

文章编号:0253-9993(2007)01-0098-05

基于小波-支持向量机的矿用通风机故障诊断

荆双喜, 华 伟

(河南理工大学 机械与动力工程学院, 河南 焦作 454003)

摘 要: 运用小波包频道能量分解技术提取了不同频带反映矿用通风机不同工作状态的特征向量, 以此作为支持向量机多故障分类器的故障样本, 经训练的分类器作为故障智能分类器可对通风机的工作状态进行自动识别和诊断. 并以不对中故障为例, 进行了实用验证. 研究表明, 支持向量机在小样本情况下仍能准确、有效地对通风机的工作状态和故障类型进行分类.

关键词: 小波包; 支持向量机; 通风机; 故障诊断

中图分类号: TD411.2 文献标识码: A

The mine ventilator fault diagnosis based on wavelet packet and support vector machine

JING Shuang-xi, HUA Wei

(School of Mechanical and Power Engineering, Henan Polytechnic University, Jiaozuo 454003, China)

Abstract: Which reflected different working state of ventilator, was extracted from different frequency segment with the technology of wavelet packet frequency segment power decomposition, and taking it as input fault of support vector machine (SVM) multi-fault classifier. The trained classifier, as fault intelligent classification, had very strong identification capability, which could identify automatically the working state of ventilator. And the shaft-misalignment was conducted. The result shows that SVM can classify working condition of ventilator accurately and effectively even in the case of smaller number of samples.

Key words: wavelet packet; support vector machine; ventilator; fault diagnosis

目前对通风机故障诊断的研究已由传统的振动频谱分析的方法转向智能诊断, 在机械智能故障诊断中应用比较广泛的是人工神经网络, 这一方法要求有大量典型的训练样本数据或先验知识, 但是在大型机械设备中, 大量典型故障数据往往很难获取, 这成为制约人工神经网络等智能诊断方法发展和应用的重要因素. 在统计学习理论上发展的一种新的机器学习方法——支持向量机 (Support vector machine, SVM)^[1]——较好地解决了小样本、非线性和高维模式识别等实际问题, 并克服了神经网络学习方法中网络结构难以确定、收敛速度慢、局部极小点、过学习与欠学习以及训练时需要大量数据样本等不足, 大大提高了学习方法的推广能力, 正成为智能故障诊断新的热点.

本文以矿用通风机为研究对象, 研究基于小波分析和支持向量机的故障自动识别技术, 即通过小波变换, 把通风机振动信号分解在不同的频段内, 各频段内的能量可形成一个特征向量, 且对应通风机不同的故障有不同的特征值, 该向量可作为支持向量机分类器的输入样本, 通过典型故障样本的学习与训练, 得

到可用于对通风机进行故障自动识别的分类器. 研究表明, 基于小波和支持向量机的故障诊断技术适用于通风机机械系统中的多故障、多征兆的复杂故障模式识别问题, 可实现通风机故障的智能诊断.

1 基于小波包的能量故障特征提取

离散信号按小波包基展开时, 包含低通滤波与高通滤波两部分, 每一次分解就将上层 $j + 1$ 的第 n 个频带进一步分割变细为下层 j 的第 $2n$ 与 $2n + 1$ 两个子频带. 离散信号的小波包分解算法^[2]: $d_i(j, 2n) = \sum_k a_{k-2l} d_k(j + 1, n)$, $d_i(j, 2n + 1) = \sum_k b_{k-2l} d_k(j + 1, n)$, 其中 a_k, b_k 为小波分解共轭滤波器系数.

由 Parseval 恒等式知 $\int_{-\infty}^{\infty} |f(x)|^2 dx = \sum |d(j, k)|^2$. 由此可知, 小波包变换系数 $d(j, k)$ 的平方具有能量的量纲, 可用于机械故障诊断的能量特征提取, 假设离散信号按最优小波包分解^[3]后可得到 M 个正交的频带, 各频带的能量 $E_i = \sum_{k=1}^{N_i} |d(i, k)|^2$, 其中 $i \leq M$; N_i 为第 i 个子频段的数据长度, 且 $k \leq N_i$.

