

# 基于时序二维变换和多尺度Transformer的电能质量扰动分类方法

王守相<sup>1,2</sup>, 李慧强<sup>1,2</sup>, 赵倩宇<sup>1,2</sup>, 郭陆阳<sup>1,2</sup>, 王同勋<sup>3</sup>, 王洋<sup>3</sup>

(1. 智能电网教育部重点实验室(天津大学), 天津市 300072;

2. 天津市电力系统仿真控制重点实验室(天津大学), 天津市 300072; 3. 国网智能电网研究院有限公司, 北京市 102209)

**摘要:** 随着新能源渗透率的不断提高,电网面临的电能质量扰动(PQD)问题变得更加复杂,基于一维PQD信号的传统分类方法难以同时提取并辨识周期性与趋势性扰动。针对此问题,提出了一种基于时序二维变换和多尺度Transformer的PQD分类方法。首先,利用时序二维变换将一维PQD时间序列转换为基于多个周期的二维张量,以实现在二维空间中深入挖掘PQD信号中所包含的特征信息。然后,通过多尺度Transformer编码器模块提取PQD信号的多尺度特征图,利用多尺度Transformer解码器模块对多尺度特征图进行拼接和特征融合,有效合并在不同尺度上提取的特征图。最后,通过全连接层和Softmax分类器完成PQD分类任务。为验证所提方法的有效性,建立了含24种PQD的数据集对模型进行测试,结果表明所提方法对PQD信号具有较高的分类准确率和噪声鲁棒性。

**关键词:** 电能质量; 扰动分类; 时序二维变换; 多尺度Transformer; 特征提取; 特征融合

## 0 引言

在“双碳”目标引领下,中国正在加速构建以新能源为主体的新型电力系统<sup>[1-2]</sup>。而可再生能源的随机性与间歇性以及非线性负载的广泛接入使得电网的电能质量扰动(power quality disturbance, PQD)日益突出<sup>[3]</sup>。这将会严重影响电网的稳定性和可靠性,甚至造成严重的经济损失。因此,PQD信号的检测和分类对新型电力系统的电能质量治理和电力故障预防等工作具有重要意义<sup>[4]</sup>。

目前,PQD分类方法主要分为2个步骤:首先,对扰动信号进行特征提取;然后,根据提取的特征向量对扰动信号进行分类。在传统的分类方法中,首先,通过傅里叶变换(Fourier transform, FT)<sup>[5]</sup>、小波变换(wavelet transform, WT)<sup>[6]</sup>和S变换(S transform, ST)<sup>[7-8]</sup>等信号处理技术解析重要时频特征,利用人工经验确定特征值组,然后通过决策树、支持向量机、极限学习机等机器学习算法学习特征序列与标签间的映射关系,完成扰动分类任务。文献[9]通过小波变换提取PQD的多尺度特征,同时引入样本熵作为特征,然后利用支持向量机完成PQD分类,但其结果受小波基和分解层数的影

响较大。文献[10]通过S变换进行时频域分析,利用集成学习的混沌搜索优势,构建混沌集成决策树进行PQD分类,其中,S变换具有良好的时频特性提取能力,但是其对信号奇异点的检测不敏感,且计算量较大。此外,传统的PQD分类方法依赖于人工经验确定特征值组,这些特征通常比较单一且含有大量冗余信息,影响分类结果的准确性。

相较于传统的分类方法,基于深度学习的分类方法克服了传统方法依赖人工经验的局限,为自适应提取并学习PQD特征提供了新思路。常用的深度学习方法有卷积神经网络(convolutional neural network, CNN)<sup>[11]</sup>和长短期记忆(long short-term memory, LSTM)网络<sup>[12]</sup>等。例如,文献[13]通过经验模态分解(empirical mode decomposition, EMD)对原始PQD信号进行分解,利用一维CNN进行特征提取和分类。文献[14]以并行的方式结合CNN和LSTM,同时提取信号时频特征,以提升分类精度。文献[15]利用Stockwell变换将PQD信号转换为二维时频域轮廓图,结合CNN完成扰动信号的识别和分类。文献[16]采用格拉姆角场将PQD映射为二维图像,利用CNN提取图像特征并完成分类任务。上述方法取得不错的分类效果,但仍存在时间窗长度有限、转化图像过程特征损失过多等问题。PQD信号具有明显的周期性与趋势性,既包含周期内部的高频扰动,也包含周期期间的低频趋势性扰动,

收稿日期: 2024-04-12; 修回日期: 2024-10-30。

上网日期: 2024-12-16。

国家重点研发计划资助项目(2023YFB2407500)。

已有 PQD 特征提取与分类辨识方法由于时间窗长度的限制,难以同时提取并识别周期内高频扰动与周期间低频趋势性扰动。

为解决已有 PQD 特征提取与分类辨识方法难以同时提取并辨识周期性趋势性扰动问题,本文从时间序列的多周期性和模型的结构与参数优化 2 个角度进行考虑,提出了一种基于时序二维变换和多尺度 Transformer 的 PQD 分类方法。首先,对一维 PQD 时间序列进行时序二维变换,将一维时间序列重塑为二维张量,使周期内和周期间的变化分别映射到二维张量的列和行,将时序分析扩展到二维空间中,深入挖掘 PQD 时间序列中所包含的特征信息。然后,利用多尺度 Transformer 编码器提取 PQD 信号的多尺度特征图,利用多尺度 Transformer 解码器对多尺度特征图进行特征融合,有效合并在不同尺度上提取的特征图。最后,通过全连接层和 Softmax 分类器完成 PQD 分类任务。为验证所提方法的有效性,通过仿真实验进行模型测试,并加入其他深度学习模型作为实验对比。

## 1 基于时序二维变换和多尺度 Transformer 的 PQD 分类模型

本文提出一种基于时序二维变换和多尺度

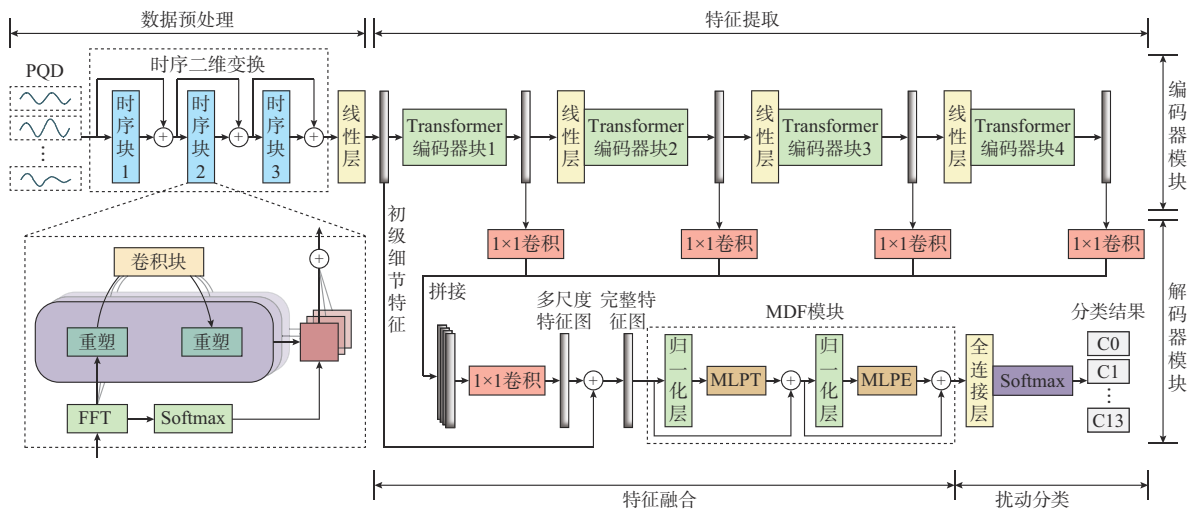


图 1 基于时序二维变换和多尺度 Transformer 的 PQD 分类模型结构

Fig. 1 Structure of PQD classification model based on time series two-dimensional transformation and multi-scale Transformer

## 2 基于时序二维变换的 PQD 数据预处理

一维 PQD 时间序列中,每个时间点不仅与其附近时间点相关,还与不同时间段内具有相同相位的时间点相关,即周期内变化和周期间变化。标准的一维时间序列结构只能呈现相邻时间点之间的变化,无法反映周期间的变化。本文利用时序二维变

