

文章编号：1005-8451（2015）08-0001-05

# 基于EMD与SVM的城轨列车滚动轴承故障诊断方法研究

何广坚<sup>1</sup>, 邢宗义<sup>2</sup>, 左成<sup>2</sup>, 张永<sup>2</sup>

(1. 广州市地下铁道总公司 基地维修中心, 广州 510320;  
2. 南京理工大学 自动化学院, 南京 210094)

**摘要：**针对城轨列车的滚动轴承故障诊断问题, 提出了一种经验模态分解(EMD, Empirical Mode Decomposition)与支持向量机(SVM, Support Vector Machine)相结合的故障诊断方法。对采集到的振动信号进行小波消噪, 利用经验模态分解将振动信号分解为一组本征模态函数(IMF, Intrinsic Mode Functions), 并计算其能量从而获得信号的特征向量。采用支持向量机实现了滚动轴承故障分类。实验结果表明, 本文提出的方法能够准确有效地识别城轨列车滚动轴承的工作状态和故障类型。

**关键词：**轨道车辆; 滚动轴承; 故障诊断; 经验模态分解; 支持向量机

**中图分类号：**U266.2 : TP39 **文献标识码：**A

## Fault diagnosis method for rolling bearing of metro vehicle based on EMD and SVM

HE Guangjian<sup>1</sup>, XING Zongyi<sup>2</sup>, ZUO Cheng<sup>2</sup>, ZHANG Yong<sup>2</sup>

(1. Maintenance Center, Guangzhou Metro Corporation, Guangzhou 510320, China;

2. School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China)

**Abstract:** Aiming at the problem of fault diagnosis for rolling bearing of metro vehicle, a method combined empirical mode decomposition (EMD), with support vector machine (SVM) was proposed. Firstly, the collected vibration signal was de-noised by using wavelet method. Then, the obtained signals were decomposed into a finite number of intrinsic mode functions (IMF) whose energy feature parameters were calculated to construct feature vectors. Finally, a certain SVM classifier was built to recognize the fault pattern. The experiment results indicated that the proposed method could identify fault patterns for ruling bearing accurately and effectively.

**Key words:** metro vehicles; rolling bearings; fault diagnosis; EMD; SVM

滚动轴承是城轨列车走行系的重要组成部分, 其服役状态是否正常直接影响列车的安全运行, 因此滚动轴承故障诊断是一个值得研究的重要问题<sup>[1-2]</sup>。城轨列车滚动轴承的故障诊断方法主要有温度法、声学法、振动法等<sup>[3-4]</sup>, 其中温度法对轴承烧伤诊断效果好, 但不能及时发现轴承早期故障; 声学法传感器安装灵活, 但噪声信号严重且难以确定具体安装位置; 振动法在轴箱上安装振动传感器, 测量振动信号, 并对信号进行处理分析来判别轴承的运行状态。由于振动法信号处理技术成熟, 信号特征明显, 易于安装与工程实施, 且对轴承的早期故障诊断有

效, 因此是列车滚动轴承故障诊断最为广泛的方法。

梁瑜等人<sup>[1]</sup>采用自适应傅立叶分解算法, 将轴承的振动信号分解为一系列单一分量, 然后进行共振解调, 从而根据得到的频谱判断轴承发生故障的部位。刘建强等人<sup>[2]</sup>根据轴承径向振动加速度信号, 采用小波包-包络分析和故障识别搜索算法, 诊断轴承故障及故障类型。潘丽莎等人<sup>[3]</sup>采用小波消噪对诊断数据进行滤波, 利用小波分解提取故障信号的能量特征向量, 最后采用径向基函数(RBF)神经网络进行故障诊断。陶海龙等人<sup>[5]</sup>提出了一种基于改进粒子群优化算法的逆传播(BP)神经网络优化模型, 实现了轴承故障诊断。危韧勇等人<sup>[6]</sup>以峭度等作为特征向量, 建立支持向量机分类器, 实现机车轴承状态和故障类型的判断。

