

基于变分模态分解和高阶统计量的 梯级故障诊断研究

丁国荣, 王文波

(武汉科技大学 理学院, 武汉 430065)

摘要: 自动扶梯是地铁车站内必不可少的大型公共交通设备, 一旦发生故障, 小则影响运营, 大则引发安全事故; 梯级作为自动扶梯的重要结构部位, 其固定螺栓松动必然会导致自动扶梯运行异常; 针对梯级振动信号故障特征难以提取的问题, 提出了变分模态分解 (VMD) 和高阶统计量 (HOS) 联合来对自动扶梯故障特征提取; 该方法首先对原始振动信号进行 VMD 分解, 得到 K 个固有模态分量 (IMF); 然后对主 IMF 分量进行奇异值分解 (SVD) 降噪, 对去噪后的主 IMF 分量进行重构得到新的信号; 最后通过高阶统计量对新的信号故障特征提取, 并利用随机森林分类算法对三类不同的振动信号样本进行分类识别, 确定梯级振动故障类型; 实验结果表明, 该方法可以有效地提取故障特征, 实现故障诊断与分类。

关键词: VMD 分解; 高阶统计量; 故障诊断

Research on Cascade Fault Diagnosis Based on Variational Mode Decomposition and Higher Order Statistics

Ding Guorong, Wang Wenbo*

(College of Science, Wuhan University of Science and Technology, Wuhan 430065, China)

Abstract: The escalator is an essential large-scale public transportation equipment in a subway station. Once a failure occurs, the operation will be affected if the escalator is small, and it will cause a safety accident. As an important structural part of the escalator, the loosening of its fixing bolts will inevitably lead to abnormal operation of the escalator. Aiming at the problem that it is difficult to extract the fault characteristics of cascade vibration signals, this paper proposes a method of combining variational modal decomposition (VMD) and higher order statistics (HOS) to extract escalator fault characteristics. This method first performs VMD decomposition on the original vibration signal to obtain K intrinsic modal components (IMF); then performs singular value decomposition (SVD) noise reduction on the main IMF component, and reconstructs the denoised main IMF component to obtain a new. Finally, the new signal fault characteristics are extracted through high-order statistics, and the random forest classification algorithm is used to classify and identify three different vibration signal samples to determine the type of cascade vibration fault. Experimental results show that this method can effectively extract fault features and realize fault diagnosis and classification.

Keywords: VMD; higher order statistics; fault diagnosis

0 引言

自动扶梯是地铁车站内必不可少的大型公共交通设备, 已成为了人们生活中广泛使用的特种设备之一。自动扶梯设备常年处于工作状态, 当维保人员进行日常巡查时, 只能知道当前自动扶梯的状态, 对于此前的情况却无法得知, 这对于自动扶梯的安全性有很大隐患, 一旦发生故障, 小则影响运营, 大则引发安全事故。自动扶梯故障主要有轴承故障、主机故障、梯级故障、扶手带故障以及链条故障等。近年来, 随着数据挖掘技术的快速发展, 可以在特定位置通过传感器实时采集海量的数据, 基于海量的数据提取故障类型特征, 通过提取的故障类型特征进行故障诊断以及分类。

梯级作为自动扶梯的关键部位, 其固定螺栓发生松动必然会导致自动扶梯运行故障。当梯级固定螺栓发生松动时, 其振动信号会表现出明显的非平稳性。对于非平稳振动信号, 需要采用合适的时频分析方法来提取故障特征分量^[1-2]。加窗傅里叶变换 (short time fourier transform, STFT) 和小波变换 (wavelet transform, WT) 是比较常见的时频分析方法, 邢蓉等人采用 SFFT 对滚动轴承信号进行频谱分析, 通过多尺度卷积神经网络中分析可以有效提升故障的诊断精度^[3]。但是在实际应用的其他方面, 由于 STFT 和 WT 的窗函数选取对分析结果影响较大, 在整个过程中都不能替换, 所以不具备自适应性在应用中有所限制^[4]。Huang 等^[5-6]提出的经验模态分解 (empirical mode decomposition, EMD) 是一种自适应分解的方法, 兰夏燕

收稿日期: 2020-07-27; 修回日期: 2020-08-27。

作者简介: 丁国荣 (1997-), 男, 甘肃天水人, 硕士研究生, 主要从事信号处理与模式识别方向的研究。

通讯作者: 王文波 (1985-), 男, 湖北武汉人, 博士, 教授, 主要从事神经网络与深度学习方向的研究。

引用格式: 丁国荣, 王文波. 基于变分模态分解和高阶统计量的梯级故障诊断研究[J]. 计算机测量与控制, 2021, 29(3): 42-47.

