

文章编号: 1000-8055(2004)06-0844-05

支持向量机在航空发动机故障诊断中的应用

尉询楷, 陆 波, 汪 诚, 路建明, 李应红
(空军工程大学 工程学院, 陕西 西安 710038)

摘要: 提出了一种基于支持向量机的航空发动机故障诊断方法。该方法在利用恰当的工具或方法提取到发动机故障的特征信息之后, 采用支持向量机对特征信息与故障模式进行关联, 实现故障模式的分类。该方法专门针对小样本集合设计, 能够在小样本情况下获得较大的推广能力, 将其应用于某型发动机的故障诊断中, 取得了较好的效果。该方法尤其对于新型发动机的故障诊断具有一定的参考价值。

关键词: 航空、航天推进系统; 航空发动机; 故障诊断; 特征提取; 支持向量机
中图分类号: V 235.13; TP18 **文献标识码:** A

Applications of Support Vector Machines to Aeroengine Fault Diagnosis

WEI Xun-kai, LU Cheng, WANG Cheng, LU Jian-ming, LI Ying-hong
(The Engineering Institute, Air Force Engineering University,
Xi'an 710038, China)

Abstract: An aeroengine fault diagnosis method based on support vector machines is presented. After extracting fault symptoms via proper equipments or methods, support vector machines were adopted to set up correlation between fault symptoms and fault patterns and to realize the classification of faults. Support vector machines are specially designed for good generalization ability under the condition that only small samples set is available. Applying this method to a certain engine, the diagnostic results are satisfactory, and it is referable to develop diagnostic system for newly-developed engines.

Key words: aerospace propulsion system; aeroengine; fault diagnosis; symptom extraction; support vector machines

随着航空发动机性能的不断改进和提升, 发动机的各部件的工况也变得越来越恶劣, 及时的检测和诊断出系统的故障则可以有效地避免事故的发生以及由此造成的巨大经济损失^[1~3]。对于发动机的故障诊断而言, 常见的诊断方法有基于气路模型的诊断方法以及基于知识的智能诊断方法等。基于气路模型的诊断方法对系统的数学模

型依赖较大, 对于建模误差、参数摄动、噪声和干扰等都十分敏感, 这使得诊断结果的可靠性不能得到严格的保证; 基于知识积累的智能诊断方法, 具有逼近任意复杂非线性系统的能力和分类能力, 但是该方法需要有足够的发动机典型故障数据样本和先验知识, 而实际的发动机系统尤其是新研制的发动机往往不具备条件, 因而使得这些

收稿日期: 2003-12-10; 修订日期: 2004-03-20

作者简介: 尉询楷(1981-), 男, 山东莱阳人, 空军工程大学工程学院博士生, 主要从事航空发动机的智能控制与智能诊断研究

理论上优秀的方法面临从有限样本获得大推广能力的难题, 从而限制了其广泛的实用化。

支持向量机是一种专门针对小样本条件下的机器学习问题而建立的新型学习机制, 这种方法在最小化经验风险的同时, 最小化置信区间的上界, 有效的解决了小样本、高维数和非线性, 消除了因样本数目不足带来的过学习问题, 克服了人工神经网络学习方法中合理结构难以确定和存在局部极小点等缺陷, 使其具有优秀的推广泛化能力和强的抗干扰能力。

本文在采用模糊方法对故障信息进行特征提取的基础之上, 采用支持向量机实现故障的分类达到智能诊断的目的。为了验证其有效性将其应用于某型发动机的自动停车故障诊断中, 在训练样本中加入 Gaussian 噪声以测试其鲁棒性和抗干扰能力; 为验证其推广特性, 对三组现场获得的故障模式进行了分析和验证。最后, 给出了结论。

1 支持向量机

支持向量机是由 Vapnik 在上世纪90年代中期提出的一种机器学习算法^[4, 5]。支持向量机以其良好的理论背景, 结构风险最小化原则为机器学习提供了崭新的方向。支持向量机最初用于解决模式识别问题, 为了发现具有推广能力的决策规则, 所选择的训练数据的一些子集称为支持向量。最佳的支持向量分离等效于所有数据的分离。支持向量机是从线性可分情况下的最优分类面发展而来的, 其基本思想可参阅文献^[4]。支持向量机通过固定经验风险, 再最小化置信风险, 将输入空

