

DOI: 10.19783/j.cnki.pspc.231582

基于 TCN-LSTM 模型的电网电能质量扰动分类研究

王义国¹, 林峰², 李琦², 刘钰淇¹, 胡贵洋³, 孟祥宇³

(1. 广东省能源集团有限公司, 广东 广州 510620; 2. 广东粤电青溪发电有限责任公司, 广东 梅州 514200;
3. 西南交通大学电气工程学院, 四川 成都 610000)

摘要: 随着新能源发电和众多电动汽车充电桩等非线性设备并网运行, 电网电能质量问题日渐凸显。现有解决方案在电能质量扰动分类上流程复杂, 且在处理扰动信号时分类准确率偏低。为应对这一挑战, 引入了 TCN-LSTM 混合模型, 融合了时域卷积网络(temporal convolutional network, TCN)和长短时记忆网络(long short-term memory, LSTM)。其中, TCN 专注于捕捉时序数据的局部特性, 而 LSTM 负责挖掘长期依赖关系, 两者结合能够有效捕捉信号的局部特征和全局关系。为验证模型性能, 对 14 种加入不同信噪比白噪声的电能质量扰动信号进行分类测试。结果表明, TCN-LSTM 模型展现出较强的抗噪性能, 并在与现有深度网络模型的对比中展现了更高的分类准确度。

关键词: 电能质量; 扰动分类; TCN-LSTM 模型; 时序数据; 抗噪性能

Classification of power quality disturbances in a power grid based on the TCN-LSTM model

WANG Yiguo¹, LIN Feng², LI Qi², LIU Yuqi¹, HU Guiyang³, MENG Xiangyu³

(1. Guangdong Energy Group Co., Ltd., Guangzhou 510620, China; 2. Guangdong Yuedian Qingxi Power Generation Co., Ltd., Meizhou 514200, China; 3. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610000, China)

Abstract: The increasing integration of non-linear devices such as new energy generation and a large number of electric vehicle charging stations into the power grid has led to increasingly prominent power quality problems. However, current methods face challenges in the classification of power quality disturbances, with complex steps and low accuracy when considering disturbance signals. To address these issues, this paper proposes the TCN-LSTM model, which combines a temporal convolutional network (TCN) with long short-term memory (LSTM). The TCN network excels in capturing local features of time series, while the LSTM is proficient in digging long-term dependencies within the time series. The fusion of both enables the model to effectively capture both local characteristics and global relationships of the signals. To validate the model's performance, a classification test is conducted on 14 types of power quality disturbance signals with varying signal-to-noise ratios. Finally, the results demonstrate that the TCN-LSTM model exhibits strong noise resistance. In comparison to existing deep network models, the model proposed in this paper achieves higher classification accuracy.

This work is supported by the Sichuan Youth Science and Technology Innovation Research Team Project "Electrical Safety Protection of High-speed Rail Electric Traction System" (No. 2016TD0012).

Key words: power quality; disturbance classification; TCN-LSTM model; time series data; noise resistance performance

0 引言

大量新能源和电动汽车充电装置等非线性负载

基金项目: 四川省青年科技创新研究团队项目“高铁电力牵引系统电气安全防护”(2016TD0012)

接入电网时^[1], 可能会引起电压不稳定、频率波动、谐波扰动等问题^[2], 从而影响电网的正常运行和供电质量。考虑新能源电站与大功率负荷接入下的电力系统如图 1 所示。这不仅直接影响居民的用电体验, 还可能危及电网的稳定性^[3]。因此, 准确且快速识别不同噪声水平下电能质量扰动类型, 对电能

质量问题的治理和故障诊断具有重要意义^[4], 已成为国内外学者们共同关注的研究方向^[5]。

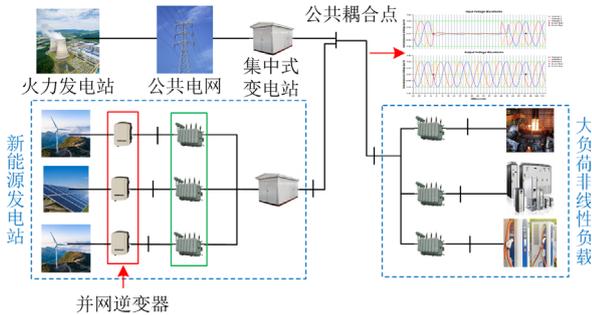


图1 考虑新能源电站与大功率负荷接入下的电力系统
Fig. 1 Power system considering the access of new energy power stations and high-power loads

