

文章编号: 1000-8055(2005)02-0298-05

基于支持向量机的航空发动机故障诊断

徐启华¹, 师 军²

(1 淮海工学院 电子工程系, 江苏 连云港 222005;

2 西北工业大学 自动控制系, 陕西 西安 710072)

摘要: 支持向量机是一种具有完备统计学习理论基础和出色学习性能的新型机器学习方法,它能够较好地克服神经网络容易出现的过学习和泛化能力低等缺陷。提出一种基于支持向量机的航空发动机故障诊断方法,应用该方法成功地对发动机气路部件的几种典型故障进行了正确诊断。在对检验样本施加噪声后,支持向量机构成的故障分类器仍然能够满足发动机故障诊断的要求,表明提出的故障诊断算法具有良好的鲁棒性,可以作为工程应用的基础。

关键词: 航空、航天推进系统; 航空发动机; 支持向量机; 故障诊断; 鲁棒性

中图分类号: V 263.6; TP181

文献标识码: A

Aero-Engine Fault Diagnosis Based on Support Vector Machine

XU Qi-hua¹, SHI Jun²

(1. Electronic Engineering Department,

Huaihai Institute of Technology, Lianyungang 222005;

2. Automatic Control Department,

Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: The capabilities of Support Vector Machine (SVM) applied to aero-engine fault diagnosis (i.e. classification of multiple faults) were investigated. The gas path components of a jet engine were selected to gather datasets for the evaluation of the classification capabilities. With the proposed approach, 24 sets of component single fault testing data from the datasets were classified into 5 single faults and 16 sets of multiple faults testing data were classified into 8 faults. The single faults are low pressure compressor (LP) fault, high pressure compressor (HP) fault, low pressure turbine (LT) fault, high pressure turbine (HT) fault and no fault; while the multiple faults are LP+HP, HP+HT, HT+LT, LP+LT and LP+HP+LT+HT faults. There is no misclassification for all of the testing data using SVM. When the datasets are masked with noise as great as 12% in single faults and 10% in multiple faults, the effectiveness and robustness of the fault diagnosis algorithms are still satisfactory.

Key words: aerospace propulsion system; aero-engine; support vector machines; fault diagnosis; robustness

收稿日期: 2004-05-24; **修订日期:** 2004-09-22

基金项目: 江苏省高校自然科学研究计划项目(04KJD510018); 连云港市科技计划项目(GY200401); 淮海工学院自然科学研究计划项目(Z2003018)

作者简介: 徐启华(1962-),男,陕西山阳人,淮海工学院电子工程系教师,博士,主要从事非线性系统故障诊断与容错控制,智能控制,机器学习的研究

近几年来, 神经网络因其强大的并行处理能力、任意函数逼近能力以及自学习、自组织、自适应等特点而在航空发动机故障诊断领域得到了较多应用, 已成为发动机智能故障诊断的重要手段之一^[1~4]。但是, 神经网络是一种依赖于经验的启发式技术, 它的学习过程采用经验风险最小化 (ERM, Empirical Risk Minimization) 原则, 因而在小样本情况下, 容易出现过学习 (over-fitting) 现象从而导致低的泛化能力; 另外, 神经网络算法的复杂性受网络结构复杂性和样本复杂性的影响较大。这些不足, 使神经网络在故障诊断中的应用效果远不如期望的那样好^[5,6]。支持向量机 (SVM, Support Vector Machines) 是 Vapnik 提出的一种新型机器学习方法, 它具有完备的统计学习理论基础和出色的学习性能, 已经成为机器学习界的研究新热点, 并在模式识别、回归分析、函数逼近、信号处理等领域得到了成功应用^[5,7~9]。支持向量机根据结构风险最小化 (SRM, Structural Risk Minimization) 原则, 可以尽量提高学习机的泛化能力, 同时, 它将优化问题转化为求解一个凸二次规划的问题, 二次规划所得的解是唯一的全局最优解, 这样就不存在一般神经网络的局部极值问题。另外, 它巧妙地解决了维数问题, 使得其算法的复杂度与样本维数无关。本文尝试采用支持向量机算法, 在小样本基础上, 构建航空发动机故障诊断模型, 进行航空发动机故障诊断。

1 支持向量机的基本原理

发动机的故障诊断问题可以转化为对数据的分类问题。采用支持向量机对数据进行分类的主要思想是: 通过事先选择的非线性映射将输入向量映射到高维特征空间, 在这个空间中构造满足分类要求的线性最优超平面 (optimal hyperplane) 来分割训练样本集, 并且使训练样本集中的点距离该最优超平面尽可能地远, 即使超平面两侧的空白区域 (margin) 最大。

进行非线性分类的具体算法如下。

训练样本 $T = \{(x_i, d_i)\}_{i=1}^n$, 其中 $x_i \in R^l$ 是第 i 个输入模式, $d_i \in \{+1, -1\}$ 是对应的期望输出。

