

用于复杂电能质量扰动分类的全尺度特征校准多任务分类方法

华回春¹, 房东霖¹, 郭 敏²

(1. 新能源电力系统国家重点实验室(华北电力大学), 河北 保定 071003;

2. 广西电网有限责任公司电力科学研究院, 广西 南宁 530023)

摘要:非线性电力电子装置的接入会使电网产生复杂的电能质量扰动(power quality disturbances, PQDs), 为了提高对 PQDs 信号的分类准确率, 提出了一种用于复杂 PQDs 分类的全尺度特征校准多任务分类方法(omni-scale feature calibration method, OSFC)。首先, 为进一步提高一维卷积神经网络的特征提取能力, 在全尺度卷积模块的基础上, 使用了压缩激励网络模块(squeeze-and-excitation network, SENet)模块来校准不同尺度的特征对扰动分类的重要性; 然后, 构建多任务学习框架, 将 PQDs 标签之间的相关性转化为 PQDs 分类任务之间的相关性, 提高了模型的分类精度; 最后, 基于仿真 PQDs 信号进行了一系列实验, 结果表明所提方法在不同噪声水平下的分类准确率可以达到 99%。

关键词:电能质量扰动; 全尺度; 特征校准; SENet 模块; 多任务学习; 多任务分类方法

中图分类号: TM711 **文献标志码:** A **文章编号:** 1001-9898(2026)01-0001-08

Omni-scale Feature Calibration Method for Multi-task Classification of Complex Power Quality Disturbances

HUA Huichun¹, FANG Donglin¹, GUO Min²

(1. State Key Lab of Alternate Electrical Power System with Renewable Energy Sources (North China Electric Power University), Baoding 071003, China; 2. Electric Power Research Institute of Guangxi Power Grid Co., Ltd., Nanning 530023, China)

Abstract: The integration of nonlinear power electronic devices generates complex power quality disturbances (PQDs) in the power grid. To improve the classification accuracy of PQD signals, we propose an omni-scale feature calibration multi-task classification method (OSFC) for complex PQDs. Firstly, in order to further improve the feature extraction ability of 1-D convolution neural network, the SENet Module is designed to calibrate the importance of features at different scales to disturbances classification on the basis of omni-scale convolution module. Then, the multi-task learning framework is constructed which can transform the correlation between PQDs labels into the correlation between PQDs classification tasks and meet the requirements of real-time PQDs classification on the premise of ensuring the classification accuracy. Finally, experiments based on simulation complex PQDs signals are conducted, where the results demonstrate that the classification accuracy of the proposed approach can reach 99% at different noise levels.

Key words: power quality disturbance; omni-scale; feature calibration; SENet module; multi-task learning; multi-task classification method

0 引言

随着电力电子技术的发展, 现代电力系统中涌现出各种非线性电力电子装置, 如敏感电子器件、功率变换器、工业驱动装置等, 这些设备可能

会诱发电网中电压和电流波形的严重畸变, 从而逐渐增加电力系统中复杂电能质量扰动(power quality disturbances, PQDs) 的发生概率^[1]。IEEE std 1159—2019《IEEE Recommended Practice for Monitoring Electric Power Quality》定义

收稿日期: 2024-12-11 修回日期: 2025-06-17

作者简介: 华回春(1980—), 男, 副教授, 主要从事电能质量方向研究工作。

了 7 类典型的 PQDs, 包括脉冲瞬变、振荡瞬变、电压暂降、电压中断、电压暂升、谐波和电压波动^[2]。在现代电力系统中, PQDs 通常以复杂扰动形式存在, 而不是理想的单一扰动^[3]。确定复杂 PQDs 缓解措施的前提是准确划分 PQDs 信号的类型, 因此, 为了保护电力系统免受复杂 PQDs 的影响, 有必要对复杂 PQDs 信号进行准确分类^[4-5]。

传统的 PQDs 分类方法通常包括特征提取和扰动分类 2 个步骤, 如 S 变换^[6]、完全集合经验模态分解^[7]、LightGBM^[8]和核 SVM^[9]。然而, 特征提取方法与机器学习算法的简单结合不能最大限度地提高分类系统的效率和性能^[10]。近年来, 深度学习因其能够自动学习深层特征而被应用于各个研究领域, 复杂 PQDs 分类领域也引入了深度学习方法。用于复杂 PQDs 分类的大多数深度学习方法可分为基于图像和基于时间序列的深度学习方法两类。基于图像的深度学习方法需要通过 S 变换、马尔可夫变换场、格拉姆角场等图像变换技术将复杂 PQDs 信号转换为图像数据, 然后使用 ResNet 和 GoogLeNet 等深度学习图像分类方法对图像数据进行分类^[3, 11-13]。然而, 图像转换步骤增加了模型的耗时, 并且需要更多的存储空间来存储图像数据。为了避免基于图像的深度学习方法的缺陷, 一些研究者提出了基于时间序列的深度学习方法来对复杂的 PQDs 信号进行分类, 如一维卷积神经网络(convolution neural network, CNN)^[14-15], CNN 的特征提取能力会受到感受野的影响, 合适的感受野能大大提高 CNN 提取有效特征的能力^[16]。为了使一维 CNN 能够覆盖更全面的感受野, 文献^[17]提出了一种用于时间序列分类的全尺度卷积模块。在 PQDs 分类问题中, 不同尺度的特征对不同类型 PQDs 的重要性不同, 而全尺度卷积模块虽然能提取到更全面的特征, 但该模块认为所有尺度的特征都是同等重要的, 这导致其在 PQDs 分类问题中的识别准确率仍有提升空间。

