

文章编号:1000-6788(2005)09-0131-06

基于 SVM 和 EMD 包络谱的滚动轴承故障诊断方法

程军圣,于德介,杨宇

(湖南大学机械与汽车工程学院,湖南长沙 410082)

摘要: 针对滚动轴承故障振动信号的调制特征和传统包络分析法的缺陷以及现实中难以获得大量典型故障样本的实际情况,提出了一种基于支持向量机(Support Vector Machine,简称 SVM)和经验模态分解(Empirical Mode Decomposition,简称 EMD)包络谱的滚动轴承故障诊断方法.该方法首先对原始信号进行经验模态分解,将其分解为多个固有模态函数(Intrinsic Mode Function,简称 IMF)之和,然后求出包含主要故障信息的若干个 IMF 分量的包络谱,最后定义包络谱中各种故障特征频率处的幅值比为特征幅值比,将其作为故障特征向量,并以此作为 SVM 分类器的输入参数来区分滚动轴承的工作状态和故障类型.实验分析结果表明了该方法的有效性.

关键词: 支持向量机;经验模态分解;包络谱;特征幅值比;滚动轴承;故障诊断

中图分类号: TH165;TH113;TH133

文献标识码: A

A Fault Diagnosis Approach for Roller Bearing Based on SVM and EMD Envelope Spectrum

CHENG Jun-sheng, YU De-jie, YANG Yu

(College of Mechanical and Automotive Engineering, Hunan University, Changsha 410082, China)

Abstract: According to the modulation characteristics of roller bearing fault vibration signals, the limitation of the traditional envelope analysis and the situation that it is hard to obtain enough fault samples, a roller bearing fault diagnosis method based on Support Sector Machine (SVM) and Empirical Mode Decomposition (EMD) envelope spectrum is proposed in this paper. Firstly, vibration signals are decomposed into a finite number of intrinsic mode functions (IMFs), then, the ratios of amplitudes in different characteristic frequencies are defined as the characteristic amplitude ratios after the envelope spectra of some IMFs which include the most dominant fault information are obtained; finally, the characteristic amplitude ratios are regarded as the fault features and served as input parameters of SVM classifier to classify working condition and fault patterns of roller bearings. The analysis results demonstrated the effectiveness of the proposed method.

Key words: SVM; EMD; envelope spectrum; characteristic amplitude ratio roller bearing; fault diagnosis

1 引言

在滚动轴承故障诊断中,基于人工神经网络的模式识别方法以其较强的自组织、自学习能力和非线性模式分类性能得到了广泛应用^[1,2].但人工神经网络需要大量的典型故障数据样本或经验知识^[3,4],而在实际生产当中,一般来讲很难获得大量典型的滚动轴承故障样本.支持向量机(Support Sector Machine,简称 SVM)是 Vapnik 等人根据统计学习理论提出的一种学习方法^[5],它在解决模式识别的小样本问题中表现出了独特的优势和良好的应用前景^[6],已用于模式识别和特征提取等领域^[7,8].SVM 可以采用少量的时域故障数据样本训练故障分类器,不必进行信号预处理来提取特征量,便可实现多故障的识别和诊断^[9].然而,在工程中测取的滚动轴承故障振动信号常常受到随机噪声的干扰,使得信号的信噪比很低,特别是发生早期故障时,其微弱的故障信息完全淹没在噪声中,因此有必要在采用 SVM 对滚动轴承故障分类之前对原始信号进行预处理来提取故障特征,以获得更好的分类效果.事实上,滚动轴承发生故障时其振动信号往

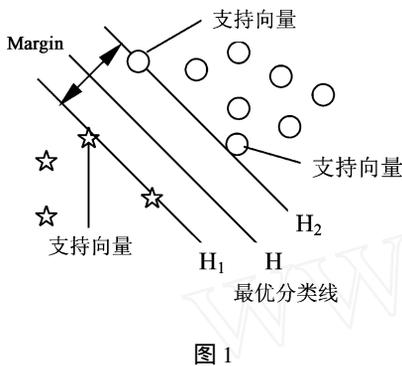
收稿日期:2004-03-25

资助项目:国家自然科学基金(50275050);高等学校博士点专项科研基金(20020532024)

作者简介:程军圣(1968-),男,湖南大学,副教授,博士,从事信号处理、机械故障诊断研究.

