

DOI: 10.19783/j.cnki.pspc.250041

基于神经盲反卷积时频域去噪的电能质量扰动联合识别方法

郑博妍¹, 袁至¹, 李骥²

(1. 新疆大学可再生能源发电与并网控制教育部工程研究中心, 新疆 乌鲁木齐 830017;

2. 国网新疆电力有限公司电力科学研究院, 新疆 乌鲁木齐 830011)

摘要: 现有的电能质量扰动(power quality disturbances, PQDs)去噪算法存在易丢弃真实信号、去噪效果差、无法识别 1/f 噪声和 Laplace 噪声等缺点。为提高噪声下 PQDs 识别精度和效率, 提出一种基于神经盲反卷积(neural blind deconvolution, NBD)时频域去噪的 PQDs 联合识别方法。首先, 构建由 NBD 与 Transformer 组成的联合识别模型, NBD 整合了时域二次卷积滤波器和频域线性滤波器以实现去噪功能。Transformer 负责从去噪后数据中提取特征并进行分类任务。其次, 为保证训练效果最优, 提出了基于贝叶斯不确定性的动态加权策略, 构建由峰度、包络谱目标函数和交叉熵损失组成的联合损失函数对所提模型进行优化。最后, 基于 IEEE Std 1159-2019 标准生成 25 类 PQDs 并进行仿真实验。仿真结果表明, 该方法实现了不同噪声类型下 PQDs 的准确识别, 相较于其他方法具备更优的 F1 分数、Params、FLOPs 等, 提高了去噪性能、识别精度和效率。

关键词: 神经盲反卷积; 时域二次神经滤波器; 频域线性神经滤波器; 时频域去噪; 联合损失函数; 电能质量扰动

Joint identification method for power quality disturbances based on neural blind deconvolution time-frequency domain denoising

ZHENG Boyan¹, YUAN Zhi¹, LI Ji²

(1. Engineering Research Center for Renewable Energy Power Generation and Grid-connected Control, Ministry of Education, Xinjiang University, Urumqi 830017, China; 2. Electric Power Research Institute, State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830011, China)

Abstract: Existing denoising algorithms for power quality disturbances (PQDs) have shortcomings such as loss of true signal components, poor denoising performance, and inability to identify 1/f noise and Laplace noise. In order to improve the accuracy and efficiency of PQD identification under noisy conditions, a joint identification method based on neural blind deconvolution (NBD) time-frequency domain denoising is proposed. First, a joint identification model combining NBD and Transformer is constructed. The NBD integrates a time-domain quadratic convolution filter and a frequency domain linear filter to realize denoising, while the Transformer is responsible for extracting features and performing classification on the denoised data. Second, to ensure optimal training effect, a dynamic weighting strategy based on Bayesian uncertainty is proposed, and a joint loss function composed of kurtosis, envelope spectrum objective function, and cross-entropy loss is introduced to optimize the proposed model. Finally, based on the IEEE Std 1159-2019 standard, 25 classes of PQDs are generated and simulated. The simulation results show that the proposed method achieves accurate identification of PQDs under different noise types, and outperforms other methods in terms of F1 score, Params, and FLOPs, thereby improving denoising performance, identification accuracy and computational efficiency.

This work is supported by the Major Science and Technology Special Projects of Xinjiang Uygur Autonomous Region (No. 2022A01001-4).

Key words: neural blind deconvolution; time domain quadratic neural filter; frequency domain linear neural filter; time-frequency domain denoising; joint loss function; power quality disturbance

0 引言

随着各种电力电子设备和电动汽车等新型非线性

性负载接入电网, 电能质量扰动事件频发, 可能导致设备损坏、效率降低、保护装置误动、电网稳定性下降等安全隐患^[1-4]。电力系统中各种电子设备、控制器、电弧设备等产生 1/f 噪声, 电力电子装置工作时交流输入电流切换也经常出现 Laplace 噪声, 存在于实际系统的多源耦合噪声将严重影响特征提

基金项目: 新疆维吾尔自治区重大科技专项资助 (2022A01001-4)

取, 甚至造成特征提取方法完全失效。因此, 研究高效的电能质量信号去噪算法, 对于 PQDs 准确识别具有重要意义。

现有研究通常采用基于不同信噪比的单一高斯噪声模型来模拟电力系统实际噪声环境^[5], 然而, 该建模方式与真实电力系统的复杂噪声特性存在显著差异。这种差异主要体现在: 1) 电力电子装置交流侧换相过程产生的非高斯 Laplace 噪声; 2) 电弧炉、晶闸管等非线性负载引发的 1/f 噪声; 3) 多源噪声耦合形成的非平稳混合噪声。针对这一关键问题, 本文提出复合噪声建模方法, 通过构建包含高斯噪声、1/f 噪声、Laplace 噪声及其耦合噪声的 4 类复合噪声数据库, 可实现 PQDs 识别数据集有效扩展, 显著提升噪声模型与实际电力场景的动态匹配度。

近年来, 国内外学者提出了诸多有效的信号去噪算法。小波阈值处理(wavelet thresholding, WT)是常采用的 PQDs 去噪方法, 但其处理非线性特征和非高斯分布信号的效果有限^[6-7]。傅里叶变换去噪(Fourier transform denoising, FTD)通过消除频域内特定频段的噪声实现去噪^[8-9], 然而该方法可能导致时域信号相位失真。经验模态分解(empirical mode decomposition, EMD)去噪通过分离信号的本征模态函数(intrinsic mode functions, IMFs)并排除噪声成分, 以重建清晰信号, 但该技术受模态混叠效应影响^[10-11]。变分模态分解(variational mode decomposition, VMD)去噪通过设定中心频率和带宽约束, 采用迭代优化方法求解 IMFs, 可有效控制模态混叠效应, 但可能面临长时模态重叠问题^[12-13]。Wiggins 提出盲反卷积(blind deconvolution, BD)领域下最小熵去卷积(minimum entropy deconvolution, MED)方法。该方法具有强适应性和不受带宽及中心频率限制的特点, 但 MED 依赖峰度作为目标函数来寻找最优的逆滤波器, 而峰度仅对异常值具有较高敏感性^[14-16]。NBD 作为 BD 领域的变体, 保留了 MED 等现有 BD 的良好去噪性能, 且克服了 MED 与深度学习分类器无法无缝衔接的弊端, 本文采用联合损失作为目标函数, 以实现 NBD 与神经网络分类器共同优化, 且可以弥补峰度仅对异常值敏感的缺陷。

数据去噪后需识别 PQDs 信号类型, 考虑到 MobileNetV3^[17]、EfficientNet^[18]、ResNet18^[19]、1DCNN^[20]等方法 PQDs 识别准确率低的问题, 本文引入 Transformer 以增强扰动特征表征能力^[21]。进一步地, 针对现有研究的信号去噪与分类任务采用解耦式损失函数设计导致难以兼顾信号去噪质量与分类精度平衡的问题, 本文通过贝叶斯不确定性的

动态加权策略, 将时域峰度指标、频域包络谱目标函数与分类交叉熵损失进行协同优化, 形成损失函数耦合机制, 旨在有效解决去噪质量与分类精度的平衡难题。

综上, 本文提出一种基于 NBD 时频域去噪的 PQDs 联合识别方法。首先, 针对现有去噪方法存在的时频域失真、非高斯噪声的抑制效果不佳等弊端, 构建 NBD 进行 PQDs 去噪, NBD 核心结构为时域二次卷积滤波器和频域线性滤波器。其次, 针对现有深度学习对于多分类问题识别率较低问题, 利用 Transformer 实现 25 类 PQDs 的精确识别。最后, 针对峰度仅对异常值敏感的问题, 提出一种新型物理信息损失函数来共同优化 NBD 和 Transformer 的策略。本文通过训练曲线、混淆矩阵验证了 NBD 和 Transformer 联合识别方法的有效性, 并进一步通过多组对比试验验证 NBD 去除 1/f 噪声和 Laplace 噪声等非高斯噪声的效果及 NBD 和 Transformer 的联合识别方法的必要性。