目前针对电能质量扰动分类的研究主要分为两个方向: 一种是通过信号处理算法提取电信号特征, 再利用分类器进行分类的传统方法; 另一种是基于数据驱动, 运用深度学习的人工智能方法^[6-7]。在传统方法中, 常用的信号分析方法包括傅里叶变换^[8]、小波变换^[9]、S变换^[10]和经验模态分解^[11]等, 在提取时频特征后, 将其输入分类器以学习序列与标签之间的映射, 常用的分类器有决策树^[12]、支持向量机^[13]和神经网络^[14]等。传统方法针对单一扰动识别时较为合适, 但是针对复合扰动问题时, 因为存在复杂的特征量重叠, 很难有较高的识别率。此外, 信号处理方法本身也有局限性, 例如小波变换对基波选择非常敏感, S变换计算复杂, 经验模态分解在信号中的振荡模式与噪声频率接近时容易产生误分。

为解决上述问题, 可以考虑引入深度学习模型, 其具有较强的鲁棒性和自适应能力。文献[15]提出结合全连接网络和长短时记忆网络(long short-term memory, LSTM)的神经网络模型, 挖掘电能质量扰动在空间和时间上的高维特征, 实现了较高的分类准确率。文献[16]提出一种利用卷积神经网络和长短期记忆网络提取扰动数据特征并完成分类的方法, 但是长短期记忆网络对于全局关注效果好, 对于局部的关注有限。文献[17]设计了多个训练任务对信号进行特征的提取, 通过模型的预训练后实现了较好的电能质量扰动分类, 但训练过程较为复杂。然而, 现有研究表明, 通过加深网络层次和堆叠模块来优化模型可能导致梯度爆炸和过拟合问题, 并且在噪声干扰下模型的鲁棒性有待提高。

本文提出了一种结合时域卷积网络(temporal convolutional network, TCN)和LSTM的模型, 以对

电能质量扰动进行精准分类。该模型巧妙地融合了TCN和LSTM在序列数据处理方面的优势。TCN通过其卷积层和残差连接的结构, 有效地捕捉了时域序列中的局部特征, 而LSTM则擅长于捕获序列中的长期依赖关系。将TCN的输出作为LSTM的输入, 充分结合了两者的优势, 使网络能够同时处理局部和全局特征, 避免了梯度爆炸的问题并且增强了抗噪能力。

1 TCN-LSTM模型

本文提出了TCN-LSTM的网络模型, TCN提取局部特征, LSTM捕获序列中的长期依赖性。为了充分利用它们的优点, 将它们组合成一种新的混合模型, 进一步提高分类的准确度。

1.1 TCN

1.1.1 因果卷积

因果卷积是卷积神经网络中的一种特殊类型的卷积操作, 如图2所示。它通过在输入序列前面补充长度为 l 的零值向量, 来使输入与卷积计算输出在维度上保持一致^[18]。在因果卷积中, 卷积核只能从输入数据的过去时刻向当前时刻进行滑动, 而不能获取未来时刻的信息。因此输出信息只依赖于过去的输入信息, 有效地避免了未来信息的干扰。

