DOI:10.11918/j.issn.0367-6234.201604066

# EEMD-PE 与 M-RVM 相结合的轴承故障诊断方法

刘晓东, 刘朦月, 陈寅生, 朱文炜

(哈尔滨工业大学 电气工程及自动化学院,哈尔滨 150001)

摘 要:滚动轴承振动信号中包含了大量轴承运行状态信息,但是由于振动信号具有非线性和非平稳性的特点,难以充分提 取振动信号中的故障特征,导致现有基于模式识别的轴承故障诊断方法的故障识别准确率较低.为了提高滚动轴承故障识别 的准确率,提出了一种基于集合经验模态分解-排列熵(EEMD-PE)特征提取与多分类相关向量机(M-RVM)相结合的轴承故 障诊断方法.首先,该方法利用 EEMD 对非线性和非平稳信号的自适应分解能力,将轴承故障信号分解为一组包含故障特征 的本征模态函数(IMFs).然后,利用排列熵提取由 EEMD 分解得到的 IMFs 中的故障特征,并组成特征向量.最后,采用 EEMD-PE对不同故障状态下的训练样本集进行特征提取,组成特征向量集对 M-RVM 分类器进行建模,以概率输出的形式实 现对滚动轴承的故障诊断.实验结果表明:EEMD-PE 特征提取方法能够对滚动轴承振动信号的故障特征进行有效提取, M-RVM能够对故障滚动轴承振动信号包含的故障特征进行识别.与现有轴承故障诊断方法相比较,所提出的方法能够提高故 障识别准确率,达到 99.58%.

文章编号: 0367-6234(2017)09-0122-07

## Rolling bearing fault diagnosis based on EEMD-PE coupled with M-RVM

LIU Xiaodong, LIU Mengyue, CHEN Yinsheng, ZHU Wenwei

(School of Electrical Engineering and Automation, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Vibration signals of faulty rolling bearing contain a large amount of information about the bearing operating status. However, it is difficult to extract the fault features completely because of its characteristics of nonlinearity and non-stationarity, which leads to a problem of relatively low fault identification rate of current fault diagnosis methods based on pattern recognition. In order to improve the accuracy of rolling bearing fault diagnosis, this paper proposes a fault diagnosis method of rolling bearing, which adopts ensemble empirical mode decomposition and permutation entropy (EEMD-PE) to extract the fault features coupled with multiclass relevance vector machine (M-RVM) to achieve the goal of fault classification. Firstly, the vibration signal of faulty rolling bearing decomposes into a series of intrinsic mode functions (IMFs) by using the adaptive decomposition ability of nonlinear and non-stationary signals. Afterwards, the fault features contained in IMFs are extracted by permutation entropy, and the features constitute the feature vector. Finally, EEMD-PE method is used to extract the fault feaures of training sample set under different fault conditions. The M-RVM classifier is trained by using feature vector set, and the multiple fault identification is implemented in the form of probability output. The experimental results show that EEMD-PE feature extraction method can effectively extract fault features of rolling bearing vibration signal, M-RVM can identify the fault feature contained in rolling bearing vibration signals. Compared with the existing bearing fault diagnosis methods, this method can improve the fault identification rate reaching up to 99.58%. Keywords: rolling bearing; fault diagnosis; EEMD; PE; M-RVM

滚动轴承故障诊断方法一直是国内外研究的热 点.滚动轴承运行过程中的振动信号往往包含着重 要的运行状态信息<sup>[1-3]</sup>.因此,目前应用最为普遍的 轴承故障诊断方法是通过提取轴承振动信号中的故 障特征后,利用模式识别方法实现故障识别<sup>[2]</sup>.然 而,滚动轴承振动信号具有非线性与非平稳性的特 点,并且在传输过程中容易受到背景噪声以及其他 运动部件的影响,导致从原始振动信号中提取出故 障特征变得十分困难<sup>[3,22-23]</sup>,进而严重影响故障识 别的准确率.传统的时-频分析方法在轴承故障诊 断中有较多的应用也取得了相应的成果,如短时傅 里叶变换<sup>[4]</sup>、小波变换<sup>[2]</sup>等.但以上方法都存在着 对轴承振动信号分解缺乏自适应能力的缺陷.对于 复杂的故障振动信号,仅仅依靠人的主观参数设置 来进行分解,可能会造成故障特征信息的遗漏,严重 影响故障诊断的性能<sup>[5]</sup>.