针对上述问题, 本文提出了一种用于复杂 PQDs 的全尺度特征校准多任务分类方法(omni-scale feature calibration method, OSFC), 介绍 OSFC 模型的设计与构建, 进行了各种实验测试, 其创新如下: 全尺度卷积以广度扩展为特点来增大卷积神经网络的感受野, 针对现有应用中对于

同尺度特征的处理不够有效的情况, 本文在全尺度卷积层的基础上, 引入了压缩激励网络模块(squeeze-and-excitation network, SENet)^[18], 该模块能够对不同尺度的特征进行校准, 使 OSFC 能够提取出更有利于复杂 PQDs 分类的具有高判别性的特征, 显著提升了模型的性能, 弥补了全尺度卷积在特征处理方面的不足。同时, 将 PQDs 标签之间的相关性转化为 PQDs 分类任务之间的相关性, 然后利用多任务学习完成模型构建, 这种方法更有效地利用了标签间的关系, 进一步提高了模型的准确率。

1 全尺度卷积模块原理

1.1 感受野

假设输入的电能质量扰动信号序列为 $s = (s_1, s_2, \dots, s_n)^T$, 输入信号经过多个一维卷积层计算后输出的特征序列为 $f = (f_1, f_2, \dots, f_m)^T$, 那么感受野 R_i 定义为输入信号 s 中参与计算特征 f_i 的区域大小, 其计算公式为

$$R_i = R_{i-1} + (p_i - 1) \times \prod_{j=1}^{i-1} t_j \quad (1)$$

式中: R_i 为第 i 层卷积层的感受野大小; p_i 为第 i 层卷积层的卷积核大小; t_j 为第 j 层卷积核的滑动步长。

根据定义可知, 感受野的大小反映了特征 f_i 的尺度范围, 感受野越大, 表示特征 f_i 能反映的原始信号序列的范围越大, 更可能包含扰动信号里的全局特征; 感受野越小, 表示特征 f_i 能反映的原始信号序列的范围越小, 更可能包含扰动信号里的局部特征。

1.2 全尺度卷积模块

依据感受野与扰动信号局部特征、全局特征的关系, 可对全尺度卷积模块进行设计, 使其能够提取出电能质量扰动信号不同尺度的特征。

全尺度卷积模块有 3 个卷积层, 如图 1 所示, 每个卷积层都包括多个不同质数长度的一维卷积核、特征连接层与批归一化层, 激活函数均为 ReLU 函数, 其中卷积核长度集合可表示为

$$K^{(i)} = \begin{cases} \{1, 2, 3, 5, 7, 11, \dots, p\}, & i = 1, 2 \\ \{1, 2\}, & i = 3 \end{cases} \quad (2)$$

式中: $K^{(i)}$ 为第 i 层卷积核长度集合; p 为能够覆

盖指定范围内所有感受野的最小质数。




图1 全尺度卷积模块

特征连接层将不同卷积核输出的特征序列在通道方向上进行拼接。批归一化层对特征图进行批归一化处理,从而确保特征服从相同的分布,假设特征图为 $X \in \mathbb{R}^{m \times n}$,批归一化层的计算公式为

$$\begin{cases} \mu_j = \frac{1}{m} \sum_{i=1}^m x_{i,j} \\ \sigma_j^2 = \frac{1}{m} \sum_{i=1}^m (x_{i,j} - \mu_j)^2 \\ \tilde{x}_{i,j} = \frac{x_{i,j} - \mu_j}{\sqrt{\sigma_j^2 + \epsilon}} \\ y_{i,j} = \gamma_j \tilde{x}_{i,j} + \beta_j \end{cases} \quad (j = 1, 2, \dots, n) \quad (3)$$

式中: n 为特征维度; m 为批次大小; ϵ 为一个较小的数; μ_j 为特征图 X 中第 j 列元素的均值; $y_{i,j}$ 为批归一化层的输出结果; $x_{i,j}$ 为特征图 X 中的元素; γ_j, β_j 为可学习的参数。

全尺度卷积模块中卷积核的滑动步长均为 1, 因此由公式(1)可得全尺度卷积模块的感受野为 $P = \{k^{(1)} + k^{(2)} + k^{(3)} - 2 \mid k^{(i)} \in K^{(i)}, i = 1, 2, 3\}$ (4)

