

文章编号: 1000-6893(2005)06-0686-05

应用 SVM 的发动机故障诊断若干问题研究

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 自动化学院, 陕西 西安 710072)

Some Studies in Aero-engine Fault Diagnosis Using Support Vector Machines

XU Qi-hua¹, SHI Jun²

(1. Electronic Engineering Department, Huaihai Institute of Technology, Lianyungang 222005, China)

(2. College of Automatic Control, Northwestern Polytechnical University, Xi an 710072, China)

摘要: 支持向量机能够克服一般神经网络容易出现的过学习和泛化能力低等不足。提出一种基于支持向量机的航空发动机气路部件故障诊断方法, 讨论了支持向量机的核函数选择和参数确定问题, 并对“块算法”进行了分析。仿真实验表明, 设计的正则化参数和核参数合理, 故障分类器具有良好的分类准确性和泛化性能, 可以对发动机气路部件的典型故障进行正确诊断。

关键词: 航空发动机; 支持向量机; 故障诊断; 核函数; 泛化

中图分类号: V235.1; TP181 **文献标识码:** A

Abstract: Support vector machines can avoid over-fitting and have better generalization ability as compared with neural networks. In this paper, the support vector machines based fault diagnosis algorithms are developed for aero-engines. The influence of kernel function is discussed and the chunking algorithms are analyzed. The methods are presented to select normalized parameter and kernel parameter. With the proposed algorithms, the support vector machines can give correct fault diagnosis results for the gas path components of an aero-engine. The results show that the fault diagnosis algorithms are also able to meet the application requirements and can keep robust when the measurement inputs are disturbed by noises.

Key words: aero-engine; support vector machines; fault diagnosis; kernel; generalization

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, 已经成为当前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^[1~4]。SVM 的突出特点是采用结构风险最小化 (SRM, structural risk minimization) 学习原则, 可以从根本上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惟一的全局最优解, 这样就不存在一般神经网络的局部极值问题; 而且, 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。

航空发动机的故障诊断问题实质上是模式分类问题^[5,6], 文献 [6] 讨论了基于 SVM 分类算法的发动机故障诊断问题, 证明 SVM 是解决这一问题的一种有效方法。但是, 像 SVM 在其他领域的应用一样, 利用 SVM 进行故障诊断的一些

实现技术仍然没有很好解决, 比如, 核函数的选择和核函数参数的确定, 控制训练精度和泛化能力的正则化参数的确定, 快速高效的学习算法等等, 这些问题使 SVM 的通用性受到限制, 并阻碍了 SVM 泛化性能的进一步提高^[1,7~9]。本文将研究上述问题, 期望通过具体实例的分析, 为解决 SVM 在发动机故障诊断中的技术困难提供一条途径。

1 应用 SVM 的发动机故障诊断方法

文中输入参数为 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_x ; 高、低压涡轮出口压力 P_y, P_4 ; 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。故障诊断的任务就是根据得到的输入参数推断出相应的故障模式。

气路部件故障分为单一型和复合型, 单一型故障模式有: 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); 8 种复合故障模式

收稿日期: 2005-03-28; 修订日期: 2005-08-22

基金项目: 江苏省高校自然科学基金计划 (04 KJD510018)、连云港市科技计划 (GY200401) 资助项目

分别是:LP+HP,HP+HT,HT+LT,LP+LT,LP,HP,HT,LT。

下面简单介绍基本二分类 SVM 算法。

对于训练样本 $(x_i, d_i) \quad \mathbf{R}^l \times \{+1, -1\}, i = 1, 2, \dots, n$, SVM 的原始优化问题为

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

应用核函数理论后,得到的对偶问题为

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

这里,各参数的意义与通常文献中的一致^[1,9]。

测试样本 x 的决策规则为

$$f(x) = \text{sgn} \left[\sum_{i=1}^n a_i d_i K(x, x_i) + b \right] \quad (3)$$

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。本文采用一种新的多元 SVM 故障分类方法,其思路是:对 m 元故障分类问题,首先用一个 SVM 把全部训练样本分为 2 类,再分别各用一个 SVM 把上述 2 类故障细分,如此重复,直到分出基本的故障类别。随着 m 的增加,上述分类方法在需要训练的 SVM 个数上有很大的优势,比较起来,可以大幅度地减少计算工作量和存储空间。

