

DOI: 10.19783/j.cnki.pspc.231503

# 基于深度学习融合网络的含噪电能质量扰动识别方法

王海东<sup>1</sup>, 程杉<sup>1</sup>, 徐其平<sup>1</sup>, 刘烨<sup>2</sup>, 王灿<sup>1</sup>

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 2. 国网浙江省电力有限公司嘉兴供电公司, 浙江 嘉兴 314000)

**摘要:** 针对强噪声环境下电能质量扰动识别精度不高的问题, 提出一种自适应小波降噪和深度学习相结合的电能质量扰动识别方法。首先, 通过改进峰和比分层自适应阈值和能量优化的阈值函数算法对含噪扰动信号进行降噪处理。然后, 通过残差神经网络对降噪后的扰动信号进行深层特征提取, 在此基础上融入多头注意力机制下的双向长短时记忆网络, 建立时序特征依赖关系, 构成适用于噪声环境下的扰动识别框架。最后, 在不同强度噪声环境下对20类扰动信号进行仿真实验。由仿真结果可知, 该方法具有良好的噪声鲁棒性, 在不同噪声环境下均有较高的识别正确率。

**关键词:** 电能质量扰动; 自适应小波降噪; 残差神经网络; 多头注意力; 双向长短时记忆网络

## Identification of power quality disturbance with noises based on an integrated deep learning network

WANG Haidong<sup>1</sup>, CHENG Shan<sup>1</sup>, XU Qiping<sup>1</sup>, LIU Ye<sup>2</sup>, WANG Can<sup>1</sup>

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China;  
2. Jiaxing Power Supply Company, State Grid Zhejiang Electric Power Co., Ltd., Jiaxing 314000, China)

**Abstract:** A novel method combined with adaptive wavelet threshold noise reduction and deep learning is proposed to improve the accuracy of identifying power quality disturbances in strong-noise environments. First, the noise-containing disturbance signals are noise-reduced by a threshold function algorithm based on an improved peak and score level adaptive thresholding and energy optimization. Then, the residual network is used to extract deep features from the noise-reduced disturbance signals, based on which the bidirectional long short term memory network under the multi-attention mechanism is incorporated to establish temporal feature dependency. This constitutes a framework applicable to the recognition of disturbance signals in a noisy environment. Finally, numerical simulations are carried out on 20 types of disturbance signals in different noise environments. It can be seen from the results that the proposed method has good noise robustness and high recognition accuracy in different noise environments.

This work is supported by the National Natural Science Foundation of China (No. 52107108).

**Key words:** power quality disturbances; adaptive wavelet threshold; residual neural network; multi-headed attention; bidirectional long-short term memory network

## 0 引言

电力系统电力电子化不可避免地会引起电压暂降、中断、波动和谐波等一系列电能质量扰动(power quality disturbances, PQDs)问题<sup>[1-2]</sup>, 不仅影响通信质量和电力系统运行, 甚至造成电子设备损坏<sup>[3]</sup>。随着电力系统的发展, 将出现海量 PQDs 数据<sup>[4]</sup>。因此, 快速准确地识别 PQDs 类型可大幅降低人工处理的工作量, 同时有利于防止 PQDs 问题进一步扩大<sup>[5]</sup>。

PQDs 信号识别可分为信号预处理和信号识别两个步骤<sup>[6]</sup>。针对信号预处理, 理想环境下特征提取已有不少研究, 文献[7]利用短时傅里叶变换和谱峭度提取 PQDs 信号特征, 实时性强但窗口选择难确定, 而文献[8]运用 S 变换可根据信号特点自适应选择窗口, 但计算复杂度高。但是, 实际电网中 PQDs 信号包含大量白噪声, 严重影响特征提取, 甚至造成特征提取方法完全失效。为此文献[9]提出软硬阈值函数降噪算法, 由于具有高效性和稳定性, 从而被广泛应用。但软硬阈值函数的不连续性和恒定偏差, 部分扰动降噪效果不佳, 为此文献[10]改进阈

基金项目: 国家自然科学基金项目资助(52107108)

值和阈值函数，虽然解决了文献[9]的问题，但会把谐波扰动特征当作噪声而误处理。文献[11]利用小波系数相关性改进了阈值估计精度，整体降噪效果进一步提高，但需要区分有效系数和无效系数的阈值。文献[12]提出了利用峰和比自适应调整阈值和改进阈值函数相结合的算法，阈值估计精度更加精确，整体降噪效果优越。

在 PQDs 识别方面，文献[13]提出了基于决策树的方法，但由于人工选取特征的主观性导致正确率难以达到较高水平。深度学习具有优良的自动提取特征能力和识别一体化能力，因此被广泛应用于 PQDs 识别领域，如：文献[14]将一维 PQDs 数据通过格拉姆角场变为二维图像后利用卷积神经网络(convolutional neural network, CNN)进行特征提取、分类，克服了文献[13]的缺陷，但存在模型训练量大和特征易丢失等问题；文献[15]在文献[14]的基础上提出了双通道格拉姆角场变换，解决了部分特征丢失的问题，又因融入残差网络(residual network, ResNet)使其在无噪声环境下识别精度接近于 1，但在强噪声环境下识别精度显著降低；文献[16]提出了基于一维 CNN 和长短时记忆(long and short term memory network, LSTM)串行融合网络，具有过程简洁、计算量小及识别精度较高的优点，但噪声干扰强度增大时识别效果会有较大幅度降低。

为此，本文提出一种如图 1 所示的自适应小波阈值降噪和深度学习融合网络相结合的 PQDs 识别方法。首先，通过改进峰和比分层自适应阈值和能量优化的阈值函数算法对扰动信号进行降噪处理。该方法通过小波变换原理将信号分解为不同频率的子带，根据噪声分布特点对每个子带进行自适应阈值估计，并根据阈值对小波系数进行滤波，随后执行逆变换，将滤波后的小波系数重新组合为降噪后

的信号。

其次，基于 CNN 和 ResNet 残差模块对 PQDs 信号进行深度特征提取。考虑到 PQDs 信号特征存在时序关联性，利用双向长短时记忆(BLSTM)网络对提取到的特征建立时间序列依赖关系。

再次，考虑到 BLSTM 网络处理长序列信号时易出现梯度消失和梯度爆炸等问题，在 BLSTM 前加入多头注意力机制。该方法将注意力分散在不同头之间，每个头关注序列不同部分，通过注意力权重计算提取特征的重要部分，改善超长时间序列信号的处理，提供更强大和有效的序列处理能力。

最后，利用全连接层对提取到的 PQDs 扰动特征进行识别分类。考虑多种噪声生成大量数据集，投入模型进行训练学习，并运用验证集进行测试，取最佳权重得到最优识别模型。

### 1 自适应小波降噪

真实电力系统中 PQDs 信号多包含以高斯分布的白噪声，而白噪声会严重影响识别模型对特征的提取。利用小波降噪对被噪声污染的扰动信号进行处理，主要包括以下三个步骤。