离散信号的能量均方根 $E_r = \sqrt{\sum_{i=1}^M E_i^2}$, 则能量特征向量为

$$T = \frac{1}{E_r} [E_1, E_2, \dots, E_M]. \tag{1}$$

2 支持向量机 (SVM) 及多故障分类器的建立

2.1 支持向量机

支持向量机 (SVM) 是从线性可分情况下的最优分类面发展而来的, 基本思想可用图 1 的两维情况说明^[4]. 图中, 圆和三角代表两类样本; H 为分类线, H_1, H_2 分别为过各类中离分类线最近的样本且平行于分类线的直线, 它们之间的距离叫做分类间隔 (margin). 所谓最优分类线就是要求分类线不但能将两类正确分开 (训练错误率为 0), 而且使分类间隔最大. 分类线方程为 $w \cdot x - b = 0$, 对其进行归一化, 使得对线性可分的样本 $(x, y), i = 1, \dots, n, x \in R_d (R_d$ 为 d 维数据空间; n 为样本的人数) $v \in \{+1, -1\}$ 满足

$$y_i [(w \cdot x_i) + b] - 1 \geq 0 \quad (i = 1, \dots, n). \tag{2}$$

此时分类间隔等于 $2 / \|w\|$, 使间隔最大等价于使 $\|w\|^2$ 最小. 满足条件 (2) 且使 $1/2 \|w\|^2$ 最小的分类面就叫做最优分类面, H_1, H_2 上的训练样本点就称作支持向量. 利用 Lagrange 优化方法可以把上述最优分类面问题转化为其对偶问题.

$$Q(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j), \tag{3}$$

且满足约束条件

$$\sum_{i=1}^n y_i \alpha_i = 0, \alpha_i \geq 0 \quad (i = 1, \dots, n) \tag{4}$$

下的 $Q(\alpha)$ 的最大值. α_i 为原问题中与每个约束条件式 (4) 对应的 Lagrange 乘子, 这是一个不等式约束下二次函数寻优的问题, 存在唯一解. 容易证明, 解中将只有一部分 (通常是少部分) α_i 不为 0, 对应的样本就是支持向量. 解上述问题后得到的最优分类函数为

$$f(x) = \text{sgn} \{ (w \cdot x) + b \} = \text{sgn} \left\{ \sum_{i=1}^n \alpha_i^* y_i (x_i \cdot x) + b^* \right\}. \tag{5}$$

式中, $\text{sgn} \{ \}$ 为符号函数, 求和实际上只对支持向量进行; α_i^* 为 α_i 的最优解; b^* 为分类阈值, 可以用




图 1 最优分类面

Fig. 1 Optimal separating hyperplane

任一个支持向量 (满足式 (2) 中的等号) 求得, 或通过两类中任意一对支持向量取中值求得. 根据待分类的样本 x , 由分类函数 $f(x)$ 的正负即可判定 x 所属的类别.

对于解决线性不可分问题时, 可以加入非负的松弛变量 ξ_i , 把式 (2) 的条件放宽为 $y_i[(w \cdot x_i) + b] - 1 + \xi_i \geq 0 (i = 1, \dots, n)$. 当发生分类错误时, 相对应的 $\xi_i > 0$, $\sum \xi_i^k$ 为训练集错分个数的上界. 引入错误惩罚分量, 使 $1/2 \|w\|^2$ 变为 $1/2 \|w\|^2 + C \sum \xi_i^k$, 从而将目标改为

$$(w, \xi) = 1/2 \|w\|^2 + C \sum \xi_i^k, \tag{6}$$

其中, C 为某个指定的常数, 起控制对错分样本惩罚的程度, 越大说明对错误惩罚越重. 求解式 (6) 的最小, 即折衷考虑最少错分样本和最大分类间隔, 就得到广义最优分类面. 广义最优分类面的对偶问题与线性可分情况下几乎完全相同, 只是式 (4) 中 $\alpha_i \geq 0$ 变为 $0 \leq \alpha_i \leq C (i = 1, \dots, n)$.

