

基于IVMD-GA-KELM的电梯曳引系统故障诊断方法*

魏义敏¹, 张红兵², 刘 辉¹, 潘 骏¹, 陈文华¹, 孙小龙¹

(1. 浙江理工大学机电产品可靠性分析与测试国家地方联合工程研究中心 杭州, 310018)

(2. 杭州西奥电梯有限公司 杭州, 311103)

摘要 针对电梯曳引系统运行过程中振动信号具有非线性和非平稳性、导致故障诊断精度较低的问题,提出了一种基于改进变分模态分解-遗传算法-核极限学习机(improved variational modal decomposition-genetic algorithm-kernel extreme learning machine,简称IVMD-GA-KELM)的电梯曳引系统故障诊断方法。首先,将动态时间规整算法与残余能量熵占比指标相结合,自适应确定变分模态分解(variational modal decomposition,简称VMD)的最优分解层数 K 和二次惩罚因子 α ;其次,采用VMD将所采集到的振动信号分解成多个固有模态分量(intrinsic mode functions,简称IMF),并根据最大峭度准则选取相应故障分量构建故障特征集;然后,采用遗传算法(genetic algorithm,简称GA)优化的核极限学习机(kernel extreme learning machine,简称KELM)对故障特征进行识别与分类;最后,进行故障注入试验以验证方法有效性。研究结果表明,所提出方法能够分析复杂的振动信号,对电梯曳引系统常见故障识别准确率达到96.67%,为电梯曳引系统的故障诊断提供了一种可行方法。

关键词 曳引系统;改进变分模态分解;故障特征提取;动态时间规整;残余能量熵

中图分类号 TH17;TU857

引 言

电梯作为重要的垂直交通工具,其曳引系统是核心组成部分,该系统在长期服役中易出现曳引轮轴承故障、反绳轮不对中故障及钢丝绳缺陷故障等^[1]。因此,对曳引系统开展故障诊断具有重要意义。

电梯在运行过程中经历加速、匀速和减速多个阶段,每个阶段的振动信号特征不同。负载变化与零部件磨损等因素都会导致振动信号的统计特性随时间变化,具有非平稳性的特点^[2]。电梯的机械系统包括曳引机、制动器、导轨和钢丝绳等组件,这些组件之间的相互作用具有非线性特性^[3],使传统方法对曳引系统的故障诊断效果不佳。

信号处理方法在状态监测与故障识别中得到了广泛应用^[4]。经验模态分解(empirical mode decomposition,简称EMD)常被用于分析非线性、非平稳信号,通过时间尺度从高频到低频提取原始信号中的所有分量,但EMD存在模态混叠与端点效应两大问题^[5]。为了克服模态混叠现象,集合经验模态分解(ensemble empirical mode decomposition,简称EEMD)^[6]与互补集合经验模态分解(complementary ensemble empirical mode decomposition,简称

CEEMD)^[7]被相继提出。局部均值分解(local mean decomposition,简称LMD)改善了EMD中端点效应和迭代计算量大等问题,但依然存在端点效应、模态混叠以及噪声鲁棒性差等局限性^[8]。Dragomiretskiy等^[9]提出了VMD,该方法能够有效减少模态混叠问题,对采样和噪声具有较好的鲁棒性,可以降低复杂度高和非线性强的时间序列非平稳性^[10]。

VMD算法存在需要预先设定若干参数,且对信号分解的效果取决于自身参数的设置^[11-12]。目前,提高VMD适应性的方法主要有2类:①通过哈里斯鹰优化算法与鲸鱼优化算法等进行参数寻优;②基于先验知识,对信号频谱进行分析,估算信号的共振频带数量,依照过往经验设定对应的参数。陈春俊等^[10]利用哈里斯鹰优化算法对VMD参数寻优,从而达到对轴箱轴承故障的精准识别。Li等^[13]提出一种基于频谱分割的自适应能量约束VMD滚动轴承故障检测方法。当对不同信噪比的信号进行分解时,效果也不一样,这是由于参数的选取与信号的成分及信噪比有关。

智能算法寻优效果取决于构建的适应度函数,智能算法本身存在局部最优的缺陷,并且过多的算法将导致整个分解过程变得复杂。从信号自身特性

* 国家自然科学基金资助项目(72401261,52075496);浙江省重点研发计划资助项目(2024C01136)