收稿日期: 2015-01-15

基金项目: 国家“八六三”计划项目(2011AA110506)。

作者简介: 何广坚, 工程师; 邢宗义, 副教授。

本文采用经验模态分解与支持向量机结合的方法对城轨列车滚动轴承进行故障诊断。对采集到的轴承振动信号进行小波消噪,利用经验模态分解(EMD)提取故障信号的能量特征向量,最后利用提取的能量特征向量训练支持向量机,进行故障诊断。实验结果证明了基于EMD和支持向量机的方法在城轨列车滚动轴承故障诊断中的有效性。

## 1 振动信号的特征提取

振动信号特征提取在频域内一般将信号分解为多个分量并计算每一个分量的特征值,以提取原始振动信号的特征。常用的信号分解方法包括傅立叶变换、小波分解和EMD等,其中EMD具有较强的自适应性,能够有效提取信号微弱的特征,不再依赖于基函数,是进行滚动轴承振动信号处理的理想选择<sup>[7~8]</sup>。由于采集振动信号的过程中存在噪声,采用小波消噪法对信号进行去噪处理,可以更准确地对列车滚动轴承的振动信号进行分析。

### 1.1 EMD算法

EMD算法<sup>[9~10]</sup>将一个复杂的信号分解为若干个本征模态函数分量之和,每个本征模态函数必须满足两个基本条件:(1)整个数据段上的信号,过零点的个数和极值点的个数必须相等或相差最多不能超过一个;(2)在任意时刻,局部极大值点和局部极小值点分别形成的上下包络线的均值为零。

对信号 $x(t)$ 进行EMD处理步骤如下:

(1) 计算信号 $x(t)$ 的局部极大值点和局部极小值点,并将极值点用3次样条曲线连接,形成信号的上下包络线;

(2) 将上下包络线的平均值记为 $m_1$ ,求取:

$$h_1(t)=x(t)-m_1 \quad (1)$$

如果满足两个基本条件,则 $h_1(t)$ 是 $x(t)$ 的第一个本征模态函数(IMF)分量。

(3) 如果则 $h_1(t)$ 不满足两个基本条件,则将其作为待处理信号,重复步骤(2)得到:

$$h_{11}(t)=h_1(t)-m_{11} \quad (2)$$

重复上述过程 $k$ 次,直到 $h_{1k}(t)$ 满足本征模态函数成立的两个基本条件,把 $h_{1k}(t)$ 记为 $c_1(t)$ ,则 $c_1(t)$ 为 $x(t)$ 的第一个IMF分量。

(4) 将 $c_1(t)$ 从 $x(t)$ 中分离出去,得:

$$r_1(t)=x(t)-c_1(t) \quad (3)$$

将 $r_1(t)$ 作为初始信号,再次对 $r_1(t)$ 重复上述过程,逐步分离出各个IMF分量如下:

$$r_2(t)=r_1(t)-c_2(t)$$

$$r_3(t)=r_2(t)-c_3(t)$$

.....

$$r_n(t)=r_{n-1}(t)-c_n(t) \quad (4)$$

当 $r_n(t)$ 为单调函数或者 $c_n(t)$ 小于某一阈值时,循环终止。

(5) 将原始信号 $x(t)$ 表示为多个IMF分量与残余量之和:

$$x(t)=\sum_{i=1}^n c_i(t)+r_n(t) \quad (5)$$

其中, $c_1(t), c_2(t), \dots, c_n(t)$ 为各阶IMF分量,包含信号从高到低不同频率段的成分, $r_n(t)$ 为残余量,表示信号的平均趋势。

### 1.2 EMD分解特征能量的提取

在信号特征提取方面,可以直接对信号进行时域或频域计算,获得均值、峭度等特征参数,也可以对变换分解后的信号求取特征指标<sup>[11]</sup>。本文对EMD分解后的信号进行特征提取。列车滚动轴承正常工作和故障时在信号能量上有所区别,因此本文以EMD分解后各IMF分量的能量作为特征值,其步骤如下。

