# 基于混合多尺度模糊熵的配电网电能质量复合扰动检测

# 马国煜, 陶 锴\*

## 南京邮电大学自动化学院、人工智能学院 江苏南京

【摘要】电能质量扰动检测对保障分布式新能源接入的电力系统运行稳定性至关重要。为提升电能质量 扰动检测精度,本文提出了一种融合 NRBO (Newton Raphson Based Optimizer)、BiGRU (Gated Recurrent Unit)及 AM (Attention Mechanism)的扰动自适应检测方法。首先,通过 NRBO 优化模态分解的超参数, 并提取电能质量扰动信号的混合多尺度模糊熵 (Composite Multiscale Fuzzy Entropy, CMFE)特征向量。提 取扰动信号特征,为后续检测提供可靠的数据基础。随后,本文提出 BiGRU-AM 模型以检测多类型电能质 量复合扰动。为验证方法的有效性,本文开展了 8 种单一扰动和 8 种复合扰动的检测实验,并与其他 6 种 算法对比。结果表明,该方法显著提升了性能,在扰动特征提取和检测准确性方面有好的表现优异。

【关键词】配电网;电能质量扰动;NRBO;CMFE;BiGRU-AM 【基金项目】江苏省自然科学基金(BK20210600) 【收稿日期】2025 年 2 月 20 日 【出刊日期】2025 年 3 月 18 日 【DOI】10.12208/j.jeea.20250076

#### Multiscale fuzzy entropy-based composite disturbance detection for power quality in distribution grids

# Guoyu Ma, Kai Tao\*

## School of Automation and Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu

**【Abstract】** Power quality disturbance detection is crucial for ensuring the operational stability of power systems with integrated distributed renewable energy. To enhance detection accuracy, this paper proposes an adaptive disturbance detection method integrating the NRBO, BiGRU-AM. First, the hyperparameters of modal decomposition are optimized via NRBO, and the composite multiscale fuzzy entropy (CMFE) feature vectors of power quality disturbance signals are extracted. This establishes a reliable data foundation for subsequent detection. Subsequently, a BiGRU-AM model is proposed to detect multiple types of composite power quality disturbances. To validate the method's effectiveness, experiments were conducted on eight types of single disturbances and eight types of composite disturbances, with comparisons against six other algorithms. The results demonstrate demonstrated superior classification performance in composite disturbance scenarios.

[Keywords] Distribution network; Power quality disturbance; NRBO; CMFE; BiGRU-AM

# 引言

随着可再生能源技术在电力系统中的深度应用, 以光伏、风能及生物质能为代表的分布式电源在现 代智能配电网中占比持续提升<sup>[1]</sup>。这种能源结构的 转型在推动电力系统低碳化发展的同时,也因分布 式电源固有的间歇性和不稳定性引发了新型电能质 量问题。特别是多源逆变器并网产生的功率波动与 电网固有特性相互作用,导致电能质量扰动呈现复 合化、高频化的特征演变,对电网保护装置和精密 用电设备构成潜在威胁。依据 IEEE 制定的标准,智 能配电网包含多种形式的扰动,例如:暂态震荡、暂 态冲击、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,例如:暂升+尖峰、谐波+暂降等,此种 扰动复合特性加剧了标签分类系统的复杂性。

IEEE 制定的电能质量标准体系明确将电网扰

作者简介:马国煜(1999-),硕士,研究方向为电力系统故障诊断;

<sup>\*</sup>通讯作者: 陶锴(1993-),博士,副教授,研究方向为电力系统扰动检测。

动划分为暂态振荡、电压暂升/暂降、供电中断等基 本类型。实际运行数据显示,现代电网中超过 65% 的电能质量事件表现为多种基础扰动的耦合形态, 典型如暂态冲击叠加高频谐波、电压骤降伴随相位 跳变等现象。这种多维度扰动叠加特性不仅增加了 信号特征的解耦难度,更对检测系统的模式标签分 类能力提出了更高要求。

人工智能方法在复杂场景电能质量扰动标签分 类中的应用愈发广泛。例如,文献[2]基于改进经验 小波变换和 XGBoost 算法实现了电能质量复合扰动 快速准确标签分类。文献[3]提出一种基于改进 DenseNet 神经网络的电能质量特征数据扰动标签分 类模型。文献[4]开展了弱电网中并联逆变器作用下 的电能质量标签分类及治理研究。文献[5]利用多尺 度 Transformer 进行电能质量分类。文献[6]利用知识 蒸馏与 RP-MobileNetV3 展开电能质量复合扰动识 别。参数优化调节、特征选择对数据驱动的扰动标 签分类准确性有重要影响。传统智能算法在分布式 新能源接入后引发的电能质量扰动标签分类准确性 上具有可提高空间。