首先，根据 PQDs 信号特点、基波频率和采样频率等选择小波基和分解层数进行小波分解。

其次，运用阈值和阈值函数对每个分解层的小波系数进行处理，从而获得经过降噪的小波系数。

最后，将处理后的小波系数进行重构，获得降噪后的 PQDs 信号。

#### 1.1 自适应小波阈值

纯净信号和噪声的小波系数具有不同特征，具体取决于小波分解层数。在 PQDs 信号中，噪声主要集中在模较小的小波系数中<sup>[17]</sup>。随着分解层数的增加，噪声小波系数的数值会不断减小<sup>[18]</sup>。因此，

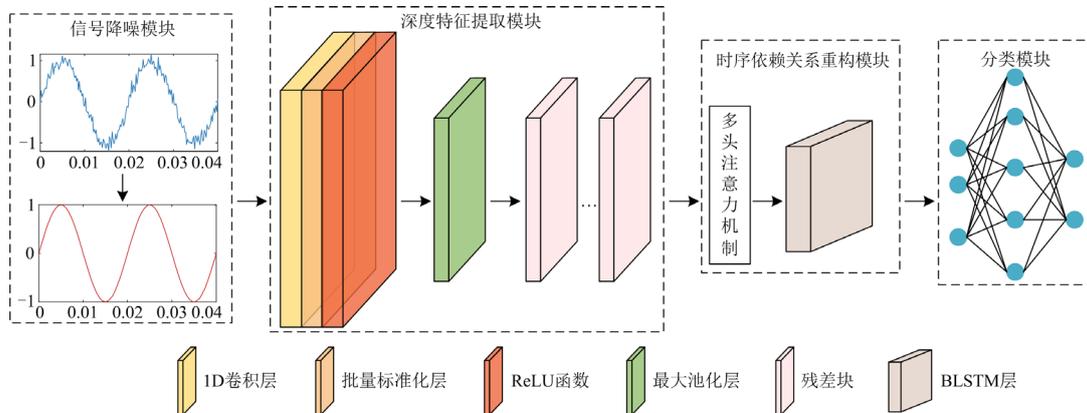


图 1 PQDs 识别框架

Fig. 1 PQDs identification framework

使用恒定阈值处理每层小波系数给降噪带来巨大偏差, 出现纯净信号噪声滤除不足和局部特征被误除的现象。

根据纯净信号和噪声分布特点, 利用峰和比调节因子  $F_j$  对各层阈值进行修正。各层小波系数峰和比  $P_{SRj}$  定义为

$$P_{SRj} = \frac{\max(|d_{j,k}|)}{\sum_{k=1}^{L_j} |d_{j,k}|} \quad (1)$$

式中:  $d_{j,k}$  为各层小波系数;  $L_j$  为各层信号长度。

$P_{SRj}$  反映了各分解层纯净信号与噪声信号的比例, 若  $P_{SRj}$  较大, 表明存在较多模较大的小波系数, 该层纯净信号为主导; 相反, 则说明存在较多数值较小的小波系数, 该层噪声为主导。根据  $P_{SRj}$  的特点, 峰和比调节因子  $F_j$  可定义为

$$F_j = L_j^{P_{SRj}} \quad (2)$$

只利用峰和比调节因子进行阈值调节相对固定, 为提高阈值估计精度, 加入临界分解层  $j_0$ 。在较小分解层 ( $j < j_0$ ) 中, 噪声占据主导, 并随着分解层数的增加而减小, 相应的能量也随之减少; 相反, 在较大分解层 ( $j > j_0$ ) 中, 相应的能量也随之增加。各层能量  $E_j$  的计算公式为

$$E_j = \sum_{k=1}^{L_j} d_{j,k}^2 \quad (3)$$

根据上述能量特点, 首个能量极值即临界分解层, 在传统方法的基础上加入能量调节因子  $r$ , 阈值  $\lambda_j$  可定义为

$$\lambda_j = \frac{\sigma \sqrt{2 \ln N}}{2 \lg(1+rj) F_j} \quad (4)$$

式中,  $\sigma$  表示噪声标准差对噪声进行整体估计, 如式(5)所示。

$$\sigma = \frac{\text{median}(|d_{j,k}|)}{0.6745} \quad (5)$$

式中, **median** 表示取中位数。

当  $j < j_0$  时,  $r$  取较小值, 使阈值变大; 当  $j > j_0$  时,  $r$  取较大值, 使阈值变小。根据实验测试, 当  $j < j_0$  时,  $r = 0.76$ ; 当  $j > j_0$  时,  $r = 1.02$ ; 当  $j = j_0$  时,  $r = 1$ 。

加入能量调节因子协同峰和比调节因子使阈值估计更加精确, 从而使噪声滤除效果更佳, 对于含谐波的复合扰动尤为明显。

## 1.2 能量优化阈值函数

定义含噪信号为  $s(t)$ , 其由纯净信号  $x(t)$  和噪声信号  $n(t)$  组成, 即

$$s(t) = x(t) + n(t) \quad (6)$$

传统软阈值函数  $d_1$  定义为

$$d_1 = \begin{cases} \text{sgn}(x)(|x| - \lambda), & |x| \geq \lambda \\ 0, & |x| < \lambda \end{cases} \quad (7)$$

式中, **sgn** 为阶跃函数。

传统硬阈值函数  $d_h$  定义为

$$d_h = \begin{cases} x, & x \geq \lambda \\ 0, & x < \lambda \end{cases} \quad (8)$$

硬阈值函数保留模大于阈值的小波系数, 滤除模小于阈值的小波系数, 可较好地保留信号特征, 但在设定的阈值处引入了不连续性, 导致信号重构时出现严重振荡。

软阈值函数具有较强的整体连续性, 但经过阈值量化处理后的小波系数呈现恒定偏差, 导致突变点处信号特征出现丢失。

针对上述软、硬阈值存在的问题, 本文结合两种阈值函数优点, 通过能量优化因子  $\mu_j$  并根据能量分布特点建立数学模型, 定义为

$$\mu_j = \frac{E_{sj} + 10E_{nj}}{E_{sj}} \quad (9)$$

式中,  $E_{sj}$  和  $E_{nj}$  分别为第  $j$  层  $s(t)$ 、 $n(t)$  的能量, 其中  $E_{n1} \approx E_{s1}$ , 其余有  $E_{sj} = 2^j E_{nj}$ , 可推算出  $\mu_j$  取值范围为 1~11。

基于能量优化阈值函数定义为

$$d'(x, \mu_j) = \begin{cases} x + \frac{\lambda_j}{\mu_j + 1} e^{\lambda_j - |x|} - \lambda_j, & x \geq \lambda_j \\ \text{sgn}(x) \frac{|x|^{\mu_j + 1}}{(\mu_j + 1)\lambda_j^{\mu_j}} e^{\lambda_j - |x|}, & |x| < \lambda_j \\ x - \frac{\lambda_j}{\mu_j + 1} e^{\lambda_j - |x|} + \lambda_j, & x \leq -\lambda_j \end{cases} \quad (10)$$

