

DOI:10.19651/j.cnki.emt.2210458

基于 VMD-WOA-ELM 的电缆外力 破坏振动信号在线识别*

崔岩^{1,2} 方春华^{1,2} 文中¹ 许瑶¹ 张云杰¹ 侯正宇¹

(1.湖北省输电线路工程技术研究中心 宜昌 443002; 2.三峡大学电气与新能源学院 宜昌 443002)

摘要: 保障电力电缆的安全运行是建设新型智能电力系统的基础,为实现对外力破坏事件的数字化预警,提出基于 VMD-WOA-ELM 的外力破坏振动信号在线识别方法。首先,利用 VMD 将采集到的异常振动信号分解为若干本征模量函数分量(IMF),然后提取各 IMF 分量的时、频域特征值组成特征向量,最后采用极限学习机(ELM)进行振动信号类型识别,为解决 ELM 模型随机性选取初始权值和阈值导致的分类稳定性较差的问题,将鲸鱼优化算法(WOA)应用于 ELM 的参数寻优,从而获得最优分类模型。将该方法应用于施工振动信号类型识别实验,分别采集四种典型外破事件的振动信号各 100 组,将其中 80% 作为训练集,20% 作为测试集检验算法的识别性能,并与传统 ELM、PSO-ELM、GA-ELM 进行了对比。结果表明:在相同计算机运行条件下,WOA-ELM 对外破振动信号的分类准确度达 98.75%,相比传统 ELM 识别精度提高了 5%,且整体运行时间仅为 4.10 s。与另外两种算法相比,该算法识别精度最高、收敛速度最快,具有最优综合性能。

关键词: 外力破坏;变分模态分解(VMD);鲸鱼优化算法(WOA);极限学习机(ELM)

中图分类号: TM757 **文献标识码:** A **国家标准学科分类代码:** 470.4017

Online identification of cable external force damage vibration signal based on VMD-WOA-ELM

Cui Yan^{1,2} Fang Chunhua^{1,2} Wen Zhong¹ Xu Yao¹ Zhang Yunjie¹ Hou Zhengyu¹

(1. Hubei Transmission Line Engineering Technology Research Center, Yichang 443002, China;

2. College of Electricity and New Energy, China Threc Gorges University, Yichang 443002, China)

Abstract: Ensuring the safe operation of power cables is the basis of building a new intelligent power system. In order to realize the digital early warning of external force damage events, an online identification method of external force damage vibration signals based on VMD-WOA-ELM is proposed. Firstly, the collected abnormal vibration signal is decomposed into several intrinsic modulus function components (IMF) by VMD, then the time and frequency domain eigenvalues of each IMF component are extracted to form the eigenvector, and finally the extreme learning machine (ELM) is used to identify the type of vibration signal. In order to solve the problem of poor classification stability caused by the random selection of initial weights and thresholds of ELM model, whale optimization algorithm (WOA) is used to optimize the parameters of ELM to obtain the optimal classification model. This method is applied to the identification experiment of construction vibration signal type. The vibration signals of four typical breaking events were collected, and each signal has 100 groups. 80% of them were used as the training set and 20% as the test set to test the recognition performance of the algorithm. The algorithm is compared with traditional ELM, PSO-ELM and GA-ELM. The results show that under the same computer operating conditions, the classification accuracy of WOA-ELM is 98.75%, which is 5% higher than that of traditional ELM, and the overall running time is only 4.10 s. Compared with the other two algorithms, this algorithm has the highest recognition accuracy, the fastest convergence speed and the best comprehensive performance.

Keywords: external force damage; variational modal decomposition (VMD); whale optimization algorithm (WOA); extreme learning machine (ELM)

0 引 言

新型电力系统的运行正向着数字化、智能化的方向发

展,电力设备需要具备自主感知与实时预警的智慧功能。高压电缆被广泛用于输变电工程建设中,但由于部分施工单位对电力设施保护意识淡薄、电力运维部门与城建衔接

收稿日期:2022-06-24

* 基金项目:国家自然科学基金(51807110)项目资助

存在漏洞以及人为偷盗等因素,导致电缆被损坏的事故频发,严重影响电网正常运行和人民财产安全^[13]。挖掘机和冲击锤等重型设备的施工和人工开挖经常造成电缆本体的直接损坏,重型车辆碾压引起的地面沉降会导致电缆发生错位或变形,严重时会造成缺陷故障^[4-6]。因此,快速准确地识别上述四种典型的外力破坏事件,实现对外力破坏事件的自主感知和实时预警,对电缆的安全运行具有重要意义。