哥德巴赫猜想指出任何一个正偶数都可以由 2 个质数组成。尽管哥德巴赫猜想还未在理论上得到证明,但是其正确性已被验证到 4×10^{14} 以内的偶数^[19],这已远超电能质量扰动信号的长度。又因为全尺度卷积模块前 2 个全尺度卷积层的卷积核长度都是质数,因此有

$$E = \{k^{(1)} + k^{(2)} \mid k^{(i)} \in K^{(i)}, i = 1, 2\} \quad (5)$$

式中: E 为一定范围内的偶数集合。

将公式(5)代入公式(4)可得

$$P = \{e + k^{(3)} - 2 \mid e \in E, k^{(3)} \in K^{(3)}\} \quad (6)$$

结合公式(2)和公式(6),可得全尺度卷积模块的感受野为

$$P = \{e \mid e \in E\} \cup \{e - 1 \mid e \in E\} \equiv \mathbb{N}^+ \quad (7)$$

式中: $\mathbb{N}^+$ 为指定范围内的所有正整数集合。

综上所述,只需将全尺度卷积模块里前两层

卷积层的卷积核长度设置为质数集合,就可以使全尺度卷积模块覆盖一定范围内的全部感受野,从而在电能质量扰动信号里提取到一定范围内的全尺度特征。与其他卷积模块相比,全尺度卷积模块提高了特征的多样性,提取到的特征序列包含了一定范围内的全局特征与局部特征,有利于对不同类别的电能质量扰动进行分类识别。

2 全尺度特征校准多任务分类方法

不同尺度的特征对复杂 PQDs 类型的分类具有不同的重要性,而原始的全尺度卷积模块^[17]认为所有尺度特征都同等重要。因此,本文引入了 SENet 模块来校准不同尺度特征的重要性,然后使用多任务学习框架来构建模型。

2.1 SENet 模块

全尺度卷积模块能够在一定范围内提取到电能质量扰动信号的全局特征与局部特征,但其未能关注到不同尺度特征之间的相关性以及同一尺度下不同特征的重要程度,因此引入 SENet,通过神经网络训练的方式来自适应地获取每个特征通道的重要性权重,利用特征加权的方式来增强有用的特征通道并抑制用处不大的特征通道。

SENet 模块包括特征压缩、通道激活和重加权,如图 2 所示。假设输入的特征图为 $\mathbf{Y} = [y_1, y_2, \dots, y_c]^T \in \mathbb{R}^{c \times n}$,在特征压缩中,利用全局平均池化对每一个特征通道进行压缩处理,得到特征向量 $\hat{\mathbf{y}} = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_c)^T \in \mathbb{R}^{c \times 1}$,计算公式为

$$\hat{y}_i = f_{\text{GAP}}(y_i) = \frac{1}{n} \sum_{j=1}^n y_{i,j} \quad (8)$$

式中: f_{GAP} 为全局平均池化函数; n 为每个特征通道的特征序列长度; y_i 为特征图 $\mathbf{Y}$ 中第 i 个通道的特征序列($i = 1, 2, \dots, c$),其中, c 为特征图的通道数。




图2 SENet 模块

在通道激活中,利用 2 个全连接层网络对特征向量进行缩放处理,得到通道权重向量 $\hat{\omega} = (\hat{\omega}_1, \hat{\omega}_2, \dots, \hat{\omega}_c)^T \in \mathbb{R}^{c \times 1}$,激活函数选择 ReLU 函数和 Sigmoid 函数,计算公式为

$$\hat{\omega} = f_{\text{sigmoid}}(\mathbf{W}_2 \cdot f_{\text{ReLU}}(\mathbf{W}_1 \cdot \mathbf{y})) \quad (9)$$

式中: f_{sigmoid} 为 Sigmoid 函数; f_{ReLU} 为 ReLU 函数; $\mathbf{W}_1, \mathbf{W}_2$ 分别为第 1 个、第 2 个全连接层的权重矩阵,其中 $\mathbf{W}_1 \in \mathbb{R}^{\frac{c}{r} \times c}$ 、 $\mathbf{W}_2 \in \mathbb{R}^{c \times \frac{c}{r}}$; r 为缩放比例。

ReLU 函数和 Sigmoid 函数的计算公式分别为:

$$f_{\text{ReLU}}(x) = \max(0, x) \quad (10)$$

$$f_{\text{sigmoid}}(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

在重加权中,将通道权重向量 $\hat{\omega}$ 与特征图 $\mathbf{Y}$ 对应的特征通道相乘,得到 SENet 模块的输出 $\mathbf{Z} = [z_1, z_2, \dots, z_c]^T \in \mathbb{R}^{c \times n}$,计算公式如下

$$z_i = \hat{\omega}_i \cdot y_i \quad (12)$$

式中: $\hat{\omega}_i$ 为第 i 个通道的权重。

SENet 模块利用通道权重向量 $\hat{\omega}$ 来衡量不同特征通道的重要程度,并通过加权的方式使神经网络聚焦于更加重要的特征通道上,这可以在全尺度卷积模块的基础上对不同类型扰动信号的局部特征与全局特征进行衡量,突出对扰动类型识别有利的特征,抑制不利于扰动类型识别的特征,从而进一步提高电能质量扰动识别的准确率。

