

DOI:10.19651/j.cnki.emt.2211789

## 基于 IEWT-DELM 的行星齿轮箱故障诊断\*

贺全玲<sup>1</sup> 魏秀业<sup>1,2</sup> 赵峰<sup>1</sup> 王佳宁<sup>1</sup>

(1. 中北大学机械工程学院 太原 030051; 2. 中北大学先进制造技术山西省重点实验室 太原 030051)

**摘要:** 针对在恶劣情况下行星齿轮箱特征难以提取以及多种故障状态下难以准确分类这种问题,提出在经验小波变换基础上将原有频谱分解替换为在噪声干扰下更为稳定的尺度谱分解的改进经验小波变换与深度极限学习机相结合的故障诊断方法。首先,将行星齿轮箱不同故障工况下的信号利用改进经验小波变换分别进行降噪处理并提取各阶调频-调幅分量,之后选取包络幅值峭度较高的前6个分量多尺度样本熵作为故障特征集,输入到深度极限学习机中进行故障诊断分类,行星齿轮箱故障诊断试验表明:与 EWT、EMD 与 DELM 结合的故障诊断准确率相比,该方法故障平均识别率可达 97.6%,具有一定的有效性。

**关键词:** IEWT; MSE; DELM; 故障诊断; 信号处理

**中图分类号:** TH165 **文献标识码:** A **国家标准学科分类代码:** 460

## Planetary gearbox fault diagnosis based on IEWT-DELM

He Quanling<sup>1</sup> Wei Xiuye<sup>1,2</sup> Zhao Feng<sup>1</sup> Wang Jianing<sup>1</sup>

(1. School of Mechanical Engineering, North University of China, Taiyuan 030051, China;

2. Advanced Manufacturing Technology Key Laboratory of Shanxi Province, Taiyuan 030051, China)

**Abstract:** Aiming at the problem that it is difficult to extract the features of planetary gearboxes under harsh conditions and difficult to classify accurately under various fault states. Based on the Empirical Wavelet Transform, the Improved Empirical Wavelet Transform is proposed, which replaces the original spectrum decomposition with the scale-spectrum decomposition which is more stable under noise interference. A fault diagnosis method combining Improved Empirical Wavelet Transform and Deep Extreme learning machine. Firstly, the signals of the planetary gearbox under different fault conditions are denoised by IEWT respectively and the FM-AM components of each order are extracted. Then, Multiscale sample entropy of the first six components with higher Envelope spectrum kurtosis was selected as the fault feature set and input into DELM for fault diagnosis and classification. The results of planetary gearbox fault diagnosis test show that compared with the fault diagnosis accuracy of EWT, EMD and DELM, the average fault recognition rate of this method can reach 97.6%, which has certain effectiveness.

**Keywords:** IEWT; MSE; DELM; fault diagnosis; signal processing

## 0 引言

行星齿轮箱具有大传动比和重载特征,且被广泛应用在航空航天、汽车和重工等行业,因此极易发生故障,故行星齿轮箱的故障诊断受到了人们广泛的关注<sup>[1]</sup>。因齿轮箱内部结构复杂,工作环境恶劣,存在噪声大故障信号微弱特征难以提取等问题。针对此问题,李政等<sup>[2]</sup>提出最大相关峭度解卷积与经验小波变换结合的方法,李辉等<sup>[3]</sup>提出经验小波变换与极限学习机相结合的方法,胡璇等<sup>[4]</sup>提出利用连续平均谱负熵对经验小波变换改进的方法,Deng 等<sup>[5]</sup>

提出了一种自适应频域窗 EWT,引入一个频域宽度可变的滑动频域窗对轴承故障信号的傅里叶频谱进行分割,Wang 等<sup>[6]</sup>引入稀疏函数来引导 EWT,从而自动建立信号的傅里叶段,为进一步进行解调包络分析做准备,这些方法在一定程度上解决了在强噪声环境下特征提取困难进而导致故障难以分类的问题,EWT 在进行强噪声信号 Fourier 频谱分段时,极大值的选取经常陷入局部最优,导致分解出的信号分量混叠<sup>[7]</sup>。故将频谱划分换成尺度空间表示的尺度谱可以更好地解决这一问题。