1 基于 NBD 和 Transformer 的识别模块

1.1 NBD 去噪模块

NBD 是一种结合深度学习和传统反卷积的信号处理技术, 旨在从已知的输出信号中恢复原始输入信号和系统冲激响应, 且不需要对系统的特性具有先验知识。

PQDs 识别问题中, 采样到的输出信号可以解释为扰动源信号与从扰动源到采样点的传递函数之间卷积运算的结果, PQDs 信号传递过程表示为^[22]

$$x = d * h_d + n * h_n \quad (1)$$

式中: 被测信号 $x \in \mathbf{R}^N$, N 为整数; 扰动源信号 $d \in \mathbf{R}^N$; 噪声信号 $n \in \mathbf{R}^N$; h_d 和 h_n 表示传递函数。

为实现从测量信号中提取扰动相关特征, NBD 通过构造滤波器 f 来恢复离 d 更近的信号 y 。

$$y = x * f = (d * h_d + n * h_n) * f \approx d \quad (2)$$

本文滤波器 f 由时域二次卷积滤波器(本质为二次卷积神经网络, 为匹配传统盲反卷积的习惯表达, 本文称作“滤波器”)、频域线性滤波器组成, 用于从 PQDs 复合信号中分离出所需信号成分, 抑制噪声和干扰。

1.1.1 时域二次卷积滤波器

时域二次卷积滤波器的核心为二次卷积神经网络(quadratic convolutional neural networks, QCNN)。多项式神经网络引入多阶关系来增强模型识别精度, 可有效解决单层传统线性神经网络(convolutional neural networks, CNN)^[20]局限性。将多项式引入神经

网络的方法分为两类:多项式结构和多项式神经元,在前者方面,多项式神经网络通过递归多项式展开或张量分解来实现,后者则将传统神经网络中的线性函数(神经元)替换为各种多项式函数。本文重点研究后者。

CNN 和 QCNN 分别为

$$y = \sigma(\mathbf{W}^T x + b) \quad (3)$$

$$y = \sigma((\mathbf{W}_1^T x + b_1)(\mathbf{W}_2^T x + b_2) + \mathbf{W}_3^T(x \odot x) + b_3) \quad (4)$$

式中: $\sigma(\bullet)$ 为激活函数; \mathbf{W} 、 b 分别为 CNN 的权重矩阵、偏置; \mathbf{W}_1 、 \mathbf{W}_2 、 \mathbf{W}_3 为 QCNN 的 3 组不同权重矩阵; b_1 、 b_2 、 b_3 为 QCNN 的 3 组不同偏置; \odot 为 Hadamard 积。

式(4)用二次函数代替式(3)的线性函数构造二次网络。为避免参数过多影响特征提取速度,本文利用文献[23]提出的二次型神经元对式(4)进行简化,如式(5)所示。

$$y = \sigma((\mathbf{W}_1^T x)(\mathbf{W}_2^T x) + \mathbf{W}_3^T(x \odot x)) \quad (5)$$

在效率方面,传统神经网络需要指数级神经元,而 QCNN 使用效率更高的多项式级神经元来近似径向函数。在特征表示方面,传统网络采用非线性激活函数分段逼近,相比之下,QQNN 可实现性能更优的多项式近似^[24]。并且文献[25]已成功验证了 QCNN 在强噪声等具有挑战性条件下的实用性。

虽然多项式函数可扩展到更高阶,但会增加神经网络计算复杂度,为便于稳定训练,本文限制多项式函数为二阶。

1.1.2 频域线性滤波器

频域线性滤波器的核心为傅里叶神经网络(Fourier neural network, FNN),FNN 将傅里叶变换应用于神经网络模型,使用傅里叶基函数作为激活函数,以更好地捕捉数据的频率特性。

频域线性滤波器的滤波流程如下:首先将经过时域滤波器的信号 $\hat{x}(t)$ 应用快速傅里叶变换(fast Fourier transform, FFT)转换到频域;其次采用线性神经网络对生成的频域信号进行滤波;最后将滤波后的频域信号进行逆快速傅里叶变换(inverse fast Fourier transform, IFFT),将信号输出到时域。具体实现过程如式(6)一式(8)所示。

$$\hat{X}(f) = F(\hat{x}(t)) \quad (6)$$

$$\hat{Y}(f) = \sum_{f=1}^N w_f(f) \hat{X}(f) + b_f \quad (7)$$

$$\hat{y}(t) = F^{-1}(\hat{Y}(f)) \quad (8)$$

式中: $F(\bullet)$ 为傅里叶变换; $\hat{X}(f)$ 为频域信号; $\hat{Y}(f)$ 为频域滤波后的信号; w_f 、 b_f 分别为频域的权重

和偏置; $\hat{y}(t)$ 为经过频率线性滤波器后最终输出的信号; $F^{-1}(\bullet)$ 为逆傅里叶变换。

1.2 Transformer 分类模块

本研究 Transformer 模块架构包括时间序列嵌入模块、位置信息编码、类别信息嵌入、Transformer 基础模块、softmax 层和全连接层。Transformer 基础模块由前馈全连接网络、批量归一化层(batch normalization, BN)、多头自注意力机制(multi-head self-attention, MSA)、残差连接共同构成。

2 联合损失函数的构建

2.1 时域二次卷积滤波器的目标函数构建

为衡量时域二次卷积滤波器的去噪结果与原始扰动源信号之间的差异(即 y 和 d 之间的差异),需构建一个目标函数,有学者提出多种稀疏度量标准作为目标函数,其中峰度是一个典型代表。峰度是评估数据分布的统计量,峰度值的增加表明偏离标准正态分布,直观地看,电能质量扰动发生时扰动源信号会出现更多的峰值(异常值),即峰度最大化,通过最大化峰度来驱动自适应滤波器,实现从噪声中提取出有用信息,进而有效恢复原始扰动信号的目的。为适配联合损失函数最小化的求解,本文在原始峰度计算式前加入负号,如式(9)所示。

$$L_t = -\frac{\sum_{n=1}^M y(n)^4}{\left(\sum_{n=1}^M y(n)^2\right)^2} \quad (9)$$

式中: L_t 表示峰度; $y(n)$ 表示时域滤波器的输出; M 为输入的二进制数据集长度。

2.2 频域线性滤波器的目标函数构建

频域滤波器的目标函数旨在增强频域的信号稀疏性,从而有效减轻噪声频率分量的影响,本文采用基于包络谱的目标函数,具体如下。

希尔伯特变换(Hilbert transform, HT)的数学表达式如式(10)^[26]所示。

$$h(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} x(\tau) \frac{1}{t-\tau} d\tau = x(t) * \frac{1}{\pi t} \quad (10)$$

HT 施加于频域计算的线性层。根据卷积定理,有

$$\hat{H}(f) = (-j\text{sgn}(f))\hat{Y}(f) \quad (11)$$

式中: $\hat{H}(f)$ 为经 HT 后信号的频域频谱; $\text{sgn}(f)$ 为符号函数。

对实值信号进行 HT 得到信号的解析信号。解析信号是一个复数信号,实部是原始信号,虚部是原始信号的 HT。该步骤基于逆离散傅里叶变换(inverse discrete Fourier transform, IDFT)实现。

$$\hat{h}(n) = F^{-1}(\hat{H}(f)) \quad (12)$$

$$z(n) = \hat{y}(n) + j\hat{h}(n) \quad (13)$$

式中: $\hat{y}(n)$ 为式(8)的时域离散值; $\hat{h}(n)$ 为经 HT 后信号的时域离散值; $z(n)$ 为解析信号的离散形式。

解析信号取模(计算复数的模)得到信号的包络, 包络信号包含原始信号的振幅信息^[27]。

$$|z(n)| = \sqrt{\hat{y}^2(n) + \hat{h}^2(n)} \quad (14)$$

式中: $|z(n)|$ 称为包络。

对包络信号进行傅里叶变换, 得到包络谱。

$$E_s(f) = F\left(\sqrt{\hat{y}^2(n) + \hat{h}^2(n)}\right) \quad (15)$$

式中: $E_s(f)$ 为包络的傅里叶频谱, 即包络谱。

基于包络谱的频域线性滤波器目标函数为

$$L_f = \frac{\sum_{f=1}^M E_s(f)^2}{\left(\sum_{f=1}^M E_s(f)^4\right)^{\frac{1}{2}}} \quad (16)$$