收稿日期:2024-06-11;修回日期:2024-12-26

出发的VMD参数选取方法自适应性较差,并且需先确定分解层数 K 再确定二次惩罚因子 α ,忽略了参数之间的相互影响,而借助专家经验或先验知识来选取分解参数的方法,自适应能力欠佳,而且还有可能引发较大的误差^[14]。

为了有效开展电梯曳引系统进行故障诊断,笔者提出一种基于IVMD-GA-KELM的曳引系统故障诊断方法。首先,采集曳引系统振动信号,根据动态时间规整算法和残余能量熵占比指标自适应确定参数 K 和 α 的最优值并进行VMD;其次,根据最大峭度准则选取分量构建时频特征集;然后,考虑到KELM具有更快的训练速度和更高的泛化能力^[15],采用了基于遗传算法优化的KELM作为故障分类器;最后,搭建试验装置并开展故障注入试验,对所提出方法进行验证。

1 改进变分模态分解

1.1 VMD

VMD主要涵盖2个部分:①构造变分问题;②求解变分问题^[9]。首先,将分解的信号进行希尔伯特黄变换,引入单位脉冲信号 $\delta(t)$ 和指数项 $e^{-j\omega_k t}$,得到第 k 个分量的频谱为

$$H_k = [(\delta(t) + \frac{j}{\pi t}) * u_k(t)] e^{-j\omega_k t} \quad (1)$$

其中: $u_k(t)$ 为分解得到的 k 个模态分量; ω_k 为各模态分量的中心频率; $e^{-j\omega_k t}$ 为复数信号在时域内旋转的矢量; $j = \sqrt{-1}$ 。

为求解变分模型的最优解,在约束变分模型中引入二次惩罚因子 α 以及拉格朗日乘法算子,构造的增广拉格朗日函数为

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_{k=1}^K \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} & \sum_{k=1}^K u_k(t) = f(t) \end{aligned} \quad (2)$$

其中: $f(t)$ 为待分解信号。

为搜索增广拉格朗日函数鞍点,引入交替方向乘子迭代算法,交替寻优迭代后的 u_k , ω_k 和 λ , $\hat{u}_k^{n+1}(\omega)$, $\hat{\lambda}_k^{n+1}(\omega)$ 的迭代公式分别为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \gamma(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (4)$$

ω_k^{n+1} 的计算公式为

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega \left| \hat{u}_k^{n+1}(\omega) \right|^2 d\omega}{\int_0^\infty \left| \hat{u}_k^{n+1}(\omega) \right|^2 d\omega} \quad (5)$$

其中: γ 为噪声容忍度; $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{f}(\omega)$ 和 $\hat{\lambda}(\omega)$ 为对应项的傅里叶变换。

1.2 动态时间规整算法

动态时间规整算法主要包括构建距离矩阵 D 、寻找最优规整路径 w_{best} 和计算距离 $L_{a,b}$ ^[16]。

首先,计算 a, b 序列任意两点之间的距离 $\lambda(i, j)$,即

$$\lambda(i, j) = \|x_i - y_j\| \quad (6)$$

其中: x_i, y_j 为 a, b 序列元素。

得到距离矩阵 D 为

$$D = \begin{bmatrix} \lambda(1, 1) & \cdots & \lambda(1, m) \\ \vdots & & \vdots \\ \lambda(n, 1) & \cdots & \lambda(n, m) \end{bmatrix}$$

其次,求解距离矩阵 D 的最优路径 w_{best} ,计算公式为

$$w_{\text{best}} = \{w_1, w_2, \dots, w_z\} \quad (7)$$

其中: w_z 为距离矩阵中的第 z 个元素; z 为最优路径中的总元素数。

此时,式(7)需满足2个约束条件:① $w_1 = (1, 1)$, $w_z = (m, n)$;②若 $w_z = (a', b')$, $w_{z-1} = (a, b)$, 则 $0 \leq a' - a \leq 1$, $0 \leq b' - b \leq 1$ 。

最后,计算序列之间的距离 $L_{a,b}$,即

$$L_{a,b} = \min_w \left\{ \frac{1}{z} \sum_{i=1}^z \lambda(p_i) \right\} \quad (8)$$