题, 快速算法保证了收敛速度。用于分类的典型支持向量机结构如图1所示。

1.1 支持向量机的分类算法^[6~8]

对于给定的样本集 $\{(x_i, y_i)\}_{i=1}^N, x_i \in R^m, y_i \in \{\pm 1\}$, 支持向量机首先通过非线性映射 $\Phi: R^m \rightarrow R^n$, 将输入向量映射到高维空间, 当数据在高维空间可分时, 支持向量机便在高维空间 R^n 构造最大间隔分类超平面: $(w \cdot \Phi(x)) + b$, 可以证明 w 可以写成 Φ 的线性组合: $w = \sum_{i=1}^N \alpha y_i \Phi(x_i)$, 其中 α 是 Lagrange 乘数, 并可由求解下面的二次规划问题得到:

$$\begin{aligned} \text{Max } W(\alpha) = & \sum_{i=1}^N \alpha - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha \alpha y_i y_j [\Phi(x_i) \cdot \Phi(x_j)] \\ \text{s.t. } & \sum_{i=1}^N \alpha y_i = 0 \quad \alpha \geq 0 \end{aligned} \tag{1}$$

由 Reproduce Kernel Hilbert Space (RKHS) 理论知: 在高维空间的内积 $[\Phi(x_i) \cdot \Phi(x_j)]$ 总可以在输入空间找到一个满足 Mercer 条件的核函数使得 $K(x_i, x_j) = [\Phi(x_i) \cdot \Phi(x_j)]$, 因此并不需要知道非线性映射的具体形式。(1) 式可以改写为如下的形式:

$$\begin{aligned} \text{Max } W(\alpha) = & \sum_{i=1}^N \alpha - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha \alpha y_i y_j K(x_i, x_j) \\ \text{s.t. } & \sum_{i=1}^N \alpha y_i = 0 \quad \alpha \geq 0 \end{aligned} \tag{2}$$

常见的核函数有:

多项式核 $K(x, y) = [1 + (x \cdot y)]^p, p = 1, \dots, n$; 高斯径向基函数核 $K(x, y) = \exp(-\|x - y\|^2 / 2\sigma^2)$ 以及两层前馈神经网络核 $K(x, y) = \tanh[k(x \cdot y) - \theta]$ 。

对于分类边界上的点, 对应的 $\alpha > 0$, 这样的点叫做支持向量点。支持向量点的数目一般要小于样本的个数, 且支持向量点与分类器的推广能力紧密相关。利用 Karush-Kuhn-Tucker (KKT) 条件可以得到域值 b 。因此, 得到的分类决策函数为:

$$y = \text{sign} \left[\sum_{i=1}^N \alpha y_i K(x_i, x) + b \right] \tag{3}$$

当数据在高维空间不能没有误差的分离时, 支持向量机引入松弛变量 $\xi \geq 0$, 并通过求解下述二次规划使得错分误差最小:

$$\text{Min } L_P = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \tag{4}$$




图1 典型的支持向量机结构

Fig 1 Typical structure of Support Vector Machines

间映射到高维内积空间中, 有效避免了“维数灾难”。支持向量机通过解一个线性约束的二次规划问题得到全局最优解, 因而不存在局部极小值问

其中松弛变量 $\xi \geq 0$ 反映了实际指示值 y_i 与支持向量机输出之间的距离。 C 是平衡因子, 反应的是第一项与第二项之间的权衡。(4) 式的求解可转化为:

$$\begin{aligned} \text{Max } W(\alpha) = & \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \\ \text{s.t. } & \begin{cases} \sum_{i=1}^N \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq C \end{cases} \end{aligned} \quad (5)$$

求解(5)式, 同样利用 KKT 条件获取域值得到决策函数式(3)。

1.2 多类支持向量机分类算法

多类支持向量机的基本思想是将多类问题转化为两类问题的组合, 本文采用的是 One-Against-One 方法, 即对 N 元分类问题^[9,10] 建立 $N(N-1)/2$ 个 Support Vector Machines (SVM), 每两类之间训练一个 SVM 将两类分开, 算法如下:

设训练数据样本属于第 k 类和第 l 类, 二元分类器可转化为多元分类器:

$$\text{Min}_{w^{kl}, b^{kl}, \xi^{kl}} \frac{1}{2} (w^{kl})^T w^{kl} + C \left[\sum_i (\xi_i^{kl}) \right] \quad (6)$$

$$[(w^{kl})^T \mathcal{Q}(x_i)] + b^{kl} \geq 1 - \xi_i^{kl},$$

如果 x_i 属于第 k 类;

$$[(w^{kl})^T \mathcal{Q}(x_i)] + b^{kl} \leq -1 + \xi_i^{kl},$$

如果 x_i 属于第 l 类;

$$\xi_i^{kl} \geq 0.$$

采用多元分类器训练数据样本后, 在测试新样本时, 输入新样本到每个训练好的 SVM 分类器中进行分类识别, 每次获得一个类别。然后对 $N(N-1)/2$ 次分类的结果进行统计, 以最多的类别数所属类别为新样本的类别。采用这种方法构造的多元分类器, 单个 SVM 训练规模较少、编程易实现、结果准确、训练数据均衡。

2 航空发动机故障特征信息的提取与关联

由于航空发动机是一个极其复杂的非线性时变系统, 很多故障原因与征兆之间的关系无法显化, 因此无法准确的找出确定的分析函数关系来诊断发动机系统的故障。气路诊断方法可以根据各个部件间的气动热力关系进行分析, 但是在实

际中, 由于飞机监测参数的个数远远地小于发动机气路部件和指示系统故障的数目, 因此气路方法的使用也受到一定的限制。支持向量机等智能方法则避开了解析方法的建模缺陷^[11], 特别是当发动机的有些故障模式和故障征兆之间为定性关系而无法量化时, 则可以采用模糊方法估计二者的定量关系获得有益的特征信息, 然后利用支持向量机直接对特征信息与故障模式之间进行关联, 并利用支持向量机的强大推广能力实现对未知故障模式的诊断。本文采用模糊方法建立故障征兆与模式之间的隶属度矩阵, 即提取到的特征信息, 然后利用支持向量机进行智能诊断, 所提出的基于支持向量机的航空发动机诊断结构如图2所示(其中 $X_1, \dots, X_n$ 表示故障的原始信息, $F_1, \dots, F_m$ 表示经过特征提取获得的信息), 特征提取器采用模糊手段, 这里也利用文献[12]提供的一个例子作为支持向量机的训练样本。




图2 基于支持向量机的故障诊断系统结构

Fig 2 Fault diagnosis structure based on SVM

某发动机常见的自动停车故障征兆有6个, 即排气温度超温(F_1)、振动大(F_2)、转速急降(F_3)、滑油警告灯亮(F_4)、滑油消耗量大(F_5)和转速上不去(F_6), 故障成因有5个, 即离心活门抱轴(S_1)、涡轮叶片折断(S_2)、滑油导管振裂(S_3)、油泵随动活塞卡死(S_4)和传动轴折断(S_5)。经过模糊处理和有经验的专家确定之后, 故障征兆与故障成因之间的隶属度关系^[13]如表1所示。获得了特征信息之后, 就可以对支持向量机进行训练。为了验证其鲁棒性和抗干扰性, 加入不同 Gaussian 噪声, 得到的分类结果如表2所示(表中1, 2, 3, 4, 5为对应故障模式的指示值), 为了直观的说明分类的效果, 采用前2维数据绘制了其分类边界线的效果图, 如图3所示。随着噪声程度的加大, 分类点逐渐接近边界线, 而当噪声达到0.15时, 开始出现错分现象, 这是由于噪声比较剧烈已开始将原始信号吞没。从表2、图3可以看出: 在噪声情况下, 支持




图3 不同噪声水平下的分类结果

Fig 3 Classification results under different level Gaussian noise

表1 停车训练样本

Table 1 Training samples

训练样本	F1	F2	F3	F4	F5	F6
S1	0.60	0.80	0.95	0.00	0.00	0.30
S2	0.40	0.98	0.00	0.00	0.00	0.60
S3	0.00	0.30	0.80	0.98	0.90	0.90
S4	0.98	0.00	0.30	0.00	0.00	0.98
S5	0.00	0.00	0.98	0.00	0.00	0.95

表2 噪声下的分类结果

Table 2 Training errors under Gaussian noise

高斯噪声水平	S1	S2	S3	S4	S5	分类正确率/(%)
0.01	1	2	3	4	5	100
0.05	1	2	3	4	5	100
0.10	1	2	3	4	5	100
0.15	2	2	3	4	5	80

