

DOI: 10.19783/j.cnki.pspc.241545

# 基于 GWO 优化与 BiLSTM-AM 的配电网电能质量 复合扰动自适应感知

周建华<sup>1</sup>, 马国煜<sup>2</sup>, 陶 锴<sup>2</sup>, 徐俊俊<sup>2</sup>

(1. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211103; 2. 南京邮电大学  
自动化学院-人工智能学院, 江苏 南京 210023)

**摘要:** 为有效应对高渗透率分布式电源并网引起的电压暂升、电压振荡等电能质量扰动(power quality disturbances, PQDs)问题, 提出一种基于双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络-注意力机制(attention mechanism, AM)的复合扰动自适应感知方法。首先, 通过灰狼优化(grey wolf optimizer, GWO)算法优化改进的完全自适应噪声集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)参数, 实现扰动信号模态分解与重构。其次, 提取扰动信号的层次加权排列熵(hierarchical weighted permutation entropy, HWPE)特征。最后, 构建 BiLSTM-AM 模型, 利用多维特征长短期依赖关系实现电能质量复合扰动识别。在仿真与真实电网数据集上开展实验验证, 结果表明所提方法对不同扰动均具有较好的识别效果。此外, 与现有深度网络模型相比, 所提模型具有更高的识别准确率。

**关键词:** 配电网; 分布式电源; 电能质量扰动; 层次加权排列熵; 双向长短期记忆网络

## Adaptive sensing of power quality composite disturbances in distribution systems based on GWO optimization and BiLSTM-AM

ZHOU Jianhua<sup>1</sup>, MA Guoyu<sup>2</sup>, TAO Kai<sup>2</sup>, XU Junjun<sup>2</sup>

(1. Electric Power Research Institute of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211103, China; 2. School of Automation and Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

**Abstract:** In order to effectively address power quality disturbances (PQDs) such as voltage swells and voltage oscillations caused by the high penetration grid connection of distributed generation, a composite disturbance adaptive sensing method based on a bidirectional long short-term memory (BiLSTM) network integrated with an attention mechanism (AM) is proposed. First, the grey wolf optimizer (GWO) algorithm is employed to optimize the parameters of the improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN). The modals of the disturbance signals are decomposed and reconstructed. Subsequently, the features of hierarchical weighted permutation entropy (HWPE) of the disturbance signals are extracted. Finally, a BiLSTM-AM model is constructed to capture the long- and short-term dependencies of multidimensional features for composite PQD recognition. Validation using both simulated and real-world power grid datasets demonstrates excellent identification performance on various disturbance types with the proposed method. Moreover, compared with other deep learning models, the proposed model further demonstrates higher recognition accuracy.

This work is supported by the Science and Technology Project of State Grid Corporation of China (No. J2024062).

**Key words:** distribution network; distributed generation; power quality disturbance; hierarchical weighted permutation entropy; bidirectional long short-term memory

**基金项目:** 国家电网有限公司科技项目资助(J2024062)“基于扰动自愈控制的智能配电网电能质量耐受能力提升技术研究”

## 0 引言

高比例新能源、电力电子设备并网是新型电力系统发展的主趋势<sup>[1-3]</sup>，且在配电侧的比例逐年提高。由于分布式电源输出功率的随机性与波动性<sup>[4-6]</sup>，在优化电力结构的同时也引发了电压暂升、谐波叠加等电能质量扰动(power quality disturbances, PQDs)问题，进而影响高精度工商业负荷等多类型电力设备运维的安全性和可靠性<sup>[7-8]</sup>。因此，快速准确地检测与识别电能质量扰动对智能配电网安全稳定运行具有重要意义。

依据 IEEE Std 1159—2019 标准<sup>[9]</sup>，智能配电网包含多种形式的扰动，如闪变、暂升、暂降、中断等。在电网运行中，扰动往往以复合的形式出现。复合扰动由若干单一扰动叠加而成<sup>[10-11]</sup>，如暂升+脉冲、暂降+谐波等，此种扰动复合特性加剧了识别系统的复杂性。此外，实际场景中的电能质量扰动可能处于噪声环境，因此消除电能质量扰动信号中的噪声亦十分必要。

扰动电压、电流信号特征参数(例如幅值、相位、频率等)包含了智能配电网运行信息，此种信息可用于电能质量扰动评估。传统基于电能质量扰动信号识别的方法首先采用诸如 S 变换(S-transform)等方法提取扰动特征，然后将特征信息输入支持向量机(support vector machine, SVM)等分类器开展识别。此种方法适用于结构简单、拓扑单一的网络<sup>[12]</sup>。面对分布式电源接入背景的复杂网络，多扰动耦合下的参数阈值评估法对短时、非周期性扰动的敏感性会降低，易出现漏识别风险。

近年来，人工智能方法在复杂场景电能质量扰动识别中的应用愈发广泛。文献[13]基于马尔可夫转移场(Markov transition field, MTF)可视化和改进 DenseNet 神经网络算法实现了电能质量复合扰动快速准确识别。为实现大规模系统中电能质量扰动的深度特征提取及智能分类识别，文献[14]提出一种基于堆叠稀疏自编码器(stacked sparse autoencoder, SSAE)-前馈神经网络(feed forward neural network, FFNN)的复合扰动分类模型。为提高电能质量扰动信号在受到噪声和异常干扰时的分类准确率，文献[15]提出了一种双分支并联特征融合网络的 PQDs 分类方法。文献[16]针对电能质量混合扰动的复杂性及当前分类识别的低准确率问题，提出一种数据库查询的多标签电能质量混合扰动分类与识别方法。文献[17]构建了一种基于轨迹颜色编码与知识

蒸馏的电能质量扰动轻量化识别系统。文献[18]提出了一种集成本征时间尺度分解(ensemble intrinsic time-scale decomposition, EITD)-全局深度混洗卷积神经网络(global depthwise shuffle convolutional neural network, GSCNN)方法，此方法在不同噪声环境下均表现出色，能精准识别复杂扰动。文献[19]提出了一种基于改进 Kaiser 窗的 S 变换(modified kaiser window-based S-transform, MKS)-多尺度并行注意力残差网络(multiscale parallel attention residual network, MPARN)的分类策略，算例仿真结果表明其对非线性 PQD 具有较好的识别效果。文献[20]提出了一种快速自适应 S 变换(fast adaptive S-transform, FAST)，提高了扰动特征提取的时频分辨率和计算效率。文献[21]提出了一种模糊转移场(fuzzy transfer field, FTF)方法，将扰动特征信号转换为二维图像，然后通过深度残差网对包含复杂 PQDs 信息的二维图像进行分类和识别。然而，上述基于数据驱动或深度学习的电能质量扰动识别方法，严重依赖海量的优化参数与庞大的特征矩阵维数，这使得传统智能算法在识别高比例分布式电源并网引发的复杂电能质量扰动时，其准确性和效率仍有提升空间。

基于上述研究与分析，为应对分布式电源并网所引发的电能质量扰动高效识别问题，首先，采用灰狼优化(grey wolf optimizer, GWO)算法对改进的自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)的参数进行优化。此步骤能在保留信号特征的同时抑制噪声，提高模态分解的准确性和鲁棒性。其次，针对去噪后的扰动信号，采用层次加权排列熵(hierarchical weighted permutation entropy, HWPE)方法提取具有辨识性和判别力的扰动特征。最后，采用双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络结合注意力机制(attention mechanism, AM)构建识别模型。BiLSTM 能够充分利用时间序列的前后信息，在电能质量扰动建模中引入时间特性，可有效提高识别准确率。结合注意力机制，模型能够自动学习扰动信号中的关键特征并赋予其较高的权重，进一步增强了模型的鲁棒性和识别能力。基于 IEEE Std 1159-2019 标准，选取并仿真 16 种常见的电能质量扰动信号，分别在 4 种信噪比(signal-noise ratio, SNR)下进行扰动识别实验。与其他 4 种典型的算法开展对比分析，结果验证了所提方法的有效性及其优越性。此外，展开了不同环境下的实测数据验证实验，结果进一步验证了本文方法的有效性。