经验模态分解(empirical mode decomposition,

收稿日期:2016-04-14

作者简介:刘晓东(1967—),男,副教授

通信作者:刘晓东, liuxiaodong@ hit.edu.cn

EMD)<sup>[6]</sup>是最具代表性的自适应时—频分析方法之 一,并且已经在传感器信号处理、机械故障诊断等很 多领域得到了应用<sup>[7-8]</sup>.然而,由于 EMD 存在模态混 淆现象,会在一定程度上影响信号分解的效果,导致 分解结果不稳定<sup>[9]</sup>,进而影响后续特征提取的结果. 因此,本文利用文献[10]提出的集合经验模态分解 (ensemble EMD, EEMD)的方法,利用噪声辅助分析 方法抑制模态混叠现象,改善 EMD 的信号分解能力. 针对于轴承振动信号包含信息丰富、成分复杂的特 点,利用 EEMD 自适应地将轴承振动信号分解为一系 列本征模态函数(intrinsic mode functions, IMFs),减 少不同故障信号特征信息之间的干涉或耦合,有利于 突出轴承运行状态更深层次的信息<sup>[11]</sup>.

排列熵(permutation entropy, PE)作为一种衡量一维时间序列复杂度的平均熵参数,不仅能够度量一个非线性信号的不确定性,而且具有计算简单, 抗噪声能力强等优点<sup>[12]</sup>,选择排列熵对 IMFs 中包含的故障特征进行提取, EEMD 分解后得到的每个 IMF 分量包含了振动信号在不同时间尺度下的特征.通过计算各个 IMF 分量的排列熵值并组成特征 向量,能够有效突出在多尺度下的轴承故障特征.

在对不同故障情况下的特征向量进行有效提取 后,需要利用高性能的多分类器对故障模式进行识 别.相关向量机(relevance vector machine, RVM)和 支持向量机(support vector machines, SVM)是机械 故障诊断中常用的分类器. RVM 是由 Micnael E. Tipping<sup>[13]</sup>提出的一种与 SVM 类似的稀疏概率模 型,是一种基于贝叶斯网络的新的监督学习方法.

多分类相关向量机(multiclass relevance vector machine, M-RVM)<sup>[14]</sup>是 RVM 算法针对多分类应用 场合下的理论扩展,该方法继承了 RVM 算法模型 稀疏度高、小样本学习能力强及分类速度快的优点, 通过不同类别的概率输出直接实现多分类,有效降 低了基于 RVM 分类器进行多分类时结构的复杂性.

本文针对目前基于模式识别的轴承故障诊断方 法存在的问题,提出了一种基于 EEMD-排列熵特征 提取与 M-RVM 分类器相结合的轴承故障诊断方法. 首先利用 EEMD 将滚动轴承振动信号自适应地分 解为一系列 IMFs,采用排列熵提取各个 IMF 的特征 值,组成特征向量.为了突出主要的故障特征,通过 计算包含主要故障信息的前几个 IMFs 分量的排列 熵值来组成特征向量.利用不同故障下训练样本的 特征向量对 M-RVM 分类器进行建模,最后以概率 输出的形式实现对故障轴承振动信号的多故障识 别,实现滚动轴承的故障诊断.

## 1 轴承振动信号特征提取

### 1.1 基于 EEMD 的轴承振动信号分解

振动是滚动轴承运行过程中的重要特征,振动 信号能够体现滚动轴承运行过程中的状态信息.通 过对滚动轴承振动信号进行分解,提取轴承运行状 态中的故障特征,为轴承故障诊断提供信息.由于 故障轴承的振动信号在某一频率上包含故障信息, 采用时-频分析法对轴承振动信号进行分解.

传统的 EMD 分解存在着模态混叠问题,会导致 分解出的本征模态函数的物理意义不明确,影响后续 的特征提取效果.针对以上问题,文献[10]提出了 EEMD 算法,该方法通过在原始信号上叠加一定幅值 的高斯白噪声,利用其统计特性解决 EMD 算法的模 态混叠问题,使得 EEMD 分解得到的本征模态函数更 加稳定.因此,本文采用 EEMD 对轴承振动信号进行 自适应分解以突出故障在各个频带上的特征.

基于 EEMD 算法的滚动轴承振动信号分解过 程的具体步骤如下:

1) 指定 EEMD 算法的总体平均次数 M 以及高 斯白噪声的幅值 a.

2) 在原始的振动信号 x(t) 上叠加幅值为 a 的随 机高斯分布的白噪声  $n_i(t)$ ,获得一个新的信号,即

 $x_i(t) = x(t) + n_i(t).$  (1) 其中  $i = 1, 2, \dots, M, n_i(t)$  为第 i 次加入的白噪声序 列,  $x_i(t)$  为第 i 次叠加白噪声后得到的新信号.

