

DOI: 10.19783/j.cnki.pspc.241498

# 基于时频图像组合和 DenseNet-CPSAMs 的电能质量 复合扰动识别

毕贵红, 杨楠, 刘大卫, 杨毅, 陈冬静, 陈仕龙

(昆明理工大学电力工程学院, 云南 昆明 650500)

**摘要:** 针对新一代电力系统的电能质量扰动(power quality disturbances, PQDs)识别难题, 提出一种改进的自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)、两种模态时频图组合和 DenseNet-CPSAMs 深度学习模型结合的 PQDs 识别新方法。首先, 提出 ICEEMDAN 分解 PQDs 信号, 并重构分量。其次, 通过同步提取变换(synchroextracting transform, SET)和 S 变换(Stockwell transform, ST)生成对应时频图, 组合为 6 通道输入张量。最后, 引入 DenseNet-CPSAMs 深度学习模型, 融合了密集连接卷积神经网络(densely connected convolutional networks, DenseNet)、通道注意力机制(channel attention mechanism, CAM)与并行空间注意力机制(parallel spatial attention mechanisms, PSAMs), 实现融合时频图特征深度提取与强化识别。相比于 DenseNet-121 模型, DenseNet-CPSAMs 模型方法在成功减少模型参数 6.5 M 的同时, 在 20 dB 高信噪比条件下对 31 类扰动的平均识别率为 99.645%, 仿真实验表明该方法特征提取能力强、抗噪性能好, 并且对复合扰动识别率高。

**关键词:** 电能质量扰动; ICEEMDAN; 同步提取变换; S 变换; DenseNet; 深度学习

## Composite power quality disturbance identification based on time-frequency image fusion and DenseNet-CPSAMs

BI Guihong, YANG Nan, LIU Dawei, YANG Yi, CHEN Dongjing, CHEN Shilong

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

**Abstract:** To address the challenge of identifying power quality disturbances (PQDs) in new-generation power systems, a novel PQDs identification method is proposed, which combines improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN), dual time-frequency image fusion, and a DenseNet-CPSAMs deep learning model. First, ICEEMDAN is utilized to decompose the PQDs signals and reconstruct their components. Second, corresponding time-frequency images are generated through the synchroextracting transform (SET) and Stockwell transform (ST), which are fused into a 6-channel input tensor. Finally, a DenseNet-CPSAMs deep learning model is introduced, integrating densely connected convolutional networks (DenseNet), channel attention mechanisms (CAM), and parallel spatial attention mechanisms (PSAMs), to achieve multi-scale time-frequency feature extraction and the enhanced disturbance recognition. Compared to the DenseNet-121 model, the DenseNet-CPSAMs method reduces model parameters by 6.5 M, while achieving an average recognition rate of 99.645% for 31 disturbance types under a 20 dB high signal-to-noise ratio. Simulation results demonstrate that the proposed method exhibits strong feature extraction capability, high noise resistance, and superior recognition performance for composite disturbances.

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

**Key words:** power quality disturbance; ICEEMDAN; synchronous extraction transformation; S transform; DenseNet; deep learning

基金项目: 国家自然科学基金项目资助(51767012)

## 0 引言

电力系统中高比例可再生能源、高比例电力电子装备、多能互补综合能源与物理信息深度融合的智能电网和能源互联网,是新一代电力系统的主要技术特征<sup>[1-2]</sup>。在多物理场强耦合的复杂电网运行环境中,新一代电力系统呈现显著的电能质量非平稳波动特征。多种扰动源时空耦合的交互机制,导致电能质量扰动(power quality disturbances, PQDs)呈现高度复杂的行为特性<sup>[3-5]</sup>,给复合 PQDs 类型的监测和识别带来挑战。另外能源互联网强大的信息系统为 PQDs 数据的海量获取与存储提供了技术支撑,这种高维异构数据的实时获取能力为基于大数据分析和人工智能的数据驱动 PQDs 识别带来了可能<sup>[6]</sup>。

深度学习模型因具有强大的特征挖掘和自学习能力,目前被广泛应用于 PQDs 分类和识别的研究<sup>[7]</sup>。针对基于深度学习的 PQDs 识别优化,目前主要从 3 个方面进行改进:首先,利用某种信号变换方法完成从信号空间到特征空间的映射,实现信号特征的显现和强化,为后续深度学习模型的特征挖掘与模式识别提供了基础;其次,寻找噪声抑制与特征保留的有效方法,保证信号变换方法对特征空间映射的有效性;最后,构建轻量化、具有高效学习能力的模型,实现 PQDs 识别精度与效率的双重提升。

当前 PQDs 识别研究主要分为两大方向:1) 直接利用一维时序数据训练进行识别,此方法虽保留原始信息但特征挖掘受限,尤其对复合扰动识别效果不佳<sup>[7-9]</sup>;2) 将一维信号映射为二维图像,采用深度学习进行扰动分类,如格拉姆角场<sup>[10]</sup>、马尔可夫转换场<sup>[11]</sup>、轨迹圆<sup>[12]</sup>、递归图<sup>[13]</sup>等非线性一维信号的图形化转换方法。除此之外,提出基于时频分析与深度学习融合的 PQDs 识别方法。文献[14]利用 S 变换将 PQDs 信号转换为时频图像,并结合了自适应特征增强分组卷积神经网络(grouping convolutional neural network with adaptive feature enhanced network, GCNN-AFEN)进行深度特征学习与分类。文献[15]采用同步压缩小波变换(wavelet synchrosqueezing transform, WSST)对频率信号进行分析,提取特征后,将特征输入到 GoogLeNet 和 SqueezeNet 模型中执行识别任务。文献[16]通过连续小波变换(continuous wavelet transform, CWT)将 PQDs 转换为时频图,与轻量级卷积神经网络结合,并融入最大似然卡尔曼滤波器去噪。上述所提方法借助不同的

时频转换技术以及神经网络架构,实现了高准确率和强噪声鲁棒性的效果,为 PQDs 分类识别提供了有效策略。

实际应用中,对提升基于深度学习模型的 PQDs 分类识别性能意义重大。文献[17]采用自适应最大似然卡尔曼滤波技术去噪以提取纯净扰动信号;文献[18]采用自适应小波降噪技术,优化阈值函数消除噪声、保留特征。这些合适的去噪方法可解决 PQDs 信号噪声抑制中突变特征点保留难题,为深度学习挖掘学习扰动信号特征提供基础。

随着深度学习的进步,其在 PQDs 识别领域的应用扩展迅速,当前研究聚焦于构建轻量级且高效的学习模型,以实现快速准确识别。文献[14,19]提出利用卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN)提升识别准确性,避免了人工特征选择的主观性。本研究通过引入注意力机制对传统深度学习模型进行改进,使模型聚焦于图像核心区域,实现了特征精细解析与多向信息融合,在 PQDs 识别中的成功应用验证了该方法的有效性<sup>[20-21]</sup>。此外,面对海量 PQDs 信息,轻量化模型能够提高模型在资源受限环境中的部署效率和运行性能<sup>[16]</sup>。密集连接卷积神经网络(densely connected convolutional networks, DenseNet)作为轻量级模型的代表,通过密集连接机制实现了特征的高效复用与传输,构建紧凑且性能优异的网络结构,有效缓解了梯度消失的问题,提升了参数效率和抗噪性,PQDs 分析与识别技术已成为近年来电能质量领域的研究热点。文献[22]提出 2D DenseNet 模型,自动学习 PQDs 特征并降低了计算成本,为电力质量扰动实时诊断提供了技术支持。然而,DenseNet 存在卷积层冗余和超参数敏感的问题,需进行改进以提高网络的性能与实用性。

