



DOI:10.12404/j.issn.1671-1815.2303747

引用格式:金星,周凯翔,于海洲,等.基于卷积神经网络与 Transformer 的电能质量扰动分类方法[J].科学技术与工程,2024,24(16):6726-6733.

Jin Xing, Zhou Kaixiang, Yu Haizhou, et al. Power quality disturbances classification method based on convolutional neural network and Transformer [J]. Science Technology and Engineering, 2024, 24(16): 6726-6733.

## 电工技术

# 基于卷积神经网络与 Transformer 的 电能质量扰动分类方法

金星,周凯翔,于海洲,王盛慧\*,伍孟海

(长春工业大学电气与电子工程学院,长春 130000)

**摘要** 复杂电能质量扰动(power quality disturbances, PQD)的智能分类对于智能电网发展具有重要意义。扰动特征的提取与定位、模式识别与分类是电能质量扰动分类方法研究的难点。采用深度学习算法,将具有关注全局信息的 Transformer 与善于提取局部特征的卷积神经网络相融合,提出一种基于卷积神经网络(convolutional neural network, CNN)与 Transformer 的电能质量扰动分类方法,即 CTranCBA。这种双深度学习模型分类方法主要是通过一维卷积神经网络提取电能质量扰动信号特征,利用 Transformer 自注意力机制引导模型关注序列中不同位置间的依赖关系,实现对扰动信号局部特征与全局特征的互补,克服了因感受野的限制而带来的识别不清、分类不准等问题。使用 23 种不同电能质量扰动信号,将 CTranCBA 与 Deep-CNN、CNN-LSTM、CNN-CBAM 方法进行比较。结果表明:该方法在分类准确率和抗噪性方面表现优异,可为电能质量扰动智能分类提供一种新的方法。

**关键词** 电能质量扰动(PQD);卷积神经网络(CNN);Transformer 模型;卷积注意力机制

中图分类号 TM711;

文献标志码 A

## Power Quality Disturbances Classification Method Based on Convolutional Neural Network and Transformer

JIN Xing, ZHOU Kai-xiang, YU Hai-zhou, WANG Sheng-hui\*, WU Meng-hai

(School of Electrical and Electronic Engineering, Changchun University of Technology, Changchun 130000, China)

**[Abstract]** It is of great significance to the development of smart grid on intelligent classification of complex power quality disturbances (PQD). Disturbance feature extraction and location, pattern recognition and classification are the difficulties of power quality disturbance classification. Based on deep learning, Transformer, which paid attention to global information, was combined with convolutional neural network (CNN). It was good at extracting local features. A power quality disturbance classification method based on CNN and Transformer, namely CTranCBA, was proposed. This dual-deep learning model classification mainly extracted the characteristics of power quality disturbance signals by one-dimensional CNN, and used Transformer self-attention mechanism to guide the model to pay attention to the dependence between different positions in the sequence. As a result, it realized the complementarity of local characteristics and global characteristics of disturbance signals, and overcame the problems of unclear recognition and inaccurate classification caused by the limitation of receptive fields. The CTranCBA was compared with Deep-CNN, CNN-LSTM, CNN-CBAM in 23 different power quality disturbance signals. The results show that the CTranCBA is superior in classification accuracy and noise immunity, which can provide a new method for intelligent classification of power quality disturbance.

**[Keywords]** power quality disturbances (PQD); convolutional neural network (CNN); Transformer model; convolutional attention mechanism

收稿日期:2023-05-22 修订日期:2024-03-11

基金项目:吉林省科技发展计划项目(20230203195SF)

第一作者:金星(1976—),男,汉族,吉林长春人,硕士,教授。研究方向:电工理论与新技术。E-mail:jinxing@ccut.edu.cn。

\*通信作者:王盛慧(1976—),女,汉族,吉林吉林人,硕士,教授。研究方向:电工理论与新技术。E-mail:wangshenghui@ccut.edu.cn。

投稿网址:www.stae.com.cn

近年来,为了追求更科学、更环保、可持续发展模式,智能电网迎来了快速发展。然而,在日益复杂的电网系统中,电能质量扰动(power quality disturbances, PQD)问题日益明显<sup>[1]</sup>。尤其是在新能源接入规模不断扩大的情况下,PQD如谐波、电压骤降、电压闪变等情况出现得更频繁<sup>[2]</sup>。这会严重影响电网的稳定和运行质量,给电网和用电设备带来巨大隐患,并导致电力设备过载、电能效率降低、数据损失等问题,甚至会导致电力系统崩溃<sup>[3]</sup>。因此,精确检测和分类PQD对于智能电网的稳定发展具有重要意义。

