

# 基于动态 PCA 与改进 SVM 的航空发动机故障诊断\*

崔建国<sup>1</sup>, 严雪<sup>1</sup>, 蒲雪萍<sup>2</sup>, 齐义文<sup>1</sup>, 蒋丽英<sup>1</sup>, 师建强<sup>2</sup>

(1. 沈阳航空航天大学自动化学院 沈阳, 110136) (2. 中国燃气涡轮研究院 成都, 610500)

**摘要** 为了对航空发动机进行高效地故障诊断, 确保飞机的飞行安全, 提出了一种基于动态主元分析和改进支持向量机的航空发动机智能故障诊断方法。该方法结合了动态主元分析(principal component analysis, 简称 PCA)在特征提取方面和改进支持向量机(support vector machine, 简称 SVM)在故障诊断方面的优势。动态 PCA 方法对所涉及的过程变量进行去噪、降维、消除相关性等预处理和特征提取, 采用改进 SVM 方法将所得的特征向量进行故障诊断。所提出的方法可解决航空发动机模型精度和传感器测量参数有限情况下的滑油系统故障诊断精度差、效率低和易误诊、漏诊等问题。以某型真实航空发动机滑油系统为例, 对提出方法的有效性进行试验验证。结果表明, 采用的动态 PCA 和改进 SVM 故障诊断方法能有效提高故障诊断正确率, 实现航空发动机滑油系统故障诊断的效能, 具有较好的应用价值与前景。

**关键词** 航空发动机; 滑油系统; 动态主元分析; 改进支持向量机; 故障诊断

**中图分类号** TP206.3; TH165.3

## 引言

对航空发动机进行有效监控和诊断是实现航空发动机视情维护、降低使用维护成本、保证飞行安全的关键<sup>[1]</sup>。航空发动机滑油系统的健康状况将直接影响飞机的飞行安全。据统计, 航空发动机滑油系统故障在发动机故障中占有较高比例<sup>[2]</sup>。因此, 对航空发动机滑油系统进行有效监控和智能故障诊断, 可提高航空发动机的故障诊断率, 降低其虚警率<sup>[1]</sup>。近年来, 国内外很多学者致力于航空发动机故障诊断研究。由于发动机使用环境的限制, 不可能测量很多参数, 且得到的测量数据并不完全。如何从有限的监视信息中正确诊断出发动机的故障便成为了一个技术难点<sup>[3-4]</sup>。结构的复杂性、故障的多样性和监视信息的有限性决定了用传统的故障诊断技术很难建立起一套完整且准确的分析模型。随着智能故障诊断技术在故障诊断领域中的广泛应用, 它也被引入到了发动机故障诊断研究领域<sup>[5]</sup>。

笔者提出采用动态主元分析<sup>[6-7]</sup>和改进支持向

量机<sup>[8-9]</sup>的方法对某型航空发动机滑油系统进行智能故障诊断。首先利用动态 PCA 方法对涉及的过程变量进行去噪、降维、消除相关性等预处理和特征提取, 再采用改进 SVM 方法将特征向量进行特征层融合诊断。试验结果表明, 动态 PCA 和改进 SVM 建模方法能够很好地实现故障诊断效能。

## 1 基于动态 PCA 故障特征提取机理

PCA 是一种多变量统计分析算法, 用于对具有高度相关性的测量数据进行分析 and 处理。它利用坐标变换的思想, 将高维空间问题转化为低维空间处理, 使问题变得比较简单、直观。但 PCA 特征提取方法中训练的数据  $\mathbf{X}$  只有变量和采样次数两维数据, 它假设某一时刻的观测数据与历史的观测数据序列无关。这种假设在采样时间间隔较长时是有效的, 但当采样时间间隔较短时, 除了要考虑不同变量之间的互相关性, 还需要考虑自相关性。改进的方法就是采用动态 PCA 技术。

动态 PCA 特征提取方法是将原变量的静态数

\* 辽宁省自然科学基金资助项目(2014024003); 航空科学基金资助项目(2010ZD54012); 国防技术基础科研项目(Z052012B002)

收稿日期: 2013-05-28; 修回日期: 2013-08-13

据利用动态时间序列构造动态时间数据,再运用 PCA 方法进行特征提取,这样就能够有效地提取系统变量间的动态关系,从而准确地描述系统的动态行为。

假设采样正常工况下的观测数据集  $\mathbf{X}$ , 其包含  $m$  个观测变量, 每个变量有  $n$  个观测值,  $\mathbf{X}$  可以表达为

