

DOI: 10.19783/j.cnki.pspc.230241

基于混合分解多尺度时频图和 Res-GRU-AT 的 电能质量复合扰动识别

毕贵红, 鲍童语, 陈臣鹏, 赵四洪, 陈仕龙, 张梓睿

(昆明理工大学电力工程学院, 云南 昆明 650500)

摘要: 能源互联网背景下的电能质量问题越来越凸显, 针对传统电能质量扰动(power quality disturbances, PQDs) 识别过程中存在的信号特征提取复杂、算法识别能力不足和复合扰动区分困难等问题, 提出了一种混合分量多尺度时频图和残差神经网络(residual neural network, ResNet)、门控循环单元(gated recurrent units, GRU)网络与注意力机制(attention, AT)组合的电能质量复合扰动识别新方法—Res-GRU-AT。首先利用奇异谱分解(singular spectrum decomposition, SSD)和逐次变分模态分解(successive variational mode decomposition, SVMD)对 PQDs 信号分别进行多尺度分解得到混合分量, 再对混合分量进行希尔伯特黄变换(Hilbert-Huang transform, HHT), 分析得到多尺度时频图。其次, 利用 Res-GRU-AT 模型对多尺度时频图进行深层次特征提取、强化和识别。Res-GRU-AT 模型能够利用 ResNet 的二维图像空间特征提取能力和 GRU 的时序特征提取能力进行特征融合, 再通过 AT 进行特征加权强化, 提高了 PQDs 的识别能力。不同方案的仿真结果表明, 所提方法特征提取能力强且抗噪性能好, 对复合扰动识别率高。

关键词: 电能质量; 故障识别; 时频分析; 混合模式分解; 深度学习

Composite PQDs identification based on a hybrid decomposition multi-scale time-frequency map and Res-GRU-AT

BI Guihong, BAO Tongyu, CHEN Chenpeng, ZHAO Sihong, CHEN Shilong, ZHANG Zirui

(School of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: The power quality problem in the context of the energy internet is becoming more and more prominent. However, there are several problems in the traditional power quality disturbance (PQD) identification process, such as the signal feature extraction is complex, the algorithm recognition ability is insufficient, and it is difficult to differentiate composite disturbance, etc. Thus a new method—Res-GRU-AT, combining hybrid component multi-scale time-frequency diagram, residual neural network (ResNet), gated recurrent units (GRU) network and attention (AT) mechanism, is proposed for power quality composite disturbance identification. First, the PQDs signals are decomposed at multiple scales using singular spectrum decomposition (SSD) and successive variational modal decomposition (SVMD) respectively to obtain the hybrid components. Then the hybrid components are analyzed by Hilbert-Huang transform (HHT) to obtain the multi-scale time-frequency diagram. Secondly, multi-scale time-frequency diagrams are deeply extracted, strengthened, and recognized using the Res-GRU-AT model. The Res-GRU-AT model can perform feature fusion by using the spatial feature extraction capability for 2D images of ResNet and the temporal feature extraction capability of GRU. Then the feature-weighted enhancement is done by AT to improve the recognition capability of PQDs. Simulation results of different schemes show that the proposed method has strong feature extraction capability, good noise immunity, and high recognition rate of composite perturbation.

This work is supported by the National Natural Science Foundation of China (No. 51767012).

Key words: power quality; fault identification; time and frequency analysis, hybrid decomposition; deep learning

基金项目: 国家自然科学基金项目资助(51767012)

0 引言

大力发展以风、光等新能源为主体的新型电力系统, 已成为推动我国能源清洁低碳转型的重要举措。随着以多能源互补协调、“信息-物理-社会”系统深度融合为特征的能源互联网系统逐步出现, 新能源、电力电子设备、可控负荷和电能产销者等非传统主体单元将逐步产业化, 进而大规模渗入电网^[1], 电能质量问题越来越凸显。一方面电能质量扰动类型越来越复杂, 各种电能质量扰动及其复合扰动事件频繁发生^[2], 另一方面能源互联网强大的信息系统为电能质量扰动信息的海量获取与保存提供了可能。电能质量领域正向与信息系统深度融合、与人和社会的互动程度大幅加深的方向发展。电能质量扰动通常表现为电压或电流的幅值、相位以及频率的突变, 包括暂降、谐波、振荡等多种扰动形式, 且各种扰动能够同时复合发生^[3-4], 正确的电能质量扰动识别是电能质量扰动定位、扰动数据关联性分析、动态负荷建模以及电压暂降综合评估等电能质量分析的基础。

数据驱动的电能质量扰动识别方法目前主要有传统机器学习方法和深度学习两种。传统的机器学习方法主要为三步法^[5]: 首先利用信号分解技术, 得到电能质量扰动(power quality disturbances, PQDs)的信号重构分量; 其次, 进行人工特征选取, 计算扰动特征量; 最后, 结合决策树、支持向量机、人工神经网络等机器学习算法, 建立从连续特征到离散标签的映射关系, 实现对 PQDs 的分类。传统的机器学习方法能够实现 PQDs 的分类, 但是其特征提取严重依赖于专家经验, 提取的特征量缺乏适应性, 而且传统机器学习能够区分的扰动种类有限, 难以应对能源互联网背景下复合扰动频繁的复杂电能质量扰动识别问题。

文献[6-7]提出了基于深度学习的 PQDs 识别新方法, 避免了传统人工选择特征的主观性, 转而利用神经网络强大的自动学习与特征挖掘能力进行特征提取。卷积神经网络(convolutional neural network, CNN)、循环神经网络(recurrent neural network, RNN)等深度学习方法模拟人类大脑结构和自我训练能力, 对大量 PQDs 样本数据进行学习, 实现对复杂 PQDs 的分类。深度学习方法在 PQDs 分类领域中, 从输入信号的维度可以分为两类: 一是将预处理后的 PQDs 作为一维时间序列, 利用 CNN 的空间特征提取能力和 RNN 的时序特征记忆能力^[8-10]等深度学习网络挖掘一维 PQDs 的空间特征和时序特征间的潜在联系, 实现 PQDs 的分类; 二是将 PQDs 一

维信号通过某种数学变换将其转换为二维图像数据, 再结合 CNN 和 RNN 的空间和时序特征提取和学习能力实现 PQDs 的分类。一维信号转换为二维信号进行电能质量扰动识别的方法有多尺度分解分量伪彩色图、格拉姆角场^[11]、可视化轨迹圆^[12]、递归图^[13]、Wigner-Ville 分布(Wigner-Ville distribution, WVD)时频图^[14]、连续小波时频图^[15]等方法。将一维信号转换为二维图像, 能够形成信息充分、特征明显的图像训练集, 而 CNN 和 RNN 等深度学习模型对图像有着强大的特征提取和规律挖掘能力, 所以, 二维图像和深度学习结合是研究复杂电能质量扰动识别的主要方法。但是对于 CNN 或者 RNN 等单一模式构成的深度学习神经网络而言, 网络堆叠层数越多, 提取的特征层次越丰富, 网络进一步加深后, 容易出现梯度消失和梯度爆炸等问题, 即使通过各种权重初始化方法能使得网络重新收敛, 但网络退化问题仍无法解决。残差神经网络(residual neural network, ResNet)正是以解决网络退化为出发点, 在网络中引入短路路径, 即通过直接将输入信息绕道传到输出, 保护信息的完整性, 整个网络则只需要学习输入、输出差别的那一部分, 简化学习目标和难度, 保留深层网络极强特征提取能力的同时, 使得网络的底层权重参数得到有效更新, 故 ResNet 近年来在复杂 PQDs 识别领域得到广泛重视。目前使用的 ResNet-18、ResNet-35 和 ResNet-50 等网络虽然具有较好的 PQDs 识别率, 但是庞大的结构仍需要进一步提高计算效率。研究者正从生成信息更加丰富的特征图像和构建学习能力更强、效率更高的深度学习模型两方面加以改进和提高。文献[16]提出了对同一扰动信号同时进行奇异谱分析和曲波变换获得不同变换域的互补特征, 利用 CNN 学习两种互补特征的电能质量复合扰动识别方法。所以, 构造具有丰富信息、规律互补的特征图像是实现强噪声背景下达到高精度高可靠性的多类型复合电能质量扰动识别的发展方向之一。

时频分析是处理非平稳信号的一类重要方法, 它将非平稳信号表示为时间和频率的二维函数, 进而表示成时频图像, 能够凸显信号的时频能量特征。但是直接对复杂扰动进行时频分析并不能完全展示其信号的多层次精细特征, 目前的研究表明分解后的多尺度时频图更加有利于复杂故障信号的多层次精细特征的表达。文献[17]提出一种基于多尺度时频图像的滚动轴承故障诊断方法。该方法采用互补集合经验模态分解(complete empirical mode decomposition, CEEMD)方法对故障振动信号进行分解, 然后对分解得到的多尺度分量进行 WVD 变换得到多尺度时

频图, 然后提取各尺度时频图像的局部二进制纹理特征, 最后用支持向量机成功对不同的轴承故障振动信号进行故障识别。文献[18]也提出利用 CEEMD 和 WVD 变换得到铁道车辆车轮故障信号的多尺度时频图, 利用 CNN 模型进行故障特征提取和规律学习, 实现了较高的故障识别率。文献[19-20]的研究表明, 对于同一个复杂的非平稳信号, 同时利用不同模式多尺度分解方法得到的多尺度分量信号, 能更加准确地表达复杂信号的多层次特征, 有利于后期的特征提取和规律的挖掘。