由式(10)可见,  $\mu_j$  根据能量分布特点进行自适应调节, 当  $\mu_j$  取较大值时, 阈值函数偏向于硬阈值函数  $d_h$ , 反之偏向于软阈值函数  $d_1$ , 从而可根据实际情况自适应选择合适的处理方式。

## 2 深度学习融合网络识别模型

### 2.1 ResNet

在传统的 CNN 中, 随着网络层数的增加, 虽

然目标特征的丰富性也在增强,但同时也可能会引发梯度爆炸和梯度消失的问题<sup>[19-20]</sup>,而深度残差网络可在不降低网络收敛速度的同时增加网络的深度,以提取目标更为复杂的特征<sup>[21]</sup>。

传统 CNN 由卷积层、池化层和全连接层组成,而 ResNet 是在 CNN 中的几个卷积层间并联一条短路路径,残差结构如图 2 所示。短路路径中的恒等函数与卷积层和批量标准化输出相加,必须保证两条路径下输出的维度完全相同,但卷积操作时选择不同的步幅,会导致输出维度的一致性难以保障,两者不能相加。此时可加入  $1 \times 1$  的卷积层,使两者输出的维度保持一致,如图 2(b) 所示。

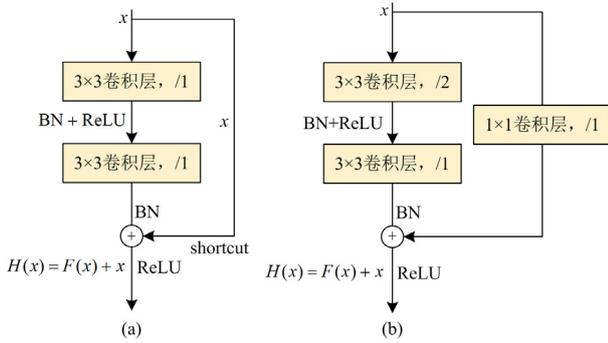


图 2 残差结构

Fig. 2 Residual structure

卷积层在对输入张量进行卷积运算实现特征提取,但输出结果会出现分布不均和极端值的情况,故卷积运算后还需要进行批量标准化。

批量标准化层是将卷积输出转变为标准正态分布,避免梯度消失和梯度爆炸,具体过程为

$$\begin{cases} \mu = \frac{1}{m} \sum_{i=1}^m x_i \\ \sigma^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu)^2 \\ \hat{x}_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \varepsilon}} \\ y_i = \gamma \hat{x}_i + \beta \end{cases} \quad (11)$$

式中:  $x_i$  和  $y_i$  分别为批处理的输入与输出;  $\mu$  和  $\sigma^2$  分别为批处理的均值与方差;  $\hat{x}_i$  为  $x_i$  的标准化;  $\varepsilon$  为极小数;  $\gamma$  和  $\beta$  均为模型训练过程的学习权重系数。

非线性激活函数为模型提供更强大的表达能力和学习能力,本文选择 ReLU 激活函数。

对于多分类问题,通常使用 Softmax 函数作为输出分类器,交叉熵函数作为损失函数来评估模型的性能。

传统 ResNet 是针对二维图像数据进行处理,而所处理的 PQDs 作为一维信号,直接调用其网络结构但不能直接运用,故本文模型采用其核心的残差结构搭建了适用于一维信号的 ResNet 网络框架。

## 2.2 BLSTM

BLSTM 通过堆叠两个 LSTM<sup>[22]</sup>层并分别按正序和逆序处理输入序列,构建一种双向循环神经网络结构,输出为两层 LSTM 输出的组合,不仅考虑当前时刻信息,还考虑当前时刻后的信息,拥有更强的记忆能力,对于具有长时间序列关联性特征的 PQDs 信号具有更好的处理效果。LSTM 网络结构如图 3 所示。

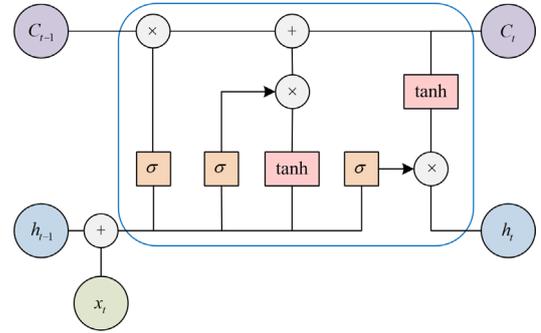


图 3 LSTM 网络结构

Fig. 3 LSTM network structure

## 2.3 多头注意力机制

注意力机制是一种模拟人在处理信息时关注和选择的机制,将其融入 BLSTM 层可有效缓解其难以学习长时间序列的依赖关系引发的梯度消失和梯度爆炸。

深度学习常选择软注意力机制,通过计算注意力权重并对其进行加权平均,从而更有针对性地进行表示。假定有一组 PQDs 特征数据  $D = \{d_1, d_2, d_3, \dots, d_k\}$ , 同时给定查询向量  $q$ , 通过打分函数  $s(d_i, q)$  计算每个输入  $d_i$  与  $q$  的相关性, 然后通过 Softmax 函数对各相关性得分输出进行归一化, 得到与 PQDs 对应的注意力分布  $G = \{g_1, g_2, g_3, \dots, g_k\}$ , 最后通过注意力分布对输入数据进行加权求和得到输出结果  $A$ , 计算公式为

$$G_i = \frac{\exp(s(d_k, q))}{\sum_{i=1}^k \exp(s(d_i, q))} \quad (12)$$

$$A = \sum_{i=1}^k g_i \cdot d_i \quad (13)$$

多头注意力机制<sup>[23]</sup>是注意力机制的扩展形式,通过引入多个独立注意力头,同时捕捉不同层次和

角度的特征, 以提高模型的表达能力和泛化能力。具体结构如图 4 所示。

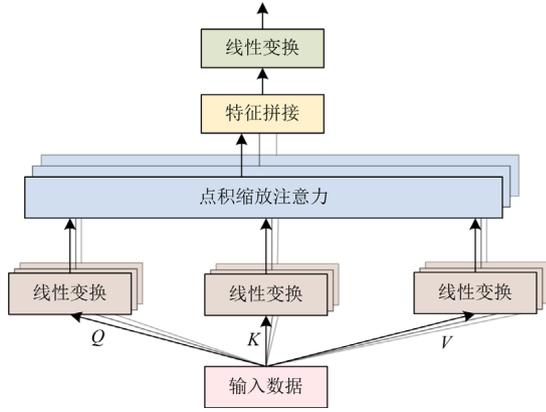


图 4 多头注意力结构

Fig. 4 Multi-headed attention structure

### 2.4 网络模型设计及参数设置

本文深度学习融合网络模型结构主要包括卷积层、池化层、残差模块、多头注意力机制层、BLSTM 层和全连接层, 具体结构与参数如图 5 所示。此外, 优化器选择 Adam, 初始学习率设置为 0.001, 激活函数为 ReLU 函数。