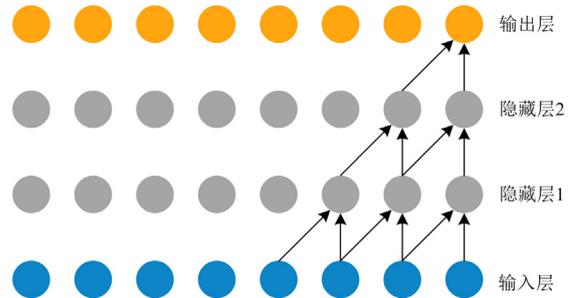


图2 因果卷积示意图

Fig. 2 Schematic diagram of causal convolution

1.1.2 膨胀卷积

膨胀卷积又称空洞卷积, 如图3所示。通过在卷积核元素之间插入零来实现膨胀, 从而在保持参数数量不变的情况下, 增大了每一层卷积核的感受野, 解决了因果卷积需要很多层或者是增大卷积核来增大感受野的问题。总的来说, 膨胀卷积的加入使得模型参数数量在相对较小的情况下, 扩大了感受野, 进而提升了模型性能。膨胀卷积的表达式如式(1)所示。

$$F(x) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-di} \quad (1)$$

式中: x 为输入序列; f 为过滤器; k 为卷积核大小; x_{s-di} 表示的是输入信号中当前位置 s 向左 di 距离处的值, 其中 d 是膨胀率, 而 i 是当前卷积核的位置索引。

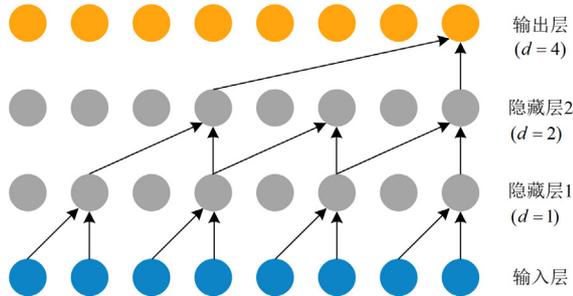


图 3 膨胀卷积示意图

Fig. 3 Schematic diagram of dilated convolution

1.1.3 残差模块

由于 TCN 的感受野取决于网络深度以及膨胀因子和卷积核大小, 因此想要网络提取的信息更加丰富或是网络拥有更好的非线性表达能力, 就需要增加网络的深度。但是盲目地增加网络的深度会使得网络引入更多的卷积层和池化层, 进而引起梯度消失和爆炸的问题, 使得网络的性能下降。

残差块的引入能够很好地解决以上问题, 不仅能够缓解梯度消失的问题, 还可以减少信号在网络传递过程中的衰减。残差模块示意图如图 4 所示。

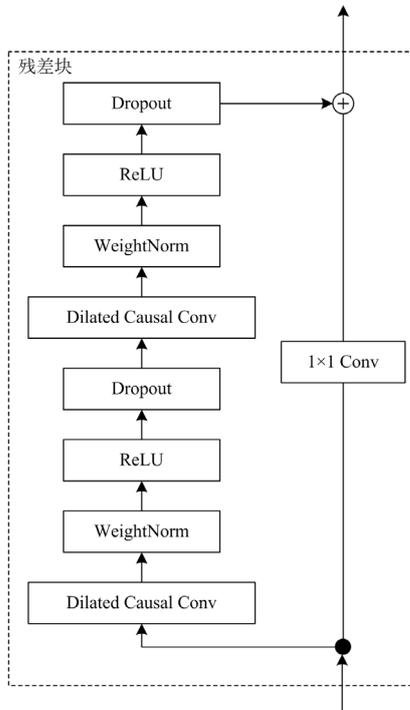


图 4 残差模块示意图

Fig. 4 Schematic diagram of the residual module

由图 4 可知, 输入特征依次经过第一膨胀卷积层、归一化层(WeightNorm)、激活函数层和 Dropout 层, 将输出结果再输入到第二膨胀卷积层、归一化层、激活函数层和 Dropout 层, 得到最终的输出特征。但是不同于标准的残差结构, 输入直接添加到残差函数的输出中, 在 TCN 中, 输入和输出可能拥有不同的宽度。因此, 残差块中使用了 1×1 的卷积来确保元素加法接收相同形状的张量^[19]。假设第 i 个残差块的输入为 X^i , 输出为 X^{i+1} , 那么两者的关系为

$$X^{i+1} = Activation(X^i + F(X^i)) \quad (2)$$

式中: $Activation$ 为激活函数; $F(x)$ 为残差块操作。

1.2 LSTM

LSTM 是一种特殊的递归神经网络, 专门设计用于处理时序数据, 与循环神经网络相比, LSTM 具有更强的记忆能力, 可以更好地捕获时间序列的长期依赖关系, 避免了梯度消失/爆炸的问题。LSTM 的核心包括 3 个门控单元。