基于以上分析, 本文提出一种混合分解多尺度时频图和 Res-GRU-AT 组合的电能质量复合扰动识别新方法。(1) 利用奇异谱分解(singular spectrum decomposition, SSD)和逐次变分模态分解(successive variational mode decomposition, SVMMD)对电能质量扰动信号分别进行多尺度分解, 并将两者的多尺度分量进行合并, 然后对合并的多尺度混合分量进行希尔伯特变换分析, 最后得到电能质量扰动信号对应的混合分量多尺度时频图; (2) 利用 Res-GRU-AT 组合模型对电能质量混合多尺度时频图进行深层次学习和识别, ResNet 和 GRU 两种深度学习算法的结合

避免了梯度消失和梯度爆炸的问题, 而且能够利用 ResNet 的二维图像空间特征并行提取能力和 GRU 的时序特征规律提取能力进行特征融合, 可以提高学习和识别能力, 最后通过 AT 将特征进行重点强化。通过在有无噪声等环境下对算法进行仿真分析, 比较单分解模式和混合分解模式多尺度时频图构造的特征图像以及深度学习网络结构对分类结果的影响, 以此验证所提算法能够快速、准确地对复合电能质量扰动信号进行分类辨识。

1 理论基础

1.1 PQDs 分类

为了确保仿真数据的完整性, 涵盖更全面的故障样本, 以贴近实际工程, 参考 IEEEStd1159-2019 标准并结合其他文献, 本文构造了电压尖峰、切痕、闪变、谐波、暂降、暂升、中断、瞬态脉冲、暂态振荡 9 种单一扰动类型和电压闪变+谐波、电压闪变+暂降、电压闪变+暂升、电压暂降+谐波、电压暂升+谐波、电压中断+谐波 6 种复合扰动类型, 共计 15 种扰动类型, 如表 1 所示, $\varepsilon(t)$ 为单位阶跃信号, 计及正常运行状态, 共计 16 种信号类型。图 1 给出其中两种原始扰动波形。

表 1 扰动信号类型

Table 1 Disturbance signal type

标号	扰动	数学模型	约束条件
C0	正常	$y(t) = [1 \pm \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$\alpha < 0.04, T \leq t_2 - t_1 \leq 9T$
C1	尖峰	$y(t) = \sin(\omega t) + \text{sign}(\sin(\omega t)) \times \sum_{i=1}^n k[u(t - (t_1 - 0.02n)) - u(t - (t_2 - 0.02n))]$	$0 \leq t_1, t_2 \leq 0.5T, 0.1 \leq K \leq 0.4, 0.01T \leq t_2 - t_1 \leq 0.05T$
C2	切痕	$y(t) = \sin(\omega t) - \text{sign}(\sin(\omega t)) \times \sum_{i=1}^n k[u(t - (t_1 - 0.02n)) - u(t - (t_2 - 0.02n))]$	$0 \leq t_1, t_2 \leq 0.5T, 0.1 \leq K \leq 0.4, 0.01T \leq t_2 - t_1 \leq 0.05T$
C3	闪变	$y(t) = [1 + \alpha_f \sin(\beta \omega t)] \sin(\omega t)$	$0.1 \leq \alpha_f \leq 0.2, 5 \leq \beta \leq 20$
C4	谐波	$y(t) = \alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t)$	$0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15, \sum(\alpha_i^2) = 1$
C5	暂降	$y(t) = [1 - \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 9T$
C6	暂升	$y(t) = [1 + \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.8, T \leq t_2 - t_1 \leq 9T$
C7	中断	$y(t) = [1 - \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.9 \leq \alpha \leq 1, T \leq t_2 - t_1 \leq 9T$
C8	瞬态脉冲	$y(t) = 1 - \alpha[u(t-t_1) - u(t-t_2)] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.414, 0.05T \leq t_2 - t_1 \leq 0.17T$
C9	暂态振荡	$y(t) = \sin(\omega t) + \alpha^{-\tau(t-t_1)/\tau} \sin(\omega_i(t-t_1)) \times (u(t-t_2) - u(t-t_1))$	$0.1 \leq \alpha \leq 0.8, 0.5T \leq t_2 - t_1 \leq 3T, 8 \leq \tau \leq 40, 300 \leq f_n \leq 900$
C10	闪变+谐波	$y(t) = [\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t)] \times [1 + \alpha_f \sin(\beta \omega t)]$	$0.1 \leq \alpha_f \leq 0.2, 5 \text{ Hz} \leq \beta \leq 20 \text{ Hz}, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15, \sum(\alpha_i^2) = 1$
C11	闪变+暂降	$y(t) = [1 + \alpha_f \sin(\beta \omega t)] \times [1 - \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.1 \leq \alpha_f \leq 0.9, T \leq t_2 - t_1 \leq 9T, 0.1 \leq \alpha \leq 0.2, 5 \text{ Hz} \leq \beta \leq 20 \text{ Hz}$
C12	闪变+暂升	$y(t) = [1 + \alpha_f \sin(\beta \omega t)] \times [1 + \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.8, T \leq t_2 - t_1 \leq 9T, 0.1 \leq \alpha_f \leq 0.2, 5 \text{ Hz} \leq \beta \leq 20 \text{ Hz}$
C13	暂降+谐波	$y(t) = [1 - \alpha(u(t-t_1) - u(t-t_2))] \times [\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t)]$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 9T, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15, \sum(\alpha_i^2) = 1$
C14	暂升+谐波	$y(t) = [1 + \alpha(u(t-t_1) - u(t-t_2))] \times [\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t)]$	$0.1 \leq \alpha \leq 0.8, T \leq t_2 - t_1 \leq 9T, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15, \sum(\alpha_i^2) = 1$
C15	中断+谐波	$y(t) = [1 - \alpha(u(t-t_1) - u(t-t_2))] \times [\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t)]$	$0.9 \leq \alpha \leq 1, T \leq (t_2 - t_1) \leq 9T, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15, \sum(\alpha_i^2) = 1$

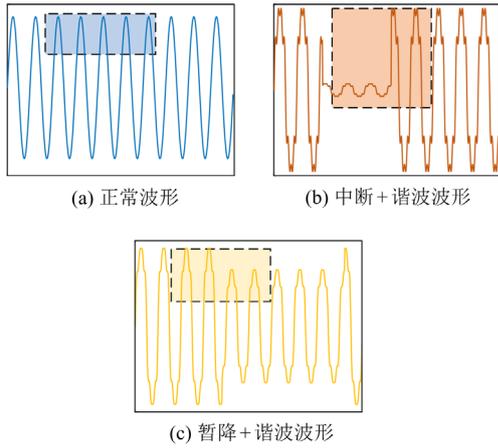


图1 电压中断+谐波、暂降+谐波波形与正常波形对比
Fig. 1 Comparison of voltage interruption+harmonic and sag+harmonic waveforms with normal waveforms

1.2 混合模式分解方法

SSD 是一种可以自适应地处理非线性、非平稳时间序列数据的方法, 通过构建一种新型的信号矩阵, 将强噪声背景下的非线性、非平稳信号按从高频到低频的顺序依次分解为不同的奇异谱分量和残差分量。变分模态分解(variational mode decomposition, VMD)本质上是一种求解变分问题的方法, 具有完全非递归、准正交的特性。逐次变分模态分解(successive variational mode decomposition, SVMD)在 VMD 的基础上对本征模态函数(intrinsic mode function, IMF)的个数设置进行改进, 使子模态分量的提取效率大幅提高。SVMD 通过在原始优化问题中加入自适应准则进行模态分解, 用参数优化的方法代替经验参数算法, 通过分解信号值得模态中心频率的近似值, 从而求得理想的 IMF。

相较于单一的分解方法, 经过 SSD 和 SVMD 两种分解方法得到的时频图, 更有助于 Res-GRU-AT 结合空间与时序的规律进行精准的扰动识别。在单一分解的过程中, 大部分模态存在混叠现象, 这就导致部分模态子序列无法被一种固定的分解方法有效分解。本文提供两种基于不同数学原理的分解方法: SSD 和 SVMD。这两种算法在处理信号分解问题时往往表现出卓越的性能。SSD 本身就表现出优异的处理非线性、非平稳信号的性能, 而作为新型的信号处理方法, SVMD 有着不同规律性的表征力和提取时序特征的能力。两种分解方法在处理复杂的故障电流信号时, 能获得不同的模态处理结果, 有效地减小了单一分解结果下混叠模态子序列逃逸的可能性, 且具有一定的规律互补性。利用两种分解方法对不同的扰动信号特征进行精确而全面

的挖掘, 获得的异种模态子序列集合能更清楚地反映扰动信号的规律, 更有力地捕捉时间序列中的依赖关系, 为后续的 Res-GRU-AT 深度学习网络提供明显的信号特征与时序规律。