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} = \begin{bmatrix} x_1^t \\ x_2^t \\ \vdots \\ x_n^t \end{bmatrix} \quad (1)$$

其中:  $x_i \in \mathbf{R}^m (i=1,2,\dots,n)$  为一个  $m$  维的观测向量。

根据动态时间序列的思想对  $\mathbf{X}$  进行扩展, 即将某个时刻  $t$  前面  $h$  个观测对每个观测向量进行扩充, 可得

$$\mathbf{X}(h) = \begin{bmatrix} \mathbf{x}_t^T & \mathbf{x}_{t-1}^T & \cdots & \mathbf{x}_{t-h}^T \\ \mathbf{x}_{t-1}^T & \mathbf{x}_{t-2}^T & \cdots & \mathbf{x}_{t-h-1}^T \\ \vdots & \vdots & & \vdots \\ \mathbf{x}_{t-n+h}^T & \mathbf{x}_{t-n+h-1}^T & \cdots & \mathbf{x}_{t-n}^T \end{bmatrix} \quad (2)$$

其中:  $\mathbf{x}_t^T$  为  $t$  时刻在训练集中的  $m$  维观测向量。

计算滞后因子  $h$  的方法为: 首先, 处理  $h=0$  的静态情况, 数据矩阵中的静态关系系数等于变量数与主元个数之差; 然后, 令  $h=1$ , 计算新的动态关系系数, 新的动态关系系数等于变量数减去主元个数和第一步计算出的静态关系系数,  $h$  函数逐渐增加。新关系函数  $r_{\text{new}}(h)$  递推计算公式为

$$r_{\text{new}}(h) = r(h) - \sum_{i=0}^{h-1} (h-i+1)r_{\text{new}}(i) \quad (3)$$

直至  $r_{\text{new}}(h) \leq 0$ , 即持续到没有新的静态和动态关系为止。

采用动态 PCA 特征提取的过程实际上是对增广矩阵采用 PCA 特征提取的过程。具体步骤如下:

- 1) 采集数据;
- 2) 根据式(3)计算滞后因子的方法, 计算滞后因子;
- 3) 根据式(2)构造出动态数据矩阵, 并将矩阵转化成均值为 0、方差为 1 的标准数据矩阵;
- 4) 根据式  $\sum = \frac{1}{n-1} \mathbf{X}^T \mathbf{X}$ , 计算协方差矩阵  $\sum$ ;
- 5) 计算主元方差向量  $[\lambda_1, \lambda_2, \dots, \lambda_m]^T$  和对应负载矩阵  $[p_1, p_2, \dots, p_m]$ ;

6) 根据方差累计和百分比,  $\text{CPV} = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^m \lambda_i}$  来确定主元个数, 一般取  $\text{CPV} \geq 85\%$ ;

7) 当主元个数  $k$  确定之后, 则选取前  $k$  个特征值对应的特征向量作为提取的特征。

## 2 基于 SVM 的故障诊断机理

### 2.1 传统 SVM 的故障诊断机理

支持向量机核心思想是选择最小的结构风险, 解决学习机的学习能力和泛化能力之间的矛盾。SVM 通过核函数把原数据空间映射到高维的特征空间, 在特征空间最大化分类间隔构造最优分类超平面, 这一过程无需任何先验知识, 且分类面只需少量的支持向量就能表示<sup>[10-11]</sup>。SVM 克服了神经网络的不足, 在解决小样本、非线性及高维故障诊断中表现出结构简单、全局最优、泛化能力强等优势。

对于两分类的非线性问题, 设定样本集  $T = \{(x_1, y_1), \dots, (x_n, y_n)\}$ , 其中:  $x_i \in X = \mathbf{R}^M$ ;  $\mathbf{R}^M$  为输入空间;  $M$  为输入变量数; 样本所属类别  $y_i \in \{-1, +1\}$ ;  $n$  为样本数。在式(4)

$$\sum_{i=1}^n y_i a_i = 0 \quad (0 \leq a_i \leq C; i=1, 2, \dots, n) \quad (4)$$

的约束条件下, 最优目标函数  $W(a)$  为

$$W(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j a_i a_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (5)$$

