的卡尔曼滤波器在输入通道中增加估计偏差的积分项,使滤波输入包含偏差的累积激励,以消除稳态估计偏差.

首先建立真实发动机在退化量作用下的小偏差状态变量模型,用来描述退化量对发动机的影响,其形式如下:

$$\left.\begin{aligned}\Delta\dot{\boldsymbol{x}} &= \boldsymbol{A}\cdot\Delta\boldsymbol{x} + \boldsymbol{B}\cdot\Delta\boldsymbol{u} + \boldsymbol{L}\cdot\Delta\boldsymbol{d}\\ \Delta\boldsymbol{y} &= \boldsymbol{C}\cdot\Delta\boldsymbol{x} + \boldsymbol{D}\cdot\Delta\boldsymbol{u} + \boldsymbol{M}\cdot\Delta\boldsymbol{d}\end{aligned}\right\} \tag{27}$$

式中,$\Delta\boldsymbol{x}=[\Delta N_{\mathrm{f}} \quad \Delta N_{\mathrm{c}}]^{\mathrm{T}}$ 分别是发动机风扇和压气机转速的增量;$\Delta\boldsymbol{u}=[\Delta W_{\mathrm{fb}} \quad \Delta A_8]^{\mathrm{T}}$ 分别是主燃油和尾喷口面积的增量;$\Delta\boldsymbol{d}$ 为退化量;$\boldsymbol{A},\boldsymbol{B},\boldsymbol{C},\boldsymbol{D},\boldsymbol{L},\boldsymbol{M}$ 为适维矩阵.

改进的卡尔曼滤波估计器最优状态估计公式表示为

$$\begin{bmatrix}\Delta\dot{\boldsymbol{x}}\\ \Delta\dot{\boldsymbol{d}}\end{bmatrix} = (\tilde{\boldsymbol{A}} - \boldsymbol{K}\cdot\tilde{\boldsymbol{C}})\begin{bmatrix}\Delta\boldsymbol{x}\\ \Delta\boldsymbol{d}\end{bmatrix} + (\tilde{\boldsymbol{B}} - \boldsymbol{K}\cdot\tilde{\boldsymbol{D}})\cdot\Delta\boldsymbol{u} + \boldsymbol{K}\cdot(\Delta\boldsymbol{y} + \Delta\boldsymbol{y}') \tag{28}$$

式中,$\tilde{\boldsymbol{A}}=\begin{bmatrix}\boldsymbol{A} & \boldsymbol{L}\\ \boldsymbol{0} & \boldsymbol{0}\end{bmatrix}$;$\tilde{\boldsymbol{B}}=\begin{bmatrix}\boldsymbol{B}\\ \boldsymbol{0}\end{bmatrix}$;$\tilde{\boldsymbol{C}}=[\boldsymbol{C} \quad \boldsymbol{M}]$;$\tilde{\boldsymbol{D}}=\boldsymbol{D}$;$\Delta\boldsymbol{y}'$为 $\Delta\boldsymbol{y}$ 的积分;$\boldsymbol{K}$ 为卡尔曼滤波增益阵.

通过式(28)便可以估计出发动机的退化量,从而对部件故障进行定位.

4 数字仿真

本文以某型带加力燃烧室的混合排气双轴涡扇发动机的部件级模型为对象. 分别选取表 1 所示的 8 个健康参数以及表 2 所示的 8 个传感器进行故障模拟及仿真验证[4]. 在稳态工作条件下,对表 1 所示的 8 个健康参数分别退化 1%,2%,3%,4%,5% 来模拟部件故障;对表 2 所示的 8 个传感器分别进行 1%,2%,3%,4%,5% 的偏置故障模拟,这样就可以得到这个工作点的 80 组训练数据,用于训练 SVM 故障分类模型和 ELM 故障定位模型. 再对表 1 所示的 8 个健康参数分别退化 1.5%,2.5%,3.5%,4.5%;表 2 中的 8 个传感器分别进行 1.5%,2.5%,3.5%,4.5% 的偏置故障,得到 64 组测试数据,用于测试分类的效果.

表 1 健康参数

参数项	健康参数	参数含义
1	η_{f}	风扇效率退化量
2	φ_{f}	风扇流量退化量
3	η_{c}	压气机效率退化量
4	φ_{c}	压气机流量退化量
5	η_{h}	高压涡轮效率退化量
6	φ_{h}	高压涡轮流量退化量
7	η_{l}	低压涡轮效率退化量
8	φ_{l}	低压涡轮流量退化量

表 2 传感器位置描述

参数项	传感器变量	参数含义
1	N_{f}	风扇转速
2	N_{c}	压气机转速
3	P_{13}	外涵道进口压力
4	T_{25}	压气机进口温度
5	P_3	压气机出口压力
6	T_3	压气机出口温度
7	P_6	低压涡轮出口压力
8	T_6	低压涡轮出口温度

表 3 给出了不同稳态工作点下航空发动机传感器故障与部件故障区分的统计数据,包含 80 组训练数据测试结果和 64 组测试数据的验证结果,为了说明本文方法的优越性,表格中同时给出了标准 LSSVM 和 RR-LSSVM 分类方法的仿真结果. 从表中可以看出,本文所提出的 IRR-LSSVM 分类

机,能够有效区分传感器故障与部件故障,并且不存在误诊情况. 与标准的 LSSVM 和 RR-LSSVM 相比,IRR-LSSVM 支持向量更少,占用内存更小,运算速度更快,大大提高了诊断系统的实时性.