表3 测试故障模式与分类结果
Table 3 Test fault patterns and results

测试故障模式	F1	F2	F3	F4	F5	F6	分类结果
T1	0.58	0.80	0.94	0.10	0.00	0.30	S1
T2	0.00	0.38	0.80	0.90	0.90	0.90	S3
T3	0.10	0.00	0.97	0.00	0.10	0.95	S5

向量机依然有较高的分类精度,足以说明支持向量机诊断方法具有极好的鲁棒性和抗干扰特性,如果与合适的特征提取手段相结合则可作为优选的分类器使用。

3 应用实例

某型发动机在几次试车试验中,采集到3次不同状态的自动停车参数。经过滤波和处理提取出6个征兆参数,把这些参数经过选定的隶属度函数模糊处理后得到模糊特征向量,将其带入支持向量机分类器中进行测试,得到的特征信息与分类结果如表3所示。

这3个故障经过现场专家的人工诊断,分别确诊为: T1离心活门抱轴(S1)、T2滑油导管振裂(S3)和 T3传动轴折断(S5)。从中可以看出,支持向量机诊断的正确率为100%,也说明了支持向量机对于小样本集合确实有很强的推广泛化能力,进一步验证了该方法的高效性和实用性。

4 结 论

本文提出了一种基于支持向量机方法的航空发动机故障诊断方法,通过应用实例得出如下结论:

- (1) 该方法具有很强的鲁棒性和抗干扰特性,对于小样本集合,由于采用了结构风险最小化的新型学习机制,有效地避免了过学习问题而能够获得较大的推广能力,与恰当的特征提取器结合可以作为理想的分类器使用。
- (2) 该方法可以扩展至发动机的振动故障诊断,采用适当的特征提取器(如 FFT 或者小波变换),获得多传感器振动信号的特征信息,就可以采用支持向量机实现特征级的信息融合诊断。
- (3) 支持向量机克服了解析法对模型依赖过大的缺陷,消除了神经网络等方法存在的推广能力不足和结构难以优化确定、存在过学习和局部极值等问题,是一种不需要过多先验知识和专家知识的智能学习方法。

参考文献

[1] 胡寿松,王源. 基于支持向量机的非线性系统故障诊断[J]. 控制与决策, 2001, 16(5): 618- 620

[2] 张周锁,李凌均,何正嘉. 基于支持向量机的机械故障诊断方法[J]. 西安交通大学学报, 2002, 36(3): 1303- 1306

[3] 周东华,叶银忠. 现代故障诊断与容错控制[M]. 北京: 清华大学出版社, 2002

[4] Vapnic V. The Nature of Statistical Learning [M]. New York: Springer, 1998

[5] 边肇基,张学工. 模式识别[M]. 北京: 清华大学出版社, 2000

[6] Amari S, Wu S. Improving Support Vector Machine Classifiers by Modifying Kernel Functions[J]. Neural Networks, 1999, 12: 783- 789

[7] Burges C J C. A Tutorial on Support Vector Machines for Pattern Recognition[J]. Data Mining and Knowledge Discovery, 1998, 2(2): 8- 34

[8] Scholkopf B, Sung K K, Burges C, et al. Comparing Support Vector Machines with Gaussian Kernels to Radial Basis Function Classifiers[J]. IEEE Transactions on Signal Processing, 1997, 45: 2758- 2765

[9] Weston J, Watkins C. Support Vector Machines for Multi-Class Pattern Recognition[A]. In Proceedings of 7th European Symposium on Artificial Neural Networks (ESANN '99) [C]. 1999: 219- 224

[10] Sanna Poyhonen. Fault Diagnostics of an Electrical Machine with Multiple Support Vector Classifiers[A]. In Proceedings of 2002 IEEE International Symposium on Intelligent Control [C]. Vancouver, Canada, 2002: 373- 378

[11] Yan Weiwu, Shao Huihe. Applications of Support Vector Machine Nonlinear Classifier to Fault Diagnoses[A]. In proceedings of 4th World congress on intelligent control and automation [C]. ShangH ai, PR China, 2002: 2697- 2700

[12] 范作民,孙春林. 航空发动机状态诊断[M]. 天津: 天津科技翻译出版公司, 1996

[13] 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

J IANG Dong-xiang, WANG Feng-yu, et al. Application of Fuzzy Self-Organizing Neural Network to Aeroengine Fault Diagnosis. Journal of Aerospace Power, 2001, 16(1): 80- 82