## 1 配电网电能质量扰动识别原理

### 1.1 扰动信号自适应模态分解

#### 1.1.1 ICEEMDAN

ICEEMDAN 首先利用经验模态分解(empirical mode decomposition, EMD)方法对初始信号进行分解, 得到若干固有模态函数(intrinsic mode function, IMF), 分解过程如下。

设某信号为  $X(t)$ , 通过该信号构建含有白噪声的信号  $X_f^{(i)}(t)$ , 如式(1)所示。

$$X_f^{(i)}(t) = X(t) + A_0 E_1[\omega^{(i)}(t)] \quad (1)$$

式中:  $E_1[\omega^{(i)}(t)]$  为特定白噪声;  $A_0$  表示叠加白噪声时的标准差;  $i$  表示添加次数;  $\omega^{(i)}(t)$  为高斯白噪声。将  $X_f^{(i)}(t)$  分解为各 IMF 的步骤具体如下。

首先, 使用 EMD 方法分解得到第一个残余  $r_1(t)$ , 如式(2)所示。

$$r_1(t) = \langle M[X_f^{(i)}(t)] \rangle \quad (2)$$

式中:  $\langle \cdot \rangle$  表示全局平均操作;  $M[\cdot]$  为求解信号包络。

其次, 求出第一阶 IMF 分量  $F_1(t)$ , 如式(3)所示。

$$F_1(t) = X(t) - r_1(t) \quad (3)$$

接着, 采用上述方法进行类似迭代, 得到第  $k_1$  个残余  $r_{k_1}(t)$  如式(4)所示。

$$r_{k_1}(t) = \langle M[r_{k_1-1}(t)] + A_{k_2-1} E_{k_2}[\omega^{(i)}(t)] \rangle \quad (4)$$

式中:  $A_{k_2-1}$  表示第  $k_2$  次 EMD 分解时添加的特定白噪声的标准差。

最后, 得到第  $k_3$  阶 IMF 分量  $F_{k_3}(t)$  如式(5)所示。

$$\begin{cases} F_{k_3}(t) = r_{k_1-1}(t) - r_{k_1}(t) \\ k_1 = k_2 = k_3 \end{cases} \quad (5)$$

#### 1.1.2 GWO 优化 ICEEMDAN

GWO 是一种模拟灰狼捕食行为而提出的优化算法。GWO 的种群结构呈 4 层金字塔型, 从上而下分别为  $\alpha$  狼、 $\beta$  狼、 $\delta$  狼、 $\xi$  狼。 $\xi$  狼构成灰狼种群的基础<sup>[22]</sup>。本文的 GWO 优化 ICEEMDAN 流程如图 1 所示。

### 1.2 HWPE 特征提取

提取扰动信号的 HWPE 特征。利用层次化方式分割时间序列信号, 过程如下。

1) 针对信号  $x(q)$ ,  $q=1,2,\dots,Q$ , 有

$$\begin{cases} C_0 = [A_{2j} + A_{2j+1}]/2 \\ C_1 = [A_{2j} - A_{2j+1}]/2 \end{cases} \quad (6)$$

式中:  $j=0,1,\dots,2^{q-1}$ ;  $C_0$  为平均算子;  $C_1$  为差分算子, 且长度均为  $2^{q-1}$ ;  $Q=2^q$ ,  $q$  为正整数;  $A_{2j}$ 、 $A_{2j+1}$  分别表示信号  $x(q)$  的偶数及奇数个元素组成的向量。

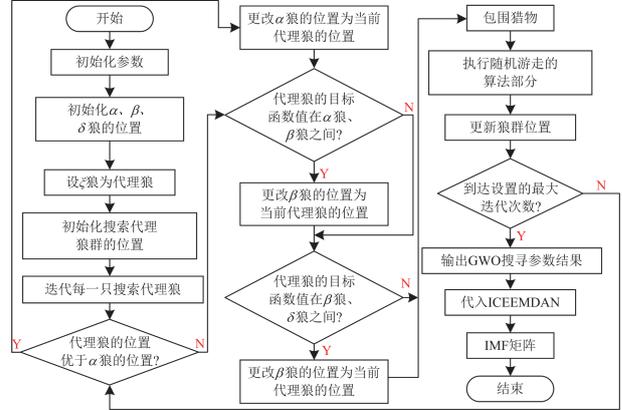


图 1 GWO 优化 ICEEMDAN 流程

Fig. 1 Flow chart of ICEEMDAN optimized by GWO

算子  $C_0$ 、 $C_1$  用于重构信号  $x_b(q)$ , 如式(7)所示。

$$x_b(q) = \text{Concat}(C_{0-j} + C_{1-j}, C_{0-j} - C_{1-j}) \quad (7)$$

式中:  $\text{Concat}(\cdot)$  表示向量连结;  $C_{0-j}$  与  $C_{1-j}$  分别表示第  $j$  个平均算子及差分算子。当  $j=0$  或  $j=1$  时, 定义  $2^q \times 2^{q-1}$  维矩阵算子  $C_j$  如式(8)所示。

$$C_j = \begin{bmatrix} \frac{1}{2} & \frac{(-1)^j}{2} & 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & \frac{1}{2} & \frac{(-1)^j}{2} & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & \frac{1}{2} & \frac{(-1)^j}{2} \end{bmatrix} \quad (8)$$

2) 生成  $q$  维向量  $[\sigma_1 \sigma_1 \dots \sigma_q] \in \{0,1\}$ , 并定义信号  $x_b(q)$  每一层分解的节点序列, 如式(9)所示。

$$x_{b(l,\eta)}(q) = C_{\sigma_q} C_{\sigma_{q-1}} \dots C_{\sigma_1} \quad (9)$$

式中:  $x_{b(l,\eta)}(q)$  表示将  $x_b(q)$  分解到第  $l$  层、第  $\eta$  个节点时的序列。如果  $l=2$ , 表示初始信号经历两个层次的分解。

3) 计算对应于向量  $[\sigma_1 \sigma_1 \dots \sigma_q]$  的正整数序号  $\gamma$ , 如式(10)所示。

$$\gamma = \sum_{j=1}^l \sigma_q \cdot 2^{l-j} \quad (10)$$

4) 计算各层次分量的 WPE 值  $V_w$ , 得出  $2^l$  个层次分量的 WPE 值, 即 HWPE 值  $V_H$ , 如式(11)所示。

$$V_H(x_b(q), l, \gamma, \chi, \tau) = V_w(x_{b(l,\gamma)}(q), \chi, \tau) \quad (11)$$

式中:  $x_{b(l,\gamma)}(q)$  表示将  $x_b(q)$  分解至第  $l$  层、第  $\gamma$  个节点时的序列;  $\chi$  表示嵌入维度;  $\tau$  表示时延。

基于上述流程, 算子  $C_0$  和  $C_1$  分别为信号的低频部分和 高频部分。节点  $x_{b(1,0)}(q)$  及  $x_{b(2,0)}(q)$  的 WPE 值分布表示在多尺度计算环境中, 不同时间尺度下的 WPE 值。HWPE 特征在提取电能质量扰动信号高频信息的同时也保留了低频信息。

### 1.3 扰动识别

#### 1.3.1 BiLSTM

BiLSTM 是对 LSTM<sup>[23-24]</sup> 网络的扩展, BiLSTM 处理序列时分为前向计算与后向计算两部分, 主要由遗忘门、输入门和输出门构成。其中输入门  $\theta_\rho$  决定了  $\rho$  时刻单元状态; 遗忘门  $c_\rho$  控制记忆单元, 负责  $\rho-1$  时刻  $c_{\rho-1}$  中的数据; 输出门  $o_\rho$  计算过程如式 (12) 一式 (14) 所示。