3) 对由步骤 2 获得的新信号  $x_i(t)$  进行 EMD 分 解,得到一组本征模态函数 IMFs 以及一个残余分量,即

$$x_i(t) = \sum_{s=1}^{S} C_{i,s}(t) + r_i(t) .$$
 (2)

其中*S*为分解出的IMF分量的总数,  $r_i(t)$ 为残余分量,  $(C_{i,1}(t), C_{i,2}(t), \dots, C_{i,s}(t))$ 为包含着从高频 到低频的的本征模态函数.

4)根据步骤1中设置的总体平均次数M,重复 第2、3步M次,获得M组本征模态函数.

5)将步骤 4 中获得的 M 组本征模态函数进行 总体平均,即

$$C_{s}(t) = \frac{1}{M} \sum_{i=1}^{M} \text{ IMF}_{i,s}(t) .$$
 (3)

其中 *C<sub>s</sub>*(*t*) 为 EEMD 分解后的第*S* 个 IMF 向量, *i* = 1,2,…,*M* 并且 *s* = 1,2,…,*S*.

EEMD 利用大量不同的白噪声信号的均值将趋于 0 的特性,通过多次重复步骤 2、3,将叠加的白噪 声对信号的不利影响从平均后的 IMF 分量中剔除, 保留了目标信号的分解结果,提高了信噪比. 与单 次 EMD 分解相比,显著减少了模态混叠的发生,能 更准确地揭示信号的真实物理意义. 基于以上考虑,本文选择 EEMD 进行滚动轴承振动信号的分解. 通过对以上 EEMD 算法的实现步骤可知,总体平均次数 *M* 与白噪声幅值 *a* 是影响分解结果的两个重要参数. 文献[4]表明,白噪声幅值 *a* 取值约为0.2~0.4 倍的原始数据标准差,总体平均次数 *M* = 100~500 时,EEMD 具有较好的分解结果.

#### 1.2 基于排列熵的轴承振动信号特征提取

通过上一节介绍的 EEMD 可以对轴承振动信号 进行自适应分解,分解得到的本征模态函数与残余分 量中包含不同故障类型的频率特征.为了突出不同故 障类型的特征,本节采用排列熵对轴承振动信号进行 特征提取.排列熵是由 Christoph Band<sup>[16]</sup>提出的是一 种时间序列复杂性衡量方法.对于长度为 *N* 的时间 序列 { $x(k), k = 1, 2, \dots, N$ },按照相空间延迟坐标 法,对任一元素 x(i)其进行重构,对每个采样点取其 连续的 *m* 个样本点,得到点 x(i) 的 *m* 维重构向量

$$X(i) = \{x(i), x(i+\tau), \cdots, x(i+(m-1)\tau)\} \frac{1}{n}.$$
 (4)

其中 *m* ≥ 2 为嵌入维数, *τ* 为延迟时间, *i* = 1,2,…, *N*. 将 *X*(*i*) 中的 *m* 个重构分量按照升序排列,即

 $\{ x(i + (j_1 - 1)\tau) \le x(i + (j_2 - 1)\tau) \le \\ \dots \le x(i + (j_m - 1)\tau) \}.$  (5)

如果 X(i) 存在相同的元素,即  $x(i + (j_p - 1)\tau) = x(i + (j_q - 1)\tau)$ 时,那么按照 j 的大小来排序,也就是  $p \leq q$ 时,排列方式为  $x(i + (j_p - 1)\tau) \leq x(i + (j_q - 1)\tau)$ .

因此,任意向量 X(i) 都能得到一组符号序列

$$S(l) = (j_1, j_2, \cdots, j_m).$$
 (6)

其中: $j = 1, 2, \dots, k$ , 与 m 维相空间映射的 m 个不同 的符号序列具有 m! 种不同的排列方式, 而 S(l) = $(j_1, j_2, \dots, j_m)$  是其中的一种符号序列, 设每种符号 序列出现的概率分别为  $P_1, P_2, \dots, P_k$ , 时间序列  $\{x(k), k = 1, 2, \dots, N\}$  的排列熵定义为

$$H_p(m) = -\sum_{j}^{k} P_j \ln P_j.$$
(7)

很明显,  $0 \le H_p(m) \le \ln(m!)$ , 其中上限  $\ln(m!)$  为  $P_i = 1/m!$  时对应的  $H_p(m)$  值.

通过值  $H_p$  的大小就能够衡量出一维时间序列 { $x(k), k = 1, 2, \dots, N$ } 的复杂程度.  $H_p$  值越小,则该 时间序列越规则,信号复杂度越小;相反的,  $H_p$  值越 大,则该时间序列无序程度越高,信号复杂度越大.