在信号特征映射中,某些方法虽对多数扰动类型识别精度高,但对于特定的复合扰动容易混淆,尤其在高噪声环境下问题更明显。因此,多模态组合识别方法受到了研究领域的广泛关注,诸多文献探索了多特征组合策略,旨在增强 PQDs 的识别能力。文献[20,23]分别采用双通道格拉姆角场(Gramian angular field, GAF)、特征分量彩色图与小波时频图组合来捕获 PQDs 时频特征。此外,文献[19,24]均融合了一维时间序列与二维图像特征,结合深度学习进行特征提取与识别。这些研究表明,多特征组合策略能有效分离高维特征,提高识别精度。然而,多分支模型增加了学习收敛难度、影响

学习效率, 模态特征组合方式会对识别准确性产生影响, 因此需要进一步探讨。

基于以上分析, 本文提出了一种新颖的电能质量复合扰动识别方法: 1) 提出改进的自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)与重构去噪技术, 有效抑制信号噪声并保留关键特征, 为深度学习奠定基础。2) 结合 S 变换 (Stockwell transform, ST) 与同步提取变换 (synchroextracting transform, SET) 生成两种模态时频图特征, 并将其组合构建成 6 通道张量, 以此实现不同模态信息间的互补, 增强特征的可区分性。3) 提出 DenseNet-CPSAMs 模型, 采用改进的 DenseNet 模型、通道注意力机制和并行空间注意力

机制组合策略, 优化信息传播, 聚焦核心特征, 从而提升识别精度。同时, 利用 6 通道张量作为输入, 通过单支路特征提取, 减少了计算量。

## 1 信号预处理

### 1.1 PQDs 模型构建

电能质量是衡量电力供应纯净度与稳定性的关键指标。实际电力系统常偏离理想状态, 存在复杂 PQDs, 鉴于设备采集真实数据困难, 本文参考 IEEEStd1159-2019<sup>[25]</sup>标准, 对 PQDs 信号进行建模, 确保仿真数据完整真实, 覆盖各种故障场景。表 1 列出 9 种常见的 PQDs: 正常、暂降、暂升、中断、瞬态脉冲、暂态振荡、谐波、闪变、切痕, 并详述每种扰动模型及约束条件。

表 1 单一 PQDs 模型

Table 1 Single model of PQDs

标号	扰动	数学模型	约束条件
C1	正常	$y(t) = [1 \pm \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$\alpha < 0.04, T \leq t_2 - t_1 \leq 9T$
C2	暂降	$y(t) = [1 - \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.9, T \leq t_2 - t_1 \leq 9T$
C3	暂升	$y(t) = [1 + \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.8, T \leq t_2 - t_1 \leq 9T$
C4	中断	$y(t) = [1 - \alpha(u(t-t_1) - u(t-t_2))] \sin(\omega t)$	$0.9 \leq \alpha \leq 1, T \leq t_2 - t_1 \leq 9T$
C5	瞬态脉冲	$y(t) = \sin(\omega t) + \alpha_2 e^{\frac{(t-t_1)}{\tau}} [u(t-t_1) - u(t-t_2)]$	$1 \leq \alpha_2 \leq 10, 0.008 \leq \tau \leq 0.04,$ $0.5T \leq t_2 - t_1 \leq 3T$
C6	暂态振荡	$y(t) = \sin(\omega t) + \alpha \frac{(t-t_1)}{\tau} \sin(\omega_n(t-t_1))(u(t-t_2) - u(t-t_1))$	$0.1 \leq \alpha \leq 0.8, 0.5T \leq t_2 - t_1 \leq 3T,$ $8 \leq \tau \leq 40, 300 \leq f_n \leq 900$
C7	谐波	$y(t) = \alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t)$	$0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15, \sum (\alpha_i^2) = 1$
C8	闪变	$y(t) = [1 + \alpha_f \sin(\beta \omega t)] \sin(\omega t)$	$0.1 \leq \alpha_f \leq 0.2, 5 \leq \beta \leq 20$
C9	切痕	$y(t) = \sin(\omega t) - \text{sign}(\sin(\omega t)) \cdot \sum_{i=1}^n k[u(t - (t_1 - 0.02n)) - u(t - (t_2 - 0.02n))]$	$0 \leq t_1, t_2 \leq 0.5T, 0.1 \leq k \leq 0.4,$ $0.01T \leq t_2 - t_1 \leq 0.05T$

目前, 已有研究多聚焦于 9 种单一 PQDs。为更为全面地探究电能质量问题, 本文扩展了范围, 剖析电能质量复合扰动的复杂性。具体而言, 除了 9 种常见的单一 PQDs 外, 还选取了 22 种具有代表性的复合扰动类型, 这些复合扰动包括: 14 种双扰动电能质量复合扰动、5 种三扰动电能质量复合扰动和 3 种四扰动电能质量复合扰动, 表 2 详细列出了 22 种复合扰动信号, 图 1 给出部分扰动波形对比。

### 1.2 改进的自适应噪声完备集合经验模态分解

ICEEMDAN 算法是针对 CEEMDAN 算法的一种改进版本, 其核心目标在于解决 CEEMDAN 算法中存在的残留噪声和伪模态问题。通过改进噪声引入机制, 减少噪声过度引入, 提高信号分解精度。算法独立分解原始信号和人工白噪声, 选择白噪声本征模态函数(intrinsic mode function, IMF)分量辅助信

表 2 复合扰动信号

Table 2 Compound disturbance signal

标号	扰动	标号	扰动
C10	暂降 + 谐波	C21	闪变 + 谐波
C11	暂升 + 谐波	C22	闪变 + 暂态振荡
C12	闪变 + 暂降	C23	谐波 + 暂态振荡
C13	闪变 + 暂升	C24	暂降 + 闪变 + 谐波
C14	暂降 + 暂态振荡	C25	暂升 + 闪变 + 谐波
C15	暂升 + 暂态振荡	C26	暂降 + 谐波 + 暂态振荡
C16	暂降 + 瞬态脉冲	C27	暂升 + 谐波 + 暂态振荡
C17	暂升 + 瞬态脉冲	C28	闪变 + 谐波 + 瞬态脉冲
C18	闪变 + 瞬态脉冲	C29	暂降 + 谐波 + 暂态振荡 + 闪变
C19	谐波 + 瞬态脉冲	C30	暂升 + 谐波 + 暂态振荡 + 闪变
C20	中断 + 谐波	C31	暂降 + 谐波 + 暂态振荡 + 瞬态脉冲

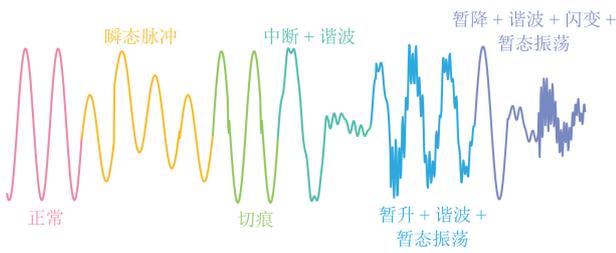


图1 部分 PQDs 波形

Fig. 1 Partial waveforms of PQDs

号分解。多级迭代生成 IMF 和更新残差,直至满足终止条件。通过动态调整策略,使算法能够适应信号的复杂性和非平稳性特征,从而显著提升处理复杂信号的能力<sup>[26]</sup>。

以“暂升+谐波+闪变+暂态振荡”的复杂四扰动信号为例,在 20 dB 白噪声下,采用 ICEEMDAN 分解重构,并进行 SET 和 S 变换,结果如图 2 所示。图 2(a)为分解前 SET 时频图,噪声干扰大;图 2(b)为分解后 SET 时频图,噪声有效抑制,背景清晰。图 2(c)为分解前 ST 时频图,图 2(d)为分解后 ST 时频图,信号固有特征明显,时频域辨识度提升,避免时频混叠,增强分析准确性与细致度。验证了 ICEEMDAN 在处理含高噪声 PQD 信号方面的有效性和性能优越性。