2.2 多任务学习

多任务学习是一种基于共享表示的机器学习模式^[20-21],利用多个具有相关性的任务中包含的有用信息来帮助每个任务学习到更加准确的分类器。结合电能质量扰动识别问题的实际情况,分别构建 6 个扰动识别多分类任务:第 1 个任务识别电压暂降、电压暂升、电压中断,第 2 个任务识别脉冲瞬变,第 3 个任务识别振荡瞬变,第 4 个任务识别电压波动,第 5 个任务识别谐波,第 6 个任务判断信号是否为正常信号。每个输入的扰动信号都基于上述 6 个任务进行识别,并根据模型最终输出的编码向量判断扰动信号的类别。在编码向量中,任务 1 的暂降、暂升、中断依次被标记为 1、2、3,若扰动信号不属于这 3 种类别,则被标记为 0;任务 2 的脉冲被标记为 1,若扰动信号不属

于该类别,则被标记为 0;剩余任务的标记方式与任务 2 一致,若扰动信号属于对应类别,则标记为 1,否则标记为 0。表 1 展示了以“暂升+谐波”为例的编码向量标记。

表 1 “暂升+谐波”扰动的编码向量

项目	任务 1	任务 2	任务 3	任务 4	任务 5	任务 6
扰动类别	电压暂降/ 电压暂升/ 电压中断	脉冲 瞬变	振荡 瞬变	电压 波动	谐波	正常
编码	2	0	0	0	1	0

第 1 个任务的损失函数选择多分类交叉熵,计算公式为

$$l_1 = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^4 h_{i,j} \ln(q_{i,j}) \quad (13)$$

式中: $h_{i,j}$ 为第 i 个样本属于第 j 个类别的真实概率; $q_{i,j}$ 为第 i 个样本属于第 j 个类别的预测概率; n 为样本数量。

其余任务的损失函数选择二分类交叉熵,计算公式为

$$l_k = -\frac{1}{n} \sum_{i=1}^n [h_i \ln(q_i) + (1 - h_i) \ln(1 - q_i)] \quad (14)$$

式中: h_i 为第 i 个样本的标签,正类为 1,负类为 0; q_i 为第 i 个样本预测为正类的概率, $k \in \{2, 3, 4, 5, 6\}$ 。

结合以上分析,多任务学习的目标函数可表示为

$$l = \sum_{k=1}^6 \omega_k l_k \quad (15)$$

式中: ω_k 为第 k 个任务的权重; l_k 为第 k 个任务的损失。

2.3 模型整体结构

结合全尺度卷积模块与 SENet 模块,在多任务学习模式下构建电能质量扰动识别模型,模型整体框架如图 3 所示,其中全尺度卷积层与 SENet 模块为多任务学习模型的共享参数层;全连接层作为多任务学习模型中不同任务的特定参数层。

OSFC 模型在特征提取阶段的计算公式为

$$x^{(j)} = f_{\text{SE}}^{(j)}(f_{\text{OS}}^{(j)}(x^{(j-1)})) \quad (16)$$

式中: $x^{(j)}$ 为第 j 个 SENet 模块的输出; $f_{\text{SE}}^{(j)}$ 为第 j 个 SENet 模块; $f_{\text{OS}}^{(j)}$ 为第 j 个全尺度卷积模块; j

$=1,2,3$,当 $j=1$ 时, $x^{(j-1)}$ 为输入的 PQDs 信号。

OSFC 模型在分类阶段的计算公式如下

$$y_{\text{result}}^{(t)} = f_{\text{Softmax}}(f_{\text{FC}}^{(t)}(f_{\text{GAP}}(x^{(3)}))) \quad (17)$$

式中: $y_{\text{result}}^{(t)}$ 为第 t 个任务的分类结果; f_{Softmax} 为 Softmax 激活函数; $f_{\text{FC}}^{(t)}$ 为第 t 个任务的全连接层, $t=1,2,3,4,5,6$; f_{GAP} 为全局平均池化层; $x^{(3)}$ 为第 3 个 SENet 模块输出的特征。




图 3 OSFC 模型

3 算例验证

根据 IEEE std 1159—2019 并结合相关文献^[14,22]建立电能质量扰动数据集,基波频率为 50 Hz,采样频率设置为 3 200 Hz,采样周期为 10 个周期,即每个信号有 640 个采样点。电能质量扰动数据集中包含 7 类单一电能质量扰动,主要有电压暂降(S1)、电压暂升(S2)、电压中断(S3)、脉冲瞬变(S4)、振荡瞬变(S5)、电压波动(S6)和谐波(S7)。考虑电能质量扰动识别问题的实际情况,在单一电能质量扰动的基础上构建了 13 种复合电能质量扰动信号。另外,将正常信号(S8)作为单独一个类别。

根据相关文献^[14],通过对扰动信号添加高斯白噪声的方式来模拟实际工程中所获得的采样信号,叠加不同信噪比的高斯白噪声表明扰动信号的受扰程度不同。IEEE std 1159—2019 中指出电能质量扰动信号的噪声幅度不大于 1%,换算成信噪比为 40 dB,因此本文考虑在 40 dB、50 dB、无噪声环境下生成电能质量扰动信号,使得所生成的电能质量扰动信号更加接近于实际测量信号。