往是多分量的调制信号 $x(t) = \sum_{m=1}^M a_m(t) \cos[\omega_m(t)]$, 由于调制信号的包络更集中地携带了故障信息^[10], 因此对这类信号采用包络分析方法来提取特征是十分有效的^[11,12]. 但传统的包络分析方法需要根据先验知识, 预先确定滤波中心频率, 而中心频率的选择恰当与否将极大地影响分析诊断结果的准确性^[13].

针对上述问题, 本文提出了基于 SVM 和经验模态分解 (Empirical Mode Decomposition, 简称 EMD) 包络谱的滚动轴承故障诊断方法. 首先对滚动轴承振动信号进行了 EMD 分解, 将其分解为有限的 IMF (Intrinsic Mode Function, 简称 IMF) 分量之和, 每一个 IMF 分量可以是幅度或频率调制的^[14], 也就是一个单分量的调制信号 $c(t) = a(t) \cos[\omega(t)]$, 这样就可以对每个 IMF 分量进行包络分析, 求出包含主要故障信息的前几个 IMF 分量的包络谱, 再定义包络谱中滚动轴承内圈、外圈、滚动体故障特征频率处的幅值比为特征幅值比, 并以此作为故障特征向量输入 SVM 分类器, 以 SVM 的输出结果为依据来判断滚动轴承的工作状态和故障类型. 对滚动轴承内圈、外圈故障振动信号的分析结果表明, 该方法克服了传统包络分析法的缺陷, 可以有效地提取滚动轴承故障特征, 并成功地对滚动轴承工作状态和故障类型进行了分类.



2 SVM 原理

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. 图中, 五角星和圆圈分别代表两类样本, 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 $x \cdot n + b = 0$, 我们可以对它进行归一化, 使得对线性可分的样本集 $(x_i, y_i), i = 1, \dots, l, x \in R^d, y \in \{+1, -1\}$, 满足

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

此时分类间隔等于 $2/||n||$, 使间隔最大等价于使 $||n||^2$ 最小. 满足条件 (1) 且使 $\frac{1}{2} ||n||^2$ 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 (Support Vector).

Vapnik 给出了求该最优分类面问题的解, 即分类函数^[5]为:

$$f(x) = \text{sgn} \left[\sum_{i=1}^l y_i (x_i \cdot x) + b \right], \tag{2}$$

其中乘子 α_i 为目标函数:

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

在约束

$$\alpha_i \geq 0, i = 1, 2, \dots, l, \tag{4}$$

$$\sum_{i=1}^l \alpha_i y_i = 0 \tag{5}$$

下的极大值点, 非零 α_i 对应的样本点 x_i 为支持向量, 阈值:

$$b = \sum_{i=1}^l y_i - \sum_{i=1}^l \alpha_i x_i \tag{6}$$

$$= \sum_{i=1}^l y_i x_i \tag{7}$$

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, 在变换空间求最优分类面. 这种变换一般来讲比较复杂, 但是我们可注意到, 在上面的问题中, 不论是寻优函数 (3) 还是分类函数 (2) 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, 而这种内积运算是可以用原空间中的函数实现的, 我们甚至没有必要知道变换的形式. 根据泛函的

有关理论,只要一种核函数 $K(x_i, x_j)$ 满足 Mercer 条件,它就对应某一变换空间中的内积^[5].

因此,在最优分类面中采用适当的内积函数 $K(x_i, x_j)$ 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,此时目标函数(3)变为

$$W(\cdot) = \sum_{i=1}^l y_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j K(x_i, x_j), \quad (8)$$

相应的分类函数(2)也变为

$$f(x) = \text{sgn} \left[\sum_{i=1}^l y_i K(x, x_i) + b \right]. \quad (9)$$

常用的核函数有线性核函数、多项式核函数、径向基核函数、Sigmoid 核函数.