其中: $\lambda(p_i)$ 为最优路径 w_{best} 中第 i 个元素在距离矩阵中的距离。

1.3 改进的VMD

VMD对信号分解的优劣程度取决于分解层数 K 和二次惩罚因子 α 的选取。若 K 取值过大,则会造成信号过度分解,使本属于同一中心频率的分量被分解成2个分量;若 K 取值过小,则会导致信号分解不够充分,影响后续故障特征提取的精度和诊断准确率。 α 的取值在很大程度上决定了各IMF的寻优区间范围,即 α 越大,搜索范围越窄,反之搜索范围越宽。当搜索范围变宽时,迭代速度加快,同时也会出现模态混叠风险上升的问题。相对的,更狭窄的搜索范围可能导致寻优过程陷入局部最优解的困境,且迭代速度也会相应减慢。

笔者根据原始信号的频谱分布特性,初步筛选出频域特征明显的分量数,从而确定参数 K 的最优取值区间,并选择排列熵指标来衡量 α 值的优劣性。排列熵指标越大,则说明分解效果越差。残余能量熵占比是指分解后残余信号的能量占总能量的比例,用于评估分解是否充分。该参数越小,表明分解越充分,信号特征提取越完整。笔者采用的VMD参数自适应确定方法的步骤如下。

1) 确定参数 K 的取值范围。对振动信号进行快速傅里叶变换,计算其信息熵参数 S ,从而确定分解层数 K 的取值范围,即 $K \in [K_0, K_0 + S]$ 。其中: K_0 为未被噪声淹没的频谱峰值数; S 为信号的信息熵参数,可有效反映信号的复杂度和不确定性。较高的信息熵表明信号较为复杂,可能需要较大的分解层数 K 进行分解;较低的信息熵表明信号较为简单,所需的分解层数 K 较小。利用信息熵参数 S 可以动态调整模态范围,确保自适应性。 S 的计算公式为

$$S = [H(x)] = \left[-\sum_{k=1}^K p_k \log_2(p_k) \right] \quad (9)$$

其中: p_k 为第 k 个模态的概率分布。

2) 确定参数 α 的寻优范围。首先,根据文献[17],将参数 α 的初始取值区间设为 $[620, 8000]$;

其次,根据等分区搜索思想(equal-interval search, 简称EIS),选取点 α_m 和 α_n ,将初始取值区间划分成3个相等子区间;然后,分别计算参数组合 $[x, \alpha_m]$ 和 $[x, \alpha_n]$ 分解后的排列熵指标 Z_m 和 Z_n ,当 $Z_m > Z_n$ 时, α 的最优取值区间为 $[\alpha_m, 8000]$;当 $Z_m < Z_n$ 时, α 的最优取值区间为 $[620, \alpha_n]$;最后,在最优取值区间,以 $\Delta\alpha$ 为步长计算不同 α 值的排列熵值,选取排列熵最小的 α 值作为最优值。排列熵 Z_i 的计算公式为

$$Z_i(n) = -\sum_{j=1}^{n!} P_j \ln P_j \quad (10)$$

其中: n 为信号的维数; P_j 为序列的概率分布。

3) 确定最优参数组合 $[K_{\text{opt}}, \alpha_{\text{opt}}]$ 。通过计算残余分量能量熵占比 REP_i 来判断当前 K 值下信号是否被充分分解, REP_i 的计算公式为

$$\text{REP}_i = \frac{\int_{-\infty}^{\infty} |f(t)|^2 dt - \sum_{k=1}^K \int_{-\infty}^{\infty} |u_k(t)|^2 dt}{\int_{-\infty}^{\infty} |f(t)|^2 dt} \quad (11)$$

通过计算相邻分量的相关度,来判断相邻分量是否为同一分量被过度分解,最终获得最优参数组合 $[K_{\text{opt}}, \alpha_{\text{opt}}]$ 。

图1为改进变分模态分解算法流程图。




图1 改进变分模态分解算法流程图

Fig.1 Flowchart for improved variational mode decomposition

2 基于遗传算法优化的核极限学习机

2.1 核极限学习机

KELM是在极限学习机^[18]的基础上引入核函数以提高模型精度。核函数 Ω_{ELM} 为

$$\Omega_{ELM} = HH^T = h(x_i)h(x_j) = K(x_i, x_j) \quad (12)$$

其中: x_i, x_j 为输入向量; H 为隐含层输出矩阵。

KELM的输出可以表示为

$$f(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix} \left(\frac{I}{C} + \Omega_{ELM} \right)^{-1} U \quad (13)$$