1) 遗忘门

$$f_\rho = \mu(W_f u_\rho + U_f h_{\rho-1} + b_f) \quad (12)$$

2) 输入门

$$\begin{cases} \theta_\rho = \mu(W_\theta u_\rho + U_\theta h_{\rho-1} + b_\theta) \\ \tilde{c}_\rho = \tanh(W_c u_\rho + U_c h_{\rho-1} + b_c) \\ c_\rho = f_\rho \otimes c_{\rho-1} + \theta_\rho \otimes \tilde{c}_\rho \end{cases} \quad (13)$$

3) 输出门

$$\begin{cases} o_\rho = \mu(W_o u_\rho + U_o h_{\rho-1} + b_o) \\ h_\rho = o_\rho \otimes \tanh(c_\rho) \end{cases} \quad (14)$$

式中:  $W_f$ 、 $U_f$ 、 $W_\theta$ 、 $U_\theta$ 、 $W_c$ 、 $U_c$ 、 $W_o$ 、 $U_o$  分别为对应各门的权值矩阵;  $b_f$ 、 $b_\theta$ 、 $b_c$ 、 $b_o$  分别对应各门的偏置向量;  $f_\rho$  为  $\rho$  时刻遗忘门输出;  $u_\rho$  为  $\rho$  时刻输入特征;  $\tilde{c}_\rho$  为  $\rho$  时刻候选单元状态的输出向量;  $h_\rho$ 、 $h_{\rho-1}$  分别为  $\rho$ 、 $\rho-1$  时刻的隐藏状态向量;  $\mu$  表示 Sigmoid 激活函数;  $\otimes$  为 Hadamard 积。

#### 1.3.2 AM

AM 可以筛选关键信息, 并对  $b_o$  特征赋予不同权重, 该层的输出  $U_A$  如式 (15) 所示。

$$U_A = \sum_{\rho=1}^T \left\{ \frac{\exp[\mathbf{v}^T \tanh(W_A h_\rho + b_A)]}{\sum_{s=1}^T \exp[\mathbf{v}^T \tanh(W_A h_s + b_A)]} \right\} h_\rho \quad (15)$$

式中:  $\mathbf{v}$  为注意力权重向量;  $W_A$  表示权重矩阵;  $b_A$  表示偏置向量, 且  $\rho=1, 2, \dots, T$ ,  $s=1, 2, \dots, T$ 。

## 2 配电网电能质量扰动识别流程

配电网电能质量扰动识别流程如图 2 所示。

首先, 采用 GWO 优化 ICEEMDAN 的噪声幅

值权重(noise standard deviation, Nstd)与噪声添加次数(noise ensemble, NE), 并利用最佳参数分解电能质量扰动信号, 得到 IMF 分量集合。筛选出相关系数大于给定限值的分量进行信号重构。随后, 利用 HWPE 提取重构信号的扰动特征。最后, 利用 BiLSTM-AM 开展扰动识别。

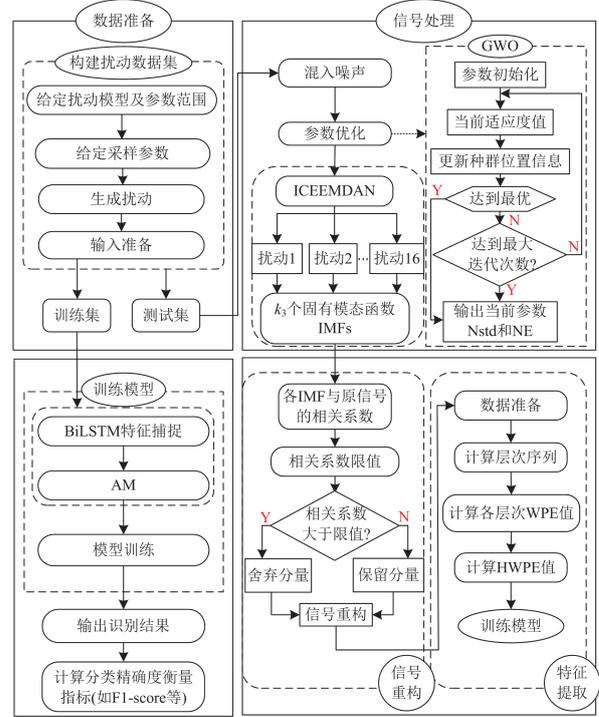


图 2 扰动识别流程

Fig. 2 Perturbation identification process

## 3 算例分析

### 3.1 典型电能扰动数学模型及参数指标

根据 IEEE Std 1159—2019 标准, 单 PQDs 数学模型及参数指标如表 1 所示。

表 1 中:  $\omega_m$  为基波圆频率;  $f_m$  为基波频率;  $\alpha_m$  为幅值变化系数;  $\beta_m$  为振荡基频系数;  $\tau_m$  为衰减系数;  $t_m$  为时间变量;  $t_{m1}$ 、 $t_{m2}$  分别为扰动开始和结束时刻;  $T_{\xi 1}$ 、 $T_{\xi 2}$  为微小常数,  $T_{\xi 1} = 0.001$  s,  $T_{\xi 2} = 0.003$  s, 复合 PQDs 的模型如式 (16) 所示。