## 3 仿真分析与讨论

### 3.1 PQDs 数学建模与数据集生成

依据 IEEE Std1159-2019 将电能质量单一扰动

分为 9 种, 并在其划分的单一扰动规则基础上生成 11 种复合型扰动, 相应数学模型如表 1 所示。

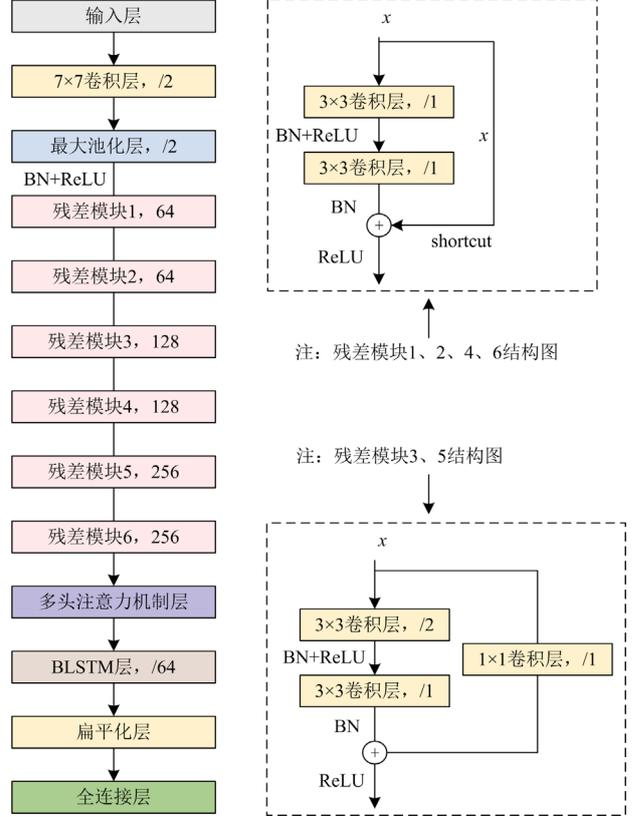


图 5 所提模型参数和结构

Fig. 5 Proposed model parameters and structure

表 1 电能质量扰动数学模型

Table 1 Mathematical model of PQDs

类别	数学模型	参数约束
C1 正常	$y(t) = A \sin(\omega t + \varphi)$	$\omega = 2\pi f_0, f_0 = 50 \pm 0.5$ $\varphi = 0 \sim 2\pi, A = 0.9 \sim 1.07$
C2 暂升	$y(t) = A\{1 + \alpha[u(t-t_1) - u(t-t_2)]\} \sin(\omega t + \varphi)$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 6T$
C3 暂降	$y(t) = A\{1 - \alpha[u(t-t_1) - u(t-t_2)]\} \sin(\omega t + \varphi)$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 6T$
C4 中断	$y(t) = A\{1 - \alpha[u(t-t_1) - u(t-t_2)]\} \sin(\omega t + \varphi)$	$0.9 \leq \alpha \leq 1, T \leq t_2 - t_1 \leq 6T$
C5 波动	$y(t) = A[1 + \alpha \sin(\beta \omega t)] \sin(\omega t + \varphi)$	$\alpha \geq 0.1, \beta \leq 0.2$
C6 谐波	$y(t) = A[\sin(\omega t + \varphi) + a_3 \sin(3\omega t + \varphi) + a_5 \sin(5\omega t + \varphi) + a_7 \sin(7\omega t + \varphi) + a_{11} \sin(11\omega t + \varphi)]$	$0.05 \leq a_3, a_5, a_7, a_{11} \leq 0.15$
C7 缺口	$y(t) = A\{\sin(\omega t + \varphi) - \text{sign}[\sin(\omega t + \varphi)] \times \sum_{n=1}^9 \alpha(u(t-t_1-0.02n) - \alpha(u(t-t_2-0.02n)))\}$	$0.01T \leq t_2 - t_1 \leq 0.05T$ $0.1 \leq \alpha \leq 0.4$
C8 脉冲	$y(t) = A\{1 + \alpha[u(t-t_1) - u(t-t_2)]\} \sin(\omega t + \varphi)$	$1 \leq \alpha \leq 3, 1 \text{ ms} \leq t_2 - t_1 \leq 3 \text{ ms}$
C9 振荡	$y(t) = A\{\sin(\omega t + \varphi) + \alpha e^{-\zeta(t-t_1)} \sin(\beta \omega t + \varphi) \times [u(t-t_1) - u(t-t_2)]\}$	$0.1 \leq \alpha \leq 0.8, 0.5T \leq t_2 - t_1 \leq 3T$ $0.1 \leq \zeta \leq 0.8, 10 \leq \beta \leq 15$
C10 暂降+谐波	$y(t) = A\{[1 - \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t + \varphi) + a_3 \sin(3\omega t + \varphi) + a_5 \sin(5\omega t + \varphi) + a_7 \sin(7\omega t + \varphi) + a_{11} \sin(11\omega t + \varphi)\}$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 6T$ $0.05 \leq a_3, a_5, a_7, a_{11} \leq 0.15$
C11 暂升+谐波	$y(t) = A\{[1 + \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t + \varphi) + a_3 \sin(3\omega t + \varphi) + a_5 \sin(5\omega t + \varphi) + a_7 \sin(7\omega t + \varphi) + a_{11} \sin(11\omega t + \varphi)\}$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 6T$ $0.05 \leq a_3, a_5, a_7, a_{11} \leq 0.15$