换模块将一维 PQD 时间序列转化为一组基于多个周期的二维张量,其整体结构如图 1 所示。

Transformer 的 PQD 分类模型,其整体结构如图 1 所示。本模型通过时序二维变换模块<sup>[17]</sup>,将一维 PQD 时间序列转化为一组基于多个周期的二维张量,这一转换过程可以将 PQD 信号中的周期内变化和周期间变化分别映射到二维张量的列和行,实现了将时序分析从一维空间拓展到二维空间,利用二维卷积核深入挖掘 PQD 信号中所包含的特征信息。

然后,将所得结果输入到多尺度 Transformer 模块<sup>[18-19]</sup>完成 PQD 分类任务。该模块采用编码器-解码器结构。在编码器部分,本文利用多个单层 Transformer 编码器块作为多尺度特征提取模块,这种分层设计继承了 Transformer 模型的自注意力机制<sup>[20]</sup>,使模型能够更好地捕捉数据的内部相关性,同时可以有效提取 PQD 信号的多尺度特征图。在解码器部分,模型将多尺度 Transformer 编码器提取的多尺度特征图合并,并通过残差结构将其与初级细节特征结合起来形成完整的特征图,将最终特征图输入到多维度特征融合模块(MDF 模块),对特征图进行加权融合,增强关键信息,减少不相关细节干扰。最后,通过全连接层和 Softmax 分类器完成 PQD 分类任务。

换模块将一维 PQD 时间序列转化为一组基于多个周期的二维张量,将 PQD 信号中的周期内变化和周期间变化分别映射到二维张量的列和行,通过二维卷积核同时捕获二维空间中的周期内和周期间变化,充分挖掘 PQD 信号中所包含的特征信息。本文所提时序二维变换的基本原理如图 2 所示。




图2 时序二维变换基本原理

Fig. 2 Basic principle of time series two-dimensional transformation

首先,对输入时间序列进行快速傅里叶变换(fast Fourier transform, FFT),将其从时域转换到频域,展示 PQD 信号各个频率成分的强度。其中,FFT 的结果包含每个频率成分的振幅信息,振幅在频率分析中反映该频率成分的强度,振幅越大,则该频率在时间序列的构成中更为显著。接着,计算所有频率的振幅均值,选择振幅最大的前  $k$  个频率,作为时间序列中最重要的周期成分。

针对  $k$  的选择,本文首先通过分析不同类型扰动信号的频域能量分布,选取能够涵盖大部分扰动能量的  $k$  值范围。然后,通过实验和交叉验证,对不同  $k$  值进行测试和评估,最终确定一个能够在各类 PQD 信号上均能实现较高识别准确率的  $k$  值,提升模型的泛化能力。通过这种基于频率的分析方法,模型不仅能够识别出时间序列中的显著周期,还可以根据这些周期将时间序列重构为二维张量,更有效地捕捉时间序列中的周期内和周期间变化。

PQD 数据时序二维变换流程图如附录 A 图 A1 所示。输入的一维 PQD 时间序列  $X_{1D} \in \mathbb{R}_{T \times C}$  中,  $T$  代表一维时间序列长度,  $C$  代表一维时间序列变量的个数。为表示 PQD 信号周期期间的变化,首先通过 FFT 将  $X_{1D}$  转换到频域,计算过程如下:

$$A = \text{Avg}(\text{Amp}(\text{FFT}(X_{1D}))) \quad (1)$$

$$f_i = \arg \text{Topk}(A) \quad i \in \{1, 2, \dots, k\} \quad (2)$$

$$L_i = \frac{T}{f_i} \quad i \in \{1, 2, \dots, k\} \quad (3)$$

式中:  $\text{FFT}(\cdot)$  为 FFT 计算函数;  $\text{Amp}(\cdot)$  为幅度值计算函数;  $\text{Avg}(\cdot)$  为平均值计算函数;  $A$  为向量,代表输入时间序列  $X_{1D}$  通过 FFT 后每个频率所对应幅度的均值;  $\arg \text{Topk}(A)$  表示在向量  $A$  中求出前  $k$  个最大的振幅值所对应的频率分量  $f_i$ , 其中,通过实验和交叉验证来选择使模型性能最优的  $k$  值;  $L_i$  为频率分量  $f_i$  所对应的周期长度。

然后,如图 2 所示,基于选定的周期对原始的一

维时间序列  $X_{1D}$  进行折叠拼接,得到一组大小为  $f_i \times L_i$  的二维张量  $\{X_{2D,1}, X_{2D,2}, \dots, X_{2D,k}\}$ ,  $X_{2D,i}$  对应着由频率分量  $f_i$  主导的二维时序变化,该二维张量的每列与每行分别对应着相邻的时刻与相邻的周期,即周期内变化和周期间变化。其中,  $X_{2D,i}$  计算过程如下:

$$X_{2D,i} = \text{Reshape}_{2, f_i \times L_i}(\text{Padding}(X_{1D})) \quad i \in \{1, 2, \dots, k\} \quad (4)$$

式中:  $\text{Reshape}_{2, f_i \times L_i}(\cdot)$  为重塑函数,表示将一维 PQD 时间序列转换为二维张量;  $\text{Padding}(\cdot)$  为填充函数,表示在输入一维时间序列  $X_{1D}$  末尾补 0,使序列长度可以被周期长度  $L_i$  整除。

接着,  $X_{2D,i}$  通过二维卷积块进行学习处理,得到  $k$  个二维张量  $\hat{X}_{2D,i}$ , 卷积块通过将大小不同的二维卷积核叠加在一起,同时捕获时序数据的周期内和周期间变化,  $\hat{X}_{2D,i}$  计算过程如下:

$$\hat{X}_{2D,i} = \text{Inception}(X_{2D,i}) \quad i \in \{1, 2, \dots, k\} \quad (5)$$

式中:  $\text{Inception}(\cdot)$  为卷积块,捕获时序数据的周期内和周期间变化。

然后,将  $\hat{X}_{2D,i}$  重塑为一维张量  $\hat{X}_{1D,i}$ , 计算过程如下:

$$\hat{X}_{1D,i} = \text{Trunc}(\text{Reshape}_{1, f_i \times L_i}(\hat{X}_{2D,i})) \quad i \in \{1, 2, \dots, k\} \quad (6)$$

式中:  $\text{Reshape}_{1, f_i \times L_i}(\cdot)$  为重塑函数,表示将二维张量转换为一维张量;  $\text{Trunc}(\cdot)$  表示将式 (4) 中  $\text{Padding}(\cdot)$  操作补充的 0 去除。

计算一维张量  $\hat{X}_{1D,i}$  对应频率分量  $f_i$  的权重  $\hat{A}_i$ , 计算过程如下:

$$\hat{A}_i = \text{Softmax}(A_{f_i}) \quad i \in \{1, 2, \dots, k\} \quad (7)$$

式中:  $\text{Softmax}(\cdot)$  为归一化指数函数;  $A_{f_i}$  为  $\hat{X}_{1D,i}$  对应频率分量  $f_i$  的幅值。



最后,将 $\hat{X}_{ID,i}$ 按其对应频率分量 $f_i$ 的强度进行自适应聚合,得到最终输出 $\hat{X}_{ID}$ ,计算过程如下:

$$\hat{X}_{ID} = \sum_{i=1}^k \hat{A}_{f_i} \times \hat{X}_{ID,i} \quad (8)$$

### 3 基于多尺度 Transformer 的 PQD 分类识别

#### 3.1 多尺度 Transformer 编码器特征提取

一维 PQD 时间序列首先经过时序二维变换处理,随后通过一个线性层调整特征维度,得到形状为 $B \times T \times E$ 的张量 $S$ (其中, $B$ 为批次数量, $E$ 为特征维度)。然后,此张量被输入多尺度 Transformer 的编码器模块,该多尺度 Transformer 编码器模块包含线性层与 4 个单层 Transformer 编码器块,用于提取 PQD 信号在多个尺度上的特征图。