由排列熵的计算过程看出,排列熵的值与嵌入 维数 m,延迟时间 τ 以及数据长度 N 有关. 文献 [18]表明,嵌入维数 m = 4~8 时,4 种工作状态的区 分度良好,实际上当嵌入维数 m < 4 时,排列熵无法 准确地检测出振动信号中的动态变化,而当 m > 8 时,不仅会使排列熵的计算量增大,并且会使排列熵 的的变化范围变窄而难于准确衡量信号复杂度.延 迟时间 τ 的选取对排列熵的影响不大.但是,当τ > 5 时,排列熵不能准确地检测振动信号中的微小变 化.数据长度 N 也是影响排列熵计算结果的重要参 数, N 过大时会将信号平滑,不能准确的衡量信号的 动态变化.N 取过小的值,计算结果将失去统计意义.

2 基于多分类相关向量机的故障识别

M-RVM 是在 RVM 的基础上提出的一种基于贝 叶斯框架的统计学习方法<sup>[14]</sup>,它采用分层贝叶斯模 型结构,通过引入多项概率似然函数来实现多分类 以及输出类别成员概率.通过采集不同故障条件下 的振动信号作为训练样本,结合上一节介绍的特征 提取方法对 M-RVM 故障识别模型进行训练.基于 M-RVM 的故障识别模型的建模过程如下.

设训练集  $X = \{x_i, t_i\}_{i=1}^{N}, x \in R^D$ ,  $t \in \{1, 2, \cdots, C\}$  为类别标签, 当选定核函数时, 可以得到训练核 函数集  $K = (k_1, \cdots, k_N)^T$ ,  $K \in R^{N \times N}$ , 其中  $k_n \frac{x - \mu}{\sigma}$ 代 表训练集的第 n 个样本数据与其他样本的相似度. 通过引入辅助回归目标  $Y \in R^{L \times N}$  与权重参数  $W \in R^{N \times L}$ , 得到标准噪声回归模型为

 $y_{nl} | w_l, k_n \sim N_{y_{nl}}(k_n w_l, 1).$  (8) 式中  $y_{nl}$  为 Y 的第 n 行 l 列的元素,  $w_l$  为 W 的第 l 列,  $N_*(m,v)$  表示 x 服从均值为 m, 方差为 v 的正态分布.

回归目标可以通过式  $t_n = i, y_{ni} > y_{nj}, \forall j \neq i$ 将回归目标转化为类别标签.

为了保证模型的稀疏性,为权重向量引入均值 为0,方差为 $\alpha_{nl}^{-1}$ 的标准正态先验分布.由先验参数  $\alpha_{nc}$ 组成的矩阵记为 $A \in R^{N \times L}$ ,服从超参数为 $\alpha_{nl}$ 的 Gamma 分布.由此可见 M-RVM 采用的是分层贝叶 斯模型结构,模型结构示意图如图 1 所示.



图 1 M-RVM 模型结构示意

Fig.1 Structure diagram of M-RVM 由此,可以推导出后验概率

$$P(\boldsymbol{W}|\boldsymbol{Y}) \propto P(\boldsymbol{Y}|\boldsymbol{W})P(\boldsymbol{W}|\boldsymbol{A}) \propto$$

$$\prod_{c=1}^{c=1} N((\mathbf{K}\mathbf{K}^{T} + \mathbf{A}_{c})^{-1}\mathbf{K}\mathbf{y}_{c}^{T}, (\mathbf{K}\mathbf{K}^{T} + \mathbf{A}_{c})^{-1}).$$
(9)

其中 $A_c$ 为由A的c列导出的对角阵.

## 由最大后验概率估计可得

 $\hat{W} = \operatorname{argmax}_{W} P(W|Y, A, K).$  (10) 因此,当给定类别时,基于最大后验估计的权重 更新方式为

$$\hat{\boldsymbol{w}}_{c} = (\boldsymbol{K}\boldsymbol{K}^{T} + \boldsymbol{A}_{c})^{-1}\boldsymbol{K}\boldsymbol{y}_{c}^{T}.$$
 (11)

最后,权重向量先验参数的后验概率分布为

$$P(\boldsymbol{A} \mid \boldsymbol{W})) \propto P(\mid \boldsymbol{W} \mid \boldsymbol{A}) P(\boldsymbol{A} \mid \boldsymbol{\tau}, \boldsymbol{v}) \propto$$
$$\prod_{c=1}^{C} \prod_{n=1}^{N} G(\boldsymbol{\tau} + \frac{1}{2}, \frac{w_{nc}^{2} + 2\boldsymbol{v}}{2}).$$
(12)

利用式(12)就可以计算出测试信号属于不同 类型的概率,测试信号对应的概率最高的一类,即为 测试信号的归属.