其中: $x_1, x_2, \dots, x_n$ 为给定的训练样本; $K(x_i, x_j)$ 为核函数; U 为期望输出矩阵; I 为单位矩阵; C 为正则化系数。

笔者选择了高斯径向基核函数 $K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}}$,其中 σ 为尺度参数。

2.2 基于遗传算法优化的核极限学习机

KELM的难点在于参数的选取,遗传算法是一种随机全局寻优算法,其通过模拟自然界生物进化机制,对目标参数进行随机全局搜索与优化。本质上,这是一种高效且并行的全局搜索方法。与一般迭代方法相比,此方法能够规避陷入局部最优解的难题,有效发挥其独特优势。

通过使用遗传算法对KELM的正则化系数 c 和核函数参数 σ 进行优化,核心思想是利用训练集对 c, σ 进行循环迭代,最终得到KELM的最优参数值。图2为遗传算法优化KELM流程图,其步骤如下:




图2 遗传算法优化KELM流程图

Fig.2 Flowchart for optimizing KELM by GA

- 1) 建立 KELM 网络模型与训练样本;
- 2) 通过对 KELM 网络模型的权值和阈值进行编码,得到初始种群;
- 3) 通过解码得到优化后的权值和阈值,用训练样本对网络进行训练,计算初始种群适应度;
- 4) 从中选择出适应度高的染色体进行复制,经历交叉变异得到新种群;
- 5) 判断是否满足终止条件,若不符合,则重复步骤3~4;若符合,则解码获得最优参数 c 和 σ 。

利用遗传算法对KELM参数 c 和 σ 进行迭代寻优,得到训练后的KELM分类模型可提高分类模型的精度和准度。

3 试验验证

为了验证所提出方法对电梯曳引系统故障诊断的有效性和准确性,采用故障注入法模拟电梯曳引系统发生的故障。本试验采用型号为6310深沟球轴承、钢丝绳直径为10 mm、采用压电式1A116E单轴振动传感器,其灵敏度为 $10.38 \text{ mV}/(\text{m}\cdot\text{s}^{-2})$,采用DH5922D多通道动态信号测试分析仪采集振动信号。曳引系统的主要故障包括:曳引轮轴承故障、反绳轮不对中故障和钢丝绳缺陷故障等。围绕这3种故障开展故障注入试验:①在曳引轮轴承滚动体上通过电火花加工注入点蚀故障,模拟曳引轮轴承故障;②通过调节反绳轮左右端固定螺栓,模拟反绳轮不对中故障;③通过在钢丝绳上切割深度为2 mm的裂纹来模拟钢丝绳故障。图3为曳引系统故障示意图。



图3 曳引系统故障示意图

Fig.3 Schematic of traction system's faults

试验电梯及信号采集设备如图4所示。

试验时,分别采集曳引轮轴承故障、反绳轮不对中故障和钢丝绳缺陷故障这3种故障状态下的振动信号。曳引系统故障状态下的振动信号如图5所示。




图 4 试验电梯及信号采集设备

Fig.4 Experimental elevator and signal acquisition equipment




图 5 曳引系统故障状态下的振动信号

Fig.5 Vibration signal of the traction system with faults

对上述 3 种故障信号进行分析,得到每种信号的最优分解参数并进行 VMD 分解,基于 IVMD 曳引系统故障信号分解效果如图 6 所示。

将正常状态、曳引轮轴承故障、反绳轮不对中故障和钢丝绳缺陷故障标签分别设置为 1、2、3 和 4。采集上述故障工况信号各 30 组、正常工况信号 10 组,共 100 组信号总量,提取时、频域特征指标构建 100×16 的特征指标集。将 40 组特征作为训练样本




