

基于侧输出融合卷积神经网络的电能质量扰动分类方法

王继东,张迪

(天津大学 智能电网教育部重点实验室,天津 300072)

摘要:针对传统电能质量扰动分类方法分类准确率低、人工选择特征困难等缺点,提出了一种基于深度学习的侧输出融合卷积神经网络用于电能质量扰动信号分类。首先,对电能质量扰动信号进行预处理,使输入信号数据标准化,有利于提升所提方法的收敛速度和精度。在传统卷积神经网络中引入侧输出融合结构,通过组合卷积低、中和高层的信息进行特征融合,以更好地对输入信号进行分类。针对实测数据不足和信号数据类型分布不均衡等问题,采用数据增强的方法对信号进行处理。仿真和实测数据验证表明,所提方法可以自动进行特征提取和优化,具有分类速度快、分类准确率高等优点。

关键词:电能质量;扰动分类;侧输出融合卷积神经网络;深度学习;特征提取

中图分类号:TM 732

文献标志码:A

DOI:10.16081/j.epae.202107010

0 引言

传统的电能质量扰动分类分为扰动特征提取选择及分类器设计2个阶段。目前,电能质量扰动特征提取算法有短时傅里叶变换、S变换(ST)、小波变换及其改进方法等,对提取到的特征进行选择后作为分类器的输入对电能质量扰动信号进行分类。文献[1]采用改进ST提取电能质量扰动信号特征,通过直接支持向量机SVM(Support Vector Machine)分类器进行分类识别;文献[2]采用离散小波变换DWT(Discrete Wavelet Transformation)提取特征,配合多层感知极限学习机进行电能质量扰动信号分类,但小波基的选取和品质因子 Q 的调谐存在困难等问题增加了算法的难度;文献[3]采用匹配追踪MP(Matching Pursuit)算法和粒子群优化PSO(Particle Swarm Optimization)算法相结合的分层搜索的原子分解法提取电能质量复合扰动参数。以上特征提取和分类器的组合算法在对电能质量扰动信号进行分类方面有着较好的表现,但这些算法主要凭借经验和统计量提取信号特征,特征的不足或冗余都会对后续分类器的精度产生较大的影响。文献[4-5]利用PSO算法进行参数寻优来筛选出最优特征子集,但该方法对于不同类型和起止时刻的复合扰动类型的检测效果并不理想;文献[6]构造了一种基于欧氏距离的自适应度函数,利用改进的自适应遗传算法对原始特征进行筛选和组合优化,但该算法对于更多分类器的适用性有限。

扰动特征的选取是电能质量扰动信号分类的前提^[7],因此应采用一种更有效的方法自适应地对电

能质量扰动信号进行特征提取和选择,排除人为因素的干扰。近年来,数据挖掘、深度学习方法的发展使得快速分类和处理大规模数据成为可能,因此将深度学习方法应用于电能质量扰动分类领域具有潜在优势^[8-9]。文献[10]提出了基于Hoeffding Tree算法的在线电能质量扰动分类方法,首先结合小波变换和离散傅里叶变换进行电能质量扰动检测,然后应用Hoeffding Tree算法建立增量分类训练模型;文献[11]提出了一种基于稀疏自动编码器SAE(Sparse Auto-Encoder)深度神经网络的电能质量扰动算法,该算法利用稀疏自动编码器对电能质量扰动原始数据进行无监督特征学习,自动提取数据特征的稀疏特征表达。

本文提出了一种基于侧输出融合卷积神经网络SFCNN(Side-output Fusion Convolutional Neural Network)的电能质量扰动分类方法,能够自动对电能质量扰动信号进行特征选择及分类。针对一维序列的电能质量扰动信号,在卷积一层采用一维卷积,实现对电能信号序列的有效提取;通过对卷积神经网络CNN(Convolutional Neural Network)的低、中、高层信息进行特征融合,侧向输出融合分类结果,能够更好地把握信号的整体特征和局部特征,有效提高分类精度;通过批量归一化BN(Batch Normalization)结构和学习率设置优化CNN,避免过度拟合等问题;利用添加高斯白噪声的仿真数据对CNN进行训练,提高网络的抗噪性。仿真和实测数据验证了本文方法的有效性。