首先用一非线性映射 $\Phi(x) = [\Phi_1(x), \Phi_2(x), \dots, \Phi_N(x)]^T$ 把输入数据从原空间映射到 N 维特征空间, 在特征空间中构造最优分类超平面:

$$\sum_{j=1}^N w_j \Phi_j(x) + b = 0$$

其中 $w = [w_1, w_2, \dots, w_N]^T$ 表示把特征空间连接到输出空间的线性权值向量, b 表示偏置, 它们是 SVM 设计时需要确定的参数。上述问题即为在满足条件:

$$d_i \left[\sum_{j=1}^N w_j \Phi_j(x_i) + b \right] \geq 1 - \xi_i$$

时最小化 $\|w\|$ 的问题^[5], 这里 ξ_i 为松弛变量。写成标准形式为:

$$\left. \begin{aligned} \min J(w, \xi) &= \frac{1}{2} w \cdot w + c \sum_{i=1}^n \xi_i \\ \text{s.t.} \quad d_i \left[\sum_{j=1}^N w_j \Phi_j(x_i) + b \right] &\geq 1 - \xi_i \\ \xi_i &\geq 0, \quad i = 1, 2, \dots, n \end{aligned} \right\} \quad (1)$$

c 为影响分类精度的可调参数。用 Lagrange 乘子法求解这一优化问题, 建立 Lagrange 函数:

$$L(w, b, \xi, \alpha, \beta) = \frac{1}{2} w \cdot w + c \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i \{d_i [w^T \Phi(x_i) + b] - 1 + \xi_i\} - \sum_{i=1}^n \beta_i \xi_i \quad (2)$$

其中 α_i, β_i 为非负的 Lagrange 乘子。根据优化条件:

$$\frac{\partial L}{\partial w} = 0 \qquad \frac{\partial L}{\partial b} = 0 \qquad \frac{\partial L}{\partial \xi} = 0$$

得到:

$$\sum_{i=1}^n \alpha_i d_i = 0 \qquad w = \sum_{i=1}^n \alpha_i d_i \Phi(x_i) \qquad c - \alpha_i - \beta_i = 0 \quad (3)$$

把 (3) 代入 (2), 由式 (1) 描述的问题转化为最大化下面的泛函:

$$Q(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j d_i d_j [\Phi^T(x_i) \cdot \Phi(x_j)]$$

SVM 并不直接求解高维特征空间的点积 $\Phi^T(x_i) \cdot \Phi(x_j)$, 而是用原空间的核函数代替它。核函数是满足 Mercer 条件的对称函数:

$$K(x, x_i) = \Phi(x)^T \cdot \Phi(x_i) = \sum_{j=1}^N \Phi_j(x) \Phi_j(x_i)$$

最终, 优化问题转化为:

$$\left. \begin{aligned} \max Q(\alpha) &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j d_i d_j K(x_i, x_j) \\ \text{s.t.} \quad &\sum_{i=1}^n \alpha_i d_i = 0 \\ &0 \leq \alpha_i \leq c, \quad i = 1, 2, \dots, n \end{aligned} \right\} \quad (4)$$

把它整理成以 α 为变量的标准形式二次优化问题, 可以方便地利用MATLAB的优化工具箱求解。求出各 α 后, 即可得到 w , 并可根据全部支持向量(support vector)得到 b 的平均值:

$$b = \frac{1}{I_s} \sum_{i \in I} \left[d_i - \sum_{j=1}^n d_j \alpha_j K(x_i, x_j) \right]$$

I 为支持向量的集合, I_s 为支持向量的个数。

样本训练完成后, 获得数据分类的最优超平面、支持向量和相应参数构成的分类器。测试样本 x 按下式进行分类预测:

$$f(x) = \text{sgn} \left[\sum_{i=1}^n d_i \alpha_i K(x, x_i) + b \right] \quad (5)$$

选择不同的核函数, 可构造不同的SVM, 常用的核函数有多项式核函数、Gauss核函数、Sigmoid核函数等, 我们采用Gauss核函数:

$$K(x, x_i) = \exp \left(- \frac{|x - x_i|^2}{2\sigma^2} \right)$$

2 基于支持向量机的航空发动机故障诊断方法与诊断实例

2.1 诊断方法

SVM 是二元分类器, 对于多个故障类型的航空发动机, 必须构造多元分类器才能进行故障诊断。有文献采用“one-against-one”方法构造多元分类器^[6], 其基本思想是: 对 m 元分类问题建立 $M = m(m-1)/2$ 个SVM, 每两类之间训练一个SVM 将彼此分开, 预测新样本时, 使用成对的SVM 进行比较, 每次产生一个优胜者, 然后在优胜者之间依次再进行比较, 直至最后仅剩一个优胜者。事实上, 预测新样本时, 并不需要对每两类之间的优胜者再次进行竞争淘汰, 两类之间比较获胜次数最多的类, 即为新样本所属的故障类别。本文采用了基于上述思想的多类故障诊断方法, 这种方法单个SVM 训练规模较小, 易于扩展。