PQD的分类通常包括两个步骤,即扰动信号的特征提取和特征分类<sup>[4]</sup>。传统方法是先将这两个步骤单独区分开,首先运用各种信号处理算法得到扰动特征,然后通过分类算法对得到的特征进行识别分类。张家宁等<sup>[5]</sup>使用多分辨率奇异值分解进行信号处理,并提取分解后得到的信号特征,最后使用随机森林分类信号。郭云峰等<sup>[6]</sup>提出双层支持向量机的方法,使用可调Q因子小波变换提取特征,并使用优化的支持向量机进行分类。然而,传统方法通常需要在时频域中对信号进行预处理,这涉及人工干预的过程,难免会出现特征遗漏等问题。

深度学习<sup>[7]</sup>在各个领域的成功实践也为PQD分类提供了新的方向。深度学习能够大大减少人工干预的过程,提高分类效率和准确性。目前,以深度学习为核心的人工智能算法在PQD识别分类领域已经有了较为成熟的发展。胡杰等<sup>[8]</sup>提出双模态特征融合的卷积神经网络,将时序扰动特征和图像振幅特征相结合,增强了特征信息。Gong等<sup>[9]</sup>通过堆叠多个单元构造了一维深度卷积神经网络(geographic information system, CNN),实现扰动特征的自动提取与分类。王伟等<sup>[10]</sup>提出多任务分类,提升了复合扰动与单一扰动的标签关联性。Sindi等<sup>[11]</sup>结合一维CNN和二维CNN实现了PQD在不同维度上的特征融合,增强了特征信息的深度。奚鑫泽等<sup>[12]</sup>将软阈值函数插入一维CNN中,提高了模型的抗噪能力。但是上述方法只关注了扰动信号的局部特征,缺乏对扰动信号全局信息的捕捉能力,缺少对序列中不同元素之间关系的理解。

为了弥补上述方法在复杂电网环境下对PQD分类的不足,提出基于CNN与Transformer的电能质量扰动分类方法CTranCBA。该方案结合了两种深度学习模型的优势,既能提取扰动的局部特征又能捕获全局特征,增强了特征图的信息表达。首先引入CNN提取到信号中的细微变化和局部特征,使模

型对不同类型的扰动能够作出区分。然后,结合Transformer的自注意力机制,使模型能够更好地捕捉到扰动信号中的长距离依赖关系和全局特征,从而有效地学习到信号中更为抽象的特征表示。为了更好地结合CNN和Transformer并提升模型的性能,还引入卷积注意力机制(convolutional block attention mechanism, CBAM),通过加强特征图的相关信息,改进了特征表达,使CTranCBA能够更好地处理多模态数据,提高泛化能力和鲁棒性。

## 1 模型的设计与实现

CTranCBA模型结构如图1所示,其主要由3个模块构成,即CNN特征提取模块、Transformer模块、CBAM模块。首先通过3个CNN特征提取模块学习扰动特征局部信息以及位置信息;利用Transformer捕获全局像素点之间的相关性以捕捉扰动特征的全局信息;引入CBAM模块对通道维度和空间维度进行重点关注;最后利用1个CNN模块融合所有特征信息,并通过全局平均池化进行降维,由全连接层与Softmax分类器实现PQD的自动识别与分类。

### 1.1 CNN特征提取模块

采用CNN对PQD信号的局部特征进行提取。CNN是一类包含卷积计算且具有深度结构的前馈神经网络<sup>[13]</sup>,其优点在于局部连接和权值共享,不仅能够减少权值的数量使得网络易于优化,也能够降低模型的复杂度<sup>[14]</sup>。

所构造的卷积块结构如图2所示,每个卷积块中都包括两个卷积层和一个池化层。首先使用一个卷积层对输入数据进行特征提取,然后通过激活函数进行非线性变换。对于一维输入信号,使用一维卷积层执行卷积运算,卷积层内部包含了多个卷积核,在工作时会有规律地扫过输入特征,在感受野内对输入做矩阵元素乘法求和并叠加偏差量,其表达式为

$$y_i = f\left(\sum_{d=1}^D W_d \otimes X_{i+d-1} + b\right) \quad (1)$$

式(1)中: $D$ 为卷积核的大小; $\otimes$ 为卷积运算; $W_d$ 为卷积核的权重,是一维向量; $X$ 为一维信号样本; $b$ 为偏置参数; $f$ 为激活函数 $\text{relu}$ <sup>[15]</sup>,用于在卷积运算后将网络非线性化以提升神经网络的拟合能力,其计算速度比Tanh函数更快,并且能够让模型更容易训练,其表达式为

$$\text{relu}(X) = \begin{cases} X, & X \geq 0 \\ 0, & X < 0 \end{cases} \quad (2)$$