1) 遗忘门: 决定哪些信息需要被遗忘, 以便在长序列中保持记忆的稳定性。

2) 输入门: 决定哪些新信息需要被添加到记忆中。

3) 输出门: 决定从记忆中提取哪些信息传递到下一层。

3 个门控单元保证了网络在处理时序数据时能够选择性地遗忘、记忆和输出信息, 从而保留了对长期信息的感知。

LSTM 的基本单元如图 5 所示。其中: x_t 为当前输入; \tilde{C}_t 为当前 LSTM 的状态; h_t 为当前编码隐藏状态; f_t 为遗忘程度; i_t 为输入保留程度; C_t 为当前状态的处理信息; O_t 为输出保留程度。在每一个时间步, LSTM 单元会接收输入和前一个时间步的隐藏状态, 然后根据遗忘门、输入门和输出门的权重来更新当前隐藏状态和记忆细胞。

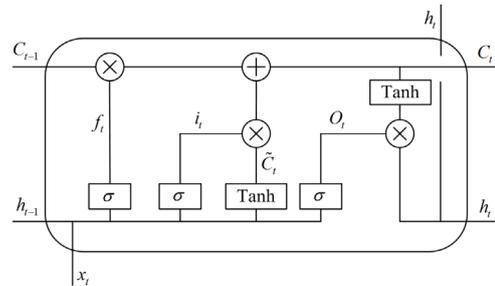


图 5 LSTM 基本单元示意图

Fig. 5 Schematic diagram of LSTM basic unit

1.3 TCN-LSTM

本研究采用一种结合了 TCN 和 LSTM 的神经网络模型,具体架构如图 6 所示。首先,通过将 TCN 和 LSTM 模块串联,使得网络能够同时捕捉序列的局部特征和长期依赖关系。训练时,批量大小取为 128,并对输入数据进行归一化处理。数据经过 4 个 TCN 残差模块,这些模块的卷积核大小为 3,卷积核数量均为 128。随后,TCN 的输出特征作为 128 隐藏单元的 LSTM 的输入,从而获得 LSTM 的输出数据。接着,引入一个 Dropout 层(丢弃率为 0.2),紧随其后的是一个全连接层和一个 Softmax 激活函数层,用于最终的分类输出。通过这样的设计,在网络结构上取得了良好的平衡,同时保证了对序列特征的全面捕获。

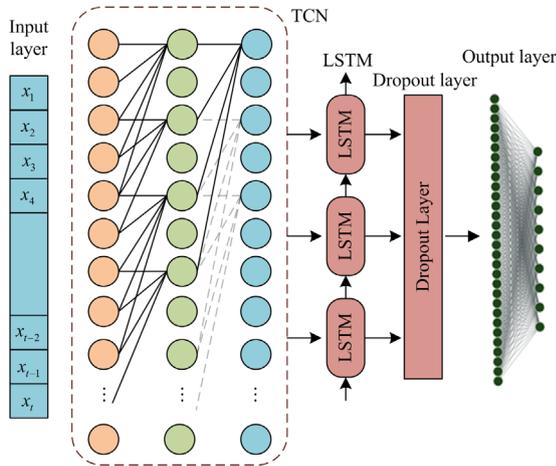


图 6 TCN-LSTM 模型示意图

Fig. 6 Schematic diagram of TCN-LSTM model

2 获取电能质量扰动数据集

本文根据 IEEE-1159 的标准以及文献[20],通过 Matlab 对常见的扰动信号进行了仿真,仿真的采样周期 N 为 10,采样频率 f_s 为 6.34 kHz,采样点个数为 1280 个,构建 7 种单一扰动信号和 6 种复合扰动信号。13 种电能故障的数学表达和波形图如表 1 所示。