1 CNN

CNN是一种监督学习的网络模型,广泛应用于图像识别、语义分割、EGG分类等领域,取得了令人瞩目的效果^[12-13]。传统的CNN包含卷积层、池化层、全连接层和Softmax分类层^[14]。在利用CNN处理图

收稿日期:2020-08-27;修回日期:2021-05-16

基金项目:国家重点研发计划项目(2016YFB0901102)

Project supported by the National Key Research and Development Program of China(2016YB0901102)

像时,可以将其看作一个函数,函数的输入、输出分别为原始图像、分类的结果,即:

$$\mathbf{x}_{\text{output}} = f_{\text{Softmax}}(f_{\text{fc}}(f_{\text{conv}}(\mathbf{x}_{\text{input}}))) \quad (1)$$

式中: $\mathbf{x}_{\text{input}}$ 、 $\mathbf{x}_{\text{output}}$ 分别为输入、输出; $f_{\text{conv}}(\cdot)$ 为卷积层运算; $f_{\text{fc}}(\cdot)$ 为全连接层运算; $f_{\text{Softmax}}(\cdot)$ 为Softmax分类层运算。式(1)中包含可变的参数运算,CNN的训练过程即通过改变参数值,使网络获得良好的训练效果。为便于说明,下文对CNN的各层进行说明时,均将该层作为第 l 层。

CNN组成说明如下。

1)卷积层。卷积层是CNN自学特征提取的核心步骤,该层通过在数据上滑动卷积核,并与其覆盖的数据进行卷积操作提取特征。卷积层的运算为:

$$x_j^l = f(x_i^{l-1} * k_{ij}^l + b_j^l) \quad (2)$$

式中: $f(\cdot)$ 为激活函数;“*”为卷积运算; x_j^l 为卷积层输出的第 j 个神经元; x_i^{l-1} 为第 $l-1$ 层输出的第 i 个神经元; k_{ij}^l 为卷积层第 i 个神经元与第 j 个神经元的权重,即卷积核; b_j^l 为卷积层的第 j 个神经元的偏置量。

2)池化层。池化层用于对卷积层的输入数据进行特征选择和信息过滤,即通过缩小输入特征图来减小运算参数数量。池化层的函数输出为:

$$x_j^l = f_{\text{down}}(x_1^{l-1}, x_2^{l-1}, \dots, x_n^{l-1}) \quad (3)$$

式中: $f_{\text{down}}(\cdot)$ 为下采样函数,通常选取为最大池化函数(取局部感受视野内的各节点最大值)或平均池化函数(取局部感受视野内各节点平均值); n 为神经元个数。

3)全连接层(Dense层):全连接层对卷积层和池化层提取到的特征进行综合,计算特征对应的类别,输出分类信息。全连接层的运算为:

$$x_j^l = f(x_i^{l-1} d_i^l + b_j^l) \quad (4)$$

式中: d_i^l 为全连接层的可学习参数。

4)Softmax分类层。Softmax分类层是具有激活函数的全连接层,其用于建立特征与类别之间的完全连接,Softmax分类层的输出值为输入样本属于相应类别的样本的概率,因此Softmax分类层的神经元数量等于分类类别数量。第 m 个类别的Softmax分类层的输出为:

$$p_m = \exp(x_m) / \sum_{i=1}^k \exp(x_i) \quad m=1, 2, \dots, k \quad (5)$$

式中: k 为样本类别数; p_m 为该样本被分为第 m 个类别的概率; x_m 为第 m 个类别的输出层待激活的神经元。

5)BN层。BN层一般位于卷积层或全连接层之后,通过规范化层输入数据解决数据内部协变量移位问题。BN层的主要原理公式为:

$$z_j^l = \gamma_j^l \hat{y}_j^l + \beta_j^l \quad (6)$$

$$\hat{y}_j^l = \frac{y_j^l - E[y_j^l]}{\sqrt{V_{\text{ar}}[y_j^l] + \varepsilon}} \quad (7)$$