附录 A 图 A2 为 Transformer 编码器块,每个编码器块均由位置编码层、多头注意力层、Add&LayerNorm 层和前馈网络层组成。其中,Add 为残差链接,LayerNorm 为归一化层。输入矩阵 $S$ 经位置编码转换为矩阵 $S_1$ ,然后分别定义查询矩阵 $Q$ 、关键矩阵 $K$ 和数值矩阵 $V$ ,它们分别是 $S_1$ 与查询权重矩阵 $W_Q$ 、键权重矩阵 $W_K$ 、值权重矩阵 $W_V$ 相乘得到的隐状态矩阵,具体计算公式如下:

$$\begin{cases} S_1 \times W_Q = Q \\ S_1 \times W_K = K \\ S_1 \times W_V = V \end{cases} \quad (9)$$

式(9)是对同一个输入矩阵 $S_1$ 进行 3 次不同的线性变换来表示其 3 种不同的状态。计算得到矩阵 $Q$ 、 $K$ 、 $V$ 之后,进一步计算得到其缩放点积注意力:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (10)$$

式中:Attention( $\cdot$ )为缩放点积注意力函数; $K^T$ 为矩阵 $K$ 的转置; $d_k$ 为矩阵 $Q$ 、 $K$ 的列数,即向量维度。

对于输入矩阵 $Q$ 、 $K$ 、 $V$ ,本文应用多头注意力以获得 $Q_a$ 、 $K_a$ 、 $V_a$ , $a \in \{1, 2, \dots, h\}$ ,其中, $h$ 为多头注意力头数,具体公式如下:

$$\text{MultiHeadAtt}(Q, K, V) = \text{Concat}(H_a) \quad (11)$$

式中:MultiHeadAtt( $\cdot$ )为多头注意力函数;Concat( $\cdot$ )为拼接注意力矩阵函数; $H_a = \text{Attention}(Q_a, K_a, V_a)$ 。

LayerNorm 层计算公式如下:

$$\begin{cases} S_{1,1} = \text{LayerNorm}(S_1 + \text{MultiHeadAtt}(S_1)) \\ S_{1,2} = \text{LayerNorm}(S_{1,1} + \text{FeedForward}(S_{1,1})) \end{cases} \quad (12)$$

式中: $S_1 + \text{MultiHeadAtt}(S_1)$ 表示将多头注意力层的输出与其对应输入进行相加;FeedForward( $\cdot$ )为前馈网络层函数, $S_{1,1} + \text{FeedForward}(S_{1,1})$ 表示将前馈网络层的输出与其对应输入进行相加;LayerNorm( $\cdot$ )为归一化层函数,将每层的输入标准化,使其具有相同的均值和方差,加快模型收敛。

前馈网络层由 2 个全连接层构成。第 1 层使用 ReLU 作为激活函数,而第 2 层则不采用任何激活函数。最终,前馈网络层输出的矩阵维度与输入矩阵 $S_{1,1}$ 保持一致。对应的公式如下:

$$\max(0, S_{1,1}W_1 + b_1)W_2 + b_2 \quad (13)$$

式中: $W_1$ 和 $b_1$ 分别为第 1 层的权重矩阵和偏置向量; $W_2$ 和 $b_2$ 分别为第 2 层的权重矩阵和偏置向量。

通过上面描述的位置编码层、多头注意力层,Add&LayerNorm 层和前馈网络层就可以构成一个 Transformer 编码器块,将 4 个 Transformer 编码器块叠加就形成了本文所提多尺度 Transformer 编码器。

#### 3.2 多尺度 Transformer 解码器特征融合

多尺度 Transformer 的解码器模块<sup>[18]</sup>用于融合编码器模块输出的多尺度特征图。如图 1 所示,首先,为了引入 PQD 信号的初级细节特征,输入的 PQD 信号经过时序二维变换和线性层处理,直接提取 PQD 信号的初级细节特征 $t_p \in \mathbb{R}_{B \times T \times E}$ ;然后,将初级细节特征 $t_p$ 输入多尺度 Transformer 编码器,提取不同尺度的特征图 $t_i$ ;  $t_i$ 通过 $1 \times 1$ 卷积处理,将其特征维度 $E_i$ 映射到统一的特征维度 $E$ ,再沿特征维度拼接获得多尺度特征图 $t_m \in \mathbb{R}_{B \times T \times 4 \times E}$ 。其次,通过 $1 \times 1$ 卷积将多尺度特征图 $t_m$ 的特征维度减少到原来的 $1/4$ ,得到与初级细节特征对齐的多尺度特征图 $t_{m1} \in \mathbb{R}_{B \times T \times E}$ 。最后,通过残差结构将初级细节特征 $t_p$ 与多尺度特征图 $t_{m1}$ 拼接起来,得到完整的特征图 $t_c \in \mathbb{R}_{B \times T \times E}$ 。

多尺度 Transformer 解码器中的 MDF 模块对完整特征图 $t_c$ 进行特征融合,MDF 模块由归一化层、MLP 块组成。其中,MLP 块由 2 个不同的多层感知机 MLPT 和 MLPE 组成。MLPT 和 MLPE 只专注于需要融合的维度,对这一维度上的特征进行融合和处理,而保持其他维度不变,每个维度的信息都被单独处理。通过 2 个不同多层感知机堆叠,可以使模型在其他维度上共享参数,信息可以在整个特征图上流动。其中,MLP 块包含线性层、ReLU 激活函数和正则化层。在多尺度 Transformer 解码器中,MDF 模块的具体计算过程如下:

$$\text{MLP}(X) = \text{Dropout}(\text{ReLU}(\text{Linear}(X))) \quad (14)$$

$$h_1 = t_c + \text{MLP}_T(\text{LayerNorm}(t_c)) \quad (15)$$

$$h_2 = h_1 + \text{MLP}_E(\text{LayerNorm}(h_1)) \quad (16)$$

式中： $X$ 为变量； $\text{Linear}(\cdot)$ 为线性层函数； $\text{Dropout}(\cdot)$ 为正则化层函数，防止模型过拟合； $\text{MLP}_T(\cdot)$ 和 $\text{MLP}_E(\cdot)$ 分别表示沿时间维度 $T$ 和特征维度 $E$ 对完整特征图进行加权融合。

最后，通过全连接层将加权融合后的特征图的特征维度转换为初始输入PQD信号的类别数，利用Softmax分类器完成PQD分类任务。

## 4 算例分析

### 4.1 实验准备及数据获取

本文根据IEEE Std. 1159—2019标准<sup>[21]</sup>，在MATLAB环境下仿真生成PQD信号，包含正常电压信号、单重扰动、双重扰动和三重扰动共计24种PQD信号。这些多重扰动类型常见于复杂电力系统中，是目前领域内关注的热点<sup>[15]</sup>。其中，双重扰动是指同一信号中出现2种不同的单重PQD，这种组合在复杂电力系统中较为普遍。实验中，本文通过叠加单一扰动信号生成双重扰动，同时确保每个扰动均符合IEEE标准的波形特征，真实地反映实际电网中的复杂扰动情况。三重扰动则是在双重扰动的基础上增加第3种扰动，模拟更为复杂的电力故障，通常由电力设备故障或多个负载切换引起。通过合理组合3个独立PQD信号，确保合成信号中各扰动的比例合理，以更准确地模拟实际场景的复杂性。具体PQD信号及其对应标签情况如附录A表A1所示，部分PQD信号波形图如附录A图A3所示。

文中生成信号的基波频率为50 Hz，采样频率为12.8 kHz，每种扰动类型均在10个工频周期内进行采样。为生成一个全面的PQD数据集，本文针对每种扰动类型生成了500个随机样本，共计12 000个样本。在构建的数据集中，共有8 400个随机选取的样本被用于训练分类模型，而剩余的3 600个样本用于测试模型的性能。此外，本文在模型训练过程中采用小批量随机训练方法，其中，每个批次包含64个样本。整个训练过程持续50轮。

文中所提模型的训练和测试采用Python 3.8和Pytorch 1.7.1的深度学习框架，CPU处理器为AMD Ryzen Threadripper 3970 X；GPU为NVIDIA GeForce RTX 3090；RAM为DDR4 64 GB；HDD为SSD 1 024 GB。