对单一型故障,用文献[10]表 7-3 中的样本 1-48 训练 SVM,样本 49-72 进行检验。选择 Gauss 型核函数来构造 SVM,核函数的形式为

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

取正则化参数 $c = 1.6$,核函数宽度 $\sigma^2 = 0.05$,训练好的 SVM 对全部检验样本均给出了正确的分类结果。SVM 的训练和检验在 MATLAB 6.5 环境下实现,其中,输入参数在 $[0, 1]$ 上进行了归一化处理。

图 1 给出了 LP 故障与 HP 故障的诊断过程和诊断结果,其中,检验样本有 24 个,序号 1-24 分别表示表 7-3 中的检验样本 49-72;纵轴中的决策函数值由 $\sum_{i=1}^n a_i d_i K(x, x_i) + b$ 给出,故障分类器根据这个决策值的正负来进行故障分类。第 1 步,故障分类器把全部 24 个检验样本分为无故障(NON)类和有故障类,样本 49-56 为 NON 类,图中用实心三角形表示,其余样本为有故障类,图中用“+”符号表示;第 2 步,故障分类器继续把 16 个有故障类样本再划分为 P 故障类和 T 故障类,样本 57-60,65-66,69-70 为 P 故障类,图中用实心点表示,其余样本为 T 故障类,图中用“*”符号表示;第 3 步,故障分类器最后把 8 个 P 故障类样本细分为最基本的 LP 故障类与 HP 故障类,样本 57-58,65,69 为 LP 故障类,图中用方形点表示,另外 4 个样本 59-60,66,70 为 HP 故障类,图中用五角星符号表示。这一诊断结果与实际情况完全一致。

障(NON)类和有故障类,样本 49-56 为 NON 类,图中用实心三角形表示,其余样本为有故障类,图中用“+”符号表示;第 2 步,故障分类器继续把 16 个有故障类样本再划分为 P 故障类和 T 故障类,样本 57-60,65-66,69-70 为 P 故障类,图中用实心点表示,其余样本为 T 故障类,图中用“*”符号表示;第 3 步,故障分类器最后把 8 个 P 故障类样本细分为最基本的 LP 故障类与 HP 故障类,样本 57-58,65,69 为 LP 故障类,图中用方形点表示,另外 4 个样本 59-60,66,70 为 HP 故障类,图中用五角星符号表示。这一诊断结果与实际情况完全一致。

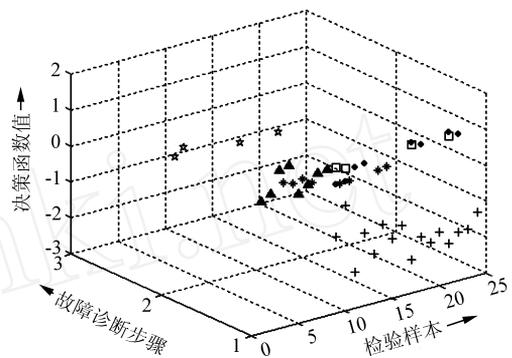


图 1 故障 LP 与故障 HP 的诊断过程
Fig 1 Diagnosis of fault LP and fault HP

对复合型故障,用文献[10]表 7-5 中的样本 1-32 训练,样本 33-48 检验,仍然取 Gauss 型核函数, $c = 1, \sigma^2 = 0.055$ 。检验结果为:16 个检验样本的故障类别全部诊断正确。

已有文献表明^[10],对于上述复合故障,神经网络分类器的泛化效果不理想,例如,应用自组织竞争神经网络和自组织特征映射神经网络(SOFM),就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。

2 正则化参数与核函数的确定

2.1 对正则化参数的分析

式(1)中目标函数的前一项与分类间隔有关,它影响着泛化性能;后一项表示对样本错分后的惩罚,它关系着训练精度。通过控制正则化参数 c ,可以平衡泛化性能和训练精度。显然,参数 c 对 SVM 的最终分类结果有很大影响,但如何确定 c 的值,目前理论上还没有解决,绝大多数文献用简单试凑的办法确定一个 c 值,这个值一般都

