

DOI: 10.19783/j.cnki.pspc.230846

基于双分支并联的特征融合电能质量扰动分类方法

王飞¹, 王立辉¹, 周少武², 赵才², 张志飞¹

(1. 佛山科学技术学院机电工程与自动化学院, 广东 佛山 528000;

2. 湖南科技大学机电工程与自动化学院, 湖南 湘潭 411201)

摘要: 为了提高对电能质量扰动信号(power quality disturbance signal, PQDs)在受到噪声和异常数据干扰时的分类准确率, 提出了一种双分支并联特征融合网络的 PQDs 分类方法。首先, 采用一维残差神经网络和一维卷积神经网络两个分支进行特征提取。然后, 通过特征融合模块将这些特征融合在一起。最终, 通过分类模块对 PQDs 进行准确分类。相对于串联神经网络, 所提方法融合特征向量, 增强了特征的区分度, 同时适用于并行计算, 进一步提高了识别速度。仿真结果表明, 所提方法在叠加信噪比为 13 dB、15 dB 和 18 dB 的 PQDs 分类任务中, 识别率均超过 95%, 此外, 该方法对异常数据的分类效果也具有一定的鲁棒性。

关键词: 一维卷积神经网络; 一维残差神经网络; 特征提取; 扰动分类

A dual-branch parallel-based feature fusion approach for power quality disturbance classification

WANG Fei¹, WANG Lihui¹, ZHOU Shaowu², ZHAO Cai², ZHANG Zhifei¹

(1. School of Mechatronic Engineering and Automation, Foshan University, Foshan 528000, China; 2. School of Mechanical and Electrical Engineering, Hunan University of Science and Technology, Xiangtan 411201, China)

Abstract: To enhance the classification accuracy of power quality disturbance signals (PQDs) in the presence of noise and abnormal data interference, this paper introduces a dual-branch parallel feature fusion network-based classification method. First, feature extraction of two branches is accomplished by using a one-dimensional residual neural network and a one-dimensional convolutional neural network. Then, these extracted features are fused together through a feature fusion module. Finally, a classification module is used to accurately classify PQDs. In contrast to serial neural networks, this approach combines feature vectors enhancing feature distinctiveness and is compatible with parallel computing, further improving recognition speed. Simulation results demonstrate that this method achieves recognition rates exceeding 95% for PQDs classification tasks with signal-to-noise ratios of 13 dB, 15 dB, and 18 dB. Additionally, the method exhibits a certain level of robustness in classifying abnormal data.

This work is supported by the National Natural Science Foundation of China (No. 51277056).

Key words: one-dimensional convolutional neural network; one-dimensional residual neural network; feature extraction; disturbance classification

0 引言

在理想状态下, 电力系统向用电客户传输的是幅值恒定和频率恒定的正弦交流电。然而, 在实际情况中, 随着新能源的广泛整合和非线性负载的强烈冲击, 电流和电压波形开始发生畸变^[1], 从而引

发电能质量扰动问题。在电网中, 一个微小的突变也会给电力电子设备造成较大影响甚至毁坏, 因此电能质量的治理和改善已经刻不容缓^[2]。电能质量扰动信号(power quality disturbance signals, PQDs)的检测和识别是解决电能问题的前提^[3-4], 因此, 在大量的电能质量扰动中有效地提取信号并正确分类是改善电能质量首先需要解决的问题。

传统的电能质量扰动识别包括特征提取和分类两个步骤, 特征提取方法有傅里叶变换^[5]、小波变

基金项目: 国家自然科学基金项目资助(51277056); 湖南省自然科学基金项目资助(2021JJ30280)

换^[6]、S 变换^[7]、希尔伯特-黄变换^[8-9]等, 其中傅里叶变换无法反映局部特征, 对于突变信号无法应用; 小波变换对于基函数的选取依靠经验, 没有可靠的理论依据支撑; S 变换虽然提供的时频信号丰富, 但是运算量较大, 对计算环境要求很高; 希尔伯特-黄变换在信号去噪中具有优势, 但其因果性和无界性限制对模型影响大, 特征选择依赖规则或人工提取, 缺乏统一的理论支持, 从而分类特征不具有-般性, 对于不同的数据集, 分类结果会产生较大的差异。分类是基于提取的特征向量对 PQDs 进行识别的过程, 常见的分类方法有支持向量机^[10]、随机森林^[11]、人工神经网络^[12-13]、BP 神经网络^[14]等, 其中支持向量机在分类问题中具有较高的准确性和较强的泛化能力, 但需要精心选择参数, 对于大规模高维数据和样本不平衡情况处理较为困难; 随机森林在分类任务中表现出极高的准确性, 同时具备处理复杂特征关系和多类别问题的能力, 但它也存在一些缺点, 如参数调优和预测时间较长; 人工神经网络在分类方面擅长处理复杂的非线性关系, 然而, 其应用受制于对大量数据的依赖、复杂的参数调优过程以及模型解释性较差等问题; BP 神经网络具有强大的逼近能力和学习能力, 但缺点是训练时间长、容易陷入局部最优解、需要大量标记数据。文献[15]提出了一种基于稀疏分解的分类新方法, 通过构建正余弦字典、脉冲字典将 PQDs 分解为近似部分和细节部分, 并从中提取了 8 个特征量, 但较少的特征量可能无法完整地表达数据的特征和信息。文献[16]利用傅里叶变换结合动态测度法提取了 6 个特征、并借助 S 变换提取了 5 个特征, 共提取 11 个特征用于 PQDs 分类, 但是其方法对于双重扰动分类效果有待提高。以上算法均需对信号进行人工特征选取, 容易产生特征冗余, 而且会丢失一些其他的特征, 导致分类效果不理想和抗噪性能不强。为了解决人工特征提取的缺点, 文献[17]提出一种基于双通道格拉姆角场(Graham angular field, GAF)与深度残差神经网络的电能质量扰动分类方法, 但其方法要把 PQDs 转换成 GAF 图片进行分类识别, 这会增加计算量和计算时间。文献[18]使用维格纳-维尔分布(Wigner-Ville distribution, WVD)将一维电压干扰信号转换为二维图像, 然后使用二维卷积模型进行图像分类, 但其方法在把 PQDs 转化为图片时会增加计算量和计算时间。文献[17-18]虽然不需要特征提取, 但是需要将电能质量扰动信号转换为二维图像, 然后采用二维卷积网络进行图像识别, 但转换过程复杂。对于一维时间序列电能质量扰动信号, 使用一维卷积神经网络(one-dimensional