(1) 计算IMF分量的能量 $E_i$

$$E_i=\int_{-\infty}^{+\infty} |c_i(t)|^2 dt \quad (6)$$

(2) 构造能量特征向量 $T$

$$T=[E_1, E_2, \dots, E_n] \quad (7)$$

(3) 对特征向量进行归一化处理,定义信号总能量为 $E=\sum_{i=0}^n E_i$ ,则归一化后的特征向量 $T'$ 为:

$$T'=[\frac{E_1}{E}, \frac{E_2}{E}, \dots, \frac{E_n}{E}] \quad (8)$$

## 2 基于支持向量机的故障诊断

### 2.1 支持向量机的概念

支持向量机是在统计学理论和结构风险最小化原理的基础上,为解决小样本数据分类和非线性问题而提出的方法<sup>[12~13]</sup>,其基本思想是:(1)定义最优

线性超平面，将寻找最优超平面的算法归结为一个求解凸规划的问题；(2) 采取非线性映射将样本空间映射到高维的特征空间；(3) 应用线性学习机解决特征空间中高度非线性分类和回归等问题。以图 1 所示的二维情况对支持向量机进行说明，实心点和空心点代表 2 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，所谓最优分类线就是要求分类线不但能将 2 类正确分开，而且使分类间隔最大，其中  $H_1$  和  $H_2$  上的训练样本点称之为支持向量。

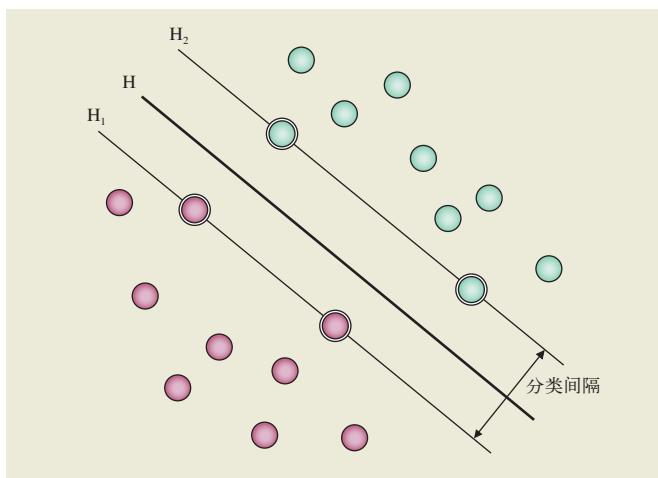


图1 最优分类超平面

## 2.2 基于支持向量机的故障诊断建模

列车滚动轴承的工作状态主要分为 4 种，即正常轴承、内圈故障、外圈故障和滚动体故障。本文采用有向无环决策支持向量机<sup>[14]</sup>进行滚动轴承故障诊断，其分类规则如图 2 所示。其中 A 为正常的轴承，B 为内圈故障，C 为外圈故障，D 为滚动体故障。

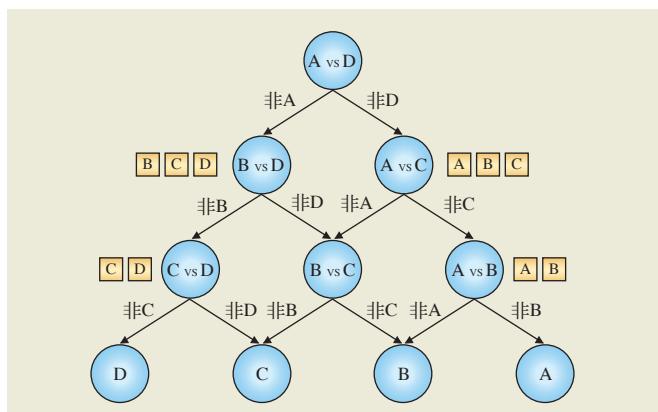


图2 SVM多分类规则

SVM 核函数选用高斯径向基函数：

$$K(x, x_i) = \exp\left[\frac{-x(x-x_i)^2}{\sigma^2}\right] \quad (9)$$

## 3 实验与分析

### 3.1 实验数据

实验所用的轴承振动信号通过城轨列车滚动轴承故障试验平台采集获得，轴承选用的是 SKF 型号轴承，实验轴承包含正常、内圈故障、滚动体故障和外圈故障 4 种状态的轴承，轴箱外壳上加装 625B10 型加速度传感器，采样频率为 12 kHz。

