

融合 PSO 优化的相关变模态分解与深度学习的 旋转机械早期故障智能分类方法

董红平¹, 李明²

(1. 绍兴职业技术学院, 浙江 绍兴 312000; 2. 西南林业大学, 昆明 650224)

摘要: 针对旋转机械早期故障信号呈现微弱、相互干扰, 易导致故障智能分类精度低的现状, 提出一种融合优化的 PSO—RVMD (particle swarm optimization—relevant variational mode decomposition) 与 SAE (stacked autoencoder) 的旋转机械早期故障分类方法; 智能分类方法主要由信号增强与智能分类两阶段组成; 首先该方法利用所改进的 PSO—RVMD 分解电机—轴承系统的早期故障振动信号, 通过定义的相关能量比概念计算各分量信号 (IMFs) 与原始信号之间的相关程度, 筛选并重构相关程度高的分量, 去除冗余与不相干的干扰与噪声成分, 实现信号增强; 最后, 将增强的早期微弱信号输入到 SAE 模型中进行训练; 利用 SAE 模型提取高层、抽象且利于分类的深度特征且在最后一层添加 BP 层, 直接对提取的深度特征进行故障分类; 通过仿真与实际电机—轴承系统振动信号验证了该方法的有效性, 结果表明该方法能快速的实现旋转机械早期微弱故障的精确识别与诊断, 提高故障特征学习与自动分类程度。

关键词: 旋转机械; 早期故障诊断; 群粒子优化的相关变模态分解 (PSO—RVMD); 堆栈自编码 (SAE)

Early Fault Intelligent Classification Method of Rotating Machinery Based on PSO — Relevant Variational Mode Decomposition and Deep Learning

Dong Hongping¹, Li Ming²

(1. Shaoxing Vocational & Technical College, Shaoxing 312000, China;

2. Southwest Forestry University, Kunming 650224, China)

Abstract: Aiming at the weakness and mutual interference of the early failure signals of rotating machinery, it is easy to cause the intelligent fault classification with low accuracy. An early fault classification method of rotating machinery based on PSO—RVMD (Particle Swarm Optimization—Related Variational Mode Decomposition) and SAE (Stacked AutoEncoder) is proposed. The main methods of intelligent classification are two phases of signal enhancement and intelligent classification. Firstly, Improved PSO—RVMD motor breakdown. — Early fault vibration signals of the bearing system, the correlation between each component signal (IMF component) and the original signal is calculated through the definition of the correlation energy ratio concept, the high correlation component is screened and reconstructed, eliminate the redundant and irrelevant interference and noise components, to achieve signal enhancement. Finally, the enhanced early weak signal is input into the SAE model for training. The SAE model is used to extract the high—level, abstract and class—specific depth features, and the BP layer is added on the last layer. The extracted deep features are directly simulated for fault classification with the motor. The bearing system vibration signal verifies the effectiveness of this method. The method can quickly identify and diagnose the early weak faults of rotating machinery, and improve the learning and automatic classification of fault features.

Keywords: rotating machinery; early fault diagnosis; particle swarm optimization—relevant variational mode decomposition (PSO—RVMD); stacked autoencoder (SAE)

0 引言

旋转机械被广泛应用于航空、航天、船舶、汽车、核技术等工业领域, 扮演着财富生产与制造经济的巨大作

用^[1-2]。众所周知, 旋转机械高速运转极易产生故障或损伤, 从而造成不可估量的经济损失甚至是人员伤亡。如能尽早的发现或诊断出潜在的、微弱的故障, 这对于降低故障影响、提升经济效益具有积极的现实意义^[3-4]。在实际工程应用中, 经传感器采集的振动信号大多是非平稳、非线性的多分量混叠信号且振动传输路径的衰减影响及背景噪声的干扰等因素均会对特征信息的提取形成严重的阻碍。因此, 相对于中、晚期故障而言, 旋转机械早期、微弱故障的识别与诊断更为困难^[5-6]。