convolutional neural network, 1D-CNN)可提高计算效率。文献[19]提出一种基于多特征融合卷积神经网络 PQDs 识别模型, 它的优点是模型结合了时域和频域信息, 提高了网络中不同层的多样性特征。文献[20]提出了一维多尺度深度残差网络对电能质量扰动进行分类的方法, 它的优点在于多尺度卷积操作可以捕捉不同时间尺度上的特征, 有助于更全面地理解 PQDs 的特征。

本文根据现有的 1D-CNN 的分类方法, 提出一种基于 1D-CNN 和残差网络的特征融合 PQDs 分类方法。在此方法中, 分别使用 1D-CNN 和一维残差神经网络对 PQDs 进行特征提取, 随后, 通过融合模块将提取的特征进行融合, 然后将融合后的特征输入分类模块进行分类识别。这种方法使得分类网络的泛化能力和鲁棒性变强, 是一种对电能质量复合扰动分类效果良好的方法。

1 一维卷积神经网络和一维残差神经网络

1.1 一维卷积神经网络

在深度学习领域中, 1D-CNN 是一种用于处理时间序列数据的深度学习模型。与传统的机器学习方法相比, 1D-CNN 在处理一维序列数据方面具有很好的性能, 适用于许多任务, 如文本分类、语音识别、信号处理等。它能够自动学习序列数据中的局部模式和抽象特征, 并具备平移不变性, 可以处理不同位置的特征。同时, 1D-CNN 的参数共享和并行计算特性使其能够高效地处理大规模序列数据, 并加速模型的训练和推断过程。其基本结构为输入层、卷积层、池化层、全连接层及 Softmax 层, 如图 1 所示。

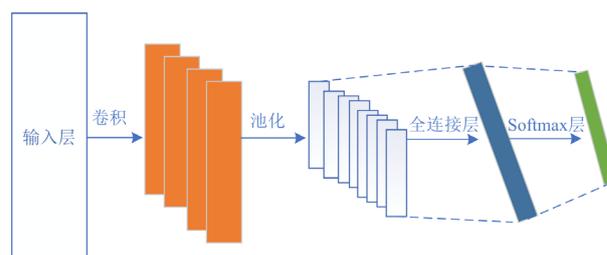


图 1 卷积神经网络结构图

Fig. 1 Architecture diagram of convolutional neural network

1.2 一维残差神经网络

文献[21]提出在卷积神经网络中引入残差结构, 以解决深层网络结构因连续非线性映射导致的退化问题, 使得搭建更深层次的网络结构变得可能。此外, 残差结构可以更好地提取不同类型数据的更细微差异特征, 从而弥补了 1D-CNN 网络结构在层

数过多时每一层变换可能导致信息损失(梯度消失)的缺陷,进而解决特征表示的瓶颈问题。

2 并联特征融合模型

2.1 模型框架

由于一维电能质量扰动数据复杂性低,因此可以采用层级浅的网络进行 PQDs 的分类识别,并且 1D-CNN 与 PQDs 的维数更为契合,无须进行数据重构和特征提取,而传统电能质量扰动分类模型需要人为特征提取,所以相对于传统方法,1D-CNN 在很大程度上提高了模型分类效率。

本文所提出的并联特征融合模型结构如图 2 所示,模型含有 4 个子模块,其中包括 2 个特征提取模块、1 个特征融合模块、1 个分类模块。其中特征提取模块的作用是对 PQDs 数据进行降维并提取 PQDs 具有较高区分度的时间特征向量(A 和 B);特征融合模块的作用是将来自不同特征提取器中提

取的特征信息进行整合和融合,生成更具有综合性和表征能力的特征,从而提高特征的鉴别能力,缓解特征冗余和噪声,进而提升模型的性能;分类模块的作用是接收融合特征并进行分类识别。特征融合模块分别使用加法融合(以 e 为底的指数化特征逐元素相加)、乘法融合(以 e 为底的指数化特征逐元素相乘)、连接融合(以 e 为底的指数化特征按维度进行 CAT 拼接)并进行效果对比,从而得出最优的融合方法。采用以 e 为底数的指数化特征是为了扩大不同特征值之间的距离,从而突出重要特征。具体的融合公式为

$$e^A + e^B = [e^{a_1} + e^{b_1}, e^{a_2} + e^{b_2}, \dots, e^{a_n} + e^{b_n}] \quad (1)$$

式中: a_1, a_2, \dots, a_n 为 A 的分量; b_1, b_2, \dots, b_n 为 B 的分量。

$$e^A \cdot e^B = [e^{a_1+b_1}, e^{a_2+b_2}, \dots, e^{a_n+b_n}] \quad (2)$$

$$e^A, e^B = [e^{a_1}, e^{a_2}, \dots, e^{a_n}, e^{b_1}, e^{b_2}, \dots, e^{b_n}] \quad (3)$$