基于相关文献^[14,22]中给出的电能质量扰动信号模型,本文利用 Python 随机生成 40 dB、50 dB 和无噪声环境下的 21 类电能质量扰动信号,每种

噪声环境下每个扰动类型包含 140 个样本,并按照 5:1:1 的比例划分训练集、验证集和测试集。为了使电能质量扰动识别模型能够识别不同噪声含量的扰动信号,将不同噪声环境的训练集混合,让模型学习并适应不同噪声环境下的扰动信号特征。因此训练集中包含 6 300 个样本,验证集中包含 1 260 个样本,测试集中包含 1 260 个样本。

3.1 模型参数设置与验证

OSFC 模型的参数设置主要针对全尺度卷积模块的最大卷积核长度。具体模型参数设置如表 2 所示。

表 2 模型参数设置

模块名称	输出尺寸	参数设置	激活函数
全尺度卷积层 1	1 000,25	$a=1, p=89, s=1$	ReLU
SENet 模块 1	1 000,25	$r=16$	ReLU、Sigmoid
全尺度卷积层 2	1 000,225	$a=9, p=89, s=1$	ReLU
SENet 模块 2	1 000,225	$r=16$	ReLU、Sigmoid
全尺度卷积层 3	1 000,50	$a=2, p=2, s=1$	ReLU
SENet 模块 3	1 000,50	$r=16$	ReLU、Sigmoid
全连接层	1,4	$U=4$	Softmax
	1,2	$U=2$	Softmax
	1,2	$U=2$	Softmax
	1,2	$U=2$	Softmax
	1,2	$U=2$	Softmax
	1,2	$U=2$	Softmax

注: a 为每个卷积核的通道数; p 为卷积核长度集合中最大的质数; s 为卷积核滑动步长; r 为 SENet 模块的缩放比例; U 为全连接层的神经元个数。

由于本文主要对卷积核长度的设置进行研究,因此参数验证实验中主要考虑卷积核长度设置对所提模型的影响。在对比分析中仅改变卷积核长度集合中最大的质数 p ,其他参数不变。由于本文仅考虑质数长度的卷积核,因此选择对比的参数 p 包括:79、83、89、97。参数 p 对 OSFC 模型的影响如表 3 所示。

表 3 参数 p 对 OSFC 模型的影响

p	训练集准确率/%	验证集准确率/%
79	97.34	97.06
83	98.11	97.85
89	99.81	99.50
97	98.23	98.33

由表 3 可以看出,当 p 小于 89 时,OSFC 模

型的准确率会随着 p 的增大而增大,当 p 大于 89 时,OSFC 模型的准确率反而会下降。因此,本文选择 $p=89$ 作为模型参数。

3.2 模型训练与消融实验

通过消融实验来展示模型的训练过程,其不仅能够体现模型的训练过程,还能够验证 SENet 模块对全尺度卷积模块的积极作用。实验中通过控制变量的方式形成无优化的全尺度卷积模块(OS)和经过 SENet 模块优化的全尺度卷积模块(OSFC)2 组对比实验,2 组模型的设置与超参数均一致。模型训练过程采用 Adam 优化算法并引入学习率衰减机制,初始学习率设置为 0.001,当连续 50 代训练集损失率未下降时,以 0.5 的倍率缩小学习率。训练过程中的准确率和损失值均被记录,如图 4 所示,其中趋势向下的曲线为损失值曲线,趋势向上的曲线为准确率曲线,acc 和 val acc 标记分别表示训练集和验证集的准确率。




图 4 模型训练过程的准确率曲线与损失曲线

对比图中损失值曲线的放大部分可知,OSFC 模型的收敛速度比 OS 模型更快;对比训练集准确率曲线可知,在训练 280 代后,OSFC 模型与 OS 模型在训练集上的准确率整体上 OSFC 模型更优;对比验证集准确率曲线可知,在训练 280 代后,OSFC 模型在验证集上的准确率稳定在 $(99.5 \pm 0.1)\%$,而 OS 模型的验证集准确率仅仅稳定在 $(98.7 \pm 0.2)\%$;对比 OSFC 模型和 OS 模型训练集与验证集准确率的差距,可以看出 OSFC 模型在训练集与验证集上准确率的差距更小,这表明 OSFC 模型的泛化能力更强。综上,通过消融实验可知,SENet 模块能够有效提高全尺度卷积模块在电能质量扰动识别问题上的训练效率与识别能力。

由于全尺度卷积模块与 Inception 架构相似,因此,本文利用 Inception 架构对 OSFC 模型进行消融实验。在 Inception1 网络中,将所提方法中的全尺度卷积模块改为 Inception 架构,卷积核个