1.3 深度学习方法

CNN 由卷积层、池化层和全连接层等组成, 能有效处理不同维度的信号, 提取图像的隐藏特征, 最终完成特征分类识别。然而, 类似其他常规网络, CNN 容易出现过拟合问题。随着网络层数的增加, 虽然能提取更丰富的特征, 但也引发了梯度消失和爆炸的困扰, 影响训练效果。ResNet 应运而生, 通过增加残差块、引入短路路径, 简化网络复杂度的同时解决网络退化问题。ResNet 不仅能有效处理图像和提取特征, 而且通过跨层传播误差的方式, 解决了梯度爆炸或消失导致误差增加的问题, 其基本结构如图 2 所示。将 ResNet 与 GRU 结合能够有效解决梯度消失和爆炸的问题, 处理复杂时间序列信息的同时高效提取图像的时间特征; 而注意力机制的加入更加突出了重要元素的作用。综上, 本文提出的 Res-GRU-AT 组合深度学习网络能够通过各个模块的结合有效挖掘输入 PQDs 数据丰富的规律和特性, 提高 PQDs 的识别精度。

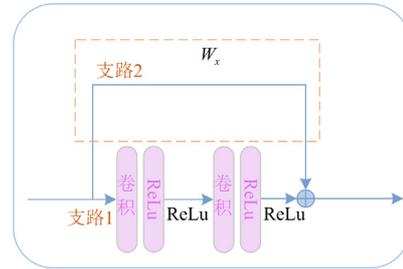


图2 传统残差结构

Fig. 2 Traditional residual structure

2 基于混合模式分解的 Res-GRU-AT 的 PQDs 识别模型

为了更好地提取 SSD 和 SVMD 所得分解分量的细节特征和时空规律, 本文提出了 Res-GRU-AT 识别模型, 其详细结构如图 3 所示, 该识别模型主要由卷积模块、改进残差模块、GRU 模块和 AT 模块组成, 分别构成了初步特征、空间特征、时序特征提取部分以及特征加权强化部分。首先, 由传统卷积模块提取输入信号的初步特征, 并将特征引入改进残差模块的两条支路, 实现双支路特征的规律互补; 其次, 通过构建 GRU 模块进一步提取该特征矩阵中的时序性规律, 实现残差模块与 GRU 模块的优势互补; 最后, 将空间特征与时序特征输入

AT 模块, 突出重要信息, 提高模型整体表现。改进的残差模块不仅在传统残差模块中增加了批量化归一层(batch normalization, BN), 形成卷积层-批量化归一层-ReLu 的统一结构, 更进一步改进了如图 2 所示的传统残差支路中的恒等映射结构, 在恒等映射支路中构建了卷积模块, 既保留了其防止梯度爆炸或消失的优点, 又加强了网络的特征细化能力, 减少网络计算量的同时提高了非线性拟合能力。残差支路 1 与支路 2 对卷积模块所提取的特征进行进一步细化, 分别对不同的权重值进行学习, 增强了不同尺度的空间特征, 实现了不同支路的特征互补。式(1)一式(4)分别为各残差模块提取特征并输出的数学表达式。

$$f_{1,1}^i = \sigma_r \left(\sum W_{1,1}^i * x^i + B_{1,1}^i \right) \quad (1)$$

$$f_{2,1}^i = \sigma_r \left(\sum W_{2,1}^i * x^i + B_{2,1}^i \right) \quad (2)$$

$$f_{2,2}^i = \sigma_r \left(\sum W_{2,2}^i * f_{2,1}^i + B_{2,2}^i \right) \quad (3)$$

$$\sigma_r = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (4)$$

式中: $f_{1,1}^i$ 、 $f_{2,1}^i$ 和 $f_{2,2}^i$ 为经过双残差支路提取到的特征向量; σ_r 为 ReLu 激活函数; x 为输入特征; x^i 为残差部分的输入; $W_{1,1}^i$ 、 $W_{2,1}^i$ 和 $W_{2,2}^i$ 为残差模块中卷积层的卷积核; $B_{1,1}^i$ 、 $B_{2,1}^i$ 和 $B_{2,2}^i$ 为 3 个残差模块中卷积层的偏置。

将两个残差支路提取到的空间特征向量合并后输入 GRU 模块, 经过 Flatten 压平层转换为一维长向量。两个并行残差支路输出的特征向量合并后的数学表达式如式(5)所示。

$$f^i = \text{flatten}(f_{2,2}^i \oplus f_{1,1}^i) \quad (5)$$

式中: f^i 为 GRU 网络的输入; flatten 为压平函数, 实现特征向量的维数转换。

随后, 利用 GRU 对时序信号的敏感性, 通过 GRU 层挖掘出时频图中的时序特征, 并经过 Dropout 层筛选后极大避免了过拟合现象。

将 GRU 层的输出记为 X_i , AT 层的输入即为经过 GRU 层处理的输出向量 X_i 。AT 在深度学习领域中的应用通常分为以下两步。

第一步即通过全局搜索获得关键信息。假设给定某一组 PQDs 的特征序列 $X_i = [x_1, x_2, \dots, x_k]$ 作为网络输入, 对于这组序列有

$$a_i = \text{softmax}[s(X_i, \eta)] = \frac{\exp[s(X_i, \eta)]}{\sum_{j=1}^N \exp[s(X_j, \eta)]} \quad (6)$$

式中: a_i 为注意力分布; η 为与目标相关的查询向量; X_i 表示 GRU 层的输出向量; $s(X_i, \eta)$ 为采用点积模型的注意力打分函数, 负责计算 η 与每个 X_i 的相关性, $s(X_i, \eta) = X_i^T \eta$; softmax 函数负责对计算所得分数进行归一化处理, 得到与输入 PQDs 的特征序列逐次对应的注意力分布 $A_i = [a_1, a_2, \dots, a_k]$ 。

第二步即强化有效信息的影响并弱化无效信息。将式(6)的结果通过式(7)进行加权求和计算, 得到最终结果 Y , 具体计算步骤如下。

$$Y = \sum_{i=1}^k a_i \cdot X_i \quad (7)$$

卷积模块、改进残差模块、GRU 模块和 AT 模块相互配合充分捕捉 PQDs 故障分量的空间耦合特征和时序耦合特征, 实现 PQDs 的高精度识别。

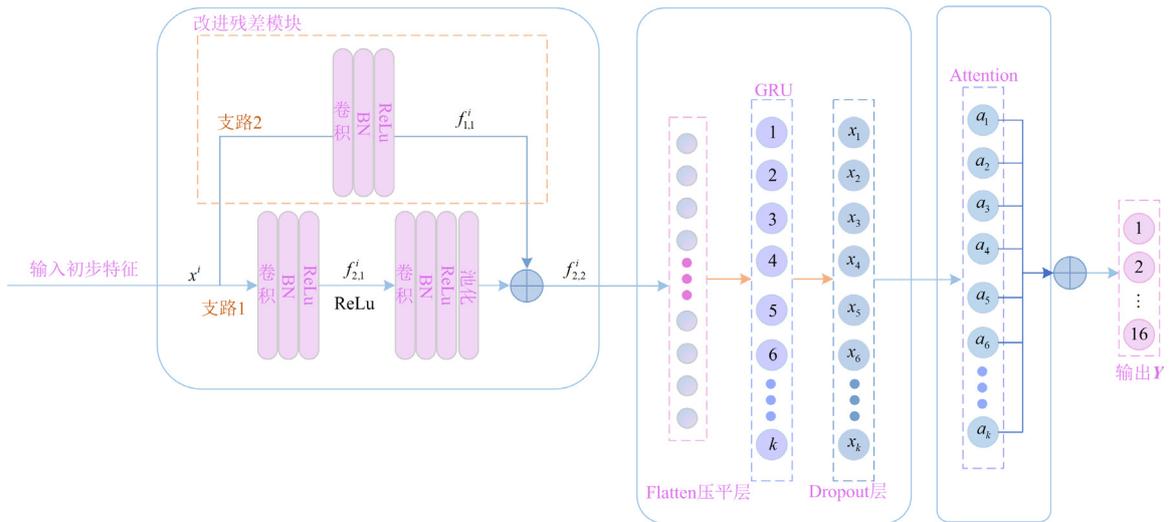


图 3 Res-GRU-AT 结构

Fig. 3 Structure of Res-GRU-AT

3 识别框架及流程

为了提高电能质量扰动的识别准确率, 本文提出一种基于混合模式分解、希尔伯特时频图与 Res-GRU-AT 的组合识别模型。该模型的详细结构如图 4 所示, 该组合模型包括信号的预处理部分和特征提取识别部分。

1) 信号的预处理。本文使用 SSD 和 SVMd 对 n 个原始故障信号进行分解, 以中断+谐波、闪变+谐波和暂降+谐波为例, 将分解后得到的分解分量进行合并, 得到原始信号矩阵, 然后对矩阵中的非平稳信号进行网络分辨率重构和希尔伯特变换得到

希尔伯特时频图, 实现对非平稳信号的处理, 有效避免可能出现的模态混叠、虚假分量等现象, 获得更能反映不同故障信号类别间内在规律的异种模态子序列集合。

2) 信号的特征提取与识别。将希尔伯特时频图输入 Res-GRU-AT 中, 首先通过 Res 网络的双支路残差模块的多卷积核有效识别时频图的不同尺度特征, 实现局部细节的特征互补, 获得更清晰的空间特征; 其次通过 GRU 模块提取出时序特征; 最后, 引入 AT 机制, 聚焦于关键特征, 并对该特征给予更高的权重。最终得到显著增强的特征, 完成电能质量扰动信号的识别归类。