当获胜次数最多的故障类别(故障类别 I)优势不明显时, 比如, 故障类别 II 的获胜次数与故障

类别 I 的获胜次数相差很近, 为了避免误诊, 可以在这两类故障之间再进行一次判别, 如果故障类别 I 获胜, 则最终的故障类别即为 I 类; 如果故障类别 II 获胜, 则考虑采用其他的故障诊断手段。

2.2 诊断实例

航空发动机的故障一般分为气路部件故障、附件故障和转子机械故障3类, 在上述3类故障中, 气路部件故障往往是潜在且难以判断的, 因此对它进行研究具有重要的实际意义^[10]。本文以一双转子涡喷发动机为实例, 采用支持向量机进行气路部件故障诊断。支持向量机的输入参数为8个, 包括: 高、低压转速 N_H, N_L ; 高、低压压气机出口压力 P_2, P_3 ; 高、低压涡轮出口压力 P_4, P_5 ; 高压压气机出口温度 T_2 ; 低压涡轮出口温度 T_4 。上述参数均采用偏离基准状态的相对量表示, 无量纲。

故障诊断在MATLAB 6.5 环境下实现。诊断时, 对输入参数在 $[0, 1]$ 上进行了归一化处理。

2.2.1 单一故障的诊断

双转子涡喷发动机气路部件单一故障种类有: 无故障(NON), 低压压气机故障(LP), 高压压气机故障(HP), 低压涡轮故障(LT)和高压涡轮故障(HT)。若只需判别气路部件有无故障, 训练一个SVM 即可; 若要诊断出上述5类故障, 则需训练10个SVM。

用文献[10]表7-3中的样本1~48训练SVM, 样本49~72进行检验, 取 $c=100, \sigma^2=0.2$ 。在2类故障模式和5类故障模式两种情况下, 训练好的SVM 对全部检验样本均给出了正确的分类结果。

根据计算结果, 在2类故障模式下, 48个训练样本中有19个样本成为支持向量, 它们的样本号是: 5, 6, 10, 11, 12, 15, 17, 18, 23, 25, 28, 29, 31, 34, 37, 40, 42, 46, 48, 其中, 样本5, 6, 10, 11, 12, 15, 17, 18, 23 在无故障类的边界上, 其余样本在有故障类的边界上, 这些支持向量离分类边界最近。对于任一个检验样本, 故障分类器依据式(5)进行分类, 如

果判别函数 $\sum_{i=1}^{48} d_i \alpha_i K(x, x_i) + b \geq 0$, 属于无故障类, 否则属于有故障类。图 1 给出了全部检验样本的判别函数分布情况, 样本 49~ 56 的判别函数为正, 属于无故障类; 样本 57~ 72 的判别函数为负, 属于有故障类。图 2 是仅利用参数 N_L, N_H 和 P_x 在三维空间中给出的样本点的分类情况, 其中, 方形点代表无故障类边界上的支持向量 S_N , 三角形点代表有故障类边界上的支持向量 S_F ; “+”点代表检验样本 49~ 56, 可以看出, 它们离 S_N 更近, 属于无故障类; “*”点代表检验样本 57~ 72, 它们离 S_F 更近, 属于有故障类。这些计算结果与实际情况完全相符。




图1 检验样本的判别函数

Fig 1 The discriminant function values are positive for non-failure class samples, negative for failure class samples




图2 三维空间中样本点的分类

Fig 2 In 3-dimensional space, sample points fall inside their class separation band

在5类故障模式下也有类似的具体计算结果。为了考察支持向量机故障分类器的鲁棒性, 对样本49~ 72施加噪声后再进行检验。以8个输入参数相应训练样本的均值、方差来生成正态分布信

号, 该信号乘以百分比系数后作为噪声加入。在5类故障模式下, 用训练好的故障分类器对施加噪声的样本进行检验, 结果, 噪声百分比系数从0增加到12%, 24个检验样本的故障分类仍然正确。这一诊断结果说明, SVM故障分类器对气路部件的单一故障具有良好的鲁棒性。

2.2.2 复合故障诊断

双转子涡轮发动机气路部件有8种复合故障模式: LP+HP, HP+HT, HT+LT, LP+LT, LP, HP, HT, LT。诊断时, 用文献[10]表7-5中的样本1~32训练, 样本33~48检验, 取 $c=1$, $\sigma^2=0.2$ 。检验结果为: 16个检验样本的故障类别全部诊断正确。