目前,通过实时监测电缆周界振动信号实现对入侵事件的识别已成为防外力破坏的主要手段之一^[7-10]。Seedahmed等^[7]通过提取振动信号的持续时间、过零率、最大振幅等特征组成特征向量,利用人工神经网络及决策树进行外破信号识别,取得了良好效果。盛智勇等^[8]获得振动信号频谱后,将信号在各频段的能量占比特征作为特征向量,利用线性判别分析分类器实现了信号类型的有效识别。本文研究的4种外破信号均为非平稳信号,仅通过提取时域特征或频域特征很难完全反映信号的整体特征。而传统时频方法如小波类方法存在高频分辨率不足,小波基难以选取等缺点^[9];经验模态分解(EMD)容易受到信号间断、奇异点的影响,导致模态混叠和端点效应^[10]。

变分模态分解(variational modal decomposition, VMD)是由 Dragomiretskiy 等于 2014 年提出的一种新的非稳态、非线性信号分析方法^[11]。采用交替方向乘子法(ADMM)获取变分模型的最优解,使得每个模态的频带宽度之和最小,实现信号的自适应分解。目前已在振动信号处理、机械故障诊断、通讯技术等领域被广泛使用^[12-16]。尚秋峰等利用 VMD 对海缆振动信号进行分解,通过提取 IMF 分量的相关特征值,实现了对锚砸、冲刷、摩擦三种工况下振动信号的识别^[14]。张炎亮等^[15]为有效提取非平稳性、复杂性的滚动轴承振动信号特征,将 VMD 算法用于信号分解及特征提取,实现了对滚动轴承故障的有效诊断。王磊等将变分模态分解用于雷达辐射源个体识别方法,并与传统经验模态分解算法进行对比分析,可以验证 VMD 算法解决了传统 EMD 在递归模式分解过程中的模态混叠、对频率相近的分量无法正确分离、受采样频率影响等缺点,且时频分辨率强,稳定性高^[16]。因此,本文基于 VMD 分解提取各个模态分量的时频特征作为信号的特征值。其中能量熵可以用来表征各 IMF 分量的能量分布;峭度因子、波形因子可用于反映信号的冲击特性和信号平缓程度;重心频率和频率标准差能够体现信号在频域上的分布特征。将能量熵、峭度因子、波形因子、重心频率和频率标准差组合作为特征向量更有助于提升外破信号类型识别的准确率。

传统机器学习算法如 BP 神经网络存在对初始网络权重敏感、收敛速度慢、容易陷入局部最优等问题^[17];支持向量机(SVM)运算时间长、运行内存大、对于多分类问题效果不理想^[18]。由黄广斌提出的极限学习机(extreme learning machine, ELM)是一类具有快速学习能力的单隐层神经网络,解决了传统神经网络的反馈式误差更新低

效等问题,具有更高的训练效率和识别准确率,目前已被广泛应用于各种回归和分类问题中。陈泽等人将极限学习机用于识别矿山微震事件,杨明莉等人将极限学习机用于高光谱遥感图像的分类,均取得了良好的分类效果^[19-20]。王涛等人利用极限学习机实现了光伏阵列故障检测与区域定位,并与支持向量机、多层感知神经网络和随机森林算法的分类效果进行比较,证明了极限学习机具有更加优异的分类性能^[21]。但在建立 ELM 模型时初始权值和阈值的随机性选取导致 ELM 模型的隐含层输出矩阵随着训练样本变换而产生较大差异。为了解决此问题,本文引入鲸鱼优化算法(whale optimization algorithm, WOA)对极限学习机进行优化改进,通过迭代寻优获得最佳网络参数以提高极限学习机的稳定性和泛化能力,WOA 算法与其他智能优化算法相比,具有更快的收敛速度,鲁棒性更高^[22]。

综上,本文提出基于 VMD-WOA-ELM 算法用于识别挖掘机施工、破碎锤施工、人工挖掘和重型车辆经过四类典型外力破坏振动信号。首先使用 VMD 直接对采集信号进行分解获得 4 个 IMF 分量,然后求得各个分量的能量熵、峭度因子、波形因子、重心频率和频率标准差共 20 个特征值组成特征向量输入到 WOA 优化的 ELM 中实现振动信号类型的识别。使用 VMD-WOA-ELM 可以准确、快速地识别上述四类外破振动信号,识别准确率达 98.75%,算法收敛速度快、识别准确率高,为实现外力破坏事件的精准识别提供了一种有效分类方法。

1 VMD-WOA-ELM 算法基本原理

1.1 变分模态分解

VMD 分解可将振动信号分解为多个调幅调频分量信号的集合,每个“模态分量”为具体中心频率的有限带宽,对信号进行迭代求解,使得每个模态的估计带宽之和最小,据此实现振动信号的自适应分解。固有模态函数(IMF),即是通过幅频调制的谐波信号。