$$f(t) = \Phi_m(t) \sin(\omega_m t) + \sum \delta_m(t) \quad (16)$$

式中:  $\Phi_m(t)$  为乘法模块, 包含暂升、暂降、中断和闪变;  $\delta_m(t)$  为叠加模块, 包括振荡、脉冲、谐波。

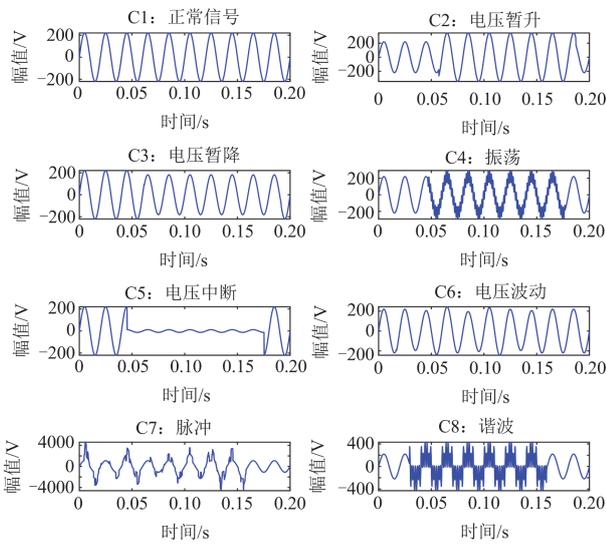
### 3.2 测试数据提取

按 3.1 节所给定的数学模型以及参考指标, 分布式电源接入智能配电网后产生的 16 种电能质量扰动(编号 C1—C16)如图 3 所示。

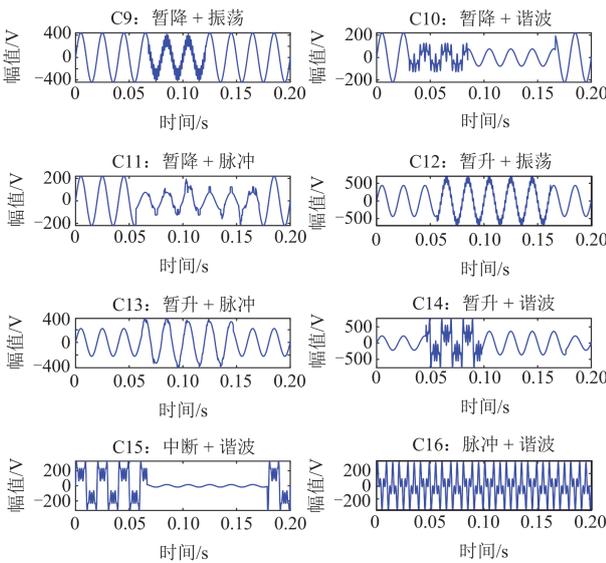
表 1 电能质量单扰动数学模型及参数指标

Table 1 Mathematical models and parameter indicators of single PQDs

类型	数学模型	参数指标
正常	$f(t) = \sin(\omega_m t)$	$\omega_m = 2\pi f_m, f_m = 50 \text{ Hz}$
电压暂升	$f(t_m) = \{1 + \alpha_m [\varepsilon(t_m - t_{m1}) - \varepsilon(t_m - t_{m2})]\} \sin(\omega_m t_m)$	$0.1 \leq \alpha_m \leq 0.8, T_m \leq t_{m2} - t_{m1} \leq 9T_m$
电压暂降	$f(t_m) = \{1 - \alpha_m [\varepsilon(t_m - t_{m1}) - \varepsilon(t_m - t_{m2})]\} \sin(\omega_m t_m)$	$0.1 \leq \alpha_m \leq 0.8, T_m \leq t_{m2} - t_{m1} \leq 9T_m$
电压振荡	$f(t_m) = \sin(\beta_m \omega_m t_m) [\varepsilon(t_m - t_{m1}) - \varepsilon(t_m - t_{m2})] \alpha_m \exp[-(t_m - t_{m1})/\tau_m] + \sin(\omega_m t_m)$	$0.1 \leq \alpha_m \leq 0.8, 0.5T_m \leq t_{m2} - t_{m1} \leq 3T_m,$ $0.008 \leq \tau_m \leq 0.04, 8 \leq \beta_m \leq 32$
电压中断	$f(t_m) = \{1 - \alpha_m [\varepsilon(t_m - t_{m1}) - \varepsilon(t_m - t_{m2})]\} \sin(\omega_m t_m)$	$0.9 \leq \alpha_m \leq 1, T_m \leq t_{m2} - t_{m1} \leq 9T_m$
电压闪变	$f(t_m) = \{1 + \alpha_m \sin(\beta_m \omega_m t_m)\} \sin(\omega_m t_m)$	$0.1 \leq \alpha_m \leq 0.2, 0.1 \leq \beta_m \leq 0.5$
脉冲	$f(t_m) = \alpha_m [\varepsilon(t_m - t_{m1}) - \varepsilon(t_m - t_{m2})] + \sin(\omega_m t_m)$	$1 \leq \alpha_m \leq 3, T_{\varepsilon1} \leq t_{m2} - t_{m1} \leq T_{\varepsilon2}$
谐波	$f(t_m) = \sin(\omega_m t_m) + \sum_{i=3,5,7,9,11} \alpha_{m(i)} \sin(k_m \omega_m t_m)$	$0.05 \leq \alpha_{m(i)} \leq 0.15$



(a) 提取的电能质量单扰动波形图



(b) 提取的电能质量双扰动波形图

图 3 提取的电能质量扰动波形图

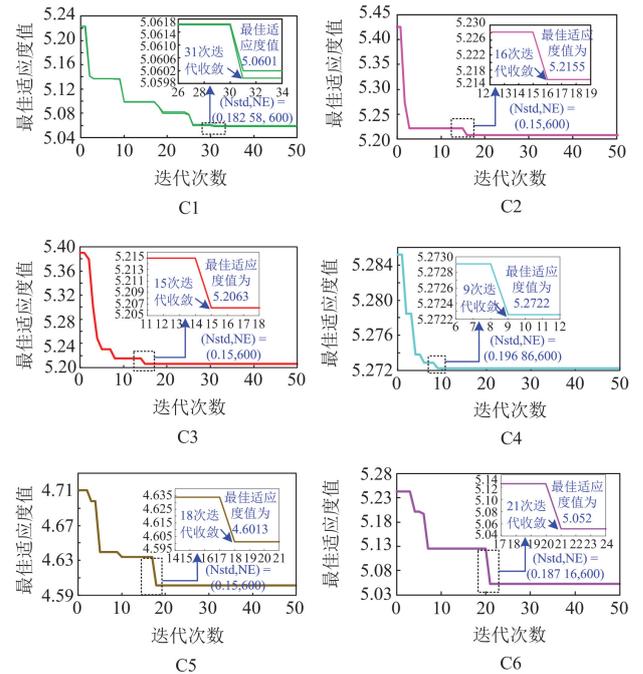
Fig. 3 Extracted PQDs waveforms

设置扰动信号基波频率为 50 Hz, 每个样本连续采样时间为 0.2 s, 共计 1000 个采样点, 各类扰动分别生成 100 个样本。为模拟真实环境, 分别设置 15 dB 信噪比、30 dB 信噪比、50 dB 信噪比、+∞ dB 信噪比(无噪声)开展仿真。每种信噪比下均生成 1600 个样本。

### 3.3 扰动信号模态分解

对扰动信号进行模态分解。选择在信噪比 15 dB 下进行展示。设置 Nstd 及 NE 的优化范围, 其中 Nstd 的优化范围设置为[0.15, 0.6], NE 的优化范围设置为[50, 600], 迭代次数为 50 次, 种群规模为 10。选择最小包络熵为适应度函数。8 种单扰动适应度变化曲线如图 4 所示。

由图 4 可知, 部分扰动对 GWO 优化模型的影响在早期表现明显。进行多次迭代后, 8 种曲线均趋于平稳, GWO 优化效果达到最佳。模型对扰动有



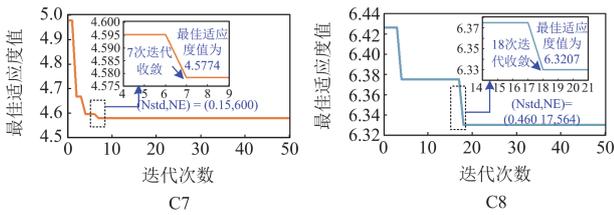


图 4 8 种单扰动适应度曲线

Fig. 4 Eight types of single disturbance fitness curves

不同的适应能力。将最佳(Nstd, NE)代入 ICEEMDAN 中, 分解各电能质量扰动信号。采用各 IMF 分量与原始信号的相关系数评估相关性, 结果如图 5 所示。

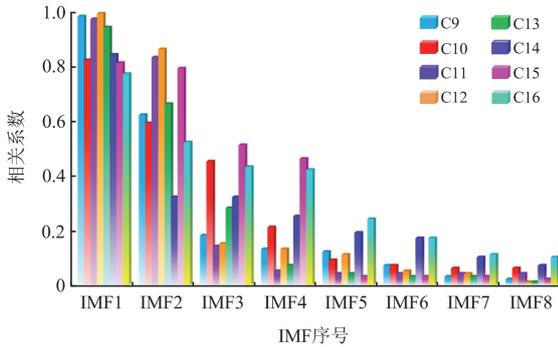


图 5 8 种双扰动的各 IMF 与原始信号相关系数图

Fig. 5 Correlation coefficient plots of each IMF with the original signal for eight types of dual disturbances

由图 5 可知, 各扰动信号的 IMF1 和 IMF2 与对应原始信号的相关系数较大, 而 IMF3 及之后的相关系数逐渐减小。表明在前几阶 IMF 中, 各扰动信号与原始信号的相关性强, 随着 IMF 序号增加, 相关性变得越来越小。低阶 IMF 分量包含了主要的信息。计算各 IMF 与原始信号的相关系数及阈值<sup>[25]</sup>, 若某相关系数大于阈值, 则该 IMF 分量被保留用于重构信号, 否则该 IMF 将被剔除。