显然, 若能将复杂的多分量早期信号分离成各个振源的单分量信号, 实现信号的增强, 必能大大提高故障诊断

收稿日期: 2019-04-11; 修回日期: 2019-07-08。

基金项目: 国家自然科学基金项目(31760182)。

作者简介: 董红平(1981—), 男, 湖北天门人, 讲师, 硕士, 主要从事智能控制、电液控制方向的研究。

通讯作者: 李明(1977—), 男, 江苏盐城人, 博士, 教授, 主要从事智能控制与智能优化算法、声发射无损检测、电液控制方向的研究。

的准确性。为解决此类问题, Huang 等^[7]提出一种经验模态分解 (empirical mode decomposition, EMD), 其原理是把非平稳信号分解成不同频段的模态分量进而转化成平稳信号进行分析^[2-5]。而 EMD 在处理多目标故障信号时容易产生模态混叠现象, 因此, Smith 等^[8]提出了一种新的时频分析方法—局部均值分解法 (LMD), 该方法可自适应地将一个给定的复杂非平稳信号分解为多个乘积函数 (PF) 分量的线性组合。虽然 EMD、LMD 等在非平稳、非线性的微弱信号处理中取得了巨大的成就, 但它们仍然存在模态混叠、端点效应和分解误差较大导致虚假分量等一系列问题^[9]。对此, 不少学者针对上述问题提出了许多优化及改进策略^[9-5], 但这些信号分解方法均属于递归模式分解, 固有缺陷很难从根本上得以解决, 应用在旋转机械故障提取与信号分析容易误判。为此, Dragomiretskiy^[10]提出一种自适应信号处理新方法—变分模态分解 (variational mode decomposition, VMD), 该方法在获取分解分量的过程中通过迭代搜寻变分模型最优解来确定每个分量的频率中心及带宽, 从而能够自适应地实现信号的频域剖分及各分量的有效分离。相比 EMD 和 LMD 的递归“筛选”模态, VMD 方法有牢固的数学理论基础, 能更准确地分解信号, 不易发生模态混叠现象, 噪声鲁棒性好, 且其运算效率高。刘长良等^[11]将 VMD 引入到机械故障诊断领域, 用于分析滚动轴承故障信号取得了良好的效果。

通过分析算法可知 VMD 有两个重要参数, 即分量个数 K 和惩罚因子 C 是由经验性设定引起的, 使得信号分解出现一定的误差, 导致诊断精度降低。基于 VMD 的早期故障诊断方法的缺点主要有以下两点:

- 1) 早期故障信号处理方法—VMD 的改进。
- 2) 传统故障诊断方法的智能化、自动化程度不高。

针对 VMD 的不足, 本研究利用 PSO 优化 RVMD 的惩罚系数和分量个数 K , 利用新定义的相关能量比系数筛选并重构相关程度高的分量, 实现微弱信号的增强。同时增强的信号不易发生模态混叠现象, 且抗噪性好。该信号增强方法能够有效抑制 VMD 中存在的交叉干扰项, 可对振动信号的全部信息进行描述。

PSO-RVMD 分解后的信号需要有效的模式识别方法, 来量化、智能化故障诊断结果。传统的故障诊断方法大多基于频谱分析或人工统计特征分析, 这类方法大多依赖于专家知识, 可靠性差且故障诊断精度不高。这些因素制约了机械设备诊断的智能化、自动化的发展进程^[12-13]。

深度学习作为当今先进的数据挖掘与模式识别方法之一, 被广泛应用到机器视觉、语音处理、智能故障诊断等领域^[14-15]。其中, SAE 作为深度学习最常用的模型之一, 可将底层数据通过神经网络层层提取为高层、有意义的特征表达, 具有良好的抗噪性^[16]。SAE 应用到故障诊断的文献综述, 深度学习可直接对原始信号进行训练学习, 无需

建立人工特征, 自动化、智能化程度高, 但 SAE 还未应用到早期故障诊断中。

综合 PSO-RVMD 在处理微弱信号增强和 SAE 在智能故障识别上的优势, 本研究拟构建一种新型的融合 PSO 优化的相关变模态分解与深度学习的旋转机械早期故障智能分类方法。

本研究主要贡献主要有:

- 1) 优化的 PSO-RVMD 可去除冗余与不相关的多故障分量信息, 实现微弱信号的增强。
- 2) 将 PSO-RVMD 增强的信号直接输入到 SAE 进行智能故障分类, 避免了人工特征的不足, 提高了智能故障诊断的自动化程度。