数不变。由于 Inception 架构最初是在图像识别领域提出的,使用的是 2 维卷积,为了使其能够处理 1 维信号,此处将 2 维卷积改为 1 维卷积,卷积核大小设置为 1×1 、 1×3 、 1×5 。另外,由于 Inception 架构中仅考虑 4 路卷积,因此 Inception1 网络 3 个 Inception 层输出的特征序列通道拼接后的通道数分别为 4、36、8,无法在 SENet1 和 SENet3 中 $r=16$ 的设置下使用,因此将 SENet1 和 SENet3 中的 r 改为 4,其他参数设置不变。在 Inception2 网络中,同样将所提方法中的全尺度卷积模块改为 Inception 架构,并且通过增加卷积核个数的方式来增大网络参数量,使其与本文所提方法的参数量相近,其他参数设置不变。在 Inception2 网络中,3 个 Inception 层的通道数分别为:64、32、16。对比分析结果如表 4 所示,其中参数量的统计使用的是 Python 中的 thop 库。

表 4 OSFC 与 Inception 架构的对比分析结果

模型	参数量	训练集准确率/%	验证集准确率/%
Inception1	73 074	94.62	61.11
Inception2	669 102	93.79	63.49
OSFC	545 731	99.81	99.36

由表 4 可以看出,Inception1 网络的参数量远远低于 OSFC 模型,但其训练集准确率与验证集准确率也低于 OSFC 模型。Inception2 网络的参数量大于 OSFC 模型,但识别准确率仍然低于 OSFC 模型,这是因为 Inception2 网络仅在 Inception1 网络的基础上增加了卷积核的个数,而没有改变卷积核长度,这意味着 Inception2 网络的感受野没有发生改变,从而导致识别准确率较低。因此,与 Inception 架构相比,在具有 3 个卷积模块的网络中,本文所提的 OSFC 模型能够获取更全面的感受野,从而能够提高扰动识别的准确率。

3.3 不同噪声环境下的测试实验

在不同信噪比环境下,本文提出的模型在测试集上的分类精度如表 5 所示。由表 5 可知,在不同的噪声环境下,本文所提出的 OSFC 模型均能达到 99% 以上的准确率,除个别扰动类型由于特征相似导致准确率稍低外,大部分扰动类型均能被 OSFC 模型准确识别。


为了进一步分析所提模型的特征提取能力,以测试集为输入,分别得到 SENet 模块 1、SENet 模块 2 和 SENet 模块 3 输出的特征,然后用 t-SNE 方法对特征进行可视化处理,如图 5 所示。由图 5 可以看出,SENet 模块 1 输出的特征仍然存在混淆。从

SENet 模块 2 开始,特征开始逐渐具有复杂 PQDs 类型的辨别能力。在 SENet 模块 3 中,特征具有了区分不同类型复杂 PQDs 的能力。


表 5 OSFC 在不同噪声环境下

对各类扰动的识别准确率 单位: %


扰动类型	准确率		
	40 dB	50 dB	无噪声
电压暂降	100	95	100
电压暂升	100	100	100
电压中断	100	100	100
脉冲瞬变	100	100	100
振荡瞬变	100	100	100
电压波动	100	100	100
谐波	100	100	100
电压暂降+谐波	95	90	95
电压暂升+谐波	100	100	100
电压中断+谐波	100	100	100
振荡瞬变+谐波	100	100	100
脉冲瞬变+谐波	95	100	95
电压波动+谐波	100	100	100
电压暂降+振荡瞬变	95	100	95
脉冲瞬变+振荡瞬变	100	100	100
振荡瞬变+电压波动	100	100	100
脉冲瞬变+电压波动	100	100	100
脉冲瞬变+电压波动+谐波	100	100	100
脉冲瞬变+振荡瞬变+谐波	100	100	100
脉冲瞬变+振荡瞬变+电压波动	100	95	100
正常信号	100	100	100
平均准确率	99.29	99.05	99.29



(a) SENet 模块 1 输出特征



(b) SENet 模块 2 输出特征



(c) SENet 模块 3 输出特征

图 5 各个 SENet 模块输出特征的 t-SNE 结果

3.4 对比实验

将 OSFC 模型与其他已提出的现有方法进行比较,分析 OSFC 模型在精度、性能等方面的优势。与现有电能质量扰动多分类方法的对比结果如表 6 所示。其中,所选择的方法包括:1 维卷积神经网络(模型 1)^[23],传统 PQDs 分类方法(模型 2)^[24],基于图像的分类方法(模型 3)^[25]。OS 表示无 SENet 模块优化的全尺度卷积模块,OSFC-FC 表示将 OSFC 设置为全连接数作为输出的网络结构,OSFC 表示本文所提方法。另外,由于模型 2 不是神经网络结构,因此不统计该模型的参数量。对比分析结果如表 6 所示,其中模型参数量统计使用的是 Python 中的 thop 库。

表 6 与多分类方法对比结果

方法	准确率/%				参数量
	40 dB	50 dB	无噪声	平均	
模型 1	98.81	97.14	98.30	98.10	4 326 645
模型 2	79.52	80.95	77.14	77.93	
模型 3	90.48	91.19	90.00	90.56	5 621 429
OS	97.85	98.81	98.33	98.33	527 168
OSFC-FC	99.47	98.81	98.33	98.89	534 289
OSFC	99.29	99.05	99.29	99.21	545 731