式中: L_f 为测量 $E_s(f)$ 稀疏度的目标函数。

2.3 Transformer 分类模块的目标函数构建

PQDs 识别是一个多分类问题, 交叉熵函数能很好地处理这种多类别情况; 且 Transformer 模型通过 Softmax 层将最终的输出转化为概率分布, 表示样本属于每个类别的概率, 交叉熵损失函数适合这种概率输出。故拟采用交叉熵函数作为 Transformer 分类模块的目标函数 L_c , 如式(17)^[21]所示。

$$L_c = -\sum_i p_i \log q_i \quad (17)$$

式中: i 为 PQDs 的类别索引; p_i 、 q_i 分别为真实标签和预测标签。

2.4 联合损失函数构建

PQDs 识别任务中采用 NBD 和 Transformer 联合识别方法, 而非 NBD、Transformer 各自独立优化方法, 主要基于以下考量。

1) 联合优化允许 NBD 去噪模块和 Transformer 分类器在训练过程中相互适应, 这种协同效应可增强模型对 PQDs 特征的捕捉能力。

2) 联合损失函数可在整个模型层面实现全局优化, 而不是局部优化, 有助于避免过拟合, 并确保模型在去噪和分类上的整体性。

3) 联合优化可以平衡 NBD 和 Transformer 的损失, 确保两者在训练过程中得到适当权重, 避免任何一个模块占主导而影响另一个模块的性能。

4) 联合优化共享中间层的特征表示, 可减少训练过程中的计算复杂度, 从而提高训练效率。

5) NBD 去噪和 Transformer 分类任务在特征空间上互补, 有助于模型在不同任务间实现知识迁移, 学习到有用的表示。

因此, 构建联合损失函数进行联合优化是提高 PQDs 识别性能的有效策略。本文采用峰度、包络谱目标函数和交叉熵损失组成的联合损失函数 L , 该联合损失函数并非 3 者的简单加和, 而是采用基于贝叶斯不确定性的动态加权策略, 如式(18)所示。

$$L = \sum_{i=1}^3 \frac{1}{2\sigma_i^2} L_i + \ln \prod_{i=1}^3 \sigma_i \quad (18)$$

式中: L_i 为第 i 个损失项; σ_i 为可学习的不确定性参数, 通过梯度反传自动调节各损失项贡献度。

可得联合损失函数为

$$L = \frac{1}{\sigma_c^2} L_c + \frac{1}{\sigma_i^2} L_i + \frac{1}{\sigma_f^2} L_f + \ln \sigma_c + \ln \sigma_i + \ln \sigma_f \quad (19)$$

式中: σ_c^2 、 σ_i^2 、 σ_f^2 分别为不同模块噪声的方差, 其值越大, 相应损失分量的贡献就越小, 反之亦然。在训练过程中, 尺度由最后一项 $\ln \sigma$ 来调节, 如果 $\ln \sigma$ 太大, 则会被惩罚。该联合损失函数允许每个损失平稳减少, 并防止快速收敛到零。

联合损失函数最小化的过程, 旨在保证模型的损失不断降低、识别准确率不断升高, 达到最优训练效果。鉴于遗传算法、粒子群优化等智能优化算法参数量大、效率低的问题, 本文采用梯度下降法优化联合损失函数, 通过迭代逐步逼近最优解, 每次迭代时, 根据目标函数和优化算法更新估计的输入信号和系统冲激响应。

3 模型整体框架

所提 PQDs 识别模型框架如图 1 所示, 分为以下 3 部分。

1) 处理噪声环境下的 PQDs 扰动信号采用时域滤波器和频域滤波器组合的方法。

时域滤波器网络架构采用双阶段融合设计: 第一级处理层由 16 通道 QCNN 构成, 通过平均池化层降维后接续二次卷积层(输入通道 1, 输出通道 16), 完成含噪信号的初级滤波; 第二级重构层采用逆向 QCNN 架构实现通道融合, 依次通过批量归一化层、ReLU 非线性激活、二次卷积层(输入通道 16、输出通道 1), 最终经最大池化层与 Sigmoid 激活函数生成初步去噪信号。

在频域滤波器网络架构中, 首先对时域滤波器输出的初步去噪信号进行 FFT, 将时域信号映射至频域空间, 通过频域表征提取信号中的离散频率成分。在此基础上, 采用全连接层对频域信号进行自适