1 改进的信号处理方法—PSO-RVMD

VMD 的惩罚参数 α 与 IMF 各分量的带宽成反比, 但实际待分析信号的复杂多变性使得分解个数 K 和惩罚参数 α 这两个决定分解结果的参数难以确定。因此, 选定合适的参数组合 $[\alpha, K]$ 是利用 VMD 算法分析轴承早期故障信号的关键。因此本研究利用粒子群算法的良好全局寻优能力, 对 VMD 算法的两个影响参数进行智能优化, 避免人为主观因素的干预, 自动筛选出最佳的影响参数组合。

为了提取故障分量信号, 去除冗余与干扰分量, 实现信号增强, 提取早期微弱的故障信息。通过定义一种新型的筛选指标即融合分量与原始信号的相关系数与能量比的概念来确定信号的相关程度, 以此为依据进行信号重构。

相关系数 $\rho(x_i, x_j)$ 在统计学中是用来描述向量数据点 x_i, x_j 之间的相关程度指标, $\rho(x_i, x_j) \in [-1, 1]$, 其绝对值大小表明两点相关程度的高低。相关系数公式定义为:

$$\rho(x_i, x_j) = \frac{E(x_i - E(x_i)) - E(x_j - E(x_j))}{\sqrt{D(x_i)} \sqrt{D(x_j)}} \quad (1)$$

式中, $E(x_i), E(x_j)$ 分别是变量 x_i, x_j 的期望, $D(x_i), D(x_j)$ 表示 x_i, x_j 的方差。相关系数只反映数据间的相关程度, 与空间分布情况无关, 且稳定性好。同时相关能量比定义如下:

$$RE(imf(i)) = E_{total}(IMF(i)) * \rho(x, IMF(i)) \quad (2)$$

式中, RE 值越大, 表示故障的信号分量的相关程度越高。相对于单一的相关系数以及能量比, 所提出的相关能量比新评价指标能更真实地筛选出故障分量并排除干扰, 当累计指标达到 0.8 以上, 进行信号重构, 可以得到增强的信号。

本研究提出的 PSO-RVMD 优化分为 6 步:

- 1) 初始化 PSO 各项参数, 并确定适应度函数进行寻优。
- 2) 以随机产生的影响参数组合 $[\alpha, K]$ 作为粒子的初始位置, 随机初始化每个粒子的移动速度, 实现种群粒子初始化。
- 3) 针对每个粒子不同的位置条件, 对故障信号做

VMD 运算, 获取每个粒子位置的适应度值 $(IMF_{b_i})_{\min}$ 。

4) 对比、分析各粒子的适应度值, 更新个体局部极值与种群全局极值, 进而更新粒子的速度与位置。

5) 循环迭代步骤 3, 至次数最大设定值, 得到寻优全局中的最佳适应度值与粒子位置。

6) 计算经 PSO 优化后 VMD 分解的 IMF 分量 RE 值, 当累计 RE 值达到 0.8 后, 进行信号分量重, 得到信号增强的新信号替换原始信号。

2 智能故障分类方法—SAE 模型

2.1 SAE 模型

Stacked Auto encoder (SAE) 模型是一个由若干 AE 堆叠而成的无监督深度学习神经网络模型。输入向量 x 通过某种编码函数 $f(x)$, 将输入数据投影到另一个空间中, 然后再通过解码函数 $g(f(x))$ 来重构 x , 利用重构 x' 与输入 x 的误差最小化, 实现对输入数据的特征表示以及相关参数的训练。其前一层自编码器的输出作为其后一层自编码器的输入, 最后一层为分类器 (logistic 分类器或 soft max 分类器), 完成深度特征的抽取。该神经网络的输入到编码层的映射函数为非线性函数, 通常有如下形式:

$$h_i = f(x_i) = \frac{1}{1 + \exp(-(\omega_1 x_i + b_1))} \quad (3)$$

式中, ω_1 为层间的权重; b_1 为对应的偏差。从编码层到解码层的非线性函数为:

$$x'_i = g(h_i) = \frac{1}{1 + \exp(-(\omega_2 h_i + b_2))} \quad (4)$$

式中, ω_2 为层间的权重; b_2 为对应的偏差。自编码的目标函数的最小重构误差如下:

$$L\{x', x\} = \min \frac{1}{N} \sum_{i=1}^N x'_i - x_i \quad (5)$$

该网络训练出来的各层特征提取器容错性能好, 同时学习得到的特征更健壮。

2.2 融合 PSO—RVMD 和 SAE 的旋转机械早期故障智能分

旋转机械故障一旦发生, 需及早发现故障信息并作出相应的分类与诊断, 减轻旋转机械故障所带来的危害。改进的 PSO—RVMD 能自动学习隐含在数据中的关系, 深度抽取故障信号特征, 重构并增强故障信号, 而抑制、分解非线性、非平稳的微弱信号。同时, 为克服传统故障分类方法智能化、自动化程度低的情况, 通过利用深度学习模型可以直接将增强的原始信号输入到 SAE 中, 层层提取抽象的、利于分类的高层故障特征, 实现旋转机械早期微弱故障的智能分类。该方法首先通过采集的旋转机械各类故障振动信号, 然后利用所提的 PSO—RVMD 进行振动信号增强, 最后将增强的微弱信号输入训练好的深度学习 SAE 模型中, 进行智能分类。本研究正是结合两者优势, 将 PSO—RVMD 方法和 SAE 进行有机融合并应用到早期故障智能诊断中。该方法主要分为早期微弱信号增强与智能分类两阶段:

早期微弱信号增强阶段

步骤 1: 首先, 获取旋转机械的多状况振动信号。

步骤 2: 初始化 PSO 各参数, 确定适应度函数, 并进行 VMD 参数组合寻优。

步骤 3: 所提的 PSO—RVMD 对早期微弱信号进行分解与信号重构, 得到增强的信号。随后进行归一化处理, 将频谱信号分为训练与测试样本。

智能分类阶段:

步骤 4: 初始化 SAE 模型参数。

步骤 5: 确定 SAE 模型的隐层数 N , 以无监督的 CD 方式逐层训练 N 个 AE, 完成无标签样本数据的 SAE 模型预训练。

步骤 6: 根据样本状况信息, 微调模型参数, 保存网络结构。

步骤 7: 得到 SAE 模型, 对测试样本进行测试、分类, 得出诊断结果。

3 试验验证与分析

轴承作为旋转机械的关键部件, 它的健康状况通常会影响机器的使用寿命。为验证本研究所提的智能故障分类方法的可行性, 选择轴承作为研究对象。其试验数据来自于美国凯斯西储大学 (CWRU) 电气工程实验室^[17]。试验中轴承的损伤用电火花加工模拟, 如图 1 所示。

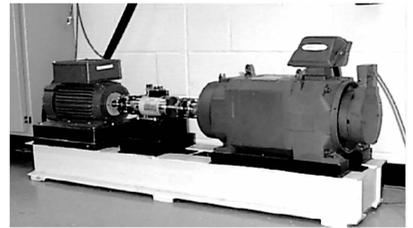


图 1 美国凯斯西储大学 (CWRU) 电机—轴承试验台

在轴承故障数据中, 轴承六类状态中有早期微弱故障与晚期故障的振动信号时域与单边谱频域波形图如图 2 所示。早期故障比较微弱受到噪声干扰的程度影响更大, 其冲击特性不明显, 频谱中共振频带也不明显。

本研究所提的方法分为两个阶段: 早期微弱信号增强阶段与智能分类阶段。为了对早期微弱信号进行重构、与增强, 按照所提的方法流程图所示, 利用 PSO—RVMD 对信号进行重构, 以内圈故障振动信号为例进行 PSO—RVMD 分解。

使用 PSO—RVMD 算法对仿真轴承内群故障信号进行处理, 设定混沌搜索最大次数 $\max k=10$, 加速常数 $c1=2$, $c2=2$, 扩张收缩系数最大值=1.0 和最小值=0.5。 $[\alpha, k] = [261, 7]$, 由此设定 VMD 算法的 $\alpha=601$ 、 $k=7$, 并对仿真信号进行处理。