为实现分布式新能源并网引发的电能质量扰动 高效标签分类,本文采用 NRBO (Newton Raphson Based Optimizer)优化模态分解参数,重构去噪扰动 信号并提取扰动特征。然后,提出 BiGRU (Gated Recurrent Unit)-AM (Attention Mechanism)模型 开展电能质量复合扰动标签分类。基于 IEEE Std 1159-2019 标准仿真 16 种扰动信号,与其他 6 种算 法开展标签分类对比实验,结果显示本方法在多项 指标上具有好的表现。

1 NRBO 优化与 BiGRU-AM 模型

1.1 扰动信号特征模态分解

1.1.1 OFMD

(1) 信号分解

特征模态分解(Feature Mode Decomposition, FMD),相比传统的 EMD 和 VMD,具有更强的鲁 棒性和灵活性,适用于复杂非平稳信号的分析。然 而由于 FMD 不具备参数的自适应性,因此需要提前 人工设定重要参数。滤波器长度 L<sub>F</sub> 是影响 FMD 分 析结果的关键参数,因此引入梯度下降策略以及自 适应筛选实现 L<sub>F</sub> 的动态选择,形成 OFMD。

设损伤信号为 $x_F(n)$ ,接着将损伤信号频带平均

分为 $K_F$ 段,构建 $K_F$ 个 FIR(Finite Impulse Response) 滤波器,则有:

$$\begin{cases} f_1 = k_F \cdot f_s / 2K_F \\ f_{u_F} = (k_F + 1) \cdot f_s / 2K_F \end{cases}, k_F = 0, 1, 2L, K_F - 1 \quad (1)$$

其中, f<sub>1</sub>及 f<sub>u</sub>, 分别为每个 FIR 滤波器上、下截 止频率。f<sub>s</sub>为采样频率。接着更新滤波器以及估计 损伤信号周期, 损伤信号长度为 N。相关峭度 K<sub>c</sub>为 衡量模态信号聚焦程度和结构特征的重要指标。为 了使得算法更加聚焦于这一指标, 必须最大化 K<sub>c</sub>。 则列出约束方程:

$$\arg\max_{\{f_{k}(l)\}} \left\{ K_{C,R_{F}}\left(u_{k_{F}}\right) = \sum_{n=1}^{N} \frac{\left[\prod_{m_{F}=0}^{R_{F}} u_{k_{F}}\left(n-m_{F}T_{s}\right)\right]^{2}}{\left[\sum_{l_{F}=1}^{N} u_{k_{F}}\left(n\right)^{2}\right]^{R_{F}+1}}\right\}$$
(2)  
s.t.  $u_{k_{F}}\left(n\right) = \sum_{l_{F}=1}^{L_{F}} f_{k}\left(l_{F}\right) x_{F}\left(n-l_{F}+1\right)$ 

其中,  $R_F$ 为周期移位的阶数,表示模态特征在 周期维度上的聚焦程度。 $T_s$ 为使用采样数测量的输 入周期。约束条件中 $u_{k_F}(n)$ 表示第 $k_F$ 个滤波器 $f_{k_F}(l_F)$ 从 $x_F(n)$ 中提取的第 $k_F$ 个模态分量。通过对信号进行 子频段的选择性提取,使得每个模态分量 $u_{k_F}(n)$ 聚焦 于特定频段的信号特征。针对上述约束方程,利用 迭代特征值分解算法,如下所示:

$$\begin{cases} \boldsymbol{u}_{k_{F}} = \boldsymbol{X}_{F}\boldsymbol{f}_{k_{F}} = [\boldsymbol{u}_{k_{F}}(1), \boldsymbol{L}, \boldsymbol{u}_{k_{F}}(N-L_{F}+1)]^{\mathrm{T}} \\ \boldsymbol{X}_{F} = \begin{bmatrix} \boldsymbol{x}_{F}(1) & \boldsymbol{L} & \boldsymbol{x}_{F}(L_{F}) \\ \boldsymbol{M} & \boldsymbol{O} & \boldsymbol{M} \\ \boldsymbol{x}_{F}(N-L_{F}+1) & \boldsymbol{L} & \boldsymbol{x}_{F}(N) \end{bmatrix} \\ \boldsymbol{f}_{k_{F}} = [\boldsymbol{f}_{k_{F}}(1), \boldsymbol{L}, \boldsymbol{f}_{k_{F}}(L_{F})]^{\mathrm{T}} \end{cases}$$
(3)

其中,  $u_{k_{F}}$ 表示各分解模态,  $X_{F}$ 表示各 $k_{F}$ 采样 段组合形成的嵌入矩阵,  $f_{k_{F}}$ 为各滤波器系数。然而 滤波器长度过大可能导致模态能量分散,过小可能 导致频带混叠。因而采取梯度下降策略,如下所示:

$$\begin{cases} E_{k_{F}} = \left(\sum_{n=1}^{N-L_{k_{F}}+1} \left| u_{k_{F}}(n) \right|^{2} \right) / L_{k_{F}} \\ L_{k_{F},i_{F}+1} = L_{k_{F},i_{F}} - \eta_{F} \frac{\partial E_{k_{F}}}{\partial L_{k_{F}}} \end{cases}$$
(4)