由表 6 可以看出,与模型 1、模型 2、模型 3 相比,所提方法的准确率更高且参数量更低。与 OS 网络相比,OSFC 网络在参数量没有显著增加的前提下,提高了模型的识别准确率,验证了引入 SENet 模块的有效性。与 OSFC-FC 网络相比,OSFC 网络的参数量没有显著增加,并且 OSFC 网络在各个噪声环境下均能达到 99% 以上的识别准确率,平均准确率优于 OSFC-FC 网络,验证了多任务学习的有效性。

目前,利用多任务学习框架解决复杂 PQDs 分类问题的研究较少。为了进一步验证 OSFC 的

优越性,选择了同样采用多任务学习框架构建的模型 MT-CNN^[26] 进行比较,对比结果如表 7 所示。从表 7 可以看出,OSFC 在各种评价指标上都优于 MT-CNN 方法。

表 7 与多任务分类方法对比结果

信噪比	方法	评价指标					
		排序 损失	覆盖 率	汉明 损失	精确 率	召回 率	F1 准确 率
40 dB	MT-CNN	0.028 3	1.935 7	0.014 6	0.965 2	0.974 7	0.969 9 0.914 2
	OSFC	0.003 1	1.764 2	0.001 9	0.997 6	0.996 8	0.997 2 0.992 9
50 dB	MT-CNN	0.044 7	2.009 5	0.021 4	0.945 8	0.965 9	0.955 7 0.878 6
	OSFC	0.003 1	1.764 2	0.002 3	0.997 6	0.996 8	0.997 2 0.990 5
无噪声	MT-CNN	0.029 2	1.892 9	0.017 0	0.951 4	0.978 6	0.964 8 0.897 6
	OSFC	0.002 3	1.766 7	0.001 5	1.000 0	0.997 6	0.998 8 0.992 9

4 结论

为了利用一维卷积神经网络来更加有效地提取电能质量扰动信号特征,同时充分发挥扰动类别相关性的作用,本文提出了一种融合了 SENet 模块与全尺度卷积神经网络的多任务电能质量扰动识别方法,并利用 Python 进行仿真实验验证得到以下结论。

1)全尺度卷积神经网络能够充分提取电能质量扰动信号的局部特征与全局特征,具有良好的扰动识别能力。

2)SENet 模块能够有效增强重要的特征并抑制用处不大的特征,充分提高了全尺度卷积神经网络的扰动识别能力。同时,多任务学习能够自动学习到不同类型电能质量扰动分类任务之间的相关性,进一步提高了模型的识别准确率。在仿真验证中,所提模型在 40 dB 噪声条件下可达到 99.29% 的识别准确率,具有良好的泛化能力。

未来可收集更多不同类别的电能质量扰动数据,并且进一步研究 OSFC 方法在未见复合扰动类型分类问题上的解决方案,拓展该方法的应用前景。

参考文献:

- [1] 王 燕,李雨婕,卞安吉,等.一种数据库查询的多标签电能质量混合扰动识别与分类新方法[J].中国电机工程学报,2024,44(15):5886-5899.
- [2] IEEE Power & Energy Society.IEEE recommended practice for monitoring electric power quality:IEEE Std 1159TM—

2019[S].Washington:IEEE,2019.

- [3] 罗 溢,李开成,肖贤贵,等.基于马尔可夫转移场和深度残差网络的电能质量复合扰动多标签分类[J].中国电机工程学报,2024,44(7):2519-2531.
- [4] 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.
- [5] 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):128-137.
- [6] 商立群,李朝彪,邓力文,等.基于 ISSA-XGBoost 的电能质量扰动识别方法研究[J].电力系统保护与控制,2024,52(13):115-124.
- [7] 李士林,朱 旋,周冬冬,ICEEMDAN-小波阈值法在谐波信号中的应用[J].河北电力技术,2024,43(5):20-26,33.
- [8] 刘子伟.基于 LightGBM 的电力系统暂态稳定评估方法[J].河北电力技术,2022,41(2):47-52,61.
- [9] TANG Q, QIU W, ZHOU Y C. Classification of complex power quality disturbances using optimized S-transform and kernel SVM[J]. IEEE Transactions on Industrial Electronics, 2020, 67(11): 9715-9723.
- [10] 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.
- [11] 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.
- [12] TODESCHINI G, KHETA K, GIANNETTI C. An image-based deep transfer learning approach to classify power quality disturbances[J]. Electric Power Systems Research, 2022, 213(10): 1-9.
- [13] 张 锐,张 阔,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.
- [14] LIU Y L, YUAN D, FAN H W, 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(4): 1-13.
- [15] QIU W, TANG Q, LIU J, et al. An automatic identification framework for complex power quality disturbances based on multifusion convolutional neural network [J]. IEEE Transactions on Industrial Informatics, 2020, 16(5): 3233-3241.
- [16] LUO W J, LI Y J, URTASUN R, et al. Understanding the effective receptive field in deep convolutional neural networks[C]//Department of Computer Science University of Toronto: Proceedings of the 30th International Conference on Neural Information Processing Systems (NIPS). La Jolla, CA: Neural Information Processing Systems, 2016: 4905-4913.
- [17] TANG W S, LONG G D, LIU L, et al. (下转第 16 页)