识别出故障的类型之后,就要对故障进行定位. 当为传感器故障时,采用 ELM 分类机对传感器故障进行定位,图 2 给出了 $H=0$ km,$M=0$,油门杆角度 $\alpha_{pla}=50°$ 条件下的测试效果. 从图 2 可以看出,ELM 分类机能准确地对传感器故障进行定位. 而对于部件故障的定位,采用改进的卡尔曼滤波器的方法,在 $H=0$ km,$M=0$,$\alpha_{pla}=50°$ 条件下,表 1 所示的健康参数分别退化 2.5% 来模拟部件故障. 健康参数的估计结果如图 3 所示. 从图 3 中可以看出,当发动机部件故障时,改进的卡尔曼滤波器能够准确的估计出健康参数的退化量. 从而能够对发动机的部件故障进行很好的定位. 虽然本文提出的方法对传感器和部件故障同时发生的情况无法进行有效诊断,但是对于航空发动机来说,传感器故障与部件故障同时出现的几率比较小,因此,本文提出的方法在工程实际中具有一定的理论指导意义.

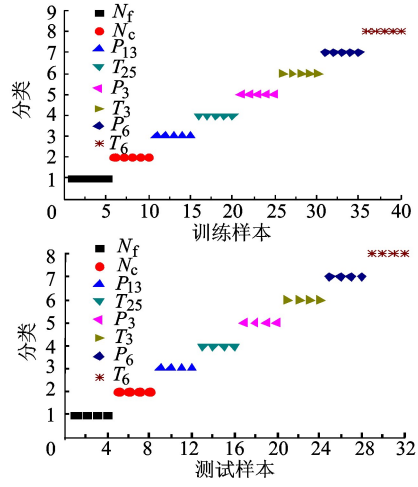

图 2　传感器故障分类仿真结果

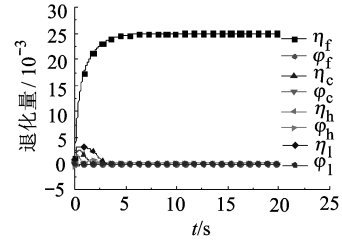

a　风扇效率退化

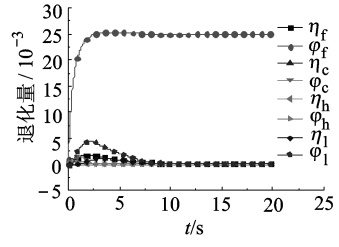

b　风扇流量退化

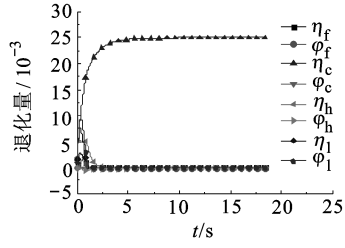

c　压气机效率退化

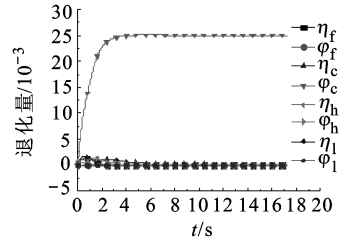

d　压气机流量退化

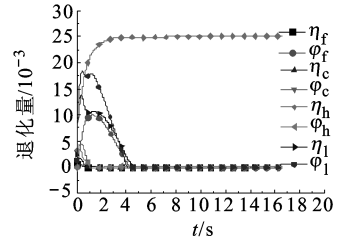

e　高压涡轮效率退化

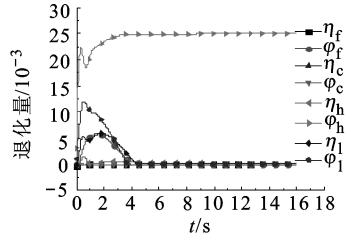

f　高压涡轮流量退化

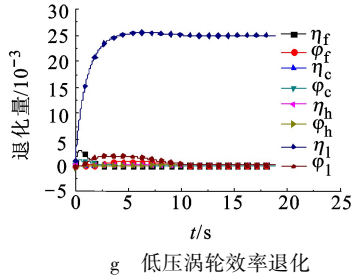

g　低压涡轮效率退化

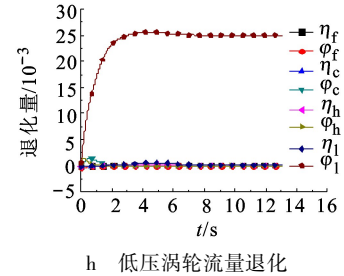

h　低压涡轮流量退化

图 3　航空发动机部件健康参数估计结果($H=0$ km,$M=0$,$\alpha_{pla}=50°$)