3 提出的故障诊断方法流程

本文通过集合经验模态分解法对非线性、非平 稳信号的自适应能力解决小波分析、短时傅里叶变 换等传统时-频分析方法适应性较差的问题.在对 经 EEMD 分解得到的本征模态函数包含故障信息 进行有效分解的基础上,采用排列熵提取轴承故障 状态下的故障特征向量.在对故障特征有效提取的 基础上,利用 M-RVM 分类器的良好特性实现对故 障的识别.在此基础上,设计了基于 EEMD-排列熵 特征提取与 M-RVM 分类器相结合的滚动轴承故障 诊断方法流程如图 2 所示.



## 图 2 基于 EEMD-排列熵与 M-RVM 的滚动轴承故障诊断流程

Fig.2 Flow of rolling bearing fault diagnosis based on EEMD-PE coupled with M-RVM

可以看出提出的轴承故障诊断方法存包括两个 步骤:训练过程和测试过程.具体过程如下:1)获取 不同故障状态下原始轴承振动信号分割为互不重叠 的子样本,组成训练样本集与测试样本集.2)对训 练样本集中各故障模式的信号进行特征提取.利用 EEMD 分解故障信号,获得若干个本征模态函数,选 择前 p 个包含大量故障信息的本征模态函数作为特征提取的对象. 3) 计算每个训练样本中选取的各本征模态函数的排列熵,并组成 p 维特征值向量,完成训练样本特征提取. 4) 选取适当的核函数以及核参数,利用训练样本的特征向量对 M-RVM 分类器进行训练. 5) 在测试过程中,将测试样本经 EEMD-排列熵特征后的特征向量作为 M-RVM 分类模型的输入,利用输出各类别的概率来确定滚动轴承的故障模式,实现故障识别.

# 4 实验结果

## 4.1 实验数据

为了说明本文提出的基于 EEMD-排列熵特征 提取与 M-RVM 分类器相结合的滚动轴承故障诊断 方法的性能,本文采用美国西储大学轴承数据库 (Case Western Reserve University, CWRU)<sup>[17]</sup>发布的 公共数据集. 被测试轴承通过电火花加工技术设置 单点故障,数据集中包括四种滚动轴承运行状态下 获得的振动信号,分别为正常(normal, N),滚珠故 障(ball fault, BF),内圈故障(inner race fault, IRF) 以及外圈故障(outer race fault, ORF),4种工作状态 下的振动信号样本,时域波形如图 3 所示.



## 图 3 负载为 0 kW 时不同轴承状态下采集的振动信号

Fig.3 Vibration signals under different modes with 0 kW 每种状态下采集到的信号又按照故障直径与负载的大小进行分类.本文选取 CWRU 数据集中的各个样本进行轴承故障诊断实验,采样频率为 12 kHz. 实验包含的所有样本如表 1 所示,其中"√"代表该样本被选取,"\*"代表着该样本未选取.按照负载的不同,可以将实验分为4组,每组实验所用数据按照故障类型及故障直径分类共有 12 种.由于实际状况下,轴承发生故障时故障程度不可知,因此本文

将故障直径不同,故障类型相同的数据归为一类,即 负载相同的 12 种数据按照故障类型的不同总共归 为 4 类.每种数据的前 120 000 个点,分割成 50 个 长度为2 400的子样本,因此每组实验中共包含了 600 个样本,其中正常状态下的样本数为 50 个,随 机选取 20 组作为训练数据.外圈故障的样本数为 150 个,随机选取 60 组作为训练数据.其余两种状 态的样本数都是 200 个,分别随机选取 80 组作为训 练数据,其余的所有样本作为测试样本.

表1 不同负载下的实验样本

Tab.1 Experimental samples under different loads

运动状态	故障直径	样本				
	∕em	0 kW	0.746 kW	1.491 kW	2.237 kW	
N		$\checkmark$		$\checkmark$		
	0.018	$\checkmark$		$\checkmark$	$\checkmark$	
DE	0.036	$\checkmark$		$\checkmark$	$\checkmark$	
BF	0.053	$\checkmark$				
	0.071	$\checkmark$	$\checkmark$	$\checkmark$	$\checkmark$	
	0.018	$\checkmark$		$\checkmark$	$\checkmark$	
IDE	0.036	$\checkmark$		$\checkmark$	$\checkmark$	
IKF	0.053	$\checkmark$			$\checkmark$	
	0.071	$\checkmark$	$\checkmark$	$\checkmark$	$\checkmark$	
	0.018	$\checkmark$		$\checkmark$	$\checkmark$	
ODE	0.036	$\checkmark$		$\checkmark$	$\checkmark$	
ORF	0.053	$\checkmark$		$\checkmark$	$\checkmark$	
	0.071	*	*	*	*	