式(2)中: $X$ 为输入的特征值。




图1 模型整体框架

Fig. 1 Overall framework of the model




图2 卷积块结构图

Fig. 2 Convolution block structure diagram

随后应用另一个卷积层进一步提取变换后的特征,再通过激活函数后就得到了一个经过两次卷积的新特征图。为了降低特征维数并提高特征提取的鲁棒性,将新特征图通过一个最大池化层(Max-Pooling)进行下采样。在池化操作之后,添加批量归一化层(batch normalization layer, BN)对池化后的数据进行归一化处理。BN会对每个小批量数据进行均值和方差的运算,并应用于每个数据,从而使特征具有相同的统计性质,可以缓解模型训练过程中的梯度消失等问题。BN的表达式为

$$y = \frac{x - m_{\text{ean}}(x)}{\sqrt{\text{Var}(x) + e_{\text{ps}}}}\gamma + \beta \quad (3)$$

式(3)中; $m_{\text{ean}}(x)$ 为输入特征图 $x$ 的均值; $\text{Var}(x)$ 为 $x$ 的方差; $\gamma$ 和 $\beta$ 分别为缩放与平移变量,用于恢复原分布,默认情况下 $\gamma$ 为0, $\beta$ 为1; $e_{\text{ps}}$ 为很小的常量,用于防止分母为零的情况。

PQD信号本质是一组一维的时间序列数据<sup>[16]</sup>,因此使用3个一维卷积块叠加以提取扰动的局部特征,最后由1个卷积块融合特征信息,并输入至全连接层和Softmax层得到最终分类结果。

## 1.2 Transformer 模块

CNN擅长对局部特征进行提取,但对于序列中的长程依赖关系表现欠佳,这些依赖关系是指序列中某些时刻的特征与其前后几个时刻的特征之间的关系。而Transformer模型能够提取序列中的长程依赖

关系进而得到更具有全局性的特征<sup>[17]</sup>。因此,借鉴Vision Transformer模型<sup>[18]</sup>的思路,引入Transformer的Encoder模块,使模型可以同时关注局部信号特征和全局特征,从而提高PQD信号的识别准确率。

自注意力机制(self-attention)<sup>[19]</sup>是Transformer中核心的组成部分,其通过查询(query,  $Q$ )与键(key,  $K$ )的注意力汇聚来为值(value,  $V$ )分配注意力权重,从而生成最终的输出结果。这种注意力机制在自然语言处理和图像处理等领域都得到了广泛应用<sup>[20]</sup>。

多头注意力机制(multi-head self-attention, MSA)是在自注意力机制的基础上进行的改进,是将输入的序列分成 $n$ 个子序列,每个子序列都通过不同的变换矩阵进行自注意力计算,得到 $n$ 个不同的输出结果。这些输出结果再进行拼接,并经过一次线性变换生成最终的关注权重。这种机制的好处在于,它能够让模型学习到不同子空间的特征信息,得到多种类型的特征表达,从而提高模型的表达能力。同时,MSA还能够并行计算多个子序列,提高模型的训练效率<sup>[21]</sup>,其表达式为

$$\text{MSA}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_n)W^o \quad (4)$$

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (5)$$

式中: $Q$ 为查询向量; $K$ 为键向量; $V$ 为数值向量,这3个向量均由输入序列经过线性变换得到;Concat为级联运算; $\text{head}_i$ 为第 $i$ 个并行计算的自注意力头;

$W^O$ 为输出变换矩阵; $W_i^Q$ 、 $W_i^K$ 、 $W_i^V$ 为第*i*个查询、键、值的变换矩阵;Attention为自注意力运算。

本文Transformer模块结构如图3所示,它由层归一化(layer norm, LN)<sup>[22]</sup>、MSA、Dropout和前馈网络构成。LN是在单个数据的指定维度进行的运算,能够避免批量归一化层中受小批量数据分布的影响,更适合Transformer。特征在经过层归一化处理,输入MSA,本文MSA头数设置为4,即4头注意力。前馈网络是Transformer中的另一个重要结构,它由全连接层、Dropout层和激活函数SiLu构成。其中,Dropout层能够随机丢弃一些神经元,使得模型具有更好的泛化能力。需要注意的是,为了避免梯度消失,在Dropout层后都由残差连接的形式连接到下一层。本文叠加两个Transformer模块用于加强模型对全局特征的提取能力。