图 6 基于 IVMD 曳引系统故障信号分解效果

Fig.6 Decomposition effect of traction system faults based on IVMD

训练分类模型,将余下 60 组样本作为测试样本,用于分类测试。笔者采用 IVMD-KELM 与所提出的 IVMD-GA-KELM 这 2 种方法对测试样本开展故障诊断与识别。图 7 为基于 2 种方法的曳引系统故障分类结果。图 8 为基于 IVMD-GA-KELM 的曳引系统故障分类混淆矩阵。

由图 7、8 可知,钢丝绳缺陷故障的故障识别率为 85.7%,相对较低,其原因主要在于钢丝绳发生缺




图7 基于2种方法的曳引系统故障分类结果

Fig.7 Classification results of traction system faults based on the 2 methods

输出类	1	14 23.3%	0 0%	0 0%	0 0%	100% 0%
	2	0 0%	20 33.3%	0 0%	1 1.7%	95.2% 4.8%
	3	0 0%	0 0%	12 20.0%	1 1.7%	92.3% 7.7%
	4	0 0%	0 0%	0 0%	12 20.0%	100% 0%
		100% 0%	100% 0%	100% 0%	85.7% 14.3%	96.7% 3.3%
		1	2	3	4	

图8 基于IVMD-GA-KELM的曳引系统故障分类混淆矩阵

Fig.8 Confusion matrix for traction system fault classification based on the IVMD-GA-KELM

陷故障时,会引起电梯多部件的大幅振动,使得故障特征被无用信号淹没,最终导致诊断准确率相对较低。笔者所提出方法对于电梯曳引系统的故障识别准确率达到96.67%,相较于未使用GA算法优化的KELM模型准确率提高了6.67%,从而验证了所提出方法的准确性。

t分布随机邻居嵌入(t-distributed stochastic neighbor embedding,简称t-SNE)是一种数据可视化工具,根据非线性降维结果表征当前数据的特征分布情况^[19]。为了对原始数据和分类后数据开展特征分布进行分析,笔者利用t-SNE开展了研究。图9、10分别为原始数据特征以及故障模型分类结果的t-SNE可视化结果。

由图9、10可知,原始数据特征分布分散且杂乱,经过笔者提出方法处理后,数据特征分布集中且




图9 原始数据特征t-SNE可视化结果

Fig.9 t-SNE visualization of original data features




图10 故障模型分类结果t-SNE可视化结果

Fig.10 t-SNE visualization of fault model classification results

更容易识别分类。

通过对试验结果分析可知,采用笔者提出的方法能够准确提取曳引系统故障特征、识别正常工况、曳引轮轴承故障以及反绳轮不对中故障,验证了所提出方法的正确性和合理性。

4 结 论

1) 在VMD参数寻优过程中,构建参数最优区间能够大幅减少算法的寻优时间和计算量,相较于全局步进方法,最优区间寻优速度提升一倍左右。

2) 基于动态时间规整算法和残余能量熵占比的方法能够自适应获得待分解信号的最优参数组合,通过VMD分解准确提取曳引系统故障特征,并成功诊断曳引系统全部故障。

3) KELM模型适用于电梯曳引系统故障识别,GA算法优化的KELM模型故障识别率达到96.67%,相较于KELM模型提升6.67%。

4) 所提出方法可有效用于曳引系统的单一故障,但对于同时存在多个故障的情形还需进一步研究。

参 考 文 献

- [1] WANG Q, CHEN L, XIAO G, et al. Elevator fault diagnosis based on digital twin and PINNs-e-RGCN [J]. Scientific Reports, 2024, 14(1): 30713.
- [2] 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.