其中,  $E_{k_r}$  为各分解模态的能量集中度,  $E_{k_r}$  越大则  $L_{k_r}$  越小。给出频带能量熵  $H_{BEE}$  (Band Energy

Entropy, BEE) 判别条件:

$$\begin{cases} H_{BEE} = -\sum_{k_{F}=1}^{K_{F}} P_{k_{F}} \ln P_{k_{F}} = -\sum_{k_{F}=1}^{K_{F}} \frac{E_{k_{F}}}{\sum_{k_{F}=1}^{K_{F}} E_{k_{F}}} \ln \frac{E_{k_{F}}}{\sum_{k_{F}=1}^{K_{F}} E_{k_{F}}} \\ P_{k_{F}} > \tau_{F}, 0 \le H_{BEE} \le \ln K_{F} \end{cases}$$
(5)

其中,  $P_{k_r}$ 为某频带能量比,  $\tau_F$ 为阈值。当  $P_{k_r} = 1/K_F$  (能量分布均匀)时,此时 $H_{BEE} = \ln K_F$ ,当 某频带能量比为1且其余均为0时,此时 $H_{BEE} = 0$ 。 当某 $P_{k_r} > \tau_F$ 时,即表明该频带的能量占比过高<sup>[7]</sup>,频 带能量分布不均匀,则通过式(4)继续迭代,直至 满足 $P_{k_F} \leq \tau_F$ 为止,此时可以得出满足要求的滤波器 长度 $L_F$ 。接着,为衡量各信号模态的特征表达程度, 引入各分解模态的相关峭度 $K_c$  (Correlated Kurtosis) 如下所示:数值越大表示信号模态越能反映信号的 特征

$$\begin{cases} K_{c}\left(\boldsymbol{u}_{k_{F}}\right) = \frac{\boldsymbol{f}_{k_{F}}^{\mathrm{H}}\boldsymbol{X}_{F}^{\mathrm{H}}\boldsymbol{W}_{F}\boldsymbol{X}_{F}\boldsymbol{f}_{k_{F}}}{\boldsymbol{f}_{k_{F}}^{\mathrm{H}}\boldsymbol{X}_{F}^{\mathrm{H}}\boldsymbol{X}_{F}\boldsymbol{f}_{k_{F}}} = \frac{\boldsymbol{f}_{k_{F}}^{\mathrm{H}}\boldsymbol{R}_{XWX}\boldsymbol{f}_{k_{F}}}{\boldsymbol{f}_{k_{F}}^{\mathrm{H}}\boldsymbol{R}_{XX}\boldsymbol{f}_{k_{F}}} & (6)\\ \boldsymbol{R}_{XWX}\boldsymbol{f}_{k_{F}} = \boldsymbol{R}_{XX}\boldsymbol{f}_{k_{F}}\boldsymbol{\lambda}_{F} \end{cases}$$

其中, $W_F$ 为加权矩阵, $R_{xwx}$ 为加权相关矩阵,  $R_{xx}$ 为普通相关矩阵, $\lambda_F$ 表示调节系数。

在迭代过程中,通过式(6)的解更新第 $k_F$ 个滤 波器系数,不断逼近设定目标。随着 FIR 滤波器的 更新,周期估计也会更新,并且越来越精确。最后进 行模态选取<sup>[8]</sup>,在相关系数(Correlation Coefficient) 最大的两个模态中放弃 $K_c$ 较小的模态,两个模态 $u_{p_F}$ 和 $u_{a_F}$ 的相关系数定义为:

$$C_{F,pq} = \frac{\sum_{n=1}^{N} \left[ u_{p_{F}}(n) - \overline{u}_{p_{F}} \right] \left[ u_{q_{F}}(n) - \overline{u}_{q_{F}} \right]}{\sqrt{\sum_{n=1}^{N} \left[ u_{p_{F}}(n) - \overline{u}_{p_{F}} \right]^{2}} \sqrt{\sum_{n_{F}=1}^{N} \left[ u_{q_{F}}(n) - \overline{u}_{q_{F}} \right]^{2}}}$$
(7)

其中,  $\bar{u}_{p_{r}}$ 及 $\bar{u}_{q_{r}}$ 分别为 $u_{p_{r}}$ 及 $u_{q_{r}}$ 的均值。 $C_{F,pq}$ 越大表示两个模态间的相似程度越高,设定相关系数 阈值 $C_{thre}$ 。当 $C_{F,pq} < C_{thre}$ 时,不再筛选模态,分解完成。