续表 1

类别	数学模型	参数约束
C12 暂降+振荡	$y(t) = A\{[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t + \varphi) + \alpha'e^{-\zeta(t-t_3)} \sin(\beta\omega t + \varphi) \times [u(t-t_3) - u(t-t_4)]\}$	$0.1 \leq \alpha' \leq 0.8, 0.5T \leq t_4 - t_3 \leq 3T$ $0.1 \leq \zeta \leq 0.8, 10 \leq \beta \leq 15$
C13 暂升+振荡	$y(t) = A\{[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t + \varphi) + \alpha'e^{-\zeta(t-t_3)} \sin(\beta\omega t + \varphi) \times [u(t-t_3) - u(t-t_4)]\}$	$0.1 \leq \alpha' \leq 0.8, 0.5T \leq t_4 - t_3 \leq 3T$ $0.1 \leq \zeta \leq 0.8, 10 \leq \beta \leq 15$
C14 脉冲+谐波	$y(t) = A\{[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t + \varphi) + a_3 \sin(3\omega t + \varphi) + a_5 \sin(5\omega t + \varphi) + a_7 \sin(7\omega t + \varphi) + a_{11} \sin(11\omega t + \varphi)\}$	$1 \leq \alpha \leq 3, 1 \text{ ms} \leq t_2 - t_1 \leq 3 \text{ ms}$ $0.05 \leq \alpha_3, \alpha_5, \alpha_7, \alpha_{11} \leq 0.15$
C15 中断+振荡	$y(t) = A\{[1 - \alpha[u(t-t_1) - u(t-t_2)]]\sin(\omega t + \varphi) + \alpha'e^{-\zeta(t-t_3)} \sin(\beta\omega t + \varphi) \times [u(t-t_3) - u(t-t_4)]\}$	$0.1 \leq \alpha' \leq 0.8, 0.5T \leq t_4 - t_3 \leq 3T$ $0.1 \leq \zeta \leq 0.8, 10 \leq \beta \leq 15$
C16 脉冲+振荡	$y(t) = A\{[1 + \alpha[u(t-t_1) - u(t-t_2)]]\sin(\omega t + \varphi) + \alpha'e^{-\zeta(t-t_3)} \sin(\beta\omega t + \varphi) \times [u(t-t_3) - u(t-t_4)]\}$	$1 \leq \alpha \leq 3, 1 \text{ ms} \leq t_2 - t_1 \leq 3 \text{ ms}$ $0.1 \leq \alpha' \leq 0.8, 0.5T \leq t_4 - t_3 \leq 3T$
C17 暂降+脉冲	$y(t) = A\{1 - [\alpha(u(t-t_1) - u(t-t_2)) + \alpha'(u(t-t_3) - u(t-t_4))]\sin(\omega t + \varphi)\}$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 6T$ $1 \leq \alpha' \leq 3, 1 \text{ ms} \leq t_4 - t_3 \leq 3 \text{ ms}$
C18 暂升+脉冲	$y(t) = A\{1 + [\alpha(u(t-t_1) - u(t-t_2)) + \alpha'(u(t-t_3) - u(t-t_4))]\sin(\omega t + \varphi)\}$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 6T$ $1 \leq \alpha' \leq 3, 1 \text{ ms} \leq t_4 - t_3 \leq 3 \text{ ms}$
C19 暂升+振荡+谐波	$y(t) = \{[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t + \varphi) + \alpha'e^{-\zeta(t-t_3)} \sin(\beta\omega t + \varphi) \times [u(t-t_3) - u(t-t_4)]\} a_3 \sin(3\omega t + \varphi) + a_5 \sin(5\omega t + \varphi) + a_7 \sin(7\omega t + \varphi) + a_{11} \sin(11\omega t + \varphi)$	$0.1 \leq \alpha' \leq 0.8, 0.5T \leq t_4 - t_3 \leq 3T$ $0.05 \leq \alpha_3, \alpha_5, \alpha_7, \alpha_{11} \leq 0.15$
C20 暂降+振荡+脉冲	$y(t) = A\{1 - [\alpha(u(t-t_1) - u(t-t_2)) + \alpha'(u(t-t_3) - u(t-t_4))]\sin(\omega t + \varphi) + \alpha''e^{-\zeta(t-t_5)} \sin(\beta\omega t + \varphi) \times [u(t-t_5) - u(t-t_6)]\}$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 6T$ $1 \leq \alpha' \leq 3, 1 \text{ ms} \leq t_4 - t_3 \leq 3 \text{ ms}$ $0.1 \leq \alpha'' \leq 0.8, 0.5T \leq t_6 - t_5 \leq 3T$

通过 Matlab 生成 9 种单一扰动信号、9 种双扰动信号和 2 种三扰动信号，共计 20 种扰动信号。其中单一扰动和部分复合型扰动波形图如图 6 所示。

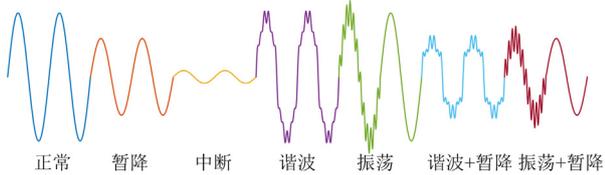


图 6 PQDs 波形图

Fig. 6 PQDs waveform

其中主要参数设置：基波频率为  $50 \pm 0.5 \text{ Hz}$ ，采样时间设置为  $0.2 \text{ s}$ ，共计 1280 个采样点；扰动幅值、持续时间等参数完全随机，20 种扰动各生成 1000 组，考虑到无噪声信号过于理想，故分别生成包含 3 种信噪比(SNR)(40 dB、30 dB 和 20 dB)的高斯白噪声信号，共计 60 000 个样本，按照 7:3 的比例将数据分为训练集和测试集。

本文模型基于 Tensorflow 框架和 Python 构建，所用硬件版本和运行环境详见表 2。

### 3.2 PQDs 识别模型训练与评估

为量化所提模型识别正确率，进行了消融实验，即对不同网络组成模型进行对比实验。比较模型包括 CNN-BLSTM、CNN-ResNet、ResNet-BLSTM 和

本文模型，所有模型的隐藏层节点、batch size 和学习率等超参数设置完全一致。经过迭代训练后，各模型验证集识别效果如表 3 所示。

表 2 硬件版本及运行环境

Table 2 Hardware version and operating environment

硬件/软件	型号/版本	硬件/软件	型号/版本
OS	Win10 64bit	Python	3.8
CPU	Intel i5-8300H	Tensorflow	2.4.0
RAM	DDR4 16 GB	CUDA	11.0
GPU	GTX 1050 4 GB	cuDNN	8.0.1

表 3 不同模型识别正确率

Table 3 Recognition accuracy of different models

模型类别	识别正确率/%		
	SNR 为 40 dB	SNR 为 30 dB	SNR 为 20 dB
CNN-BLSTM	94.94	94.25	86.38
CNN-ResNet	98.95	97.40	93.85
ResNet-BLSTM	99.33	98.48	96.16
本文	99.57	98.81	97.30

由表 3 可见：在 40 dB 噪声下，本文模型的识别正确率比 CNN-BLSTM、CNN-ResNet 和 ResNet-BLSTM 模型分别提升了 4.63%、0.62%和 0.24%，在 30 dB 噪声下分别提升了 4.56%、1.41%和 0.33%，在 20 dB 噪声下分别提升了 10.92%、3.45%和 1.14%。由

于多头注意力机制改善了 BLSTM 提取超长时间序列出现的梯度消失和梯度爆炸情况, 同时 ResNet 具有更好的特征提取能力和抗干扰能力, 因此识别精度得到进一步的提升。