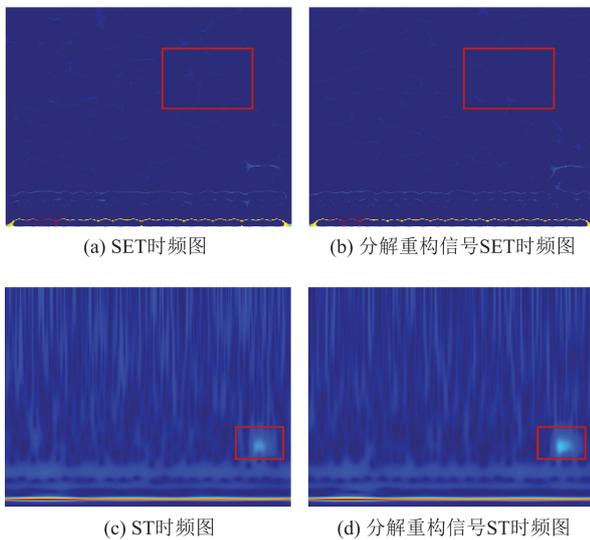


图2 “暂升+谐波+闪变+暂态振荡”数据预处理过程

Fig. 2 Data preprocessing process of “swell + harmonic + flicker + oscillatory transient”

### 1.3 同步提取变换

SET 作为一种在短时傅立叶变换(short-time Fourier transform, STFT)基础上进行后处理的高分

辨率时频分析方法,其核心目标在于生成能量高度聚集的时频分布表征,将时频系数重新分配至接近理想时频表示的瞬时频率轨迹附近,同时确保其具备信号重构的能力<sup>[27]</sup>。

### 1.4 S 变换

S 变换由 R.G.Stockwell<sup>[28]</sup>等人于 1996 年提出,在傅里叶变换(Fourier transform, FT)、短时傅里叶变换和小波变换的基础上发展而来。其核心创新点在于对窗口函数进行了设计优化,具体表现为窗口宽度与频率呈反比关系。高频时提供高时间分辨率,低频时提供高频率分辨率。这一特性使 S 变换能同时捕捉信号的局部时间特征和全局频率特征,准确获取各频率分量的真实相位信息。

图 3 展示了“谐波+暂降+暂态振荡”信号的时频分析,波形如图 3(a)所示。图 3(b)的 ST 时频图具备优越的时频分辨率,覆盖范围广,特征呈面状分布,但精确性欠佳;图 3(c)的 SET 时频图呈现出显著的色带断裂效应,具有高精度、能量集中的特性,其特征表现为线性且分布局限。鉴于此,融合 SET 与 ST 时频图的优势,实现二者组合应用,能够获取更为丰富全面的时频特征信息。

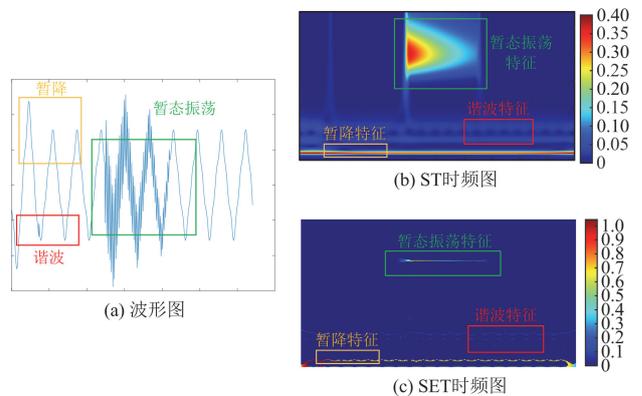


图3 “谐波+暂降+暂态振荡”信号时频图

Fig. 3 Signal time-frequency diagram of “harmonic + sag + transient oscillation”

## 2 深度学习模型

### 2.1 注意力机制

深度学习中的注意力机制主要分为通道注意力机制(channel attention mechanism, CAM)和空间注意力机制(spatial attention mechanism, SAM),二者分别聚焦于特征的不同维度,旨在增强模型对关键信息的捕捉能力。

CAM 以压缩和激励网络(squeeze-and-excitation

networks, SENet)作为典型实现形式, SENet 结构如图 4 所示。CAM 通过显式建模特征通道间的依赖关系, 自适应重新标定通道特征权重。其中, SENet 首先对输入特征层执行全局平均池化, 将多维特征压缩为全局实数; 再经两次全连接层处理, 首次降维, 第二次升维至与输入通道数匹配, 并利用 Sigmoid 函数将输出限制在 0~1 之间, 生成各通道权重; 最后, 这些权重与原始特征层相乘, 实现通道重新加权, 完成特征重构与增强。图中:  $F_{sq}(\cdot)$  表示空间特征压缩过程;  $F_{ex}(\cdot, w)$  表示通道特征学习过程;  $F_{scale}(\cdot)$  表示通过权重调整特征图中每个通道的贡献度;  $c$ 、 $h$ 、 $w$  分别表示输入特征图的通道数、高度和宽度。

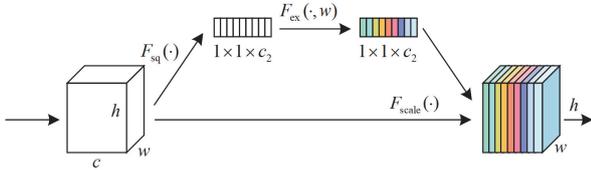


图 4 SENet 结构

Fig. 4 Structure of SENet

相比之下, SAM 聚焦于输入特征图的空间位置信息, 其结构如图 5 所示。首先对输入特征层开展特征点聚合操作, 以此捕捉每个位置的特征显著性及平均表现。随后, 借助卷积层调整特征图的通道维度, 并运用 Sigmoid 激活函数生成权重图, 从而反映不同空间位置特征点的重要性。最后, 这些权重被应用于原始特征层, 进行空间特征加权, 以优化模型对重要信息的关注度和处理效果。

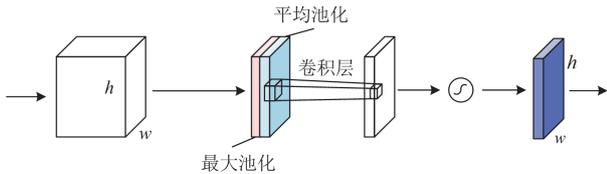


图 5 SAM 结构

Fig. 5 Structure of SAM

因此, 在 DenseNet 网络结构中引入 CAM 和 SAM, 可以重新加强浅层网络的全局特征, 并对深层次网络中各特征的重要通道进行重新加权, 从而有效提高模型精度。

### 2.2 DenseNet-CPSAMs 网络结构

DenseNet 通过密集块中的跨层特征复用和过渡层的降维压缩, 显著提升了模型的参数效率与特征表达能力。其加强了层间直接连接, 提高了信息传播效率, 缓解了梯度消失问题, 减少了参数冗余。

DenseNet-CPSAMs 模型在 DenseNet-121 的基础上进行改进, 构建了更紧凑高效的网络结构, 增强了梯度流动和特征表达能力, 进而提升了计算效率与整体性能, 实现了高效的特征传播, 展现出优异性能。其识别网络如图 6 所示, 具体改进如下所述。