3 EMD 方法

EMD 方法^[14]是由 Huang 提出的一种新的信号处理方法,它假设任何信号都由不同的固有模态函数(IMF)组成,每个 IMF 可以是线性的,也可以是非线性的,IMF 分量必须满足下面两个条件:一是其极值点个数和过零点相同或最多相差一个,二是其上下包络线关于时间轴局部对称.这样,任何一个信号就可以分解为有限个 IMF 之和,而 IMF 可以按以下方法获得^[14]:

1) 确定信号 $x(t)$ 的所有局部极值点,然后用三次样条线将所有的局部极大值点连接起来形成上包络线,用三次样条线将所有的局部极小值点连接起来形成下包络线,这两条包络线包络了所有的信号数据.

2) 将两条包络线的均值记为 μ_1 , 求出

$$y_1(t) = x(t) - \mu_1. \quad (10)$$

3) 判断 $y_1(t)$ 是否为 IMF,若 $y_1(t)$ 不满足 IMF 条件,则将 $y_1(t)$ 作为原始数据,重复步骤 1)、2),直到 $y_1(t)$ 满足 IMF 条件,此时,记 $y_1(t) = c_1(t)$,则 $c_1(t)$ 为信号 $x(t)$ 的第一个 IMF 分量,它代表信号 $x(t)$ 中最高频率的分量.

4) 将 $c_1(t)$ 从 $x_1(t)$ 中分离出来,即得到一个去掉高频分量的差值信号 $r_1(t)$, 即有

$$r_1(t) = x(t) - c_1(t). \quad (11)$$

将 $r_1(t)$ 作为原始数据,重复步骤 1)、2)和 3),得到第二个 IMF 分量 $c_2(t)$,重复 n 次,得到 n 个 IMF 分量.这样就有

$$\left. \begin{aligned} r_1 - c_2 &= r_2 \\ &\dots \\ r_{n-1} - c_n &= r_n \end{aligned} \right\} \quad (12)$$

当 $c_n(t)$ 或 $r_n(t)$ 满足给定的终止条件(通常使 $r_n(t)$ 成为一个单调函数)时,循环结束,由(11)式和(12)式可得到:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t). \quad (13)$$

因此,我们可以把任何一个信号 $x(t)$ 分解为 n 个 IMF 分量和一个残量 r_n 之和,各个 IMF 分量 $c_1(t)$, $c_2(t)$, \dots , $c_n(t)$ 都是一个单分量的调制信号,分别包含了信号从高到低不同频率段的成分.

4 基于 SVM 和 EMD 包络谱的滚动轴承故障诊断方法

采用 EMD 方法对滚动轴承故障振动信号分解后,得到若干个 IMF 分量,每个 IMF 分量都是一个单分量的调制信号,这样就可以对每个 IMF 分量进行包络分析.考虑到滚动轴承的故障信息主要在高频带,因此可以对前几个 IMF 分量分析来提取故障特征信息.

对(13)式中的前几个 IMF 作 Hilbert 变换有

$$H[c_i(t)] = \frac{1}{\pi} \int \frac{c_i(t)}{t - \tau} d\tau. \quad (14)$$

进一步可求出包络信号

$$B(t) = \sqrt{c_i^2(t) + H^2 [c_i(t)]}. \tag{15}$$

对包络信号作谱分析即可得到包络谱^[15].