上面讨论的是线性问题, 对非线性问题, 可以通过非线性变换转化为某个高维空间的线性问题. 这种变换一般比较复杂, 但是可注意到, 在上面的问题中, 不论是目标函数式 (3) 还是分类函数式 (5) 都只涉及训练样本之间的内积运算 ($x_i \cdot x_j$), 这样, 在高维空间实际上只需进行内积运算, 而这种内积运算可以用原空间中的函数实现的, 甚至没有必要知道变换的具体形式. 根据泛函的有关理论, 只要一种核函数 $K(x_i \cdot x_j)$ 满足 Mercer 条件, 它就对应某一变换空间中的内积. 因此, 在最优分类面中采用适当的内积函数 $K(x_i \cdot x_j)$ 就可以实现某一非线性变换后的线性分类, 而计算复杂度却没有增加, 此时式 (3) 和 (5) 变为

$$Q(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(x_i \cdot x_j), f(x) = \text{sgn}\{ \sum_{i=1}^n \alpha_i^* y_i K(x_i \cdot x) + b^* \}.$$

这就是支持向量机. 常用的核函数有: (1) 线性核函数 $K(x, y) = x \cdot y$; (2) 多项式核函数 $K(x, y) = (x \cdot y + 1)^d, d$ 为多项式的阶数, $d = 1, 2, \dots$; (3) 径向基核函数 $K(x, y) = \exp(-\|x - y\|^2 / 2\sigma^2), \sigma$ 为径向基函数宽度, $\sigma > 0$; (4) Sigmoid 核函数 $K(x, y) = \tanh[a(x \cdot y) - \delta], a, \delta$ 为常数.

2.2 SVM 多故障分类器的建立

支持向量机是一种处理二分类问题的方法, 但在实际应用中需要解决多类分类问题, 为此需要研究用支持向量机解决多类分类问题. 多类分类也是以二分类为基础的, 现在主要的多类分类算法^[5]主要有一对一、一对多和有向无环图分类法等, 本文应用一对一分类法. 多类分类问题可以形式化地表述为: 给定属于 k 类的 m 个训练样本 $(x_1, y_1), \dots, (x_m, y_m)$, 其中 $x_i \in R^n (i = 1, \dots, m)$, 且类别标签 $y_i \in \{1, \dots, k\}$. 其中, R^n 为 n 维数据空间, m 为训练样本的个数.

一对一方法是在每两类之间训练一个分类器, 因此对于一个 k 类问题, 有 k 类训练数据, 这 k 类训练数据两两组合, 共可构建 $M = C_k^2 = k(k-1)/2$ 个训练集, 分别使用 SVM 二类分类算法对这 M 个训练集进行学习, 产生 M 个分类器. 测试阶段的判别采用投票决策法^[6], 其决策流程图 2 所示. 图中 x_i 为待分类的样本; V_i 为第 i 类的得票数. 其解释是: 用所有的 $k(k-1)/2$ 个分类器对 x_i 进行分类, 在第 i 类和第 j 类之间分类时, 若该分类器判断 x_i 属于 i 类, 则 i 类的票数加 1, 否则 j 类的票数加 1. 最后将待分类的样本 x_i 归为得票数最多的那一类. S 为对应类的类别标签.

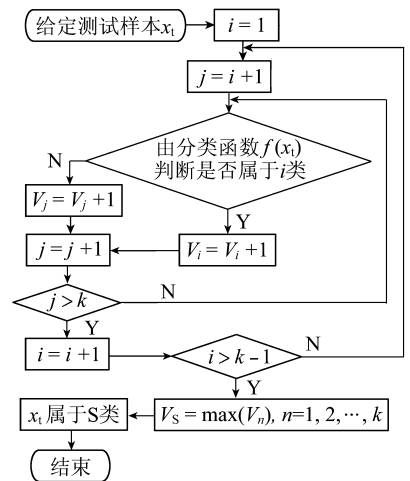


图 2 投票决策流程

Fig. 2 Flowchart of voting decision

3 诊断实例

图 3 为一轴流式通风机的 5 种典型故障的振动时域加

速度信号^[7] (信号经过小波除噪与零均值化处理). 风机转轴旋转频率 $f_r = 12.5 \text{ Hz}$, 采样频率 $f_s = 1 \text{ kHz}$, 分析频率 500 Hz , 采样长度为 $4\ 096$ 点. 由旋转机械典型故障频率特征分析^[8], 可按频域空间的最优小波包分解图 3 信号, 表示为 $d(0, 0) = d(6, 0) \oplus d(6, 1) \oplus d(6, 2) \oplus d(6, 3) \oplus d(4, 1) \oplus d(3, 1) \oplus d(2, 1) \oplus d(1, 1)$, 其中, $d(0, 0)$ 为原始信号的频域空间; $d(j, k)$ 为 j 层的第 k 个子频带.