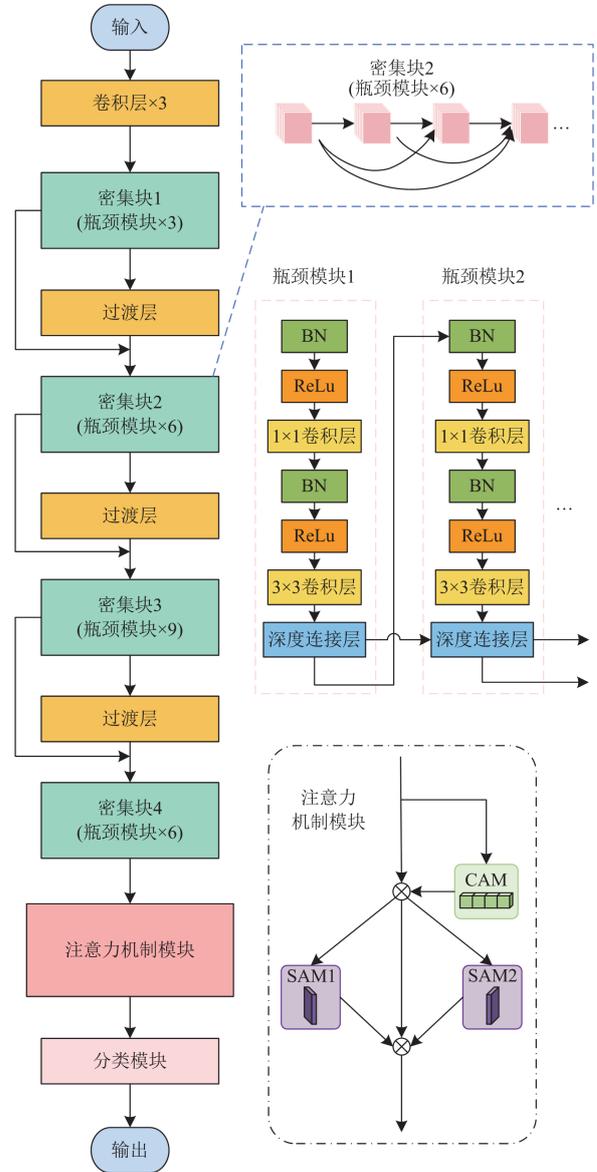


图 6 DenseNet-CPSAMs 识别网络

Fig. 6 DenseNet-CPSAMs identification network

1) 输入卷积层改进: 采用多通道输入, 并用 3 个  $3 \times 3$  (第一个卷积步长为 2, 其余为 1) 的卷积层替代一个  $7 \times 7$  (步长为 2) 卷积层, 从而在保留 DenseNet 高效特征复用与信息传播优势的同时, 优化了对图像细节信息的处理能力。

2) 密集块模块优化: 每个密集块包含多个瓶颈模块, 缩减瓶颈模块卷积层数, 减少计算量和参数

量, 提高了模型的简洁性和泛化能力。如将密集块 1 中 6 组 1×1 卷积和 3×3 卷积缩减为 3 组, 其余模块具体缩减情况如表 3 所示。

3) 注意力机制加入: 在 DenseNet 的分类层前引入通道注意力机制(CAM)和并行空间注意力机制(parallel spatial attention mechanisms, PSAMs), 自动关注重要特征通道和关键空间区域, 提升了特征表达能力和模型鲁棒性, 提高了整体精度。

Grad-Cam 方法通过热力图可视化神经网络关注度, 颜色条值反映关注度强弱。在本文模型中, 对比注意力机制模块前后的热力图发现, 注意力模块显著减少了对干扰噪声的关注, 增强了对关键特征信息的权重分配。对于“谐波+暂降”时频图(图 7), 注意力机制后更聚焦核心特征; 对于“谐波+暂降+闪变”时频图(图 8), 则增强了对闪变特征的关注, 从而有效区分两类扰动。

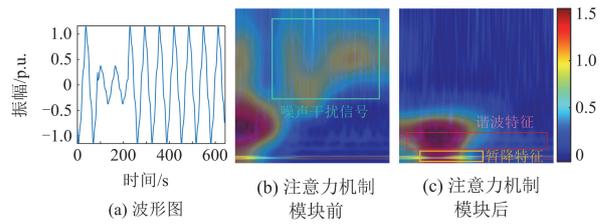


图 7 “谐波 + 暂降”热图对比

Fig. 7 Comparison of “harmonic + sag” heat map

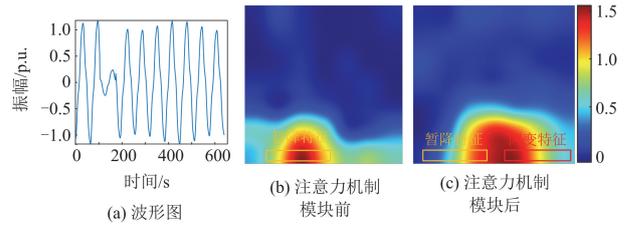


图 8 “谐波 + 暂降 + 闪变”热图对比

Fig. 8 Comparison of “harmonic + sag + flicker” heat map

表 3 DenseNet-121 与本文模型网络层参数对比

Table 3 Comparison of network layer parameters between DenseNet-121 and the model proposed in this paper

类型	输出尺寸	DenseNet-121	本文模型
卷积层 1	112×112		3×3 卷积, 步长 2
卷积层 2	112×112	7×7, 步长 2	3×3 卷积, 步长 1
卷积层 3	116×116		3×3 卷积, 步长 1
池化层	58×58		3×3 最大池化, 步长 2
密集块 1	58×58	{1×1 卷积} × 6 {3×3 卷积}	{1×1 卷积} × 3 {3×3 卷积}
过渡层 1	58×58 29×29		1×1 卷积 2×2 平均池化, 步长 2
密集块 2	29×29	{1×1 卷积} × 12 {3×3 卷积}	{1×1 卷积} × 6 {3×3 卷积}
过渡层 2	29×29 14×14		1×1 卷积 2×2 平均池化, 步长 2
密集块 3	14×14	{1×1 卷积} × 24 {3×3 卷积}	{1×1 卷积} × 9 {3×3 卷积}
过渡层 3	14×14 7×7		1×1 卷积 2×2 平均池化, 步长 2
密集块 4	7×7	{1×1 卷积} × 16 {3×3 卷积}	{1×1 卷积} × 6 {3×3 卷积}
分类层	7×7	7×7 全局平均池化	{CAM SAM1, SAM2}
	1×1	全连接, softmax	7×7 全局平均池化 全连接, softmax

### 3 研究框架及识别流程

本文提出的基于时频图像组合和 DenseNet-CPSAMs 的电能质量复合扰动识别基本流程如图 9 所示, 其主要步骤如下。

1) 首先, 使用 ICEEMDAN 算法对  $n$  个原始 PQDs 信号进行自适应分解与重构操作, 以此实现去噪目的, 确保信号模态的有效分离, 并减少虚假分量的产生。图 9 以 20 dB 暂态振荡信号为例进行分解重构。然后对重构信号进行同步提取变换和 S