信号包络集中反映了每周期的冲击情况及每次冲击的剧烈程度,若对包络信号定义一个合适的描述指标,则可准确地反映滚动轴承的工作状况和故障类型.当滚动轴承分别在内圈、外圈、滚动体等部位出现故障时,在包络谱中相应的故障特征频率处就会出现谱峰,因此我们定义在包络谱中滚动轴承外圈、滚动体故障特征频率处的幅值与内圈故障特征频率处的幅值比为特征幅值比,即:

$$= \frac{A(f_o)}{A(f_i)}, \quad = \frac{A(f_r)}{A(f_i)}, \tag{16}$$

并以此作为故障特征向量,采用 SVM 对滚动轴承的工作状态和故障类型进行分类.式(16)中, $A(f_o)$ 、 $A(f_r)$ 、 $A(f_i)$ 分别表示在包络谱中滚动轴承外圈、滚动体、内圈故障特征频率处的幅值.

基于 SVM 和 EMD 包络谱的滚动轴承故障诊断方法流程图如图 2 所示,它采用 EMD 方法对滚动轴承振动信号进行预处理,然后求出前几个 IMF 分量的包络谱,在此基础上,求出各 IMF 分量的特征幅值比、,并以此作为故障特征向量,以 SVM 作为分类器来识别滚动轴承的工作状态和故障类型.

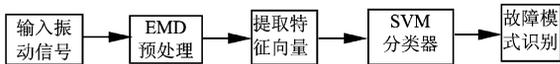


图 2 基于 SVM 和 EMD 包络谱的滚动轴承故障诊断流程图

具体诊断步骤如下:

- 1) 按一定的采样频率 f_s 分别对滚动轴承的几种状态(正常、滚动故障、外圈故障和内圈故障)进行采样;
- 2) 对每个样本信号进行 EMD 分解,得到各信号的各 IMF 分量;

3) 由于滚动轴承故障振动信号的信息主要包含在高频段,因此选择前若干个高频段的 IMF 分量作 Hilbert 变换,并求出其包络谱;

4) 根据(16)式求出每个样本信号的特征幅值比、(即特征向量值);

5) 设计 2 个 SVM 分类器.对 SVM1 定义 $y = +1$ 表示内圈故障, $y = -1$ 表示正常状态或外圈故障,即用 SVM1 将内圈故障分离出来;再对 SVM2 定义 $y = +1$ 表示外圈故障, $y = -1$ 表示正常状态,即用 SVM2 将外圈故障分离出来.将前几个 IMF 分量的特征幅值比、作为 SVM 的输入,对 SVM 进行训练;

6) 将测试样本的特征幅值比、输入 SVM 分类器进行分类计算,并根据分类函数的结果来确定滚动轴承的工作状态和故障类型.

5 应用

实测的轴承为 6311 型滚动轴承,实验时轴的转频为 25Hz,采样频率为 4096Hz,振动信号由安装在轴承座上的加速度传感器来拾取.故障是通过激光切割在内圈或外圈上开槽来设置的,槽宽为 0.15mm,槽深为 0.13mm.由于实验条件的限制而未能在滚动体上设置故障.其中某一具有内圈故障的滚动轴承故障振动加速度信号如图 3 所示.经计算,滚动轴承外圈故障特征频率 $f_o = 76\text{Hz}$,滚动轴承内圈故障特征频率 $f_i = 124\text{Hz}$.

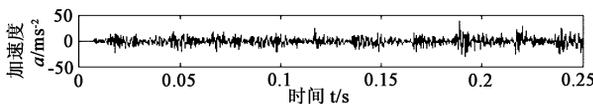


图 3 具有内圈故障的滚动轴承振动加速度信号

在三类数据中分别随机抽取 2 组作为训练样本,再各取 2 组数据作为测试样本.对实测的振动信号,首先按(10)~(13)式对样本数据进行 EMD 分解,由于滚动轴承振动信号的主要信息在高频段,因此本文选择包含了主要信息的前 3 个 IMF 分量进行 Hilbert 变换,

并求出其包络信号的包络谱,从其包络谱中可求出其特征幅值比 r_i ($i = 1, 2, 3$ 分别表示 c_1, c_2, c_3 的包络谱中外圈故障特征频率处与内圈故障特征频率处的幅值比),并以此作为故障特征向量输入 SVM 分类器.

