

doi: 10.3969/j.issn.1006-1576.2012.04.015

一种基于 SVM 的航舵故障诊断方法

周晶, 宋辉, 李铁, 李明海

(海军大连舰艇学院训练部模拟训练中心, 辽宁 大连 116018)

摘要: 针对舵机故障样本数量不足、诊断知识不完备的实际情况, 提出一种基于支持向量机 (support vector machine, SVM) 的故障诊断方法。根据航舵故障输入输出映射非线性的特点, 分析 SVM 的分类机理, 对基于 SVM 的故障诊断步骤进行介绍, 解决了小样本模式的分类问题, 并通过仿真对该方法的有效性进行验证。仿真结果表明: 该方法对舵机故障分类准确性可达 92%。

关键词: 计算智能; 支持向量机; 故障诊断

中图分类号: TJ03 **文献标志码:** A

A Method of Nautical Steer Fault Diagnose Based on SVM

Zhou Jing, Song Hui, Li Tie, Li Minghai

(Simulation Training Center, Dept. of Training, Dalian Warship Academy of PLA Navy, Dalian 116018, China)

Abstract: Aiming at lack of fault samples and diagnosis knowledge in nautical steer, introduce a method based on support vector machine (SVM). According to nautical steer nonlinear input-output mapping feature, analyze SVM classification mechanism, introduce the fault diagnosis steps based on SVM, and solve the classification problems of small sample mode. Then, use simulation to verify the validity. The simulation result shows that the method fault classification correctness can reach 92%.

Key words: computational intelligence; support vector machine; fault diagnosis

0 引言

航舵作为船舶控制系统中的重要部位之一, 发挥着至关重要的作用。随着航舵系统性能的大幅提高, 系统结构越来越复杂, 设备故障种类、发生率也呈现上升趋势。航舵一旦出现故障, 轻则航期延误, 经济受损, 重则严重威胁人员安全。由于舵机体积庞大, 在海上突发故障后维修不便, 因此通过日常的监控, 提早诊断设备的故障显得至关重要。但航舵故障的复杂性使得故障确诊比较困难; 另外故障现象与故障本身并非一对一的映射关系, 实质上是典型的复杂非线性分类问题。

近年来, 国内外学者使用基于信号处理和基于知识的方法进行故障诊断, 并取得了显著的成效。其中基于知识的方法的研究及应用较多采用故障树 (fault tree, FT) 分析方法、人工神经网络 (artificial neural network, ANN) 方法、专家系统 (expert system, ES) 方法、模糊数学方法等^[1]。尽管这些理论和方法在很多领域解决非线性分类问题上有独到之处, 但这些对数据样本要求较高, 需大量典型故障数据样本, 且样本数据分布要尽量覆盖各种故障模式^[2]。设备故障往往具有突发性, 通常不可重复, 在实际故障诊断中, 样本的数量与质量难以保证。

支持向量机 (support vector machine, SVM) 是一种新型机器学习方法, 对解决小样本模式分类问题具有独特的优势。因此, 笔者提出一种基于 SVM 的智能诊断方法来解决该问题。

1 支持向量机的分类机理

支持向量机产生于 20 世纪 70 年代, 对有限样本下的统计学习问题提供了一个有效的解决途径^[3]。SVM 基于结构风险最小化理论, 兼顾了经验风险和推广能力, 对解决小样本的模式分类问题具有独特的优势, 适合舵机系统诊断。SVM 由线性可分情况下的最优分类面推广而来。最优分类面有 2 项要求: 分类面能正确分类且分类间隔最大。前者是使经验风险最小, 而后者保证界中的置信范围最小, 从而真实风险最小^[4]。SVM 工作流程如图 1。

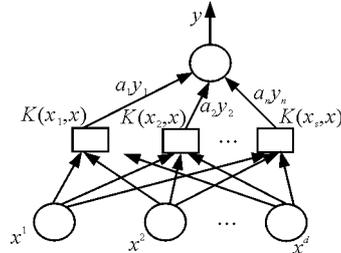


图 1 支持向量机分类流程图

收稿日期: 2011-10-27; 修回日期: 2011-12-07

作者简介: 周晶 (1970—), 男, 湖北人, 硕士, 讲师, 从事故障诊断、模式识别与智能系统研究。

样本集为 (x_i, y_i) , $i=1, 2, \dots, n, x \in R^d$, $y_i \in \{+1, -1\}$ 是类别标号。 d 维空间中线性判别函数为: $g(x) = w \cdot x + b$ 。