(2) 信号重构

设分解得到模态个数为*M*。。为进一步提高重构 效果,引入最小化均方误差 MSE,对信号进行多次 重构,每次重构后计算当前重构信号与原损伤信号 的 MSE 值,如下所示:

$$\begin{cases} x_m(n) = \sum_{k_F=1}^{M_o} \alpha_{k_F} u_{k_F}(n) \\ MSE = \frac{1}{N} \sum_{n=1}^{N} \left[ x_F(n) - x_m(n) \right]^2 = \left\| \mathbf{x}_F - \mathbf{u}_{k_F} \alpha_{k_F} \right\|^2 \end{cases}$$
(8)

其中,  $x_m(n)$ 表示中间重构信号,随着  $M_o$ 的增加, MSE 减小,但在某次重构之后,增加更多的模态数 所带来的误差减小非常有限。此时设定限值 MSE<sub>thre</sub>, 选择使得 MSE 低于限值时的模态个数  $M_F$  作为最终 的模态数。重构信号为 x(n):

$$\begin{cases} x(n) = \sum_{k_{F}=1}^{M_{F}} \alpha_{k_{F}} u_{k_{F}}(n) \\ \{M_{o} = M_{o} + 1, & \text{if } MSE > MSE_{thre} \\ M_{o} = M_{F}, & \text{if } MSE \le MSE_{thre} \end{cases}$$
(9)

1.1.2 NRBO

(1) 种群初始化

牛顿-拉夫逊算法(Newton Raphson Based Optimizer, NRBO)采用 Newton-Raphson 搜索规则(NRSR)提高算法本身的探索能力,在提升收敛速度的同时,通过引入陷阱避免算子来避免局部最优陷阱,具体流程如下:

首先初始化种群,随机生成个体初始位置如下 所示:

$$\begin{cases} \delta_m^j = lb + \operatorname{rand} (up - lb) \\ j \in [1, \dim], m \in [1, N_\delta] \end{cases}$$
(10)

其中,为第 m 个个体在第 *j* 维度的位置, up 及 lb 分别为待优化参数的上、下限, rand(·)表示(0,1) 间的随机数。

(2) N-R 搜索规则(NRSR)

NRSR 可以加快算法收敛,首先给出更新后的 位置:

$$\begin{cases} \delta_{m+1} = \delta_m - \frac{\left[f\left(\hat{\delta}_m\right) - f\left(\hat{\delta}_m\right)\right] \cdot \Delta\delta}{2\left[f\left(\hat{\delta}_m\right) - f\left(\hat{\delta}_m\right) - 2f\left(\delta_m\right)\right]} & (11) \\ \hat{\delta}_m = \delta_m + \Delta\delta, \delta_m = \delta_m - \Delta\delta \end{cases}$$

其中, $\Delta\delta$ 为位置增量, $f(\cdot)$ 为对应位置适应度 值, $\delta_m - \Delta\delta$ , $\delta_m + \Delta\delta$ 分别表示相邻于 $\delta_m$ 的个体位置, 通过引入 NRSR 来进一步表述各个体的位置,如下 所示:

$$\begin{cases} \text{NRSR} = \text{rand}_{n} \times \frac{\left(\delta_{w} - \delta_{b}\right) \cdot \Delta \delta}{2 \times \left(\delta_{w} - \delta_{b} - 2\delta_{m}\right)} & (12) \\ \delta_{m+1} = \delta_{m} - \text{NRSR} \end{cases}$$

其中, rand<sub>n</sub>为服从N(0,1)的随机数, δ<sub>w</sub>, δ<sub>b</sub> 分别表示最差及最佳位置,将式(13)中适应度值替 换为位置量这一操作节省了计算时间,引入自适应 系数 *ζ* 表示位置增量,如下所示:

$$\begin{cases} \Delta \delta = \operatorname{rand}(1, \dim) \times \left| \delta_b - \delta_m^{it} \right| \\ \zeta = \left[ 1 - \left( 2 \cdot it / it_{\max} \right) \right]^5 \end{cases}$$
(13)

其中, it 为当前迭代次数, it<sub>max</sub> 为最大迭代次数, 接着通过参数 ρ 将种群引入正确位置。

$$\begin{cases} \delta \mathbf{l}_{m}^{it} = \delta_{m}^{it} - [\operatorname{rand}_{n} \times \operatorname{NRSR}] + \rho \\ \rho = a_{nr} \left( \delta_{b} - \delta_{m}^{it} \right) + b_{nr} \left( \delta_{r_{1}}^{it} - \delta_{r_{2}}^{it} \right) \end{cases}$$
(14)

其中, *a<sub>m</sub>*, *b<sub>m</sub>*均为 (0,1) 间的随机数, *δ<sup>u</sup><sub>r<sub>1</sub>*</sub>, *δ<sup>u</sup><sub>r<sub>2</sub></sub>* 为随机位置, *δ*l<sup>u</sup><sub>m</sub>为当前位置。引入 NRM 进一步改 进 NRSR, 如下所示:

$$\begin{cases} Y_{m+1} = \delta_m - \operatorname{rand}_n \times \operatorname{NRSR} \\ \lambda_w = r_1 \left[ \operatorname{Mean} \left( Y_{m+1} + \delta_m \right) + r_1 \Delta \delta \right] \\ \lambda_b = r_1 \left[ \operatorname{Mean} \left( Y_{m+1} + \delta_m \right) - r_1 \Delta \delta \right] \end{cases}$$
(15)