优化的 RVMD 可以将故障信号从高频到低频进行分解, 故障振动信号被展开, 相关能量比筛选的分量进行信号重构。从六种故障的时域与频域波形图可以观察到各类

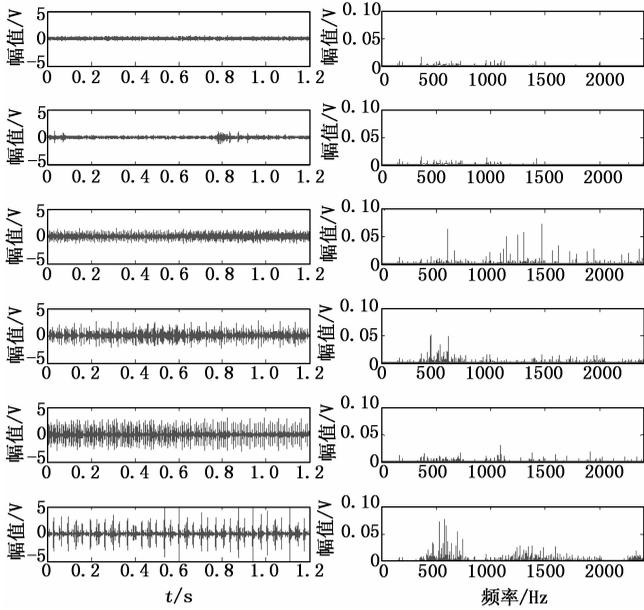


图 2 轴承早期与晚期故障信号的时域与频域波形包络图

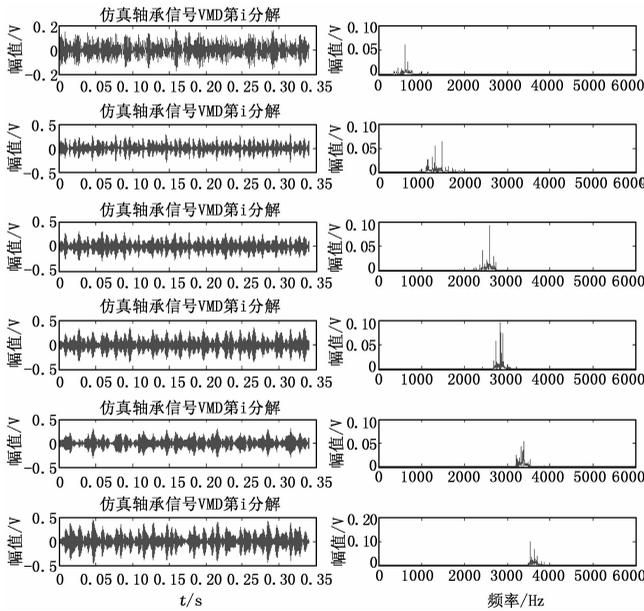
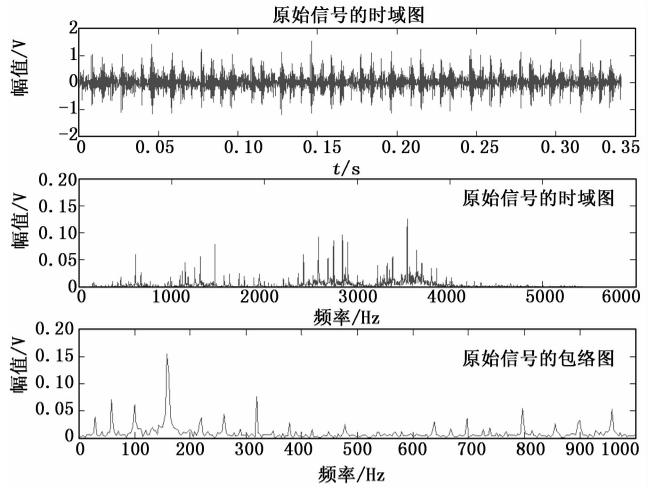