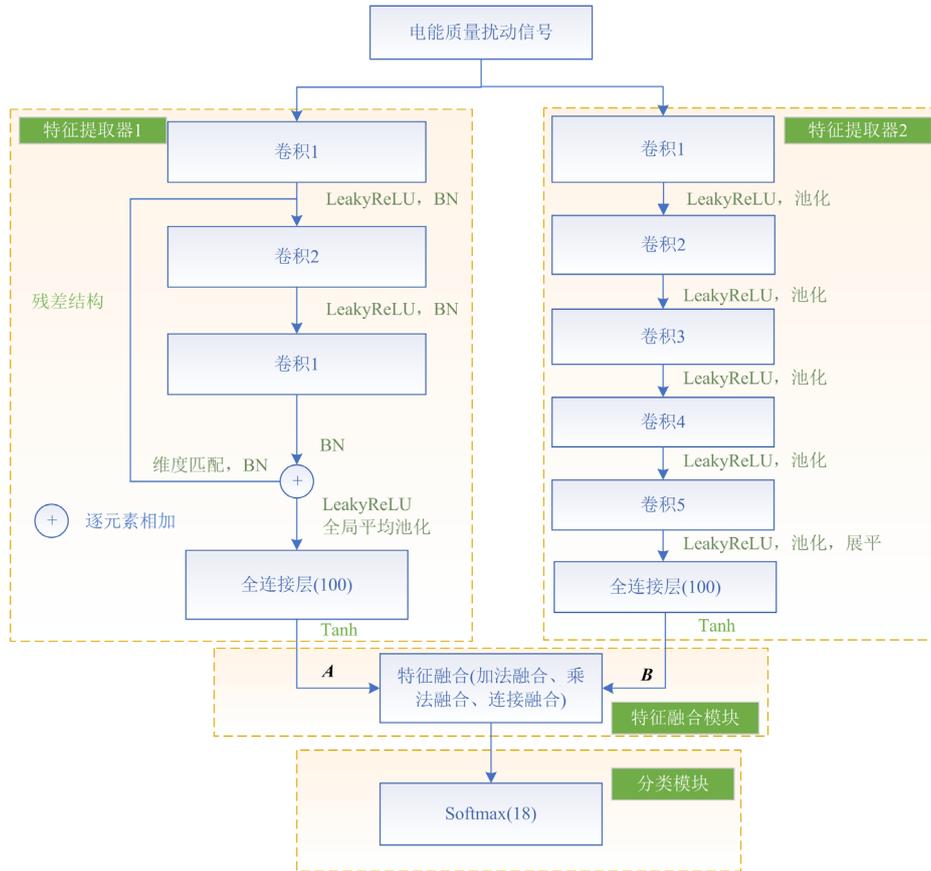


图 2 模型结构图

Fig. 2 Model architecture diagram

一维残差神经网络(特征提取器 1)仅含 3 个卷积层、1 个全局平均池化层、1 个残差结构、1 个全连接层。它的层数较浅,更浅层的网络决定了更小

的参数数量,进一步提高了特征提取器的效率,使其能够更有效地提取特征。为了使并联特征融合模型具有效果更佳分类效果,需要对残差网络结构和

1D-CNN(特征提取器 2)进行设计, 从而满足模型特征提取的多样化。特征提取器 2 使用小卷积核堆叠的结构, 相对于特征提取器 1 使用小卷积核的特点, 特征提取器 1 使用一些大的卷积核可以检测到扰动数据长期的时间依赖关系和全局模式, 从而使分类模型增强了特征表达能力。因此特征提取器 1 的第一层设计为 64×1 的大卷积核, 第二层为 32×1 的大卷积核, 第三层为 4×1 的小卷积核。为了不同层级之间进行空间维度的匹配, 设计残差结构的卷积核大小为 1×1 、步长为 1。池化层为全局全局池化, 全连接层为 100 个神经元。本文特征提取器 1 的具体参数如表 1 所示。

表 1 特征提取器 1 的参数结构

Table 1 Parameter structure of the feature extractor 1

层	卷积核/神经元个数	步长	激活函数	输出尺寸
输入层	—	—	—	1200×1
卷积层 1	$64 \times 1 \times 64$	2	LeakyRelu	600×64
卷积层 2	$32 \times 64 \times 64$	1	LeakyRelu	600×64
卷积层 3	$4 \times 64 \times 64$	1	LeakyRelu	600×64
残差层	$1 \times 64 \times 64$	1	LeakyRelu	600×64
池化层	—	—	—	64
全连接层	100	—	Tanh	100

特征提取器 2 由输入层、5 层卷积、5 层最大池化、展平层以及 1 个 100 神经元的全连接层组成, 其中使用小卷积核的目的是小卷积核更关注细节和局部模式, 并且它能够检测到数据中更小的时间尺度的变化和模式。特征提取器 2 的具体参数如表 2 所示。

表 2 特征提取器 2 的参数结构

Table 2 Parameter structure of the feature extractor 2

层	卷积核/神经元个数	步长	激活函数	输出尺寸
输入层	—	—	—	1200×1
卷积 1	$4 \times 1 \times 32$	2	LeakyRelu	600×32
池化 1	2×1	2		300×32
卷积 2	$4 \times 32 \times 32$	2	LeakyRelu	150×32
池化 2	2×1	2		75×32
卷积 3	$4 \times 32 \times 64$	2	LeakyRelu	38×64
池化 3	2×1	2		19×64
卷积 4	$3 \times 64 \times 64$	1	LeakyRelu	19×64
池化 4	2×1	2		8×64
卷积 5	$2 \times 64 \times 64$	1	LeakyRelu	8×64
池化 5	2×1	2		4×64
展平层	—	—	—	256
全连接层	100	—	Tanh	100

2.2 模型训练

所提方法的训练流程如图 3 所示, 它包括数据分割、模型训练和模型评估 3 部分。其中数据分割将扰动数据集按照 14:3:3 的比例划分为训练集、验证集和测试集; 模型训练是使用训练集进行模型参数更新优化, 达到最大训练次数后数停止训练进行参数保护, 然后使用验证集进行超参数的调整, 最后固定模型; 模型评估是使用测试集对训练好的模型进行性能评估的过程, 从而验证本文模型在扰动分类方面的准确性、抗干扰能力和泛化能力是否良好。