图3 Transformer 结构图  
Fig. 3 Transformer structure diagram

### 1.3 CBAM 模块

卷积注意力模块是一种简单而有效的轻量级注意力模块<sup>[23]</sup>。它将通道注意力模块与空间注意力模块串行连接,最后输出注意力特征图,用于突出通道上和空间上更有意义的特征。其优点是可以让模型关注重要特征,抑制不必要特征,并且所需的运算量很小,也能够很容易地与卷积神经网络相融合。其中的通道注意力与空间注意力的结构如图4所示。




图4 CBAM 结构图  
Fig. 4 CBAM structure diagram

#### 1.3.1 通道注意力模块

首先,输入的全局空间信息分别通过全局平均池化和全局最大池化的运算,得到两个特征,然后将

两个特征传入多层感知机(multilayer perceptrons, MLP),在MLP中,输入特征通过两个一维的卷积层和一个relu激活函数将通道数压缩再扩张回原通道数,最后将两个特征逐元素相加并通过Sigmoid函数生成通道注意力特征,其表达式为

$$\begin{aligned} M_c(F) &= \sigma \{ \text{MLP}[\text{Avgpool}(F)] + \\ &\quad \text{MLP}[\text{Maxpool}(F)] \} \\ &= \sigma \{ W_1[W_0(F_{\text{avg}}^c)] + W_1[W_0(F_{\text{max}}^c)] \} \end{aligned} \quad (6)$$

式(6)中: $F$ 为输入的特征图; $\sigma$ 为Sigmoid激活函数;Avgpool( $F$ )和 $F_{\text{avg}}^c$ 为对特征图做全局平均池化;Maxpool( $F$ )和 $F_{\text{max}}^c$ 为全局最大池化;MLP的权重 $W_0$ 和 $W_1$ 对于两个输入是共享的。

#### 1.3.2 空间注意力模块

空间注意力模块的输入是经过通道注意力模块运算得到的特征图,首先输入基于通道维度做最大池化和平均池化的操作,得到两个新特征图。其中,基于通道维度的最大池化通过每个通道的对应位置保留最大的数值,而平均池化是计算每个通道对应位置的平均值。然后将这两个特征图按照通道拼接得到特征向量,最后在经过一维的卷积层和Sigmoid激活函数后得到空间注意力特征,其表达式为

$$\begin{aligned} M_s(F) &= \sigma(f^{7 \times 7} \{ [\text{Avgpool}(F); \text{Maxpool}(F)] \}) \\ &= \sigma \{ f^{7 \times 7} [(F_{\text{avg}}^s; F_{\text{max}}^s)] \} \end{aligned} \quad (7)$$

式(7)中: $f^{7 \times 7}$ 为进行卷积操作,卷积核大小为 $7 \times 7$ 。

### 1.4 模型训练方式

深度学习的训练是指从训练数据中自动获得最优权重参数的过程。CTranCBA模型采用误差反向传播算法进行训练,并使用交叉熵误差作为损失函数<sup>[24]</sup>。通过对比,选择Adam优化器更新模型中可学习的参数。由于数据参数较多,采用小批量学习方式(mini-batch)进行训练,将数据样本随机划分成一份份小样本数据集,再分别对这些小样本进行训练。表1为本文模型的具体超参数设置。

表1 CTranCBA 模型参数设置  
Table 1 CTranCBA model parameter settings

| 网络结构           | 参数         | 数值               |
|----------------|------------|------------------|
| CNN 特征提取模块     | 卷积通道数      | 32, 64, 128, 256 |
|                | 卷积核大小      | $3 \times 1$     |
|                | 填充         | 1                |
|                | 卷积步长       | 1                |
|                | 池化层        | $2 \times 2$     |
| Transformer 模块 | 注意力头数      | 4                |
|                | Encoder 深度 | 2                |
| CBAM 模块        | 通道下降倍数     | 8                |

2 实验与分析

2.1 数据集介绍

本次研究中,使用 23 种不同 PQD 信号来评估所提出的框架的性能,并根据 *IEEE Recommended Practice for Monitoring Electric Power Quality* (IEEE Std. 1159—2009)<sup>[25]</sup> 标准和文献[26]中的数学模型,在 MATLAB 中对这些扰动信号进行仿真,包含 7 种单一电能质量扰动:谐波、电压暂降、电压暂升、电压中断、电压闪变、暂态振荡、暂态脉冲,以及 16 种由不同单一扰动组合而成的复合电能质量扰动信号。电能质量扰动仿真信号如表 2 所示。