图3给出了3个检验样本在依次使用成对的SVM进行比较时各故障类别的获胜次数。其中, 37号样本第7类故障的获胜次数最多, 为7次, 且与获胜次数为6的第2类故障比较时仍然获胜, 该样本即为第7类故障HT; 同理, 42号样本第1类故障的获胜次数最多, 它即为第1类故障LP+HP; 48号样本第4类故障的获胜次数最多, 它的故障类别即为第4类LP+LT; 上述诊断结果与样本的实际故障类别完全一致。其它检验样本也有类似的诊断结果。




图3 不同故障类别的获胜次数

Fig 3 For the 3 samples, failure classes have different win frequencies

对样本33~ 48施加与单一故障情形类似的噪声后再进行检验, 当噪声百分比系数从0增加到10%时, 故障分类结果也完全正确。

已有文献表明^[10], 对于上述复合故障, 应用自组织竞争神经网络和自组织特征映射神经网络(SOFM)进行诊断的效果不理想, 需要再次进行故障信息特征提取。本文的分类结果说明, 支持向量机对于发动机气路部件的复合故障具有良好的诊

断能力。

利用文献[10]表7-5中经过特征提取后的样本训练支持向量机,训练完成的分类器对检验样本仍然给出了完全正确的诊断结果。

3 结 论

基于支持向量机的故障诊断技术能够避免一般神经网络容易出现的过学习、局部极小等不足,且算法简单,容易实现。通过实例验证,支持向量机对航空发动机气路部件的典型单一故障与复合故障具有良好的诊断能力,可以为航空发动机提供一种快速、可靠的智能故障诊断方法。

参考文献

- [1] 陈恬,孙健国,杨蔚华,等. 自组织神经网络航空发动机气路故障诊断[J]. 航空学报, 2003, 24(1): 46~48
CHEN Tian, SUN Jian-guo, YANG Wei-hua, et al. Self-Organizing Neural Network Based Fault Diagnosis for Aeroengine Gas Path[J]. *Acta Aeronautica ET Astronautica Sinica*, 2003, 24(1): 46~48
- [2] 蒋东翔,王风雨,周明,等. 模糊自组织神经网络在航空发动机故障诊断中的应用[J]. 航空动力学报, 2001, 16(1): 80~82
JIANG Dong-xiang, WANG Fengyu, ZHOU Ming, et al. Application of Fuzzy Self-Organizing Neural Network to Aeroengine Fault Diagnosis[J]. *Journal of Aerospace Power*, 2001, 16(1): 80~82
- [3] 杨建国,孙扬,郑严. 基于小波神经网络的涡喷发动机故障诊断[J]. 推进技术, 2001, 22(2): 114~117
YANG Jian-guo, SUN Yang, ZHENG Yan. Fault Diagnosis of Turboengine Based on Wavelet and Fuzzy Neural Network[J]. *Journal of Propulsion Technology*, 2001, 22(2): 114~117
- [4] 朱家元,邓振挺,张恒喜,等. 基于自组织拓扑映射图的发动机故障诊断研究[J]. 航空动力学报, 2002, 17(5): 533~537.
ZHU Jia-yuan, DENG Zhen-ting, ZHANG Heng-xi, et al. Aeroengine Fault Diagnosis Based on Self-Organizing Topology Maps[J]. *Journal of Aerospace Power*, 2002, 17(5): 533~537.
- [5] Simon Haykin. *Neural Networks: A Comprehensive Foundation*, (Second Edition) [M]. Beijing: China Machine Press, 2004
- [6] 杨云,朱家元,张恒喜. 基于新型机器学习的电子装备系统智能故障诊断研究[J]. 计算机工程与应用, 2003, 22: 210~213
YANG Yun, ZHU Jia-yuan, ZHANG Heng-xi. Electronic Equipment Systems Intelligent Fault Diagnosis Based on New Machine Learning Approach[J]. *Computer Engineering and Applications*, 2003, 22: 210~213
- [7] Chiang Leo H, Kotanchek Mark E, Kordon Arthur K. Fault Diagnosis Based on Fisher Discriminant Analysis and Support Vector Machines[J]. *Computers & Chemical Engineering*, 2004, 28(8): 1389~1401
- [8] Samanta B, Al-Balushi K R, Al-Araimi S A. Artificial Neural Networks and Support Vector Machines with Genetic Algorithm for Bearing Fault Detection[J]. *Engineering Applications of Artificial Intelligence*, 2003, 16(7): 657~665
- [9] Jack L B, Nandi A K. Support Vector Machines for Detection and Characterization of Rolling Element Bearing Faults[J]. *Journal of Mechanical Engineering Science*, 2001, 215(9): 1065~1074
- [10] 杨蔚华. 航空发动机建模及故障诊断[D]. 南京: 南京航空航天大学, 2000
YANG Wei-hua. Aeroengine Modeling and Failure Diagnosis[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2000