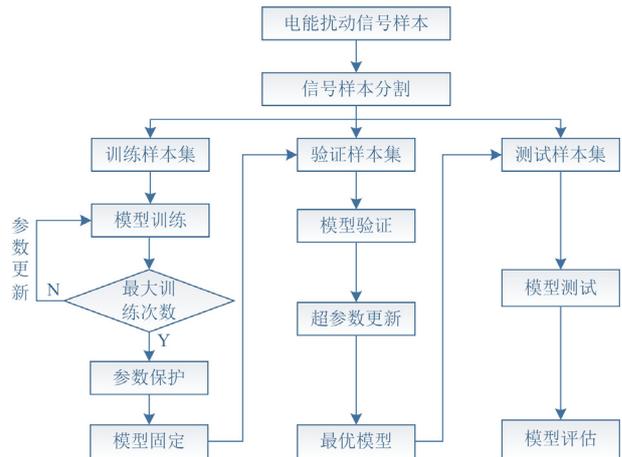


图 3 训练流程图

Fig. 3 Training workflow diagram

3 方法验证

3.1 实验设置和扰动数据仿真

实验中计算机的处理器、RAM 分别为 8 核的 AMD Ryzen 7 6800H CPU 和 16 GB、GPU 为 NVIDIA GeForce RTX 3060。本文的模型训练使用 Adam 优化算法更新网络参数, 学习率为 0.0002, 迭代次数为 50 次, 每个训练批次有 256 个样本。激活函数 LeakyRelu 中的参数为 0.01, 整个实验使用的软件平台为 Tensorflow2.7.0, 损失函数选择交叉熵损失函数。

本文共考虑如表 3 所示的 18 种扰动信号, 包含表 4 中的 7 种单一 PQDs(R1—R7), 11 种复合扰动则由单一扰动信号模型复合而成。参数变化符合 IEEE-1159 标准^[22], 其中基波频率 w 为 50 Hz, 幅值 X 为 1 V, 采样周期为 T , 采集长度为 10 个周期 (0.2 s), 采样频率为 5995 Hz, 总共 1200 个采样点, $u(t)$ 为单位阶跃信号。按照上述的数学模型随机更改约束参数可以生成大量数据, 为了较好地模拟真实数据, 在合成 PQDs 数据时分别叠加信噪比为 0 dB、20 dB、40 dB、60 dB 的高斯白噪声, 共生成了 72 000 个扰动信号样本, 用于模型的训练。另外

生成叠加信噪比为 13 dB、15 dB、18 dB 的扰动信号共 27 000 个,用于测试模型的抗强噪声能力和泛化能力。

3.2 性能评估

本文的特征融合模块选用加法融合、乘法融合、连接融合 3 种方式,使用 3.1 节的数据经过 50 轮迭代训练,3 种方式对于电能扰动的分类效果如表 5 所示,3 种融合方式的识别率均超过 99.4%,但乘法融合的性能明显优于其他两种方式。

3 种方式的训练准确率曲线和验证准确率曲线如图 4 所示。

表 3 电能质量扰动信号类型

Table 3 Types of electric power quality disturbance signal

标签	信号类型	标签	信号类型
R1	谐波	R10	谐波+电压中断
R2	闪变	R11	谐波+暂态脉冲
R3	电压暂升	R12	谐波+暂态振荡
R4	电压暂降	R13	谐波+闪变
R5	电压中断	R14	暂态脉冲+暂态振荡
R6	暂态振荡	R15	闪变+电压暂降
R7	暂态脉冲	R16	闪变+电压暂升
R8	谐波+电压暂降	R17	电压暂升+谐波+闪变
R9	谐波+电压暂升	R18	谐波+暂态振荡+暂态脉冲

表 4 几种典型扰动信号

Table 4 Several typical disturbance signals

类型号	扰动类型	信号模型	参数范围
R1	谐波	$y(t) = X[\alpha_1 \sin(\omega t) + \alpha_2 \sin(\omega t) + \alpha_3 \sin(\omega t) + \alpha_4 \sin(\omega t)]$	$0.05 \leq \alpha_1, \alpha_2, \alpha_3, \alpha_4 \leq 0.15, \sum \alpha_i^2 = 1$
R2	闪变	$y(t) = X[1 + \alpha \sin(\beta \omega t)] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.2, 0.1 \leq \beta \leq 0.3$
R3	电压暂升	$y(t) = X[1 + \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 9T$
R4	电压暂降	$y(t) = X[1 - \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 9T$
R5	电压中断	$y(t) = X[1 - \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.9 \leq \alpha \leq 1, T \leq t_2 - t_1 \leq 9T$
R6	暂态振荡	$y(t) = X[\sin(\omega t) + \alpha e^{-\tau(t-t_1)} \sin(\beta \omega t)(u(t_2) - u(t_1))]$	$0.05 \leq \alpha \leq 1, 0.5T \leq t_2 - t_1 \leq 3T$
R7	暂态脉冲	$y(t) = X[\sin(\omega t) + \alpha(u(t-t_2) - u(t-t_1))]$	$1 \leq \alpha \leq 3, T/20 \leq t_2 - t_1 \leq T/10$

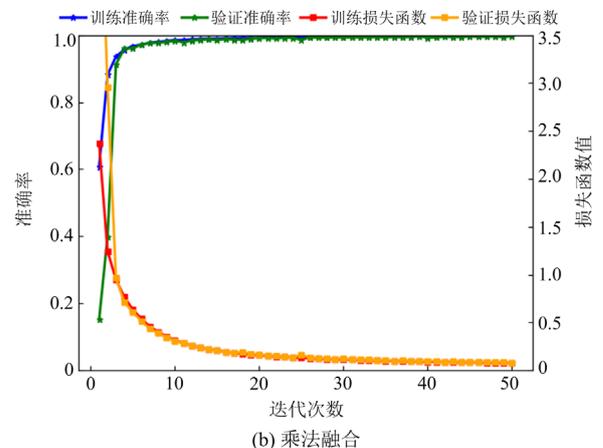
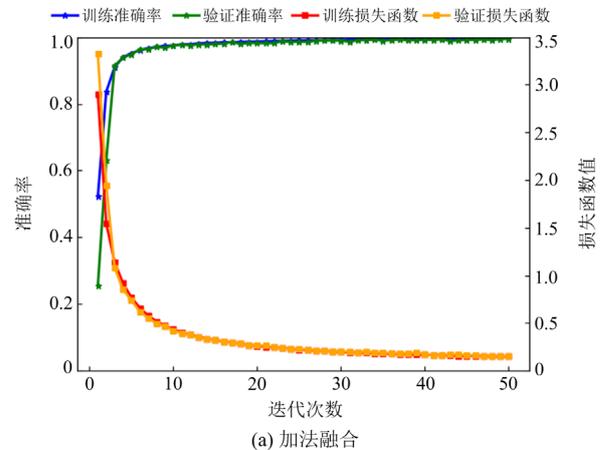
表 5 3 种融合模型分类效果