表 2 23 种 PQD 信号

| Table 2 23 types of PQD signals |             |     |                       |
|---------------------------------|-------------|-----|-----------------------|
| 类型                              | PQD 信号      | 类型  | PQD 信号                |
| D1                              | 谐波          | D13 | 电压暂升 + 暂态振荡           |
| D2                              | 电压暂降        | D14 | 电压闪变 + 暂态振荡           |
| D3                              | 电压暂升        | D15 | 谐波 + 暂态振荡             |
| D4                              | 电压中断        | D16 | 电压暂降 + 暂态脉冲           |
| D5                              | 电压闪变        | D17 | 电压暂升 + 暂态脉冲           |
| D6                              | 暂态振荡        | D18 | 闪变 + 暂态脉冲             |
| D7                              | 暂态脉冲        | D19 | 谐波 + 暂态脉冲             |
| D8                              | 电压暂降 + 谐波   | D20 | 暂降 + 谐波 + 暂态振荡        |
| D9                              | 电压暂升 + 谐波   | D21 | 暂升 + 谐波 + 暂态振荡        |
| D10                             | 电压中断 + 谐波   | D22 | 闪变 + 谐波 + 暂态脉冲        |
| D11                             | 电压闪变 + 谐波   | D23 | 暂降 + 谐波 + 暂态振荡 + 暂态脉冲 |
| D12                             | 电压暂降 + 暂态振荡 |     |                       |

电压信号的基频为 50 Hz,采样率设置为 3 200 Hz,每个样本采样 10 个周期,采样长度为 640,每组样本都有 1 000 个信号。由于在实际工程中电能质量扰动信号都存在噪声干扰,为了保证数据的真实性,在每个信号中随机加入 0~50 dB 高斯白噪声。将 23×1 000 组信号组成的数据集按照 6:2:2 分为训练集、验证集以及测试集。模型的训练基于 Pytorch1.7 框架,硬件环境为 i5-10600KF CPU、RTX 3070TI GPU。

2.2 仿真验证与分析

为了验证所提 CTranCBA 模型的有效性,在 Pytorch深度学习框架中实现并训练,训练的迭代次数设为 120 次,样本的小批量尺寸大小为 256。在训练的过程中,每次迭代都会检测模型在验证集中的准确率是否有提升,若有提升,则将其保存到本地,选择在验证集中性能最好的模型作为最终模型,分类准确率和损失值是评估模型性能的重要指标。分类准确率  $A_{cc}$  代表正确样本数与样本总数的比值,其表达式为

$$A_{cc} = \frac{\text{正确分类数}}{\text{样本总数}} \times 100\%$$
 (8)

损失值  $L_{oss}$  是用于衡量模型的预测概率分布与实际标签之间的差异,其表达式为

$$L_{oss} = -\frac{1}{M} \sum_{m=1}^M \sum_{n=1}^N y_{m,n} \ln p_{m,n}$$
 (9)

式(9)中: $M$  为样本批量大小; $N$  为类别总数; $y_{m,n}$  和  $p_{m,n}$  分别为  $n$  的第  $m$  个扰动样本真实标签和预测值。

训练过程准确率与损失变化如图 5 所示。在训练开始阶段,模型的准确率较低,损失值较大,并且在训练过程中存在一定的波动,但总体呈上升趋势。随着迭代次数增加,模型的表现不断提升,在经过 35 轮的迭代后,训练集和验证集的准确率逐渐趋于稳定,准确率超过 99.02%,验证集的损失值稳定在 0.038,表明模型已经逐渐收敛。同时在训练的过程中也未出现过拟合与欠拟合的现象,表明模型的泛化能力较强。

为了进一步证明所提 CTranCBA 模型的有效性,构建了 3 种其他的深度学习模型进行比较分析,并在保证模型参数基本相同的情况下进行仿真实验。

(1) Deep-CNN<sup>[16]</sup>。在 PQDS 检测与分类领域使用的一种经典 CNN 结构,特征提取单元由一维卷积层、池化层和批量归一化层堆叠而成,并输出至全连接层,最后由一个 Softmax 层得到分类结果。各层卷积的卷积核数量分别设为 32、32、64、64、128、128,卷积核大小为 3,步长为 1。

(2) CNN-LSTM<sup>[27]</sup>。使用 CNN 和 LSTM 的混合模型,先采用 CNN 提取出扰动信号的特征数据,并将其以序列的形式作为 LSTM 的输入,再用 LSTM 对特征数据进行筛选更新,最后对输出特征进行学习分类。