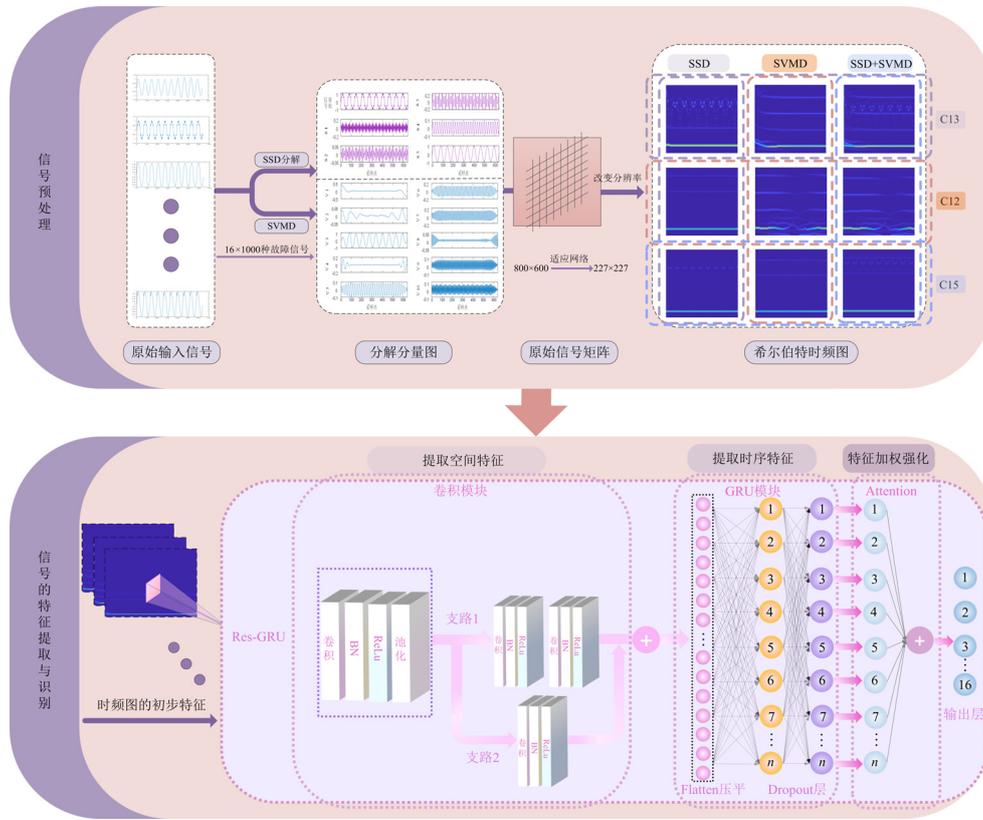


图 4 识别流程

Fig. 4 Identification process

4 算例及仿真结果分析

本文共设置 16 种信号类型, 每种信号类型各 100 组, 共计 1600 组样本信号。基波为 50 Hz, 采样频率为 3200 Hz, 每种信号均采样 10 个周波, 故采样点数为 640, 组成了 1600×640 的原始信号矩阵, 按 7:3 的比例划分为训练集和测试集。考虑到实际应用中电能质量扰动信号会受到电子仪器、外界复杂环境等各种因素的影响, 扰动信号中常常包

含噪声。通过在模拟扰动信号中加入白噪声, 一方面在一定程度上模拟电力系统中的随机干扰噪声; 另一方面用于验证深度学习模型在复杂背景下的特征提取和学习能力以及模型的适应性和泛化能力, 提高电能质量扰动识别算法的实用性和可靠性。本仿真设置两个场景: 无噪声和分别加上信噪比为 40 dB、30 dB 与 20 dB 的高斯白噪声。

4.1 数据预处理

利用 SSD 和 SVMd 两种不同数学原理的分解

算法对 1600×640 的原始信号矩阵同时进行分解。SSD 和 SVMd 能够根据信号的复杂度自适应地确定分解分量数，减小了人为确定分解个数带来的误差。图 5 为“电压谐波+暂升+暂态振荡”原始信号

经 SSD 和 SVMd 自适应分解后的结果，其中 S1—S4 表示按高频到低频排列的子分量，V1—V8 表示按低频到高频排列的子分量。

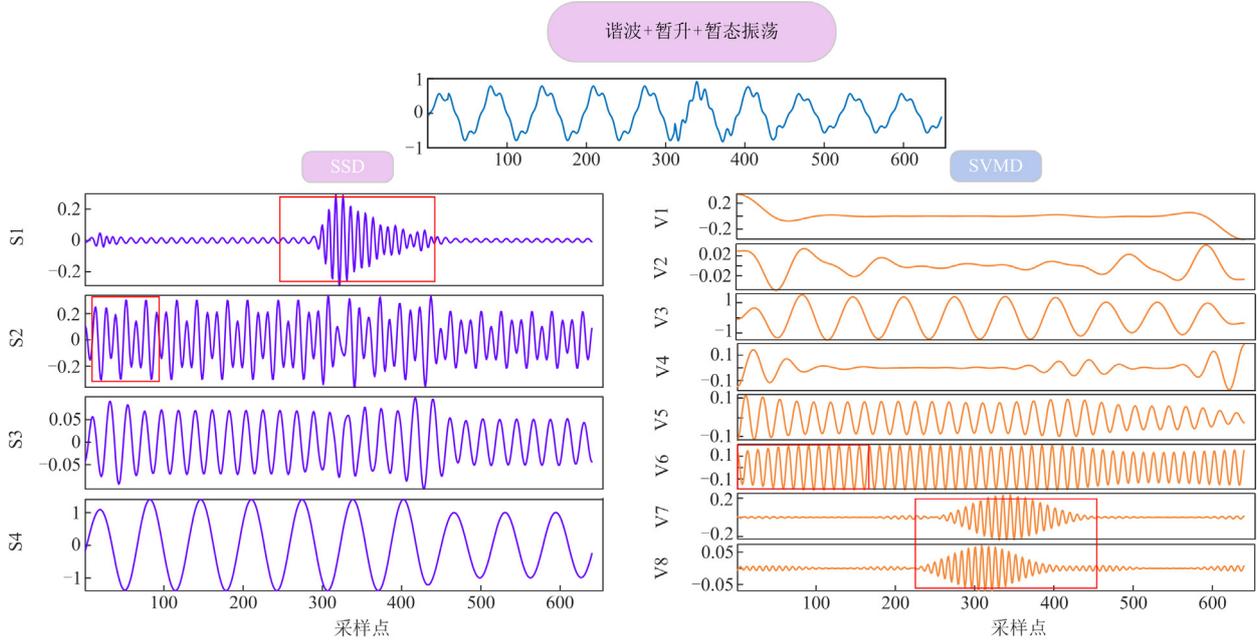


图 5 电压谐波+暂升+暂态振荡分解结果

Fig. 5 Decomposition results of voltage harmonics+transient rise+transient oscillation

由于电网结构的复杂性以及电网负荷的多样性，电力系统中常常出现多种扰动同时发生的现象。以“电压谐波+暂升+暂态振荡”三重复合扰动为例进行研究，得到的时频图如图 5 所示。由于各类噪声的干扰导致电压谐波的波动程度较小，一般图像难以提取出谐波特征，网络极易出现混淆识别的情况，而经过 SVMd 自适应分解得到的子分量可以呈现出细微的幅值变化与明显的谐波特征；SSD 对信号突变与波动特征具有高度敏感性，呈现出明显的幅值波动与缓慢周期变化，与 SVMd 优秀的谐波特征表达能力互补。两种方法针对复杂特征时体现出优越的互补性，有效避免了模态混叠现象，获得更能反映故障特征的模态子序列集合，从而可有效区分不同的复杂扰动类型、提高网络识别精度。

后所得时频图所反映的 3、5、7 次谐波的暂降变化只表现出细微的波动，暂降现象表征不明显，而 SVMd 后所得时频图呈现出显著带状断层特征，网络能够利用此类型特征实现更好的识别效果。

区别于传统的傅里叶、小波等基于积分变换的时频分析方法，希尔伯特变换不会受到时间、频率分辨率的影响，捕获瞬时频率和幅值，获得更加精细的时频矩阵，呈现更清晰的局部细节。利用希尔伯特时频图，旨在综合混合模式分解后所有模态分量的信息，通过时频分析增强原始信号的特征。由图 6 中可以看出，由混合模式分解可得到不同信号的时频图，纹理形状和分布差异明显，能够有效反映出不同的扰动类型，为下一步仿真识别提供更为可靠的样本依据。

图 6 为中断+谐波、暂降+谐波两种信号经 SSD 和 SVMd 后生成的分辨率为 227×227 的希尔伯特时频图。针对电压中断+谐波故障，SSD 和 SVMd 都在一定程度上反映了中断过程，SVMd 后所得时频图的条状特征复杂，容易被压缩，从而造成特征缺失，难以被网络识别，而 SSD 后所得时频图呈现的点状特征断层明显，利用此特征有助于识别准确率的进一步提升；针对电压暂降+谐波故障，SSD

4.2 识别模型及参数设置

本文提出的 Res-GRU-AT 模型主要由残差模块、GRU 模块和注意力机制构成。

对于残差模块，卷积核的合理尺寸是有效提取空间特征的关键，有利于更好地捕获时频图中的局部细节和波动规律。对于 GRU 模块，其神经元个数将直接影响网络的复杂度和拟合程度。因此通过改变 Res-GRU 模型中两条支路中卷积核的大小或 GRU 神经元的个数，进一步确定该模型的结构。为