Table 5 Classification effects of three fusion models

融合策略	准确率/%			
	无噪声	60 dB	40 dB	20 dB
加法融合	99.43	99.57	99.58	99.43
乘法融合	99.63	99.80	99.84	99.69
连接融合	99.51	99.67	99.58	99.51

根据图 4 的结果,可以观察到 3 种方法在训练过程中都表现出了稳定的趋势,且它们都展现了较快的收敛速度。此外,本文对叠加信噪比分别为 13 dB、15 dB 和 18 dB 的扰动信号进行了测试,以验证本文模型在面对强噪声干扰时的性能。验证结果如表 6 所示,从表 6 中可以看出,乘法融合方法在不同信噪比条件下都表现出更高的识别率,超过了加法融合和连接融合方法。特别值得注意的是,在叠加信噪比为 13 dB 的强噪声情况下,乘法融合仍然实现了卓越的 PQDs 识别率,达到了 95.79%。进一步证明了乘法融合是一种有效的抗干扰策略。

乘法融合的优势在于其能够全面考虑每对特征元素之间的交互关系。乘法融合还在处理异常值(特别是极大或极小的值)时表现出较好的鲁棒性,因为它在相乘时不容易导致数值迅速增长。与之相比,加法融合和连接融合较为敏感,容易受到异常值的影响。



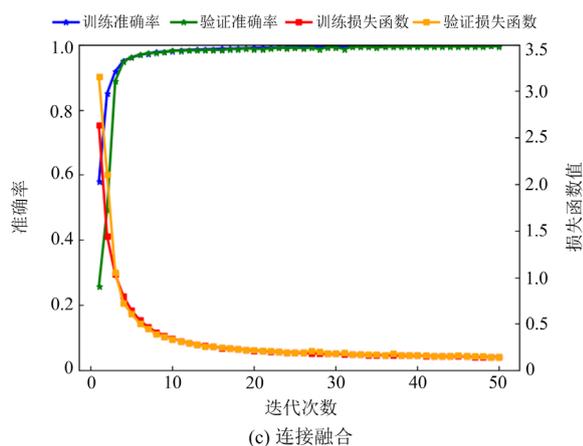


图 4 3 种融合方法的模型训练情况

Fig. 4 Training results of three fusion methods

表 6 强噪声扰动分类结果

Table 6 Classification results of strong noise disturbance

融合策略	准确率/%		
	18 dB	15 dB	13 dB
加法融合	99.34	98.10	95.79
乘法融合	99.70	98.51	95.97
连接融合	99.36	97.76	94.33

为验证特征融合模块的特征易于分类以及其在抗噪能力方面的优势, 将乘法融合的特征与其他 7 种分类模型(包括支持向量机、随机森林、BP 神经网络、逻辑回归、K 最近邻算法(K-nearest neighbors, KNN)、决策树以及朴素贝叶斯)进行分类比较。通过对不同信噪比情况下的分类结果进行评估和对比, 从而进一步验证特征融合模块所提取的特征在分类任务中具有显著的优势, 并展示其在面对噪声干扰时的优越表现, 其分类结果如表 7 所示。

根据表 7 的结果, 乘法融合的特征在所有分类模型中都表现出较好的分类性能, 尤其在叠加信噪比为 18 dB 的 PQDs 上, 各分类模型分类准确率均达到了 98.3% 以上。然而, 对于信噪比为 15 dB 的情况, 决策树和朴素贝叶斯分类器相比其他分类模型表现稍逊, 其分类准确率为 96.4% 以上。而在信噪比为 13 dB 的情况下, 随机森林、决策树和朴素贝叶斯的分类效果不佳, 其分类准确率不到 93.1%。综上所述, 乘法融合的特征在分类任务中展现了出色的性能, 表明乘法融合是一种有效的分类方法。然而, 对于不同信噪比情况下的数据, 各分类器的表现可能存在差异, 因此在实际应用中需要根据具体情况选择合适的分类器或采用更灵活的融合策略, 以获得最佳的分类结果。

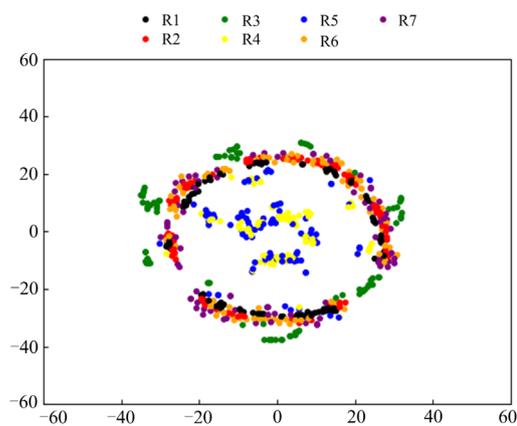
表 7 其他模型的分类结果

Table 7 Classification results of other models

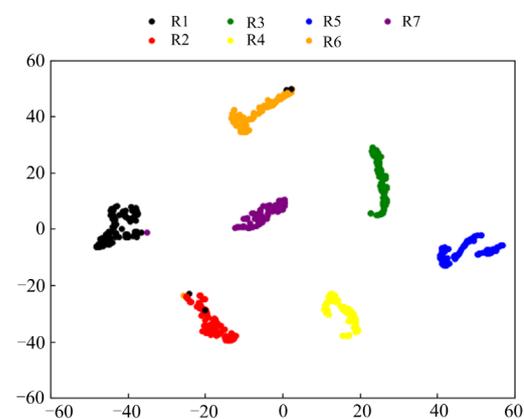
融合策略	准确率/%		
	18 dB	15 dB	13 dB
乘法融合 + 支持向量机	99.77	98.29	94.93
乘法融合 + 随机森林	99.69	96.44	86.09
乘法融合 + BP	99.74	97.78	93.56
乘法融合 + 逻辑回归	99.76	97.50	93.19
乘法融合 + KNN	99.79	98.61	95.89
乘法融合 + 决策树	98.63	91.44	79.23
乘法融合 + 朴素贝叶斯	98.32	92.52	81.47