等人基于 EMD 分解对电梯导靴振动信号故障进行特征提取, 首先对突变信号进行 EMD 分解得到若干固有模态函数 (intrinsic mode function, IMF), 然后计算 IMF 分量的 Hilbert 边际谱, 最后获得电梯导靴故障的特征频率信息^[7]。但是该方法存在端点效应以及模态混叠等问题。针对 EMD 的模态混叠现象, Wu 等^[8]提出的集合经验模态分解 (ensemble empirical mode decomposition, EEMD) 可在一定程度上改善模态混叠现象, 高立龙等人使用改进的 EEMD 方法对液压系统突然换向引起的冲击振动信号进行分析, 通过选取代表信号特征的 IMF 分量, 可以为智能诊断提供依据^[9]。由于本身算法递归迭代的局限性, 仍然存在一定的分解误差。局部均值分解 (local mean decomposition, LMD) 是由 Jonathan S. Smith 等^[10]学者提出的一种新的自适应非平稳信号处理方法, 但是该方法存在由解调而引起的信号突变问题^[11]。

鉴于 EMD、EEMD 和 LMD 方法自身的局限性, 很多学者提出了针对性的优化和改进策略。变分模态分解 (variational mode decomposition, VMD) 是 Dragomiretskiy 等^[12]人提出的一种新的自适应信号分解方法, 该方法通过循环迭代求解约束变分方程的最优解来确定 IMF 分量, 实现信号各个频率分量的分离。与上述几种方法相比, VMD 不仅具有扎实的理论依据, 而且对于噪声也不敏感。

近年来, 在故障诊断领域, 白堂博等人基于 VMD 和奇异值分解 (singular value decomposition, SVD) 提取旋转机械故障的早期微弱信号, 该方法可以有效地提取故障信号的周期成分, 去除噪声干扰, 具有很好的微弱特征提取能力, 可大幅度提高故障诊断的准确性^[13]。李余兴等人提出一种基于 VMD 分解、中心频率、复杂度特征和支持向量机 (support vector machine, SVM) 的舰船辐射噪声特征提取及分类识别方法, 通过提取能量最大的 IMF 中心频率和排列熵作为特征参数, 并利用 SVM 对四类舰船信号样本进行分类识别。与已有方法对比, 提高了识别率^[14]。罗小燕等人提出一种基于 VMD 和 SVD 的联合降噪方法, 试验结果表明, 该方法能够去除磨机筒体信号中的噪声, 提高了信号后续分析处理的可靠性^[15]。李亚兰等人提出一种 VMD 和特征融合相结合的雷达辐射源信号识别方法, 对提取的 IMF 分量提取排列熵和样本熵特征进行特征融合构成 6 维特征向量, 最后用 SVM 对辐射源信号进行识别^[16]。张建财等人提出基于 VMD 和多尺度排列熵的滚动轴承故障特征提取方法, 并采用经粒子群算法优化的概率神经网络故障诊断模型进行故障类型识别^[17]。唐贵基等人通过分析 VMD 分解中的惩罚因子及分量个数的设置对 VMD 方法滤波特性的影响, 能够有效区分轴承早期故障信号中的微弱特征信息, 实现故障类型的准确判别^[18]。

近年来发展起来的高阶统计量 (higher order statistics, HOS) 的理论和方法, 为非高斯噪声的处理提供了强有力的手段, 已经成为现代信号处理的核心内容之一。祁广云等人针对剩余电流保护技术中生物触电支路的触电电流具有复杂性及多样性的问题, 应用 HOS 与 STFT 相结合的方法,

分析了剩余电流及触电电流特征量的变化规律^[19]。冯正权等人探讨了高阶统计量在生物医学信号处理中的应用, 得出高阶统计量不仅包含原始信号的幅度信息, 还包括其相位信息, 能解决非高斯、非线性问题, 在理论上可以完全抑制高斯有色噪声的影响, 是一种分析具有非线性特征信号的理想工具^[20]。

鉴于 VMD 方法在诸多领域所呈现出的优异特性, 本文将其引入到自动扶梯故障诊断, 用于分解梯级固定螺栓的振动信号。结合高阶统计量 (三阶累积量) 提取振动信号的特征, 作为随机森林 (random forest, RF) 分类模型的输入特征参数, RF 的目标输出参数为固定螺栓的 3 种不同状态, 本文所提出的方法成功地将梯级固定螺栓正常、松动一圈和松动三圈的信号进行分类, 提取的三类信号的特征非常明显, 从而实现自动扶梯梯级故障诊断。