按式 (1) 即可求得 5 组 8 维的能量特征向量, 每种典型故障各取 3 个样本作为训练样本, 分别将 3 个不平衡样本作为一类, 类别标签为 1, 3 个不对中样本作为一类, 类别标签为 2, 3 个基础松动样本作为一类, 类别标签为 3, 3 个碰磨故障样本作为一类, 类别标签为 4, 3 个叶片故障作为一类, 类别标签为 5. 共 15 组 8 维的能量特征向量, 并以此作为通风机多故障分类器的训练样本. 通风机多故障分类器的训练样本见表 1.




图 3 风机的 5 种典型故障时域波形

Fig. 3 Time wave of five typical faults of ventilator

表 1 SVM 多故障分类器的训练样本

Table 1 Training samples of SVM multi-fault classifier

| 样本序号 | 训练样本的特征向量 | | | | | | | | 类别标签 | 故障类型 |
|------|-----------|---------|---------|---------|---------|---------|---------|---------|------|------|
| 1 | 0.036 1 | 0.975 0 | 0.027 2 | 0.135 1 | 0.143 4 | 0.063 8 | 0.051 0 | 0.057 1 | 1 | 不平衡 |
| 2 | 0.043 3 | 0.979 2 | 0.036 6 | 0.135 7 | 0.148 5 | 0.065 9 | 0.059 6 | 0.060 4 | 1 | 不平衡 |
| 3 | 0.028 0 | 0.974 2 | 0.017 5 | 0.125 8 | 0.137 0 | 0.060 5 | 0.042 3 | 0.051 9 | 1 | 不平衡 |
| 4 | 0.036 0 | 0.469 1 | 0.053 6 | 0.836 4 | 0.265 3 | 0.064 4 | 0.033 5 | 0.026 7 | 2 | 不对中 |
| 5 | 0.042 8 | 0.469 5 | 0.056 6 | 0.841 0 | 0.269 3 | 0.069 6 | 0.039 2 | 0.027 1 | 2 | 不对中 |
| 6 | 0.027 0 | 0.461 5 | 0.045 1 | 0.827 9 | 0.258 3 | 0.062 0 | 0.030 3 | 0.019 7 | 2 | 不对中 |
| 7 | 0.614 5 | 0.634 2 | 0.229 0 | 0.296 5 | 0.275 8 | 0.060 9 | 0.028 0 | 0.037 5 | 3 | 基础松动 |
| 8 | 0.619 4 | 0.634 6 | 0.229 9 | 0.298 7 | 0.279 1 | 0.064 7 | 0.037 1 | 0.043 0 | 3 | 基础松动 |
| 9 | 0.610 7 | 0.629 2 | 0.223 0 | 0.294 4 | 0.266 7 | 0.050 4 | 0.022 0 | 0.036 7 | 3 | 基础松动 |
| 10 | 0.461 1 | 0.498 2 | 0.060 3 | 0.393 2 | 0.611 6 | 0.070 8 | 0.047 2 | 0.035 3 | 4 | 碰磨故障 |
| 11 | 0.469 1 | 0.504 1 | 0.067 0 | 0.393 9 | 0.615 2 | 0.073 8 | 0.048 7 | 0.043 3 | 4 | 碰磨故障 |
| 12 | 0.451 5 | 0.491 6 | 0.057 5 | 0.389 5 | 0.609 1 | 0.065 1 | 0.042 9 | 0.030 4 | 4 | 碰磨故障 |
| 13 | 0.027 0 | 0.355 2 | 0.056 7 | 0.039 1 | 0.025 8 | 0.088 5 | 0.926 3 | 0.042 5 | 5 | 叶片故障 |
| 14 | 0.024 1 | 0.351 1 | 0.051 0 | 0.031 8 | 0.021 9 | 0.086 9 | 0.921 6 | 0.037 3 | 5 | 叶片故障 |
| 15 | 0.032 1 | 0.359 6 | 0.061 4 | 0.048 4 | 0.028 4 | 0.092 0 | 0.929 1 | 0.046 1 | 5 | 叶片故障 |