- TAO Ran, XU Youcai, DENG Fanghua, et al. Fault feature extraction of vibration signal of elevator guide shoe based on SVD optimization LMD[J]. Journal of Vibration and Shock, 2017, 36(22): 166-171. (in Chinese)
- [3] LI C, MO L, KWONG C K, et al. Noise-robust multi-view graph neural network for fault diagnosis of rotating machinery[J]. Mechanical Systems and Signal Processing, 2025, 224: 112025.
- [4] 陈是杆, 彭志科, 周鹏. 信号分解及其在机械故障诊断中的应用研究综述[J]. 机械工程学报, 2020, 56(17): 91-107.
- CHEN Shiqian, PENG Zhike, ZHOU Peng. A review of signal decomposition and its application in mechanical fault diagnosis[J]. Journal of Mechanical Engineering, 2020, 56(17): 91-107. (in Chinese)
- [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 (1971): 454.
- [6] MEHDI Z, MOHAMMAD N N. End-effects mitigation in empirical mode decomposition using a new correlation-based expansion model[J]. Mechanical Systems and Signal Processing, 2023, 194: 110205.
- [7] GOSWAMI P, RAI R N. A novel methodology for chipped teeth and worn tooth gear fault detection using minimum entropy deconvolution and CEEMDAN[J]. Journal of Vibration Engineering & Technologies, 2025, 13(1): 11.
- [8] WANG J, LI J, WANG H, et al. Research on gearbox composite fault diagnosis based on improved local mean decomposition[J]. International Journal of Dynamics and Control, 2021, 9(4): 1411-1422.
- [9] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [10] 陈春俊, 周林春, 杨露. 基于平均自相关和优化VMD的轴箱轴承故障诊断[J]. 振动、测试与诊断, 2023, 43(2): 231-239.
- CHEN Chunjun, ZHOU Linchun, YANG Lu. Fault diagnosis of axlebox bearing based on average autocorrelation and optimized VMD[J]. Journal of Vibration, Measurement & Diagnosis, 2023, 43(2): 231-239. (in Chinese)
- [11] 计江, 赵琛, 王勇勤. 基于VMD-MMPE的轧机轴承滚动体与保持架故障诊断[J]. 振动、测试与诊断, 2023, 43(2): 290-297.
- JI Jiang, ZHAO Chen, WANG Yongqin. Fault diagnosis of rolling elements and cages of rolling mill bearings based on VMD-MMPE[J]. Journal of Vibration, Measurement & Diagnosis, 2023, 43(2): 290-297. (in Chinese)
- [12] 李国英, 王诗彬, 陈雪峰. 基于自适应EEMD的风电机组联轴器松动故障诊断[J]. 振动、测试与诊断, 2022, 42(2): 292-298.
- LI Guoying, WANG Shibin, CHEN Xuefeng. Fault diagnosis of wind turbine coupling looseness based on adaptive EEMD [J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2): 292-298. (in Chinese)
- [13] LI J, CHENG X, LI Q, et al. Adaptive energy-constrained variational mode decomposition based on spectrum segmentation and its application in fault detection of rolling bearing[J]. Signal Processing, 2021, 183: 108025.
- [14] LI Y, LEE C G, XU F. Multichannel intelligent fault diagnosis of hoisting system using differential search algorithm-variational mode decomposition and improved deep convolutional neural network[J]. Structural Control and Health Monitoring, 2022, 29(10): 1002.
- [15] MO D, WANG S, FAN Y, et al. Enhanced multi-constraint dung beetle optimization-kernel extreme learning machine for lithium-ion battery state of health estimation with adaptive enhancement ability[J]. Energy, 2024, 307: 132723.
- [16] ZHANG Z, TAVENARD R, BAILLY A, et al. Dynamic time warping under limited warping path length [J]. Information Sciences, 2017, 393: 91-107.
- [17] ZHANG M, JIANG Z, FENG K. Research on variational mode decomposition in rolling bearings fault diagnosis of the multistage centrifugal pump[J]. Mechanical Systems and Signal Processing, 2017, 93: 460-493.
- [18] HUANG G, HUANG G, SONG S, et al. Trends in extreme learning machines: a review[J]. Neural Networks, 2015, 61: 32-48.
- [19] 胡芑庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报, 2019, 55(7): 9-18.
- HU Niaoqing, CHEN Huipeng, CHEN Zhe, et al. Fault diagnosis method of planetary gearbox based on empirical mode decomposition and deep convolutional neural network[J]. Journal of Mechanical Engineering, 2019, 55(7): 9-18. (in Chinese)



第一作者简介:魏义敏,男,1986年6月生,博士、副教授。主要研究方向为机电设备状态监测、故障诊断和预测。曾发表《Influence of axial loads to propagation characteristics of the elastic wave in a non-uniform shaft》(《Chinese Journal of Mechanical Engineering》2019, Vol. 32, No.70)等论文。
E-mail: yiminwei@126.com

通信作者简介:潘骏,男,1974年12月生,博士、教授、博士生导师。主要研究方向为可靠性分析、设计与试验。
E-mail: panjun@zstu.edu.cn