### 4.2 实验参数设置与评价指标

本文所提模型的主要参数设置如附录A表A2所示。在PQD识别分类过程中，本文采用交叉熵损

失函数作为所提模型的训练目标函数，模型使用Adam优化器，通过反向传播和Adam优化算法来更新模型参数，设置优化参数的范围为 $[0.01, 100]$ 。目标函数公式如下：

$$\text{Loss}(y, \hat{y}) = -\frac{1}{N} \sum_{r=1}^N \sum_{j=1}^K y_{r,j} \log(\hat{y}_{r,j}) \quad (17)$$

式中： $y$ 为真实值； $\hat{y}$ 为预测值； $\text{Loss}(y, \hat{y})$ 表示真实值和预测值之间的损失； $N$ 为样本数量； $K$ 为PQD类别数量； $y_{r,j}$ 为样本 $r$ 属于类别 $j$ 的真实标签（1表示属于，0表示不属于）； $\hat{y}_{r,j}$ 为模型预测样本 $r$ 属于类别 $j$ 的概率。

本文实验评价指标采用准确率指标 $R_{\text{Acc}}$ 、精度指标 $R_{\text{Pre}}$ 、召回率指标 $R_{\text{Rec}}$ 和F1分数指标 $R_{\text{F1}}$ 作为性能评估指标。具体定义如下：

$$R_{\text{Acc}} = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (18)$$

$$R_{\text{Pre}} = \frac{T_P}{T_P + F_P} \quad (19)$$

$$R_{\text{Rec}} = \frac{T_P}{T_P + F_N} \quad (20)$$

$$R_{\text{F1}} = \frac{2R_{\text{Pre}}R_{\text{Rec}}}{R_{\text{Pre}} + R_{\text{Rec}}} \quad (21)$$

式中： $T_P$ 为真实值和预测值都是1的个数； $T_N$ 为真实值和预测值都是0的个数； $F_P$ 为真实值为0和预测值为1的个数； $F_N$ 为真实值为1和预测值为0的个数。

### 4.3.1 实验结果分析

为了更加清晰地展示本文所提时序二维变换和多尺度Transformer的有效性，本节通过消融实验来评估模型在训练过程中的表现。在实验中，本文以控制变量的方式设置了5种对比模型：时序二维变换+多尺度Transformer(TST+MT)、WT+多尺度Transformer(WT+MT)、时序二维变换+CNN(TST+CNN)、时序二维变换+传统Transformer(TST+Trans)、多尺度Transformer(MT)。其中，为保证实验的公平性，所有模型在设置和超参数方面保持一致，在测试过程中，记录各模型在测试集上的准确率和损失值，并将这些数据在图3中以双坐标轴的形式呈现。

由图3可以看出，本文提出的基于时序二维变换和多尺度Transformer的PQD分类模型表现出快速的收敛速度以及优于其他模型的准确率和损失值。通过对比时序二维变换+多尺度Transformer、WT+多尺度Transformer和多尺度Transformer模型的测试结果曲线，时序二维变换模块对原始PQD




图3 各分类模型测试过程

Fig. 3 Testing process of each classification model

时间序列进行时序二维变换,并通过二维卷积核提取信号特征,可以加强时间序列表示能力,提高 PQD 分类的准确率,其效果也超过了传统的 WT 方法。进一步地,对时序二维变换+多尺度 Transformer、时序二维变换+CNN、时序二维变换+传统 Transformer 的测试结果比较表明,一维 PQD 时间序列经过时序二维变换模块处理后,通过多尺度 Transformer 进行多尺度特征提取与特征融合,能够有效提高 PQD 分类准确率,在效果上也优于传统的 Transformer 模型与 CNN 模型。

此外,本文还将所提模型的准确率、参数量与识别效率与其他模型进行了比较,结果如表 1 所示。

表 1 不同分类模型性能比较  
Table 1 Performance comparison of various classification models

模型	准确率/%	参数量/MB	总轮数	平均每轮训练时间/s	平均每个测试时间/ms
TST+MT	98.82	22.24	24	265.73	23.13
WT+MT	94.01	21.55	43	283.81	32.38
TST+CNN	94.85	41.47	40	386.64	78.91
TST+Trans	96.02	32.69	32	413.15	89.81
MT	93.63	19.55	46	235.96	18.58

根据表 1 所示的数据,本文所提模型的 PQD 分类准确率最高,达到 98.82%。所提模型对原始 PQD 数据进行了时序二维变换,准确率比直接对原始 PQD 数据应用多尺度 Transformer 提高了 5.19%,参数量增加了 2.69 MB。同时,在对数据进行时序二维变换的前提下,多尺度 Transformer 的效果也优于 CNN 和传统 Transformer。此外,所提模型收敛速度最快,在所用数据集上仅训练 24 轮就基本收敛到最佳参数配置,平均每轮训练时间为

265.73 s,平均每个测试时间为 23.13 ms,展示了较高的 PQD 分类效率。

#### 4.3.2 噪声鲁棒性测试

为评估所提模型在 PQD 分类任务中的噪声鲁棒性,本文在不同噪声水平环境下进行了实验。具体考虑了信噪比(signal to noise ratio, SNR)为 50、30、20 的噪声环境以及理想的无噪声环境。实验中,将本文所提方法与其他文献中针对噪声环境下的 PQD 识别方法进行对比,包括:CTranCBA<sup>[22]</sup>、ST-CNN<sup>[15]</sup>和 ResNet-BLSTM<sup>[23]</sup>。其中,CTranCBA 通过 CNN 提取 PQD 信号的局部特征,利用 Transformer 的自注意力机制捕捉信号的长距离依赖关系,进而完成分类任务;ST-CNN 使用 Stockwell 变换提取信号特征,然后将特征输入 CNN 进行训练和分类;ResNet-BLSTM 利用 ResNet 进行深层特征提取,利用双向 LSTM 网络建立时序特征依赖关系,完成分类任务。为确保实验结果的稳定性和可靠性,每个模型在各种噪声环境下都进行了多次测试。

为全面评估各个模型在 PQD 分类任务中的性能,本文选择了准确率、精度、召回率及 F1 分数 4 个关键评价指标。所有模型的实验结果如表 2 所示。

根据表 2 所示的数据,在无噪声环境和 SNR 为 50 dB 时,4 个模型均表现出较高的准确率和可靠性,且本文所提模型在各项指标上均优于其他模型,体现了其最佳的整体性能。随着噪声水平的增加,所提模型依旧能够保持良好的性能,特别是在 SNR 为 20 dB 时,所提模型的准确率达到 97.12%,比准确率第 2 高的 ResNet-BLSTM 高出 2.91%,相比之下,CTranCBA 模型和 ST-CNN 模型随着噪声水平的增加,性能下降较为明显。尤其是在 SNR 为 20 dB 时,准确率比所提模型低 3.5% 左右。

虽然本文模型的参数量略高于 CTranCBA、ST-CNN 和 ResNet-BLSTM 模型,但所提模型在噪声环境中的分类准确率和鲁棒性表现更为出色。由此可见,时序二维变换可以将时序分析扩展到二维空间,以便更充分地挖掘 PQD 数据特征,多尺度 Transformer 可以有效地提取和融合特征信息,使模型具有较好的分类准确率与噪声鲁棒性。

为进一步评估和比较各模型在不同噪声条件下的性能差异,本文采用箱线图的形式直观地展示各模型在不同噪声条件下的 F1 分数分布,如图 4 所示。图中:蓝色块表示的是 F1 分数的具体分布情况。

由图 4 可以看出,本文所提模型在各种噪声水平条件下均表现出最高的 F1 分数中位数,且分布箱



表 2 不同噪声环境下不同模型的分类效果评估  
Table 2 Classification effect evaluation of various models in different noise environments