1 研究方法的基本原理

1.1 VMD 分解

VMD 算法是 Dragomiretskiy 等人在 2014 年提出的一种新的自适应信号分解方法, 主要目的是将信号 f 分解成 K 个 IMF 分量 $\mu_k(t)$, 每个 IMF 分量可以看作是存在不同中心频率的调幅-调频信号:

$$\mu_k(t) = A_k(t) \cos(\varphi_k(t)) \quad (1)$$

式 (1) 中, $A_k(t)$ 为瞬时幅值, $\varphi_k(t)$ 的一阶导数为瞬时频率。每个 IMF 分量集中分布在中心频率附近, 通过迭代求解变分模态方程的最优解来确定每个 IMF 分量的频率中心和带宽, 实现信号各个 IMF 分量的有效分离。VMD 分解构造受约束的变分模型为:

$$\min_{\{\mu_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t [(\delta_t + j/\pi t) * \mu_k(t)] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (2)$$

$$s. t. \sum_k \mu_k = f \quad (3)$$

式 (2)、(3) 中, $\{\mu_k\} = \{\mu_1, \mu_2, \dots, \mu_K\}$ 表示分解得到的 K 个 IMF 分量, $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_K\}$ 各分量的频率中心, K 表示 IMF 分量的数量, f 为原始输入信号。

为了求解该约束变分问题, 引入二次惩罚因子 α 和 Lagrange 算子 $\lambda(t)$ 以消除其约束条件, 进一步求出受约束的变分模型的最优解。构造的 Lagrange 方程为:

$$\begin{aligned} L(\{\mu_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t [(\delta_t + j/\pi t) * \mu_k(t)] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k \mu_k(t) \right\|_2^2 + \\ & [\lambda(t), f(t) - \sum_k \mu_k(t)] \end{aligned} \quad (4)$$

VMD 算法中采用乘子交替方向算法 (Alternate Direction Method of Multipliers, ADMM) 解决上式非约束变分问题, 再通过迭代循环求解 μ_k^{n+1} 、 ω_k^{n+1} 和 λ^n 来寻求扩展 Lagrange 表达式的“鞍点”, 由此来实现 VMD 分解^[16-17]。

VMD 的算法流程如下:

- 1) 初始化 $\{\hat{u}_k^1\}, \{\hat{\omega}_k^1\}, \hat{\lambda}^1$ 和 $n = 0$;
- 2) $n \leftarrow n + 1$, 并根据式 (4) 更新 u_k 和 ω_k ;
- 3) 更新 λ ;

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (5)$$

重复 (2) 和 (3)，直到满足迭代停止条件，即 $\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \epsilon$ ，结束循环，输出结果，得到 K 个模态分量及其中心频率。

1.2 奇异值分解的原理

在信号处理过程中，奇异值分解可用来对信号进行降噪滤波、特征提取和弱信号分离。在奇异值理论中，任何一个矩阵 $A \in R^{m \times n}$ ，必然存在正交矩阵 U, V 使得：

$$A_{m \times n} = U_{m \times m} S_{m \times n} V_{n \times n}^T \quad (6)$$

式 (6) 中， U 和 V 是 $m \times m$ 阶和 $n \times n$ 阶正交矩阵， $S = [diag[\sigma_1, \sigma_2, \dots, \sigma_q], 0]$ ，其对角元素为 A 的奇异值，并按降序排列^[18-19]。

一般测量的原始信号 $x(t)$ 通常由两部分组成：真实信号 $s(t)$ 和噪声信号 $n(t)$ ，并且真实信号和噪声信号互不相关。将原始信号构造成矩阵 M 后，再将矩阵 M 进行奇异值分解，其中较大的奇异值对应于真实信号，较小的奇异值对应于噪声信号的重构^[20]。

将噪声信号对应的奇异值置为 0 后，通过 SVD 逆重构信号，以获得降噪后的新信号。

1.3 高阶统计量

高阶统计量是随机过程的新的数字特征，通常指阶数大于二阶的统计量。从统计学的角度，对正态分布的随机变量可以用一阶、二阶统计量来表示其统计特征，对于不服从高斯分布的随机变量，一阶和二阶统计量无法完备表示包含的信息。由于高阶统计量不仅包含原始信号的幅度信息，还包含其相位信息，能解决非高斯、非线性问题^[21-23]。因此在实际生活中广泛应用。