对判别函数进行归一化, 使两类中离分类面最近的样本的 $|g(x)|=1$ 。最优分类面问题可以表述为求函数的最小值。Lagrange 函数定义如下:

$$L(w, b, a) = \frac{1}{2}(w \cdot w) - \sum_{i=1}^n a_i \{y_i [(w \cdot x_i) + b] - 1\} \quad (1)$$

其中 a_i 为 Lagrange 乘子, 求取对 w 和 b 的 Lagrange 函数最小值。

对于非线性问题, 只需要将输入向量非线性映射到一个更高维的特征空间, 然后再构造最优分类超平面。约束条件式中的 a_i 应满足:

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

其中 C 为惩罚参数, 用来控制分类误差与推广性能的折中。

对于任意的对称函数 $K(x, x')$, 它是某个特征空间中的内积运算的充分必要条件是, 对于任意的 $\varphi(x) \neq 0$ 且 $\int \varphi(x) dx < \infty$ 有:

$$\iint K(x, x_i) \varphi(x) \varphi(x') dx dx' > 0 \quad (3)$$

其中 x' 表示特征向量 x 的转置。

当核函数 $K(x, x')$ 满足 Mercer 条件, 就可以代替最优分类面中的点积^[5], 优化函数为:

$$Q(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j K(x_i, x_j) \quad (4)$$

决策规则函数为:

$$y = \text{sgn} \left(\sum_{i=1}^n a_i y_i K(x_i, x) + b \right) \quad (5)$$

2 基于 SVM 故障诊断的步骤

2.1 故障特征提取

故障特征提取是故障诊断中的重点和难点之一, 直接关系到诊断结果的准确性。舵机在故障发生时, 其振动会表现出异常特征。特征信号的采集与处理是实现故障诊断的重要环节, 通常包含对设备信号进行加工、变换、提取敏感的故障特征等内容^[6]。目前广泛采用壳体振动信号的功率谱分析或倒频谱分析来对舵机系统进行状态监测和故障诊断^[7], 通过对壳体振动与噪声进行测量分析, 提取

与特定故障相关的敏感特征量。

2.2 训练阶段

训练阶段主要目的: 在已知舵机正常和故障 2 种状态下, 分别输入的多组特征样本对支持向量机进行学习, 找到训练样本的支持向量, 产生一个分类函数来区分正常或异常种类样本, 构造最优分类超平面, 其步骤如下:

1) 根据已知的舵机正常状态和故障状态下的特征数据样本, 归一化处理后建立训练样本集 $\{x_i, y_i\}$, 将训练样本集输入系统;

2) 根据特点选择合适的核函数 $K(x_i, x_j)$ 及核参数, 并对样本进行规范化;

3) 在约束条件下, 求取 Lagrange 函数极小值系数 a_i ;

4) 根据训练样本特征找出支持向量 (support vector, SV), 计算阈值 b ;

5) 结束训练, 建立训练数据样本的最优分类超平面。

2.3 故障诊断阶段

故障诊断阶段就是载入训练后产生的最优分类超平面对测试样本集做出分类决策, 步骤如下:

1) 载入学习阶段训练完成的相关数据, 包含: 支持向量 SV、系数 a_i 、阈值 b 和测试样本集 $\{x_i, y_i\}$;

2) 利用决策函数计算待测数据样本的指示函数决策输出值, 做出分类决策。

3 计算机仿真与分析

笔者在 Matlab7.1 下建立仿真环境, 以某型自动舵的 5 种常见故障为例进行仿真实验。故障类型定义如下: F_1 为密封件摩擦引起的振动; F_2 为轴承油膜涡动和油膜振荡所引起的振动; F_3 为转子不平衡所引起的振动; F_4 为活塞磨损引起的振动; F_5 为电气方面原因引起的振动。

首先提取正常工作状态下与 5 种典型舵机故障状态下的振动特征信息。笔者采用特征能量法提取振动特征信息, 用小波包分解子带特征能量, 将各频段能量归一化处理后得到用于训练的样本集和诊断测试样本集^[8-10]。训练样本空间包含正常、故障样本共 50 组, 诊断测试样本包含 5 种故障样本共 25 组, 部分训练样本详见表 1。