### 3.4 扰动信号特征提取

#### 3.4.1 扰动信号重构

为充分说明重构效果, 对信噪比为 15 dB 下的各扰动进行测试, 同时采用 Hilbert 变换<sup>[26]</sup>进行包络对比分析。各单扰动重构对比如图 6 所示。

由图 6 可知, 对于扰动 C4、C8, 重构信号出现了更多的高频振荡, 与原始信号的包络不完全吻合。这种高频波动在包络线中表现为明显的振荡, 表明 C4、C8 扰动主要带有高频噪声或快速变化的信息。这种信息在原始信号中会减弱, 因此在重构过程中容易出现失真和偏差。这种高频分量通常难以在重构过程中完全去除, 对信号整体影响较小, 但会影响高频特性部分的识别准确性。

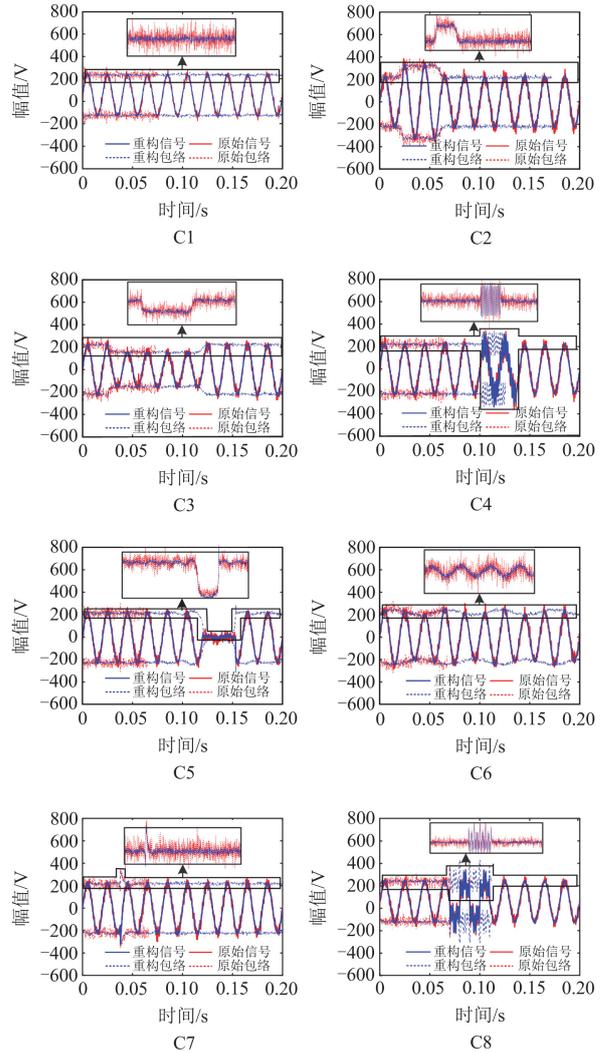


图 6 信噪比 15 dB 下各单扰动信号重构对比图

Fig. 6 Reconstruction comparison of individual disturbance signals under 15 dB SNR

#### 3.4.2 HWPE 特征提取

提取各扰动信号的 HWPE 特征。设置 HWPE 的嵌入维数  $\chi=5$ , 时延  $\tau=1$ , 分解层数  $l=3$ 。

得到 16 种电能扰动类型在 7 个特征尺度下的 HWPE 值, 各扰动的 HWPE 值随特征尺度变化, 如图 7 所示。

由图 7 可知, 在各个特征尺度上, 扰动 HWPE 值具有一定的差异。这是因为高频成分主要对应扰动信号细节和边缘信息, 低频成分对应扰动信号整体轮廓和纹理。选择各类扰动差异较大的 4 个尺度的特征构造扰动特征样本。

### 3.5 扰动识别结果

将提取的电能质量扰动特征按 8:2 的比例随机分割为训练样本和测试样本, 从每种扰动的 100 个

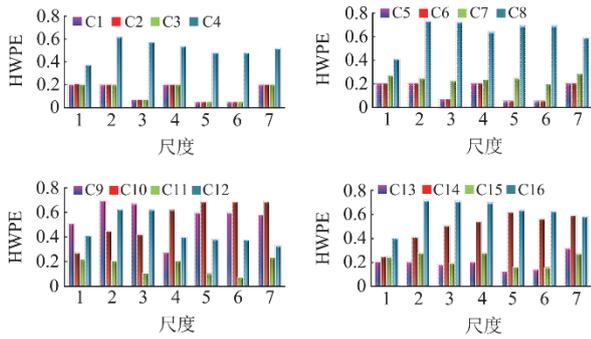


图 7 7 个特征尺度下各扰动的 HWPE 值

Fig. 7 HWPE values of disturbances across seven feature scales

样本中任意抽取 80 个作为训练样本, 20 个作为测试样本。分别在 15 dB、30 dB、50 dB、 $+\infty$  dB 信噪比下对各扰动测试样本进行分类, 以模拟电网受到扰动事件冲击的分类结果, 如图 8 所示。

由图 8 可知, 在 15 dB 信噪比时, 共有 11 类扰动被准确识别。由于信噪比略低, 不能充分去噪, 导致模型捕捉扰动特征时受到一定影响, 例如第 15 类扰动(C15: 中断+谐波)的 2 个样本被识别为第 5 类样本(C5: 电压中断), 3 个样本被错误地识别为第 11 类样本(C11: 暂降+脉冲), 准确率为 75%。这是由于中断时间过长并且受到噪声干扰, 从而识别错误。

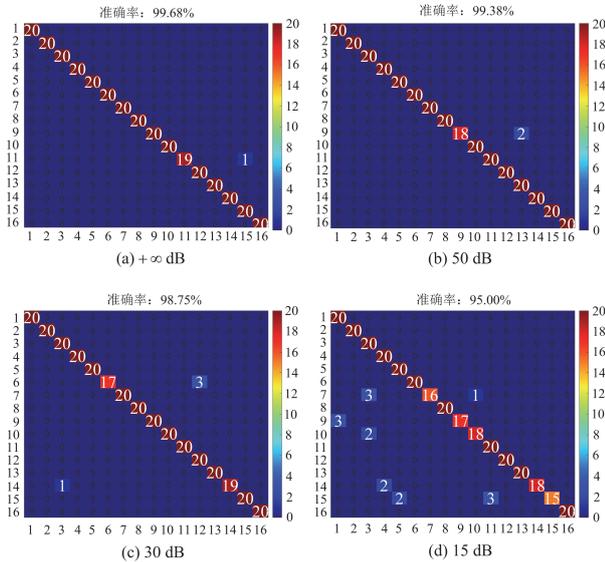


图 8 各信噪比下识别混淆矩阵

Fig. 8 Recognition confusion matrix under various SNRs

### 3.6 真实数据验证

为进一步验证本文所提方法在真实智能配电网电能质量监测中的实用性, 通过华东某地域电网的实测录波数据进行验证, 包括 5400 组数据, 源于配

电网 6 种不同扰动事件, 在 3 个时间段采集, 实测录波数据的采集情况如表 2、表 3 所示。

表 2 不同时间段下不同事件下数据采集情况

Table 2 Data collection scenarios under different time

periods and events			
事件	06:00—09:00	11:00—14:00	18:00—21:00
正常情况	90 组	90 组	90 组
单相故障	360 组	360 组	360 组
两相故障	270 组	270 组	270 组
三相故障	360 组	360 组	360 组
大负荷启动	270 组	270 组	270 组
电力设备投切	270 组	270 组	270 组
雷击事件	180 组	180 组	180 组