不是最合适的。

从 c 的意义可以看出,较大的 c 有利于提高训练精度,但可能会相应降低泛化能力,图2和图3的结果证实了这一点。图2是不同 c 下的训练误差,图中的训练误差由误诊次数表示,核函数为 Gauss 型,实线和虚线分别对应不同的 σ^2 值;图3是不同 c 下的分类间隔。单个 SVM 的分类间隔由下式给出

$$= (\mathbf{w} \cdot \mathbf{w})^{-1/2} = \left(\sum_{i,j \in V_s} d_i d_j \kappa(x_i, x_j) \right)^{-1/2} \quad (4)$$

这个公式可以根据式(2)对应的 KKT 条件推导出, V_s 是支持向量集。对于多类问题,间隔是按照式(4)计算出的所有 γ 中的最小值。两图中的结果均由单一型故障的训练样本数据计算得到,采用其它形式的核函数和复合型故障的训练样本数据进行计算,也有类似的结论。

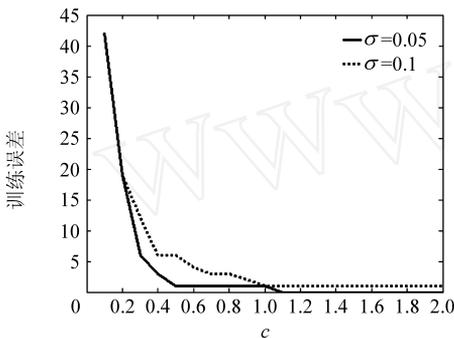


图2 不同正则化参数下的训练误差

Fig. 2 Training error is variant with variant parameter c

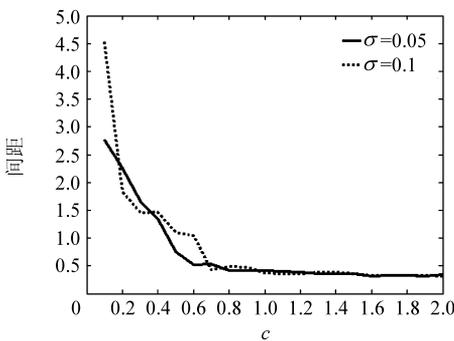


图3 不同正则化参数下的分类间隔

Fig. 3 Margin is variant with variant parameter c

为了进一步考察参数 c 对 SVM 故障分类器泛化性能的影响,对单一型故障样本 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 $c = 1.6$ 的情况下,当噪声系数增加到 14% 时,故障分类器仍然

可以保证 24 个检验样本全部分类正确;增加 c 到 $c = 10$,要保证检验样本全部分类正确,分类器只能容忍 12.3% 的噪声。这也证明,增大 c ,泛化性能会降低。

以上分析表明,参数 c 可以由训练样本数据的特性来决定。给定核参数,根据训练样本数据容易找到满足训练精度且具有最大分类间隔的 c 值,一般地,取这个 c 值可以较好地均衡分类准确性和泛化性。比较不同核参数下得到的 c 值,能够选择出 1 组合适的 c 值和核参数。对于本文讨论的发动机单一型故障,如果要求训练误差为零,可选择 $\sigma^2 = 0.05, c = 1.6$ 。

2.2 核函数的选择与核函数参数的确定

核函数的形式及其参数也是影响最终分类结果的重要因素,选择不同的核函数,可构造不同的 SVM,常用的基本核函数有多项式核函数、Gauss 型核函数、Sigmoid 型核函数等,基本核函数经过相加、相乘、与常量相乘等常规运算后可以形成新的核函数。由于 Sigmoid 型函数只有一些特定的参数能够满足 Mercer 条件,因此,其应用受到一定限制,前两种核函数应用相对更广,本文将讨论这两种基本核函数对发动机故障诊断的影响以及它们的参数确定问题。

表 1 和表 2 分别给出了 Gauss 型核函数和多项式核函数对发动机复合型故障的诊断结果,其中,多项式核函数的形式为

$$k(x, x_i) = (x \cdot x_i + 1)^q$$

表 1 采用 Gauss 核函数的故障诊断结果

Table 1 Diagnosis results of Gaussian kernel SVM		
$\sigma^2 (c=1)$	误诊样本数量	误诊样本序号
0.055	0	—
0.15	2	40, 44
0.5	4	38, 39, 40, 44