噪声环境	模型	参数量/MB	准确率/%	精度/%	召回率/%	F1分数/%
SNR为50 dB	TST+MT	21.24	98.66	98.67	98.71	98.69
	CTranCBA	18.72	97.01	97.91	97.93	97.92
	ST-CNN	17.67	96.16	96.79	96.85	96.82
	ResNet-BLSTM	19.93	97.61	98.14	98.22	98.18
SNR为30 dB	TST+MT	21.24	97.95	98.33	98.35	98.34
	CTranCBA	18.72	95.86	96.61	96.64	96.62
	ST-CNN	17.67	94.92	95.81	95.85	95.83
	ResNet-BLSTM	19.93	96.56	97.15	97.21	97.18
SNR为20 dB	TST+MT	21.24	97.12	97.23	97.25	97.24
	CTranCBA	18.72	93.64	93.83	93.87	93.85
	ST-CNN	17.67	92.76	93.53	93.58	93.55
	ResNet-BLSTM	19.93	94.21	94.81	94.89	94.85
无噪声	TST+MT	21.24	98.89	98.94	98.96	98.95
	CTranCBA	18.72	97.51	98.14	98.18	98.16
	ST-CNN	17.67	96.89	97.51	97.57	97.54
	ResNet-BLSTM	19.93	97.95	98.25	98.31	98.28

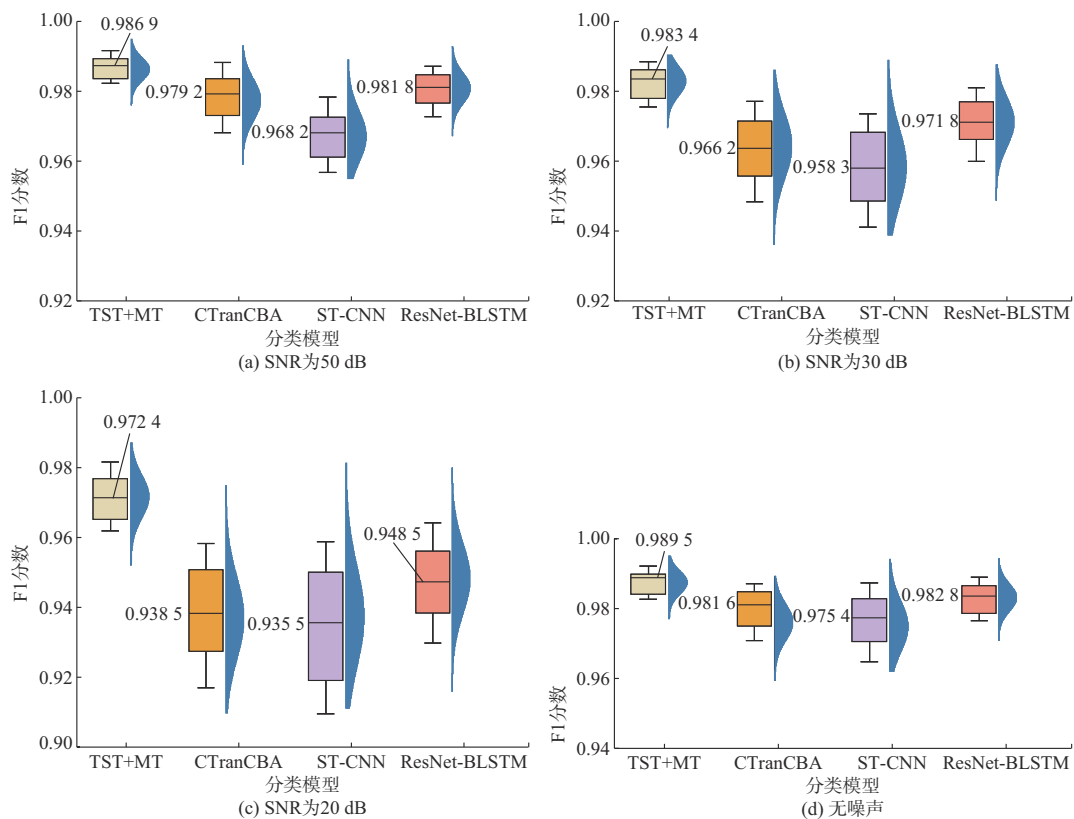


图 4 不同噪声环境下不同模型 F1 分数箱线图  
Fig. 4 Box plots of F1-scores of various models in different noise environments

体较为紧凑,表明该模型具有较好的稳定性和鲁棒性。在 SNR 为 20 dB 时,所提模型的 F1 分数中位数为 97.24%,高于其他 3 个模型。其中,ResNet-BLSTM 模型的 F1 分数中位数为 94.85%,低于所

提模型 2.39%。CTranCBA 模型和 ST-CNN 模型的 F1 分数中位数分别为 93.85% 和 93.55%,分别比所提模型低 3.39% 和 3.69%,且分布箱体较为松散,在高噪声环境下性能波动较大,鲁棒性较弱。

进一步地,本文所提分类模型在不同 PQD 识别任务中的误分类情况可以通过混淆矩阵查看。以 20 dB 噪声条件为例,所提模型分类结果的混淆矩阵如附录 A 图 A4 所示。由图可以看出,所提模型对大多数 PQD 类别有着良好的分类能力,对角线上的数值明显高于其他位置,PQD 信号主要类别被正确分类。然而,也存在一些异常,尤其是在标签 C22 与 C23 的分类精度方面,分别为 87.15% 与 87.83%;以及标签 C14 和 C15 的召回率,分别为 91.96% 和 91.43%,有少部分 PQD 信号存在误分类现象。进一步分析这 4 类标签的特点可知,模型在高噪声水平条件下,有时会将噪声信号错误地识别为谐波,对分类判断产生干扰。尽管如此,所提模型的整体准确率还是在 97.12%,验证了其在抵御噪声干扰的同时,仍能有效地对 PQD 信号进行准确分类的能力。

此外,考虑到实际电网的基波信号在频率、幅值和相位上会在允许范围内正常波动,为评估这些波动对所提方法的影响,根据文献[24-25],设置基波频率的波动范围为 $(-0.2, 0.2)$ Hz、幅值的波动范围为 $(-20, 20)$ V 以及相位的波动范围为 $(-3^\circ, 3^\circ)$ ,同时,考虑 SNR 为 50、30、20 dB 的噪声环境以及理想的无噪声环境,在这些条件下生成基波正常波动时的 PQD 数据,利用这些数据评估基波信号波动条件下所提模型在不同噪声环境中的分类性能。具体分类结果如附录 A 表 A3 所示。根据表中的数据,在基波信号波动条件下,相较于表 2 中将电网基波电压视为完全恒定不变的正弦函数,所提 PQD 识别方法在各种噪声环境下的识别准确率变化均在 0~1% 以内,表明所提方法在基波信号波动情况下仍然具有较高的分类准确率和噪声鲁棒性。

#### 4.3.3 实测数据验证

为了验证本文方法对实测信号的适用性,本文选用 IEEE PES 数据库中的 PQD 实测数据对所提模型的性能进行测试。所选信号的长度为 1 536 个采样点,采样率为每周周期 256 个点。然而,IEEE PES 数据库中的实测 PQD 数据量有限,仅包含单重扰动信号和少量双重扰动信号,难以满足模型训练和测试对多样性的需求。为此,本文通过将实测的单一扰动信号在同一时间序列上进行加权叠加,生成了双重和三重扰动信号,丰富扰动类型。此外,本文还采用信号镜像、高斯噪声添加、时间轴变换等数据增强方法,以进一步增加训练数据量。

对实测 PQD 数据集进行数据增强后得到增强型实测数据集,其中,扰动类型为 22 种,训练集和测试集的样本数量分别为 5 040 和 2 160。使用增强型实测数据集对本文所提模型和 4.3.2 节中的

CTranCBA、ST-CNN 和 ResNet-BLSTM 模型进行训练和测试,测试结果如附录 A 表 A4 所示。根据表中的数据,本文所提模型在增强型实测数据集上的平均分类准确率为 96.61%,高于其他 3 种对比模型,但低于在仿真数据上的结果。其主要原因是在 MATLAB 环境下仿真生成的 PQD 信号与实测数据之间可能存在一定差异,尽管仿真信号是基于一定的物理模型生成,但它们难以全面模拟实际系统中负载波动、设备老化、线路阻抗变化等复杂情况,由于实测数据集更为复杂,模型分类准确率有所下降。