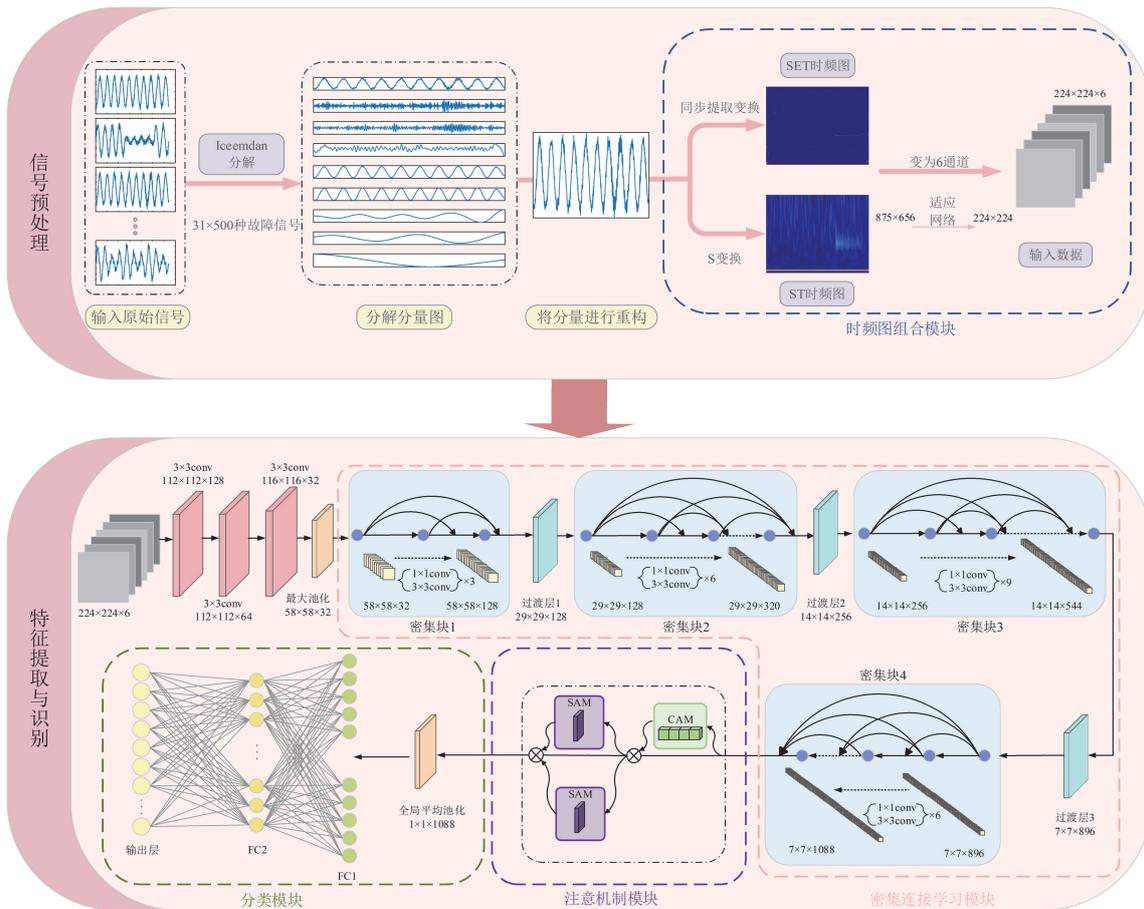


图 9 识别流程图

Fig. 9 Identification process

变换，得到 SET 时频图和 ST 时频图。最后调整两组时频图分辨率以适应深度学习网络的要求，组合得到 6 通道输入图像，实现对非平稳信号的处理。

2) 其次，基于注意力机制模块对 DenseNet-121 网络进行改进，首先利用 3 个 3×3 卷积层提取浅层特征信息，在减少参数量和计算复杂度的同时，保持特征提取能力。随后，通过密集块与过渡层实现特征重用，防止通道数过度增长，提高特征利用率与传播效率，缓解梯度消失。进一步构建由通道注意力模块串联两组并行空间注意力模块组成的混合注意力机制，自动学习并动态调整权重，强化关键特征并抑制冗余信息，提升模型表征能力及识别性能。

3) 最后，基于 DenseNet-CPSAMs 模型中注意力机制模块学习到的各类已知 PQDs 扰动特征，经分类模块将增强特征转换为一维向量，输入到 Softmax 分类器计算各类 PQDs 概率，输出最高概率类别作为识别结果，实现 PQDs 信号的准确分类。考虑多噪声及扰动组合，生成充足训练集，综合学

习得到高精度识别模型。

#### 4 算例及仿真结果分析

本文构建了一个包含 31 种扰动类型的数据集，每种类型各有 500 个样本，总计 15 500 个样本信号。所有信号均以 50 Hz 基波频率为基准，采样频率为 3200 Hz，每种信号均进行 10 个完整周波的采样，采样点数为 640，形成了 15500×640 的原始信号矩阵。为评估深度学习模型在 PQDs 识别中的性能，按 8:2 的比例将数据集划分为训练集和测试集。此外引入噪声模拟，具体设置了 4 个测试场景：以无噪声环境为基准对照组，并分别设置信噪比为 40 dB、30 dB 和 20 dB 的高斯白噪声环境进行对比分析。

##### 4.1 不同图像转换方式分解前后的识别准确率对比

为充分对比 PQDs 信号在不同图像转换方法下的特征表现，除 SET 时频图和 ST 时频图外，还构建了 CWT、WSST、同步提取小波变换(wavelet synchro-extracted transform, WSET)和 STFT 时频图，以及

GAF、轨迹圆(locus circle, LC)、马尔可夫(Markov transition fields, MTF) 3 种彩色特征图像数据集, 并参与训练识别, 采用 ResNet-18 模型进行训练, 通过多次重复实验计算平均识别率, 结果如表 4 所示。

时频图类别中, ST 时频图在低噪声环境下表现最优, 准确率超过 99%, 即使在 20 dB 噪声下仍具有较高的准确率。SET、CWT、WSST 和 WSET 4 种方法的性能趋势相似, 但识别准确率相对较低, 而 STFT 在高噪声下准确率下降更快。在彩色二维图类别中, GAF 方法在各噪声水平下均优于 LC 和 MTF。基于上述分析, 选取在各信噪比下识别率较高的图像转换方式, 先经 ICEEMDAN 分解、分量重构, 再进行二维图像转换, 识别率结果如表 5 所示。

对比表 4 和表 5, 原始数据经 ICEEMDAN 分解重构后, 各图像转换方式的识别率均得到提升, 尤其在 20 dB 噪声下最为显著, 其中 IC-ST、IC-SET、IC-CWT 提升幅度较大。在 20 dB 噪声环境下, 使用 t-SNE 算法对测试集数据进行降维可视化分析, 如图 10 所示。未分解的原始样本分布混沌、重叠严重, 缺乏明显规律(图 10(a))。ICEEMDAN 分解后样本分布有所改善, 但仍存在重叠, 分离度不高(图 10(b))。分解重构后的 SET 和 ST 时频图分别经模型识别后, 样本界限较明显, 但仍存在局部模糊现象(图 10(c)、图 10(d))。进一步观察发现, ST 时频图在红色和蓝色聚类区域聚集效果更佳, 而 SET 时频图在绿色区域能较好地地区分不同蓝色扰动。这表明 ICEEMDAN 有助于提升模型对扰动的理解和特征提取能力, 且不同时频图对扰动类型的识别精度存在差异, 可能具有互补性。

然而, 在彩色二维图中, 尽管 IC-GAF 在噪声水平下的分类准确率相对较高, 但与时频图相比,

其在各环境下的识别率均较低。基于时频图输入的模式凭借丰富的时频信息, 在捕捉扰动动态特性的瞬时变化方面表现优异, 因此其识别率优于 GAF 彩色二维图。鉴于此, 在组合图像识别中, 不再考虑彩色二维图像的仿真对比。

表 4 不同图像转换方式识别准确率对比

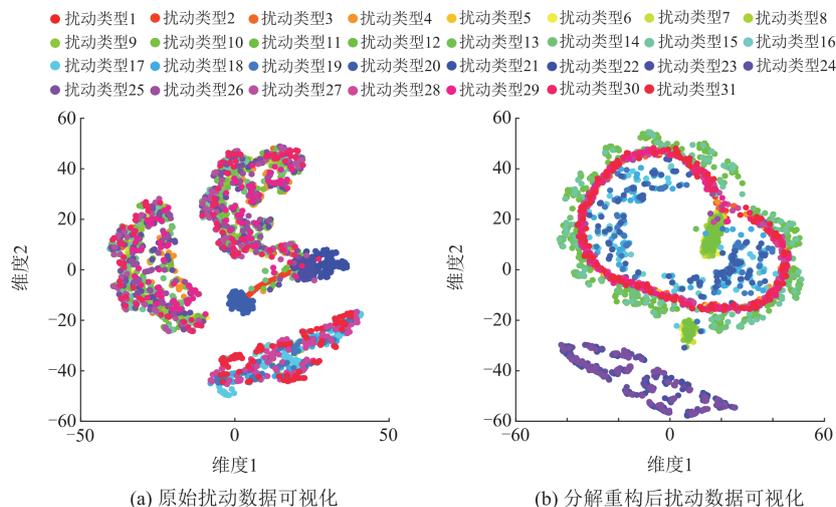
Table 4 Comparison of recognition accuracy of different image conversion methods