本文利用改进经验小波变换(improved empirical

收稿日期:2022-10-22

\* 基金项目:山西省重点实验室开放课题研究基金(XJZZ202002)、山西省青年基金(201901D211201)项目资助

wavelet transform, IEWT)对故障信号进行特征提取,以包络幅值峭度(envelope spectrum kurtosis, ESK)为敏感分量筛选分解的分量,将筛选分量的多尺度样本熵(multiscale sample entropy, MSE)作为故障特征集输入深度极限学习机(deep extreme learning machine, DELM)对行星齿轮箱齿轮裂纹、齿根断裂以及齿轮磨损等故障进行分类,对比 EMD, EWT 与 DELM 相结合的诊断准确率,该方法具有较高的准确率。

### 1 基础理论

#### 1.1 改进 EWT 原理

EWT 方法的原理是将信号的 Fourier 谱划分成连续的区间,之后在每个区间上构造小波滤波器组进行滤波,最后通过信号重构得到一组调幅-调频分量<sup>[8]</sup>。具体步骤如下:

步骤 1)对故障信号进行傅里叶变换,将信号频谱定义在  $[0, \pi]$  范围内,并将  $[0, \pi]$  分为  $N$  个带宽不等的频带<sup>[11-13]</sup>。

步骤 2)基于 Littlewood-Paley 和 Meyer 小波的构造思想,  $\forall n > 0$ , 得到经验小波的尺度函数函数  $\hat{\phi}_n(\omega)$  和小波函数  $\hat{\psi}_n(\omega)$  的计算公式参照文献<sup>[9-10]</sup>。

其中,  $\gamma$  是决定小波框架的系数:

$$\gamma < \min_n \left( \frac{\omega_n - \omega_{n-1}}{\omega_n + \omega_{n-1}} \right), n = 1, 2, \dots, N \quad (1)$$

本文选取:

$$\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3), 0 < x < 1 \quad (2)$$

步骤 3)根据经验小波的尺度函数和小波函数即可得到经验小波的细节函数  $W_j^r(0, t)$  和近似函数  $W_j^r(n, t)$  计算公式如文献<sup>[11-13]</sup>。

步骤 4)根据细节函数和近似函数重构得到重构信号。

步骤 5)信号  $f(t)$  经 EWT 分解可以获得各分量信号  $f_i(t) (i=0, 1, \dots, k)$ 。

由于原频谱划分区间过于集中存在模态混叠现象,改进后的经验小波变换将信号的频谱替换为幅值谱与高斯核函数的卷积即信号频谱的尺度谱,如式(3)所示。

$$S(f, s) = g(f, s) \times X(f) = \sum_{\tau=-M}^{+M} g(\tau, s) X(f - \tau) \quad (3)$$

式中:  $g(f, s) = \frac{1}{\sqrt{2\pi s}} e^{-\frac{f^2}{2s}}$ ;  $M = 6\sqrt{s} + 1$ ;  $s$  为尺度参数。

尺度参数设置一般为  $s = 9 \times f_{ck}^2$ , 卷积步长为  $interval$ , 其中  $f_{ck}$  为行星齿轮箱故障特征频率。

#### 1.2 多尺度样本熵(MSE)

为了计算不同时间尺度下信号的复杂性, Richman 提出多尺度样本熵提高了复杂度估计值的准确率<sup>[14]</sup>。因故障情况复杂程度不同故选用样本熵值作为故障特征集。一般情况下,尺度因子范围为 3~20, MSE 算法如下:

步骤 1)对于时间序列  $\{x(i), i=1, 2, \dots, N\}$ , 利用式(4)定义粗粒化序列  $y(s)$ <sup>[15]</sup>。

$$y_j^{(s)} = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} x_i, 1 \leq j \leq \frac{N}{s} \quad (4)$$

式中:  $s$  为尺度因子。

步骤 2)计算不同尺度因子  $s$  下粗粒化序列  $y(s)$  的样本熵值,即多尺度样本熵如式(5)<sup>[16]</sup>:

$$E_{MSE}(x, s, m, r) = E_{SE}(y^{(s)}, m, r) = -\ln \left( \frac{n_s^{(m+1)}}{n_s^{(m)}} \right) \quad (5)$$