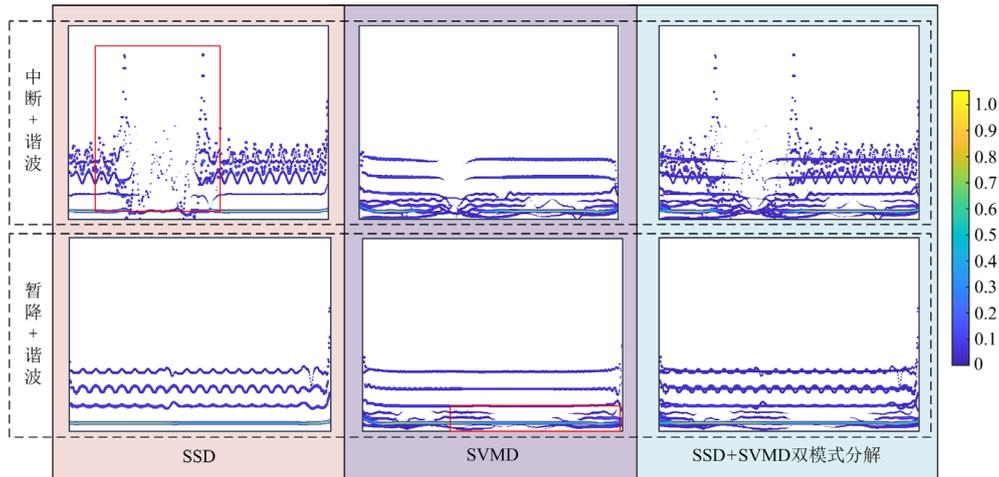


图 6 中断+谐波、暂降+谐波的扰动信号生成的时频图

Fig. 6 Time frequency diagram generated by disturbance signals of interruption+harmonics, and sag+harmonics

减小偶然性误差, 选取 20 次仿真的平均准确率作为最终的识别精度评价标准, 其仿真结果如表 2 所示。

表 2 不同网络结构的误差对比

Table 2 Errors comparison of different network structures

方案	模型	卷积块 1 卷积核大小	卷积块 2 卷积核大小	神经 元数	精度/%
确定卷 积核大小	Res-GRU	2×2	3×3	100	97.7708
	Res-GRU	3×3	4×4	100	99.8854
		3×3			
	Res-GRU	4×4	5×5	100	98.1354
		4×4			
	Res-GRU	5×5	6×6	100	97.8333
Res-GRU	6×6	7×7	100	97.5104	
确定 神经元数	Res-GRU	3×3	4×4	50	98.6979
	Res-GRU	3×3	4×4	100	99.8854
		3×3			
	Res-GRU	3×3	4×4	200	98.5833
		3×3			
	Res-GRU	3×3	4×4	300	98.0833

由表 2 可知, GRU 神经元同时为 100 的仿真条件下, 双支路的卷积核分别为(3×3、3×3; 4×4)时的模型诊断精度最高, 相较于卷积核为(2×2、2×2; 3×3)、(4×4、4×4; 5×5)、(5×5、5×5; 6×6)、(6×6、6×6; 7×7)的模型, 诊断精度分别提高了 2.1146%、1.7500%、2.0521%、2.3750%; 根据本文的输入图像分辨率, 模型中卷积核的尺寸不宜过大或过小, 过大的卷积核容易忽视某些局部细节特征, 而过小的卷积核则会导致所提取的特征

信息不充分, 进而影响模型的诊断效果。

在双支路卷积核尺寸均为(3×3、3×3; 4×4)的前提下, GRU 神经元个数为 100 个的模型诊断精度最高。相较于神经元个数为 50、200、300 的模型, 诊断精度分别提高了 1.1875%、1.3021%、1.8021%; 当神经元个数不足时, GRU 模块不能充分地提取时频图中的时间耦合信息, 而当神经元过多时, 模型会表现出过拟合现象, 同样会影响模型的诊断精度。通过对比仿真, 最终确定 Res-GRU 的双支路卷积核尺寸为(3×3、3×3; 4×4), GRU 模块的神经元个数设为 100 个。

4.3 仿真结果分析

4.3.1 不同识别方法对比

图 7 为两条支路所提取的特征。由图 7(a)和图 7(b)可知, 两条支路同时对时频图的不同区域进行特征捕捉, 实现双支路的特征互补; 由图 7(c)可知, 支路 1 中的卷积 2 对卷积 1 所提特征进一步细化, 获得更清晰的局部细节特征, 自适应地捕捉出有利于扰动识别的多尺度深层特征, 实现了特征增强。

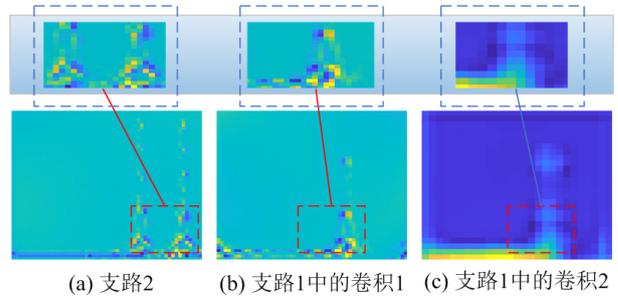


图 7 两条支路所提取的特征图

Fig. 7 Feature map extracted from two branches

为了验证混合模式分解的优越性，本文分别搭建了基于 SSD、SVMD 单模式分解的 Res-GRU 扰

动识别模型并与混合模式分解下的模型进行对比，模型的识别准确率如表 3 所示。

表 3 不同分解模式准确率对比

Table 3 Comparison of accuracy of different decomposition modes

信号	分类准确率/%											
	SSD				SVMD				SSD+SVMD			
	无噪声	40 dB	30 dB	20 dB	无噪声	40 dB	30 dB	20 dB	无噪声	40 dB	30 dB	20 dB
正常	100	99.3333	98.5	98	100	99.6667	98.6667	98.1667	100	100	99.6667	98.5000
尖峰	100	99.1667	98.8333	97.5	99.5	98.8333	98	96.8333	100	99.1667	98.8333	97.5000
切痕	99.8333	99.1667	98	96.5	99.8333	99	97.8333	96.3333	100	99.6667	98.8333	97.1667
闪变	99.8333	99.6667	99	98.3333	98.3333	98.3333	98.3333	98.3333	98.3333	98.3333	98.3333	98.3333
谐波	99	98.1667	97.1667	96.3333	98.6667	97.8333	97	96.1667	99.8333	99.0000	97.8333	97.0000
暂降	99.6667	99	98.5	97.3333	99.8333	99.3333	98.6667	97.8333	100	100	99.1667	98.3333
暂升	99.5	98.8333	98	97.6667	99.6667	99.1667	98.3333	97.8333	100	100	99.3333	98.6667
中断	100	99.6667	98.6667	97.5	100	99.3333	98.1667	97.3333	100	99.6667	99.3333	97.6667
瞬态脉冲	99.8333	99.1667	97.6667	95.8333	99.6667	99	97.5	95.5	100	99.3333	98.0000	96.8333
暂态振荡	99.5	98.5	97.6667	96.1667	99.3333	98.3333	97.5	96	100	99.5000	98.8333	97.8333
闪变+谐波	99.6667	98.8333	97.6667	96.1667	100	99.1667	98	96.8333	100	99.5000	98.6667	97.6667
闪变+暂降	98.6667	97.8333	95.8333	94.8333	99	98	96.1667	95.1667	100	98.8333	97.0000	96.1667
闪变+暂升	98.8333	97.1667	96	94.3333	98.5	96.8333	95.5	94.1667	99.6667	98.0000	97.3333	96.5000
暂降+谐波	98.5	97.1667	95.8333	94	98.1667	95.8333	95.1667	93.5	99.8333	99.3333	97.5000	97.1667
暂升+谐波	98.1667	97.5	96.1667	93.8333	98.3333	96.1667	95.5	94.1667	99.5000	98.6667	98.1667	97.0000
中断+谐波	98.1667	96.6667	95.1667	93.6667	98.5	96.6667	95.3333	93.8333	99.3333	97.8333	96.8333	96.3333
平均精度	99.3229	98.4895	97.4166	96.1249	99.2916	98.2916	97.2604	96.1041	99.8854	99.2812	98.4166	97.4479

由表 3 可知，针对不同类型的扰动信号，基于 SSD、SVMD 单模式分解模型的识别准确率不同。对于单一扰动信号“闪变”、“中断”、“切痕”、“尖峰”、“谐波”、“暂态振荡”、“瞬态脉冲”和复合扰动信号“电压闪变+暂升”、“电压暂降+谐波”，基于 SSD 单一分解的模型预测相较于基于 SVMD 单一分解的模型识别准确率更高；而对于单一扰动信号“暂降”、“暂升”、“正常”和复合扰动信号“电压闪变+谐波”、“电压闪变+暂降”、“电压中断+谐波”、“电压暂升+谐波”，基于 SVMD 单一分解的模型识别准确率更高。这说明不同分解算法对不同信号类型的理解和特征提取能力不同。值得注意的是，Res-GRU 在 4 种信噪比下的平均分类准确率达到 97.4479% 以上，表明了混合模式分解算法能够有效捕捉信号的扰动特征。对于单一扰动的“瞬态脉冲”信号和其他复合扰动信号在高信噪比噪声下难以识别的现象，本文所提方法在 20 dB 噪声下对单一扰动的识别率仍高达 96.8333% 以上，对复合扰动的识别率也高达 96.1667% 以上，表明所提方法对于噪声具有较强的抗干扰性能。这进一步说明同时利用两种分解算法对信号的扰动特征进行全面捕捉，能够获得更完备的扰动特征集合，进而有效提高识别精度。