式中: z_j^l 为BN层的输出; β_j^l 为BN层的偏置; $E[y_j^l]$ 和 $V_{\text{ar}}[y_j^l]$ 分别为输入特征 y_j^l 的均值和方差; γ_j^l 为第 l 层第 j 个神经元的缩放系数; ε 为常数项。

2 SFCNN分类模型

2.1 SFCNN的设计要求

在设计SFCNN时,需要考虑电能质量扰动信号的2个因素。

1)电能质量扰动信号为一维信号,而CNN广泛应用于二维图像的识别,文献[15]利用Wigner-Ville技术将一维电能质量扰动信号传输到二维图像文件中,然后利用CNN进行识别,但这将增加计算量和操作复杂度,此外,将一维电能质量扰动信号转换至二维图像文件的过程中,可能会丢失重要信号细节特征。为使CNN能够更好地识别一维电能质量扰动信号,需要对传统CNN的卷积层进行改进。

为了更好地对一维电能质量扰动信号进行分析处理,卷积层采用一维卷积滤波器。与传统二维卷积相比,一维卷积的计算量较少,只需要执行线性操作即可。则卷积层输出可表示为^[16]:

$$X_{o,q}^l = f\left(\sum_{i=1}^z X_i^{l-1} * K_q^l + B^l\right) \quad (8)$$

式中: $X_{o,q}^l$ 为卷积层在第 l 层第 q 台卷积滤波器的输出; X_i^{l-1} 为第 l 层的输入,为 $1 \times n$ 维矩阵; K_q^l 为第 l 层第 q 台卷积滤波器的卷积核(大小为 $1 \times k$), $z=n-k+1$; B^l 为偏置量; $f(\cdot)$ 为激活函数,在卷积层中,一般采用ReLU函数,该函数可以使信号的特征表达更加稀疏,增强信号的非线性表达能力。

2)电能质量扰动信号比较复杂,且复合扰动时有发生,训练后的CNN应具有很强的泛化能力,可以精确识别各种类型的电能质量扰动,这就要求CNN能够关注到扰动信号中的细节特征。此外,真实的电能质量扰动信号总是包含噪声,因此训练后的CNN应具有很好的抗噪性。

2.2 SFCNN结构

本文设计的SFCNN结构如附录A图A1所示。SFCNN结构包含 S_1 — S_3 这3个单元结构,每个单元结构将卷积层、BN层、池化层组合在一起作为特征提取器;将 S_1 — S_3 的卷积层的卷积滤波器数量分别设置为32、64、128台,以逐层加深网络;将卷积步长设置为小步长1,使网络能够关注到电能质量扰动信号的细节特征,从而更加全面地提取特征;池化层用于提取电能质量扰动信号的显著特征,同时减少网络参数,由于最大池化方式的降噪效果要好于平均池化方式,因此池化层采用最大池化方式;在卷积层和池化层中间嵌入BN层对数据进行归一化处理,防止内部数据过度拟合,并提高网络的收敛速度; S_1 — S_3 的输出经过Flatten层后分别展平为 n 维特征

向量 $S_{\text{sideoutput1}}$ — $S_{\text{sideoutput3}}$,为了更好地比较融合层输出与卷积低、中、高层输出,搭建网络模型时,使用函数式应用程序接口(API)构建多输出模型,在 S_1 — S_3 的 Flatten 层后添加全连接层,最后由 Softmax 分类层得到各单元结构的分类准确率。

通过对 ResNets、GoogleNet 等先进的经典 CNN 模型进行分析可知,在网络传递过程中,网络低层更加关注细节特征,提取到的低层特征伴随着网络的深入进行传递,逐步提取到高层特征,在该过程中,低层特征难免会丢失。因此本文利用融合层对不同卷积层的输出进行融合,融合层结构如图 1 所示。融合层的输入为特征向量 $S_{\text{sideoutput1}}$ — $S_{\text{sideoutput3}}$,融合层将这 3 个特征向量首尾相连,拼接为 1 个特征向量,从而实现特征融合。融合信号包含电能质量扰动信号的各级特征,且各级特征之间可以互补,低层特征可协助 SFCNN 提取适当的高层特征,提高 SFCNN 识别电能质量扰动的能力。