K 阶 IMF 分量可表示为:

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

式中: $A_k(t)$ 表示 $\mu_k(t)$ 的瞬时幅值; $\varphi_k(t)$ 表示 $\mu_k(t)$ 的瞬时频率, $\mu_k(t)$ 代表一组离散子信号,每个子信号在时频谱中的带宽稀疏不同。

VMD 分解过程如下:

1) 变分问题构建。约束变分模型表达式为:

$$\left\{ \begin{array}{l} \min_{\{\mu_k, \omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \mu_k(t) \right] e^{j\omega_k t} \right\|_2^2 \right\} \\ s. t. \sum_k \mu_k = x(t) \end{array} \right. \quad (2)$$

式中: $x(t)$ 为振动信号, $\mu_k(t)$ 为 $x(t)$ 分解后得到的模态分量; k 为分解的所有模态分量数量,本文取 $k = 6$; ω_k 为 IMF 分量的中心频率。

2) 变分问题求解。引入二次惩罚因子 α 以提高信号重构精度,本文取 $\alpha = 200$ 。

$$L(\{\mu_k\}, \{\mu_k\}, \lambda) = \alpha \sum_k \left\| \partial t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \mu_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| x(t) - \sum_k \mu_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k \mu_k(t) \rangle \quad (3)$$

式中: λ 为拉格朗日惩罚算子。

3) 交替更新。利用交替方向乘子算法求取式(3)的“鞍点”从而获得约束变分模型的最优解, 迭代方程为:

$$\hat{\mu}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i < k} \hat{\mu}_i^{n+1}(\omega) - \sum_{i > k} \hat{\mu}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (4)$$

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

$$\hat{\lambda}^n(\omega) + \gamma(\hat{f}(\omega) - \sum_k \hat{\mu}_k^{n+1}(\omega)) \rightarrow \hat{\lambda}^{n+1}(\omega) \quad (6)$$

式中: $|\hat{\mu}_k(\omega)|$ 表示每个 IMF 分量对应的维纳滤波; γ 为噪声容限, n 为迭代次数; $\hat{f}(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别为 $f(t)$ 、 $\lambda(t)$ 对应的频域形式; ω_k^{n+1} 为 IMF 分量的中心频率。本文取 $\gamma = 0, n = 100$ 。

4) 迭代停止。设定阈值 ϵ , 当满足条件:

$$\frac{\sum_k \left\| \hat{\mu}_k^{n+1}(t) - \hat{\mu}_k^n(t) \right\|_2^2}{\left\| \hat{\mu}_k^n(t) \right\|_2^2} < \epsilon \text{ 时, 迭代停止, 输出 } \hat{\mu}_k(\omega)、$$

$\hat{\omega}_k(t)$, 再利用傅里叶反变换获得各个 IMF 分量, 完成求解。

1.2 特征提取

指定 VMD 分解层数为 4 层, 对振动信号分解后得到 4 个 IMF 分量, 对每一个 IMF 分量提取能量熵、峭度因子、波形因子、重心频率和频率标准差, 将所得 20 个特征值进行组合作为该信号的特征向量。

能量熵可以体现各个模态分量的能量分布, 第 i 个模态分量的能量 E_i 定义为:

$$E_i = \sqrt{\frac{\sum_{j=1}^n x^2(j)}{n}} \quad (7)$$

则该分量的能量熵 p_i 为:

$$p_i = -e_i \log_2 e_i \quad (8)$$

式中: $x(i)$ 为第 i 个模态分量, $i = 1, 2, \dots, 6, n$ 为信号分解层数, 本文设 $n = 6, e_i$ 表示第 i 个模态分量能量与整个信号能量之比。

峭度因子和波形因子作为无量纲时域特征, 可避免同种信号因幅值大小的不同对识别效果产生影响, 峭度 K_u 和波形因子 f 表达式如下:

$$K_u = \frac{\sum_{i=1}^n (x(i) - \bar{x})^2}{(n-1)\sigma^4} \quad (9)$$

$$f = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (x(i))^2}}{\frac{1}{n} \sum_{i=1}^n |x(i)|} \quad (10)$$

式中: $x(i)$ 表示模态信号序列, σ 表示信号的标准差, \bar{x} 为信号均值, n 为采样长度。

重心频率和频率标准差属于无量纲频域特征, 能够描述信号在频谱中分量较大的信号成分的频率, 反应信号功率谱的分布情况, 中心频率 ω 和频率标准差 μ 的表达式为:

$$\omega = \frac{\sum_{k=1}^K f_k \cdot s(k)}{\sum_{k=1}^K s(k)} \quad (11)$$

$$\mu = \sqrt{\frac{\sum_{k=1}^K f_k^2 \cdot s(k)}{\sum_{k=1}^K s(k)}} \quad (12)$$