应滤波处理, 通过调整频域特征权重实现有用信号增强与噪声成分抑制。随后执行 IFFT, 将优化后的频

域信号重构为时域信号, 完成去噪流程的核心处理。

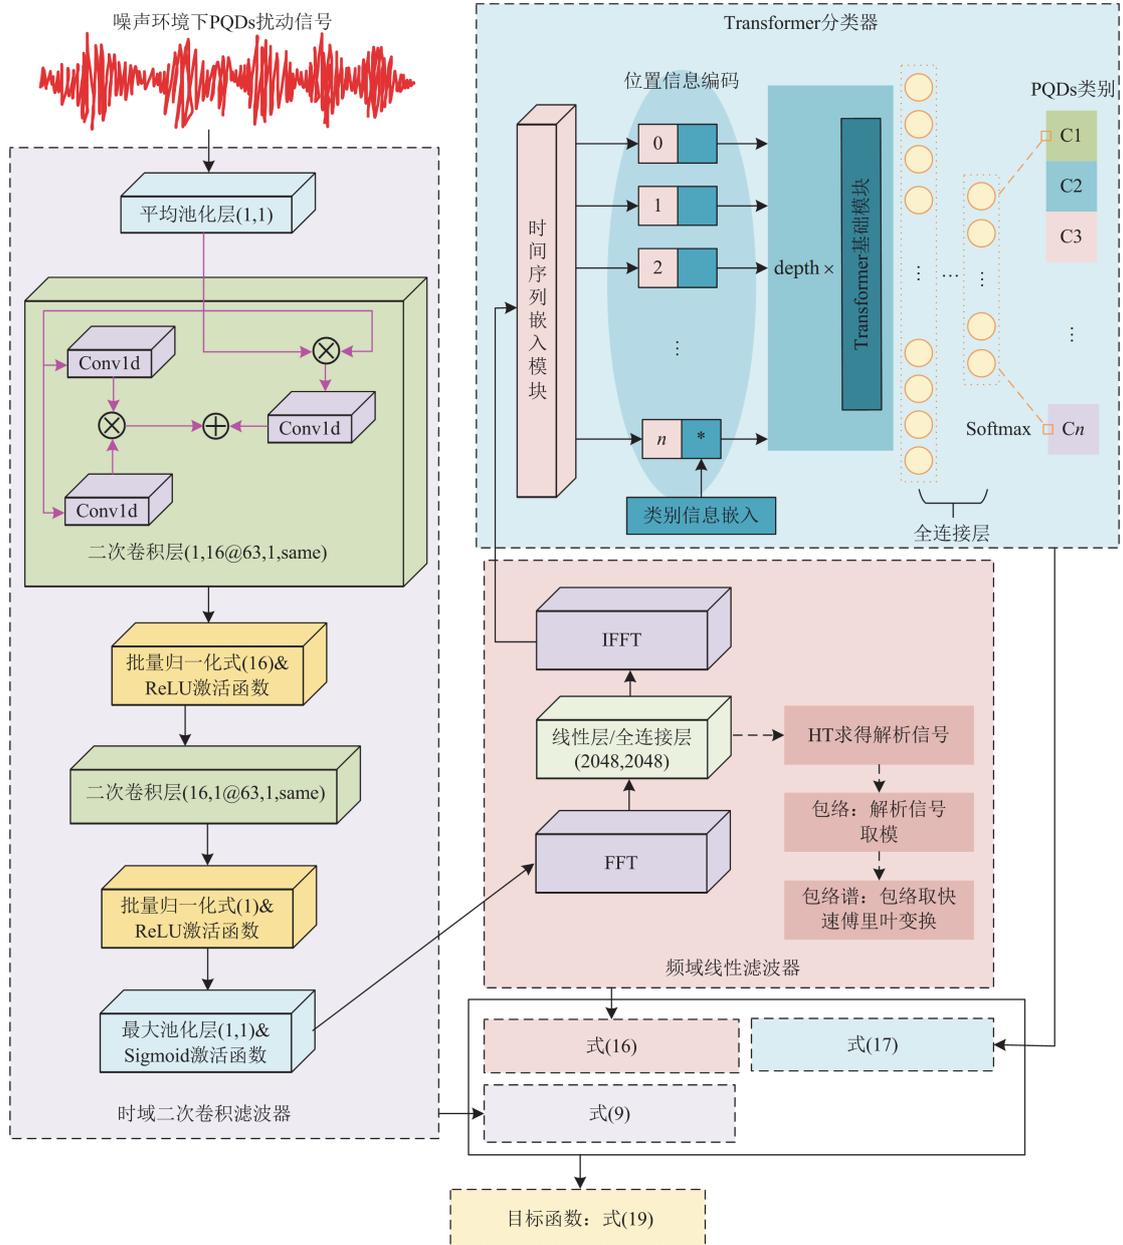


图 1 模型整体框架

Fig. 1 Overall framework of the model

2) 特征提取与分类部分采用基于编码器-解码器的 Transformer 架构实现。首先通过时间序列嵌入模块对时频域去噪后的信号进行位置信息编码, 并结合类别信息嵌入机制构建可区分性表征空间。其次经多层编码器迭代计算获得高维特征表达后, 采用全连接分类器将隐空间特征映射至决策域。最后通过 Softmax 函数建立概率分布映射, 输出 PQDs

分类结果。

3) 在端到端训练框架中, 构建了由交叉熵损失 L_c 、包络谱目标函数 L_f 和峰度 L_t 组成的联合损失函数 L , 其中: L_t 约束时域去噪性能, L_f 约束频域去噪性能, L_c 主导 PQDs 类别判别特征学习。通过最小化联合损失函数优化网络模型参数, 提升 PQDs 辨识系统的识别准确性。

4 电能质量扰动数据库的建立与参数设置

4.1 建立电能质量扰动数据库

本文参考 IEEE Std 1159-2019 标准及其他文献, 构建 10 种单一扰动类型、12 种二重复合扰动、3 种三重复合扰动类型, 共计 25 种信号类型, 复合 PQDs 的数学模型^[21]为

$$x(t) = [s_{ag}(t), s_{wl}(t), i_{tr}(t)] \times f_{lk}(t) \times \{\sin(t) + h_{my}(t) + n_{th}(t) + n_{oise}(t)\} + [o_{sc}(t), i_{mp}(t)] \quad (20)$$

式中: $s_{ag}(t)$ 、 $s_{wl}(t)$ 、 $i_{tr}(t)$ 、 $f_{lk}(t)$ 分别为电压暂降、暂升、中断、闪变扰动因子; $h_{my}(t)$ 、 $n_{th}(t)$ 、 $o_{sc}(t)$ 、 $i_{mp}(t)$ 分别为谐波、电压切痕、暂态振荡、暂态脉冲扰动因子; $n_{oise}(t)$ 为噪声信号。

所用 PQDs 数据集可通过数学公式和 Python 生成, 基波频率为 50 Hz, 采样频率设为 3200 Hz。单一扰动共计 10 类, 包括正常(C1)、电压瞬升(C2)、电压瞬降(C3)、谐波(C4)、闪变(C5)、电压中断(C6)、暂态脉冲(C7)、振荡暂态(C8)、电压缺口(C9)、电压尖峰(C10)。双重耦合扰动 12 类, 分别为谐波 + 瞬升(C11)、谐波 + 瞬降(C12)、谐波 + 中断(C13)、谐波 + 闪变(C14)、谐波 + 脉冲(C15)、谐波 + 振荡(C16)、闪变+瞬升(C17)、闪变 + 瞬降(C18)、闪变+振荡(C19)、闪变+脉冲(C20)、瞬升 + 振荡(C21)、瞬降+振荡(C22)。三重耦合扰动 3 种, 谐波 + 振荡 + 瞬升(C23)、谐波 + 振荡 + 瞬降(C24)、谐波 + 振荡 + 闪变(C25)。

IEEE STD 1159-2019 指出噪声幅度最大为 1%, 换算到信噪比(signal-noise ratio, SNR)为 40 dB, 考虑到存在采样等其他方面影响, 设置最小 SNR 为 30 dB。通过 Python 分别生成 1/f 噪声、Laplace 噪声、高斯噪声在 50 dB、40 dB、30 dB 的不同信噪比环境下幅值随机、扰动发生时间随机的 25 类 PQDs。每种扰动包括 1000 个幅值、相位均匀分布的样本。训练过程采用交叉验证, 每次迭代中, 1000 个样本按 8:1:1 的比例划分为训练集、验证集和测试集, 通过监测验证集精度来保存最优模型。

4.2 参数设置

W_1 服从高斯分布 $N(0, \sigma^2)$, b_1 服从均匀分布 $U(-1, 1)$, $W_2 = W_3 = \mathbf{0}$, $b_2 = b_3 = 0$, 该初始化过程可迫使 QCNN 从近似一级线性神经元开始, 高阶权重初始值设置为零以便放缓增长速度, 避免梯度爆炸, 提高二次网络训练过程的稳定性。

时域二级卷积滤波器利用平均池化层实现下采样, 以减少数据空间维度; 二次卷积层的参数设为

“(1,16@63,1,same)”, 表示从 1 个输入通道到 16 个输出通道的卷积层, 每个卷积核大小为 63, 步长为 1, 输出与输入尺寸相同; 相较于层归一化(layer normalization, LN), BN 可使激活函数分布在线性区间, 加大梯度和搜索步长, 加快收敛速度; 为引入非线性, 选取将所有负值置 0 的 ReLU 激活函数; 为增加模型抗噪性能, 保留最显著特征而忽略较小波动, 最大池化层窗口大小和步长都置 1。频域线性滤波器的线性层由 nn.Linear 类实现, 为避免改变数据维度, nn.Linear 类的两个主要参数 in_features 和 out_features 设为相同的值, 保证只进行线性变换。Transformer 中 MSA 设 4 个头。嵌入序列个数为 20, 序列维度为 2048。

训练环境参数如表 1 所示。

表 1 训练环境参数

Table 1 Training environment parameters	
硬件/软件	模型/版本
服务器	Lenovo R720
操作系统	Windows10 (64 bit)
CPU	Intel Core(TM)i7-7700HQ @2.80 GHz
GPU	GTX 1050
Python	3.7
Pytorch	1.2.0

5 仿真验证

5.1 模型训练过程

图 2 为模型训练过程中联合损失函数误差、测试集准确率的迭代变化极坐标图。图中角度表示迭代次数, 180°即迭代 50 次, 360°即迭代 100 次。由图可知, 在迭代至 120°时, 测试集的准确率达到 99%, 联合损失函数误差数值降至趋近 0 的水平, 此时模型达到收敛, 此后一直维持较高的准确率和较低的损失。