(3) CNN-CBAM。在本文所提的 CTranCBA 模型基础上,去除 Transformer 模块,仅保留 CNN 特征提取模块以及 CBAM 模块,其他超参数不变。




图 5 CTranCBA 训练图

Fig. 5 CTranCBA training map

在相同深度学习环境下实现上述3种模型,并与本文模型进行比较,设置迭代轮次为120次。各模型在不同噪声环境下的测试集准确率结果对比如图6所示,参数对比如表3所示。

由图6可知,CTranCBA在除20 dB的极端噪声环境中测试集的分类准确率略低于经典的Deep-CNN模型外,在其他噪声环境中都取得了最佳性能,并且在50 dB和随机噪声下准确率均超过99%。相比于CNN-CBAM,CTranCBA的准确率整体提高了约0.7%,在30 dB噪声下提高了约1%,表明通过结合CNN与Transformer,有效增强了模型的特征表达,提升了PQD分类准确率。在随机噪声下,Deep-CNN、CNN-CBAM的准确率约为98.6%,CNN-LSTM的准确率最低,为96.6%。Deep-CNN和CNN-CBAM的结构类似且准确率差距很小,表明在CNN中单独添加CBAM模块不能很明显地提升模型分类准确率。

由表3可知,在训练过程中,所提出的CTranCBA模型在验证集中达到的准确率最高,损失值最小,分类准确率能够达到99.15%,比排第二的CNN-CBAM高出0.6%。从参数和运算时间的角度来看,由于结合了两种深度学习模型,算法复杂度较高,在包含2 300个样本的测试集上的测试时间最长,为18.2 s,但总体而言,CTranCBA与CNN-CBAM、Deep-CNN的测试时间和每一轮迭代所需的时间只差几秒。本文模型在牺牲了少量的运算时间下有效提升了准确度。

理论上,在CNN-Transformer模型中加入CBAM




图6 不同噪声环境下各模型准确率对比图  
Fig. 6 Comparison of accuracy of various models under different noise environments

可以让模型增加重要特征的权重,减少噪声的干扰,提高分类性能。因此,比较了添加和不添加CBAM的结果,如图7所示。

由图7可知,在迭代35次后,添加了CBAM的模型的精度趋于稳定,并且超过了99%,而未添加CBAM的模型在迭代了50次后才趋于稳定,准确率在98.8%左右。添加了CBAM后,模型的验证准确率有所提高,并且训练曲线更加平滑,说明其拟合效果更好。以上表明在CNN与Transformer相结合的模型中引入CBAM能够使模型更有针对性地关注输入数据中的重要信息,进一步提升了模型的性能,使其更快地收敛到更高的准确率。




图7 有无CBAM的准确率对比  
Fig. 7 Comparison of accuracy with and without CBAM

3 结论

提出一种基于双深度学习模型的新方法,称为CTranCBA,用于PQD的自动分类。它结合了两个子网络的优势,即CNN和Transformer,前者用于提取扰动信号的局部和复杂特征,后者用于对特征图中的长程依赖关系进行建模处理,并在全局范围内提取特征。将CBAM引入两个子网络的连接处,使模型在通道和空间上关注更重要的特征,增加重要特征图的权重值,提升了模型的性能。在相同实验环境下,仿真结果表明,结合局部特征和全局特征的分类方法增强了特征图的信息表达,提升了扰动特征辨识度,使模型更好地处理数据集中的不同信号和噪声,提高模型的鲁棒性和准确率。相较于其

表3 各模型对比  
Table 3 Comparison of various models

| 模型       | 验证集最高准确率/% | 验证集最低损失 | 每批训练时间/s | 测试时间/s | 总参数     | 容量/MB |
|----------|------------|---------|----------|--------|---------|-------|
| Deep-CNN | 98.47      | 0.066   | 1.8      | 12.6   | 373 461 | 3.80  |
| CNN-LSTM | 97.18      | 0.100   | 2.2      | 10.4   | 107 793 | 1.24  |
| CNN-CBAM | 98.56      | 0.060   | 1.9      | 13.5   | 439 711 | 4.19  |
| CTranCBA | 99.15      | 0.034   | 3.3      | 18.2   | 502 367 | 8.56  |