其中, λ<sub>o</sub> 及 λ<sub>o</sub> 为新的最优及最差位置,新的 NRSR 如下所示:

$$\begin{cases} \operatorname{NRSR} = \operatorname{rand}_{n} \left( \lambda_{w} - \lambda_{b} \right) \Delta \delta / 2 \left( \lambda_{w} + \lambda_{b} - 2 \delta_{m} \right) \\ \delta \mathbf{1}_{m}^{it+1} = r_{2} \left[ r_{2} \cdot \delta \mathbf{1}_{m}^{it} + (1 - r_{2}) \cdot \delta \mathbf{2}_{m}^{it} \right] + (1 - r_{2}) \cdot \delta \mathbf{3}_{m}^{it} \\ \delta \mathbf{3}_{m}^{it} = \delta_{m}^{it} - \zeta \left( \delta \mathbf{2}_{m}^{it} - \delta \mathbf{1}_{m}^{it} \right) \\ \delta \mathbf{2}_{m}^{it} = \delta_{b} - \operatorname{NRSR} + \rho \end{cases}$$

$$(16)$$

(3) 陷阱规避操作(TAO) 若个体满足以下条件,则判定为陷入局部最优:

$$\left\|f(\delta_m^i) - f(\delta_m^{i-k})\right\| < \varepsilon, (k \ge 5, \varepsilon = 1e^{-6})$$
(17)

$$\begin{cases} \delta_{new}^{m} = \delta_{m}^{it} + \zeta \cdot \operatorname{rand}_{n} \cdot (\delta_{b} - \delta_{m}^{it}) + \eta (\delta_{r}^{it} - \delta_{s}^{it}) \\ \eta = (1 - it / it_{\max}) / 2 \end{cases}$$
(18)

其中, η为扰动强度系数, δ<sup>#</sup><sub>s</sub> 、δ<sup>#</sup><sub>s</sub> 为随机选择 的个体位置。若扰动后位置超出搜索空间, 按反射 边界策略调整, 如下式所示:

$$\delta_{new}^{j} = \begin{cases} 2 \cdot lb - \delta_{new}^{j}, \delta_{new}^{j} < lb\\ 2 \cdot ub - \delta_{new}^{j}, \delta_{new}^{j} > ub \end{cases}$$
(19)

接着,动态调整ζ,确保算法后期稳定收敛:

$$\zeta = 0.8e^{-(it/it_{\max})} \tag{20}$$

TAO 通过结合全局最优方向引导与随机差分扰 动,平衡局部开发与全局探索,避免过早收敛。

1.2 CMFE 特征提取

提取扰动信号的混合多尺度模糊熵(Composite Multiscale Fuzzy Entropy, CMFE)特征。

(1) 粗粒化过程

对于每个尺度因子 $\tau$ ,生成 $\tau$ 个不同的粗粒化序 列<sup>[9-11]</sup>。设原始时间序列 $\{x_1, x_2, L, x_G\}$ ,对于每个尺度  $\tau$ ,生成粗粒化序列 $y^s, g = 1, 2, L, \tau$ ,有

$$\begin{cases} y_{j}^{(g)} = \frac{1}{\tau} \sum_{i=0}^{\tau-1} x_{g+(j-1)\tau+i}, j = 1, 2, L, J \\ J = \lfloor (G-g+1)/\tau \rfloor \end{cases}$$
(21)

其中, |.|表示向下取整操作。

(2) 计算 FE

生成 a 维向量  $X_i^a$ , i = 1, 2, L, J - a + 1, 计算任意向量间距离及相似度,如下式所示:

$$\begin{cases} d_{ij}^{a} = \max_{g=0}^{a-1} |X_{i}^{a}(g) - X_{j}^{a}(g)|, j \neq i \\ X_{i}^{a} = (y_{i}, y_{i+1}, \mathsf{L}, y_{i+a-1}) \\ D_{ii}^{a} = e^{-[(d_{ij}^{a})^{2}/b]} \end{cases}$$
(22)

其中, $d_{ij}^{a}$ 表示向量间距离, $D_{ij}^{a}$ 表示向量间相似度,a为嵌入维数,b为相似性容限。接着,计算所有向量的平均相似度 $\Phi^{(a)}$ :

$$\Phi^{(a)} = \frac{1}{J-a} \sum_{i=l}^{J-a} \left[ \frac{1}{J-m-1} \sum_{j=1, j\neq i}^{J-a} D^a_{ij} \right]$$
(23)