此外,深度学习方法易受训练集数据质量问题的影响。为验证所提模型在数据质量较差、存在数据缺失和错误数据情况下的性能,本文通过随机删除数据、修改部分值和添加随机噪声等方法,降低增强型实测数据集的数据质量,生成劣化实测数据集,以进一步模拟现实中可能遇到的数据问题,并利用劣化实测数据集对本文所提模型以及 4.3.2 节中的 CTranCBA、ST-CNN 和 ResNet-BLSTM 模型的性能进行训练和测试。测试结果如附录 A 表 A5 所示。根据表中的数据,劣化实测数据集中增加了噪声和不确定性,降低了模型从数据中提取有效特征的能力,导致所有模型分类准确率均有所下降。然而,所提模型依然保持了最高的平均分类准确率,达到 96.11%。尽管数据集质量有所下降,但所提模型在处理复杂和不完整数据时,仍展现出较强的鲁棒性和分类能力。

## 5 结语

为进一步提高 PQD 分类能力,本文提出了一种基于时序二维变换和多尺度 Transformer 的 PQD 分类方法。结果表明,与现有的信号处理技术相比,所提时序二维变换信号处理技术通过将一维 PQD 信号重塑为二维张量,将 PQD 信号中的周期内变化和周期间变化分别映射到二维张量的列和行,不仅保留了信号周期内部的高频扰动特征,而且还强化了信号周期间的低频趋势性扰动特征,将时序分析扩展到二维空间中,极大地丰富了信号的特征表达能力。

此外,本文方法采用的多尺度 Transformer 结构展现出良好的特征提取和特征融合能力。它不仅能有效提取 PQD 信号的多尺度特征信息,还能对所提取特征进行高效的融合,充分挖掘 PQD 信号所包含的特征信息。与现有 PQD 分类方法相比,本文所提方法在 PQD 分类任务中取得了更好的表现,特别是在高噪声环境下。

所提方法的主要局限性在于当噪声水平较高



时,模型有将噪声信号误认为谐波的倾向,导致少数误分类的情况。因此,尽管所提方法已证明其有效性,但在高噪声条件下,保持模型的分类精度和鲁棒性仍需进一步研究和优化,以更好地应对高噪声环境中的扰动信号分类问题。

同时,在后续研究中也将会进一步研究网络结构的优化方法,包括用其他时频变换或信号分解技术替换时序二维变换中的FFT模块,并对多尺度Transformer架构进行简化,以实现更高识别准确率、更轻量化的PQD识别,进一步提升模型的应用效率。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

### 参 考 文 献

- [1] 张勇军,羿应棋,李立涅,等.双碳目标驱动的新型低压配电系统技术展望[J].电力系统自动化,2022,46(22):1-12.  
ZHANG Yongjun, YI Yingqi, LI Licheng, et al. Prospect of new low-voltage distribution system technology driven by carbon emission peak and carbon neutrality targets [J]. Automation of Electric Power Systems, 2022, 46(22): 1-12.
- [2] 胡博,谢开贵,邵常政,等.双碳目标下新型电力系统风险评述:特征、指标及评估方法[J].电力系统自动化,2023,47(5):1-15.  
HU Bo, XIE Kaigui, SHAO Changzheng, et al. Commentary on risk of new power system under goals of carbon emission peak and carbon neutrality: characteristics, indices and assessment methods [J]. Automation of Electric Power Systems, 2023, 47(5): 1-15.
- [3] 何晋伟,孟维奇,蒋玮,等.新能源配电网电能质量典型问题分析及应对策略[J].高电压技术,2023,49(7):2983-2994.  
HE Jinwei, MENG Weiqi, JIANG Wei, et al. Power quality problems in renewable energy power distribution systems: analysis and solutions [J]. High Voltage Engineering, 2023, 49(7): 2983-2994.
- [4] MAHELA O P, KHAN B, ALHELOU H H, et al. Power quality assessment and event detection in distribution network with wind energy penetration using stockwell transform and fuzzy clustering [J]. IEEE Transactions on Industrial Informatics, 2020, 16(11): 6922-6932.
- [5] ANGRIAWAN D O, WAHJONO E, SUDIHARTO I, et al. Identification of short duration voltage variations based on short time Fourier transform and artificial neural network [C]// 2020 International Electronics Symposium (IES), September 29-30, 2020, Surabaya, Indonesia: 43-47.
- [6] HONG W H, LIU Z W, WU X Y. Power quality disturbance recognition based on wavelet transform and convolutional neural network [C]// 2021 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA), June 28-30, 2021, Dalian, China: 193-197.
- [7] LIANG C B, TENG Z S, LI J M, et al. A Kaiser window-based S-transform for time-frequency analysis of power quality signals [J]. IEEE Transactions on Industrial Informatics, 2022, 18(2): 965-975.
- [8] MA J, LIU J, QIU W, et al. An intelligent classification framework for complex PQDs using optimized KS-transform and multiple fusion CNN [J]. IEEE Transactions on Industrial Informatics, 2024, 20(2): 1776-1785.
- [9] 马嘉秀,徐玮浓,何复兴,等.基于WT和SVM的电能质量分类识别方法[J].智慧电力,2019,47(3):16-22.  
MA Jiayou, XU Weinong, HE Fuxing, et al. A novel power quality classification and identification method based on WT and SVM [J]. Smart Power, 2019, 47(3): 16-22.
- [10] 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. Recognition of hybrid PQ disturbances based on a chaos ensemble decision tree [J]. Power System Protection and Control, 2021, 49(21): 18-27.
- [11] WANG S X, CHEN H W. A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network [J]. Applied Energy, 2019, 235: 1126-1140.
- [12] 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.
- [13] LI H X, YI B S, LI Q X, et al. Evaluation of DC power quality based on empirical mode decomposition and one-dimensional convolutional neural network [J]. IEEE Access, 2020, 8: 34339-34349.
- [14] 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.
- [15] CUI C H, DUAN Y J, HU H L, et al. Detection and classification of multiple power quality disturbances using stockwell transform and deep learning [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-12.
- [16] 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.
- [17] WU H X, HU T G, LIU Y, et al. TimesNet: temporal 2D-variation modeling for general time series analysis [EB/OL]. [2024-03-20]. <https://arxiv.org/abs/2210.02186v3>.
- [18] YANG J, KE A H, YU Y X, et al. Scene sketch semantic segmentation with hierarchical Transformer [J]. Knowledge-Based Systems, 2023, 280: 110962.

- [19] XIE E Z, WANG W H, YU Z D, et al. SegFormer: simple and efficient design for semantic segmentation with transformers [EB/OL]. [2024-03-20]. <https://arxiv.org/abs/2105.15203>.
- [20] LIU Y L, JIN T, MOHAMED M A. A novel dual-attention optimization model for points classification of power quality disturbances[J]. Applied Energy, 2023, 339: 121011.
- [21] IEEE recommended practice for monitoring electric power quality: IEEE Std.1159—2019[S]. 2019.
- [22] 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.
- [23] 王海东,程杉,徐其平,等.基于深度学习融合网络的含噪电能质量扰动识别方法[J].电力系统保护与控制,2024,52(10): 11-20.  
WANG Haidong, CHENG Shan, XU Qiping, et al. Identification of power quality disturbance with noises based on an integrated deep learning network [J]. Power System Protection and Control, 2024, 52(10): 11-20.
- [24] 林海雪.第1讲 供电电压偏差标准[J].建筑电气,2011,30(4):3-9.  
LIN Haixue. Lecture one: standard of supply voltage deviation [J]. Building Electricity, 2011, 30(4): 3-9.
- [25] 林海雪.第2讲 电力系统频率偏差标准[J].建筑电气,2011,30(5):10-14.  
LIN Haixue. Lecture two: standard of frequency deviation for power system [J]. Building Electricity, 2011, 30(5): 10-14.
- 王守相(1973—),男,博士,教授,博士生导师,主要研究方向:分布式发电与智能配电网。E-mail: sxwang@tju.edu.cn
- 李慧强(1995—),男,硕士研究生,主要研究方向:电能质量扰动分析。E-mail: lihuiqiang@tju.edu.cn
- 赵倩宇(1990—),女,博士,副教授,主要研究方向:智能配用电。E-mail: zhaoqianyu515@126.com
- 郭陆阳(1995—),男,通信作者,博士研究生,主要研究方向:智能配用电。E-mail: guoluyang@tju.edu.cn
- (编辑 蔡静雯)