网络训练过程中, 在 20 dB 强噪声环境下进行测试, 各模型测试集训练正确率及损失函数变化趋势如图 7 所示。

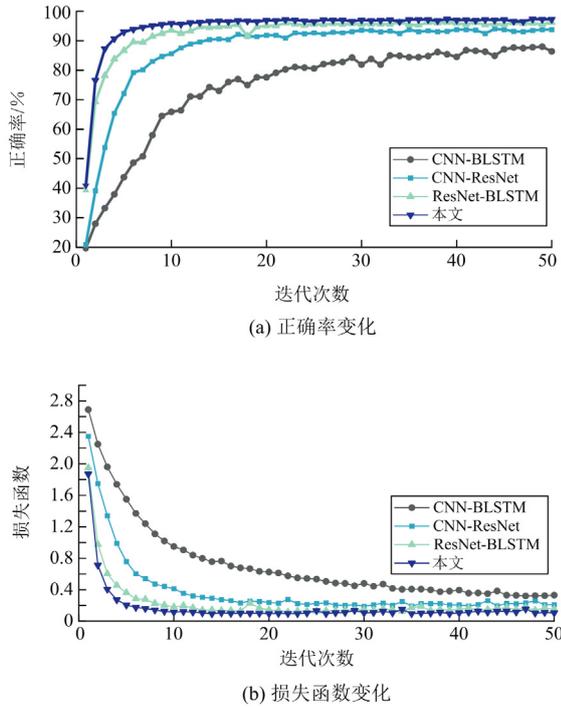


图 7 训练过程

Fig. 7 Training process

由图 7 可见, 在给定参数相同的情况下, CNN-BLSTM 模型识别最差且拟合速度慢。相比于 CNN-BLSTM 模型, CNN-ResNet 模型效果出现显著提高, 表明 ResNet 具有深度特征提取能力; ResNet-BLSTM 模型在 ResNet 的基础上融入 BLSTM 模型, 将提取到的深层特征进行时序建模, 进一步提高了识别效果和收敛速度, 但在训练过程中出现了较大波动。本文所提的融合模型在 ResNet-BLSTM 模型中融入了多头注意力机制, 优化了深层特征时序关联性的建立, 进一步提高了识别效果和收敛速度, 同时波动幅度小。

### 3.3 PQDs 降噪处理与分析

根据 3.2 节仿真分析可见, 在 20 dB 高斯白噪声环境下, 各模型识别精度出现显著降低。为缓解噪声对识别的影响, 将 3.1 节原始含噪信号经本文第 1 节所提出的自适应小波阈值算法进行降噪。首先, 选择合适的小波基函数, db4 小波具有紧致性,

使近似重构信号与原始信号十分接近, 因此, 选择 db4 小波作为小波基。其次, 确定分解层数, 文献 [24] 指出小波分解层数受基波频率和采样频率的影响, 本文基波频率为  $50 \pm 0.5$  Hz, 采样频率为 6400 Hz, 分解层确定为 4 层。再次, 利用第 2 节所提的自适应阈值和能量优化阈值函数算法对分解后的各层小波系数进行处理。最后, 执行小波重构得到降噪后的 PQDs 信号。以 20 dB 高斯白噪声下振荡+脉冲复合扰动为例, 信号波形降噪效果如图 8 所示。

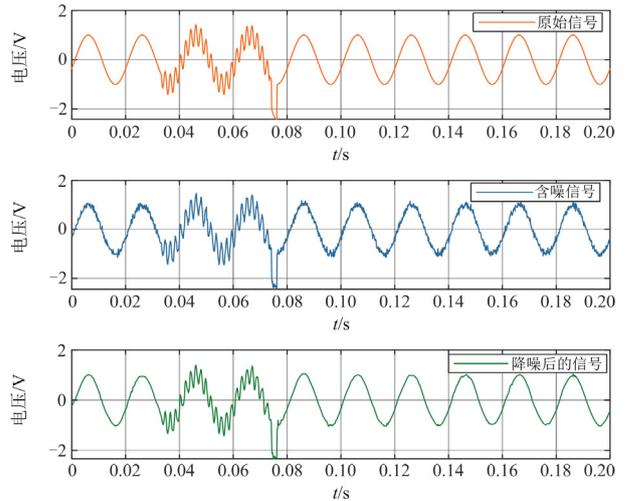


图 8 小波降噪效果

Fig. 8 Wavelet noise reduction effect

为量化所提降噪算法的有效性, 以电压暂降、脉冲、振荡和暂降+谐波为例, 在 20 dB 噪声环境下分别用 6 种不同降噪算法进行处理, 结果如表 4 所示。

表 4 不同方法降噪效果(SNR 为 20 dB)

Table 4 Noise reduction effect of different methods (SNR is 20 dB)

方法	输出信噪比/dB			
	暂降	脉冲	振荡	暂降+谐波
硬阈值	29.4544	29.4971	27.8742	21.0975
软阈值	29.1475	28.4827	27.0751	20.9123
文献[10]	29.7457	29.8757	28.7451	21.4475
文献[11]	30.0174	30.2144	29.1772	21.5272
文献[12]	30.4658	30.5711	29.7843	23.4175
本文	30.9875	31.0778	30.8052	26.5214

由表 4 可见, 各小波降噪方法对于不含谐波的单一扰动信号的降噪效果较好。由于含谐波的复合型扰动含有较为复杂的频率变化成分, 传统阈值估计方法精度不够, 导致其噪声难以去除, 因此对于暂降+谐波扰动, 除文献[12]和本文方法降噪效果均

不明显。与文献[12]相比，阈值估计算法在其基础上加入了能量调节因子，阈值估计更加精确，增强了去噪效果。因此，降噪效果得到进一步提升，降噪后的信号信噪比整体提高了 5.1532 dB。

### 3.4 自适应小波阈值降噪处理后模型训练与评估

为验证经降噪后 PQDs 信号对模型识别精度的提升，在 20 dB 强噪声环境下，利用降噪后的 PQDs 数据集分别对 3.2 节各模型进行仿真实验。降噪前后的模型识别效果对比如图 9 所示。

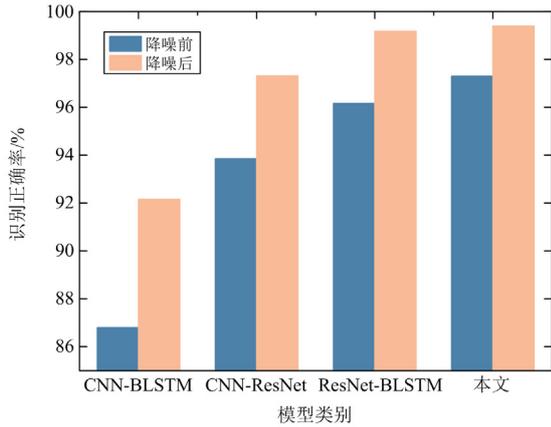


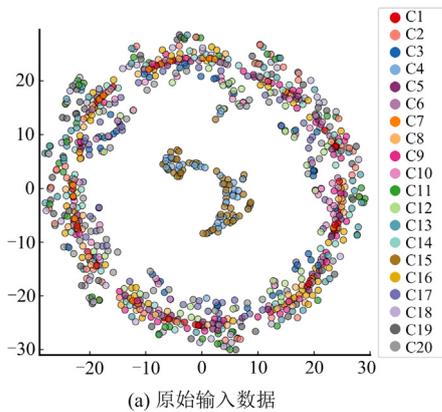
图 9 小波降噪后模型分类结果(SNR 为 20 dB)

Fig. 9 Model classification results after wavelet noise reduction (SNR is 20 dB)