5 结论

针对负荷波动导致潮流不确定引发的电力系统连锁故障现象,定义了评价电网安全性的电网安全裕度指标,给出了考虑安全性的电网连锁故障预防控制模型,结合粒子群算法以及 IEEE39 节点系统的仿真,得到以下结论。

1)提出的电网安全裕度指标能合理的量化电网的安全性,可以科学的评价电网对于负荷波动的抗干扰性。

2)给出了考虑负荷随机性的电网连锁故障预防控制模型,并验证了该模型的有效性。

3)提出的考虑负荷随机性的电网连锁故障预防控制模型为今后研究电网连锁故障的预防提供了新的方法和思路。

参考文献:

- [1] 刘宇,高山,杨胜春,等.电力系统概率潮流算法综述[J].电力系统自动化,2014,38(23):127-135.
- [2] 钱宇骋,陈忠,杨为,等.电力系统连锁故障研究综述[J].山东电力技术,2018,45(12):1-9.
- [3] 邓慧琼,李争,孙丽华,等.电网连锁故障的激发因素研究[J].河北科技大学学报,2010,31(3):222-226.
- [4] 邓慧琼,陈世举,王晓铭,等.兼顾电压稳定的电网安全裕度指标研究[J].河北电力技术,2023,42(4):29-34.

(上接第8页)

- Omni-Scale CNNs: a simple and effective kernel size configuration for time series classification[C]//ICLR.10th International Conference on Learning Representations (ICLR 2022), s.l.: International Conference on Learning Representations, 2022:1-17.
- [18] HU J, SHEN L, ALBANIE S. Squeeze-and-excitation networks[J]. IEEE Transactions On Pattern Analysis And Machine Intelligence. 2020, 42(8): 2011-2023.
- [19] RICHSTEIN J. Verifying the goldbach conjecture up to 4 center dot 10¹⁴ [J]. Mathematics of Computation, 2001, 70(236): 1745-1749.
- [20] 张雪,田岚,曾鸣,等.基于梯度幅值方向调整的心电信号多任务分类算法[J].计算机科学,2024,51(12):174-180.
- [21] 吴瑞琪,周毅.知识融入多源多任务学习的眼底图像分类方法[J/OL].计算机工程与应用,1-12[2024-12-11].http://kns.cnki.net/kcms/detail/11.2127.TP.20240522.1258.004.html.
- [22] 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,

- [5] 邓慧琼,罗杰,王晓铭,等.考虑安全性和经济性的连锁故障预防控制策略[J].电力建设,2022,43(5):100-108.
- [6] 邓慧琼,钟运恒,黄靖.计及脆弱支路筛选的含风电电网连锁故障预防策略[J].太阳能学报,2024,45(6):544-555.
- [7] ZHANG P, LEE T S. Probabilistic Load Flow Computation Using the Method of Combined Cumulants and Gram-Charlier Expansion[J]. IEEE Transactions on Power Systems: A Publication of the Power Engineering Society, 2004, 19(1): 676-682.
- [8] 曹宏宇,梁言贺,刘惠颖,等.考虑风-光-储不确定性的新型电力系统概率潮流计算[J].电测与仪表,2024,61(06):87-93.
- [9] 甘国晓.电力系统连锁故障分析与紧急控制研究[D].杭州:浙江大学,2019.
- [10] 戴小青.电力系统概率潮流新算法及其应用[D].北京:华北电力大学(北京),2006.
- [11] 王成山,郑海峰,谢莹华,等.计及分布式发电的配电系统随机潮流计算[J].电力系统自动化,2005,(24):39-44.
- [12] 邓慧琼.考虑连锁跳闸的电网安全裕度研究[J].福建工程学院学报,2016,14(03):255-261.
- [13] 朱德刚,李文辉,花永健.两种独立性定义的等价性[J].高等数学研究,2020,23(1):120-121.
- [14] 安琪.可再生能源大量接入背景下荷泽电网随机潮流研究[D].北京:华北电力大学,2018.
- [15] 韩宏志,杨洋,郜宁,等.基于正态分布的典型负荷日拟合方法[J].分布式能源,2020,5(4):69-73.

本文责任编辑:秦明娟

50(7):81-90.

- [23] WANG S X, CHEN H W. A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network[J]. Applied Energy, 2019, 235(2): 1126-1140.
- [24] RADHAKRISHNAN P, RAMAIYAN K, VINAYAGAM A, et al. A stacking ensemble classification model for detection and classification of power quality disturbances in PV integrated power network[J]. Measurement, 2021(175): 1-16.
- [25] TODESCHINI G, KHETA K, GIANNETTI C. An image-based deep transfer learning approach to classify power quality disturbances[J]. Electric Power Systems Research, 2022, 213(12): 1-9.
- [26] DONG Y L, CAO H Q, XU G P, et al. A Novel Method for multiple power quality disturbances classification using a multi-task convolution neural network[C]//Institute of Electrical and Electronics Engineers. 2019 4th International Conference on Power and Renewable Energy (ICPRE). Chengdu, China, 2019: 274-278.

本文责任编辑:王洪娟