给定一组 n 维随机变量 (x_1, x_2, \dots, x_n) ，其概率密度函数为 $f(x_1, x_2, \dots, x_n)$ ，则其第一联合特征函数为：

$$\Phi(\omega_1, \omega_2, \dots, \omega_n) = E \{ e^{j(\omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n)} \} \quad (7)$$

第二联合特征函数为第一联合特征函数的对数：

$$\Psi(\omega_1, \omega_2, \dots, \omega_n) = \ln(\Phi(\omega_1, \omega_2, \dots, \omega_n)) \quad (8)$$

如果随机变量相互独立，则第一联合特征函数为各变量第一特征函数之积，第二联合特征函数为各变量第二特征函数之和。

设 $\{x(n)\}$ 为零均值的 k 阶平稳随机过程，则该过程的 k 阶矩 $m_{kx}(\tau_1, \tau_2, \dots, \tau_{k-1})$ 定义为：

$$m_{kx}(\tau_1, \tau_2, \dots, \tau_{k-1}) = Mon(x(n), \dots, x(n + \tau_{k-1})) \quad (9)$$

K 阶累积量 $c_{kx}(\tau_1, \tau_2, \dots, \tau_{k-1})$ 定义为：

$$c_{kx}(\tau_1, \tau_2, \dots, \tau_{k-1}) = Cum(x(n), \dots, x(n + \tau_{k-1})) \quad (10)$$

式 (9)、(10) 中， $Mon(\cdot), Cum(\cdot)$ 为 k 元变量的矩和累积量。

对于绝对可和的高阶累积量 $c_{kx}(\tau_1, \tau_2, \dots, \tau_{k-1})$ ，即满足：

$$\sum_{\tau_1=-\infty}^{+\infty} \sum_{\tau_2=-\infty}^{+\infty} \dots \sum_{\tau_{k-1}=-\infty}^{+\infty} |c_{kx}(\tau_1, \tau_2, \dots, \tau_{k-1})| < \infty \quad (11)$$

则 k 阶累积谱为 k 阶累积量的 $(k-1)$ 维傅里叶变换：

$$s_{kx}(\omega_1, \dots, \omega_{k-1}) = \sum_{\tau_1=-\infty}^{+\infty} \sum_{\tau_2=-\infty}^{+\infty} \dots \sum_{\tau_{k-1}=-\infty}^{+\infty} c_{kx}(\tau_1, \dots, \tau_{k-1}) \exp\{-j \sum_{i=1}^{k-1} \omega_i \tau_i\} \quad (12)$$

高阶统计量不仅包含原始信号的幅度信息，还包含其相位信息，能解决非高斯、非线性问题^[24-26]。

1.4 随机森林

随机森林是一种组成式的有监督学习方法，在随机森林的算法中，同时生成多个预测模型，并将模型的结果汇总以提升分类准确率。

随机森林的算法涉及到两部分的随机抽样，分别是对样本单元抽样和对变量因子抽样，以此来生成大量决策树。对每一个样本单元来说，所有决策树依次对该样本单元进行分类，所有决策树预测类别中的众数即为随机森林所预测的这一样本单元类别。图 1 为随机森林分类流程图。

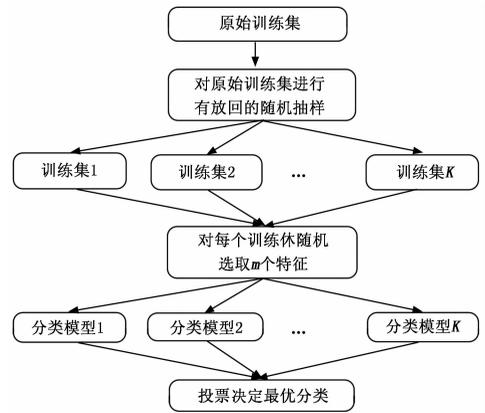


图 1 随机森林分类流程图

2 基于 VMD-HOS 的故障诊断模型

2.1 算法流程

基于 VMD 和 HOS 的梯级振动信号特征提取和分类识别步骤如下：

- 1) 获取三类梯级固定螺栓振动信号，设置 VMD 分解的参数；
- 2) 对三类振动信号进行 VMD 分解，得到一组 IMF 分量，并且选出最优的主 IMF 分量；
- 3) 对主 IMF 分量进行 SVD 降噪，重组得到去噪后的主 IMF 分量；
- 4) 用高阶统计量对去噪后的主 IMF 分量进行故障特征提取；
- 5) 采用随机森林算法对三类振动信号的特征参数进行分类识别分析，得出故障诊断分类结果。