式中:  $m$  为嵌入维数;  $r$  为相似容限;  $ESE(\ast)$  为样本熵值;  $n_s^{(m)}, n_s^{(m+1)}$  分别为粗粒化序列的  $m$  维,  $m+1$  维空间向量个数。

#### 1.3 深度极限学习机原理(DELM)

极限学习机(ELM)用来训练单隐藏层前馈神经网络于传统的基于前馈神经网络训练算法不同,极限学习机随机选择输入层权重和隐藏层偏置,输出层权重通过最小化训练误差项和输出层权重范数的正则项构成损失函数,最后根据 Moore-Penrose 广义逆矩阵理论计算求解<sup>[17]</sup>。

深度极限学习机(DELM)利用极限学习机与自动编码器相结合,形成极限学习机-自动编码器(ELM-AE),结构如图 1 所示,将 ELM-AE 作为无监督学习的基础单元对输入数据进行训练与学习,并保存 ELM-AE 由最小二乘法获得的输出权值矩阵用于堆栈多层极限学习机(ML-ELM)。相比于其他深度学习方法,深度极限学习机省去微调,ELM-AE 与最终的 DELM 分类层(或回归层)使用最小二乘法得到并且只需反向计算便可得到更新后的权重,最大限度地降低重构误差让输出可以无限接近原始输出,其输出表达式为式(6)<sup>[18-19]</sup>。

$$x_j = \sum_{i=1}^L \beta_i G(a_i, b_i, x_j), a_i \in R^m, \beta_i \in R^m, j = 1, 2, \dots, N, \mathbf{a}^T \mathbf{a} = \mathbf{I}, \mathbf{b}^T \mathbf{b} = 1 \quad (6)$$

式中:  $\mathbf{a}$  是  $a_i$  组成的矩阵,  $\mathbf{b}$  是  $b_i$  组成的向量。隐藏层的输出权重为式(7):

$$\beta = \left( \frac{1}{C} + \mathbf{H}^T \mathbf{H} \right)^{-1} \mathbf{H}^T \mathbf{X} \quad (7)$$

式中:  $\mathbf{X} = [x_1, \dots, x_N]$  是输入数据。




图 1 DELM 原理图

### 2 仿 真 验 证

#### 2.1 东南大学数据集描述

本文使用东南大学故障齿轮箱数据集来验证该方法的有效性,数据由传动系统动态模拟器收集,考虑到行星齿轮箱实际工作状态,在数据导入后又引入高斯白噪声,信噪比为-18 dB,工作情况转速-负载配置为 30-2,共有 5 种工况分别为齿根裂纹,轮齿折断,齿轮裂纹,齿面磨损,正常状态。每种工况选用行星齿轮箱  $x, y, z$  每个方向工作的各 40 000 个数据。采样时间选取为 5 s,采样频率为 2 kHz,齿轮箱试验台如图 2 所示。




图 2 东南大学试验台

#### 2.2 数据集信号处理

该试验台数据的原始信号频谱如图 3 所示,原始信号频谱由于加入噪声的原因无法实现对齿轮箱故障特征的有效提取,而将原始信号频谱换成频谱的尺度空间表示后,对原始信号进行降噪的同时将信号放大便于后期的分类识别。该数据集的行星齿轮箱故障特征频率为 20.21 Hz,故此设置尺度参数为 3 679.93,如图 4 所示为原始信号尺度谱。图 5 所示为 IEWT 尺度谱对比频谱划分结果,灰色虚线通过尺度谱划分的各个频段区间的极大值极小值拟合得到的重构信号,绿色虚线为原频谱划分边界,蓝色实线是由拟合曲线的局部极小值作为自适应频段来划分的各个频段,可以看到尺度谱自适应划分较频谱划分更为均匀。




图 3 原始信号的频谱

尺度频谱在经过划分之后得到一系列模态分量,以轮齿折断这一工况  $x$  方向数据为例,使用 IEWT 对数据点进行模态分解为 13 个模态分量,考虑故障种类分类准确性,故需要选取包含故障信号大幅值脉冲概率较大的分量进行




图 4 原始信号的尺度谱





图 5 信号的尺度谱划分

分析。ESK<sup>[20]</sup>反映振动信号冲击特性,因此,用 ESK 指标来衡量各分量中包含故障信息的丰富程度,ESK 指标越高,包含故障信息就越丰富,以 ESK 为敏感分量 IEWT 分解轮齿折断模态分解如图 6 所示。