## Power Quality Disturbance Classification Method Based on Time-series Two-dimensional Transformation and Multi-scale Transformer

WANG Shouxiang<sup>1,2</sup>, LI Huiqiang<sup>1,2</sup>, ZHAO Qianyu<sup>1,2</sup>, GUO Luyang<sup>1,2</sup>, WANG Tongxun<sup>3</sup>, WANG Yang<sup>3</sup>

(1. Key Laboratory of the Ministry of Education on Smart Power Grids (Tianjin University), Tianjin 300072, China;

2. Tianjin Key Laboratory of Power System Simulation and Control (Tianjin University), Tianjin 300072, China;

3. State Grid Smart Grid Research Institute Co., Ltd., Beijing 102209, China)

**Abstract:** With the increasing penetration of renewable energy, the power quality disturbance (PQD) problem faced by the power grid has become more complicated. The traditional classification method based on one-dimensional PQD signals makes it difficult to extract and identify periodic and trend disturbances at the same time. To address this problem, this paper proposes a PQD classification method based on time-series two-dimensional transformation and multi-scale Transformer. Firstly, the time-series two-dimensional transformation is used to convert the one-dimensional PQD time series into a set of two-dimensional tensors based on multiple periods, to deeply mine the characteristic information contained in the PQD signals in the two-dimensional space. Then, the multi-scale feature map of the PQD signal is extracted through the multi-scale Transformer encoder module. And the multi-scale Transformer decoder module is used to splice and fuse the multi-scale feature maps, for effectively merging the feature maps extracted at different scales. Finally, the PQD classification task is accomplished through a fully connected layer and a Softmax classifier. To verify the effectiveness of the proposed method, a dataset containing 24 kinds of PQD is established to test the model. The results indicate that the proposed method has a high classification accuracy and noise robustness for PQD signals.

This work is supported by National Key R&D Program of China (No. 2023YFB2407500).

**Key words:** power quality; disturbance classification; time series two-dimensional transformation; multi-scale Transformer; feature extraction; feature fusion



### 附录 A

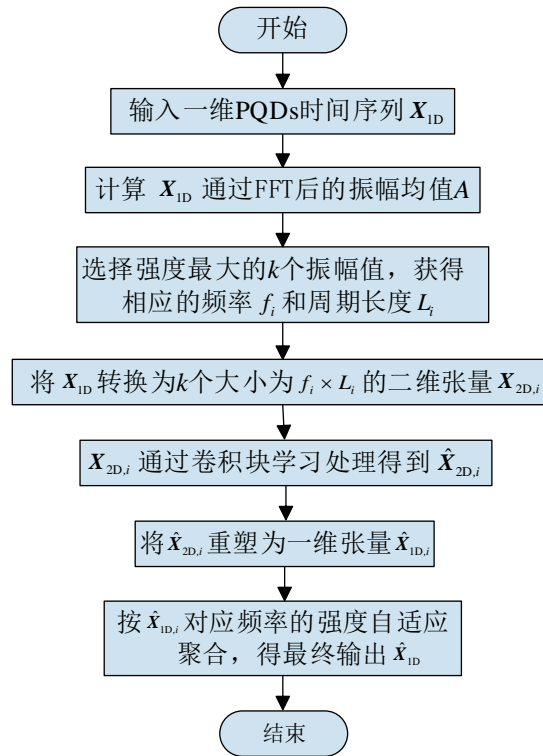


图 A1 PQD 信号时序二维变换流程图

Fig. A1 PQD signal time series two-dimensional transformation flow chart

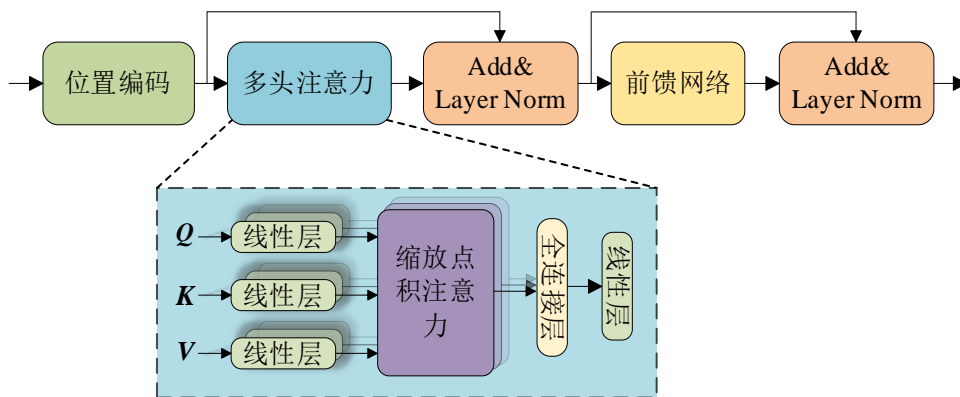


图 A2 Transformer 编码器块

Fig. A2 Transformer encoder block



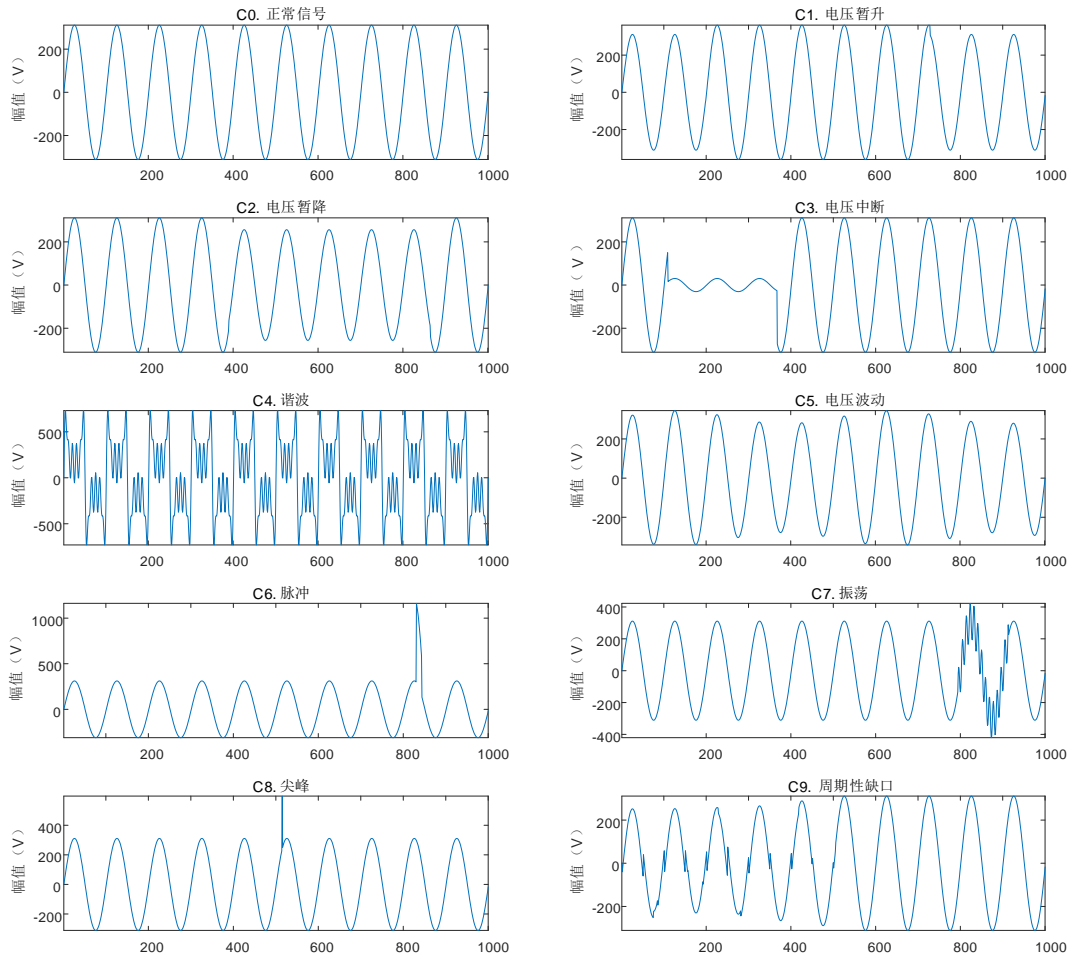


图 A3 PQR 信号波形图  
Fig. A3 PQR signal waveform figure

预测类别

	C0	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20	C21	C22	C23		
C0	149																								100	
C1		148									5				2		1						8		90.24	
C2			143	1								8									2			5	90.52	
C3				144									1												99.31	
C4					137																				100	
C5						150																			100	
C6							148																		100	
C7								150																	96.77	
C8									146																99.32	
C9										148			2								5				98.67	
C10					2						143														98.62	
C11						2						137													98.56	
C12													152												100	
C13							2							144											98.63	
C14		1													149								12		91.96	
C15																150								14	91.43	
C16																	148								100	
C17									4									152							97.45	
C18																			143						100	
C19																					144				100	
C20							1																154		99.35	
C21																							150		100	
C22		1									2			1	5									136	93.79	
C23			2									1				8									137	92.57
	100	98.67	98.62	99.31	97.15	98.68	98.67	100	97.35	100	95.33	94.52	98.06	99.31	95.51	94.95	99.34	100	100	98.63	96.86	100	87.15	87.83	Acc	97.12