式中: $s(k)$ 为信号频谱, $k = 1, 2, \dots, K, K$ 为谱线数, f_k 表示第 k 条谱线的频率值。

1.3 极限学习机

极限学习机(ELM)是由 Huang 等提出的一种单隐层前馈神经网络, 其结构由输入层、隐含层和输出层构成。ELM 获得最优解的过程如下:

设定 N 个不同的样本 $(x_i, t_i), i = 1, 2, \dots, N, L$ 个隐含层神经元, 激活函数为 $g(x)$ 的 ELM 的数学表达式为:

$$y_j = \sum \beta_j g(\omega_j x_i + b_j) \quad (13)$$

式中: $j \in 1, 2, \dots, L, \omega_j$ 为输入和隐含层神经元的权值; b_j 为隐含层神经元的阈值; β_j 为隐含层和输出层神经元的权值, $g(\omega_j x_i + b_j)$ 为隐含层神经元的输出。

为与期望输出结果靠近, 存在 ω_j, b_j, β_j , 使得:

$$\sum_{i=1}^N \beta_j g(\omega_j x_i + b_j) = t_i, i = 1, 2, \dots, N \quad (14)$$

与单隐含层神经网络相似, 式(12)可表示为:

$$H\beta = T \quad (15)$$

式中: H 为隐含层神经元的输出矩阵, T 为 ELM 网络的目标输出, 即 $T = \{t_i\}_{i=1}^N$, 于是上式可变成权值矩阵的最小二乘解问题, 即:

$$\| H\hat{\beta} - T \| = \min_{\beta} \| H\beta - T \| \quad (16)$$

可求出输出权值矩阵 $\hat{\beta}$ 为:

$$\hat{\beta} = H^+ T \quad (17)$$

式中: H^+ 为 H 的 Moore-Penrose 广义逆矩阵。

利用 ELM 建立振动信号识别模型如图 1 所示。输入层由 20 个神经元构成, 分别输入 20 个特征值, 分别是 $p_1, p_2, p_3, \dots, p_{20}$, 隐含层的个数为 L , 输出结果为振动源类型, 输出层神经元个数为 1, 将挖掘振动定义为标签类型 1, 破碎锤振动定义为标签类型 2, 人为挖掘定义为标签类型

3, 重型车辆经过定义为标签类型 4。




图 1 ELM 模型

1.4 鲸鱼优化算法 WOA 基本原理

WOA 算法的核心思路是模拟座头鲸包围猎物、攻击猎物、搜索猎物等捕食行为, 获得猎物的最终坐标位置, 也即迭代后的最优解。WOA 的基本原理如下:

1) 包围捕食阶段

WOA 首先假设当前最佳候选解为近似最优解, 在确定最佳搜索代理后, 其他搜索代理将会尝试向最佳搜索代理更新它们的位置坐标, 这种行为由式(18)、(19)表示:

$$D = |CX^*(t) - X(t)| \tag{18}$$

$$X(t+1) = X^*(t) - AD \tag{19}$$

式中: t 为当前迭代次数, A 和 C 为随机系数向量, $X^*(t)$ 是当前最优解的位置向量, $X(t)$ 是当前解的位置向量, $X(t+1)$ 是下次迭代后解的位置向量, 每次迭代过程中出现更优解时则更新 $X^*(t)$ 。 A 和 C 由如下公式得出:

$$\begin{cases} A = 2ar - a \\ a = 2 - \frac{2t}{t_{max}} \end{cases} \tag{20}$$

$$C = 2r \tag{21}$$

式中: a 在迭代过程中由 2 线性下降至 0; r 为 $[0, 1]$ 之间的随机向量; t_{max} 为最大迭代次数, 本文取 $t_{max} = 200$ 。

2) 气泡网攻击阶段

WOA 存在两种方法对座头鲸的气泡网攻击行为进行建模: 即收缩包围机制和螺旋更新位置。通过产生一个 0~1 的随机概率 p 来决定采用哪种捕食方式, 当 $|A| < 1$ 且 $p < 0.5$ 时, 选择收缩包围机制; 当 $|A| < 1$ 且 $p \geq 0.5$ 时, 选择螺旋运动更新位置。