2.2 主 IMF 分量选取

根据文献 [27] 中的方法选取主 IMF 分量来进行特征提取。如果目标信号共分解为 M 阶模态，第 m 阶模态共有 N 个采样点，第 n 个采样点的瞬时频率为 f_{mm} ，瞬时振幅为 b_{mm} ，则第 m 阶模态的第 n 个采样点的瞬时强度为：

$$Q_{mm} = b_{mm}^2 \quad (13)$$

原始信号的第 m 阶固有模态函数的中心频率为：

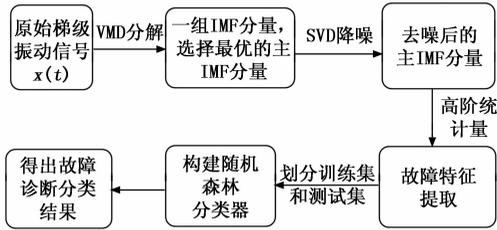


图 2 本文算法流程图

$$\hat{f}_m = \frac{\sum_{n=1}^N Q_{nm} f_{nm}}{\sum_{n=1}^N Q_{nm}} \quad (14)$$

原始信号第 m 阶固有模态函数的平均强度为:

$$\hat{B}_m = \frac{\sum_{n=1}^N Q_{nm}}{N} \quad (15)$$

定义平均强度最大的那一阶 IMF 分量为主 IMF 分量, 即:

$$\hat{B}_{\max} = \max\{\hat{B}_1, \hat{B}_2, \dots, \hat{B}_M\} \quad (16)$$

式 (16) 中: \hat{B}_i 为 VMD 分解后第 i 阶 IMF 分量的平均强度, 主 IMF 分量反映了信号的主要信息。

3 实验结果与分析

3.1 实验数据

为验证本文方法的有效性, 采用振动传感器 (图 3 所示) 采集自动扶梯梯级的振动信号, 采样频率为 2 000 Hz, 通过吸铁石安装在自动扶梯梯级固定螺栓的位置。分别采集梯级固定螺栓正常、松动一圈和松动三圈的信号, 截取一部分信号如图 4 所示。



图 3 振动传感器示意图

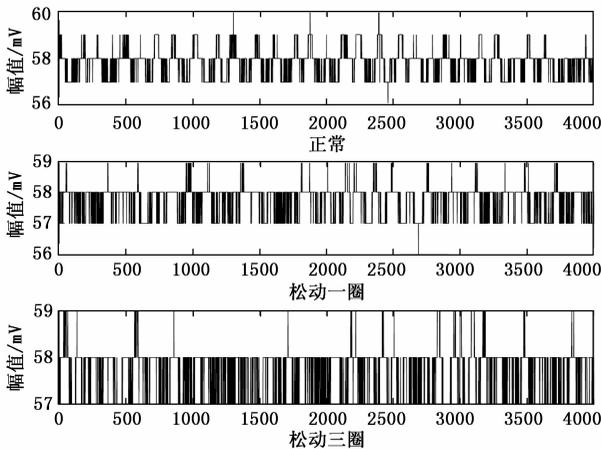
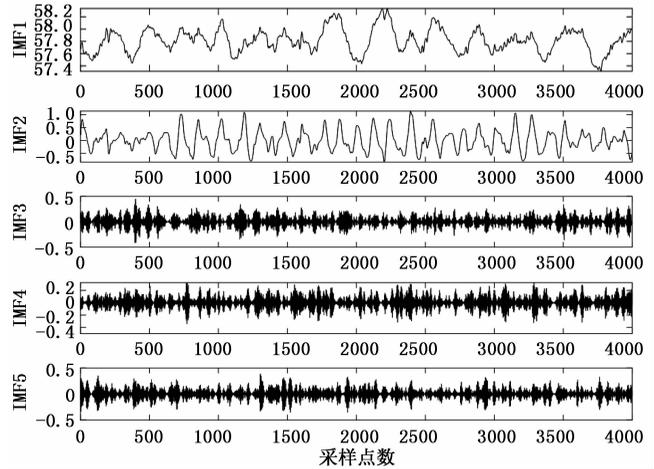