通过比较,采用线性核函数进行计算取得了令人满意的分类效果.对 SVM1 定义 $y = +1$ 表示内圈故障, $y = -1$ 表示正常状态或外圈故障,由式(7)~(11)可得到 SVM1 分类器各参数: $w = [0.6901, 0.6901, 0]^T$,

$= 1.1748, b = 1.7125$. 对 SVM2 定义 $y = +1$ 表示外圈故障, $y = -1$ 表示正常状态, 由式(7) ~ (11) 可得到 SVM2 分类器各参数: $= [6.5960, 2.5554, 1.0989, 8.0526]^T, \quad = 4.2782, b = 3.1391$. 将两个分类器按图 4 所示的二叉树形式组合, 便成为一个可分离 2 种故障的多故障分类器. 在测试中, 先将测试数据样本 x 输入分类器 1, 由式(9) 计算 $f(x)$, 若 $f(x)$ 为 1, 则确认为内圈故障, 测试结束; 否则自动输入给分类器 2, 由式(9) 计算 $f(x)$, 若 $f(x)$ 为 1, 则确认为外圈故障, 否则为正常信号. 各测试样本的分类结果可根据式(9) 得到, 结果 SVM 全部成功识别. 限于篇幅原因, 表 1 只给出了 6 组测试样本(分别对应三种模式) 的识别结果. 显然, 分类结果与实际情况完全一致, 从表中可知, 对于小样本, SVM 分类器仍然能够准确地进行分类, 这充分证明 SVM 分类器可成功应用于小样本识别中.

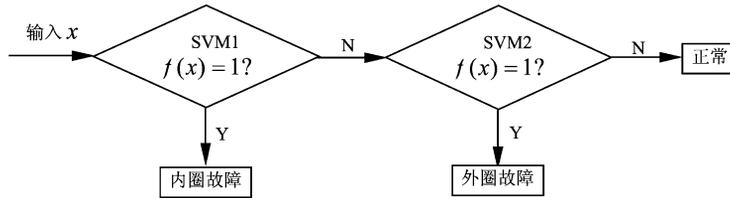


图 4 故障分类器流程图

表 1 基于 SVM 和 EMD 包络谱的滚动轴承故障识别结果

测试信号及其状态	特征幅值比			SVM1		SVM2		识别结果
	1	2	2	样本到 H 的距离	(分类结果)	样本到 H 的距离	(分类结果)	
内圈故障	0.3904	0.7678	0.2930	1.0095	(+1)			内圈故障
内圈故障	0.4941	0.8241	0.4031	1.0987	(+1)			内圈故障
外圈故障	3.3619	3.5209	5.2753	-6.5172	(-1)	5.0004	(+1)	外圈故障
外圈故障	3.1436	7.2690	8.0281	-2.5845	(-1)	10.2001	(+1)	外圈故障
正常状态	1.4473	1.4218	3.5516	-0.6918	(-1)	-2.0309	(-1)	正常状态
正常状态	0.7032	1.6770	1.7449	-1.1033	(-1)	-2.1614	(-1)	正常状态

6 结论

本文针对滚动轴承故障诊断中难以获得大量典型故障样本的实际情况和滚动轴承故障振动信号的调制特性, 提出了基于 SVM 和 EMD 包络谱的滚动轴承故障诊断方法, 经研究得出以下结论:

1) SVM 适用于小样本模式识别, 本文以 SVM 作为分类器来识别滚动轴承的工作状态和故障类型, 得到了较好的结果.

2) 滚动轴承故障振动信号为调制信号, 为了提取调制信号的特征, 采用 EMD 方法将复杂的调制信号分解为若干个平稳的 IMF 分量之和, 然后对包含主要故障信息的前几个 IMF 分量求包络谱, 再定义滚动轴承内圈、外圈、滚动体故障特征频率处的幅值比为特征幅值比, 并以此作为故障特征向量.