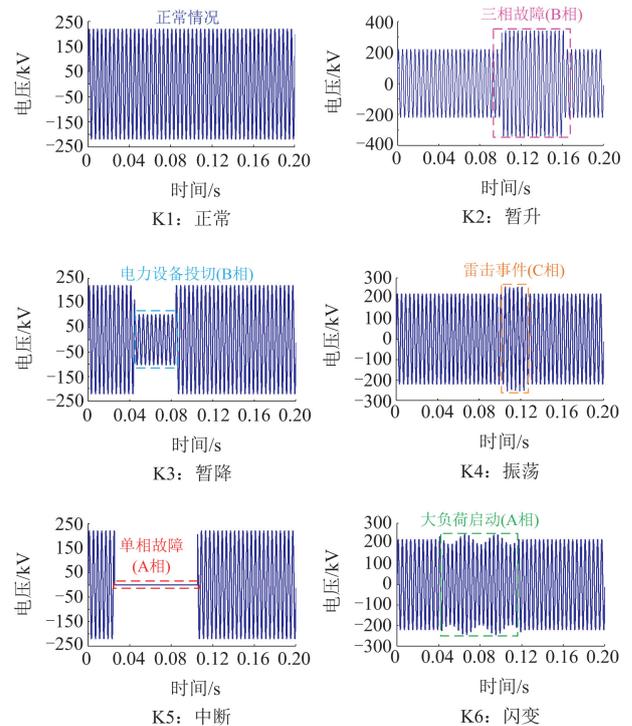
表 3 不同事件对应扰动种类数

Table 3 Number of disturbance types corresponding to different events

事件	单相故障	两相故障	三相故障
扰动种数	4 种	3 种	4 种
事件	大负荷启动	电力设备投切	雷击事件
扰动种数	3 种	3 种	2 种

录波系统采样频率为 5 kHz, 每组数据波形时长为 0.2 s。每类事件下每个时间段采集等量数据, 按实际扰动类型采集, 每种扰动均采集 270 组, 共 20 种类型的实际扰动。采集部分扰动的录波波形如图 9 所示。

经 ICEEMDAN 分解去噪后计算 20 种实测扰动在 7 个尺度下的 HWPE 值, 如图 10 所示。



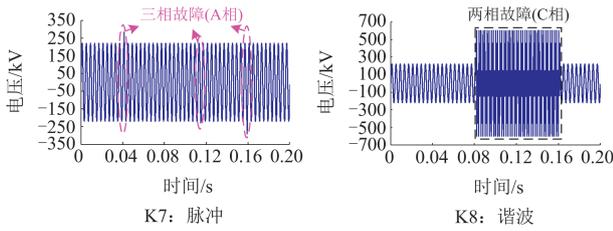


图9 部分扰动录波波形图

Fig. 9 Partial disturbance recorded waveforms

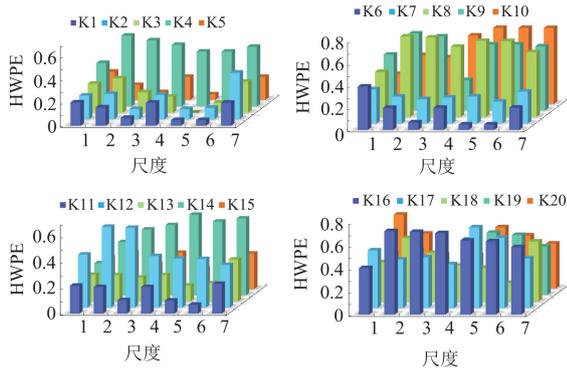


图10 各类型实测扰动 HWPE 值

Fig. 10 HWPE values of various types of measured disturbances

选择4个HWPE差异较大的特征尺度构造特征样本, 实测录波序号及数据识别情况如表4所示。

表4 实测录波数据识别结果

Table 4 Identification results of measured waveform data

实测扰动	引发事件	准确率/%	F1-score/%
K1: 正常	正常运行	100	100
K2: 暂升	三相故障	96.67	96.52
K3: 暂降	设备投切	99.26	99
K4: 振荡	雷击事件	98.52	96.19
K5: 中断	单相故障	100	100
K6: 闪变	大负荷启动	97.78	96.63
K7: 脉冲	三相故障	96.67	99.2
K8: 谐波	两相故障	98.15	97.63
K3 + K4	单相故障	90.37	87.63
K3 + K8	设备投切	95.56	97.09
K3 + K7	单相故障	96.30	98.04
K2 + K4	单相故障	98.15	97.62
K2 + K8	大负荷启动	97.78	95.92
K2 + K7	三相故障	98.15	97.63
K5 + K8	两相故障	96.67	96.52
K7 + K8	大负荷启动	98.89	98.62
K2 + K7 + K8	雷击事件	99.63	99.63
K3 + K4 + K8	设备投切	99.63	99.63
K3 + K6 + K7	三相故障	100	100
K4 + K5 + K8	两相故障	98.52	98.30

### 3.7 算例对比

#### 3.7.1 识别模型对比

为进一步验证本方法的有效性, 基于本文仿真数据选择同步压缩自适应变换(synchroextracting adaptive S-transform, SAST)方法、二维图像输入的残差网络(2D-ResNet)、改进麻雀搜索算法(improved sparrow search algorithm, ISSA)-极端梯度提升(extreme gradient boosting, XGBoost)、支持向量机(SVM)-分类与回归树(classification and regression Tree, CART)方法<sup>[27-30]</sup>进行对比分析。

比较各模型训练时间指标。各信噪比下的平均时间指标包括平均训练时间、平均处理时间, 如表5所示。

表5 不同信噪比下各模型扰动识别平均时间指标

Table 5 Average time metrics for disturbance recognition of each model under different SNRs

模型	平均迭代次数	平均训练时间/s	平均处理时间/ms
本文模型	80	360.72	42.18
SAST	80	470.24	46.25
2D-ResNet	80	869.18	163.73
ISSA-XGBoost	80	363.25	87.22
SVM-CART	80	390.25	95.02

对比指标包含准确率、查准率  $P_u$ 、召回率  $R_u$  以及 F1-score。记 F1-score 为  $F_s$ , 其中,  $P_u$  表示在模型预测为本类的所有结果中, 模型识别正确的比例。 $R_u$  表示在真实值为本类的所有结果中, 模型识别正确的比例。 $F_s = 2P_u R_u / (P_u + R_u)$ ,  $F_s$  越接近 1, 识别效果越好。各指标的对比结果如表6所示。

表6 不同信噪比下各模型扰动识别平均指标

Table 6 Average metrics for disturbance recognition of each model under different SNRs

模型	平均准确率	平均查准率	平均召回率	平均 F1-score
本文模型	98.20	98.44	98.44	98.44
SAST	95.54	95.54	96.13	95.83
2D-ResNet	97.69	97.65	98.04	97.84
ISSA-XGBoost	97.12	97.56	97.62	97.59
SVM-CART	98.09	98.02	98.35	98.18

由表5、表6可知, 本文模型的各项指标均最优, 表明该模型在扰动识别上较其余几种方法更好。SAST 处理信号时对噪声较为敏感, 尤其是在稀疏信号成分与噪声分离不明显时, 噪声可能会影响信号的时频重构效果。2D-ResNet 网络结构庞大, 硬件需求高, 处理时间较长。当数据不充分时, 该模型不

具备良好的泛化效果, 进而充分捕捉特征。ISSA-XGBoost 对少数类数据的特征无法充分捕捉。SVM-CART 可能对噪声更为敏感导致整体识别情况略逊本文模型。5 种模型对 16 种扰动的识别情况如图 11 所示。