(a) 模态分量IMF1-IMF6




图 6 IEWT 模态分量

2.3 数据集故障分类试验

由于存在分量冗余和虚假的状态,故以包络幅值峭度为指标选取 ESK 前六的分量进行下一步工作,则为 IMF1, IMF3, IMF4, IMF5, IMF11, IMF13,计算各分量的多尺度样本熵构造特征数据集,尺度因子选取 20,  $x, y, z$  三个方向,每组方向样本数选 18 组,共  $15 \times 18$  组样本作为故障特征集。之后将五种工况特征数据集输入到 DELM 模型当中,五种工况的标签分别设为 1、2、3、4、5,DELM 模型参数设置为正则化系数为 5,激活函数设置为 Relu,总数据集为 275 组样本数,训练集为总数据集 80%,测试集为 20%,则训练集 220 组,测试集为 55 组。标签细节信息如表 1 所示,部分特征数据如表 2 所示。

表 1 标签细节信息表

标签	状态	转速-负载(r/s-A)
1	齿根裂纹	30-2
2	轮齿折断	30-2
3	齿轮裂纹	30-2
4	齿面磨损	30-2
5	正常状态	30-2

为验证方法的有效性,展开了对比 IEWT, EWT, EMD,与 DELM 相结合诊断准确率的多次试验,样本数同前述一样,共 275 组数据,训练集 220 组,测试集 55 组,将

表 2 齿轮箱 5 种工况部分特征熵

多尺度样本熵						
	0.585 9	0.885 8	0.978 7	0.776 7	0.657 2	0.594 2
	0.581 3	0.893 2	0.983 3	0.775 0	0.657 0	0.598 5
1	0.578 2	0.888 1	0.981 0	0.764 6	0.649 1	0.590 3
	0.574 3	0.894 4	0.967 3	0.764 4	0.649 6	0.583 2
	0.577 2	0.895 3	0.966 5	0.766 0	0.652 4	0.585 0
	0.446 8	0.672 3	0.685 4	0.647 1	0.524 2	0.438 7
	0.446 1	0.668 9	0.682 3	0.656 0	0.523 9	0.438 6
2	0.445 8	0.663 6	0.684 1	0.669 3	0.527 3	0.437 7
	0.447 3	0.664 4	0.682 6	0.684 7	0.528 3	0.441 6
	0.446 7	0.668 4	0.691 7	0.681 5	0.532 8	0.435 5
	0.664 1	0.949 3	0.825 1	0.755 7	0.659 6	0.496 8
	0.673 2	0.953 9	0.836 9	0.758 8	0.657 6	0.492 9
3	0.673 1	0.951 8	0.831 1	0.765 3	0.662 8	0.494 2
	0.664 6	0.943 3	0.833 2	0.758 7	0.653 7	0.490 5
	0.661 9	0.941 6	0.838 6	0.759 9	0.646 8	0.490 8
	0.678 8	0.928 5	0.851 1	0.826 2	0.681 5	0.442 2
	0.679 3	0.925 9	0.854 1	0.822 6	0.677 0	0.445 5
4	0.680 8	0.931 0	0.861 7	0.824 8	0.675 1	0.443 4
	0.679 6	0.936 6	0.877 7	0.828 3	0.666 0	0.452 2
	0.678 4	0.943 1	0.886 8	0.826 4	0.664 9	0.451 5
	0.172 3	0.306 1	0.269 5	0.229 3	0.189 5	0.146 2
	0.172 5	0.305 9	0.271 2	0.232 2	0.188 8	0.146 9
5	0.172 7	0.305 1	0.269 8	0.233 7	0.189 3	0.147 7
	0.172 8	0.305 7	0.266 6	0.234 0	0.188 6	0.149 8
	0.173 0	0.305 6	0.268 1	0.234 0	0.189 4	0.151 4