表 3 故障诊断仿真结果

仿真条件	C	γ	算法	训练时间/s	测试时间/s	训练样本	测试样本	支持向量个数	误诊率/%
$H=0$ km, $M=0$, $\alpha_{pla}=50°$	2^{10}	2^{-4}	Normal LSSVM	0.0382	0.0145	80	64	80	0
			RR-LSSVM	0.0513	0.0088	80	64	46	0
			IRR-LSSVM	0.0608	0.0072	80	64	38	0
$H=12$ km, $M=0.8$, $\alpha_{pla}=50°$	2^{10}	2^{-3}	Normal LSSVM	0.0377	0.0143	80	64	80	0
			RR-LSSVM	0.0514	0.0089	80	64	48	0
			IRR-LSSVM	0.0597	0.0071	80	64	38	0
$H=15$ km, $M=1.2$, $\alpha_{pla}=50°$	2^{10}	2^{-4}	Normal LSSVM	0.0379	0.0146	80	64	80	0
			RR-LSSVM	0.0504	0.0082	80	64	44	0
			IRR-LSSVM	0.0625	0.0072	80	64	39	0

注：C 为正则化参数；γ 为核参数.

5 结 论

本文提出的基于 SVM-ELM-KF 的航空发动机传感器故障与部件突发故障诊断方法，有效实现了两种故障的区分和定位. 该方法将用于回归问题的 IRR-LSSVR 设计思想推广到分类问题中，用于训练传感器故障与部件故障的分类机，提高了诊断系统的实时性. 当诊断为传感器故障时，利用 ELM 分类机对传感器故障实现了准确定位；当诊断为部件故障时，利用改进卡尔曼滤波器所包含的积分环节，实现了健康参数的无静差估计，从而实现对部件故障的精确定位. 本文所提出的传感器故障与部件故障诊断方法在工程实际中具有一定的理论指导意义.

参考文献（References）

[1] Garg S. Controls and health management technologies for intelligent aerospace propulsion systems[R]. AIAA-2004-0949, 2004

[2] Sanjay G. Controls and health management technologies for intelligent aerospace propulsion systems[R]. AIAA-2004-0949, 2004

[3] Link C. Recent advancements in aircraft engine health management (EHM) technologies and recommendations for next step [R]. ASME GT2005-68625, 2005

[4] Kobayashi T, Simon D L. Evaluation of an enhanced band of Kalman filters for in-flight aircraft engine fault sensor fault diagnostics[J]. Engineering for Gas Turbines and Power, 2005, 127: 497-504

[5] 覃道亮，何皑，孔祥兴，等. 基于 UIO 的航空发动机控制系统传感器故障诊断[J]. 航空动力学报，2011，26(6)：1396-1404
Tan Daoliang, He Ai, Kong Xiangxing, et al. UIO-based sensor fault diagnosis for aero-engine control systems[J]. Journal of Aerospace Power, 2011, 26(6): 1396-1404 (in Chinese)

[6] 陈恬，孙健国，郝英. 基于神经网络和证据融合理论的航空发动机气路故障诊断[J]. 航空学报，2006，27(6)：1014-1017
Chen Tian, Sun Jianguo, Hao Ying. Neural network and dempster-shafter theory based fault diagnosis for aero-engine gas path [J]. Journal of Aerospace Power, 2006, 27(6): 1014-1017 (in Chinese)

[7] 鲁峰，黄金泉，陈煜，等. 基于 SPSO-SVR 的融合航空发动机传感器故障诊断[J]. 航空动力学报，2009，24(8)：1856-1865
Lu Feng, Huang Jinquan, Chen Yu, et al. Research on performance fault fusion diagnosis of aero-engine component[J]. Journal of Aerospace Power, 2009, 24(8): 1856-1865 (in Chinese)

[8] 仇小杰，黄金泉，鲁峰，等. 基于云关联度的航空发动机传感器、部件故障识别系统设计[J]. 航空动力学报，2011，26(11)：2584-2592
Qiu Xiaojie, Huang Jinquan, Lu Feng, et al. Fault diagnosis system design for the sensors and components of aircraft engine based on cloud relational analysis[J]. Journal of Aerospace Power, 2011, 26(11): 2584-2592 (in Chinese)

[9] Bottou L, Vapnik V. Local learning algorithms[J]. Neural Computation, 1992, 6(4): 888-900

[10] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119-139

[11] Vapnik V. The nature of statical learning theory[M]. NewYork, USA: Springer-Verlag, 1995

[12] Suykens J A K, Vandewalle J. Least square support vector machine[J]. Neural Processing Letters, 1999, 9(3): 293-300

[13] Zhao Yong ping, Sun Jianguo, Du Zhonghua, et al. An improved recursive least square support vector regression[J]. Neurocomputing, 2012, 87: 1-9

[14] Huang Guangbin, Zhu Qinyu, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70: 489-501

（编 辑：张 嵘）