3) 猎物搜索阶段

当 $|A| > 1$ 时进入随机搜索阶段, 通过随机确定一个鲸鱼个体来更新位置坐标, 当达到最大迭代次数以后算法终止。随机搜索的数学模型如下:

$$D = |CX_{rand} - X(t)| \tag{22}$$

$$X(t+1) = X_{rand} - AD \tag{23}$$

式中: X_{rand} 为从当前种群中选择的随机位置向量。

1.5 WOA-ELM 模型

由于 ELM 的输入权值 w 和隐含层阈值 b 是随机确定的, 但这两个参数会直接影响 ELM 的稳定性和识别精度, 参数选择不当可能会在运算过程中出现病态或过拟合现象。使用 WOA 对 ELM 中输入权值 w 和隐含层阈值 b 进行迭代寻优可获得最优解, 从而提高振动信号的识别准确率。使用 WOA 优化 ELM 的具体流程如下:

1) 将 ELM 的可调参数初始化为 WOA 的位置向量。设置 WOA 鲸鱼数量为 30, 最大迭代次数为 100, 鲸鱼算法的适应度函数 F 为:

$$F = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \tag{24}$$

2) 计算所有个体的适应度值, 获得适应度值最小时个体所在位置, 将其作为当前个体最优位置。

3) 在座头鲸和猎物之间使用收缩包围机制或螺旋方程来更新个体位置, 之后进入下一次迭代。

4) 保留最优鲸鱼个体位置, 满足误差精度或达到最大迭代次数后终止循环, 将此最优参数赋值给 ELM 网络实现对振动信号的分类。

1.6 VMD-PSO-ELM 算法流程

1) 信号分解: 对所有振动信号进行 VMD 分解, 每组信号可分解得到 4 个 IMF 分量。

2) 特征提取: 分别提取各个分量能量熵、峭度因子、波形因子、重心频率和频率标准差共 20 个特征值组成特征向量, 总共得到 400 组特征向量及其对应标签。将其中 80% 作为训练集, 20% 作为测试集。

3) WOA 优化 ELM: 初始化种群参数, 利用 WOA 针对 ELM 中输入权值 w 和隐含层阈值 b 进行迭代寻优, 迭代结束后将输出的最优参数赋值给 ELM 模型。

4) 信号识别: 使用 WOA-ELM 对测试集数据进行识别。

基于 VMD-PSO-ELM 的电缆外力破坏振动信号识别算法的流程如图 2 所示。

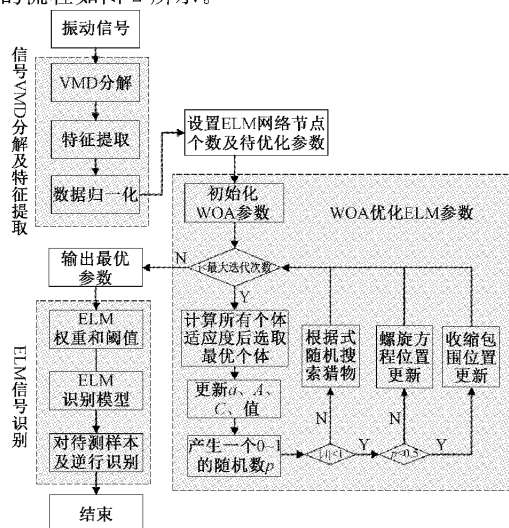


图 2 VMD-WOA-ELM 算法流程

2 振动信号获取

实验地点选择电缆实验基地空旷地面,距离施工地点5,10,20,30 m处各布置一个 IEPE 加速度传感器,传感器埋入地面约 10 cm,传感器的型号参数信息如表 1 所示。使用工控机搭载数据采集卡进行信号采集,数据采集卡的型号参数如表 2 所示,设置采集设备的采样率为 10 kHz,采样时间为 0.5 s。传感器及工控机如图 3 所示。

表 1 传感器参数

型号	量程/ g	频率范围/ Hz	工作电流/ mA	电压灵敏度/ (mV/g)
YK-YD20	25	0.5~5 000	2~10	199.9

表 2 数据采集卡参数

型号	分辨率	采样率	信号输入	电压范围
PCI-4474	24 bits	102.4 kS/s	4	±10 V




图 3 数据采集设备

分别采集机械挖掘、破碎锤施工、人工挖掘和重型车辆经过时的振动信号各 100 组,实验现场如图 4 所示。其中一组距离施工处 10 m 的实测振动信号时域波形如图 5 所示,对应三维时频图如图 6 所示。



图 4 实验现场

由图 5 可以直观地看出采集到的 4 种振动信号含有大量噪声,信号的时域特征不够明显,通过肉眼观察无法直接识别其信号类型。由图 6 可知 4 种信号在频域上具有不同的分布特征,其中人工挖掘振动信号主要集中在 0~1 000 Hz 频段内;重型车辆振动信号在 0~500 Hz 和 1 000~2 000 Hz 频段内均有分布;机械挖掘振动信号的频率分量集中在 0~500 Hz,