Pre

图 A4 所提模型分类结果混淆矩阵  
Fig. A4 Confusion matrix of classification results of the proposed model

表 A1 PQD 标签定义  
Table A1 PQD label definition

PQD 类别	标签	PQD 类别	标签
正常	C0	暂降+谐波	C12
暂升	C1	谐波+波动	C13
暂降	C2	暂升+波动	C14
中断	C3	暂降+波动	C15
谐波	C4	暂升+脉冲	C16
波动	C5	暂降+脉冲	C17
脉冲	C6	暂升+振荡	C18
振荡	C7	暂降+振荡	C19
尖峰	C8	脉冲+谐波	C20
周期性缺口	C9	脉冲+波动	C21
暂升+谐波	C10	暂升+谐波+波动	C22
中断+谐波	C11	暂降+谐波+波动	C23

表 A2 所提模型相关参数  
Table A2 Parameter settings related of the proposed model

序号	名称	参数
1	原始数据尺寸	8400*2560
2	时序块	num_kernels=6
3	FFT	top_k=3
4	多尺度 Transformer 的输入特征尺寸	8400*1024*1
6	Transformer 编码器	nhead=8, num_layers=1
5	Transformer 编码器块 1	in_c=16, ot_c=32
6	卷积层 1	in_c=32, ot_c=16
7	Transformer 编码器块 2	in_c=32, ot_c=64
8	卷积层 2	in_c=64, ot_c=16
9	Transformer 编码器块 3	in_c=64, ot_c=128
10	卷积层 3	in_c=128, ot_c=16
11	Transformer 编码器块 4	in_c=128, ot_c=256
12	卷积层 4	in_c=256, ot_c=16
13	MLPT	dropout_rate=0.08
14	MLPC	dropout_rate=0.08
15	线性层 1	in_c=16*1024, ot_c=1024
16	线性层 2	in_c=1024, ot_c=512
17	线性层 3	in_c=512, ot_c=128
18	线性层 4	in_c=128, ot_c=24

注: num\_kernels 为时间块中卷积核的数量; top\_k 为 FFT 选择振幅最大频率的个数; nhead 和 num\_layers 分别为多头注意力机制的头数和层数; in\_c 和 ot\_c 分别为输入特征和输出特征的维度; dropout\_rate 为 MLPT 和 MLPC 的学习率。

表 A3 基波信号波动条件下所提模型在不同噪声环境中的分类结果  
**Table A3 Classification results of the proposed model in different noise environments under the condition of fundamental signal fluctuation**

扰动类型	识别准确率(%)			
	50 dB	30 dB	20 dB	无噪声
正常	100	100	98.49	100
暂升	97.57	97.36	96.25	99.62
暂降	97.63	97.45	96.22	99.33
中断	98.32	97.47	96.41	99.53
谐波	97.65	97.43	96.35	99.21
波动	98.44	97.44	96.27	99.31
脉冲	98.42	97.45	96.01	99.13
振荡	98.45	97.52	96.26	99.58
尖峰	98.14	97.13	96.38	99.12
周期性缺口	98.06	97.23	96.26	99.36
暂升+谐波	97.64	96.82	95.52	98.73
暂降+谐波	97.56	96.81	95.54	98.62
中断+谐波	98.46	97.54	96.41	99.11
谐波+波动	97.85	96.67	96.38	98.37
波动+暂升	97.26	96.73	96.31	98.07
波动+暂降	97.32	96.78	96.28	98.12
暂升+脉冲	98.53	97.46	96.52	99.21
暂降+脉冲	98.16	97.36	96.21	99.33
暂升+振荡	98.49	97.35	96.24	99.31
暂降+振荡	98.27	97.26	96.13	99.14
脉冲+谐波	98.36	97.24	96.11	98.88
脉冲+波动	98.24	97.35	96.15	98.79
暂升+谐波+波动	97.02	96.36	95.23	97.78
暂降+谐波+波动	97.13	96.31	95.21	97.81
识别率	98.04	97.27	96.21	98.98



表 A4 不同模型在增强型实测数据集上的分类结果  
**Table A4 Classification results of different models on enhanced measured data sets**

扰动类型	识别准确率(%)			
	TST-MT	CTranCBA	ST-CNN	ResNet-BLSTM
正常	100	96.12	97.83	100
暂升	96.96	92.51	92.87	93.77
暂降	96.83	92.53	92.91	93.83
中断	97.45	93.67	94.22	96.31
谐波	96.77	92.65	93.31	94.23
波动	97.34	93.51	94.22	95.33
脉冲	97.37	93.42	94.16	95.37
振荡	97.15	93.48	94.27	95.41
暂升+谐波	96.11	90.81	91.34	92.57
暂降+谐波	96.06	90.75	91.51	92.63
中断+谐波	96.61	91.45	92.38	93.17
谐波+波动	96.58	90.13	90.26	91.48
波动+暂升	96.46	91.09	91.03	90.98
波动+暂降	96.31	89.82	90.37	91.22
暂升+脉冲	96.53	91.52	92.43	93.19
暂降+脉冲	96.46	91.48	92.36	93.43
暂升+振荡	96.37	89.68	92.41	93.24
暂降+振荡	96.29	91.16	92.38	93.41
脉冲+谐波	96.37	91.09	92.37	93.17
脉冲+波动	97.08	91.11	92.49	93.16
暂升+谐波+波动	94.34	87.03	88.22	90.18
暂降+谐波+波动	94.11	86.86	87.53	89.86
识别率	96.61	91.41	92.31	93.45

表 A5 不同模型在劣化实测数据集上的分类结果  
**Table A5 Classification results of different models on the degraded measured data set**

扰动类型	识别准确率(%)			
	TST-MT	CTranCBA	ST-CNN	ResNet-BLSTM
正常	100	95.33	96.52	98.62
暂升	96.48	91.21	91.53	92.41
暂降	96.33	91.25	91.59	92.43
中断	96.98	92.39	92.88	94.92
谐波	96.26	91.34	91.97	92.84
波动	96.88	92.23	92.91	93.94
脉冲	96.85	92.13	92.83	94.02
振荡	96.64	92.21	92.94	94.03
暂升+谐波	95.61	89.42	90.01	91.07
暂降+谐波	95.48	89.31	90.18	91.12
中断+谐波	96.03	90.16	91.04	91.97
谐波+波动	96.06	88.91	89.12	90.15
波动+暂升	95.86	89.93	89.74	89.67
波动+暂降	95.81	88.53	89.03	89.82
暂升+脉冲	96.04	90.23	91.16	91.81
暂降+脉冲	95.88	90.12	91.02	92.04
暂升+振荡	95.72	88.68	91.09	91.83
暂降+振荡	95.81	89.77	91.06	92.03
脉冲+谐波	96.03	89.85	91.03	91.78
脉冲+波动	96.43	89.82	91.16	91.83
暂升+谐波+波动	94.12	85.32	86.14	88.82
暂降+谐波+波动	93.51	84.57	86.71	88.48
识别率	96.11	90.12	90.98	92.07