3 试验结果

分类准确率是用于评估分类模型性能的一项重要指标,它指在所有样本中正确分类的比例,用 A_{cc} 表示,如式(3)所示。

$$A_{cc} = \frac{N_{correct}}{N_{total}} \times 100\% \quad (3)$$

式中: $N_{correct}$ 是指模型预测的类别与实际类别相符

的样本数量; N_{total} 是指所有被评估的样本数量。

在实际情况下,电压信号往往受到各种形式的噪声影响。为了模拟真实场景中的电压信号,本文在信号中引入不同程度的高斯噪声。这样做的目的是使模拟信号更贴近实际情况,以便更准确地评估 TCN-LSTM 网络对电能质量扰动分类的性能。

高斯噪声是一种常见的随机噪声模型,它符合正态分布。在模拟中可以通过调整噪声的均值和标准差来控制其强度和分布特性,这样可以模拟出各种实际场景下的电压信号,从而更全面地评估分类网络的性能。

信噪比是指一个电子设备或者电子系统中信号与噪声的比例。通常来说,越高的信噪比意味着电压信号质量更好、相对于噪声更清晰,越低的信噪比意味着电压信号质量越差,受到较大的噪声干扰。

$$S_{NR} = 10 \cdot \lg \left(\frac{P_{signal}}{P_{noise}} \right) \quad (4)$$

式中: S_{NR} 代表信噪比; P_{signal} 代表信号的平均功率; P_{noise} 代表噪声的平均功率。

图 7 为无噪声时该模型分类结果图。从图 7 中可以看出每类电能质量扰动的准确率基本都在 100%。表 2 为多种信噪比下本文 TCN-LSTM 模型分类的准确率。从表 2 中可以看出,在无噪声和信噪比分别为 50 dB、40 dB、30 dB、20 dB、10 dB 的情况下,TCN-LSTM 的分类准确率分别达到了 99.8%、99.8%、99.7%、99.5%、98.2%、84.4%,表明 TCN-LSTM 具有较强的抗噪性能。

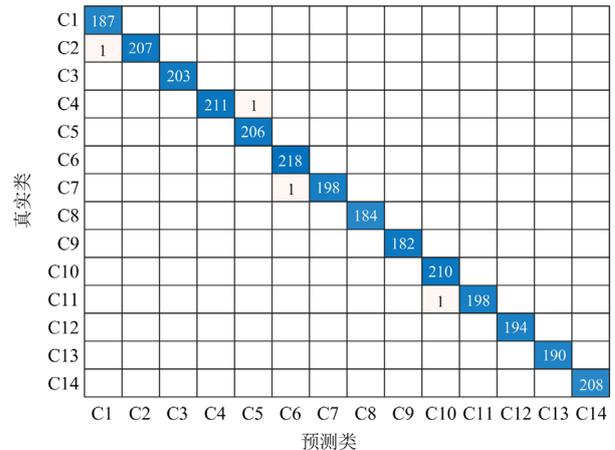


图 7 无噪声时模型分类结果图

Fig. 7 Classification results of the model without noise

表 1 不同扰动类型的数学表达式和波形图

Table 1 Mathematical expressions and waveform diagrams of different disturbance types