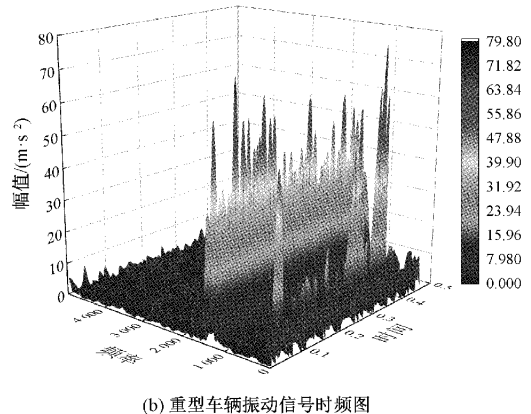



图 5 四种振动信号时域波形图




(a) 人工挖掘振动信号时频图



(b) 重型车辆振动信号时频图



(c) 机械挖掘振动信号时频图



(d) 破碎锤施工振动信号时频图


图 6 四种振动信号时频图

破碎锤施工振动信号在 0~500 Hz, 3 000~5 000 Hz 内均有分布, 4 种振动信号的频域分量存在大量重叠部分, 仅凭借频域分布特征难以识别信号类型。


3 振动分解及特征提取

3.1 振动信号 VMD 分解


对 4 种信号进行 VMD 分解, 设置分解层数 K 为 4, α 取 1 000, 噪声容限 γ 设为 0, 收敛容差设置为 10^{-6} , 经 VMD 分解后所得振动信号模式分量波形如图 7 所示。




(a) 人工挖掘振动信号 VMD 分解



(b) 重型车辆经过振动信号 VMD 分解



(c) 机械挖掘振动信号 VMD 分解



(d) 破碎锤施工振动信号 VMD 分解

图 7 四种振动信号 VMD 分解图

3.2 信号特征提取

提取 4 个 IMF 分量的能量熵 p_i 、峭度因子 Ku 、波形因子 f 、重心频率 ω 和频率标准差 μ , 得到共 20 个特征值组成特征向量, 其中一组特征值数据如表 3 所示。

4 信号识别结果与讨论

将得到的 400 组特征向量中 80% 作为训练集送入 ELM 中进行训练, 20% 作为测试集对算法识别准确度进行检验。设置 ELM 激活函数为 Sigmoid 函数, 分别对隐含节点个数为 5~20 的 ELM 分类准确度进行测试, 分类结果如图 8 所示。

表3 振动信号特征值

	类型	机械挖掘	冲击锤	人工挖掘	重型车辆
IMF ₁	能量熵	0.47	0.39	0.30	0.41
	峭度	8.86	6.084 3	6.69	3.46
	波形因子	1.61	1.18	1.03	1.27
	重心频率	405.32	555.29	369.21	254.28
	频率标准差	4 843.93	4 728.14	4 563.11	4 765.50
IMF ₂	能量熵	0.29	0.26	0.24	0.07
	峭度	2.22	5.99	5.31	3.15
	波形因子	1.65	1.13	1.56	1.20
	重心频率	848.12	1 162.2	436.77	932.97
	频率标准差	4 429.10	4 048.25	4 402.99	3 839.88
IMF ₃	能量熵	0.19	0.21	0.23	0.25
	峭度	69.123 1	13.40	8.05	1.61
	波形因子	1.28	1.15	1.41	1.12
	重心频率	1 255.6	1 575.2	557.64	1 644.11
	频率标准差	4 235.44	4 041.13	4 282.78	3 457.11
IMF ₄	能量熵	0.05	0.14	0.23	0.27
	峭度	133.09	36.18	5.60	2.373
	波形因子	1.54	1.25	1.14	1.22
	重心频率	1 834.7	2 408.4	793.06	1 283.59
	频率标准差	4 419.63	3 412.46	4 540.56	3 281.00




图8 ELM在不同隐含层节点数时的分类准确率

节点数为12、16和18时,测试集的分类准确率最高,分类准确率为93.75%。但节点数越多算法运行时间相对越长,因此综合考虑算法的分类准确率和运行时间,确定所用极限学习机的网络结构为20-12-1,即输入层20个节点,隐含层12个节点,输出层1个节点。此时ELM算法的识别结果如图9所示。

按照1.3节中参数对WOA进行初始化设置,将训练集输入WOA-ELM进行训练,对测试集数据进行分类准确度检验,分类结果如图10(a)所示,WOA的适应度曲线如图10(b)所示。