重复上述操作,构造 *a*+1 维向量,得到Φ<sup>(*a*+1)</sup>,可计算模糊熵值(Fuzzy Entropy, FE)<sup>[12]</sup>,如下所示:

$$FE = \ln(\Phi^{(a)} / \Phi^{(a+1)})$$
(24)

(3) 计算 CMFE

计算每个尺度子序列的 FE 值 FE<sup>(g)</sup>, 取均值可得 CMFE 值, 如下所示:

$$CMFE = \left(\sum_{g=l}^{\tau} FE^{(g)}\right) / \tau$$
 (25)

CMFE 特征在提取扰动信号高频信息的同时也 保留了低频成分的电能质量信息。

1.3 BiGRU-AM 检测

本文所采用的 BiGRU-AM<sup>[13]</sup>扰动检测模型如 图 1 所示。

模型由 BiGRU 层、AM 层组成。BiGRU 层提取数据时间特征,将结果输入 AM 层。AM 层基于数据计算各特征权重,计算流程如下:

1)将预处理后的特征输入到 BiGRU 网络。

BiGRU 层会生成前向和后向的隐藏状态,这些隐藏状态将作为后续 AM 层的输入。

2) 计算注意力权重:对于每一个时间步,计算 其对应的注意力权重。

3)加权求和:基于计算的注意力权重对隐藏状态加权求和,生成注意力加权后的特征向量。

4) 输出预测:通过 AM 层的输出,生成最终的 预测结果。

2 电能质量扰动检测流程







图 2 扰动检测流程

首先,采用 NRBO 对 OFMD 参数进行优化,并 利用最优参数分解扰动信号,得到 IMF 分量。选择 具有较大相关系数的分量进行重构。随后,利用 CMFE 提取重构信号的扰动特征。最后,利用 BiGRU-AM 开展扰动检测,具体流程如图 2 所示, 流程如下:

1)采用 NRBO-FMD 算法分解原始扰动信号, 生成多组 IMF。

2) 基于相关系数阈值筛选 IMF 分量, 实现信号 重构。

3)利用 CMFE 提取重构信号的模糊熵值,构建 电能质量扰动特征样本。

4)运用 AM 机制优化 BiGRU 网络参数,通过 特征训练实现扰动检测。

## 3 算例分析

3.1 测试数据提取

根据 IEEE Std 1159-2019 标准和给定的电能质

量扰动数学模型,选择生成8种单扰动(含正常信号),8种双扰动,共计16种扰动信号(编号C1~C16)。 扰动样本由 MATLAB/Simulink 根据 IEEE 标准建模 生成。

模型训练在 Python 3.9 + PyTorch 2.0 平台上完成,使用 NVIDIA RTX3080 GPU 加速。其中扰动信号基波频率设置为 50Hz,连续采样时间 0.2 s,共计 采样 1000 点。各类扰动分别生成 100 个样本。16 种 扰动信号如图 3 所示。

图 3 展示了当分布式新能源接入智能配电网后 产生的 16 中不同类型的电能质量扰动。

3.2 扰动信号模态分解

对扰动信号进行模态分解。首先,采用 NRBO 优化 FMD 的滤波器长度 L<sub>F</sub>。然后,设置 L<sub>F</sub>的优化 范围为[0.15,0.6],迭代次数设置为 30,种群规模为 10。选择最小包络熵为适应度函数。下图表征了 8 种 单扰动适应度变化。



图 3 电能质量扰动波形图



图 4 8 种单扰动适应度曲线

| 表 1 FMD 参数                 |        |        |        |        |  |  |
|----------------------------|--------|--------|--------|--------|--|--|
| 扰动                         | C2     | C8     | С9     | C14    |  |  |
| $L_{\scriptscriptstyle F}$ | 0.150  | 0.591  | 0.168  | 0.235  |  |  |
| 最佳适应度                      | 5.2394 | 6.4092 | 5.6890 | 6.2946 |  |  |



图 5 C10 扰动信号的各 IMF 波形

图 4 中显示,除 C8 以外的七种扰动初期适应 度值均略有波动,随后趋于平稳。部分扰动对 NRBO 优化模型的影响在早期表现较明显,但模型能很快 收敛。在迭代多次后,8 种曲线均趋于平稳,NRBO 优化效果达到最佳。经过 NRBO 优化得到的 FMD 最佳参数如表1所示。

将最佳 L<sub>F</sub> 代入 FMD 中,分解各电能质量扰动信号。以 C10 扰动信号为例,其分解结果如图 5 所示。

图 5 显示, IMF1~IMF4 保留了扰动原始信号的 多数特征,而 IMF5~IMF8 仅保留了少数特征。采用 各 IMF 分量与原始信号的相关系数*r*<sub>k</sub>评估相关性, 结果如图 10 所示。