五种工况行星齿轮箱样本经过多种数据处理方法输入到 DELM,多种方法准确率以及混淆矩阵如图 7、8 所示。

如图 7 所示 EWT 与 DELM 相结合的故障准确率为 96.4%,工况为正常状态有一定的诊断错误。图 8 所示 IEWT 进行信号处理之后输入到 DELM 模型当中故障诊断准确率为 98.2%,齿面磨损这一故障分类存在错误,通过图 7 和 8 的对比进一步验证了 IEWT 分解信号以及 IEWT 与 DELM 相结合对行星齿轮箱齿根断裂,齿轮裂纹,齿面磨损等故障诊断的有效性。同时如图 9 所示 EMD 与 DELM 相结合的故障诊断结果依旧没有 IEWT、EWT

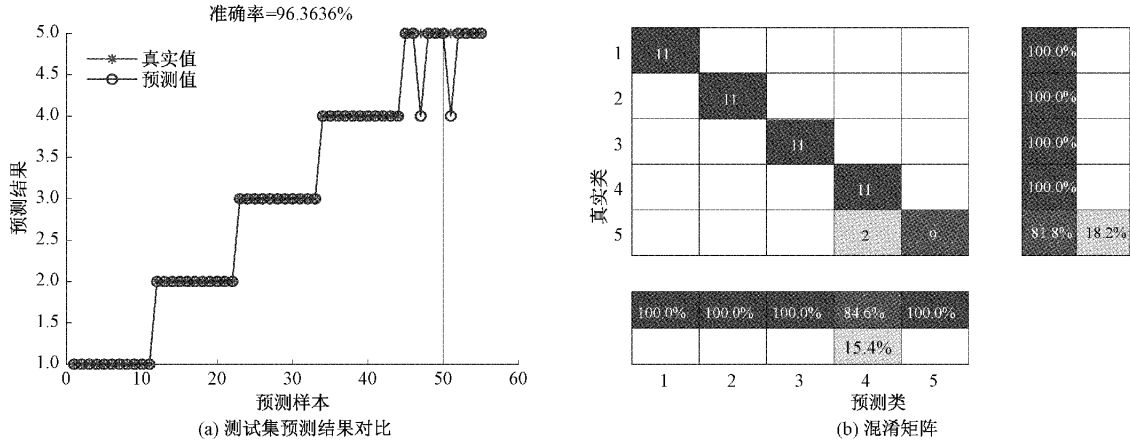


图 7 EWT 诊断准确率及混淆矩阵

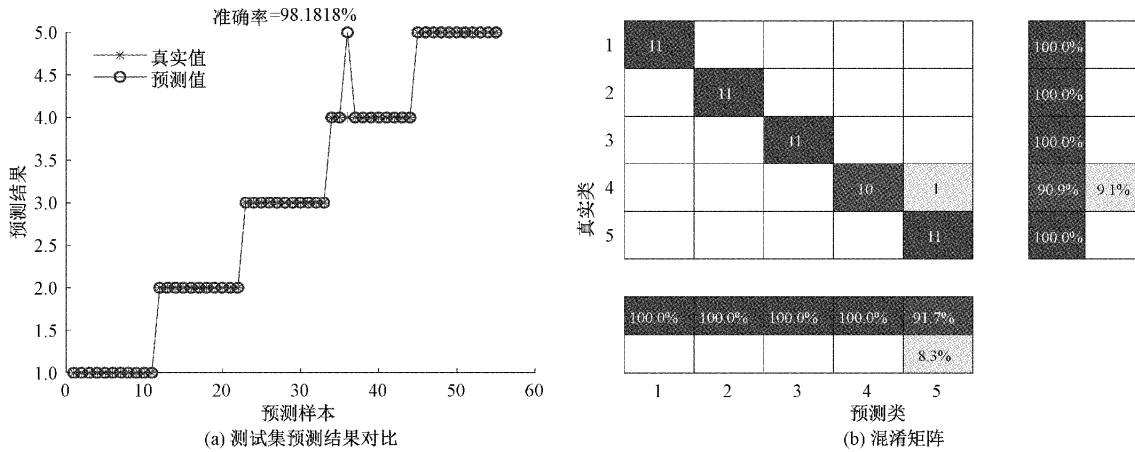


图 8 IEWT 诊断准确率及混淆矩阵




图 9 EMD 诊断结果

与 DELM 相结合的诊断准确率高,其中 EMD 准确率为 92.7%。通过对比论证,该方法具有一定的有效性和先进性。

为防止该方法准确率存在偶然性,分别对该数据集工作情况转速-负载配置为 30-2 和 20-0 进行了 5 次试验验证,并计算平均诊断精度,如表 3 所示两种转速-负载配置