选择径向基核函数^[9], 然后确定误差惩罚参数 C 和核参数 σ . 理论上在确定的数据子空间, C 的取值越小表示对经验误差的惩罚越小, 学习机器的复杂度小而经验风险较大; 反之亦然, 但对于每个数据子空间至少存在一个合适的 C 使得 SVM 的推广能力最好. 在确定核函数的基础上, 经过分析比较, 将常数 C 选为 $1\ 000$, σ 选为 1 时此多故障分类器的推广能力最好.

用图 4 的振动加速度信号验证所建立的通风机多故障分类器的分类能力和准确性. 经小波包频带能量特征提取其特征向量 $T = \{0.043\ 0, 0.412\ 1, 0.038\ 4, 0.843\ 3, 0.217\ 5, 0.037\ 2, 0.063\ 7, 0.042\ 9\}$, 由建立的多故障分类器对此待识别样本进行分类, 得输出类别标签为 2, 即表明该振动信号为不对中故障. 为验证该分类器的识别结果, 现对待检信号进行频谱分析. 图 5 为图 4 待识别信号的幅值谱, 由图 5 可知, 通风机的主要振动频率成分为旋转频率 12.7 Hz 以及高次谐波, 并且二次谐波 (25.39 Hz) 幅值最

大, 其幅值为基频幅值的 2.56 倍, 根据这些振动特征可判断该振动信号反映的故障为严重的轴系不对中, 由此证明了所建立的矿用通风机多故障分类器具有良好的分类能力.




图 4 识别的风机振动时域信号

Fig. 4 The identifying time signal of ventilator




图 5 待识别信号的幅值谱

Fig. 5 The power spectrum of identifying signal

4 结 语

本文提出的 SVM 故障诊断方法, 将支持向量机和小波分析相结合, 运用小波这一时频分析的有力工具提取通风机故障特征信息, 通过对通风机状态信号进行小波包频道能量特征提取得到 5 组 8 维能量特征向量, 将其作为 SVM 多故障分类器的训练样本, 以通风机不对中故障的振动信号作为待识别样本对训练后的 SVM 多故障分类器进行验证, 准确识别出了不对中故障, 达到了预期的效果. 研究结果表明了本文建立的 SVM 多故障分类器所用方法的正确性和有效性, 且只需较少的训练样本就能达到分类的要求, 具有较强的推广能力, 为矿用通风机故障智能诊断提出了一种新方法. 小波包与支持向量机相融合的故障诊断识别技术还可适于其他机械设备的故障分类与诊断.

参考文献:

- [1] Vladimir N Vapnik. 统计学习理论的本质 [M]. 张学工, 译. 北京: 清华大学出版社, 2000. 91 ~ 108.
- [2] 程正兴. 小波分析算法与应用 [M]. 西安: 西安交通大学出版社, 1998. 156 ~ 162.
- [3] 荆双喜. 基于小波分析的多分辨率故障诊断技术研究 [D]. 北京: 中国矿业大学 (北京), 2000.
- [4] 洗广淋. 统计学习理论与支持向量机 [J]. 工程论坛, 2005 (12): 178 ~ 181.
- [5] Chih-Wei Hsu, Chih-jen. A comparison of methods for multiclass support vector machines [J]. IEEE Trans. on Neural Networks, 2002, 13 (2): 415 ~ 425.
- [6] 段江涛, 李凌均, 张周锁, 等. 基于支持向量机的机械系统多故障分类方法 [J]. 农业机械学报, 2004, 35 (4): 144 ~ 147.
- [7] 荆双喜, 冷军发. 基于小波-神经网络的矿用通风机故障诊断研究 [J]. 煤炭学报, 2004, 29 (6): 736 ~ 739.
- [8] 徐敏, 黄昭毅. 设备故障诊断手册 [M]. 西安: 西安交通大学出版社, 1998. 298 ~ 349.
- [9] 姜谔男, 梁冰. 基于最小二乘支持向量机的煤层底板突出水量预测 [J]. 煤炭学报, 2005, 30 (5): 613 ~ 617.