输入图像类别	分类准确率/%				
	无噪声	40 dB	30 dB	20 dB	
时频图	ST	99.710	99.677	99.129	94.710
	SET	98.839	98.807	98.674	93.936
	CWT	99.613	98.516	98.097	93.871
	WSST	99.387	99.355	98.807	93.968
	WSET	99.355	98.452	97.742	93.258
	STFT	98.452	98.065	97.581	90.452
彩色图	GAF	97.097	96.323	95.968	88.516
	LC	93.129	92.129	91.226	77.903
	MTF	84.613	81.936	78.903	70.097

表 5 经过 ICEEMDAN 分解重构后不同图像转换方式识别准确率对比

Table 5 Comparison of recognition accuracy of different image conversion methods after ICEEMDAN decomposition and reconstruction

输入图像类别	分类准确率/%				
	无噪声	40 dB	30 dB	20 dB	
时频图	IC-ST	99.742	99.710	99.032	96.807
	IC-SET	99.484	98.871	98.452	96.097
	IC-WT	99.613	99.581	98.774	95.613
	IC-WSST	99.355	98.387	98.226	93.774
	IC-WSET	99.097	98.290	98.097	93.968
彩色图	IC-GAF	97.161	93.452	95.710	90.677



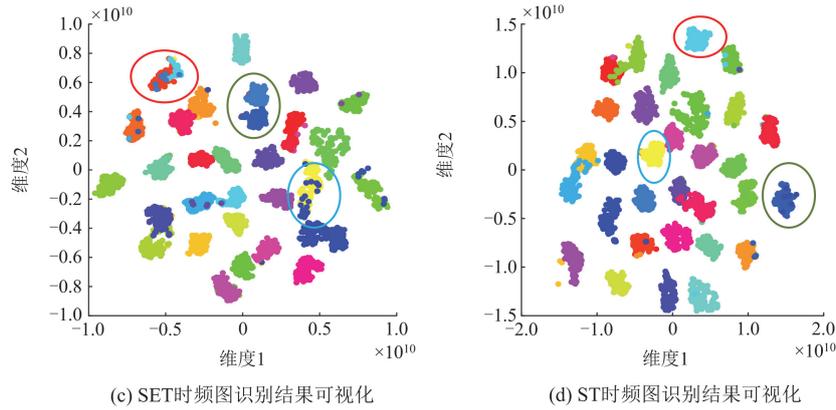


图 10 t-SNE 特征可视化

Fig. 10 Feature visualization of t-SNE

### 4.2 不同网络结构对比

为了验证本文模型的扰动识别性能，将经过 ICEEMDAN 分解，并重构后的分量作 S 变换，将生成的 ST 时频图分别输入 AlexNet、VGG-16、EfficientNet-b0、SqueezeNet、MobileNet-v2、ShuffleNet、ResNet-18 与 DenseNet-121 网络进行对比分析，结果如表 6 所示。

表 6 不同网络结构在不同信噪比下的分类准确率

Table 6 Classification accuracy of different network structures under different signal-to-noise ratios

识别模型	分类准确率/%			
	无噪声	40 dB	30 dB	20 dB
AlexNet	99.161	99.484	99.032	91.355
VGG-16	99.548	99.516	99.290	93.323
EfficientNet-b0	99.677	99.645	98.968	96.161
SqueezeNet	99.677	99.742	98.936	96.419
MobileNet-v2	99.710	99.677	99.226	93.419
ShuffleNet	99.742	99.581	98.903	96.516
ReseNet-18	99.742	99.710	99.032	96.807
DenseNet-121	99.742	99.742	99.097	97.226

在无噪声条件下，各深度学习模型分类准确率均超过 99%，表明其在图像分类中的强大性能。但在 20 dB 低信噪比条件下，模型性能差异显著，具体而言 AlexNet 准确率为 91.355%，而 DenseNet-121 高达 97.226%，相差 5.871%。在各种信噪比条件下，DenseNet 均表现出较高的准确率。相比之下，AlexNet 与 VGG-16 因网络深度不足、连接方式效率不足，在特征提取与表示上有所欠缺，且参数庞大。轻量化模型如 MobileNet-v2、SqueezeNet 及 ShuffleNet 在计算效率方面具有一定的优势，但特征提取能力不及 DenseNet-121。EfficientNet-b0 与 ResNet-18 虽具有较高的效率，但在特征重用与梯度传播方面稍逊于 DenseNet-121。

为验证本文模型分类性能，本节将采用 DenseNet-121、DenseNet-S 和本文模型 3 种密集连接网络对相同的样本集进行训练测试。同时，对 3 种网络下的 PQDs 识别准确率进行综合分析和对比，不同噪声环境下各模型对各类扰动的识别准确率对比结果如表 7 所示。

表 7 DenseNet-121、DenseNet-S 与本文模型对比

Table 7 Comparison between DenseNet-121, DenseNet-S and the model proposed

识别模型	分类准确率/%			
	无噪声	40 dB	30 dB	20 dB
DenseNet-121	99.807	99.742	99.129	97.258
DenseNet-S	99.871	99.742	99.226	97.742
本文模型	99.968	99.839	99.807	99.645

基于 DenseNet-121 模型，DenseNet-S 与本文模型均对 DenseBlock 中的卷积层进行了结构精简，将训练参数从 9.5 M 减少至 3 M。DenseNet-S 仅引入通道注意力机制，而本文模型进一步结合了纵向 SAM1 和横向 SAM2 空间注意力机制。分析结果显示，DenseNet-S 较原始 DenseNet-121 在准确率上有所提升，这证明了通道注意力机制的有效性。在所有信噪比下本文模型的平均精度高于 DenseNet-121 和 DenseNet-S，尤其在 20 dB 高噪声环境下，通道与空间注意力的结合显著提升了模型的抗干扰能力，使识别准确率达 99.645%。

### 4.3 本文模型方法实验验证

根据 4.1 节的分析，不同类型时频图在识别扰动时存在差异且具有一定互补性。为验证这一点，在 ResNet-18 模型上进行了组合时频图实验，结果如表 8 所示。

分析表 5 和表 8 对比结果可知，组合时频图的识别率优于单一时频图。在各种环境下，SET 与 ST

组合表现最佳, 这表明 SET 与 ST 的结合能够克服单一时频图的局限, 促进信息在跨尺度和跨维度上的融合, 从而构建出能够更全面、准确表征故障本质的模态子序列集合, 有效保留关键信息并凸显不同扰动特征。

表 9 对比了在本文模型下分解重构后的 ST 与 SET 时频图的扰动识别率。在 20 dB 噪声下, 两者的识别率均低于 30 dB 噪声下, 且 ST 时频图识别率高于 SET 时频图, 这表明 ST 时频图在高强度噪声下具有更强的抗噪性。当采用“ST + SET”组合时频图时, 各噪声环境下识别率均超过 99.6%, 这

进一步证明了 ST 与 SET 时频图在性能上的互补性, 其结合使用可显著提升模型的泛化能力和抗噪能力。

表 8 不同时频图特征组合识别准确率对比

Table 8 Comparison of recognition accuracy of different time-frequency graph feature combinations

输入图像类别	分类准确率/%			
	无噪声	40 dB	30 dB	20 dB
ST-SET	99.871	99.807	99.742	99.581
CWT-SET	99.839	99.613	99.161	96.871
ST-WSST	99.807	99.774	99.032	94.129
ST-WSET	99.839	99.936	99.161	97.226

表 9 ST 时频图、SET 时频图和组合时频图对比

Table 9 Comparison of ST time-frequency graph, SET time-frequency graph and combined time-frequency graph