扰动类型	数学表达式	波形图
电压暂降	$x(t) = \{1 - k[u(t - t_2) - u(t - t_1)]\} \sin(\omega t)$	
电压暂升	$x(t) = \{1 + k[u(t - t_1) - u(t - t_2)]\} \sin(\omega t)$	
电压中断	$x(t) = \{1 - k[u(t - t_1) - u(t - t_2)]\} \sin(\omega t)$	
暂态脉冲	$x(t) = \sin(\omega t) + k[u(t - t_1) - u(t - t_2)]$	
暂态振荡	$x(t) = \sin(\omega t) + k \cdot \exp(-(t - t_1)\tau) \cdot \sin(\beta\omega t) \cdot [u(t - t_1) - u(t - t_2)]$	
电压波动	$x(t) = [1 + \alpha \cdot \sin(\beta\omega t)] \cdot \sin(\omega t)$	
谐波	$x(t) = \sin(\omega t) + k_3 \sin(3\omega t) + k_5 \sin(5\omega t) + k_7 \sin(7\omega t)$	
电压暂升&谐波	$x(t) = \{1 + k[u(t - t_2) - u(t - t_1)]\} \sin(\omega t) + k_3 \sin(3\omega t) + k_5 \sin(5\omega t) + k_7 \sin(7\omega t)$	
电压暂降&谐波	$x(t) = \{1 - k[u(t - t_2) - u(t - t_1)]\} \sin(\omega t) + k_3 \sin(3\omega t) + k_5 \sin(5\omega t) + k_7 \sin(7\omega t)$	
暂态振荡&谐波	$x(t) = \sin(\omega t) + k_3 \sin(3\omega t) + k_5 \sin(5\omega t) + k_7 \sin(7\omega t) + k \cdot \exp(-(t - t_1)\tau) \cdot \sin(\beta\omega t) \cdot [u(t - t_1) - u(t - t_2)]$	
电压波动&谐波	$x(t) = [1 + \alpha \cdot \sin(\beta\omega t)] \cdot \sin(\omega t) + k_3 \sin(3\omega t) + k_5 \sin(5\omega t) + k_7 \sin(7\omega t)$	
电压暂降&暂态振荡	$x(t) = \{1 - k_1[u(t - t_2) - u(t - t_1)]\} \sin(\omega t) + k \cdot \exp(-(t - t_1)\tau) \cdot \sin(\beta\omega t) \cdot [u(t - t_3) - u(t - t_4)]$	
电压波动&暂态振荡	$x(t) = [1 + \alpha \cdot \sin(\beta_1\omega t)] \cdot \sin(\omega t) + k \cdot \exp(-(t - t_1)\tau) \cdot \sin(\beta\omega t) \cdot [u(t - t_1) - u(t - t_2)]$	

表 2 不同信噪比下模型针对不同扰动的分类准确率
Table 2 Classification accuracy of the model for different perturbations under different signal-to-noise ratios

扰动类型	无噪声	S_{NR}					%
		50 dB	40 dB	30 dB	20 dB	10 dB	
C1	99.4	100	100	98.4	98.2	81.6	
C2	100	100	100	100	98.9	88.5	
C3	100	100	100	100	100	96.9	
C4	100	100	100	98.9	95.9	66.3	
C5	99.5	100	99.5	99	99.5	92.3	
C6	99.5	99.4	99.5	99.2	98.3	89.3	
C7	100	100	100	100	95.9	91.4	
C8	100	99.4	99.4	100	100	100.0	
C9	100	100	98.9	99.4	97.7	54.7	
C10	99.5	100	100	100	100	93.2	
C11	100	100	100	100	96.2	95.7	
C12	100	100	99.5	99.4	98.5	87.3	
C13	100	100	100	99.3	98.6	94.8	
C14	100	98.9	99.4	99.4	97.4	50.3	
平均	99.8	99.8	99.7	99.5	98.2	84.4	

表 2 中: C1 为电压波动; C2 为电压波动+谐波; C3 为电压波动+振荡; C4 为谐波; C5 为电压中断; C6 为电压振荡; C7 为电压振荡+谐波; C8 为暂态脉冲; C9 为电压暂降; C10 为电压暂降+谐波; C11 为电压暂降+振荡; C12 为电压暂升; C13 为电压暂升+谐波; C14 为正常。

表 3 显示了本文所提出的模型与文献中的模型^[21-23]在准确率方面的对比。相较于其他模型, 所提模型表现出更高的准确率, 并且具有较好的抗噪性能。

表 3 所提模型与其他模型分类准确率对比

Table 3 Comparison of classification accuracy between the proposed model and other models

模型	S_{NR}				%
	20 dB	30 dB	40 dB	50 dB	
ResNet	—	94.5	95.1	95.6	
LSTM	—	70.2	76.9	77.1	
CNN	—	68.3	68.6	68.9	
DWT-BP	93.1	87.1	94.6	97.8	
MRSVD-RF	95.7	97.8	98.1	98.4	
TCN-LSTM	98.2	99.5	99.7	99.8	

4 结论

本文提出了一种基于 TCN 与 LSTM 相结合的电能质量扰动分类模型。该模型具有以下优点:

1) 本文所提模型结合了 TCN 和 LSTM 两者的

优点, 相较于传统方法, 该模型在电能质量扰动分类任务上表现出色, 分类准确率显著提升。

2) 通过在电能质量扰动信号中分别加入信噪比为 10 dB、20 dB、30 dB、40 dB、50 dB 的白噪声和无噪声的案例来模拟真实环境的分类测试, 结果表明本文所提模型具有较好的抗噪能力, 在复杂环境下依然保持高效准确的分类能力。

3) 本文所提 TCN-LSTM 模型结构简单, 分类能力强, 且鲁棒性好。相较于 ResNet、LSTM、CNN、DWT-BP 和 MRSVD-RF 这 5 个网络模型, TCN-LSTM 模型在信噪比分别为 20 dB、30 dB、40 dB 和 50 dB 时, 其分类准确度分别为 98.2%、99.5%、99.7%和 99.8%, 表示出更高的准确率和抗噪性能, 为电能质量扰动的准确辨识提供了一种有效的解决方法。

参考文献

- [1] MAHELA O P, SHAIK A G, GUPTA N. A critical review of detection and classification of power quality events[J]. Renewable and Sustainable Energy Reviews, 2015, 41: 495-505.
- [2] 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): 1-10.
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): 1-10.
- [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] 王燕. 电能质量扰动检测的研究综述[J]. 电力系统保护与控制, 2021, 49(13): 174-186.
WANG Yan. Review of research development in power quality disturbance detection[J]. Power System Protection and Control, 2021, 49(13): 174-186.
- [5] WANG M, ZHOU H J, YANG S Y, et al. Robust compressive features based power quality events classification with analog-digital mixing network (ADMN)[J]. Neurocomputing, 2016, 171: 685-692.
- [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] 侯伊楠. 基于深度学习的电能质量扰动分析方法研究[D]. 沈阳: 东北大学, 2019.
HOU Yinan. Research on power quality disturbance