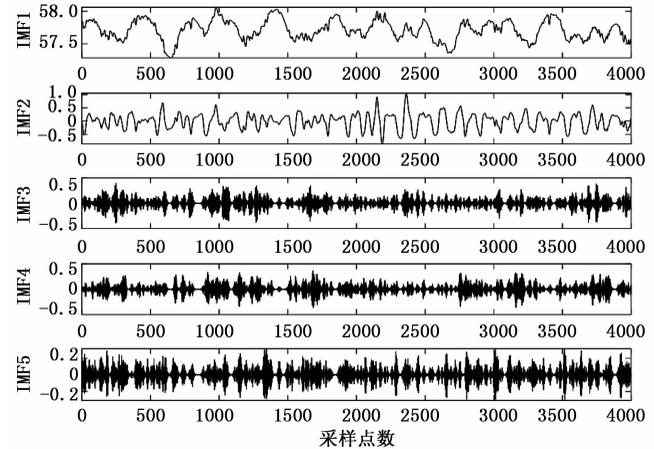
图 4 梯级振动原始信号

3.2 故障特征提取

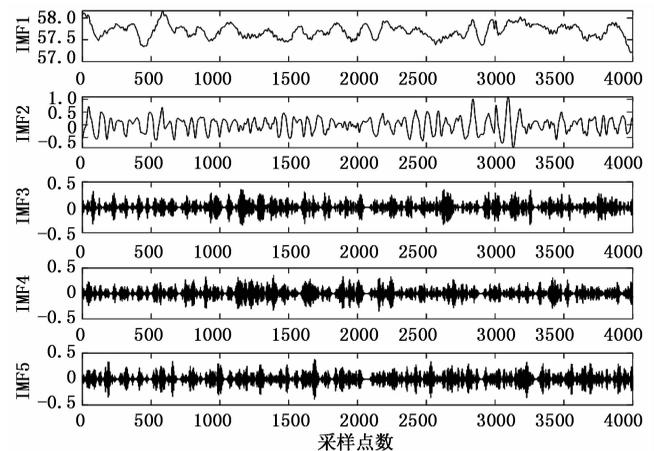
根据之前的介绍, 首先对 3 种不同类型的梯级振动信号进行 VMD 分解, 其中: VMD 分解层数为 5 层, 二次惩罚因子 $\alpha = 2\ 000$, 得到的各阶 IMF 分量如图 5 所示。



(a) 正常振动信号



(b) 松动一圈振动信号



(c) 松动三圈振动信号

图 5 三类振动信号 VMD 分解的各阶 IMF

通过式 (15) 来确定平均强度最大的 IMF 分量, 对确定的主 IMF 分量进行 SVD 分解重构降噪, 得到的信号如图

6 所示。

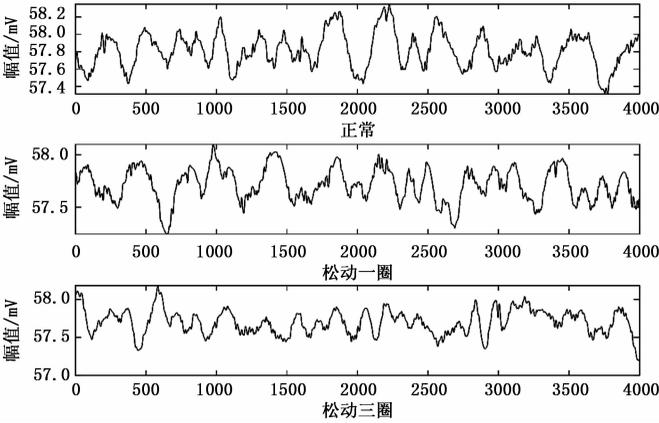


图 6 三类去噪后的主 IMF 分量

高阶累积量不仅可以自动抑制高斯噪声的影响，而且也能抑制对称分布噪声的影响，所以在信号检测以及目标分类识别等领域取得了广泛应用。本文采用三阶累积量对去噪后的主 IMF 分量来进行特征提取。

为了说明本文所提出方法提取特征的有效性，这里选用互补集合经验模态分解 (Complementary Ensemble Empirical Mode Decomposition, CEEMD)、平稳小波变换 (Stationary Wavelet Transform, SWT) 以及直接用原始信号来做对比实验。其中 CEEMD 的分解层数为 5 层，SWT 的分解层数为 3 层，小波基选用“db8”。4 种方法提取的特征如图 7 所示。

从图 7 中可以看出，本文方法提取的特征要明显优于前面 3 种方法，提取的 3 种类别梯度振动信号的特征很明显，可以诊断出梯级故障，CEEMD 和 SWT 在一定程度上都出现混叠，提取的特征不明显。