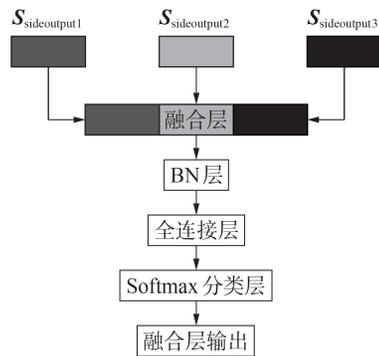


图 1 融合层结构

Fig.1 Structure of fusion layer

3 仿真分析与结果验证

3.1 实验准备及数据获取

采用包括纯正弦波在内的 15 种电能质量扰动信号来评估所提基于 SFCNN 的电能质量扰动分类方法的性能。电能质量扰动信号由 10 种单一类型和 5 种复合类型的信号组成,前者包括纯正弦波形 (C_1)、暂降 (C_2)、暂升 (C_3)、中断 (C_4)、谐波 (C_5)、脉冲瞬态 (C_6)、振荡瞬态 (C_7)、闪变 (C_8)、电压切痕 (C_9) 和尖峰 (C_{10}) 信号,后者包括谐波暂降 (C_{11})、谐波暂升 (C_{12})、谐波中断 (C_{13})、暂降闪变 (C_{14}) 和暂升闪变 (C_{15}) 信号。图 2 为典型电能质量扰动仿真信号波形图,图中幅值为标幺值,后同。参数变化符合 IEEE Std 1159—2019 标准中的参数方程^[17]。

仿真信号在 MATLAB 环境下产生,采样频率设置为 6.4 kHz,单个样本数据长度为 1 280,通过随机更改约束参数,可以生成无限数量的数据。因此,仿真信号可以满足深度学习对训练数据数量的要求。每类电能质量扰动信号有 500 个样本,共产生 4 500

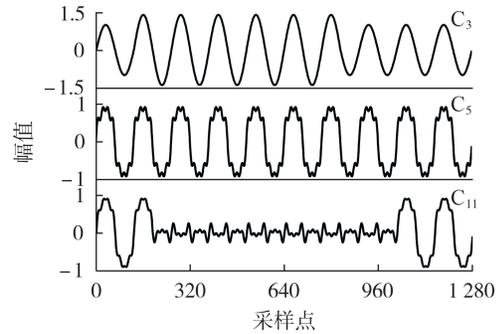


图 2 仿真信号波形图

Fig.2 Waveforms of simulative signals

个训练集、1 500 个测试集。为了便于计算损失函数,利用 one-hot 编码表示标签数据,例如 $[1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]$ 表示样本属于第 1 个类别。

实际的电能质量扰动信号采集过程不可避免地会受到采集设备以及环境噪声的干扰,为了提高 SFCNN 的泛化性,在采样信号中叠加信噪比为 50、40、30、20 dB 的噪声作为干扰以模拟真实信号,使用不同水平的模拟噪声来训练 SFCNN。表 1 为本文所采用的数据集。

表 1 训练样本数据集

Table 1 Training sample dataset

数据集	样本数量	信噪比 / dB
训练集	4 500	20, 30, 40, 50
验证集	1 500	20, 30, 40, 50
测试集	1 500	20, 30, 40, 50, 0

3.2 仿真数据验证

基于 Keras 框架训练 SFCNN,实验训练阶段设置小批次数据量为 128,训练迭代轮次为 50,通过训练集和测试集中的交叉熵损失 L_{CE} 和分类准确率 r_c 来评价 SFCNN 的性能。网络模型精度越高,交叉熵损失越小,说明网络模型性能越好。训练集和验证集的分类准确率与交叉熵损失对比如图 3 所示。由图可见,采用随机小批量方式进行 50 次迭代训练期间,在 20 次迭代之后训练集和验证集的分类准确率几乎相等,最高分类准确率在 99.5% 以上。

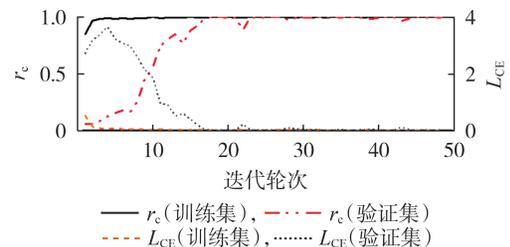


图 3 训练集和验证集的分类准确率与交叉熵损失的对比

Fig.3 Comparison of classification accuracy rates and cross entropy losses between training set and verification set