4.3.2 不同网络结构对比

为了验证本文模型的扰动识别性能，将基于矩阵输入的 CNN、GRU、XGBoost、CNN-LSTM 网络、基于时频图输入的 CNN-GRU 网络与本文方法进行对比分析，结果如表 4 示。

表 4 不同网络结构在不同信噪比下的比较

Table 4 Comparison of different network structures under different signal-to-noise ratios

识别模型	分类准确率/%				运行时长	
	无噪声	40 dB	30 dB	20 dB	迭代一次/s	测试时间/ms
XGBoost	95.2083	94.8125	91.1979	87.4375	2.0446	0.7490
GRU	97.0625	96.1667	93.4687	89.3333	3.5839	1.3499
CNN	97.3438	96.4802	94.2917	90.6458	2.4121	1.2665
CNN-LSTM	97.3854	96.5729	94.9166	91.0313	8.2675	3.5739
CNN-GRU	98.3542	97.6563	96.9688	93.9375	6.4209	3.4112
Res-GRU	99.8854	99.2812	98.4166	97.4479	4.1659	1.5991
Res-GRU-AT	99.8958	99.2916	98.4375	97.4792	4.3870	1.6273

由表 4 分析可知，基于矩阵输入的 CNN-LSTM 组合识别模型相较于基于矩阵输入的 XGBoost、GRU、CNN 单一识别模型有着更高的识别精度，这表明同时对扰动信号进行空间耦合特征和时序耦合特征提取的方法是有效的；此外，基于时频图输入的

CNN-GRU 模型相较于基于矩阵输入的 CNN-LSTM 模型识别精度更高, 进一步说明了卷积神经网络更适合处理二维图像输入, 而希尔伯特时频图一步提高了识别准确率。本文所提方法在 20 dB 噪声下相较于基于矩阵输入的 XGBoost、GRU、CNN、CNN-LSTM 模型平均分类准确率分别提高了 10.0417%、8.1459%、6.8334%、6.4479%, 相较于时频图输入的 CNN-GRU、Res-GRU 模型平均分类准确率分别提高了 3.5417%和 0.0313%。虽然单一的机器学习、深度学习模型 XGBoost、CNN、GRU 诊断时长更短, 但从多次仿真中可以看出, 其准确率和鲁棒性不足。从模型的识别过程看, 改进残差结构弥补了这一缺点, 本文模型的识别时长小于 2 ms, 较传统复合模型 CNN-LSTM 和 CNN-GRU 有着更快的计算速度。

除了本文所搭建的 Res-GRU-AT 网络结构, 还有许多网络曾被应用于电能质量的扰动识别中, 如 ResNet-18 与 VGG-19 等^[17]。为了验证 Res-GRU-AT 具有更好的分类性能, 本节将利用 ResNet-18、ResNets-GRU 和 Res-GRU-AT 3 种残差网络对相同的样本集进行训练测试, 并对 3 种网络下的 PQDs 识别精度进行综合分析对比, 各个网络的训练过程变化曲线如图 8 所示, PQDs 的诊断结果如表 5 所示。

从图 8 所反映的训练集变化过程可以看出, 在

设置条件相同的情况下, Res-GRU-AT 在 771 次迭代时就已经趋于收敛, 相较于 Res-GRU 的 825 次迭代趋于收敛较为相近, ResNet-18 则较慢, 在 1089 次时才达到收敛。除此之外, Res-GRU 和 Res-GRU-AT 的识别精确率能在很短的时间内达到 80%以上, 而 ResNet-18 则需要更多次的迭代才能达到此精度。以上结果均能表明 Res-GRU 和 Res-GRU-AT 网络的双支路结构优势, 突出了其优越的收敛性能。

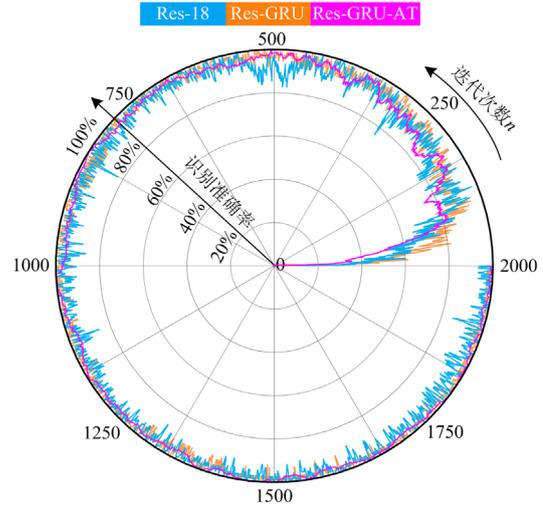


图 8 训练集准确率变化曲线

Fig. 8 Training set accuracy change curves

表 5 ResNet-18、Res-GRU 与本文模型对比

Table 5 Comparison between ResNet-18, Res-GRU and this model

信号类型	分类准确率/%											
	ResNet-18				Res-GRU				Res-GRU-AT			
	无噪声	40 dB	30 dB	20 dB	无噪声	40 dB	30 dB	20 dB	无噪声	40 dB	30 dB	20 dB
正常	100	99.8333	99.3333	98.1667	100	100	99.6667	98.5000	100	99.8333	99.5	98.5
尖峰	99.8333	99.1667	97.1667	96.6667	100	99.1667	98.8333	97.5000	99.8333	99.3333	99	97.6667
切痕	100	99.3333	98.1667	97.1667	100	99.6667	98.8333	97.1667	99.8333	99.5	98.6667	97
闪变	100	99.3333	98.3333	97	100	100	99.3333	98.8333	100	98.8333	99.5	99
谐波	99.8333	98.6667	96.1667	95.3333	99.8333	99.0000	97.8333	97.0000	100	99.1667	98	97.1667
暂降	100	98.5	97.5	96.8333	100	100	99.1667	98.3333	100	100	99	98.1667
暂升	100	98.8333	98	97.1667	100	100	99.3333	98.6667	100	100	99.3333	98.5
中断	99.8333	99.1667	97.3333	96.8333	100	99.6667	99.3333	97.6667	100	99.8333	99.1667	97.8333
瞬态脉冲	99.3333	99.5	97.1667	96.8333	100	99.3333	98.0000	96.8333	100	99.5	98.1667	96.6667
暂态振荡	99.5	99.1667	97.5	96.1667	100	99.5000	98.8333	97.8333	99.8333	99.6667	98.6667	97.6667
闪变+谐波	99.8333	98.3333	96.6667	95.8333	100	99.5000	98.6667	97.6667	100	99.6667	98.5	97.6667
闪变+暂降	99.8333	98.1667	97.6667	96.1667	100	98.8333	97.0000	96.1667	100	99	97.1667	96.3333
闪变+暂升	99.8333	98.5	97	96.8333	99.6667	98.0000	97.3333	96.5000	99.8333	98.1667	97.5	96.6667
暂降+谐波	98.8333	98.1667	97.3333	95.6667	99.8333	99.3333	97.5000	97.1667	99.6667	99.3333	97.5	97.1667
暂升+谐波	99.8333	97.6667	97.5	96.3333	99.5000	98.6667	98.1667	97.0000	99.6667	98.8333	98.3333	97.1667
中断+谐波	99.6667	97	96.6667	95.5	99.3333	97.8333	96.8333	96.3333	99.6667	98	97	96.5
平均准确率	99.7556	98.7083	97.4688	96.5444	99.8854	99.2812	98.4166	97.4479	99.8958	99.2916	98.4375	97.4792

由表 5 分析可知, 在无噪声环境下, 3 种网络结构对测试样本的识别精确率都可以达到 99% 以上。相较于 ResNet-18 模型, Res-GRU 和 Res-GRU-AT 不仅具有双支路结构, 更是一种复合型网络, 而且能够同时充分提取时频图的空间与时间特征以实现局部特征互补。在弱噪声信噪比为 40 dB 的环境下, 两者的识别能力已经明显优于 ResNet-18 网络。在强噪声环境下, 如信噪比为 20 dB 的情况, ResNet-18 的识别准确率分别比 Res-GRU 和 Res-GRU-AT 减少了 0.9035% 与 0.9348%。而电压闪变故障的准确率在 3 种网络间的差别更是十分明显, 这是因为这种扰动非常容易受到强噪声的影响, 被噪声覆盖后无法获得理想的识别准确率, 而 Res-GRU 和 Res-GRU-AT 则极大改善了这种情况, 电压闪变的识别准确率分别可以达到 98.8333% 和 99%。由以上分析可以看出, 无论是在弱噪声还是强噪声环境下, Res-GRU 和 Res-GRU-AT 的测试样本的平均识别准确率均可以达到 97% 以上, 且在 20 dB 的信噪比环境下, 所有扰动信号的识别准确率均可以维持在 96% 以上, 充分说明本文所构建的网络具有较好的抗噪性能与较高的识别能力。