- analysis methods based on deep learning[D]. Shenyang: Northeastern University, 2019.
- [8] 孙冬, 高清维, 竺德, 等. 离散傅里叶变换的自适应循环电力谐波分析算法[J]. 安徽大学学报(自然科学版), 2013, 37(6): 57-64.
SUN Dong, GAO Qingwei, ZHU De, et al. An adaptive recursive algorithm for harmonic analysis of power system based on DFT transform[J]. Journal of Anhui University (Natural Science Edition), 2013, 37(6): 57-64.
- [9] DE YONG D, BHOWMIK S, MAGNAGO F. An effective power quality classifier using wavelet transform and support vector machines[J]. Expert Systems with Applications, 2015, 42(15/16): 6075-6081.
- [10] 许立武, 李开成, 罗奕, 等. 基于不完全 S 变换与梯度提升树的电能质量复合扰动识别[J]. 电力系统保护与控制, 2019, 47(6): 24-31.
XU Liwu, LI Kaicheng, LUO Yi, et al. Classification of complex power quality disturbances based on incomplete S-transform and gradient boosting decision tree[J]. Power System Protection and Control, 2019, 47(6): 24-31.
- [11] 黄奂, 吴杰康. 基于经验模态分解的电能质量扰动信号定位方法[J]. 电网技术, 2010, 34(5): 41-45.
HUANG Huan, WU Jiekang. A method to locate power quality disturbing signal based on empirical mode decomposition[J]. Power System Technology, 2010, 34(5): 41-45.
- [12] 黄南天, 彭华, 蔡国伟, 等. 电能质量复合扰动特征选择与最优决策树构建[J]. 中国电机工程学报, 2017, 37(3): 776-786.
HUANG Nantian, PENG Hua, CAI Guowei, et al. Feature selection and optimal decision tree construction of complex power quality disturbances[J]. Proceedings of the CSEE, 2017, 37(3): 776-786.
- [13] LIU Zhigang, CUI Yan, LI Wenhui. A classification method for complex power quality disturbances using EEMD and rank wavelet SVM[J]. IEEE Transactions on Smart Grid, 2015, 6(4): 1678-1685.
- [14] 王慧慧, 王萍, 刘涛, 等. 基于生长-修剪优化 RBF 神经网络的电能质量扰动分类[J]. 电网技术, 2018, 42(8): 2408-2415.
WANG Huihui, WANG Ping, LIU Tao, et al. Power quality disturbance classification based on growing and pruning optimal RBF neural network[J]. Power System Technology, 2018, 42(8): 2408-2415.
- [15] 龚正, 邹阳, 金涛, 等. 基于特征融合并行优化模型的电能质量扰动分类方法[J]. 中国电机工程学报, 2023, 43(3): 1017-1027.
GONG Zheng, ZOU Yang, JIN Tao, et al. Classification method of power quality disturbances based on optimized parallel model of features merging[J]. Proceedings of the CSEE, 2023, 43(3): 1017-1027.
- [16] 曹梦舟, 张艳. 基于卷积-长短期记忆网络的电能质量扰动分类[J]. 电力系统保护与控制, 2020, 48(2): 86-92.
CAO Mengzhou, ZHANG Yan. Classification for power quality disturbances based on CNN-LSTM network[J]. Power System Protection and Control, 2020, 48(2): 86-92.
- [17] 王伟, 李开成, 许立武, 等. 基于一维卷积神经网络多任务学习的电能质量扰动识别方法[J]. 电测与仪表, 2022, 59(3): 18-25.
WANG Wei, LI Kaicheng, XU Liwu, et al. Power quality disturbance recognition method based on multi-task learning and one-dimensional convolutional neural network[J]. Electrical Measurement & Instrumentation, 2022, 59(3): 18-25.
- [18] 史爱武, 罗良杰, 何凯. 基于 EMD-TCN 的云资源预测研究[J]. 计算机应用与软件, 2023, 40(7): 85-90.
SHI Aiwu, LUO Liangjie, HE Kai. Cloud resource prediction based on EMD-TCN[J]. Computer Applications and Software, 2023, 40(7): 85-90.
- [19] 朱树理. 基于时间卷积网络的车辆位置追踪研究[D]. 北京: 北京交通大学, 2021.
ZHU Shuli. Research on vehicle position tracking based on temporal convolutional networks[D]. Beijing: Beijing Jiaotong University, 2021.
- [20] 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.
- [21] 陈祥宇, 林东, 王家昌. 改进 ResNet 的电能质量分类算法[J]. 福建电脑, 2023, 39(8): 1-4.
CHEN Xiangyu, LIN Dong, WANG Jiachang. Improved power quality classification algorithm for ResNet[J]. Journal of Fujian Computer, 2023, 39(8): 1-4.
- [22] 杨晓梅, 郭林明, 肖先勇, 等. 基于可调品质因子小波变换和随机森林特征选择算法的电能质量复合扰动分类[J]. 电网技术, 2020, 44(8): 3014-3020.
YANG Xiaomei, GUO Linming, XIAO Xianyong, et al. Classification of multiple power quality disturbances based on TQWT and random forest feature selection algorithm[J]. Power System Technology, 2020, 44(8): 3014-3020.
- [23] 张家宁, 罗月婉, 郭林明, 等. 基于多分辨奇异值分解包和随机森林的电能质量扰动分类研究[J]. 计算机应用与软件, 2023, 40(9): 296-302.
ZHANG Jianing, LUO Yuewan, GUO Linming, et al. Power quality disturbance classification based on multi-resolution singular value decomposition package and random forest[J]. Computer Application and Software, 2023, 40(9): 296-302.

收稿日期: 2023-12-13; 修回日期: 2024-02-12

作者简介:

王义国(1984—), 男, 本科, 高级工程师, 研究方向为水力和新能源发电; E-mail: wangyiguo@gdyd.com

林峰(1976—), 男, 本科, 高级工程师, 研究方向为电气工程及自动化; E-mail: linfeng1@gdyd.com

李琦(1986—), 男, 本科, 高级工程师, 研究方向为电力管理。E-mail: 710226@dms.yudean.com

(编辑 魏小丽)