为进一步验证融合层的性能,将融合层的分类准确率与卷积低、中、高层的分类准确率进行对比,结果见图4。由图可见:迭代轮次较少时,融合层的分类准确率明显高于卷积低、中、高层的分类准确率;随着迭代轮次的增加,卷积中、高层的分类准确率明显增加,但融合层的分类准确率始终高于卷积高层的分类准确率,可见进行特征融合后分类效果较好。

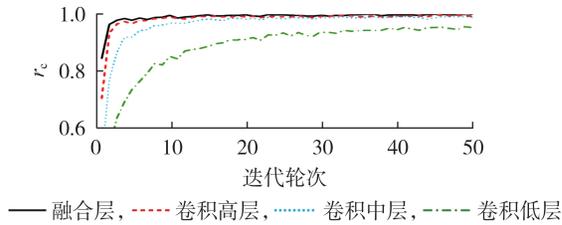


图4 融合层与各卷积层的分类准确率比较

Fig.4 Comparison of classification accuracy rates between fusion layer and convolutional layers

3.3 SFCNN 性能优化设计

为确定学习率 α 对SFCNN性能的影响,在不同学习率下对SFCNN进行训练优化,结果如图5所示。由图可见,学习率较低时网络收敛速度较慢,学习率过高又会导致网络学习性能不稳定,综合来看,学习率为0.001时SFCNN的性能最好,因此本文设置学习率为0.001。

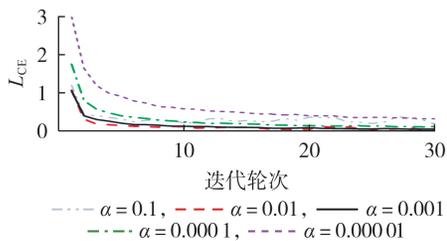


图5 不同学习率下的交叉熵损失对比

Fig.5 Comparison of cross entropy losses among different learning rates

为验证BN层对于SFCNN性能的影响,对比包含和不包含BN层的SFCNN的分类准确率和交叉熵损失,结果如图6所示。由图可以看出,包含BN层的SFCNN的分类准确率要高于无BN层的SFCNN,其交叉熵损失更小,收敛速度更快,可见BN层可以优化网络模型结构,防止网络的过拟合。

3.4 特征可视化分析

为了更加直观地理解SFCNN对于电能质量扰动信号的特征提取过程,采用t分布随机近邻嵌入(t-SNE)技术^[18],对输入数据及融合层输出进行可视化。设置t-SNE的迭代轮次为1000、困惑度为30,对输入数据以及融合层输出特征的可视化结果见附录

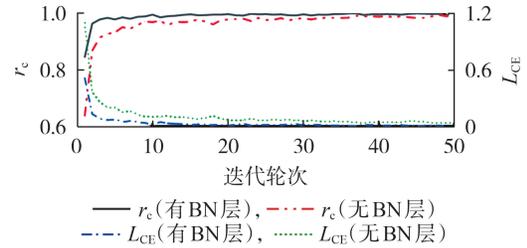


图6 有、无BN层情况下的分类准确率与交叉熵损失的对比

Fig.6 Comparison of classification accuracy rates and cross entropy losses between with and without BN layer

A图A2和图A3。由图A2可见,输入数据分布杂乱,彼此重叠交叉;由图A3可见,经过SFCNN处理后,同类别的数据聚合在一起,不同类别的数据之间距离变大,没有重叠现象,正常信号和不同类别的电能示例扰动信号在二维平面上均能明显区分,说明了特征融合的有效性。

3.5 SFCNN与现有方法的比较

为了验证本文方法的优越性,将本文算法与3种先进的深度学习算法进行对比,对比算法简要介绍如下。

1)深度CNN(DCNN):选取文献[19]提出的具有6个标准卷积层的DCNN,卷积核大小设置为3,步长设置为1,各卷积层过滤器的数量设置为32、32、64、64、128、128,全连接层数为3。