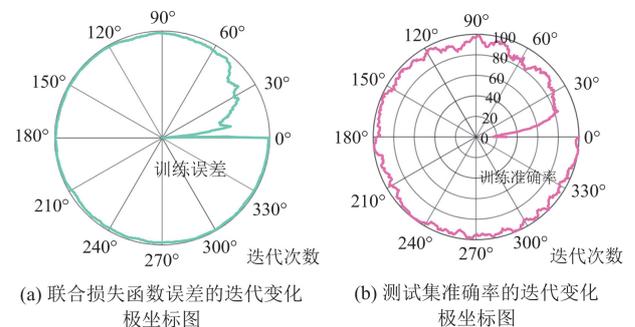


图 2 模型训练的极坐标图

Fig. 2 Polar coordinate graph of model training

5.2 整体模型的混淆矩阵

使用 NBD 与 Transformer 识别信噪比 30 dB 高

斯噪声下 25 类 PQDs, 每类 200 组信号, 绘制混淆矩阵, 如图 3 所示。混淆矩阵每一行之和表示该类别的真实样本数。图 3 第 21 行说明: 有 197 个属于 C21 的样本被正确预测为 C21 类, 有 2 个属于 C21 的样本被错误预测为 C2 类, 有 1 个属于 C21 的样本被错误预测为 C23 类, 即召回率为 98.5%。混淆矩阵每一列之和表示被预测为该类别的样本数。图 3 第 16 列说明: 分类器将 200+2+1=203 个样本预测为 C16, 其中正确的 200 个, 错误的为 3 个, 即精确率为 98.5%。根据混淆矩阵的数值分布可以发现, 所提模型在双重及三重扰动信号识别中, 大部分样本被准确识别, 少数样本未被准确识别。

针对电力电子器件的加入导致电力系统谐波危害日益突出的问题, 本文对谐波(C4)部分做出单独

分析。本文研究的谐波包含基波及其 3、5、7、11、13、15、20、30 次谐波分量, 频谱覆盖 50 Hz~1.5 kHz 频段, 属于 IEC 61000-4-7 标准中界定的中高频谐波范畴, 呈现典型的电力电子设备特征频谱分布。图 3 结果表明, 本文所提方法实现了谐波(C4)精确率与召回率双 100%的性能指标, 且在多模态耦合扰动识别中同样表现出卓越性能, 如双重耦合扰动谐波+闪变(C14)精确率、召回率分别达到 99.5%、99.5%, 三重耦合扰动谐波+振荡+闪变(C25)精确率、召回率分别达到 98.5%、98.5%。

实验结果表明, 本文提出的基于神经盲反卷积时频域去噪的 PQDs 联合识别方法, 在 PQDs 识别领域展现出显著优势, 尤其针对 50 Hz~1.5 kHz 频段的中高频谐波特征提取, 实现了 98%左右的检测精度。

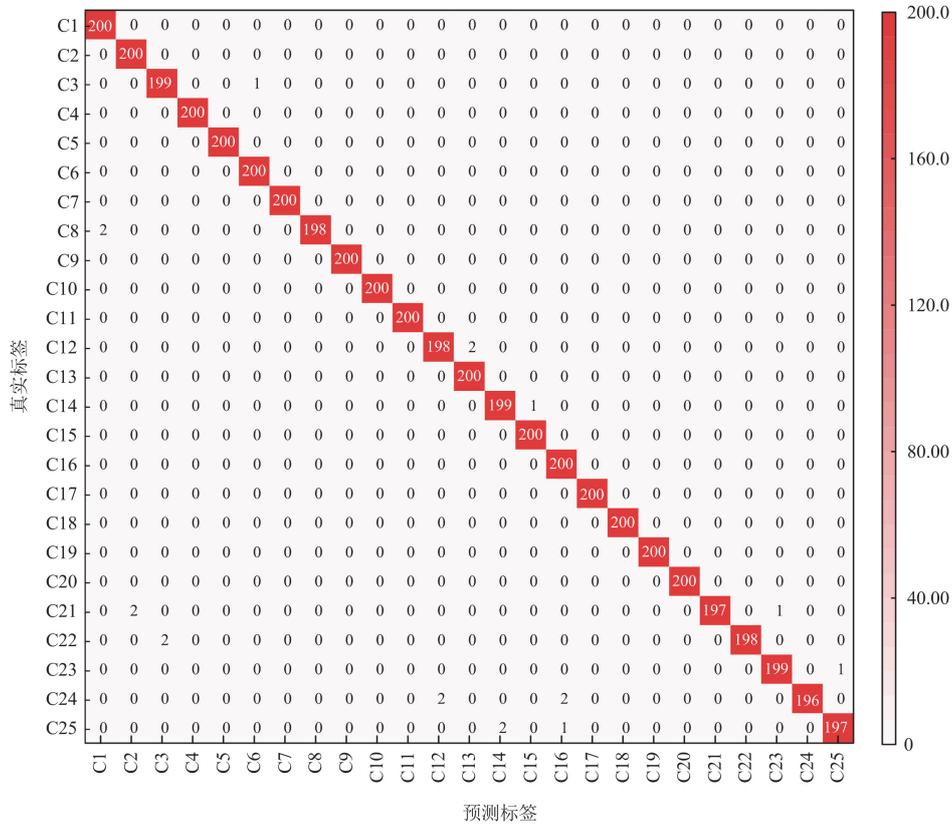


图 3 30 dB 高斯混合噪声下 25 类 PQDs 混淆矩阵

Fig. 3 Confusion matrix of 25 PQDs under 30 dB Gaussian mixed noise

5.3 去噪模块的去噪效果

为全面评估去噪性能, 本节从输入 SNR 和输出 SNR 两个关键维度对 NBD 进行分析。图 4 结果表明, 不同初始高斯噪声 SNR 条件下, 去噪过程均能显著提升信噪比。具体而言, 去噪后的输出 SNR 相较于输入 SNR 呈现出明显的增加, 表明信号的强度相对于噪声的强度变得更高, 信号中有效信息比例

变多, 从而验证了 NBD 去噪模块在改善信号质量方面的有效性。

为深入验证所提 NBD 去噪模块的性能, 采用 SNR 作为评估不同去噪模块效能的关键指标。通过将 NBD 与 WT^[6-7]、FTD^[8-9]、EMD^[10-11]、VMD^[12-13]、MED^[14-16]等先进去噪技术进行对比, 对输入信噪比为 30 dB 的 3 种最易发生的扰动类型样本实施去噪处

理。不同去噪模块输出信噪比实验结果如图 5 所示。

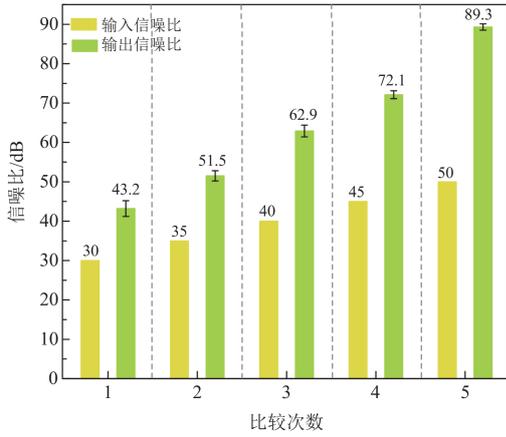


图 4 不同初始信噪比下输入与输出信噪比对比

Fig. 4 Comparison of input and output SNR under different initial SNR

图 5 直观展示了不同去噪技术在提升信号质量方面的性能差异。对于 30 dB 信噪比的高斯噪声输入信号, 基于本文所提去噪算法获得的 SNR 均高于文献[6-16]所提去噪算法, 充分说明 NBD 在 PQDs 去噪方面的优越性。

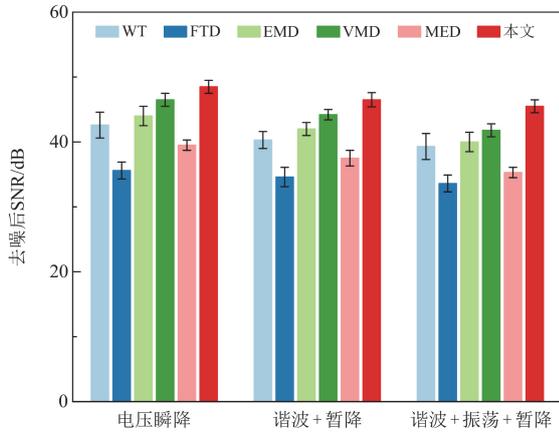


图 5 不同去噪模块去噪后 SNR 对比

Fig. 5 SNR after denoising of different denoising modules

此外, 本文构建具有 30 dB 信噪比的暂态振荡电能质量扰动信号, 来综合评估前述典型去噪算法在保留突变点特征方面的表现。图 6 展示了去噪后的波形对比结果。其中, 纵坐标表示归一化幅值, 虚线标记了振荡型瞬变发生时间段。分析结果显示, BD 领域的 MED 和 NBD 去噪后得到的去噪波形在突变点幅度上显著超过其他算法, 特别是 NBD 去噪模块基本保留了原始信号的所有突变点信息, 且该幅度与原始信号的突变点幅度大致相同, 这为后续 PQDs 的准确识别和深入分析提供了坚实的基础。