他 CNN 深度学习框架,CTranCBA 具有精度更高、收敛速度更快、结构更紧凑的优点,在不同噪声环境中都有较高的分类准确率和对噪声的鲁棒性。

### 参考文献

- [1] 陈一镖,倪陈义,陈浩,等. 基于 MPA 优化 PNN 的电能质量扰动识别方法仿真[J]. 计算机仿真, 2023, 40(6): 107-113.  
Chen Yibiao, Ni Chenyi, Chen Hao, et al. Simulation of power quality disturbance identification method based on MPA optimized PNN[J]. Computer Simulation, 2023, 40(6): 107-113.
- [2] 赵长伟, 骞睿珺, 杜天硕, 等. 基于 LSTM 的重要用户电能质量趋势预测分析模型[J]. 电力系统及其自动化学报, 2022, 34(7): 26-33.  
Zhao Changwei, Pian Ruijun, Du Tianshuo, et al. LSTM based trend prediction and analysis model for important user power quality [J]. Journal of Power Systems and Automation, 2022, 34(7): 26-33.
- [3] Zhang Y, Zhang Y, Zhou X. Classification of power quality disturbances using visual attention mechanism and feed-forward neural network[J]. Measurement, 2022, 188: 110390.
- [4] Gu D, Gao Y, Li Y, et al. A novel label-guided attention method for multilabel classification of multiple power quality disturbances [J]. IEEE Transactions on Industrial Informatics, 2021, 18(7): 4698-4706.
- [5] 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. Research on 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.
- [6] 郭云峰, 杨晓梅. 基于 SVM 的电能质量扰动信号分类方法[J]. 计算机应用与软件, 2022, 39(7): 95-100, 120.  
Guo Yunfeng, Yang Xiaomei. SVM-based classification method for power quality disturbance signals [J]. Computer Application and Software, 2022, 39(7): 95-100, 120.
- [7] 洪腾蛟, 丁凤娟, 王鹏, 等. 深度学习在轴承故障诊断领域的应用研究[J]. 科学技术与工程, 2021, 21(22): 9203-9211.  
Hong Tengjiao, Ding Fengjuan, Wang Peng, et al. Application of deep learning in bearing fault diagnosis [J]. Science Technology and Engineering, 2021, 21(22): 9203-9211.
- [8] 胡杰, 程志友, 姜帅, 等. 基于 TDFCNN 模型的电能质量扰动分类[J]. 安徽大学学报(自然科学版), 2023, 47(5): 58-64.  
Hu Jie, Cheng Zhiyou, Jiang Shuai, et al. Power quality disturbance classification based on TDFCNN model [J]. Journal of Anhui University(Natural Science Edition), 2023, 47(5): 58-64.
- [9] Gong R, Ruan T. A new convolutional network structure for power quality disturbances identification and classification in micro-grids [J]. IEEE Access, 2020, 8: 88801-88814.
- [10] 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. A method for identifying power quality disturbances based on one-dimensional convolutional neural network multitask learning [J]. Electrical Measurement and Instrumentation, 2022, 59(3): 18-25.
- [11] Sindi H, Nour M, Rawa M, et al. A novel hybrid deep learning approach including combination of 1D power signals and 2D signal images for power quality disturbances classification[J]. Expert Systems with Applications, 2021, 174: 114785.
- [12] 奚鑫泽, 邢超, 覃日升, 等. 基于深度卷积去噪网络的电能质量扰动识别方法[J]. 南方电网技术, 2022, 16(12): 118-125.  
Xi Xinze, Xing Chao, Qin Risheng, et al. Power quality disturbances identification method based on deep convolutional denoising network [J]. Southern Power Grid Technology, 2022, 16(12): 118-125.
- [13] 赵耀, 陆佳煜, 李东东, 等. 基于机电信号融合的电机磁双凸极电机绕组匝间短路故障诊断[J]. 电工技术学报, 2023, 38(1): 204-219.  
Zhao Yao, Lu Jiayu, Li Dongdong, et al. Diagnosis of inter turn short circuit fault in doubly salient electric motor windings based on electromechanical signal fusion [J]. Journal of Electrical Engineering Technology, 2023, 38(1): 204-219.
- [14] 游颖敏, 王景芹, 舒亮, 等. 基于音频特征的交流接触器电寿命预测方法[J]. 电工技术学报, 2021, 36(9): 1986-1998.  
You Yingmin, Wang Jingqin, Shu Liang, et al. Method for predicting the electrical life of AC contactors based on audio features [J]. Journal of Electrical Technology, 2021, 36(9): 1986-1998.
- [15] 卢锦玲, 郭鲁豫. 基于改进深度残差收缩网络的电力系统暂态稳定评估[J]. 电工技术学报, 2021, 36(11): 2233-2244.  
Lu Jinling, Guo Luyu. Transient stability assessment of power systems based on improved deep residual contraction network [J]. Journal of Electrical Engineering, 2021, 36(11): 2233-2244.
- [16] 奚鑫泽, 邢超, 覃日升, 等. 基于多层特征融合注意力网络的电能质量扰动识别方法[J]. 智慧电力, 2022, 50(10): 37-44.  
Xi Xinze, Xing Chao, Qin Risheng, et al. Power quality disturbances recognition method based on multi-layer feature fusion attention network [J]. Smart Power, 2022, 50(10): 37-44.
- [17] 李赵春, 周永照, 冯卫奔, 等. 基于 Transformer 模型的手势脑电信号分类识别[J]. 科学技术与工程, 2023, 23(5): 2044-2050.  
Li Zhaochun, Zhou Yongzhao, Feng Weiben, et al. Classification and recognition of gesture EEG signals based on Transformer model [J]. Science Technology and Engineering, 2023, 23(5): 2044-2050.
- [18] Yang Z, Xu C, Li L. Landslide detection based on ResU-Net with Transformer and CBAM embedded; two examples with geologically different environments[J]. Remote Sensing, 2022, 14(12): 2885.
- [19] 杨一, 卢佩, 刘效勇, 等. 基于 CNN-Transformer 双流网络的伪脸检测[J]. 科学技术与工程, 2023, 23(19): 8288-8295.  
Yang Yi, Lu Pei, Liu Xiaoyong, et al. Fake face detection based on CNN-Transformer dual stream network [J]. Science Technology and Engineering, 2023, 23(19): 8288-8295.
- [20] 双丰, 黄兴文, 李勇, 等. 基于深度学习的大规模点云语义分割方法综述[J]. 测绘科学, 2023, 48(2): 195-209.  
Shuang Feng, Huang Xingwen, Li Yong, et al. Review of large-scale point cloud semantic segmentation methods based on deep learning [J]. Surveying and Mapping Science, 2023, 48(2): 195-209.
- [21] 邱宁佳, 王宪勇, 王鹏. 多头注意力评论量化的聚类优化推荐算法[J]. 计算机应用研究, 2021, 38(5): 1376-1380.  
Qiu Ningjia, Wang Xianyong, Wang Peng. Clustering optimization recommendation algorithm for quantifying multi head attention com-