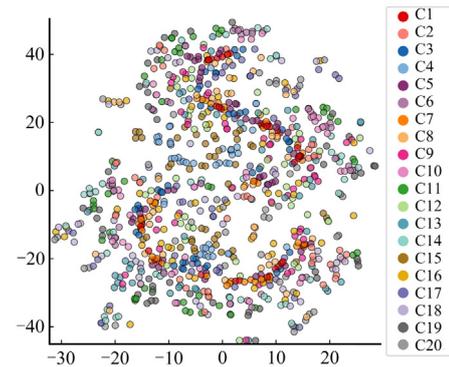
由图 9 可见，经小波降噪处理后特征提取难度得以降低，因此各模型识别效果均显著提高，证明了所提降噪预处理方法可有效提高模型识别精度。

保存本文模型训练时最优网络权重系数，并导入验证集进行识别评估。利用 t-SNE(t-distributed stochastic neighbor embedding)对各网络层识别效果进行可视化分析，如图 10 所示。

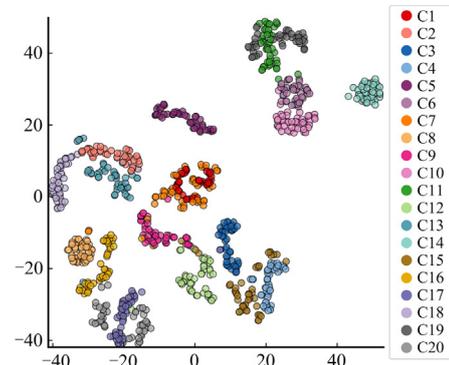
由图 10 可见，20 类 PQDs 信号随着网络层的深入，由混合杂乱到分类清晰，在 BLSTM 层和输出层尤为明显。



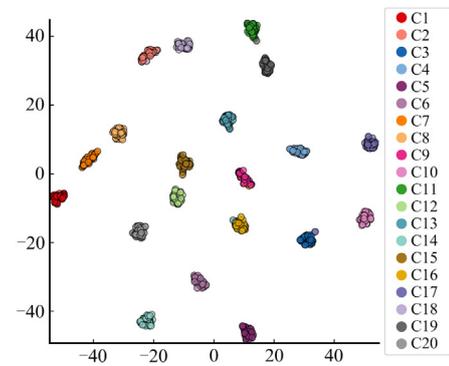
(a) 原始输入数据



(b) ResNet层



(c) BLSTM层



(d) 输出层

图 10 t-SNE 可视化

Fig. 10 The t-SNE visualization

### 3.5 PQDs 识别结果分析

为探究本文所提 PQDs 针对各种扰动的识别效果，在 20 dB 强噪声环境下，采用经降噪后的 PQDs 数据并用本文所提模型进行网络训练，分别测试 20 种扰动信号，结果如表 5 所示。

由表 5 可见，在 20 dB 强噪声环境下，本文所提方法对各类型扰动识别精度仍较高。为突出本文方法在噪声环境下的优越性，将本文所提方法与文献[25-28]所提方法进行对比，结果如表 6 所示。

表 5 20 类扰动识别正确率

Table 5 Recognition accuracy of 20 kinds of disturbances

扰动类型	正确率/%	扰动类型	正确率/%
C1 正常	99.4	C11 暂升+谐波	98.6
C2 暂升	98.6	C12 暂降+振荡	100
C3 暂降	98.6	C13 暂升+振荡	99.5
C4 中断	99.5	C14 脉冲+谐波	100
C5 波动	100	C15 中断+振荡	99
C6 谐波	99.5	C16 脉冲+振荡	99.5
C7 缺口	100	C17 暂降+脉冲	100
C8 脉冲	100	C18 暂升+脉冲	100
C9 振荡	98.4	C19 暂升+振荡+谐波	100
C10 暂降+谐波	100	C20 暂降+振荡+脉冲	100

表 6 不同方法识别正确率

Table 6 Recognition accuracy of different methods

方法	识别正确率/%		
	SNR 为 40 dB	SNR 为 30 dB	SNR 为 20 dB
文献[25]	99.00	98.66	98.11
文献[26]	98.80	98.60	95.60
文献[27]	91.70	91.40	90.90
文献[28]	99.37	99.34	97.75
本文	99.63	99.52	99.40

由表 6 可见, 在低噪声(40 dB)环境下, 本文所提方法在性能上与其他方法相差无几。但在强噪声环境(30 dB 和 20 dB)下, 噪声提高了特征提取难度, 导致其他方法的识别正确率显著降低, 而本文由于对噪声进行了处理, 因此所提方法仍保持较高的识别正确率, 进一步验证了所提方法的有效性。

## 4 结论

为提高噪声环境下 PQDs 识别精度, 本文解决了传统强噪声环境下扰动识别精度显著降低的问题, 提出了自适应小波阈值降噪和深度学习融合网络的 PQDs 识别方法。该方法首先通过改进峰和比分层自适应阈值和能量优化的阈值函数算法对含噪 PQDs 信号进行降噪预处理, 然后利用一维 CNN 和 ResNet 进行深度特征提取, 在此基础上加入多头注意力机制下的 BLSTM 层建立时间序列依赖关系, 在提高识别正确率的同时提高了对噪声的鲁棒性, 由仿真对比试验可得出以下结论。

1) 在信号预处理方面, 针对噪声对 PQDs 识别的不良影响, 通过改进自适应小波降噪算法对 PQDs 信号进行噪声滤除的同时能够保留扰动信号局部特征, 在 20 dB 强噪声环境下对频率变化复杂的谐波扰动信号降噪仍具有良好效果。

2) 在识别方面, 提出 ResNet 和多头注意力机

制下的 BLSTM 融合模型, 该模型不仅进一步提高了扰动识别精度, 而且收敛速度更快、波动幅度更小。

3) 本文所提方法不仅可应用于 PQDs 识别领域, 而且在确定预处理信号的基波频率、采样频率和模型输入尺寸等信息后, 对底层参数进行适当修改, 可广泛应用于噪声环境下的时间序列信号的识别和预测方面, 如电力系统暂态稳定评估和电力负荷预测等方面。