表 2 采用多项式核函数故障诊断结果

Table 2 Diagnosis results of polynomial kernel SVM		
$q (c=2)$	误诊样本数量	误诊样本序号
1	3	38, 40, 44
2	3	38, 40, 44
3	2	38, 44
6	2	38, 44

可以看出,对于 Gauss 型核函数,减小核度 σ^2 能够提高故障诊断的准确性,这是因为较小的 σ^2 允许分类边界的分割,分类边界可以有很多条,细致的分类边界减少了误诊样本的数量;而较大的 σ^2 使分类边界简单化,增加了误诊样本的数

量。但是,计算结果也表明, γ 太小可能导致分类边界的过分复杂,从而使泛化性能降低。

对于多项式核函数,增大 q 一般也能够提高故障诊断的准确性。但当各类故障样本之间的差别不显著时, q 增大到一定数值后即对故障诊断的准确性不再有太大影响。在本文的诊断实例中,样本 38 为 HT 类故障,样本 44 为 HP + HT 类故障,它们分别被误诊为 LP 和 HT + LT 类故障,事实上,这几类故障的输入之间相差并不明显,应该再进行故障特征提取,用提取后的信息作为故障诊断的输入量。

以上结果说明,对于发动机气路部件的故障诊断问题,如果要求检验样本不出现误诊,选择 Gauss 型核函数更为合适。

核函数的参数可以采用优化方法来确定。

由式(2)知道,取 Gauss 型核函数时,对偶问题的目标函数 Q 也是核宽度 γ 的函数,因此,参数 γ 可用梯度法进行优化

$$\gamma(l+1) = \gamma(l) + \partial Q / \partial \gamma(l)$$

其中: η 为学习率; $\partial Q / \partial \gamma(l)$ 为第 l 次学习时 Q 对 γ 的偏导数,

$$\frac{\partial Q}{\partial \gamma(l)} = - \frac{1}{4} \sum_{i,j=1}^n d_i d_j K(x_i, x_j) \cdot (|x_i - x_j| / \gamma(l))^2$$

选择多项式核函数时,参数 q 可类似地用梯度法进行优化

$$q(l+1) = q(l) + \partial Q / \partial q(l)$$

$$\frac{\partial Q}{\partial q(l)} = - \frac{q}{2} \sum_{i,j=1}^n d_i d_j [(x_i \cdot x_j) + 1]^{q-1}$$

具体实现时,二类问题可以直接应用以上方法,多类问题每次选取所有 SVM 分类器中目标函数最小的 Q 进行优化迭代。

对于发动机复合型故障,选用 Gauss 型核函数,最终确定的参数为 $c=1$, $\gamma=0.055$ 。

另外,核参数也可用式(4)给出的分类间隔作为目标函数进行优化,方法类似,这里不再详述。

3 SVM 实现算法的改进

SVM 方法要计算和存储核函数矩阵,当训练样本数目较大时,需要很大的存储空间,例如,当样本数目为 4000 时,存储核函数矩阵就需要多达 128MB 的空间;其次,SVM 在二次型寻优过程中要进行大量的矩阵运算,多数情况下,寻优算法占用了 SVM 计算的大部分时间^[1,9]。基于上述原因,有必要研究 SVM 的改进算法。工程中,航空

发动机系统的故障诊断样本数一般可能较大,旨在减少存储空间和计算工作量、提高训练速度的 SVM 改进算法对发动机的故障诊断具有实际意义。

本文采用的改进算法称为“块算法”,它是基于这样的事实:去掉非支持向量的训练样本不会影响原问题的解^[1,9]。具体做法是:(1)选择一部分样本构成工作样本集进行训练,剔除其中的非支持向量;(2)新加进一部分样本,并用训练结果对新样本进行检验,将不符合训练结果的样本与本次训练的支持向量合并成为一个新的工作样本集,重新训练;(3)如此重复,直到获得最优结果。图 4 是“块算法”的操作过程示意图,每一步中的水平细直线代表训练样本集,而粗的实心框代表该步的工作样本集。