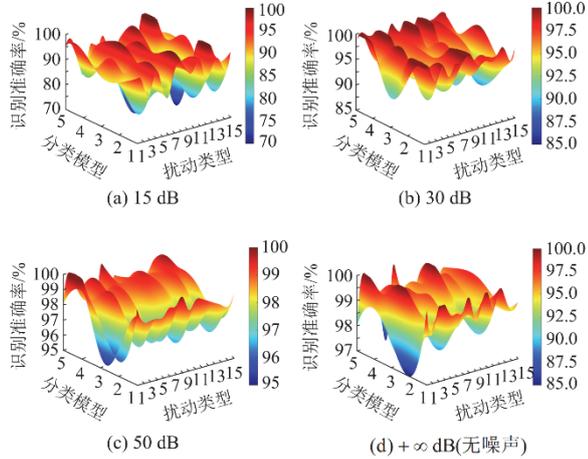


图 11 不同信噪比下 5 种模型识别 16 种 PQDs 精度

Fig. 11 Recognition accuracy of sixteen types of PQDs with five models under different SNRs

由图 11 可以看出, 本文提出的模型对各类型扰动均有高的识别准确率, 这进一步表明了本文模型在扰动识别中的有效性。

### 3.7.2 熵值指标对比

分别采用精细复合多尺度排列熵(refined composite multi-scale permutation entropy, RCMPE)、精细复合多尺度加权排列熵(refined composite multi-scale weighted permutation entropy, RCMWPE)、层次排列熵(hierarchical permutation entropy, HPE)提取扰动特征。识别准确率如表 7 所示, 每种扰动识别情况如图 12 所示。

表 7 不同信噪比下各类型熵值识别情况

Table 7 Recognition performance of different entropy types under various SNRs

熵值类型	HWPE	RCMPE	RCMWPE	HPE
B-A 平均 识别准确率	98.20	92.75	94.12	97.50

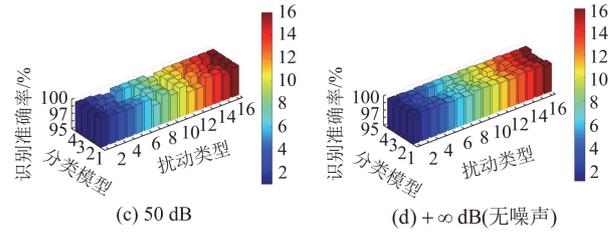
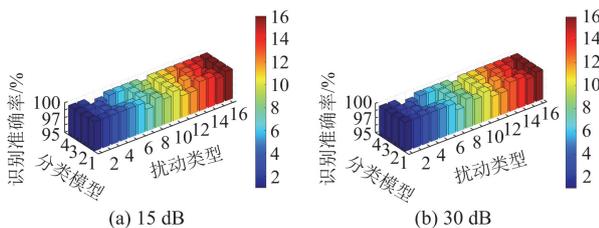


图 12 不同信噪比下 4 种熵值识别 16 种 PQDs 的精度

Fig. 12 Recognition accuracy of sixteen types of PQDs under different SNRs using four entropy values

由图 12 及表 7 可以看出, HWPE 特征获得的准确率最高, 其次是 HPE, RCMPE 准确率最低。这是因为 HWPE 和 HPE 充分提取了重构信号的高频特征, 而 RCMWPE 和 RCMPE 并未对时间序列开展层次化分割, 故存在特征漏提取的问题, 无法全面地描述电能质量的扰动特性。

## 4 结论

针对分布式电源接入智能配电网后产生的电能质量扰动问题, 本文提出了一种基于 GWO-ICEEMDAN-HWPE-BiLSTM-AM 的电能质量扰动识别模型。首先, 采用 GWO 算法优化 ICEEMDAN 超参数, 分解并重构电能质量扰动信号。然后, 计算重构信号的 HWPE 熵值生成扰动特征样本。最后, 提出 BiLSTM-AM 模型开展复合扰动识别, 本文主要结论如下。

1) 利用 GWO 优化 ICEEMDAN 超参数具有较好的效果, 结合 HWPE 提取的扰动特征能够准确地反映电能质量信号的扰动特性。

2) 提出的 BiLSTM-AM 模型具有较好的识别性能, 对比其他常用的识别算法, BiLSTM-AM 具有较高的识别准确率。

3) 相比其他的熵值指标, 基于 HWPE 的特征提取方法具有更好的合理性, 特征表征效果明显优于 HPE、RCMPE 和 RCMWPE。

## 参考文献

- [1] 欧奕昊, 姜彤, 张一航, 等. 考虑变流器无功调节特性的含高比例分布式光伏配电网电压控制方法[J]. 电力系统保护与控制, 2024, 52(20): 105-118.
- OU Yihao, JIANG Tong, ZHANG Yihang, et al. Voltage regulation method for a distribution network with high-penetration of distributed photovoltaic energy considering a converter's reactive power regulation characteristics[J]. Power System Protection and Control, 2024, 52(20): 105-118.

- [2] 宋平岗, 连加巍, 郑雅芝, 等. 基于线性自抗扰控制的单相电力电子变压器整流级控制策略[J]. 电测与仪表, 2024, 61(1): 177-182.  
SONG Pinggang, LIAN Jiawei, ZHENG Yazhi, et al. Single-phase power electronic transformer rectifier stage control strategy based on linear active disturbance rejection control[J]. Electrical Measurement & Instrumentation, 2024, 61(1): 177-182.
- [3] 李立生, 于海东, 刘洋, 等. 适应光伏高比例接入配电网的变流器控制策略[J]. 供用电, 2024, 41(3): 17-23.  
LI Lisheng, YU Haidong, LIU Yang, et al. Control strategy of converters for high penetration of PVs into distribution network[J]. Distribution & Utilization, 2024, 41(3): 17-23.
- [4] 庄重, 苏慧玲, 段梅梅, 等. 面向新型电力负荷管理的混杂负荷集群协同管控[J]. 电网技术, 2024, 48(8): 3459-3466.  
ZHANG Zhong, SU Huiling, DUAN Meimei, et al. Hybrid load cluster collaboration control for new power load management[J]. Power System Technology, 2024, 48(8): 3459-3466.
- [5] 吴润泽, 马伊嘉, 郭昊博, 等. 面向海量分布式新能源业务流的通存资源无交互协同预留算法[J]. 电力系统自动化, 2024, 48(23): 112-120.  
WU Runze, MA Yijia, GUO Haobo, et al. Interaction-free cooperative reservation algorithm of communication-cache resources for massively distributed renewable energy service flow[J]. Automation of Electric Power Systems, 2024, 48(23): 112-120.
- [6] 吴豫, 董智, 赵阳, 等. 基于 LSTM 算法的配电网分布式电源和电动汽车充电站联合优化规划[J]. 供用电, 2023, 40(6): 64-74.  
WU Yu, DONG Zhi, ZHAO Yang, et al. Joint optimization planning of distribution network DG and EV charging station based on LSTM algorithm[J]. Distribution & Utilization, 2023, 40(6): 64-74.
- [7] XIAO Xiangui, LI Kaicheng, ZHAO Chen. A hybrid compression method for compound power quality disturbance signals in active distribution networks[J]. Journal of Modern Power Systems and Clean Energy, 2023, 11(6): 1902-1911.
- [8] 于华楠, 于宏昊. 基于单向表示字典学习的电能质量扰动识别方法[J]. 电测与仪表, 2023, 60(4): 133-138.  
YU Huanan, YU Honghao. Power quality disturbance recognition method based on unidirectional representation dictionary learning[J]. Electrical Measurement & Instrumentation, 2023, 60(4): 133-138.
- [9] 刘宇龙, 崔宪阳, 袁丁, 等. 基于多级注意力机制融合的电能质量扰动点分类及时间定位方法研究[J]. 中国电机工程学报, 2024, 44(11): 4298-4311.  
LIU Yulong, CUI Xianyang, YUAN Ding, et al. Research on multi-level attention mechanism optimized method for point classification and time interval identification of power quality disturbances[J]. Proceedings of the CSEE, 2024, 44(11): 4298-4311.
- [10] 张彼德, 邱杰, 姜广鑫, 等. 基于 CNN 和 Transformer 的轻量化电能质量扰动识别模型[J]. 电力工程技术, 2025, 44(1): 69-78.  
ZHANG Bide, QIU Jie, LOU Guangxin. A lightweight power quality disturbance recognition model based on CNN and Transformer[J]. Electric Power Engineering Technology, 2025, 44(1): 69-78.
- [11] 王昭卿, 常延朝, 陈建磊, 等. 基于多融合 MVMD-ISVM 的复杂电能质量扰动识别方法[J]. 供用电, 2024, 41(9): 70-77.  
WANG Zhaoqing, CHANG Yanzhao, CHEN Jianlei, et al. Identification method for complex power quality disturbances based on multi-fusion MVMD-ISVM[J]. Distribution & Utilization, 2024, 41(9): 70-77.
- [12] 李琦, 许素安, 施阁, 等. 基于 S 变换和 IWOA - SVM 的复合电能质量扰动识别[J]. 智慧电力, 2023, 51(5): 30-35, 50.  
LI Qi, XU Su'an, SHI Ge, et al. Identification of composite power quality disturbance based on S-transform and IWOA-SVM[J]. Smart Power, 2023, 51(5): 30-35, 50.
- [13] 时帅, 陈子文, 黄冬梅, 等. 基于 MTF 可视化和改进 DenseNet 神经网络的电能质量扰动识别算法[J]. 电力科学与技术学报, 2024, 39(4): 102-111.  
SHI Shuai, CHEN Ziwen, HUANG Dongmei, et al. An identification method based on MTF visualization and improved DenseNet for power quality disturbances[J]. Journal of Electric Power Science and Technology, 2024, 39(4): 102-111.
- [14] 丁皓月, 吕干云, 史明明, 等. 基于 SCG 优化 SSAE-FFNN 的电能质量复合扰动深度特征提取与分类[J]. 电力工程技术, 2024, 43(3): 99-110.  
DING Haoyue, LÜ Ganyun, SHI Mingming, et al. Power quality composite disturbance deep feature extraction and classification based on SCG optimized SSAE-FFNN[J]. Electric Power Engineering Technology, 2024, 43(3): 99-110.
- [15] 王飞, 王立辉, 周少武, 等. 基于双分支并联的特征融合电能质量扰动分类方法[J]. 电力系统保护与控制, 2024, 52(5): 178-187.  
WANG Fei, WANG Lihui, ZHOU Shaowu, et al. A dual-branch parallel-based feature fusion approach for power quality disturbance classification[J]. Power System