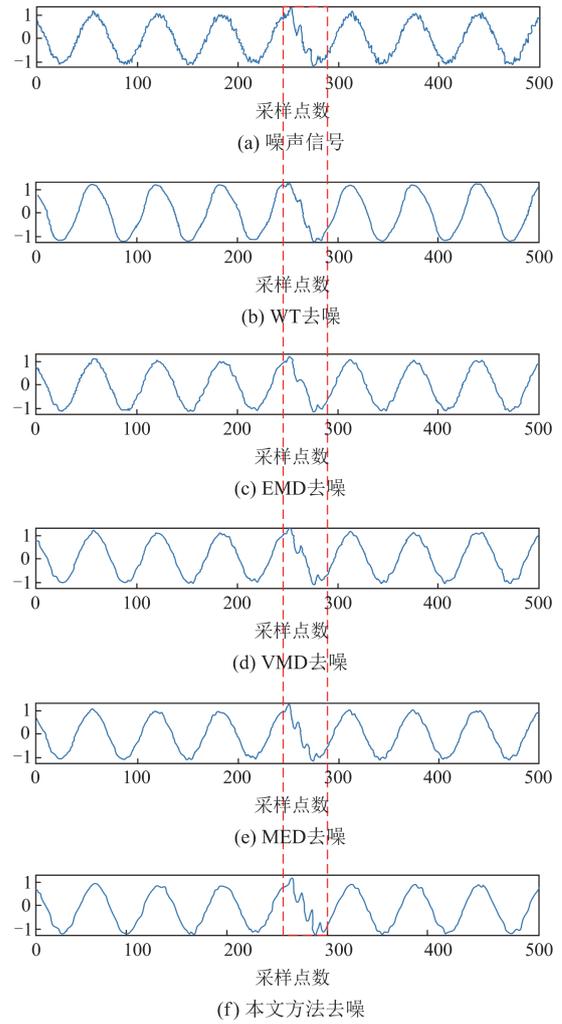


图 6 不同去噪方法下的去噪波形对比

Fig. 6 Waveform after different denoising methods

5.4 不同噪声类型的去噪性能对比

1/f 噪声和 Laplace 噪声对电能质量产生了不利影响, 但目前大部分研究仅针对高斯噪声, 为充分验证 NBD 去噪性能, 本节考虑 1/f 噪声和 Laplace 噪声环境的去噪性能, 上述两种噪声的具体生成方法分别参照式(21)、式(22)。

$$1/f: S(f) \propto \frac{1}{f^\alpha} \quad (21)$$

$$\text{Laplace: } l(x|\gamma, c) = \frac{1}{2c} e^{-\frac{|x-\gamma|}{c}} \quad (22)$$

式中: f 为随机确定的噪声频率, 设为 1; γ 为位置参数, $\gamma=0$; c 为尺度参数, $c=1$ 。

图 7 为选择 Transformer 作为分类器的前提下, 不同去噪方法对 30 dB 信噪比噪声的识别准确率。图 7 表明, 与其他方法相比, 本文方法在去除每类噪声时的识别准确率均为最高, 特别在去除 Laplace

噪声时比 MED 方法高出近 20%，这充分体现了 NBD 在不同类型噪声场景下的优越抗噪声性能。具体来说，高斯噪声最易处理，每种方法在高斯噪声下均展现了最佳效果；相反，1/f 噪声最具挑战性，表现最好的方法只有 84.35% 的识别准确率，可能是由于 1/f 噪声在频域中产生，可以干扰信号频率，这也解释了擅长处理频域信号的 FTD 去噪方法处理 1/f 噪声效果较好的原因。

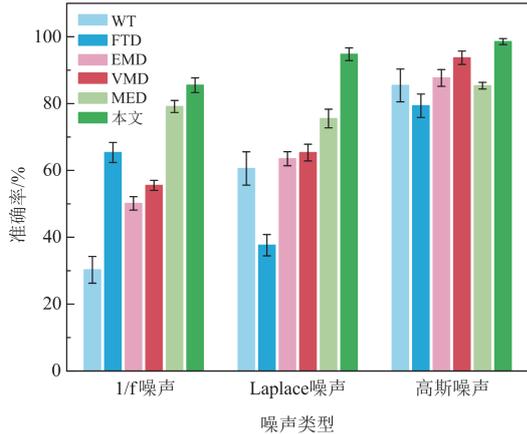


图 7 不同噪声类型下各方法的识别准确率
Fig. 7 Recognition accuracy of each method under different noise types

5.5 不同去噪模块计算成本和效率对比

本节总结了不同去噪方法的计算成本和效率。模型可训练参数数量 Parameters 影响模型的存储需求；模型在推理过程中浮点运算次数(floating point operations, FLOPs)影响模型的计算需求。Parameters 和 FLOPs 可以衡量模型计算复杂度和执行速度，两者共同反映模型处理数据能力。推理时间表示在 Intel Core(TM)i7-7700HQ @2.80 GHz CPU 上推断一个样本所花费的时间。

图 8 为不同去噪方法在 30 dB 信噪比下 PQDs 处理结果，图中气泡面积与该方法的 FLOPs 成正比，气泡上的数值为 FLOPs 值，单位为 M。Parameters 指标方面：WT>VMD>EMD>NBD>FTD>MED，本文方法 NBD 处于中间水平。与 WT 等相比，NBD 的参数数量较少，源于其不需要中心频段、模态数、惩罚因子、噪声容忍度等参数；但与 FTD 和 MED 相比，NBD 需要网络层和神经元数量、卷积核大小、步长等参数，故其参数数量多于 FTD 和 MED。本文所提方法 FLOPs 有最小值 3.39 M，推理时间最短，为 4.21 ms。总体而言，NBD 在计算成本和效率方面均具有较为出色的表现，可用作 PQDs 去噪有效模块。

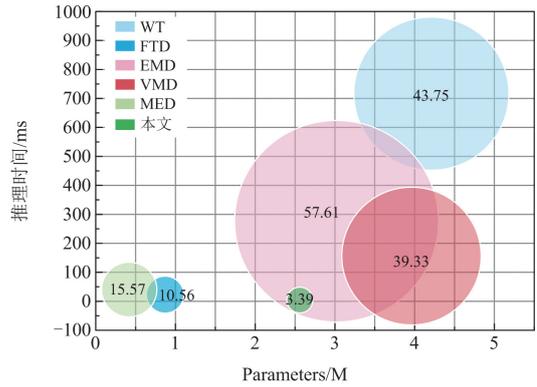


图 8 不同去噪模块计算成本和效率气泡图
Fig. 8 Bubble diagram for calculating cost and efficiency of different denoising modules

5.6 不同分类模块的 F1 分数对比

为证明本文采用的 Transformer 在多类别识别中的优良特性，本文搭建常用于 PQDs 识别的 MobileNetV3^[17]、EfficientNet^[18]、ResNet18^[19]、IDCNN^[20]和本文所提 Transformer 网络模型进行对比，对 25 类 PQDs 进行识别分类，设置每种样本类型共 1000 组数据，其中有 250 组为受不同信噪比的 1/f 噪声干扰数据，250 组为受不同信噪比的 Laplace 噪声干扰数据，另外 500 组为受不同信噪比的高斯噪声干扰的数据，将其他 4 种方法和本文所提方法在该数据集下分别进行 20 次重复实验，5 种模型 20 次的 F1 分数情况如图 9。