4.3.3 多重扰动与实测数据的鲁棒性分析

由上述仿真分析可知, Res-GRU 和 Res-GRU-AT 在单重扰动和双重扰动下均达到较高的识别准

确率, 识别精度较为相近, 进一步针对三重扰动、四重扰动复合信号对模型的适应性和鲁棒性进行比较分析。

仿真结果如图 9、表 6 和表 7 所示。分析图 9 可知, 本文模型在应对四重扰动信号时有突出优势, 其精度曲线更接近外圈高精度区域, 而传统的 VGG-19、AlexNet、ResNet-18 模型均有较大程度的向内收缩, 表明传统模型难以应对多扰动复合故障, 在强噪声背景下, 该现象尤为明显。

分析图 9(a)、表 6 可知, 本文搭建的 Res-GRU-AT 模型在三重扰动、四重扰动信号下表现出较高的识别准确率, 相较于传统的大型图像识别网络 VGG-19、AlexNet、ResNet-18, 平均精度分别提高了 1.5556%、2.1389%、1.0834%。相较于同时拥有空间特征和时序特征提取能力的 Res-GRU, 平均精度提高了 0.4722%。

在 20 dB 高强度噪声下, 本文模型仍然保持着较高的识别准确率, 相较于 VGG-19、AlexNet、ResNet-18、Res-GRU 模型, 平均识别精度分别提高了 2.7223%、3.1667%、1.8334%、0.8612%。在 20 dB 噪声下, 本文模型的识别准确率相较于 30 dB 噪声条件下仅降低了 0.4722%, 而传统的 VGG-19、AlexNet、

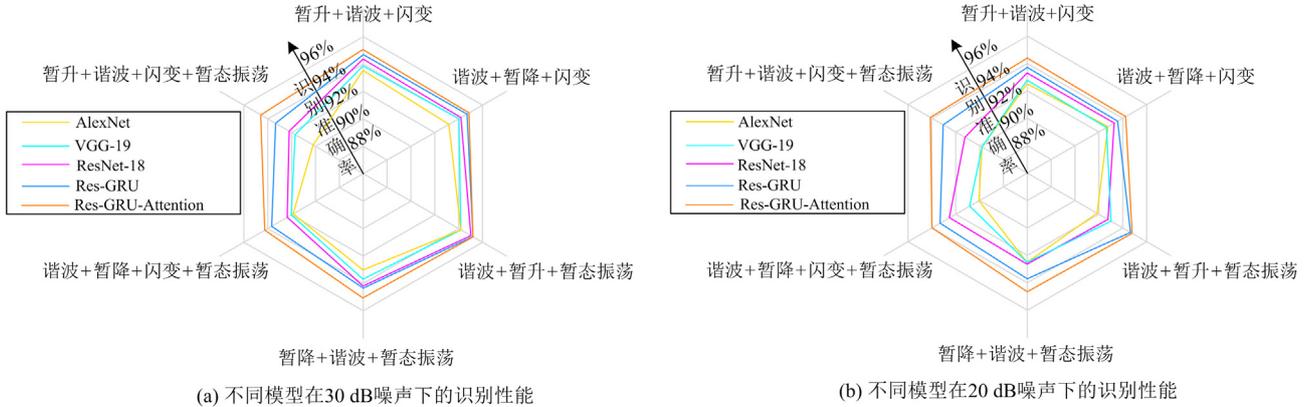


图 9 不同模型在不同噪声下的识别性能

Fig. 9 Recognition performance of different models under different noises

表 6 不同模型在 30 dB 噪声下的识别准确率

Table 6 Recognition accuracy of different models under 30 dB noise

信号类型	识别准确率/%				
	VGG-19	AlexNet	ResNet-18	Res-GRU	Res-GRU-AT
暂升+谐波+闪变	93.8333	93.5000	94.3333	94.6667	95.0000
谐波+暂降+闪变	94.0000	93.1667	94.1667	94.6667	94.8333
谐波+暂升+暂态振荡	94.1667	94.1667	95.0000	95.1667	95.1667
暂降+谐波+暂态振荡	93.6667	93.0000	94.1667	94.3333	95.0000
谐波+暂降+闪变+暂态振荡	92.0000	91.8333	92.3333	93.6667	94.1667
暂升+谐波+闪变+暂态振荡	91.6667	90.1667	92.1667	93.3333	94.5000
平均识别准确率	93.2222	92.6389	93.6944	94.3056	94.7778

表 7 不同模型在 20 dB 噪声下的识别准确率

Table 7 Recognition accuracy of different models under 20 dB noise

信号类型	识别准确率/%				
	VGG-19	AlexNet	ResNet-18	Res-GRU	Res-GRU-AT
暂升 + 谐波 + 闪变	92.6667	92.3333	93.3333	93.5000	94.3333
谐波 + 暂降 + 闪变	92.5000	92.6667	93.3333	93.3333	94.1667
谐波 + 暂升 + 暂态振荡	93.0000	91.5000	92.6667	94.6667	94.8333
暂降 + 谐波 + 暂态振荡	92.3333	92.3333	92.5000	93.5000	94.6667
谐波 + 暂降 + 闪变 + 暂态振荡	90.1667	89.1667	92.3333	93.0000	93.8333
暂升 + 谐波 + 闪变 + 暂态振荡	88.8333	88.8333	90.6667	92.6667	94.0000
平均识别准确率	91.5833	91.1389	92.4722	93.4444	94.3056

ResNet-18 模型分别降低了 1.6389%、1.5000%、1.2222%，进一步说明了本文模型在应对高强度噪声时有着较强的鲁棒性。

为了进一步验证本文模型的识别效果和实际应用价值，额外增加了两个实测数据集：分别来自(1) Amrita Honeywell Hackathon 2021 的电能质量数据集^[21]、(2) 欧洲铁路机车的开放数据集^[22](意大利)。数据集(1)主要包含了 6 种类别的扰动：正常、瞬态脉冲以及 4 种扰动强度递增的谐波信号(设定标签为谐波 1、谐波 2、谐波 3、谐波 4)；数据集(2)选用意大利的铁路机车数据，包含机车加速、制动和静止 3 种类型。

进一步引入迁移学习的思想，选择本文训练完成的电能质量扰动识别模型作为基础模型，利用不同场景下的少量实际现场数据迁移学习，对模型进行微调，以实现不同场景下的电能质量扰动识别。为了适应新的现场数据，构建一个新的顶层(全连接

层)作为输出层，以匹配新的识别任务的类别数量。冻结基础模型：在初始阶段，保持基础模型的权重不变，只训练顶层的权重。各个扰动类型下选取 20 个样本对模型进行权重微调，选取 130 个样本作为测试集，验证不同场景下本文模型的识别效果，两个数据集经迁移学习后的识别结果如表 8 和图 10 所示。

表 8 真实数据的识别结果

Table 8 Identification results of real data

数据集	扰动信号类型	样本个数	召回率/%	平均识别精度/%
(1)	正常	130	97.7	97.3
	瞬态脉冲	130	100	
	谐波 1	130	100	
	谐波 2	130	94.6	
	谐波 3	130	91.5	
(2)	加速	130	100	96.7
	制动	130	96.9	
	停滞	130	93.1	

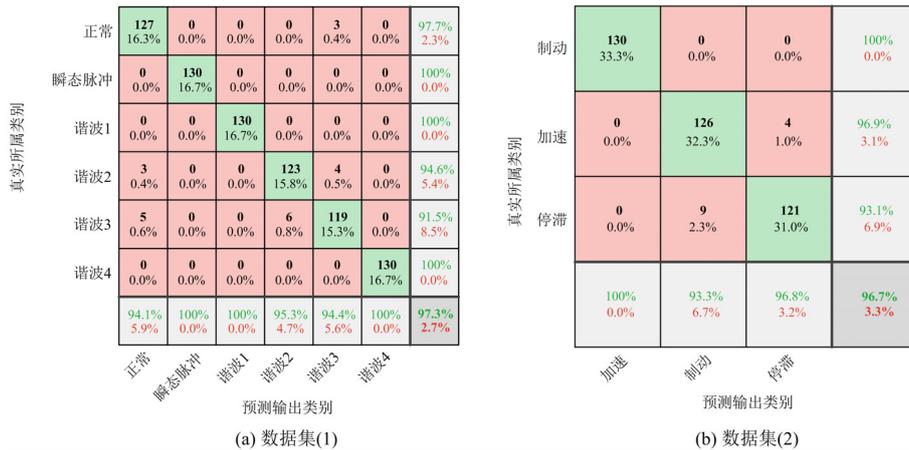


图 10 不同数据集的识别结果

Fig. 10 Recognition results with different datasets

分析图 10(a)和表 8 可知，由于基础模型中并未对谐波的强度进行划分，谐波强度相近的扰动类型之间容易出现混淆，针对谐波 2，有 3 次识别成了

正常信号，有 4 次识别成了谐波 3 信号。深入分析表明：采集的正常信号也存在少量噪声干扰；原始数据的标签并未涵盖完备的复合故障类型，但模型

仍能够达到 91.5%以上的识别精度。针对意大利的铁路机车数据,利用本文模型迁移学习,也能保持较高的识别精度,平均精度达 96.7%,表明该模型能够满足不同场景下的电能质量扰动识别任务,具有较高的适应性。