由图10可知,WOA的适应度函数值在7次迭代后达到最小,且在之后的迭代中适应度始终处于最小值,收敛速度非常快,分类准确率达98.75%。经WOA优化后的极限学习机在网络结构为20-12-1时的分类准确率提高了




图9 测试集分类结果(ELM)




图10 测试集分类结果(WOA-ELM)

5%,具有更高的鲁棒性。

为了进一步验证WOA-ELM的优越性,将训练集数据分别输入到PSO-ELM^[23]、GA-ELM^[24]中进行训练,其

中相同参数部分设置一致,使用两种方法分别对测试集数据进行分类。PSO-ELM 的分类结果如图 11(a)所示,PSO 的收敛情况如图 11(b)所示。GA 算法在适应度最大时具有最优参数,GA-ELM 的分类结果如图 12(a)所示,GA 的收敛情况如图 12(b)所示。




图 11 测试集分类结果(PSO-ELM)




图 12 测试集分类结果(GA-ELM)

由上述分析可知,WOA-ELM 和 GA-ELM 的识别准确率均为 98.75%,PSO-ELM 的识别准确率为 96.25%。WOA 在第 7 次迭代时适应度值即达到平稳,PSO 在第 12 次迭代时适应度达到最小,且之后保持稳定,GA 在第 17 次迭代时适应度达到稳定值。尽管 WOA-ELM 和 GA-ELM 都具有较高的识别准确率,但是 WOA 相比 GA 具有更快的收敛速度和更短的运行时长;PSO-ELM 尽管有较快的收敛速度,但是该方法的识别准确度明显低于 WOA-ELM 和 GA-ELM。

在相同计算机运行环境下,利用 MATLAB 对 WOA-ELM、PSO-ELM、GA-ELM 三种算法的运行时长进行对比,3 种算法各执行 20 次,记录每次开始运行到生成收敛图所用时间,运行结果如图 13 所示。

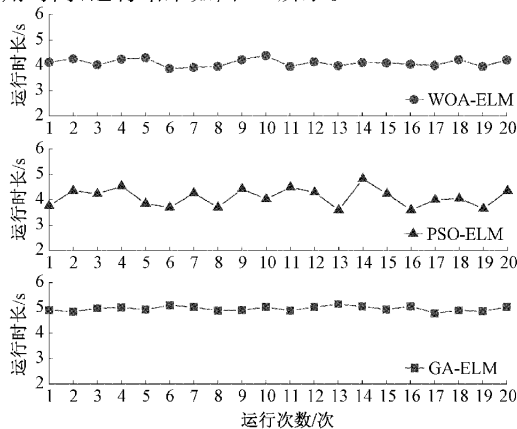


图 13 三种算法运行时间对比

由图 13 可知,WOA-ELM 的平均运行时长为 4.10 s, PSO-ELM 的平均运行时间为 4.09 s,GA-ELM 的平均运行时间为 4.97 s。WOA-ELM 与 PSO-ELM 的平均运行时长相近,但 PSO-ELM 在 20 次运行过程中的运行时间以及识别准确率具有明显波动。WOA-ELM 与 GA-ELM 表现相对平稳,但 GA-ELM 的平均运行时间最长。

综上,可以得出结论:三种识别算法中 WOA-ELM 运行时长较短、识别准确率最高、收敛速度最快,并且具有较高的稳定性,因此本文所提算法具有最优综合性能。

5 结 论

本文提出了一种基于 VMD-WOA-ELM 算法的电缆外力破坏振动信号识别方法。该算法首先利用 VMD 对振动信号进行自适应分解,然后提取各 IMF 分量的时、频特征值组成特征向量,最后采用改进的 WOA-ELM 模型实现对信号的分类。WOA 通过对 ELM 中输入权值 w 和隐含层阈值 b 进行迭代寻优,解决了 ELM 参数选择盲目性的问题,强化了 ELM 分类模型的稳定性和泛化能力。将该算法应用于实测施工振动信号类型识别,实验结果表明,WOA-ELM 的识别准确率达到 98.75%,相比传统 ELM 提高了 5%。并且与 PSO-ELM、GA-ELM 相比,WOA-ELM 识别准确率最高、收敛速度最快、运行时长较短,具有最优综合性能。需要指出的是,经 WOA 算法优化后的 ELM 仍然存在易陷局部最优的问题,WOA 优化算法的稳定性相比 GA 稍有不足,如何解决易陷局部最优问题以及如何进一步提高智能优化算法的稳定性仍然需要进一步的研究。