3.3 评价指标

为了验证本文所提方法的有效性，基于采集到的信号构造训练集和测试集来验证，然后用随机森林分类器来验证准确率。对于本文的分类预测精度，采用准确率 (ACC)、灵敏度 (Se)、特异性 (Sp)、正例命中率 (TPR) 和负例命中率 (TNR) 5 个指标来进行评估，各个指标的定义如下：

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

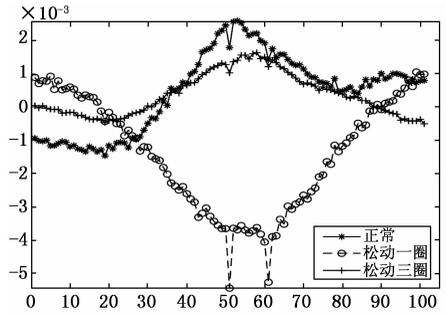
$$Se = \frac{TP}{TP + FP} \quad (18)$$

$$Sp = \frac{TN}{TN + FN} \quad (19)$$

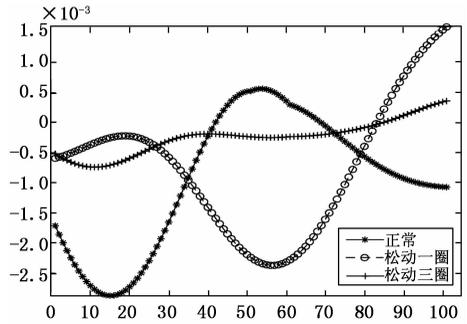
$$TPR = \frac{TP}{TP + FN} \quad (20)$$

$$TNR = \frac{TN}{FP + TN} \quad (21)$$

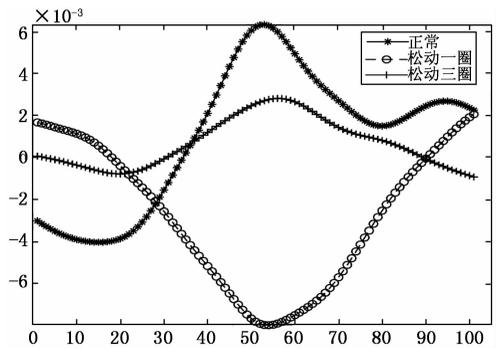
其中：TP 为分类正确的正常信号数目，TN 为分类正确的有故障的信号数目，FP 为分类错误的正常信号数目，FN 为分类错误的有故障的信号数目。



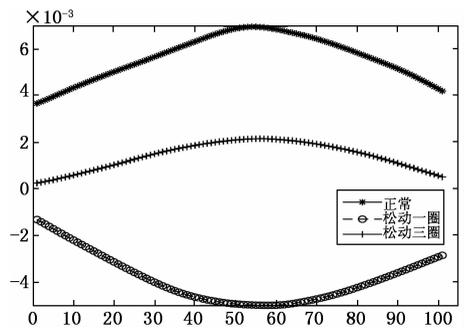
(a) 原始信号提取的特征



(b) CEEMD 分解提取的特征



(c) SWT 提取的特征



(d) 本文方法提取的特征

图 7 4 种方法提取的特征对比

从表 1 中可以看出本文所提出方法的准确率、灵敏度以及特异性均优于其他几种方法，梯级振动信号的特征提取的比较明显，可以实现自动扶梯梯级振动的故障诊断分类。由于 VMD 分解求解的原因，本文方法所用的时间较长

一点。

表1 4种方法的评价指标对比

方法	评价指标				
	Se	Sp	TPR	FPR	ACC
HOS	80.9%	82.2%	57.6%	93.5%	81.9%
SWT+HOS	88.2%	86.2%	66.3%	96.1%	87.0%
CEEMD+HOS	91.9%	87.9%	65.8%	97.3%	88.9%
本文方法	97.8%	96.5%	89.3%	99.3%	96.8%

注:在这里规定,有故障的样本为松动一圈和松动三圈的振动信号样本。

4 结束语

本文将VMD算法引入自动扶梯梯级故障诊断分析中,并结合SVD去噪和RF算法提出一种自动扶梯信号特征提取及分类识别方法。首先将3种不同故障类型的信号进行VMD分解得到主IMF分量,然后对主IMF分量进行SVD降噪得到新的重构信号。对新的重构信号用高阶统计量进行特征提取,最后通过实验结果表明,该方法可以有效提取自动扶梯梯级故障,实现故障诊断与分类。

参考文献:

[1] 陶然,许有才,邓方华,等.基于SVD优化LMD的电梯导轨振动信号故障特征提取[J].振动与冲击,2017,36(22):166-171.