3.3 特征可视化

为了更加直观地说明所提特征融合网络对特征区分度的影响, 通过 t 分布随机邻域嵌入(t-distributed stochastic neighbor embedding, t-SNE)降维可视化方法, 将叠加信噪比为 13 dB 的 7 种单一扰动(R1—R7)的原始数据和融合模块的特征降成二维并可视化, 如图 5 所示, 横纵坐标表示二维特征空间的 2 个维度。图 5(a)展示对原始扰动数据的可视化结果, 在特征提取之前 7 种单一扰动特征难以辨识, 呈现



(a) 原始扰动数据可视化结果



(b) 加法融合特征提取后可视化结果

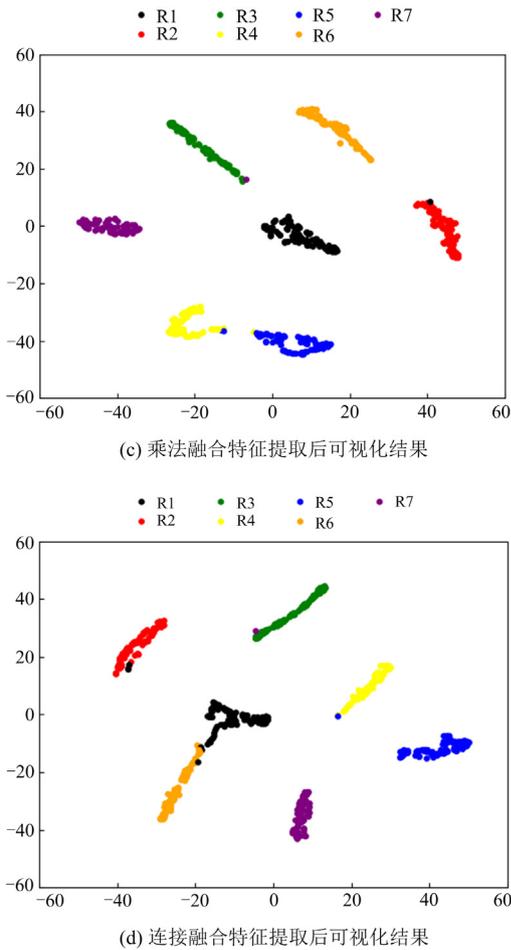


图 5 t-SNE 特征可视化

Fig. 5 Feature visualization with t-SNE

出无规律的分布，即它们在原始数据空间中难以区分。图 5(b)、图 5(c)、图 5(d)分别展示加法融合、乘法融合、连接融合网络提取特征后的可视化结果，从图中可知连接融合存在明显的交叉现象，加法融合有 6 个点被归于其他类别，而乘法融合有 4 个点被归于其他类别，且每种单一扰动聚集成一个簇，并且不同扰动类别之间存在明显的距离，说明特征具有很高的可区分性，容易进行分类。

3.4 分类效果

将本文所提乘法融合算法与现有的扰动识别算法进行对比，进一步分析本文方法的优越性。3 种传统方法分别是采用改进局部均值分解和概率神经网络的方法^[23]、采用可调品质因子小波变换和支持向量机的方法^[24]以及采用能量熵和功率谱熵的组合重构特征并结合双层前馈神经网络的方法^[25]。另外，将本文方法与文献[26]中采用的一维卷积神经网络多任务学习方法以及文献[27]中采用的多层卷积神经网络和注意力机制构建的方法在同一环

境下的扰动分类进行了实验对比，对比结果如表 8 所示。

表 8 本文所提方法与现有方法的对比

Table 8 Comparison with proposed method and existing methods

方法	PQDs 种类	特征提取	不同信噪比下的准确率/%		
			无噪声	40 dB	20 dB
文献[23]	6	人工	98.20	—	—
文献[24]	14	人工	—	99.07	97.79
文献[25]	14	人工	98.57	98.10	97.26
文献[26]	10	自动	—	99.38	96.65
文献[27]	18	自动	—	99.56	95.00
本文乘法融合	18	自动	99.63	99.80	99.69

由表 8 可知，相较于传统 PQDs 分类方法，本文自动提取特征的扰动分类方法在各个噪声水平下的识别精度优于传统的人工特征提取的分类方法。此外，本文方法解决了人工选取特征仅在特定扰动下具有良好识别效果以及对扰动识别数量的限制问题。与现有的深度学习方法相比，本文方法在分类准确率和分类数量方面均优于文献[26]。此外，相对于文献[27]，本文方法在相同的分类数量下表现出更高的准确率。尤其值得注意的是，在信噪比为 20 dB 的情况下，本文方法的准确率明显超过了文献[27]。

为了验证本文方法在处理异常数据时的分类效果，本文使用 3 种叠加信噪比为 30 dB 的扰动信号 (R1、R2、R3)，每种类型包含了尖刺(幅值在 1~1.5 V 之间变化)、换相和变频(频率在 47~53 Hz 范围内变化) 3 种异常情况，每种异常类型均包含了 100 个样本。具体分类结果如表 9 所示，从表 9 中可以清晰地看到本文的分类方法在处理异常数据时取得了卓越的效果，识别准确率达到 99% 以上，进一步证明了本文方法在应对异常数据分类方面具有较高的可靠性。

表 9 异常数据分类结果

Table 9 Classification results for anomalous data

信号类型	准确率/%		
	换相	尖刺	变频
R1	100.00	100.00	99.00
R2	100.00	99.00	100.00
R3	100.00	99.00	99.00