#### 4.2 故障特征提取实验

随机选取负载为0 kW,故障直径为0.018 cm 时 4 个状态下的一个样本,利用 EEMD 对其进行分解, 得到一组 IMF 分量,本文选取的白噪声幅值为原始 信号标准差的0.2 倍,总体平均次数为100 次. 然后 选取排列熵的参数为 m = 6,τ = 2, 计算各个状态下 分解得到的前 6 个 IMF 分量的排列熵. 如图 4 所 示,可以看出,前 4 个本征模态分量几乎包含了振动 信号的最主要的信息,并且不同状态计算出的本征 模态分量排列熵值差异较大,对故障分类的贡献也 较大. 这是由于包含轴承故障特征的频率主要集中 在中高频段,只取前 4 个 IMF 分量来提取特征值.

各类样本分解后的前 4 个 IMF 分量如图 5~8 所示.其中,图 5 是正常状态下采集的振动信号的 分解结果,图 6 是滚珠故障状态下采集的振动信号 的分解结果,图 7 是内圈状态下采集的振动信号的 分解结果,图 8 是外圈故障状态下采集的振动信号的 分解结果. 从图 5~8 可以看出,不同状态下采集 的振动信号分解出的各个 IMF 分量有着明显的差 异,相对于原始信号,能够展示更多的特征信息.



图 4 不同故障状态下的本征模态排列熵值













图 8 外圈故障样本的 EEMD 分解结果

Fig.8 EEMD decomposition results of outer race fault samples 接下来计算 EEMD 分解后的前 4 个 IMF 分量的排 列熵,组成 4 维的特征向量  $v = [d_1, d_2, d_3, d_4]$  用来描述 轴承不同状态下的特征. 负载为 0 kW 时,不同轴承状态 以及故障直径的样本数据的特征向量见表 2. 提取的 4 个特征在数值上具有一定的可分性,说明本文提出的基于 EEMD-PE 的故障特征提取方法具有明显的可分性.

#### 表 2 轴承不同状态以及不同故障直径的样本特征向量

Tab.2 Feature vectors of rolling bearing under different fault modes and severity

运行状态	故障直径	特征向量					
	/cm	$d_1$	$d_2$	$d_3$	$d_4$		
Ν		4.796	3.320	2.403	1.572		
	0.018	4.867	3.902	2.551	1.937		
DE	0.036	5.092	3.601	2.417	1.850		
Dľ	0.053	5.249	4.048	2.667	2.059		
	0.071	4.923	4.121	2.895	2.004		
	0.018	5.564	3.989	2.758	2.132		
IDE	0.036	5.424	4.391	2.859	2.003		
IKF	0.053	4.815	4.085	2.516	1.963		
	0.071	4.980	3.716	2.491	1.962		
	0.018	5.240	4.604	2.740	2.129		
ORF	0.036	5.479	4.238	2.738	1.928		
	0.053	5.408	4.371	2.639	2.028		

## 4.3 故障识别实验

决定 M-RVM 分类准确性的关键因素是在训练 阶段选取合适的核函数以及核参数. 鉴于径向基核 函数(radial basis function, RBF)高维/低维、线性/非 线性信号的优良特性,本文实验中选择 RBF 核函数 为 M-RVM 分类器的核函数,即

$$K(x,y) = \exp(-\frac{\|x - y\|^2}{2\sigma^2}).$$
 (13)

其中核参数 σ 的选择利用交叉验证法,选取诊断准 确度最高的时候对应的取值.

M-RVM 通过输出不同故障类型可能发生故障的 概率进行故障诊断,其中对应着概率最大的故障类型 被确定为最终诊断结果.表3为负载为0kW时不同样本的 M-RVM 故障识别结果,其中 Class1, Class2, Class3和 Class4分别代表属于正常状态,滚珠故障,内圈故障以及外圈故障,P1~P4表示对应着不同故障类型 Class1~Class4的 M-RVM 模型的输出概率.实验结果说明,M-RVM 能够有效地对不同状态下的故障特征进行分类,准确率达到90.0%以上,具有较高的置信度.

应用 EEMD 分解后的前 4 个 IMF 分量的排列 熵值组成特征向量,对数据集进行训练与测试,每组 实验重复 10 次,取其诊断结果的平均值作为故障诊 断结果并记录.故障分类结果见表 4.可以看出,利 用本文提出的故障诊断方法具有较高的故障识别 率,适用于不同负载情况下的滚动轴承故障诊断.