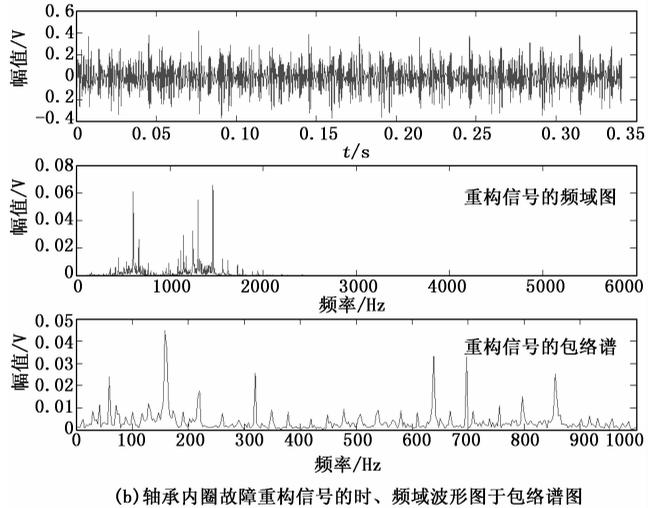
图 3 轴承内圈故障 PSO-RVMD 分解的 IMF 分量的时域与频域波形图

故障的不同,严重与轻微故障的区分明显。其中滚动体严重与轻微故障被 PSO-RVMD 分解的 IMF_s 分量,其频谱信息被从高频到低谱进行分解,如图 4 所示。可以看出,原始信号的非故障特征频率得到抑制,故障频率更加突出这些都是信号增强阶段。然而,传统的振动信号时频域分析不能量化机械故障的特征信息,描述故障能力有限,这就需要对故障振动信号进行特征提取,利用特征参数或特征提取方法来描述故障信息,即需要智能分类。

根据文献[10],设置的 SAE 为两层特征层,神经单元



(a) 轴承内圈早期原始信号的时频域波形图与包络谱图



(b) 轴承内圈故障重构信号的时、频域波形图于包络谱图

个数为: 300-250-250-6, 批次等于 35; 综合考虑算法稳定性和收敛速度,学习率 ϵ 、后向微调中学习率 α 均设为 0.1, 迭代次数设为 200, 重复试验 20 次, 以平均值作为最终识别结果。信号增强后的早期故障得到进一步增强, 将重构后的信号分类测试训练, 直接输入 SAE 中进行智能分类, 如图 5 所示。

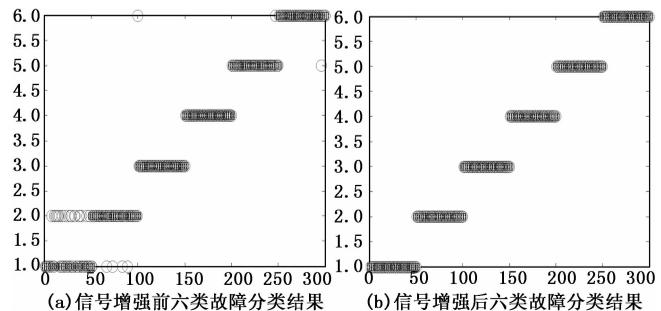


图 5 信号增强前后故障分类结果对比

信号增强后再分别输入到智能分类器 SAE 中, 可以看出经过原始频谱信号直接输入到新型的智能分类器 SAE 中, 其识别率都很高。这是因为深度学习强大的模式识别能力, 相对于传统的机器学习方法, 基于深度学习的故障诊断方法克服了传统故障诊断需要建立人工特征的限制, 直接将故障信号输入到 SAE 中, 实现故障的智能分类。

从图 5 中可以看出, 对比信号增强前故障分类的识别率, 各类早期故障不能达到最优, 且整体故障分类精度相对信号增强后的低, 这是因为信号增强提升了早期微弱故障的分类精度。增强后的故障分类可到达百分之百, 证明了本研究所提的融合信号增强的 PSO-RVMD 的有效性, 以及本研究所提的方法对于早期微弱故障的智能分类具有优异的结果。