相应的分类决策函数  $f(\mathbf{x})$  为

$$f(\mathbf{x}) = \text{sgn} \left[ \sum_{i=1}^n y_i a_i K(\mathbf{x}, \mathbf{x}_i) + b \right] \quad (6)$$

其中:  $\mathbf{x}_i$  为支持向量;  $\mathbf{x}$  为未知向量;  $b$  为分类阈值;  $a_i, a_j$  为 Lagrange 乘子。

SVM 是针对两类分类问题提出的。将 SVM 推广到多分类问题, 大体上有两种途径: 直接法和分解法。分解法又可以分为一对多、一对一、有向无环图和二叉树多分类法。其中, 一对一的方法性能较为优越, 笔者采用此算法。

一对一多分类方法在各个类别之间两两构造 SVM 分类器, 对  $m$  类问题共需构造  $m(m-1)/2$  个, 每个 SVM 由相应的两类样本进行训练。当  $m(m-1)/2$  个 SVM 建立后, 可以采用最大赢投票法(max-wins voting)对待检测样本  $x$  进行分类。当第  $i$  类和第  $j$  类的 SVM <sub>$ij$</sub>  判断  $x$  属于第  $i$  类, 则第

$i$  类的票数加 1, 否则第  $j$  类的票数加 1。当所有的  $SVM_{i,j}$  都判断完毕, 则把  $x$  分到得票最多的那一类。

## 2.2 改进 SVM 故障诊断机理

传统 SVM 在处理多分类时, 只考虑了 2 种极端的情况, 由  $SVM_{i,j}$  独立计算得到的属于第  $i$  类的概率估计值  $\hat{P}_{i,j}(i|x)$  取值是 0 或 1, 没有考虑到在  $SVM_{i,j}$  中第  $j$  类出现的概率情况, 因此笔者对 SVM 的改进就是将其估计值  $\hat{P}_{i,j}(i|x)$  进行一定的修正。

$P_{i,j}(i|x)$  表示用 SVM 分类时, 属于第  $i$  类的概率, 同时也可将其理解为在第  $j$  类发生的条件下, 样本属于第  $i$  类的后验概率。因此根据贝叶斯概率公式, 待分类的样本  $x$  属于第  $i$  类的最终后验概率为

$$P(i|x) = \sum_{j=1, j \neq i}^N \{P_{i,j}(i|x)P(j)\} \quad (i=1, 2, \dots, N) \quad (7)$$

其中:  $P(j)$  表示第  $j$  类的条件概率。

式(7)可知, 当采用  $SVM_{i,j}$  分类时, 属于第  $i$  类的概率  $P_{i,j}(i|x)$  取值不再是 0 或 1, 而必须考虑条件概率  $P(j)$ 。条件概率  $P(j)$  往往是未知, 需要对其进行近似估计。根据  $P(j)$  的含义, 其与后验概率  $P(j|x)$  之间存在着明显的相似性, 则建立近似估计为

$$\hat{P}(j) = k\hat{P}(j|x) \quad (8)$$

其中:  $k$  为平衡系数, 经推导  $k \approx 2/(N-1)$ 。

将其代入式(7), 得到

$$P(i|x) = \frac{2}{N-1} \sum_{j=1, j \neq i}^N \{P_{i,j}(i|x)P(j|x)\} \quad (i=1, 2, \dots, N) \quad (9)$$

式(9)可以看作是由  $N(N-1)/2$  个两类  $SVM_{i,j}$  的分类结果  $P_{i,j}(i|x)$ , 求解  $N$  个未知变量  $P(i|x), i=1, 2, \dots, N$  的多元线性方程组。

由式(7)建立矩阵方程

$$\begin{bmatrix} \Theta^T \\ \Omega \end{bmatrix} P = \begin{bmatrix} \mathbf{1} \\ \mathbf{O} \end{bmatrix} \quad (10)$$

其中:  $\mathbf{O} = [0 \ 0 \ \dots \ 0]^T$ ;  $\mathbf{P} = [P(1|x) \ P(2|x) \ \dots \ P(N|x)]^T$ ;  $\Omega =$

$$\begin{bmatrix} N-1 & -2P_{1,2}(1|x) & \dots & -2P_{1,N}(1|x) \\ -2P_{2,1}(2|x) & N-1 & \dots & -2P_{2,N}(1|x) \\ \vdots & \vdots & \ddots & \vdots \\ -2P_{N,1}(1|x) & -2P_{N,2}(1|x) & \dots & N-1 \end{bmatrix};$$