## 参考文献

- [1] 汪飞, 全晓庆, 任林涛. 电能质量扰动检测与识别方法研究综述[J]. 中国电机工程学报, 2021, 41(12): 4104-4121.  
WANG Fei, QUAN Xiaoqing, REN Lintao. Review of power quality disturbance detection and identification methods[J]. Proceedings of the CSEE, 2021, 41(12): 4104-4121.
- [2] 王强钢, 周亦尧, 廖建权, 等. 直流配电网电能质量研究综述[J]. 电力系统自动化, 2023, 47(7): 193-207.  
WANG Qianggang, ZHOU Yiyao, LIAO Jianquan, et al. Review on power quality in DC distribution network[J]. Automation of Electric Power Systems, 2023, 47(7): 193-207.
- [3] LIU Y, JIN T, MOHAMED M A, et al. A novel three-step classification approach based on time-dependent spectral features for complex power quality disturbances[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-14.
- [4] 张爱梅. 基于神经网络组合预测模型的农村电能替代潜力研究[J]. 自动化应用, 2023, 64(22): 58-61.  
ZHANG Aimei. Research on rural electricity substitution potential based on neural network combination prediction model[J]. Automation Application, 2023, 64(22): 58-61.
- [5] XU W, HUANG Z, XIE X, et al. Synchronized waveforms-a Frontier of data-based power system and apparatus monitoring, protection, and control[J]. IEEE Transactions on Power Delivery, 2021, 37(1): 3-17.
- [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.  
HE Caijun, LI Kaicheng, DONG Yufei, et al. Power quality compound disturbance identification based on knowledge distillation and RP-MobileNetV3[J]. Power System Protection and Control, 2023, 51(14): 75-84.
- [7] 黄建明, 瞿合祚, 李晓明. 基于短时傅里叶变换及其谱峭度的电能质量混合扰动分类[J]. 电网技术, 2016, 40(10): 3184-3191.  
HUANG Jianming, QU Hezuo, LI Xiaoming. Classification for hybrid power quality disturbance based on STFT and its spectral kurtosis[J]. Power System Technology, 2016, 40(10): 3184-3191.
- [8] MAHELA O P, SHAIK A G, KHAN B, et al. Recognition of complex power quality disturbances using S-transform based ruled decision tree[J]. IEEE Access, 2020, 8: 173530-173547.
- [9] DONOHO D L, JOHSTONE I M. Adapting to unknown

- smoothness via wavelet shrinkage[J]. Journal of the American Statistical Association, 1995, 90: 1200-1224.
- [10] SRIVASTAVA M, ANDERSON C L, FREED J H. A new wavelet denoising method for selecting decomposition levels and noise thresholds[J]. IEEE Access, 2016, 4: 3862-3877.
- [11] WANG Y, ZHANG B, DING F, et al. Estimating dynamic motion parameters with an improved wavelet thresholding and inter-scale correlation[J]. IEEE Access, 2018, 6: 39827-39838.
- [12] 王维博, 董蕊莹, 曾文入, 等. 基于改进阈值和阈值函数的电能质量小波去噪方法[J]. 电工技术学报, 2019, 34(2): 409-418.  
WANG Weibo, DONG Ruiying, ZENG Wenru, et al. A wavelet de-noising method for power quality based on an improved threshold and threshold function[J]. Transactions of China Electrotechnical Society, 2019, 34(2): 409-418.
- [13] ZHONG T, ZHANG S, CAI G, et al. Power-quality disturbance recognition based on time-frequency analysis and decision tree[J]. IET Generation, Transmission & Distribution, 2018, 12(18): 4153-4162.
- [14] 郑炜, 林瑞全, 王俊, 等. 基于 GAF 与卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2021, 49(11): 97-104.  
ZHENG Wei, LIN Ruiquan, WANG Jun, et al. Power quality disturbance classification based on GAF and a convolutional neural network[J]. Power System Protection and Control, 2021, 49(11): 97-104.
- [15] 贺才郡, 李开成, 杨王旺, 等. 基于双通道 GAF 和深度残差网络的电能质量复合扰动识别[J]. 电网技术, 2023, 47(1): 369-379.  
HE Caijun, LI Kaicheng, YANG Wangwang, et al. Power quality compound disturbance identification based on dual channel GAF and depth residual network[J]. Power System Technology, 2023, 47(1): 369-379.
- [16] LI T, GAO Z, LI Y, et al. A comprehensive study of fast Fourier transform for bearing fault diagnosis with long short-term memory networks[C] // 2023 3rd International Conference on Electrical Engineering and Mechatronics Technology (ICEEMT), July 21-23, 2023, Nanjing, China: 876-879.
- [17] GAO Y, LI Y, ZHU Y, et al. Power quality disturbance classification under noisy conditions using adaptive wavelet threshold and DBN-ELM hybrid model[J]. Electric Power Systems Research, 2022, 204: 107682-107693.
- [18] ZHANG M, LU C, LIU C. Improved double-threshold denoising method based on the wavelet transform[J]. OSA Continuum, 2019, 2(8): 2328-2342.
- [19] 李云松, 张智晟. 基于 GRU-TGTransformer 的综合能源系统多元负荷短期预测[J]. 电力系统保护与控制, 2023, 51(15): 33-41.  
LI Yunsong, ZHANG Zhisheng. Multi load short-term forecasting of an integrated energy system based on a GRU-TGTransformer[J]. Power System Protection and Control, 2023, 51(15): 33-41.
- [20] CHENG S, YU Z, LIU Y, et al. Power system transient stability assessment based on the multiple paralleled convolutional neural network and gated recurrent unit[J]. Protection and Control of Modern Power Systems, 2022, 7(1): 39-50.
- [21] 陈子含, 滕伟, 胥学峰, 等. 基于图卷积网络和风速差分拟合的中长期风功率预测[J]. 中国电力, 2023, 56(10): 96-105.  
CHEN Zihan, TENG Wei, XU Xuefeng, et al. Medium and long term wind power prediction based on graph convolutional network and wind velocity differential fitting[J]. Electric Power, 2023, 56(10): 96-105.
- [22] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30: 18-33.
- [24] ADEBISI B, ANOH K, RABIE K M, et al. A new approach to peak threshold estimation for impulsive noise reduction over power line fading channels[J]. IEEE Systems Journal, 2018, 13(2): 1682-1693.
- [25] ABDOOS A A, MIANAIE P K, GHADIKOLAEI M R. Combined VMD-SVM based feature selection method for classification of power quality events[J]. Applied Soft Computing, 2016, 38: 637-646.
- [26] 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): 232-243.  
WU Jianzhang, MEI Fei, ZHENG Jianyong, et al. Recognition of multiple power quality disturbances based on modified empirical wavelet transform and XGBoost[J]. Transactions of China Electrotechnical Society, 2022, 37(1): 232-243.
- [27] 阮梓航, 肖先勇, 胡文曦, 等. 基于多粒度特征选择和模型融合的复合电能质量扰动分类特征优化[J]. 电力系统保护与控制, 2022, 50(14): 1-11.  
RUAN Zihang, XIAO Xianyong, HU Wenxi, et al. Multiple power quality disturbance classification feature optimization based on multi-granularity feature selection and model fusion[J]. Power System Protection and Control, 2022, 50(14): 1-11.
- [28] ÖZER İ, EFE S B, ÖZBAY H. CNN/Bi-LSTM-based deep learning algorithm for classification of power quality disturbances by using spectrogram images[J]. International Transactions on Electrical Energy Systems, 2021, 31(12): 13204-13220.

收稿日期: 2023-11-27; 修回日期: 2024-01-29

作者简介:

王海东(2000—), 男, 硕士研究生, 研究方向为电能质量扰动信号检测与识别; E-mail: 1220416210@qq.com

程杉(1981—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为电能质量分析; E-mail: hpucquyzu@ctgu.edu.cn

徐其平(2002—), 男, 硕士研究生, 研究方向为电力系统暂态稳定评估. E-mail: 1494064455@qq.com

(编辑 姜新丽)