信号	分类准确率/%											
	ST				SET				ST + SET			
	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
C1	100	100	100	98	98	98	98	95	100	100	100	100
C2	100	100	100	100	100	100	100	99	100	100	100	100
C3	100	100	100	98	100	100	99	94	100	100	100	100
C4	100	100	99	100	99	99	100	100	100	100	100	100
C5	100	100	100	100	100	100	100	100	100	100	100	100
C6	100	100	100	98	100	100	100	96	100	100	100	100
C7	100	100	100	100	100	100	100	100	100	100	100	100
C8	100	100	100	100	100	100	100	99	100	100	100	100
C9	99	98	98	91	96	96	96	91	100	99	99	99
C10	98	98	95	91	96	96	94	92	100	100	100	99
C11	100	100	100	98	99	99	99	99	100	100	100	100
C12	100	100	100	98	98	98	98	93	100	100	100	100
C13	99	99	98	99	100	100	98	97	100	99	99	99
C14	100	100	97	92	97	96	94	93	100	99	99	99
C15	100	100	100	99	100	100	99	98	100	100	100	100
C16	100	100	100	99	100	100	100	91	100	100	100	100
C17	100	100	99	99	100	100	100	98	100	100	100	100
C18	100	100	100	99	100	100	100	100	100	100	100	100
C19	100	100	100	96	100	100	99	95	100	100	100	100
C20	100	100	100	100	100	100	99	100	100	100	100	100
C21	100	100	100	100	100	100	100	98	100	100	100	99
C22	100	100	100	100	100	100	100	100	100	100	100	100
C23	100	100	100	100	99	99	99	100	100	100	100	100
C24	99	99	95	89	96	95	99	94	100	100	100	98
C25	100	100	100	98	99	99	99	99	100	99	99	99
C26	100	100	100	96	98	98	97	91	100	100	100	100
C27	100	100	99	98	98	98	98	98	100	100	99	99
C28	100	100	98	95	100	100	100	94	100	100	100	99
C29	99	99	98	92	95	95	95	88	99	99	99	99
C30	100	100	99	96	98	98	96	93	100	100	100	100
C31	99	99	100	100	100	100	100	96	100	100	100	100
平均精度	99.774	99.742	99.194	97.387	98.903	98.839	98.581	96.161	99.968	99.839	99.807	99.645

进一步针对特定扰动类型的识别情况展开分析。在 20 dB 噪声环境下, ST 时频图对 C12、C16、C26、C29 等扰动的识别准确率显著高于 SET 时频图, 提升幅度达 5% 以上。例如, 对于 C26 扰动, ST 时频图的识别率达到 96%, 而 SET 时频图仅为 91%, 且 SET 时频图容易将 C26 误识别为 C10。

图 11 展示了 C10、C24 和 C26 三种易混淆扰动的 SET 和 ST 时频图对比。ST 时频图对 C24 的识别率较低, 易将其误识别为 C10; 相反, SET 时频图对 C24 的识别率高达 94%。对比图 11(b) 中的局部放大图像可知, 两种时频图在表征闪变波动特征时, 效果均相对微弱。不过, 在 SET 时频图对应的局部放大区域, 闪变特征的颜色梯度变化更为显著, 这一特性有助于更清晰地辨识 C10(图 11(a))与 C24(图 11(b))之间的差异。

而对于 C26 扰动类型, ST 时频图具有较高的识别准确率。从图 11(c) 可以看出, C26 振荡信号在 SET 时频图中的能量分布相对集中且呈线性, 因此容易受到强噪声的影响; 而 ST 时频图覆盖的区域更广泛, 特征呈面状分布, 具有较强的抗噪性。

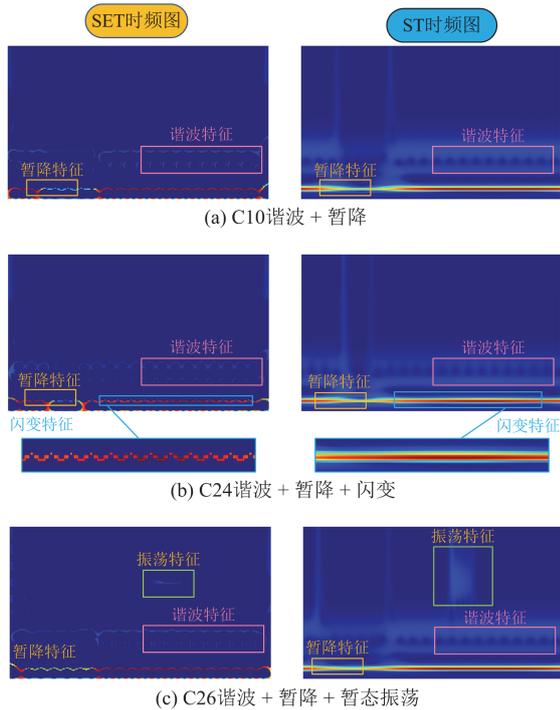


图 11 不同模型在 20 dB 下的识别性能

Fig. 11 Recognition performance of different models at 20 dB

#### 4.4 不同方法对比

本文对比分析了当前研究中的多种模型与方法, 包括 S 变换时频图结合 GCNN-AFEN 的方法<sup>[14]</sup>、特征分量彩色图与 CWT 时频图组合输入的改进六

通道 ResNet-18 模型<sup>[23]</sup>、基于多通道 GAF 和 ResNet 的分类方法<sup>[20]</sup>、采用多尺度卷积融合时间序列 Transformer(multi-scale convolution fusion time series transformer, MCF-TST)模型<sup>[8]</sup>以及基于多级注意力机制池化融合(multi-level attention pooling fusion, MAPF)的 PQDs 点分类及时间定位方法<sup>[9]</sup>, 对比结果见表 10。

表 10 不同方法在不同信噪比下分类准确率的比较

Table 10 Comparison of classification accuracy of different methods under different signal-to-noise ratios

识别模型	扰动数量	是否包含三重及以上扰动	分类准确率/%			
			无噪声	40 dB	30 dB	20 dB
GCNN-AFEN	12	否	—	99.26	98.98	96.62
CWT-ResNet18	15	否	99.63	99.63	99.48	—
GAF-ResNet	25	否	98.34	98.30	94.24	—
MCF-TST	29	是	99.33	99.34	99.51	96.74
MAPF	63	是	99.41	99.33	99.10	—
本文	31	是	99.97	99.84	99.81	99.65

前 3 种模型均未涵盖三、四重扰动的情况, 在 30 dB 信噪比下, 相比前 3 种模型, 本文方法的识别准确率分别提升了 0.83%、0.33%、5.57%。与文献[8-9]中的方法相比, 尽管二者均考虑了三、四重扰动, 但在 30 dB 下本文方法的识别准确率仍分别高出 0.3%、0.71%。特别是与文献[8]相比, 由于其涉及的扰动类型和数量与本文相近, 在无噪声、40 dB、20 dB 条件下, 本文方法的识别精度分别高出 0.64%、0.5%、2.91%。对比结果显示, 本文模型的识别性能好、泛化能力强, 尤其在高信噪比下优势更明显, 这验证了本文方法处理复杂识别任务的有效性和可靠性。

## 5 结论

为满足新型电力系统对 PQDs 识别的需求, 本文结合了 DenseNet 深度感知和信息重用特性与 ICEEMDAN 分解重构后的 ST 和 SET 时频图转换能力, 提出基于时频图像组合以及 DenseNet-CPSAMs 的 PQDs 识别方法。通过仿真实验, 得出以下结论。

1) 在信号处理方面, 首先采用 ICEEMDAN 方法精准分解扰动信号并重构去噪, 然后利用 SET 和 ST 时频分析将一维分量转换为二维图像, 强化特征表现, 形成互补特征, 为后续 DenseNet-CPSAMs 模型捕获时空特征提供参考。

2) 在识别模型方面, 本文采用了 DenseNet-

CPSAMs 轻量级网络结构。通过调整输入卷积层、减小 DenseBlock 参数以及引入注意力机制等措施, 能够精准提取时频图多维特征。基于此, 该方法实现了轻量化设计, 具备高运算效率、高识别精度以及强噪声鲁棒性。

3) 在新型电力系统背景下, 复合扰动事件频发且类型多样。随着电能质量监控系统的持续完善与优化, 电能质量数据逐渐呈现出海量化的发展趋势。因此, 本文研究的重点在于海量电能质量扰动数据的高效识别。在样本生成的实用性、网络复杂度控制以及强噪声多重复合扰动下的鲁棒性等方面, 本文所提出的模型具有一定的应用价值。