图 6 显示,各扰动信号的 IMF1 和 IMF2 与对应 原始信号的相关系数较高,而在 IMF3 及之后,相关 系数逐渐降低。这表明在前几阶 IMF 中,各扰动信 号与原始信号的相关性更强,随着 IMF 序号增加, 相关性变得越来越小。部分扰动的后几阶 IMF 与对 应原始信号的相关系数高于其余扰动。

3.3 扰动信号特征提取

3.3.1 扰动信号重构

图 6 表明,低阶 IMF 分量包含了主要的信息。 计算阈值 $r_{thr}$ ,若某 IMF 与原始信号的相关系数 $r_k$ 大于 $r_{thr}$ ,则该 IMF 分量被保留用于重构信号,否 则该 IMF 将被剔除。部分扰动的 IMFs 与原始信号 的相关系数阈值如下表 2。

以扰动 C14 为例,该类型扰动的r<sub>thr</sub>为 0.156,因此保留前 6 个 IMF 重构该扰动信号,信号重构对比如图 7 所示。

图中显示,重构后信号曲线在未暂升时有极小 部分未能覆盖原始信号曲线,当暂升扰动出现后, 原始信号曲线几乎被覆盖,扰动特征被很好的保留。

3.3.2 CMFE 特征提取

提取各扰动信号的 CMFE 特征。设置 CMFE 的 嵌入维数 *a* = 5,相似性容限 *b* = 0.5。首先,为了评 估不同类型电能质量扰动信号差异,采用 FE 对 8 种 双扰动信号进行分析,结果如图 8 所示。

由图 8 可以得出,部分扰动类型的 FE 值较为 混乱,并不具备差异。同时,暂升+谐波等部分扰动 的 FE 值较小。这是因为生成扰动参数时,扰动幅度 较小,近似正常信号,故熵值较小。对经 NRBO-FMD 分解和重构后的信号进行 CMFE 分析,得到 16 种 电能扰动类型在 7 个特征尺度下的 CMFE 值,16 种 扰动的 CMFE 值随特征尺度变化如图 9 所示。

由图 9 可知,在各个特征尺度上,扰动 CMFE 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。不同尺度的 CMFE 值反映了信号在 不同频率范围内的特征。在某些尺度上,特定类型 的扰动可能会对特征有明显的影响,从而导致 CMFE 值出较大的波动。为了增加特征的区分度, 提高扰动检测准确率,选择各类扰动差异较大的 4 个尺度的特征来构造扰动特征样本。





表 2 部分扰动 IMFs



图 8 8 种双扰动信号的 FE 值



表 3 各模型扰动检测情况

| 模型                       | 准确率/%  | 查准率/%  | 召回率/%  | F1-score/% |
|--------------------------|--------|--------|--------|------------|
| 1.本文模型                   | 98.44% | 98.44% | 98.50% | 98.47%     |
| 2.DAGSVM <sup>[15]</sup> | 92.50% | 92.61% | 93.79% | 93.20%     |
| 3.BiLSTM                 | 89.69% | 89.68% | 91.80% | 90.73%     |
| 4.KPCA                   | 95.62% | 95.65% | 96.16% | 95.90%     |
| 5.FRNN                   | 86.25% | 86.25% | 88.11% | 87.17%     |

3.4 扰动检测结果

将提取的电能质量扰动特征按照 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 个样本中任意抽取 80 个作为训练样本,20 个作为 测试样本。利用 BiGRU-AM 对其进行扰动检测。测 试样本的 BiGRU-AM 分类结果如图 10 所示。

图 10 显示,共计 12 类电能质量扰动样本均被 准确检测,其余部分样本均有检测错误的情况。其 中,第3 类中2 个样本(C3:电压暂降)被错误地 检测为第 2 类样本(C2: 电压暂升),准确率为 90.00%。这是因为生成电压暂升信号时忽略了幅值 上升的过程,当幅值恢复正常时这一过程与电压暂 降这一扰动特征类似,从而影响检测结果。整个测 试实验中,被准确检测的样本为 315 个,被错误检 测的样本为 5 个,总的检测准确率为 98.44%。

3.5 检测算法对比

3.5.1 检测模型对比

为验证本文方法的有效性,选择 DAGSVM、

# BiLSTM、KPCA、FRNN、CNN 进行对比。

对比指标有准确率(Acc)、查准率 P、召回率 R、以及  $F_i$  – score。其中,查准率 P 表示在模型预测 为本类的所有结果中模型检测正确的比重。召回率 R 表示在真实值为本类的所有结果中模型检测正确 的比重<sup>[14]</sup>。 $F_i$  – score = 2P·R/(P+R),  $F_i$  – score 越接近 1,检测效果越好。各指标的对比结果如表所示。

表 3 可知,本文模型在各项指标均为最优,表 明该模型在扰动检测上较其余几种方法更好。这表 明了本文模型在扰动检测过程中的有效性。图 11 中 三维云图展示了 6 种模型对 16 种扰动的具体检测 情况。