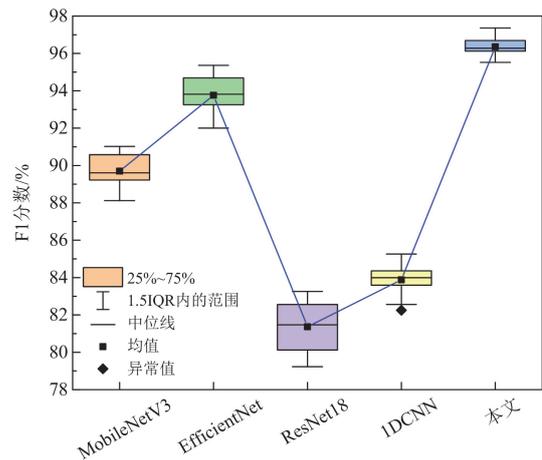


图 9 不同分类模块的 F1 分数对比
Fig. 9 F1 scores for different classification modules

由图 9 可知：总体来说，如此复杂的混合噪声数据集下，各种分类方法 F1 分数基本在 80% 以上，取得了良好的识别效果，这离不开 NBD 优异的去噪性能为深度学习分类打下的坚实基础，也离不开

联合损失函数对 NBD 和 Transformer 两个独立模块的联合优化。具体来说, Transformer 和 EfficientNet 更适用于多分类复合 PQDs 识别, 特别是 Transformer 方法 F1 分数均值达 96.18%, 具有最高的中位数和均值, 且 IQR 较小, 须部较短, 这主要是由于加入了多头注意力机制, 有助于捕捉更多特征; MobileNetV3 作为轻量级网络, 特征提取和分类能力处于中间水平; 1DCNN 结果中出现一个低值异常, 这可能与模型在某些情况下表现不稳定或噪声较为敏感有关; ResNet18 的分类效果最差, 这是由于更适合于图像数据而非一维数据。

5.7 联合损失函数构建的效果研究

本节将 NBD 和 Transformer 联合识别方法与 NBD、Transformer 各自独立识别方法进行对比。NBD 和 Transformer 联合识别方法采用式(19)联合损失函数作为模型优化的目标函数, NBD、Transformer 各自独立识别方法分别采用式(9)、式(16)作为优化 NBD 的目标函数, 采用式(17)作为单独优化 Transformer 的目标函数。设置样本数据同 5.6 节, 实验结果如图 10 所示。

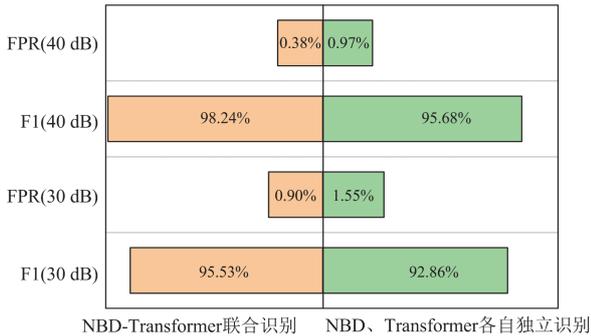


图 10 NBD 和 Transformer 联合识别方法的双边柱状图

Fig. 10 Double-sided bar chart identified jointly by NBD and Transformer

由图 10 可知, 本文所提的 NBD 和 Transformer 联合识别方法相对于 NBD、Transformer 作为两个独立模块进行 PQDs 识别方法, 在不同信噪比的混合噪声下都表现出卓越性能。

5.8 提高模型性能的潜在策略研究

30 dB 能够较好地模拟实际电网中的噪声条件, 本节选择 30 dB 高斯噪声场景来研究进一步提高 NBD 与 Transformer 性能的潜在策略。一个简单的策略是改变模型中的参数数量。NBD 的二次元层有两个关键参数: 通道数量、核大小; MSA 的头数是 Transformer 的重要参数, 本节改变这些参数的数量以了解它们对 PQDs 识别准确率的影响。结果如图 11 所示。

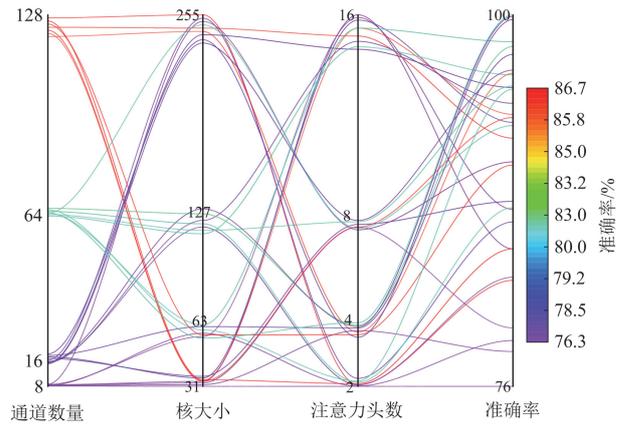


图 11 提高模型性能的潜在策略的平行坐标图

Fig. 11 A parallel coordinate plot of potential strategies for improving model's performance

图 11 显示的通道数量取值范围为[8, 16, 64, 128], 卷积核大小取值范围为[31, 63, 127, 255], 多头注意力的头数取值范围为[2, 4, 8, 16], 对交叉而成的 32 种参数组合进行分析。由结果发现数据中的结构和规律: 不同的参数组合产生不同的识别准确性, 较多的通道数和头数可提高识别准确率, 但一味追求较多的参数组合, 在增加计算复杂性的同时也增加了过拟合的风险, 最终导致识别结果不理想, 参数组合的选择规则是用尽可能少的参数组合达到更高的准确率。最优超参数组合为[64, 63, 4], 此时 PQDs 识别准确率高达 99.8%, 另外参数组合为 [16, 127, 4]时识别准确率效果达到较理想的 99.7%。

6 结论

PQDs 分类方法多在高斯噪声环境下进行识别, 但其识别精度和效率有待提高, 且未进一步探究 PQDs 在非高斯噪声下的识别情况。针对此不足, 本文提出基于 NBD 时频域去噪的 PQDs 联合识别方法, 并通过联合损失函数共同优化 NBD 与 Transformer 这两个相互独立的任务, 最终 PQDs 在非高斯噪声下识别精度和效率达到较高水平。通过仿真实验得到以下结论。

1) 对比 NBD 与其他去噪方法处理后 PQDs 的去噪波形、F1 分数、Parameters、FLOPs, 验证了 NBD 不仅适用于去除高斯噪声, 也可用于 1/f 噪声、Laplace 噪声去除, 改善了对多类型复杂 PQDs 数据序列的去噪性能。该去噪措施有利于后续模型的特征提取和分类。