4.3.4 不同文献方法对比

本文将现有的基于可视化轨迹圆技术的 ResNet-18^[12]、基于多粒度特征选择方法的融合模型网络^[23]、自适应特征增强分组卷积网络^[24]与本文方法进行对比分析,结果如表 9 所示。与文献[12]相比,在无噪声、30 dB 和 20 dB 高信噪比的情况下,本文模型的识别准确率分别提高了 2.7158%、3.3575%和 4.5592%;与文献[23]相比,本文模型在 40 dB、30 dB 和 20 dB 的情况下分别提高了 7.8224%、7.5375%和 5.7792%;与文献[24]相比,本文模型在 30 dB 的情况下精度偏低 0.5425%,但在 40 dB 的情况下高出了 0.0316%,即使是识别难度较大的高信噪比情况,本文模型的识别精度仍然高出了 0.8592%,进一步验证了该模型的优良识别性能和泛化能力。

表 9 不同文献方法在不同信噪比下的比较

Table 9 Comparison of different methods of literature under different signal-to-noise ratios

识别方法	分类准确率/%			
	无噪声	40 dB	30 dB	20 dB
文献[13]	97.81	—	95.08	92.92
文献[24]	—	91.4	90.9	91.7
文献[25]	—	99.26	98.98	96.62
本文模型	99.8958	99.2916	98.4375	97.4792

5 结论

考虑到希尔伯特时频图处理非平稳信号的优势与卷积神经网络在图像处理领域强大的优越性,本文提出了一种基于 SSD 和 SVM 的混合模式分解方法,利用深度残差网络提取图像的深层特征,即使是在强噪声背景下仍能对复合型扰动获得较高的识别精度。经过多次仿真,得出如下结论。

1) 从信号处理角度看,本文利用混合模式分解方法有特征互补的优势,同时采用 SSD 与 SVM 分解故障信号,得到更能反映故障信号特征的多层模态分量,有效抑制了模态混叠和虚假分量等现象。利用希尔伯特变换将一维分解分量集合转换为二维时频图,获得更加精细的时频特征,呈现更清晰的局部细节,极大地增强了原始信号的特征,为后续 Res-GRU-AT 的时空特征捕获提供进一步的参考。

2) 从网络识别角度看,本文提出的 Res-GRU-AT 组合网络能够对 PQDs 进行更加全面的识别,充分提取时频图的空间与时序特征,加入 AT 机制优化模型的特征提取能力,减少冗余信息的影响。其中

深度残差网络的双支路更能从不同的尺度提取特征以实现局部细节的特征互补,相较于其他网络结构有效解决了梯度问题与深层网络的退化问题,提高了 PQDs 的信号识别精度,但其中超参数的最优选取有待进一步研究。

3) Res-GRU-AT 组合网络强大的图像处理能力不仅适用于电能质量的故障识别领域,同时为各种时间序列预测问题提供了新思路,如短期风速预测问题等。

参考文献

[1] 董朝阳,赵俊华,文福拴,等. 从智能电网到能源互联网:基本概念与研究框架[J]. 电力系统自动化, 2014, 38(15): 1-11.
DONG Zhaoyang, ZHAO Junhua, WEN Fushuan, et al. From smart grid to energy internet: basic concept and research framework[J]. Automation of Electric Power Systems, 2014, 38(15): 1-11.

[2] 张宇帆,艾芊,肖斐,等. 数据驱动电能质量分析现状及其支撑技术与展望[J]. 电力自动化设备, 2018, 38(11): 187-196.
ZHANG Yufan, AI Qian, XIAO Fei, et al. Present situation, supporting technologies and prospect of data driven power quality analysis[J]. Electric Power Automation Equipment, 2018, 38(11): 187-196.

[3] 张家宁,罗月婉,郭林明,等. 基于多分辨奇异值分解包和随机森林的电能质量扰动分类研究[J]. 计算机应用与软件, 2023, 40(9): 296-302.
ZHANG Jianing, LUO Yuewan, GUO Linming, et al. Power quality disturbance classification based on multi-resolution singular value decomposition package and random Forest[J]. Computer Applications and Software, 2023, 40(9): 296-302.

[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] 陈子璇,席燕辉,沈银. 基于卡尔曼滤波和深度置信网络的复合电能质量扰动分类[J]. 电力系统保护与控制, 2022, 50(7): 82-90.
CHEN Zixuan, XI Yanhui, SHEN Yin. Recognition of multiple power quality disturbances based on a Kalman filter and deep belief network[J]. Power System Protection and Control, 2022, 50(7): 82-90.

[6] 宋铁维,施伟锋,毕宗,等. 基于 2D-ResNet 的船舶电力系统电能质量扰动识别[J]. 电力系统保护与控制, 2022, 50(10): 95-103.
SONG Tiewei, SHI Weifeng, BI Zong, et al. Shipboard power quality disturbance recognition based on a two dimensional residual network[J]. Power System Protection and Control, 2022, 50(10): 95-103.

[7] 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.
- [8] SINDI H, NOUR M, RAWA M, et al. An adaptive deep learning framework to classify unknown composite power quality event using known single power quality events[J]. *Expert Systems with Applications*, 2021, 178: 115023.
- [9] CHENG Shan, YU Zihao, LIU Ye, et al. Power system transient stability assessment based on the multiple paralleled convolutional neural network and gated recurrent unit[J]. *Protection and Control of Modern Power Systems*, 2022, 7(3): 586-601.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] 武昭旭, 杨岸, 祝龙记. 基于循环神经网络的电能质量扰动识别[J]. *电力系统保护与控制*, 2020, 48(18): 88-94.
- WU Zhaoxu, YANG An, ZHU Longji. Power quality disturbance recognition based on a recurrent neural network[J]. *Power System Protection and Control*, 2020, 48(18): 88-94.
- [14] CAI Kewei, CAO Wenping, et al. Classification of power Quality disturbances using Wigner-Ville distribution and deep convolutional neural networks[J]. *IEEE Access*, 2019, 7: 119099-119109.
- [15] RAFAEL S S, PAULO F R. The use of deep learning and 2-D wavelet scalograms for power quality disturbances classification[J]. *Electric Power Systems Research*, 2023, 214.
- [16] LIU Hui, HUSSAIN F, SHEN Yue, et al. Complex power quality disturbances classification via curvelet transform and deep learning[J]. *Electric Power Systems Research*, 2018, 163: 1-9.
- [17] 孙国栋, 王俊豪, 徐昀, 等. CEEMD-WVD 多尺度时频图像的滚动轴承故障诊断[J]. *机械科学与技术*, 2020, 39(5): 688-694.
- SUN Guodong, WANG Junhao, XU Yun, et al. Rolling bearing fault diagnosis based on CEEMD-WVD multi-scale time-frequency image[J]. *Mechanical Science and Technology for Aerospace Engineering*, 2020, 39(5): 688-694.
- [18] 李大柱, 牛江, 梁树林, 等. 基于多尺度时频图与卷积神经网络的车轮故障智能诊断[J]. *铁道科学与工程学报*, 2023, 20(3): 1032-1043.
- LI Dazhu, NIU Jiang, LIANG Shulin, et al. Intelligent wheel fault diagnosis based on multi-scale time-frequency map and convolutional neural network[J]. *Journal of Railway Science and Engineering*, 2023, 20(3): 1032-1043.
- [19] 毕贵红, 赵鑫, 陈臣鹏, 等. 基于多通道输入和 PCNN-BiLSTM 的光伏发电功率超短期预测[J]. *电网技术*, 2022, 46(9): 3463-3476.
- BI Guihong, ZHAO Xin, CHEN Chenpeng, et al. Ultra-short-term prediction of photovoltaic power generation based on multi-channel input and PCNN-BiLSTM[J]. *Power System Technology*, 2022, 46(9): 3463-3476.
- [20] 陈臣鹏, 赵鑫, 毕贵红, 等. 基于多模式分解和麻雀优化残差网络的短期风速预测模型[J]. *电网技术*, 2022, 46(8): 2975-2985.
- CHEN Chenpeng, ZHAO Xin, BI Guihong, et al. SSA-Res-GRU short-term wind speed prediction model based on multi-model decomposition[J]. *Power System Technology*, 2022, 46(8): 2975-2985.
- [21] KOTLA J R, NARAYAN. A power quality classification dataset-2[EB/OL]. [2022-05-18]. <https://www.kaggle.com/datasets/jai-deepreddykotla/power-quality-distribution-dataset2>.
- [22] MARISCOTTI A. Data sets of measured pantograph voltage and current of European AC railways[J]. *Data in Brief*, 2020, 30: 2-12.
- [23] 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): 1-11.
- 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): 1-11.
- [24] 张锐, 张闯, 高辉, 等. 基于自适应特征增强分组卷积神经网络的电能质量扰动分类[J]. *中国电机工程学报*, 2023, 43(15): 5808-5818.
- ZHANG Rui, ZHANG Chuang, GAO Hui, et al. Power quality disturbances classification based on grouping convolutional network with adaptive feature enhanced network[J]. *Proceedings of the CSEE*, 2023, 43(15): 5808-5818.

收稿日期: 2023-03-10; 修回日期: 2023-12-31

作者简介:

毕贵红(1968—), 男, 博士, 教授, 硕士生导师, 研究方向为新能源系统建模、优化与智能数据分析; E-mail: 1719847159@qq.com

鲍童语(1999—), 女, 硕士研究生, 研究方向为电能质量扰动分析研究; E-mail: 495077857@qq.com

赵四洪(1974—), 男, 通信作者, 硕士, 讲师, 研究方向为电能质量分析控制、电力电子变流器保护控制。E-mail: 20854325@qq.com

(编辑 周金梅)