为了证实本文方法的有效性，将乘法融合方法与文献[28]的方法进行了全方面比较，具体如表 10 所示。从表 10 中可以看出，本文提出的方法在无噪声和含有叠加噪声时扰动分类的平均准确率都较为良好，与文献[28]相比，本文能够处理文献[28]不能处理的信号(表中“*”)，适应范围广泛，分类的平均准确率也有了很大的提升，并且该方法在复合扰动

方面也有着较好的效果, 是一种在噪声背景下适合 PQDs 分类的方法。

表 10 扰动分类结果对比

Table 10 Comparison of perturbation classification results

扰动类型	分类准确率/%							
	文献[28]方法				本文方法			
	无噪声	60 dB	40 dB	20 dB	无噪声	60 dB	40 dB	20 dB
R1	97.78	*	97.78	95.00	100.00	100.00	100.00	100.00
R2	*	*	*	*	100.00	100.00	100.00	100.00
R3	98.89	*	98.89	98.33	100.00	100.00	100.00	99.90
R4	100.00	*	100.00	98.89	100.00	100.00	100.00	100.00
R5	98.89	*	98.89	97.78	99.80	100.00	100.00	99.80
R6	96.67	*	96.11	95.56	100.00	100.00	100.00	100.00
R7	100.00	*	99.44	98.33	100.00	100.00	100.00	100.00
R8	96.67	*	95.56	94.44	98.10	98.70	99.20	99.10
R9	96.67	*	94.44	93.33	100.00	100.00	99.80	99.20
R10	96.67	*	96.11	95.00	99.90	100.00	100.00	99.30
R11	95.56	*	95.56	93.33	100.00	100.00	100.00	100.00
R12	*	*	*	*	99.40	99.80	99.50	99.40
R13	*	*	*	*	99.40	100.00	99.80	99.80
R14	*	*	*	*	99.90	100.00	100.00	100.00
R15	*	*	*	*	99.60	99.60	100.00	99.80
R16	*	*	*	*	99.40	99.80	99.80	99.50
R17	*	*	*	*	97.90	98.50	98.90	98.50
R18	*	*	*	*	99.90	100.00	100.00	100.00
平均准确率/%	97.78	*	96.78	96.00	99.63	99.80	99.84	99.69

4 结论

针对 1D-CNN 在 PQDs 识别中易受噪声和异常数据的影响从而导致识别率低的问题, 本文提出了一种并联特征融合网络的 PQDs 分类算法, 主要贡献体现在 3 个方面: 1) 使用一维残差神经网络和 1D-CNN 的两个特征提取器进行特征提取, 然后通过特征融合模块将特征融合在一起, 从而强化特征间的互补性, 提供更丰富的特征表示; 2) 通过对比 3 种不同的以 e 为底的指数化特征融合方法, 得出分类效果最优的方法; 3) 采用小巧型的卷积网络和残差网络, 总共包含了 223 842 个参数, 这一规模的参数数量使得计算量适中, 同时在实际应用中也能够满足性能要求。主要结论如下。

1) 本文提出以 e 为底的指数化特征融合可以更好地处理数值稳定性问题, 避免数值下溢, 并增强非线性关系和突出重要特征。

2) 本文提出并联特征融合的 PQDs 分类网络可以综合多种特征信息, 可以有效地降低噪声对分类结果的影响, 提升模型分类性能和泛化能力。

3) 文中所提乘法融合方法对叠加信噪比为 13 dB、15 dB、18 dB 的 PQDs 的识别率都达到了 95% 以上, 与其他分类方法进行比较, 结果表明, 该方法在分类准确率、抗噪性方面具有更好的性能, 为电力系统中的电能故障诊断提供有效的支持。

参考文献

- [1] 陈池瑶, 苗世洪, 殷浩然, 等. 基于注意力机制-卷积神经网络的配电网单相接地故障选线方法[J]. 电力建设, 2023, 44(4): 82-93.
CHEN Chiyao, MIAO Shihong, YIN Haoran, et al. Single-phase grounding-fault line selection method based on attention mechanism-convolution neural network for distribution network[J]. Electric Power Construction, 2023, 44(4): 82-93.
- [2] 汪飞, 全晓庆, 任林涛. 电能质量扰动检测与识别方法研究综述[J]. 中国电机工程学报, 2021, 41(12): 4104-4121.
WANG Fei, QUAN Xiaoqing, REN Lintao. Review of power quality disturbance detection and identification methods[J]. Proceedings of the CSEE, 2021, 41(12): 4104-4121.