2)长短期记忆网络(LSTM):采用3层堆叠式LSTM结构,各层的LSTM记忆节点数分别为32、32、32,激活函数为tanh。

3)CNN-LSTM:文献[20]设计了具有2层标准卷积层的CNN,卷积核大小设置为3,卷积层过滤器数量为64和128,将其与LSTM结合进行电能质量扰动信号分类,LSTM层数为1,LSTM记忆节点数为50。

设置迭代轮次为50次,在相同配置的计算机和数据集上对4种算法进行训练,训练时间为算法迭代一次所用时间,性能对比结果如表2所示。表中, R_{SN} 为信噪比。由表可见:LSTM的训练时间最短,但在各种信噪比下的分类准确率均低于其他方法;综合考虑训练时间和分类准确率,本文所提的SFCNN取得了较好的效果,优于其他3种深度学习算法。

表2 4种深度学习算法的性能比较

Table 2 Performance comparison among four deep learning algorithms

算法	分类准确率 / %				训练时间 / s
	$R_{SN}=50$ dB	$R_{SN}=40$ dB	$R_{SN}=30$ dB	$R_{SN}=20$ dB	
DCNN	99.43	99.06	98.40	97.67	64.5
LSTM	94.90	94.79	94.77	94.70	3.2
CNN-LSTM	98.93	97.73	97.53	96.39	43.8
SFCNN	99.86	99.73	99.73	99.06	26.4

将SFCNN与文献[2]采用的DWT和分层极限学习机(H-ELM)方法(DWT+H-ELM),文献[21]采

用的 ST 和概率神经网络(PNN)方法(ST+PNN)、文献[22]采用的可调品质因子小波变换(TQWT)和随机森林(RF)方法(TQWT+RF)进行对比,结果如表3所示。表中,“—”表示文献[21]中未直接给出分类准确率。传统的电能质量扰动分类方法中,对信号分解后要对特征进行选择,关于特征数量的选取并没有明确的规定,文献[21]仅选取了4个特征,在30 dB的信噪比下,分类准确率为98.63%,而文献[22]选取了16个特征进行分析,在相同的噪声条件下,分类准确率达到98.13%,两者准确率接近,说明特征的类型及数量差异导致了分类结果的差别。本文所提基于SFCNN的多层信息融合结构可以自动提取有效特征,不仅简化了电能质量扰动识别的过程,而且缩短了特征的提取和选择时间,训练后在各种噪声条件下的分类准确率均高于其他传统方法。

表3 SFCNN和传统方法的分类准确率对比

Table 3 Comparison of classification accuracy rates between SFCNN and traditional methods

方法	扰动种类	特征数量	分类准确率 / %	
			$R_{SN}=20$ dB	$R_{SN}=30$ dB
DWT+H-ELM	15	19	95.20	97.67
ST+PNN	9	4	—	98.63
TQWT+RF	23	16	94.22	98.13
SFCNN	15	自动	99.06	99.73

3.6 实测数据验证

为了验证本文方法对实测信号的适用性,采用一组实测信号来测试SFCNN的分类性能。实际信号来自IEEE PES数据库提供的用于电能质量扰动分类的数据,每个信号的长度为1536,信号采样率为每周期256个点。

由于网络模型需要大量数据进行训练优化,数据的优劣直接决定所训练模型的适应性和可行性。针对个别类别的数据量少、数据分配不均衡的问题,采用数据增强的方法,通过随机裁剪、添加高斯噪声、随机翻转操作进行数据增强,增加训练数据量。以实测暂态振荡信号为例,进行数据增强后的结果见图7。

对数据集进行增强后,训练集、测试集的样本数量分别为3000、500。使用增强后的数据集训练本文所提SFCNN和3.5节中的DCNN、LSTM、CNN-LSTM,得到的电能质量扰动分类结果如表4所示。可以看出,SFCNN对增强后的实测数据的平均分类准确率为97.2%,低于仿真结果,其主要原因是训练数据是使用仿真软件生成的,与真实数据有一定的差别,而真实数据的信号所受干扰更加复杂,且实测数据量较小,类别之间分布不均匀,以及人工标注存在误差等,容易造成网络训练准确率有所下降。