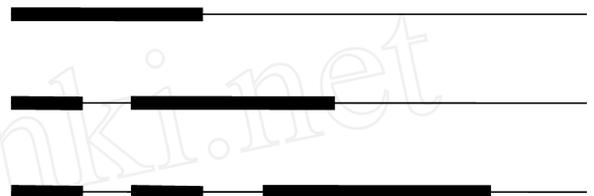


图 4 “块算法”操作过程

Fig. 4 Process of Chunking algorithm

为了说明“块算法”的效果,以文献[10]表7-3中发动机单一故障的诊断为例。表中共有 48 个训练样本,首先用一个 SVM 把这些样本分为两类,训练时,按照“块算法”,每次加进 16 个新样本,结果,最大的工作样本集中有 19 个样本。也就是说,采用“块算法”,只用了 48 个样本中的 19 个来进行 SVM 的训练和新样本的预测,计算工作量和存储空间的减少明显。继续采用“块算法”对故障类别进行细分,得到了较好的总体效果。

4 结 论

(1) SVM 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,对航空发动机气路部件的单一故障与复合故障具有良好的诊断能力。

(2) 控制训练精度和泛化能力的正则化参数 c 可以由训练样本数据的特性来决定,综合考虑误诊次数和分类间隔的影响,能够确定合适的 c 值。

(3) 对于发动机气路部件的故障诊断问题,选择 Gauss 型核函数更为合适;核函数的宽度 γ 可以通过对分类间隔或对偶问题的目标函数进行优化来确定。

参 考 文 献

- [1] Cristianini N, Shawe-Taylor J. An introduction to support vector machines and other kernel-based learning methods [M]. Beijing: Publishing House of Electronic Industry, 2004.
- [2] Chiang L H, Kotanchek M E, Kordon A K. Fault diagnosis based on Fisher discriminant analysis and support vector machines [J]. Computers & Chemical Engineering, 2004, 28(8): 1389 - 1401.
- [3] Samanta B, Al-Balushi K R, Al-Araini 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.
- [4] 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.
- [5] 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 T, Sun J G, Yang W H, *et al.* Self-organizing neural network based fault diagnosis for aero-engine gas path [J]. Acta Aeronautica et Astronautica Sinica, 2003, 24(1):46 - 48. (in Chinese)
- [6] 徐启华,师军. 基于支持向量机的航空发动机故障诊断[J]. 航空动力学报,2005,20(2):298 - 302.
Xu Q H, Shi J. Aero-engine fault diagnosis based on support vector machine [J]. Journal of Aerospace Power, 2005, 20(2): 298 - 302. (in Chinese)
- [7] 许建华,张学工,李衍达. 支持向量机的新发展[J]. 控制与决策,2004,19(5):481 - 484,495.
Xu J H, Zhang X G, Li Y D. Advances in support vector machines[J]. Control and Decision, 2004, 19(5): 481 - 484,495. (in Chinese)
- [8] 王晓丹,王积勤. 支持向量机的研究与应用[J]. 空军工程大学学报(自然科学版),2004,5(3):49 - 55.
Wang X D, Wang J Q. Research and application of support vector machine [J]. Journal of Air Force Engineering University (Natural Science Edition), 2004, 5(3): 49 - 55. (in Chinese)
- [9] Haykin S. Neural networks: a comprehensive foundation [M]. Second edition. Beijing: China Machine Press, 2004.
- [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 W H. Aeroengine modeling and failure diagnosis [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2000. (in Chinese)

作者简介:

徐启华(1962 -) 男,陕西山阳人,淮海工学院电子工程系副教授,博士,1991年毕业于西北工业大学飞行器导航与控制系统专业。主要从事非线性系统故障诊断与容错控制、智能控制等方面的研究,E-mail: qihua_xu@hhit.edu.cn。

师军(1960 -) 男,陕西西安人,西北工业大学自动化学院高级工程师,在职硕士研究生。主要从事故障诊断与容错控制方面的研究,E-mail: shijun@nwpu.edu.cn。

(责任编辑:刘振国)