[2] 张进,冯志鹏,褚福磊.滚动轴承故障特征的时间-小波能量谱提取方法[J].机械工程学报,2011,47(17):44-49.

[3] 邢蓉,高丙朋,侯培浩,等.基于MSCNN与STFT的滚动轴承故障诊断研究[J].机械传动,2020,44(7):41-45.

[4] 许爱华,闫俊泉,伍旭灿,等.基于VMD和MP算法的旋转机械故障特征提取[J].国外电子测量技术,2017,36(8):11-17.

[5] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society of London, Series A: Mathematical, Physical and Engineering Sciences, 1998, 454 (1971): 903-995.

[6] Wu Z H, Huang N E. A study of the characteristics of white noise using the empirical mode decomposition method [J]. Proceedings of the Royal Society of London, A, 2004, 2046 (460): 1597-1611.

[7] 兰夏燕,万舟,许有才,等.基于SVD优化EMD的电梯导轨振动信号故障特征提取[J].软件,2017,38(8):25-31.

[8] Wu Z H, Huang N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.

[9] 高立龙,李九林,于雨,等.基于SVM与EEMD方法的工程机械液压系统冲击振动信号研究[J].工程机械,2020,51(7):8-13.

[10] Smith J S. The local mean decomposition and its application to EEG perception data [J]. Journal of the Royal Society Interface, 2005, 2(5): 443-454.

[11] Yang Y, Cheng J S, Zhang K. An ensemble local means decomposition method and its application to local rub-impact Fault diagnosis of the rotor systems [J]. Measurement, 2012(45): 561-470.

[12] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.

[13] 白堂博,张来斌,唐满红,等.基于VMD的旋转机械故障诊断方法研究[J].石油矿场机械,2016,45(8):22-27.

[14] 李余兴,李亚安,陈晓,等.基于VMD和中心频率的舰船辐射噪声特征提取方法研究[J].振动与冲击,2018,37(23):213-218.

[15] 罗小燕,卢文海,游义平,等.基于VMD和SVD联合降噪方法的球磨机振动信号随机噪声压制[J].噪声与振动控制,2019,39(6):169-175.

[16] 李亚兰,葛鹏,金炜东.基于VMD和特征融合的辐射源信号识别[J].系统工程与电子技术,2020(7):1499-1503.

[17] 张建财,高军伟.基于变分模态分解和多尺度排列熵的滚动轴承故障诊断[J].噪声与振动控制,2019,39(6):181-186.

[18] 唐贵基,王晓龙.变分模态分解方法及其在滚动轴承早期故障诊断中的应用[J].振动工程学报,2016,29(4):638-648.

[19] 祁广云,李磊,关海鸥,等.生物触电信号高阶统计特征描述及分析方法[J].江苏大学学报(自然科学版),2017,38(2):173-178.

[20] 冯正权,何庆华,吴宝明,等.基于高阶统计量分析的生物医学信号处理应用[J].中国医学物理学杂志,2011,28(5):2899-2903.

[21] 王俊峰.高阶统计量在滚动轴承故障诊断中的应用研究[A].中国力学学会动力学与控制专业委员会.第十四届全国非线性振动暨第十一届全国非线性动力学和运动稳定性学术会议摘要集与会议议程[C].中国力学学会动力学与控制专业委员会:中国力学学会,2013:161.

[22] 郭庆丰.高阶统计量在滚动轴承故障诊断中的应用[D].成都:电子科技大学,2013.

[23] 吴杨.基于高阶统计量的信号分析与处理[J].自动化与仪器仪表,2015(4):212-214.

[24] 蔡剑华,胡惟文,王先春.基于高阶统计量的滚动轴承故障诊断方法[J].振动.测试与诊断,2013,33(2):298-301-343.

[25] 温旋旋.基于高阶统计量的舰船辐射噪声包络特征提取[D].哈尔滨:哈尔滨工程大学,2017.

[26] 中国科学院国家空间科学中心.一种基于高阶统计量的微弱信号检测方法[P].CN201810135892.4,2018.

[27] 李余兴,李亚安,陈晓.基于EEMD的舰船辐射噪声特征提取方法研究[J].振动与冲击,2017,36(5):114-119.