投影平面的二维等精确率热图也直观反映了本 方法的优越性。云图在第6类算法(CNN)检测第 4种扰动(C4:振荡)时有明显凹陷,精确率较低, 且检测C6、C16时,当扰动幅度过小时,CNN 难以 区分类似特征的扰动。



#### 图 11 6 种模型下对 16 种 PODs 的检测精度

CNN 综合检测准确率为 80.62%, 当部分扰动特 征较为相似时, CNN 并不能进行很好的检测。在第 3类模型(BiLSTM)检测 C13、第2类模型(DAGSVM) 检测 C12 时有明显凹陷, 这表明当振荡幅度过低或 时间过短、尖峰个数较少或幅值过低时, 两种算法 难以与其他特征相似的扰动(例如 C2: 电压暂升) 进行区分。本文模型对各类型扰动均有较高的检测 准确率, 这进一步表明了本文模型在扰动检测过程 中的有效性。

## 4 结论

针对分布式新能源接入智能配电网后产生电能 质量扰动问题,本文提出了一种基于 NRBO-FMD-CMFE-BiGRU-AM的电能质量扰动检测模型。首先, 采用 NRBO 算法优化 FMD 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 CMFE 熵 值生成扰动特征样本。最后,提出 BiGRU-AM 模型 开展复合扰动检测,本文主要结论如下:

1)利用 NRBO 优化 FMD 超参数具有好的效果, 结合 CMFE 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 BiGRU-AM 模型具有好的检测效果, 准确率达到了 98.44%。对比其他常用的检测算法, BiGRU-AM 具有最好的检测准确率。

3)本方法能有效进行电能质量检测,而无法进行电能质量扰动定位,因而将深入研究电能质量扰动,解决智能配电网出现的一系列问题。本方法特别适用于新能源占比高、电能质量问题频发的智能配电网场景。未来将进一步研究基于图神经网络的扰动源定位方法,并实现多区域协同扰动检测。

### 参考文献

- [1] 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): 10024.
- [2] 吴建章,梅飞,郑建勇,等.基于改进经验小波变换和 XGBoost 的电能质量复合扰动分类[J].电工技术学报, 2022, 37(1):232-43.
- [3] 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(04):102-111.
- [4] 张成,赵涛,朱爱华,等.弱电网下并联逆变器稳定性及电能质量治理研究[J].电力工程技术,2022,41(03): 224-230.
- [5] 王守相,李慧强,赵倩宇,等.基于时序二维变换和多 尺度 Transformer 的电能质量扰动分类方法[J].电力系 统自动化,2025,49(07):198-207.
- [6] 贺才郡,李开成,董宇飞,等.基于知识蒸馏与 RP-MobileNetV3 的电能质量复合扰动识别[J].电力系统保 护与控制, 2023, 51(14): 75-84.
- [7] Ni Q, Luo H, Liu J, et al. A Feature Vector Learning-Based Method for Diagnosing Main Circuit Ground Faults in Electrical Traction Drive Systems[J]. IEEE Transactions on

Power Electronics. 2024, 39(2): 2537-45.

- [8] Chen X, Ji N, Qin X, et al. Transformer Fault Diagnosis Based on the Improved Sparrow Search Algorithm and Random Forest Feature Selection[C]. 2024 3rd International Conference on Energy and Electrical Power Systems (ICEEPS), Guangzhou, China, 2024, 1086-1091.
- [9] Chen W, Shi K. A deep learning framework for time series classification using Relative Position Matrix and Convolutional Neural Network[J]. Neurocomputing. 2019, 384-94.
- [10] Tao K, Chen G, Wang Q, 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.
- [11] Tao K, Wang Q, Yue D. Data compression and damage evaluation of underground pipeline with musicalized sonar GMM[J]. IEEE Transactions on Industrial Electronics. 2023, 71(3): 3093-102.

- [12] Tao K, Xu M, Wang Q, et al. Vibration Signal ESSA-CVMD and Entropy Method for The Leakage Assessment of Pipe[J]. IEEE Transactions on Instrumentation and Measurement. 2025
- [13] Alathari A J M, Mashhadany A Y, Bakar A, et- al. COVID 19 IgG Antibodies Detection Based on CNN-BiGRU
   Algorithm Combined with Fiber-Optic Dataset[J]. Journal of virological methods, 2024: 115011.
- [14] Zheng W, Jiang J, Tao K. A method based on musical-staffinspired signal processing model for measuring rock moisture content[J]. Measurement. 2018 : 577-85.
- [15] 陈武, 钟建伟, 杨永超, 等. 基于 RQA 与 DAGSVM 的 电能质量扰动识别方法[J]. 计算机仿真, 2025, 42(01): 52-56.

**版权声明**: ©2025 作者与开放获取期刊研究中心(OAJRC)所 有。本文章按照知识共享署名许可条款发表。 https://creativecommons.org/licenses/by/4.0/