3) 在本文方法中, 取消了传统的包络分析方法中设定滤波中心频率的步骤, 也不需要包络谱中寻找滚动轴承故障特征频率谱线, 而是直接从 SVM 分类器的输出结果中判断滚动轴承的工作状态和故障类型, 这样就大大减少了人工干预的影响, 便于实现诊断过程的自动化和计算机化.

对滚动轴承正常状态、具有内圈、外圈故障振动信号的分析结果表明, 基于 SVM 和 EMD 包络谱的滚动轴承故障诊断方法在小样本情况下仍可以准确、有效地对滚动轴承工作状态和故障类型进行分类, 从而为滚动轴承故障诊断提供了一种新的方法.

参考文献:

[1] Paya A, Esat I I, Badi M N M. Artificial neural network based fault diagnosis of rotating machinery using wavelet transforms as

- processor[J]. *Mechanical Systems and Signal Processing*, 1997, 11(5): 751 - 765.
- [2] Jack L B, Nandi A K, McCormick A C. Diagnosis of rolling element bearing faults using radial basis function networks[J]. *Applied Signal Processing*, 1999(6): 25 - 32.
- [3] 屈梁生, 张海军. 机械诊断的几个基本问题[J]. *中国机械工程*, 2000, 10(1 - 2): 211 - 216.
Qu Liangsheng, Zhang Haijun. Some basic problems in machinery diagnostics[J]. *China Mechanical Engineering*, 2000, 10(1 - 2): 211 - 216.
- [4] Burges C J C. A tutorial on support vector machines for pattern recognition[J]. *Data Mining and Knowledge Discovery*, 1998, 2(2): 121 - 167.
- [5] Vapnik V N. *The Nature of Statistical Learning Theory* [M]. New York:Spring-Verag, 1995.
- [6] Vapnik V N. An overview of statistical learning theory[J]. *IEEE Transactions on Neural Networks*, 1999, 10(5): 988 - 999.
- [7] 张学工. 关于统计学习理论与支持向量机[J]. *自动化学报*, 2000, 26(1): 32 - 42.
Zhang Xuegong. Introduction to statistical learning theory and support vector machines[J]. *Acta Automatica Sinica*, 2000, 26(1): 32 - 42.
- [8] 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): 617 - 620.
Hu Shousong, Wang Yuan. Support vector machines based fault diagnosis for nonlinear dynamics systems[J]. *Control and Decision*, 2001, 16(5): 617 - 620.
- [9] 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研究[J]. *西安交通大学学报*, 2002, 36(12): 1303 - 1306.
Zhang Zhouso, Li Lingjun, He Zhengjia. Research on diagnosis method of machinery fault based on support vector machine[J]. *Journal of Xi'an Jiaotong University*, 2002, 36(12): 1303 - 1306.
- [10] Radcliff G A. Condition monitoring of rolling element bearings using the enveloping technique[J]. *Machine Condition Monitoring, Mechanical Engineering Publication Ltd.*, London, 1990, 55 - 67.
- [11] Randall B. Hilbert transform techniques in machine diagnostics[J]. *IFTOMM International Conference on Rotordynamics*, Tokyo, 1986.
- [12] Brown D N. Envelope analysis detects bearing faults before major damage occurs. *Pulp Pap.*, 1989, 63: 113 - 117.
- [13] 何岭松, 李巍华. 用 Morlet 小波进行包络检波分析[J]. *振动工程学报*, 2002, 15(1): 119 - 121.
He Lingsong, Li Weihua. Morlet wavelet and its application in enveloping[J]. 2002, 15(1): 119 - 121.
- [14] Huang N E, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. *Proc. R. Soc. Lond. A*, 1998, 454: 903 - 995.
- [15] 田涛, 丁康. 希尔伯特变换及其在故障诊断中的应用[J]. *振动与冲击*, 1996, 15(2): 23 - 27.
Tian Tao, Ding Kang. Hilbert transform and its application in the failure diagnosis[J]. *Journal of Vibration and Shock*, 1996, 15(2): 23 - 27.