2) 特征提取和分类模块采用 Transformer, 通过多头注意力机制捕获扰动信号的暂态局部特征和周

期性的稳态全局特征,使 1/f 噪声、Laplace 噪声、高斯噪声混合数据集的 F1 分数达到 96.18%,显示了 Transformer 优异的分类性能。

3) 优异的分类结果证明联合损失函数的构建成功将 NBD 与 Transformer 无缝衔接,实现了两个相互独立模块的联合优化。

本研究所提模型显著提升了 PQDs 识别效果,可为电能质量的监控和管理提供辅助决策支持。未来工作将基于识别结果,进一步对扰动源进行精确定位。

参考文献

- [1] 张博智,张茹,焦东翔,等.基于 VMD-SAST 的电能质量扰动分类识别方法[J].中国电力,2024,57(2):34-40.
ZHANG Bozhi, ZHANG Ru, JIAO Dongxiang, et al. Power quality disturbance identification method based on VMD-SAST[J]. Electric Power, 2024, 57(2): 34-40.
- [2] 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.
- [3] 李琦,许素安,施阁,等.基于 S 变换和 IWOA-SVM 的复合电能质量扰动识别[J].智慧电力,2023,51(5):30-35,50.
LI Qi, XU Su'an, SHI Ge, et al. Identification of composite power quality disturbance based on S-transform and IWOA-SVM[J]. Smart Power, 2023, 51(5): 30-35, 50.
- [4] 代义东,陆之洋,熊炜,等.基于 CDAE 和 TCN/BLSTM 模型的电能质量扰动分类方法[J].智慧电力,2023,51(12):59-66.
DAI Yidong, LU Zhiyang, XIONG Wei, et al. Power quality disturbance classification method based on CDAE and TCN/BLSTM models[J]. Smart Power, 2023, 51(12): 59-66.
- [5] CAICEDO J E, MARTÍNEZ A D, RIVAS-TRUJILLO E, et al. A systematic review of real-time detection and classification of power quality disturbances[J]. Protection and Control of Modern Power Systems, 2023, 8(1): 30-66.
- [6] 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.
- [7] 张震,刘明萍,张镇涛,等.基于 CEEMDAN 和小波软阈值的电能质量扰动信号去噪新方法[J].现代电子技术,2021,44(18):63-68.
ZHANG Zhen, LIU Mingping, ZHANG Zhentao, et al. A new method for power quality disturbance signal denoising based on CEEMDAN and wavelet soft threshold[J]. Modern Electronics Technique, 2021, 44(18): 63-68.
- [8] 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.
- [9] 朱琴跃,于逸尘,占岩文,等.基于短时傅里叶变换和深度网络的模块化多电平换流器子模块 IGBT 开路故障诊断[J].电工技术学报,2024,39(12):3840-3854.
ZHU Qinyue, YU Yichen, ZHAN Yanwen, et al. IGBT open-circuit fault diagnosis of modular multilevel converter sub-module based on short-time Fourier transform and deep networks[J]. Transactions of China Electrotechnical Society, 2024, 39(12): 3840-3854.
- [10] 王果,雷武,闵永智,等.改进 EEMD 算法在高压并联电抗器声信号去噪中的应用[J].电力系统保护与控制,2023,51(24):164-174.
WANG Guo, LEI Wu, MIN Yongzhi, et al. Application of an improved EEMD algorithm in high voltage shunt reactor sound signal denoising[J]. Power System Protection and Control, 2023, 51(24): 164-174.
- [11] 杨迪,王辉,贺仁杰,等.基于改进经验模态分解和混合深度学习模型的风速预测[J].智慧电力,2024,52(1):1-7.
YANG Di, WANG Hui, HE Renjie, et al. Wind speed prediction based on improved empirical mode decomposition and hybrid deep learning models[J]. Smart Power, 2024, 52(1): 1-7.
- [12] 张明龙,张振宇,高源,等.基于变分模态分解的暂态扰动波形去噪算法[J].电力系统保护与控制,2022,50(8):43-49.
ZHANG Minglong, ZHANG Zhenyu, GAO Yuan, et al. Transient disturbance waveform denoising algorithm based on variational mode decomposition[J]. Power System Protection and Control, 2022, 50(8): 43-49.
- [13] 马星河,师雪琳,赵军营.基于 POA-VMD-WT 的 MEMS 去噪方法[J].电子测量与仪器学报,2024,38(1):53-63.

- MA Xinghe, SHI Xuelin, ZHAO Junying. Denoising method of MEMS sensor signal based on POA-VMD-WT[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(1): 53-63.
- [14] 张新, 赵艺珂, 王家序, 等. 基于最大平均峭度盲解卷积的直升机故障诊断[J]. *振动、测试与诊断*, 2024, 44(3): 480-485, 617.
- ZHANG Xin, ZHAO Yike, WANG Jiayu, et al. Helicopter fault diagnosis by blind deconvolution based on average kurtosis maximization[J]. *Journal of Vibration, Measurement & Diagnosis*, 2024, 44(3): 480-485, 617.
- [15] YAN S, HONGWEI L, DI W, et al. Comprehensive exergoeconomic analysis and optimization of a novel zero-carbon-emission multi-generation system based on carbon dioxide cycle[J]. *Journal of Thermal Science*, 2024, 33(3): 1065-1081.
- [16] 何泽人, 彭珍瑞. 基于 SVD 和 MED 的滚动轴承特征提取[J]. *控制工程*, 2024, 31(5): 884-890.
- HE Zeren, PENG Zhenrui. Feature extraction of rolling bearing based on SVD and MED[J]. *Control Engineering of China*, 2024, 31(5): 884-890.
- [17] 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.
- [18] 付宽, 王洪新, 刘杰, 等. 基于马尔可夫变迁场和 EfficientNet 的复合电能质量扰动识别[J]. *电网与清洁能源*, 2024, 40(4): 74-83.
- FU Kuan, WANG Hongxin, LIU Jie, et al. Recognition of composite power quality disturbances based on MTF-EfficientNet convolutional neural network[J]. *Power System and Clean Energy*, 2024, 40(4): 74-83.
- [19] 兰名扬, 刘宇龙, 金涛, 等. 基于可视化轨迹圆和 ResNet18 的复合电能质量扰动类型识别[J]. *中国电机工程学报*, 2022, 42(17): 6274-6286.
- LAN Mingyang, LIU Yulong, JIN Tao, et al. An improved recognition method based on visual trajectory circle and ResnetN18 for complex power quality disturbances[J]. *Proceedings of the CSEE*, 2022, 42(17): 6274-6286.
- [20] 王立辉, 柯泳, 苏如开. 基于 1DCNN-BiLSTM-BiGRU 的电能质量扰动分类方法[J]. *电气技术*, 2024, 25(5): 51-56, 64.
- WANG Lihui, KE Yong, SU Rukai. The classification method of power quality disturbance based on 1DCNN-BiLSTM-BiGRU[J]. *Electrical Engineering*, 2024, 25(5): 51-56, 64.
- [21] 李贝奥, 李开成, 肖贤贵, 等. 基于多尺度卷积融合时间序列 Transformer 的复合电能质量扰动识别[J/OL]. *电网技术*: 1-12[2024-07-09]. <https://doi.org/10.13335/j.1000-3673.pst.2023.1764>
- LI Beiao, LI Kaicheng, XIAO Xiangui, et al. Compound power quality disturbances identification based on multi-scale fusion time series Transformer[J/OL]. *Power System Technology*: 1-12[2024-07-09]. <https://doi.org/10.13335/j.1000-3673.pst.2023.1764>
- [22] 刘璐, 何振亚. 盲源分离和盲反卷积[J]. *电子学报*, 2002(4): 570-576.
- LIU Ju, HE Zhenya. A survey of blind source separation and blind deconvolution[J]. *Acta Electronica Sinica*, 2002(4): 570-576.
- [23] FAN F, CONG W, WANG G. A new type of neurons for machine learning[J]. *International Journal for Numerical Methods in Biomedical Engineering*, 2018, 34(2).
- [24] FAN F, XIONG J, WANG G. Universal approximation with quadratic deep networks[J]. *Neural Networks*, 2020, 124: 383-392.
- [25] LIAO J, DONG H, SUN Z, et al. Attention-embedded quadratic network (attention) for effective and interpretable bearing fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1-13.
- [26] 方一胜. 基于改进 HHT 的电能质量扰动检测方法研究[D]. 郑州: 郑州大学, 2020.
- FANG Yisheng. Research on power quality disturbance detection method based on improved HHT[D]. Zhengzhou: Zhengzhou University, 2020.
- [27] GHEMARI Z. Concept and application of envelope spectrum analysis in the field of vibration signal processing[J]. *International Journal of Sensors, Wireless Communications and Control*, 2025, 15(2): 133-145.

收稿日期: 2025-01-13; 修回日期: 2025-04-16

作者简介:

郑博妍(2001—), 女, 硕士研究生, 研究方向为电能质量扰动识别方法; E-mail: 2909223359@qq.com

袁至(1984—), 男, 通信作者, 博士, 副教授, 博士生导师, 研究方向为可再生能源发电与并网控制。E-mail: yzisthecure@163.com

(编辑 周金梅)