$\Theta^T = [0 \ 0 \ \dots \ 0]^T$ ;  $\mathbf{P}$  为综合评分矩阵。

运用最小二乘法求解上式, 在得到的综合评分矩阵中, 每类样本中得分最高的类别即为样本所属类别。

传统 SVM 在处理多分类时, 不可避免地会出现由于投票票数相同而无法判断样本最终类别的情况。采用改进 SVM 可以大大减小这类事件的发生概率, 有效提高多分类器分类的正确率。

## 3 航空发动机滑油系统智能故障诊断试验

航空发动机在工作过程中广泛使用轴承和齿轮等部件来支撑转动转子和传递功率。这些部件由于相互运动而产生摩擦, 而摩擦将进一步导致磨损和产生大量的热量。滑油系统的作用就是形成滑油油膜并带走磨损产物和热量, 维持轴承和齿轮的正常温度状态, 并在轴承的滚道与滚子之间、相啮合的齿面间形成连续的油膜起到润滑的作用<sup>[12]</sup>。笔者以某型真实航空发动机为例, 采用动态 PCA 和改进 SVM 相结合的智能故障诊断方法对其进行故障诊断。航空发动机滑油系统故障诊断技术方案如图 1 所示。笔者针对某型航空发动机, 采用滑油系统故障诊断专用试验平台对其进行长期的试验, 得到大量试验数据。

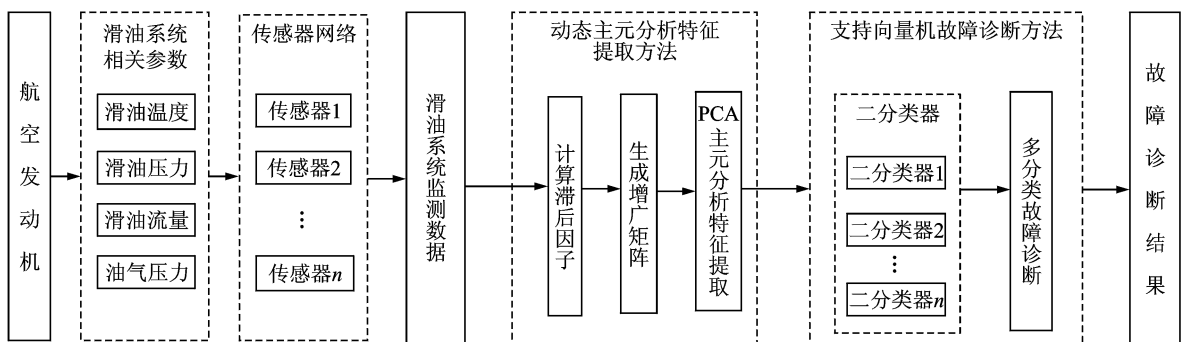


图 1 航空发动机滑油系统故障诊断技术方案

Fig. 1 The fault diagnosis technology solutions of aero-engine lubrication system

研究表明,采用能较好地表征发动机滑油系统健康状态的滑油温度、滑油压力、滑油流量以及油气压力作为航空发动机滑油系统健康状态的表征参数。其健康状态模式集合可表示为  $\{A_1, A_2, A_3, A_4, A_5\}$ ,  $A_1$  表示航空发动机滑油系统正常工作状态;  $A_2$  表示航空发动机滑油系统三级油泵损坏;  $A_3$  表示航空发动机滑油油气排气管堵塞;  $A_4$  表示航空发动机滑油系统放油开关故障,油气排气管堵塞;  $A_5$  表示航空发动机滑油系统离心通风器故障,系统气塞。试验中,每种健康状态选取 30 个样本对 SVM 进行训练。为了验证网络的推广能力和模型精度,另外每种状态选取 4 个样本做测试。

考虑到航空发动机滑油系统采样时间间隔较短,不仅要考虑不同变量之间的互相关性,还需考虑变量本身的自相关性。因此笔者采用动态 PCA 技术。根据式(3)滞后因子计算求得本次试验数据  $h=1$ ,则新的增广矩阵的维数为  $M = m(h + 1) = 4(1 + 1) = 8$ ,采用 PCA 主元提取方法对增广矩阵进行特征提取。经试验,当贡献率大于 85% 时,共提取 3 个主元成分。滑油系统状态信息特征提取结果如表 1 所示。