为了进一步的验证所提方法的故障诊断效果,将本 文的故障诊断方法与现有方法的实验结果进行对比,结 果如表5所示.实验结果表明,相比于现有的轴承故障诊 断方法,本文提出的故障诊断方法具有更高的故障识别率.

#### 表 3 负载为 0 kW 时不同样本的 M-RVM 故障识别结果

Tab. 3 Fault identification results based on M-RVM under different fault modes with 0 kW load

运动状态	故障直径	所属故障类别概率/%				识别
	( cm)	P1	P2	Р3	P4	结果
Ν		95.79	11.50	1.92	1.14	Class1
	0.018	1.09	96.62	1.20	1.09	Class2
DE	0.036	0.00	99.99	0.01	0.00	Class2
Dr	0.053	2.91	90.84	3.33	2.91	Class2
	0.071	0.02	99.84	0.13	0.01	Class2
	0.018	0.00	0.00	100.00	0.00	Class3
IDE	0.036	0.00	0.00	99.99	0.01	Class3
INF	0.053	0.00	0.00	100.00	0.00	Class3
	0.071	0.00	0.00	100.00	0.00	Class3
	0.018	3.80	3.83	10.40	81.98	Class4
ORF	0.036	0.00	0.01	0.03	99.96	Class4
	0.053	0.0018	0.0019	0.0116	0.9847	Class4

#### 表 4 不同负载情况下轴承故障分类准确率

Tab.4 Fault identification accuracy of rolling bearing under different loads

负载/kW	状态类型	训练样本数	测试样本数	平均识别率
0	N B IR OR	20 80 80 60	30 120 120 90	0.941 7
1	N B IR OR	20 80 80 60	30 120 120 90	0.970 8
2	N B IR OR	20 80 80 60	30 120 120 90	0.995 8
3	N B IR OR	20 80 80 60	30 120 120 90	0.925 0

#### 表 5 故障诊断方法比较

Tab.5 Experiment comparison of different fault diagnosis methods of rolling bearing

		υ	0	
	方法	故障类型	故障诊断方法	平均识别率
	文献[19]	N,B,IR,OR	多尺度分析+支持向量机	0.981 2
-	文献[20]	N,B,IR,OR	EMD+时频域分析+小波改进支持向量机	0.975 0
j	文献[21]	B, IR, OR	不同属性的滤波器+支持向量机	0.975 0
j	と献[11]	B, IR, OR	EEMD+样本熵+支持向量机	0.966 7
	本文	N, B, IR, OR	EEMD+排列熵+M-RVM	0.995 8

## 5 结 论

提出了一种基于 EEMD-排列熵特征提取与 M-RVM分类器相结合的滚动轴承故障诊断新方法, 将 EEMD 与排列熵算法进行特征提取,并与 M-RVM 方法融合在一起进行故障诊断.首先,采用 EEMD 分解将轴承振动信号自适应地分解为一系列包含故 障特征的 IMF 分量,再计算 IMF 分量的排列熵作为 特征向量,提高特征向量的可分性.随后,采用 M-RVM 分类器作为故障识别方法对滚动轴承进行故 障识别,利用概率输出实现故障识别.实验结果表 明,所提出的方法能够在不同负载下有效地对轴承 故障类型进行识别,与现有基于模式识别的故障诊 断方法相比,具有更高的故障识别准确率.

# 参考文献

- FENG Z, LIANG M, CHU F. Recent advances in time-frequency analysis methods for machinery fault diagnosis: a review with application examples [ J]. Mechanical Systems & Signal Processing, 2013, 38(1):165-205.
- [2] 徐金梧,徐科.小波变换在滚动轴承故障诊断中的应用[J].机 械工程学报,1997(4):50-55.
   XU Jinwu, XU Ke.Appilication of wavelet transform in failure diag-

nosis of rolling bearings [J]. Journal of Mechanical Engineering, 1997(4):50-55.

- [3] ZHANG L, XIONG G, LIU H, et al. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference [J]. Expert Systems with Applications, 2010, 37(8):6077-6085.
- [4] 彭畅,柏林,谢小亮.基于 EEMD、度量因子和快速峭度图的滚动轴承故障诊断方法[J].振动与冲击,2012(20):143-146.
  PENG Chang, BO Lin, XIE Xiaoliang. Fault diagnosis method of rolling element bearing based on EEMD, measure-factor and fast kurtogram[J]. Journal of Vibration and Shock, 2012(20):143-146.
- [5] 李舜酩, 郭海东, 李殿荣. 振动信号处理方法综述[J]. 仪器仪 表学报, 2013, 34(8):1907-1915.
   LI Shunming, GUO Haidong, LI Dianrong. Review of vibration sig-

nal processing methods [ J ]. Chinese Journal of Scientific Instrument,2013,34(8):1907-1915.