表 1 部分训练样本

样本	故障类型	特征 1	特征 2	特征 3	特征 4	特征 5	特征 6	特征 7	特征 8
1	F_1	0.090 8	0.145 5	0.186 1	0.379 6	0.042 6	0.068 5	0.085 4	0.001 5
2	F_1	0.091 4	0.121 9	0.164 6	0.402 4	0.052 6	0.083 9	0.081 3	0.001 9
3	F_2	0.093 5	0.334 1	0.172 6	0.198 9	0.049 3	0.061 3	0.050 8	0.039 5
4	F_2	0.093 5	0.349 6	0.169 6	0.189 4	0.050 1	0.064 6	0.051 9	0.031 3
5	F_3	0.145 2	0.126 1	0.132 8	0.209 1	0.173 2	0.074 5	0.057 2	0.081 9
6	F_3	0.133 1	0.136 1	0.142 8	0.198 2	0.164 9	0.080 1	0.051 9	0.092 9
7	F_4	0.102 5	0.145 8	0.185 3	0.368 8	0.046 9	0.067 2	0.035 2	0.048 3
8	F_4	0.102 7	0.116 8	0.208 9	0.393 5	0.052 3	0.046 3	0.031 7	0.047 8
9	F_5	0.080 2	0.123 1	0.154 1	0.442 6	0.055 1	0.046 2	0.012 5	0.086 2
10	F_5	0.075 2	0.141 2	0.163 2	0.439 8	0.060 1	0.044 7	0.010 8	0.065 0

在构造支持向量分类机时，选择多项式核函数阶次 $d=3$ ，同时设定惩罚因子 $C=10$ 。分类结果如图 2、3 所示，图 2 中纵坐标为故障类型编号，图 3 纵坐标为分类识别偏差。经过比对，得出训练和测试过程统计信息，见表 2。

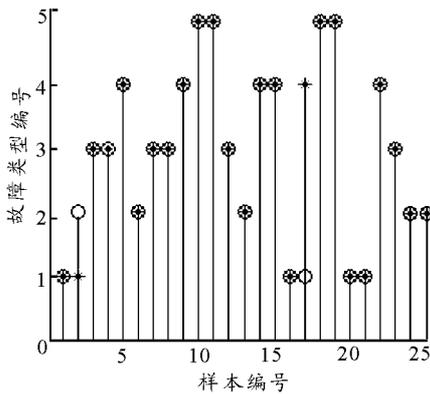


图 2 分类结果输出

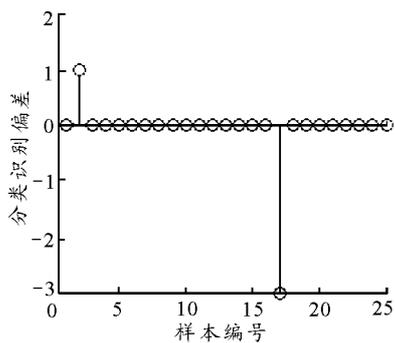


图 3 分类误差

表 2 训练和测试阶段统计信息

训练阶段		测试阶段		准确率/%
训练时间/s	样本个数	分类时间/s	样本个数	
0.219	50	0.116	25	92

4 结束语

仿真结果表明：对已知舵机故障样本进行诊断测试，确诊率可达 92%，验证了该方法在对舵机故障分类中具有较好的有效性和推广性。下一步，将突破技术难题，不断提高航舵的故障诊断率。

参考文献：

- [1] 王丽, 周新立, 尉询楷. 基于支持向量机的故障诊断方法及其应用[J]. 火力与指挥控制, 2006, 31(4): 9-11.
- [2] 姜万录. 基于混沌性质和多分辨分析的故障诊断理论及试验研究[D]. 燕山大学, 2001: 1-11.
- [3] 谭东宁, 谭东汉. 小样本机器学习理论: 统计学习理论[J]. 南京理工大学学报, 2001, 25(1): 108-112.
- [4] 何学文, 赵海鸣. 支持向量机及其在机械故障诊断中的应用[J]. 中南大学学报: 自然科学版, 2005, 36(1): 97-101.
- [5] 吴斌, 尉询楷, 刘国庆, 等. 支持向量机的滚动轴承状态监测[J]. 火力与指挥控制, 2006, 31(4): 85-87.
- [6] 肖成勇, 石博强, 王文莉, 等. 基于小波包和进化支持向量机的齿轮早期诊断研究[J]. 振动与冲击, 2007, 26(7): 26-27.
- [7] 王自营, 邱锦浩, 安钢, 等. 基于一类超球面支持向量机的机械故障诊断研究[J]. 振动工程学报, 2008, 21(6): 553-558.
- [8] 牛慧峰. 免疫机理与支持向量机复合的故障诊断理论及试验研究[D]. 秦皇岛: 燕山大学, 2006: 51-54.
- [9] 干敏梁, 刘红星. 关于振动加速度信号幅值解调的五种方法[J]. 振动与冲击, 2000, 19(1): 32-33.
- [10] 程鹏, 潘宏侠. SOM-BP 复合神经网络在齿轮箱故障诊断中的应用研究[J]. 噪声与振动控制, 2010(5): 165-168.