4) 鉴于数学模型模拟的 PQDs 与实际非线性系统暂态波形存在差异, 后续研究需利用实测数据对模型进行验证和改进。然而, 获取涵盖多种扰动类型的实测数据极为困难。因此, 可将本文所提模型作为基础模型, 并针对不同识别场景, 对基于 IEEEStd1159-2019 标准生成的数据进行预训练, 再结合少量实测数据进行迁移学习和权重更新, 以增强模型在特定场景下的适应性和识别精度。

#### 参考文献

- [1] 周孝信, 鲁宗相, 刘应梅, 等. 中国未来电网的发展模式和关键技术[J]. 中国电机工程学报, 2014, 34(29): 4999-5008.  
ZHOU Xiaoxin, LU Zongxiang, LIU Yingmei, et al. Development models and key technologies of future grid in China[J]. Proceedings of the CSEE, 2014, 34(29): 4999-5008.
- [2] LIN Y, LUO H, CHEN Y, et al. Enhancing participation of widespread distributed energy storage systems in frequency regulation through partitioning-based control[J]. Protection and Control of Modern Power Systems, 2024, 10(1): 76-89.
- [3] 董海艳, 贾清泉, 王宁, 等. 复杂电能质量扰动事件区段定位方法研究[J]. 中国电机工程学报, 2017, 37(17): 4931-4940, 5212.  
DONG Haiyan, JIA Qingquan, WANG Ning, et al. The method for section location of complex power quality disturbance events[J]. Proceedings of the CSEE, 2017, 37(17): 4931-4940, 5212.
- [4] 于华楠, 于宏昊. 基于单向表示字典学习的电能质量扰动识别方法[J]. 电测与仪表, 2023, 60(4): 133-138.  
YU Huanan, YU Honghao. Power quality disturbance recognition method based on unidirectional representation dictionary learning[J]. Electrical Measurement & Instrumentation, 2023, 60(4): 133-138.
- [5] 王昭卿, 常延朝, 陈建磊, 等. 基于多融合 MVMD-ISVM 的复杂电能质量扰动识别方法[J]. 供用电, 2024, 41(9): 70-77.  
WANG Zhaoqing, CHANG Yanzhao, CHEN Jianlei, et al. Identification method for complex power quality disturbances based on multi-fusion MVMD-ISVM[J]. Distribution & Utilization, 2024, 41(9): 70-77.
- [6] 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.
- [7] 毕贵红, 鲍童语, 陈臣鹏, 等. 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[J]. 电力系统保护与控制, 2024, 52(4): 12-25.  
BI Guihong, BAO Tongyu, CHEN Chenpeng, et al. Composite PQDs identification based on a hybrid decomposition multi-scale time-frequency map and Res-GRU-AT[J]. Power System Protection and Control, 2024, 52(4): 12-25.
- [8] 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[2024-09-20]. DOI: 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 convolution fusion time series transformer[J/OL]. Power System Technology: 1-12[2024-09-20]. DOI: 10.13335/j.1000-3673.pst.2023.1764
- [9] 刘宇龙, 崔宪阳, 袁丁, 等. 基于多级注意力机制融合的电能质量扰动点分类及时间定位方法研究[J]. 中国电机工程学报, 2024, 44(11): 4298-4311.  
LIU Yulong, CUI Xianyang, YUAN Ding, et al. Research on multi-level attention mechanism optimized method for point classification and time interval identification of power quality disturbances[J]. Proceedings of the CSEE, 2024, 44(11): 4298-4311.
- [10] 黄光磊, 田启东, 林志贤, 等. 基于图卷积神经网络和格拉姆角场的电能质量扰动分类[J]. 电气传动, 2024, 54(3): 84-90.  
HUANG Guanglei, TIAN Qidong, LIN Zhixian, et al. Power quality disturbance classification based on graph convolutional neural networks and Gramian angular field[J]. Electric Drive, 2024, 54(3): 84-90.
- [11] 钱倍奇, 陈谦, 李宗源, 等. 基于马尔可夫转换场与多头注意力机制的电能质量扰动分类方法[J]. 电网技术, 2024, 48(2): 721-733.  
QIAN Beiqi, CHEN Qian, LI Zongyuan, et al. Power quality disturbances classification based on Markov transition field and multi-head attention[J]. Power System Technology, 2024, 48(2): 721-733.
- [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] 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.
- [14] 张锐, 张闯, 高辉, 等. 基于自适应特征增强分组卷积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.
- [15] PATTANAIAK 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] // 2023 International Conference on Power Electronics and Energy (ICPEE), January 3-5, 2023, Bhubaneswar, India: 1-6.
- [16] HUIXI Y, LI X, ZHOU F, et al. Classification of multiple power quality disturbances based on continuous wavelet transform and lightweight convolutional neural network[J]. Energy Science & Engineering, 2023, 11(9): 3232-3249.
- [17] 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): 81-90.
- 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): 81-90.
- [18] 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.
- [19] SINDI H F, NOUR M K, RAWA M, et al. A novel hybrid deep learning approach including combination of 1D power signals and 2D signal images for power quality disturbance classification[J]. Expert Systems with Applications, 2021, 217.
- [20] 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): 369-379.
- 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.
- [21] LIU Y, YUAN D, FAN H, et al. A multidimensional feature-driven ensemble model for accurate classification of complex power quality disturbance[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-13.
- [22] MONTEIRO R V A, TEIXEIRA R F S, BRETAS A S. Power quality disturbances diagnosis: a 2D densely connected convolutional network framework[J]. Electric Power Systems Research, 2022, 212.
- [23] 张逸, 欧杰宇, 金涛, 等. 基于特征图像组合与改进 ResNet-18 的电能质量扰动识别方法[J]. 中国电机工程学报, 2024, 44(7): 2531-2545.
- ZHANG Yi, OU Jieyu, JIN Tao, et al. Power quality disturbance recognition method based on feature image combination and modified ResNet-18[J]. Proceedings of the CSEE, 2024, 44(7): 2531-2545.
- [24] Recommended practice for monitoring electric power quality: IEEE 1159—2019[S].
- [25] 刘慧鑫, 沈晓东, 魏泽涛, 等. 基于校准窗口集成与耦合市场特征的可解释双层日前电价预测[J]. 中国电机工程学报, 2024, 44(4): 1272-1286.
- LIU Huixin, SHEN Xiaodong, WEI Zetao, et al. Interpretable two-layer day-ahead electricity price forecast based on calibration window combination and coupled market characteristics[J]. Proceedings of the CSEE, 2024, 44(4): 1272-1286.
- [26] LÜ Y, MA Y, YUAN R, et al. Velocity synchronous chirplet extracting transform: an effective tool for fault diagnosis of variable-speed rotational machinery[J]. IEEE Sensors Journal, 2022, 22(13): 13201-13211.
- [27] STOCKWELL R G, MANSINHA L, LOWE R P. Localization of the complex spectrum: the S transform[J]. IEEE Transactions on Signal Processing, 1996, 44(4): 998-1001.
- [28] 李建文, 秦刚, 李永刚, 等. 基于布莱克曼窗与窗宽比的 S 变换电能质量扰动特征提取[J]. 高电压技术, 2020, 46(8): 2769-2779.
- LI Jianwen, QIN Gang, LI Yonggang, et al. Feature extraction based on S-transform of blackman window and window ratio in power quality disturbances[J]. High Voltage Engineering, 2020, 46(8): 2769-2779.

收稿日期: 2024-11-08; 修回日期: 2025-02-25

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: KM\_BGH@163.com

杨楠(2000—), 女, 硕士研究生, 研究方向为电能质量扰动分析; E-mail: 2428794114@qq.com

杨毅(1982—), 男, 通信作者, 硕士, 讲师, 研究方向为电力系统在线监测。E-mail: 44947434@qq.com

(编辑 许威)