下的试验结果,平均准确率均达到 98.2% 以上,进一步验证了方法的有效性。

表 3 5 次试验的诊断准确率 %

试验次数	30-2	20-0
1	98.2	100
2	100	98.2
3	98.2	98.2
4	96.4	100
5	98.2	98.2
平均值	98.2	98.92

### 3 实验验证

#### 3.1 行星齿轮箱平台搭建

为验证该方法在实际行星齿轮箱故障分类的有效性,搭建如图 10 所示的行星齿轮箱故障诊断实验台,由磁粉制动器充当负载,变频交流电动机为动力源<sup>[21]</sup>。对行星轮单齿裂纹,行星轮齿磨损,行星轮齿根断裂以及正常状态这 4 种工况的故障数据首先进行 IEWT 分解,设置电机转

动速度 1 500 rpm,采样频率为 10.24 kHz,负载为 0.3 A,采集各工况数据。




图 10 行星齿轮箱试验台

本次实验共选用了 4 种工况,每种工况选用 9 个测点的数据作为样本,各测点选用 10 000 个数据点,经 IEWT 处理后选用包络幅值峭度前六的分量进行多尺度样本熵处理,每个测点选用 5 组数据,尺度因子选择为 20,则故障特征集为 36×5 组,共 180 组样本数输入到 DELM 模型当中,正则化系数为 10,激活函数设置为 Relu,训练集为总数据集 70%,共 126 组,测试集为 30%,共 54 组。4 种工况标签细节信息如表 4 所示,测试集故障识别准确率如图 11 所示。

表 4 工况标签细节

标签	状态	负载/A
1	行星轮单齿裂纹	0.3
2	行星轮齿磨损	0.3
3	行星轮齿根断裂	0.3
4	正常状态	0.3




图 11 IEWT 诊断结果

从图 11 可知利用该方法故障分类准确率达到 98.2%,正常状态下一组样本分类错误,验证了 IEWT 与

DELM 相结合对齿轮裂纹、磨损以及齿根断裂这几种故障分类的有效性。

### 3.2 行星齿轮箱故障分类试验

为避免该诊断结果存在偶然性误差,同样对齿轮箱 4 种工况实施了 5 次试验,验证该方法的可靠性,每种方法样本数选取一样,同时对比 EWT、EMD 与 DELM 相结合的诊断准确率,计算五次实验的平均值。如表 5 所示 IEWT 与 DELM 相结合在实际行星齿轮箱故障实验中诊断准确率可达 97.6%。而其他方法与 DELM 相结合的准确率相比略低于该方法。

表 5 多种方法五次试验结果 %

试验次数	IEWT	EWT	EMD
1	98.2	95.3	95.3
2	97.5	97.5	94.5
3	96.7	95.3	94.5
4	97.5	96.7	95.3
5	98.2	96.7	95.3
平均值	97.62	96.3	95

## 4 结 论

本文提出一种新的自适应信号分解方法 IEWT 与深度极限学习机 DELM 相结合的行星齿轮箱故障诊断方法,首先 IEWT 提取信号尺度谱极大值点自适应地分割尺度谱以分理处不同的模式,相较于傅里叶频谱划分尺度谱在模式混叠方面也有所改进,之后在频域自适应地构造小波滤波器组从而构造正交小波函数,用来提取调幅-调频成分,最后将多组调幅-调频成分的多尺度样本熵构造故障数据集输入到 DELM 中,经过东南大学齿轮箱数据集仿真实验和搭建行星齿轮箱试验平台的多次对比试验,验证了该方法的准确率较其他信号分解方法输入到 DELM 更高,但该方法的鲁棒性还未验证,因此下一步研究方向计划验证该方法的鲁棒性,同时将其应用于采煤机内部行星齿轮箱进行工程实践验证该方法的可操作性。