- [6] HUANG N E, SHEN Z, LONG S R, el al. The empirical mode decomposition method and the Hilbert spectrum for non-stationary time series analysis [J]. Proceedings of the Royal Society of London A, 1998, 454(1971): 903-995.
- [7] XU H B, CHEN G H. An intelligent fault identification method of rolling bearings based on LSSVM optimized by improved PSO[J].
   Mech Syst Signal Process, 2013, 35(1/2): 167-175.
- [8] 陈寅生,姜守达,刘晓东,等.基于 EEMD 样本熵和 SRC 的自确认气体传感器故障诊断方法[J].系统工程与电子技术, 2016,38(5).

CHEN Yinsheng, JIANG Shouda, LIU Xiaodong, et al. Self-validating gas sensor fault diagnosis method based on EEMD sample entropy and SRC[J]. Systems Engineering and Electronics, 2016, 38(5).

[9] WANG H, CHEN J, DONG G. Feature extraction of rolling bear-

ing's early weak fault based on EEMD and tunable Q-factor wavelet transform[J]. Mechanical Systems & Signal Processing, 2014, 48 (1/2):103-119.

- [10] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1):1-41.
- [11]赵志宏,杨绍普.一种基于样本熵的轴承故障诊断方法[J].振动与冲击,2012,31(6):136-140.
  ZHAO Zhihong,YANG Shaopu.Sample entropy based roller fault diagnosis method[J]. Journal of Vibration and Shock,2012,31(6): 136-140.
- [12] 程军圣,马兴伟,杨宇.基于排列熵和 VPMCD 的滚动轴承故障 诊断方法[J].振动与冲击,2014,33(11):119-123.
  CHENG Junsheng, MA Xingwei, YANG Yu. Rolling fault diagnosis method based on permutation entropy and VPMCD[J]. Journal of Vibration and Shock,2014,33(11):119-123.
- [13] TIPPING M E. The relevance vector machine [J]. Advances in Neural Information Processing Systems, 1999, 12(3):652-658.
- [14] PSORAKIS I, DAMOULAS T, GIROLAMI M A. Multiclass relevance vector machines: sparsity and accuracy [J]. IEEE Transactions on Neural Networks, 2010, 21(10):1588-1598.
- [15] ZHANG X, ZHOU J. Multi-fault diagnosis for rolling element bearings based on ensemble empirical mode decomposition and optimized support vector machines [J]. Mechanical Systems & Signal Processing, 2013, 41(1/2):127-140.
- [16] CHRISTOPH B, BERND P. Permutation entropy: a natural complexity measure for time series [J]. Physical Review Letters, 2002, 88(17):174102.
- [17] Bearing Data Center. Case Western Reserve University [EB/OL]. (2000-01-31) [/2016-03-01]. http://csegroups.case.edu/ bearingdatacenter/home.
- [18] 刘永斌. 基于非线性信号分析的滚动轴承状态监测诊断研究 [D]. 合肥:中国科学技术大学,2011.

LIU Yongbin.Nonlinear signal analysis for rolling bearing condition monitoring and fault diagnosis [D]. Hefei: Universitity of Science and Technology of China, 2011.

- [19] WU S D, WU C W, WU T Y, et al. Multi-scale analysis based ball bearing defect diagnostics using mahalanobis distance and support vector machine[J], Entropy, 2013, 15(2): 416-433.
- [20] LIU Z, CAO H, CHEN X, et al. Multi-fault classification based on wavelet SVM with PSO algorithm to analyze vibration signals from rolling element bearings [J]. Neurocomputing, 2013, 99(1):399-410.
- [21] VAKHARIA V, GUPTA V K, KANKAR P K. A multiscale permutation entropy based approach to select wavelet for fault diagnosis of ball bearings [J]. Journal of Vibration & Control, 2014, 21(16).
- [22]于天剑,陈特放,陈雅婷,等.HMM 在电机轴承上的故障诊断
  [J].哈尔滨工业大学学报,2016,48(2):184-188.
  YU Tianjian, CHEN Tefang, CHEN Yating, et al. HMM on the motor bearing fault diagnosis [J]. Journal of Harbin Institute of Technology University, 2016, 48(2):184-188.
- [23]李常有,徐敏强,高晶波,等. 基于独立分量分析的滚动轴承故 障诊断[J]. 哈尔滨工业大学学报,2008,40(9):1363-1365.
  LI Changyou, XU Minqiang, GAO Jingbo, et al. Rolling bearing fault identification based on ICA [J]. Journal of Harbin Institute of Technology University, 2008, 40(9):1363-1365.

(编辑 魏希柱)