参考文献

- [1] 余臻. 基于阻抗突变测量的电缆防盗新机制的研究[J]. 仪器仪表学报,2012(2): 377-382.
- [2] 张振鹏,蒙绍新,赵健康,等. 典型敷设条件下电力电缆线路运行振动特征值的测量试验[J]. 高电压技术,2015(4):1188-1193.
- [3] 王艳,李煜,赵洪山,等. 配电设备监测信号的压缩感知与设备异常识别[J]. 高电压技术,2022(1):11-19.
- [4] 杨世迎,祝贺,何文,等. 外部冲击下电力电缆护套结构性损伤研究[J]. 振动与冲击,2020(24):122-127.
- [5] 王昱皓,周凯,汪先进,等. 基于改进时频域反射法的电力电缆局部缺陷定位[J]. 中国电机工程学报,2021(7): 2584-2594.
- [6] 刘骥,张明泽,张振鹏,等. 外部振动对 500 kV 交联聚乙烯电缆敷设条件的影响[J]. 高电压技术,2017(2): 673-681.
- [7] SEEDAHMED S M, JIM K, YUVARAJA V. Real-time distributed fiber optic sensor for security systems: Performance, event classification and nuisance mitigation [J]. Photonics Sensors, 2012,

- 2(3): 225-236.
- [8] 盛智勇,张新燕,王彦平,等. 光纤振动信号特征提取及线性分类方法[J]. 光电子·激光,2018(7):760-768.
- [9] 潘超,陈祥,蔡国伟,等. 基于小波包尺度-能量占比的变压器三相不平衡绕组振动特征辨识[J]. 仪器仪表学报,2020(4): 129-137.
- [10] 彭亚雄,刘广进,苏莹,等. 基于变分模态分解算法的隧道爆破振动信号光滑降噪模型[J]. 振动与冲击,2021(24): 173-179.
- [11] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [12] 李豪,岳朋朋,向大为,等. 基于 PSO-VMD 瞬时频率的三电平 Buck-Boost 变流器开路故障检测方法[J]. 高电压技术,2022(5):1903-1912.
- [13] 张俊,张建群,钟敏,等. 基于 PSO-VMD-MCKD 方法的风机轴承微弱故障诊断[J]. 振动. 测试与诊断, 2020(2):287-296,418.
- [14] 尚秋峰,郭家兴. 基于 VMD-BSA-SVM 的海缆振动信号识别方法[J]. 激光与光电子学进展,2022,59(17): 65-74.
- [15] 张炎亮,毛贺年,赵华东. 基于 VMD 与 IFWA-SVM 的滚动轴承故障诊断研究[J]. 机床与液压,2022(6): 180-185.
- [16] 王磊,张志勇,胥辉旗,等. 基于 VMD 分解和多域联合分布的雷达辐射源识别[J/OL]. 系统工程与电子技术: 1-13 [2023-03-12]. <http://kns.cnki.net/kcms/detail/11.2422.TN.20220613.1159.015.html>.
- [17] 毛向向,王红军,韩凤霞,等. 基于深度卷积神经网络的机电系统故障分类识别方法[J]. 电子测量与仪器学报,2021(2): 87-93.
- [18] 王文凯,邓斌. 基于 DAE-IPSO-SVM 的电缆早期故障识别方法[J]. 国外电子测量技术,2021(8): 29-35.
- [19] 陈泽,丁琳琳,罗浩,等. 基于改进小波分解和 ELM 的矿山微震事件识别方法[J]. 煤炭学报,2020(S2):637-648.
- [20] 杨明莉,范玉刚,李宝芸. 基于 LDA 和 ELM 的高光谱图像降维与分类方法研究[J]. 电子测量与仪器学报, 2020(5): 190-196.
- [21] 王涛,林培杰,周海芳,等. 采用 ELM 和优化电压传感器布局的光伏阵列故障检测与区域定位[J]. 福州大学学报(自然科学版),2022(4): 475-482.
- [22] 赵春华,胡恒星,陈保家,等. 基于深度学习特征提取和 WOA-SVM 状态识别的轴承故障诊断[J]. 振动与冲击,2019(10): 31-37,48.
- [23] 尚前明,姜苗,陈辉,等. 基于 PSO-ELM 算法实现船舶发电机组故障识别[J]. 船舶工程,2021(1):87-94.
- [24] 于志勇,张卫辉,王新库,等. 基于 GA 和 ELM 的电能质量扰动识别特征选择方法[J]. 电测与仪表,2016(23): 62-66.

作者简介

崔岩,硕士,主要研究方向为高电压与绝缘、振动信号处理与识别等。

E-mail:cuiyan011@163.com

方春华(通信作者),博士,副教授,主要研究方向为高电压与绝缘、电缆故障识别技术等。

E-mail:sxdx105@163.com