- Protection and Control, 2024, 52(5): 178-187.
- [16] 王燕, 李雨婕, 卞安吉, 等. 一种数据库查询的多标签电能质量混合扰动识别与分类新方法[J]. 中国电机工程学报, 2024, 44(15): 5886-5899.  
WANG Yan, LI Yujie, BIAN Anji, et al. A new multi-label database query method for combined power quality disturbances classification and recognition[J]. Proceedings of the CSEE, 2024, 44(15): 5886-5899.
- [17] 王守相, 赵宁, 王同勋, 等. 基于轨迹颜色编码与知识蒸馏的电能质量扰动轻量化识别方法[J]. 电力自动化设备, 2024, 44(12): 85-91.  
WANG Shouxiang, ZHAO Ning, WANG Tongxun, et al. Lightweight identification method for power quality disturbance based on trajectory color coding and knowledge distillation[J]. Electric Power Automation Equipment, 2024, 44(12): 85-91.
- [18] ZHU Kunzhi, TENG Zhaosheng, QIU Wei, et al. Complex disturbances identification: a novel PQDs decomposition and modeling method[J]. IEEE Transactions on Industrial Electronics, 2023, 70(6): 6356-6365.
- [19] MA Jun, TANG Qiu, HE Minjun, et al. Complex PQD Classification using time-frequency analysis and multiscale parallel attention residual network[J]. IEEE Transactions on Industrial Electronics, 2024, 71(8): 9658-9667.
- [20] LI Pan, ZHANG Han, XIANG Wenxu, et al. A fast adaptive S-transform for complex quality disturbance feature extraction[J]. IEEE Transactions on Industrial Electronics, 2023, 70(5): 5266-5276.
- [21] LUO Yi, LI Kaicheng, LI Linfeng, et al. A novel recognition method for complex power quality disturbances based on rotation vector and fuzzy transfer field[J]. IEEE Transactions on Industrial Informatics, 2024, 20(11): 12502-12512.
- [22] JI Ning, CHEN Xi, QIN Xue, et al. Transformer fault identification based on GWO-optimized dual-channel MA method[J]. PloS one, 2024, 19(10).
- [23] 寇晓适, 王德琳, 柯佳颖, 等. 基于雷达回波与 LSTM 的输电线路强对流灾害风险预警方法[J]. 电力工程技术, 2024, 43(5): 189-198.  
KOU Xiaoshi, WANG Delin, KE Jiaying, et al. Risk early warning method of severe convective disasters for transmission lines based on radar echo and LSTM[J]. Electric Power Engineering Technology, 2024, 43(5): 189-198.
- [24] 王义国, 林峰, 李琦, 等. 基于 TCN-LSTM 模型的电网电能质量扰动分类研究[J]. 电力系统保护与控制, 2024, 52(17): 161-167.  
WANG Yiguo, LIN Feng, LI Qi, et al. Classification of power quality disturbances in a power grid based on the TCN-LSTM model[J]. Power System Protection and Control, 2024, 52(17): 161-167.
- [25] REN Gang, ZHA Xianguang, JIANG Bing, et al. Location of multiple types of faults in active distribution networks considering synchronization of power supply area data[J]. Applied Sciences, 2022, 12(19).
- [26] TAO Kai, CHEN Geen, WANG Qiang, et al. Ultrasonic curved coordinate Transform-RAPID With Bayesian method for the damage localization of pipeline[J]. IEEE Transactions on Industrial Electronics, 2024, 71(11): 15066-15076.
- [27] 张博智, 张茹, 焦东翔, 等. 基于 VMD-SAST 的电能质量扰动分类识别方法[J]. 中国电力, 2024, 57(2): 34-40.  
ZHANG Bozhi, ZHANG Ru, JIAO Dongxiang, et al. Power quality disturbance identification method based on VMD-SAST[J]. Electric Power, 2024, 57(2): 34-40.
- [28] 宋铁维, 施伟锋, 毕宗, 等. 基于 2D-ResNet 的船舶电力系统电能质量扰动识别[J]. 电力系统保护与控制, 2022, 50(10): 94-103.  
SONG Tiewei, SHI Weifeng, BI Zong, et al. Shipboard power quality disturbance recognition based on a two dimensional residual network[J]. Power System Protection and Control, 2022, 50(10): 94-103.
- [29] 商立群, 李朝彪, 邓力文, 等. 基于 ISSA-XGBoost 的电能质量扰动识别方法研究[J]. 电力系统保护与控制, 2024, 52(13): 115-124.  
SHANG Liqun, LI Chaobiao, DENG Liwen, et al. A power quality disturbance identification method based on ISSA-XGBoost[J]. Power System Protection and Control, 2024, 52(13): 115-124.
- [30] 陈诺, 吕干云, 叶加星. 基于 SVM 级联决策树的复合电能质量扰动识别[J]. 电气工程学报, 2023, 18(2): 149-156.  
CHEN Nuo, LYU Ganyun, YE Jiaying. Recognition of complex PQ disturbances based on SVM cascaded decision tree[J]. Journal of Electrical Engineering, 2023, 18(2): 149-156.

收稿日期: 2024-03-31; 修回日期: 2025-03-13

作者简介:

周建华(1983—), 男, 博士, 高级工程师, 研究方向配电网优化运行控制技术。E-mail: zhoujianhua83@126.com

(编辑 许威)