根据支持向量机一对一多分类的基本思路,对于航空发动机滑油系统 5 种典型故障之间两两构造,形成 10 个二分类器。由动态 PCA 特征提取的主元向量作为故障训练样本集,分别对 10 个二分类器进行独立训练,构造对应的 SVM 决策函数。分别采用线性核函数  $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$ 、多项式核函数  $K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T \mathbf{x}_j + 1)^d$ 、径向基核函数  $K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2})$  进行实验研究。在采用径向基核函数训练 SVM 过程时,通过交叉验证法获取最佳参数  $C=1$ ,径向基参数  $\sigma=1$ 。表 2 以径向基核函数的 SVM 为例,给出了各个 SVM 分类器对测试样本的诊断结果。

表 1 滑油系统健康状态动态 PCA 特征提取结果

Tab. 1 Feature extraction results based on dynamic PCA of lubrication system health condition

| 健康状态  | 特征向量                     |
|-------|--------------------------|
| $A_1$ | (0.814, -0.600, -0.792)  |
|       | (0.864, 0.637, -1.087)   |
|       | ⋮                        |
| $A_2$ | (0.390, 0.524, -0.991)   |
|       | (-1.926, -2.406, 0.656)  |
|       | (-2.377, -2.292, 0.955)  |
| $A_3$ | ⋮                        |
|       | (-1.589, -2.610, 0.355)  |
|       | (-0.141, -0.166, -1.551) |
| $A_4$ | (-0.206, -0.469, -1.566) |
|       | ⋮                        |
|       | (-0.628, -0.151, -1.698) |
| $A_5$ | (-1.271, 2.033, 0.999)   |
|       | (-1.422, 2.477, 0.513)   |
|       | ⋮                        |
| $A_5$ | (-1.958, 2.477, 0.513)   |
|       | (3.216, -0.752, 0.917)   |
|       | (3.815, 0.455, 0.948)    |
| $A_5$ | ⋮                        |
|       | (3.238, 0.513, 0.904)    |

由 SVM<sub>*i,j*</sub> 决策函数的符号判断待诊断样本的隶属关系(1 属于第 *i* 类, -1 属于第 *j* 类),根据传统支持向量机分类原则,测试集各样本在 5 种健康状态类型中的综合分析及诊断结果如表 3 所示。

由表 3 试验结果可知,由于样本 3 中状态  $A_1$  和状态  $A_2$  的综合得分相同,样本 5 中状态  $A_1$  和状态  $A_4$  的综合得分也是相同,使之无法判断发动机最终的健康状态,导致有两个拒分样本,得到的故障诊断正确率为 90%。采用其他不同核函数做故障诊断时过程类似,表 4 为采用不同核函数时对 5 种状态的 20 个样本进行测试的结果。当采用 SVM 进行一对一多分类时,会不可避免地出现得分相同的情

表 2 测试样本在不同 SVM 下的诊断结果

Tab. 2 Diagnosis results of test samples based on different SVM

| 样本 | SVM <sub>1,2</sub> | SVM <sub>1,3</sub> | SVM <sub>1,4</sub> | SVM <sub>1,5</sub> | SVM <sub>2,3</sub> | SVM <sub>2,4</sub> | SVM <sub>2,5</sub> | SVM <sub>3,4</sub> | SVM <sub>3,5</sub> | SVM <sub>4,5</sub> |
|----|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|
| 1  | 1                  | 1                  | 1                  | 1                  | -1                 | 1                  | -1                 | 1                  | 1                  | -1                 |
| 2  | -1                 | 1                  | 1                  | 1                  | 1                  | 1                  | 1                  | 1                  | -1                 | -1                 |
| 3  | -1                 | 1                  | 1                  | 1                  | -1                 | 1                  | 1                  | 1                  | -1                 | -1                 |
| 4  | 1                  | -1                 | 1                  | 1                  | -1                 | 1                  | -1                 | 1                  | 1                  | -1                 |
| 5  | 1                  | 1                  | -1                 | 1                  | -1                 | 1                  | -1                 | -1                 | -1                 | 1                  |
| ⋮  | ⋮                  | ⋮                  | ⋮                  | ⋮                  | ⋮                  | ⋮                  | ⋮                  | ⋮                  | ⋮                  | ⋮                  |
| 20 | 1                  | 1                  | 1                  | -1                 | -1                 | 1                  | -1                 | 1                  | -1                 | -1                 |