- ments [J]. Computer Application Research, 2021, 38(5): 1376-1380.
- [22] 孙晶晶, 张艳艳, 高超, 等. 基于 DeblurGAN 的运动模糊图像盲复原算法研究[J]. 电子测量技术, 2022, 45(22): 112-119.  
Sun Jingjing, Zhang Yanyan, Gao Chao, et al. Research on blind restoration algorithm for motion blurred images based on DeblurGAN [J]. Electronic Measurement Technology, 2022, 45(22): 112-119.
- [23] 刘韵婷, 葛忠文, 郭辉. 基于 CA-ResNet50 的轮胎激光散斑图的分类研究[J]. 电子测量技术, 2023, 46(4): 169-174.  
Liu Yunting, Ge Zhongwen, Guo Hui. Classification of tire laser speckle pattern based on CA-ResNet50 [J]. Electronic Measurement Technology, 2023, 46(4): 169-174.
- [24] 刘烨, 程杉, 王瑞, 等. 基于小波降噪和深度学习的电能质量扰动分类方法[J]. 电力系统及其自动化学报, 2022, 34(11): 17-23.  
Liu Ye, Cheng Shan, Wang Rui, et al. Power quality disturbances classification method based on wavelet denoising and deep learning [J]. Journal of Power Systems and Automation, 2022, 34(11): 17-23.
- [25] Transmission and Distribution Committee of the IEEE Power & Energy Society. IEEE recommended practice for monitoring electric power quality: IEEE Std. 1159—2009[S]. New York: The Institute of Electrical and Electronics Engineers, Inc, 2009.
- [26] 李祖明, 吕干云, 陈诺, 等. 基于混沌集成决策树的电能质量复合扰动识别[J]. 电力系统保护与控制, 2021, 49(21): 18-27.  
Li Zuming, Lü Ganyun, Chen Nuo, et al. Identification of composite disturbances in power quality based on chaotic integrated decision tree [J]. Power System Protection and Control, 2021, 49(21): 18-27.
- [27] 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 of power quality disturbances based on convolution short-term memory network [J]. Power System Protection and Control, 2020, 48(2): 86-92.