由于采集振动信号的过程中存在噪声，为了更准确地对列车滚动轴承的振动信号进行分析，采用小波消噪法对原始信号去噪处理。图 3 给出了小波消噪后的振动信号。

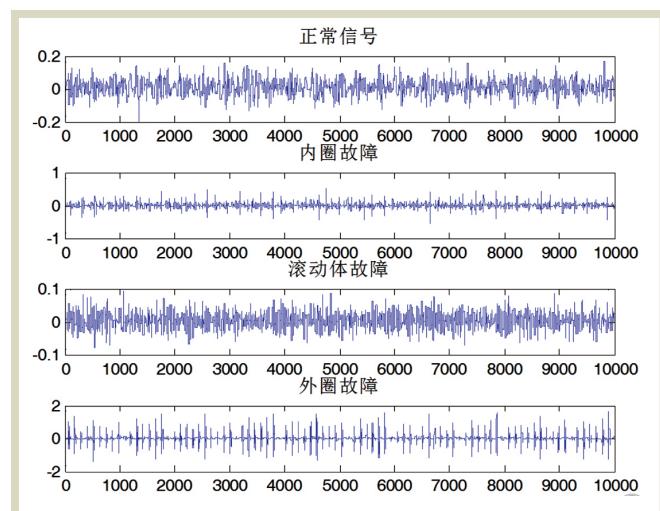


图3 消噪后的振动信号

### 3.2 轴承振动信号的特征提取

轴承振动信号经 EMD 分解后可以得到 14 个 IMF 分量，其中前 6 阶 IMF 分量的振幅较大，包含了信号的绝大多数能量。图 4 给出了正常及各故障状况的前 6 阶 IMF 分量的能量值，可见不同故障模式轴承的能量分布存在差异，因此可以选用能量向量作为支持向量机的输入向量用于滚动轴承故障诊断。

### 3.3 基于SVM的故障诊断

为实现滚动轴承的正常、内圈故障、外圈故障和滚动体故障等 4 类故障形式的分类，采用有向无

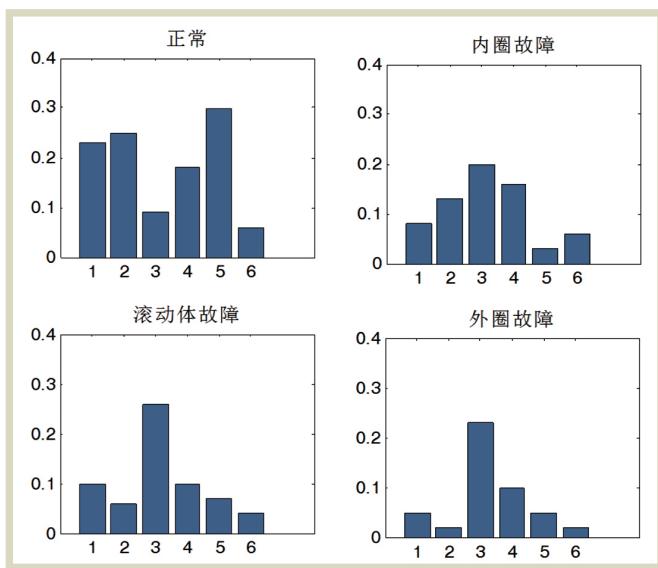


图4 各故障状况的IMF能量特征向量

环决策 SVM 机进行故障诊断。SVM 由 6 个子分类器组成，其子分类器的分类准确率如表 1 所示。

表1 各子分类器的故障诊断结果

子分类器	准确率
正常 VS 内圈故障	0.931 6
正常 VS 外圈故障	0.931 3
正常 VS 滚动体故障	0.922 4
外圈故障 VS 滚动体故障	0.789 7
内圈故障 VS 滚动体故障	0.871 8
内圈故障 VS 外圈故障	0.846 8