况,这样导致样本拒分,以至于无法判断健康状态类型,使故障诊断正确率下降。

以表 3 中样本 3 为例,采用改进支持向量机的方法判断故障类型。先由表 2 所示的各个 SVM 输出结果独立计算测试样本 3 属于第  $i$  类的概率  $P_{i,j}(i|x)$ ,代入式(11)得到矩阵方程

$$\begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 2 & -1 & -1 & 0 & -1 \\ 0 & 2 & 0 & -1 & 0 \\ -1 & 0 & -1 & 2 & -1 \\ 0 & -1 & -1 & 0 & 2 \end{bmatrix} P = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

表 3 测试样本诊断结果与实际结果对比

Tab. 3 The comparison between diagnosis results and actual results of test samples

| 样本       | $A_1$    | $A_2$    | $A_3$    | $A_4$    | $A_5$    | 诊断结果     | 实际结果     |
|----------|----------|----------|----------|----------|----------|----------|----------|
| 1        | 4        | 1        | 3        | 0        | 2        | $A_1$    | $A_1$    |
| 2        | 3        | 4        | 1        | 0        | 2        | $A_2$    | $A_2$    |
| 3        | 3        | 3        | 2        | 0        | 2        | 拒分       | $A_2$    |
| 4        | 3        | 1        | 4        | 0        | 2        | $A_3$    | $A_3$    |
| 5        | 3        | 1        | 1        | 3        | 2        | 拒分       | $A_4$    |
| $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ |
| 20       | 3        | 1        | 2        | 0        | 4        | $A_5$    | $A_5$    |

表 4 基于传统 SVM 方法的不同核函数故障诊断对比结果

Tab. 4 The comparison results of different kernel functions of fault diagnosis based on the traditional SVM methods

| 核函数       | 线性  | 多项式 | 径向基 |
|-----------|-----|-----|-----|
|           | 核函数 | 核函数 | 核函数 |
| 误诊样本数     | 1   | 3   | 0   |
| 拒分样本数     | 2   | 1   | 2   |
| 故障诊断准确率/% | 85  | 80  | 90  |

上述方程可由最小二乘法进行求解,得到测试样本 3 的得分  $P = [0.246\ 3\ 0.270\ 8\ 0.206\ 9\ 0.069\ 1\ 0.171\ 7]^T$ ,很显然  $P(2|x) = 0.270\ 8$  最大,故判断样本 3 属于  $A_2$  类。同样经过类似计算,测试样本 5 的得分为  $P = [0.243\ 4\ 0.176\ 2\ 0.117\ 6\ 0.284\ 0\ 0.166\ 6]^T$ ,  $P(4|x) = 0.284\ 0$  最大,则样本 5 属于  $A_4$  类。笔者将上述 3 种不同核函数的传统 SVM 结果进行改进,结果如表 5 所示。

根据试验结果,航空发动机滑油系统主要参数经过动态主元分析特征提取后,再采用核函数为径向基的改进支持向量机方法进行智能故障诊断,其

表 5 基于改进 SVM 方法的不同核函数故障诊断对比结果

Tab. 5 The comparison results of different kernel functions of fault diagnosis based on the improved SVM methods

| 核函数   | 线性  | 多项式 | 径向基 |
|-------|-----|-----|-----|
|       | 核函数 | 核函数 | 核函数 |
| 误诊样本数 | 1   | 3   | 0   |
| 拒分样本数 | 0   | 0   | 0   |
| 准确率/% | 95  | 85  | 100 |

准确率得到了大幅提高。表明该方法对航空发动机滑油系统进行智能故障诊断,取得了很好的效果,实现了航空发动机的诊断效能。

## 4 结束语

采用基于动态 PCA 和改进 SVM 技术对航空发动机滑油系统进行智能故障诊断技术研究。试验研究表明,采用动态 PCA 技术对滑油系统主要参数进行特征提取,不仅可以充分考虑到参数的静态及动态特性,解决了数据的自相关问题,还可以使故障标准模式大幅度降维,较好地实现故障模式的分离。在此基础上采用 3 种不同核函数的 SVM 对特征向量进行故障诊断。传统 SVM 在处理多分类问题时,由于测试结果拒分类,导致诊断率的下降,而采用改进支持向量机算法可以明显提高故障诊断率,实现了智能故障诊断。试验表明,本研究采用的智能诊断方法对航空发动机滑油系统故障诊断是可行的,为航空发动机智能故障诊断提供了新的思路。