- [3] 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.
- [4] 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.
- [5] KUMAR B N, MANIKANDAN M S, KARANKI S B. Integrated hilbert-fast Hourier Transform approach for detection and classification of power quality disturbances[C] // Proceedings of the 2021 National Power Electronics Conference (NPEC), December 15-17, 2021, Bhubaneswar, India: 1-6.
- [6] PATTANAIK D, SWAIN S C, SAMANTA I S, et al. Synchrosqueezed wavelet transform based power quality disturbance detection and monitoring of solar integrated micro-grid[C] // Proceedings of the 2023 International Conference on Power Electronics and Energy (ICPEE), January 3-5, 2023, Bhubaneswar, India: 1-6.
- [7] KUMAR R, KUMAR R, MARWAHA S, et al. S-transform based detection of multiple and multistage power quality disturbances[C] // Proceedings of the 2020 IEEE 9th Power India International Conference (PIICON), February 28-March 1, 2020, Sonapat, India: 1-5.
- [8] WANG Yang, LI Qunzhan, ZHOU Fulin, et al. A new method with hilbert transform and slip-SVD-based noise-suppression algorithm for noisy power quality monitoring[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(4): 987-1001.
- [9] 陈向群, 杨茂涛, 刘谋海, 等. 基于模糊聚类分析的电能质量扰动模式识别方法[J]. 电力科学与技术学报, 2022, 37(2): 79-85.
CHEN Xiangqun, YANG Maotao, LIU Mouhai, et al. Disturbance pattern recognition method of power quality based on the fuzzy clustering analysis[J]. Journal of Electric Power Science and Technology, 2022, 37(2): 79-85.
- [10] 张明龙, 张振宇, 罗翔, 等. 基于多核支持向量机的混合扰动波形辨识算法研究[J]. 电力系统保护与控制, 2022, 50(15): 43-9.
ZHANG Minglong, ZHANG Zhenyu, LUO Xiang, et al. Complex disturbance waveform recognition based on a multi-kernel support vector machine[J]. Power System Protection and Control, 2022, 50(15): 43-49.
- [11] ZHOU Chenjing, SHAO Zhenguo, CHEN Feixiong, et al. Classification of power quality disturbance signals based on weighting random forest[C] // proceedings of the 2022 7th Asia Conference on Power and Electrical Engineering (ACPEE), April 15-17, 2022, Hangzhou, China: 2052-2056.
- [12] MOYAL D, KOTHARI N, VAGHERA P, et al. Classifying power quality disturbance using time and multiresolution features through artificial neural network[C] // Proceedings of the 2021 International Conference on Intelligent Technologies (CONIT), June 25-27, 2021, Hubli, India: 1-5.
- [13] 王康, 席燕辉, 胡康. 一种新的基于深度置信网络的电能质量扰动分类方法[J]. 电力科学与技术学报, 2023, 38(1): 171-177.
WANG Kang, XI Yanhui, HU Kang. A novel classification method for power quality disturbance based on deep belief network[J]. Journal of Electric Power Science and Technology, 2023, 38(1): 171-177.
- [14] HUANG Nantian, LIN Lin. Power quality disturbances recognition based on PCA and BP neural network[C] // proceedings of the 2010 Asia-Pacific Power and Energy Engineering Conference, March 18-31, 2010, Chengdu, China: 1-5.
- [15] 王凌云, 李开成, 肖夏颖, 等. 基于稀疏分解的复合电能质量扰动分类[J]. 电测与仪表, 2018, 55(1): 14-20, 33.
WANG Lingyun, LI Kaicheng, XIAO Xiaying, et al. Classification for multiple power quality disturbances based on sparse decomposition[J]. Electrical Measurement & Instrumentation, 2018, 55(1): 14-20, 33.
- [16] 陈华丰, 杨志刚, 曾涛. 基于 S 变换和规则基的复合电能质量扰动识别[J]. 电测与仪表, 2015, 52(12): 122-128.
CHEN Huafeng, YANG Zhigang, ZENG Tao. Multiple power quality disturbances recognition using S-transform and rule based classification technique[J]. Electrical Measurement & Instrumentation, 2015, 52(12): 122-128.
- [17] 贺才郡, 李开成, 杨王旺, 等. 基于双通道 GAF 和深度残差网络的电能质量复合扰动识别[J]. 电网技术, 2023, 47(1): 369-79.
HE Caijun, LI Kaicheng, YANG Wangwang, et al. Power quality compound disturbance identification based on dual channel GAF and depth residual network[J]. Power System Technology, 2023, 47(1): 369-379.
- [18] CAI Kewei, CAO Wenping, AARNIOVUORI L, et al. Classification of power quality disturbances using Wigner-Ville distribution and deep convolutional neural networks[J]. IEEE Access, 2019, 7: 119099-119109.

- [19] 吴怀诚, 刘家强, 岳蕾, 等. 基于多特征融合的卷积神经网络的电能质量扰动识别方法[J]. 电网与清洁能源, 2023, 39(9): 19-23, 31.
WU Huaicheng, LIU Jiaqiang, YUE Lei, et al. Identification of power quality disturbances based on MFCNN[J]. Power System and Clean Energy, 2023, 39(9): 19-23, 31.
- [20] 龚仁喜, 涂晓云. 基于一维多尺度深度残差网络的电能质量扰动分类[J]. 电气开关, 2022, 60(6): 25-32.
GONG Renxi, TU Xiaoyun. Classification for power quality disturbance based on one-dimensional multi-scale deep residual network[J]. Electrical Switchgear, 2022, 60(6): 25-32.
- [21] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA: 770-778.
- [22] IEEE recommended practice for monitoring electric power quality: IEEE Std 1159—2019[S]. IEEE, 2019.
- [23] 牛健, 张志飞, 汤铭辉, 等. 基于改进局部均值分解和概率神经网络的电压扰动识别[J]. 电源学报, 2023, 21(5): 1-17.
NIU Jian, ZHANG Zhifei, TANG Minghui, et al. Voltage disturbance identification based on improved local mean decomposition and probabilistic neural network[J]. Journal of Power Supply, 2023, 21(5): 1-17.
- [24] 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, 20.
GUO Yunfeng, YANG Xiaomei. Power quality disturbance signal classification method based on SVM[J]. Computer Applications and Software, 2022, 39(7): 95-100, 20.
- [25] 贺虎成, 王承海, 辛钟毓, 等. 一种组合重构的电能质量扰动特征提取方法[J]. 电力系统保护与控制, 2023, 51(10): 34-44.
HE Hucheng, WANG Chenghai, XIN Zhongyu, et al. A feature extraction method for power quality disturbance based on reconstructed combination[J]. Power System Protection and Control, 2023, 51(10): 34-44.
- [26] 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.
- [27] 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 disturbance recognition method based on multi-layer feature fusion attention network[J]. Smart Power, 2022, 50(10): 37-44.
- [28] 贺虎成, 辛钟毓, 王琳珂, 等. 基于特征向量筛选和双层 BPNN 的电能质量扰动识别方法[J]. 高电压技术, 2022, 48(4): 1237-1250.
HE Hucheng, XIN Zhongyu, WANG Linke, et al. Detection method of power quality disturbance based on feature vector selection and double-layer BPNN[J]. High Voltage Engineering, 2022, 48(4): 1237-1250.

收稿日期: 2023-07-04; 修回日期: 2023-11-06

作者简介:

王 飞(1977—), 男, 博士, 副教授, 研究方向为电力电子与电力传动; E-mail: qdwf111@163.com

王立辉(1995—), 男, 通信作者, 硕士研究生, 研究方向为电能质量、人工智能。E-mail: 2739142899@qq.com

(编辑 周金梅)