4 结论

旋转机械早期故障信号呈现微弱、相互干扰, 易出现故障智能分类精度低的现状。本研究提出一种融合优化的 PSO-RVMD 与 SAE 的旋转机械早期故障分类方法。首先利用所改进的 PSO-RVMD 分解电机一轴承系统的早期故障振动信号, 通过定义的相关能量比概念计算各分量信号与原始信号之间的相关程度, 筛选并重构相关程度高的分量, 去除冗余与不相干的干扰与噪声成分, 实现信号增强。仿真信号与轴承试验数验证了方法的有效性。该方法为旋转机械早期故障诊断提供一种可参考的实现途径。

参考文献:

- [1] Lei Y, He Z, Zi Y. A new approach to intelligent fault diagnosis of rotating machinery [J]. *Expert Systems with Applications*, 2008, 35 (4): 1593-1600.
- [2] Nandi S, Toliyat H A, Li X. Condition Monitoring and Fault Diagnosis of Electrical Motors—A Review [J]. *IEEE Transactions on Energy Conversion*, 2006, 20 (4): 719-729.
- [3] Jay Lee, Wu Fangji, Zhao Wenyu, et al. Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications [J]. *Mechanical Systems and Signal Processing*, 2014, 42: 314-334.
- [4] Lei Y, Lin J, He Z, et al. Application of an improved kurtogram method for fault diagnosis of rolling element bearings [J]. *Mechanical Systems & Signal Processing*, 2011, 25 (5): 1738-1749.

(上接第 70 页)

- [12] 崔广新, 李殿奎. 基于 AdamOptimizer 自编码的手写数字识别研究 [J]. *佳木斯大学学报 (自然科学版)*, 2018, 36 (3): 363-366.
- [13] Liu Yuetian. Convolutional Neural Networks with Large-Margin Softmax Loss Function for Cognitive Load Recognition [A]. 中国自动化学会控制理论专业委员会. 第 36 届中国控制会议论文集 [C]. 中国自动化学会控制理论专业委员会:

- [5] Amar M, Gondal I, Wilson C. Vibration Spectrum Imaging: A Novel Bearing Fault Classification Approach [J]. *IEEE Transactions on Industrial Electronics*, 2015, 62 (1): 494-502.
- [6] Lei Y, Lin J, He Z, et al. A review on empirical mode decomposition in fault diagnosis of rotating machinery [J]. *Mechanical Systems & Signal Processing*, 2013, 35 (1-2): 108-126.
- [7] 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]. *Mathematical Physical & Engineering Sciences*, 1998, 454 (1971): 903-995.
- [8] 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.
- [9] 张 亢, 程军圣. 基于 LMD 和阶次跟踪分析的滚动轴承故障诊断 [J]. *振动·测试与诊断*, 2016, 36 (3): 586-591.
- [10] Dragomiretskiy K, Zosso D. Variational Mode Decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62 (3): 531-544.
- [11] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断 [J]. *中国电机工程学报*, 2015, 35 (13).
- [12] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521 (7553): 436-444.
- [13] Cui C, Wang D. High dimensional data regression using Lasso model and neural networks with random weights [J]. *Information Sciences*, 2016, 372: 505-517.
- [14] Shin H C, Roth H R, Gao M, et al. Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning [J]. *IEEE Transactions on Medical Imaging*, 2016, 35 (5): 1285-1298.
- [15] Jia F, Lei Y, Lin J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data [J]. *Mechanical Systems and Signal Processing*, 2016, 72-73: 303-315.
- [16] Liao L, Jin W, Pavel R. Enhanced Restricted Boltzmann Machine With Prognosability Regularization for Prognostics and Health Assessment [J]. *IEEE Transactions on Industrial Electronics*, 2016, 63 (11): 7076-7083.
- [17] The Case Western Reserve University [EB/OL]. <http://www.eecs.cwru.edu/laboratory/bearing>, 2013.
- [18] 中国自动化学会控制理论专业委员会, 2017: 5.
- [14] Ernst Kussul, Tatiana Baidyk. Improved method of handwritten digit recognition tested on MNIST database [J]. *Vision Computing*, 2004, 22 (12).
- [15] Vadim V. Romanuke. Appropriateness of Dropout Layers and Allocation of Their 0.5 Rates across Convolutional Neural Networks for CIFAR-10, EEACL26, and NORB Datasets [J]. *Applied Computer Systems*, 2017, 22 (1).