## 参 考 文 献

- [1] 孙闯,何正嘉,张周锁,等. 基于状态信息的航空发动机运行可靠性评估[J]. 机械工程学报, 2013, 49(6): 30-37.  
Sun Chuang, He Zhengjia, Zhang Zhouso, et al. Operating reliability assessment for aero-engine based on condition monitoring information[J]. Journal of Mechanical Engineering, 2013, 49(6): 30-37. (in Chinese)
- [2] 龚志飞,郭迎清. 基于主元分析法的航空发动机传感器故障诊断研究[J]. 计算机测量与控制, 2012, 20(8): 2017-2023.  
Gong Zhifei, Guo Yingqing. Investigation of aero-engine fault diagnosis based on principal component analysis[J]. Computer Measurement & Control, 2012, 20

- (8): 2017-2023. (in Chinese)
- [3] 刘永斌,何清波,孔凡让,等. 基于 PCA 和 SVM 的内燃机故障诊断[J]. 振动、测试与诊断, 2012, 32(2): 250-255.  
Liu Yongbin, He Qingbo, Kong Fanrang, et al. Fault diagnosis of internal combustion engine using PCA and SVM[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 250-255. (in Chinese)
- [4] 钱征文,程礼,范家栋,等. 某型航空发动机振动值摆动故障诊断[J]. 振动、测试与诊断, 2012, 32(2): 208-213.  
Qian Zhengwen, Cheng Li, Fan Jiadong, et al. Fault diagnosis of vibration amplitude swing for some kind of aeroengine[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 208-213. (in Chinese)
- [5] Sampath S, Gulati A, Singh R. Artificial intelligence techniques for gas turbine engine fault diagnostics[C] // 38th AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit. Indianapolis: American Institute of Aeronautics and Astronautics, 2002.
- [6] 刁广州,赵丽萍,要义勇. 动态可调主元分析的多元自相关质量控制方法[J]. 西安交通大学学报, 2013, 47(3): 24-29.  
Diao Guangzhou, Zhao Liping, Yao Yiyong. The dynamic regulated principal component analysis for multivariate autocorrelation process quality control method [J]. Journal of Xi'an Jiaotong University, 2013, 47(3): 24-29. (in Chinese)
- [7] 石怀涛,刘建昌,丁晓迪,等. 基于混合动态主元分析的故障检测方法[J]. 控制工程, 2012, 19(1): 148-151.  
Shi Huaitao, Liu Jianchang, Ding Xiaodi, et al. Fault detection based on hybrid dynamic principal component analysis[J]. Control Engineering of China, 2012, 19(1): 148-151. (in Chinese)
- [8] 曹冲锋,杨世锡,周晓峰,等. 改进支持向量机模型的旋转机械故障诊断方法[J]. 振动、测试与诊断, 2009, 29(3): 270-273.  
Cao Chongfeng, Yang Shixi, Zhou Xiaofeng, et al. Fault diagnosis of rotating machinery based on an improved support vector machines model[J]. Journal of Vibration, Measurement & Diagnosis, 2009, 29(3): 270-273. (in Chinese)
- [9] 王晓红. 基于概率投票策略的多类支持向量机及应用[J]. 计算机工程, 2009, 35(2): 181-183.  
Wang Xiaohong. Multi-class SVMs based on probability voting strategy and its application[J]. Computer Engineering, 2009, 35(2): 181-183. (in Chinese)
- [10] Ribeiro B, Silva C, Chen N, et al. Enhanced default risk models with SVM+ [J]. Expert Systems with Applications, 2012, 39(11): 10140-10152.
- [11] Li Xianwei, Chen Guolong. Face recognition based on PCA and SVM[C]//2012 International Symposium on Photonics and Optoelectronics. [S. l.]: IEEE Transaction on Symposium on Photonics and Optoelectronics, 2012.
- [12] 赵升红. 航空发动机与航空润滑油[M]. 北京: 中国石化出版社, 2012: 1-10.



**第一作者简介:**崔建国,男,1963年8月生,博士后、教授。主要研究方向为飞行器健康诊断、预测与综合健康管理、可视化仿真技术与应用。曾发表《基于遗传算法和 ARMA 模型的航空发电机寿命预测》(《航空学报》2011 年第 32 卷第 8 期)等论文。

E-mail: gordon\_cjg@163.com