### 参考文献

- [1] 魏秀业,程海吉,贺妍,等. 基于特征融合与 ResNet 的行星齿轮箱故障诊断[J]. 电子测量与仪器学报,2022, 36(5):213-222.
- [2] 李政,张炜,明安波,等. 基于 IEWT 和 MCKD 的滚动轴承故障诊断方法[J]. 机械工程学报,2019,55(23): 136-146.
- [3] 李辉,李宣,贾嵘,等. 基于 EWT-OPRCMDE-ELM 的风电机组齿轮箱故障诊断研究[J]. 自动化仪表,2021, 42(11):12-19.
- [4] 胡璇,李春,叶柯华. 改进经验小波变换在风力机齿轮箱故障诊断中的应用[J]. 机械强度,2022,44(2):

- 294-301.
- [5] DENG F, LIU Y. An adaptive frequency window empirical wavelet transform method for fault diagnosis of wheelset bearing in proc. prognostics Syst. [J]. Health Manage, 2018, 241(4): 1291-1294.
- [6] WANG D, ZHAO Y, YI C, et al. Sparsity guided empirical wavelet transform for fault diagnosis of rolling element bearings [J]. Mech. Syst. Signal Process, 2018, 101(2): 292-308.
- [7] 郭辉, 伍川辉, 刘泽潮, 等. 基于峭度与互相关的 IEWT 轴承故障诊断方法研究[J]. 铁道科学与工程学报, 2019, 16(7): 1774-1780.
- [8] 张思思, 刘玉波. 改进 EWT 与 HHT 边际谱结合的齿轮箱故障诊断方法[J]. 煤炭技术, 2021, 40(11): 220-223.
- [9] 张龙, 闫乐玮, 熊国良, 等. 基于 EWT-MCKD 的机车轮对轴承故障诊断[J]. 铁道科学与工程学报, 2021, 18(10): 2722-2732.
- [10] 李志农, 刘跃凡, 胡志峰, 等. 经验小波变换-同步提取及其在滚动轴承故障诊断中的应用[J]. 振动工程学报, 2021, 34(6): 1284-1292.
- [11] 唐志国, 李阳. 改进自适应无参经验小波变换在变压器高频局放电流噪声抑制中的研究[J]. 电网技术, 2022, 23(3): 1-12.
- [12] ZHI J L, TAO L, SHAO Z Y, et al. Revised empirical wavelet transform based on auto-regressive power spectrum and its application to the mode decomposition of deployable[J]. Structure, Journal of Sound and Vibration, 2018, 431(4): 70-87.
- [13] 胡少梁, 李宏坤, 王朝阁, 等. 基于 MEWT-ASCS 的行星齿轮箱微弱故障特征提取[J]. 振动. 测试与诊断, 2022, 42(3): 474-482, 615.
- [14] 靳震震, 贺德强, 苗剑, 等. 基于多尺度样本熵改进极限学习机的列车转向架轴承故障诊断[J]. 控制与信息技术, 2021(5): 66-70.
- [15] 王振亚, 姚立纲. 广义精细复合多尺度样本熵与流形学习相结合的滚动轴承故障诊断方法[J]. 中国机械工程, 2020, 31(20): 2463-2471.
- [16] 王斐, 房立清, 齐子元. 基于多尺度样本熵和 VPMCD 的自动机故障诊断[J]. 振动. 测试与诊断, 2018, 38(3): 564-569.
- [17] 兰杰, 李志宁, 吕建刚. 基于深度极限学习机的轴承故障诊断方法研究[J/OL]. 现代电子技术: 1-6[2023-03-18]. <http://kns.cnki.net/kcms/detail/61.1224.TN.20220616.1316.002.html>.
- [18] 张文帅, 王占刚. 基于改进麻雀算法优化深度极限学习机的缺失数据预测[J]. 电子测量技术, 2022, 45(15): 63-67.
- [19] 孙玮婷. 基于极限学习机的表征学习方法研究[D]. 大连: 大连理工大学, 2018.
- [20] 刘臻, 彭珍瑞. 信息熵和合成峭度优化的 VMD 和 PSO-SVM 的轴承故障诊断[J]. 机械科学与技术, 2021, 40(10): 1484-1490.
- [21] 程海吉, 魏秀业, 张宁, 等. 基于 ALNAFSA 优化 BP 神经网络的行星齿轮箱故障诊断[J]. 煤矿机械, 2021, 42(1): 143-146.

### 作者简介

贺全玲, 硕士研究生, 主要研究方向为机械故障诊断, 智能算法。

E-mail: 3102174445@qq.com