从表 1 可以看出，正常轴承与故障轴承的 3 个子分类器的故障诊断准确率分别为 0.931 6、0.931 3 和 0.922 4，平均值为 0.928 4，故障轴承的 3 个子分类器的故障诊断准确率分别为 0.789 7、0.871 8 和 0.846 8，平均为 0.831 6，因此正常轴承与故障轴承的子分类器的故障诊断准确性高于其它子分类器，平均准确性差值为 0.096 8。针对正常、内圈故障、外圈故障和滚动体故障 4 种轴承，SVM 故障诊断准确率分别为 0.928 4、0.883 4、0.855 9 和 0.861 3，可以看出正常轴承的诊断准确率最高，外圈故障诊断准确率最低。

为形象描述 SVM 的故障诊断结果，图 5 给出了故障分类图，其中横坐标为测试集样本，从 1~117 为正常轴承，118~234 为内圈故障，235~351 为外圈故障，352~468 为滚动体故障，纵坐标为类别标签，A、B、C、D 分别表示正常轴承、内、外圈和滚动体故障，可见正常轴承被错误诊断的样本点数较少，而外圈

故障被错误诊断的样本点数最多。

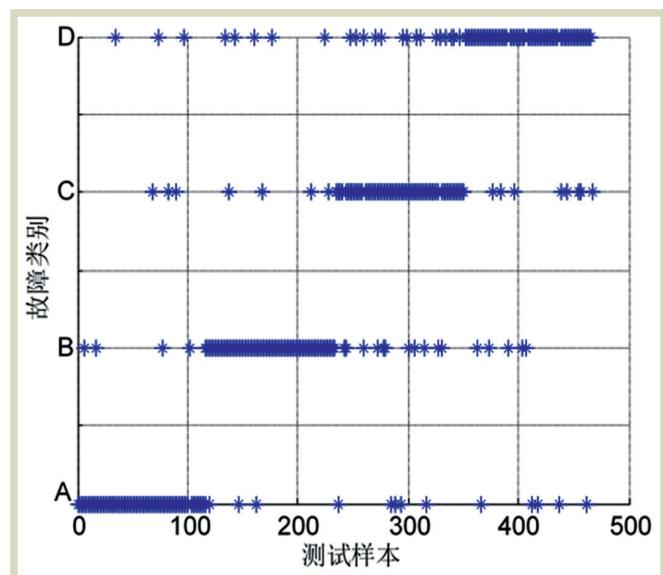


图5 故障分类图

#### 4 结束语

城轨列车滚动轴承的状态对车辆安全运行至关重要，为此本文提出了一种基于经验模态分解和支持向量机相结合的城轨列车滚动轴承故障诊断方法。采用小波分析进行原始信号消噪，利用经验模态分解将振动信号分解为一组本征模态函数，并计算其能量从而获得信号的特征向量，最后采用有向无环决策支持向量机进行滚动轴承故障模式分类。实验结果表明，本文所提出的方法能够准确、有效地实现列车滚动轴承故障诊断。

#### 参考文献：

- [1] 梁 瑜, 贾利民, 蔡国强, 刘金朝. 基于 AFD 算法的滚动轴承故障诊断方法 [J]. 中国铁道科学, 2013, 34 (1) : 95-100.
- [2] 刘建强, 赵治博, 章国平, 等. 地铁车辆转向架轴承故障诊断方法研究 [J]. 铁道学报, 2015, 37 (1) : 30-36.
- [3] 潘丽莎, 陈 皓, 秦 勇, 等. 基于小波包和 RBF 神经网络的轨道车辆滚动轴承故障诊断 [J]. 铁路计算机应用, 2012, 21 (7) : 8-11.
- [4] 鲁文波, 蒋伟康. 利用声场空间分布特征诊断滚动轴承故障 [J]. 机械工程学报, 2012, 48 (13) : 68-72.
- [5] 陶海龙, 辜琳丽, 张胜召. 改进粒子群优化算法的 BP 神经网络在机车滚动轴承故障诊断中的应用 [J]. 铁路计算机应用

(下转 P15)