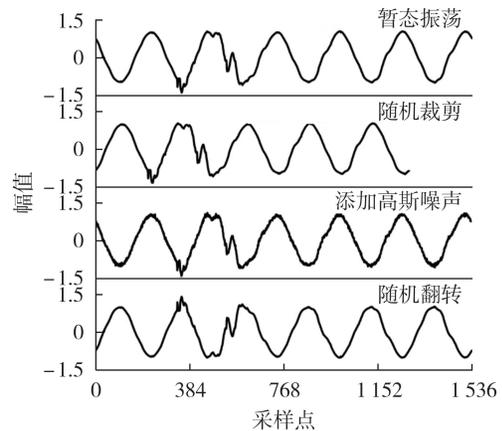


图7 数据增强结果示例

Fig.7 Example of data enhancement results

表4 数据增强后的实测信号分类结果

Table 4 Measured signal classification results after data enhancement

信号类型	分类准确率 / %			
	DCNN	LSTM	CNN-LSTM	SFCNN
暂态振荡	90.0	95.0	90.0	91.0
谐波	95.0	95.0	95.0	95.0
谐波中断	100.0	100.0	100.0	100.0
电压暂降	100.0	100.0	94.0	100.0
波形畸变	100.0	74.0	100.0	100.0
平均值	97.0	92.8	95.8	97.2

4 结论

本文针对传统电能质量信号扰动识别存在的人工选取特征困难、计算量较大等缺陷,提出了一种基于深度学习的SFCNN进行电能质量扰动信号分类,主要工作及结论如下。

1)构造了一种新型的侧输出融合结构,该结构可整合不同卷积层的信息,自动提取特征,实现电能质量扰动信号分类。

2)采用一维卷积处理电能质量扰动信号,将BN层引入SFCNN,以加快网络收敛速度,防止过拟合。

3)本文所提的SFCNN可以将传统电能质量扰动检测和识别系统的扰动特征提取选择和分类2个主要模块融合到一个学习体中,提高了分类准确率,节省了人力并简化电能质量扰动信号分类流程;仿真和实测数据验证了本文所提的SFCNN可以有效地学习分类电能质量扰动信号,分类准确率较高,且抗噪性能较好;SFCNN的输入数据以及融合层输出特征的t-SNE可视化结果也从侧面说明了SFCNN的有效性。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 徐志超,杨玲君,李晓明. 基于聚类改进S变换与直接支持向量机的电能质量扰动识别[J]. 电力自动化设备,2015,35(7):

- 50-58,73.
XU Zhichao, YANG Lingjun, LI Xiaoming. Power quality disturbance identification based on clustering-modified S-transform and direct support vector machine[J]. Electric Power Automation Equipment, 2015, 35(7):50-58, 73.
- [2] WANG Jidong, XU Zhilin, CHE Yanbo. Power quality disturbance classification based on DWT and multilayer perceptron extreme learning machine[J]. Applied Sciences, 2019, 9(11): 1-16.
- [3] 崔志强, 王宁, 贾清泉. 基于分层匹配追踪算法的电能质量复合扰动参数辨识方法[J]. 电力自动化设备, 2017, 37(3): 153-159.
CUI Zhiqiang, WANG Ning, JIA Qingquan. Parameter identification based on hierarchical matching pursuit algorithm for complex power quality disturbance[J]. Electric Power Automation Equipment 2017, 37(3):153-159.
- [4] 黄南天, 卢恒波, 王玉强, 等. 基于粒子群与极限学习机的电能质量信号特征选择与识别[J]. 电工电能新技术, 2016, 35(7): 55-61.
HUANG Nantian, LU Guobo, WANG Yuqiang, et al. Feature selection and identification of power quality signals based on particle swarm optimization and extreme learning machine[J]. Advanced Technology of Electrical Engineering and Energy, 2016, 35(7):55-61.
- [5] ZHAO Chen, LI Kaicheng, LI Yuanzheng, et al. Novel method based on variational mode decomposition and a random discriminative projection extreme learning machine for multiple power quality disturbance recognition[J]. IEEE Transactions on Industrial Informatics, 2019, 15(5):2915-2926.
- [6] 瞿合祚, 刘恒, 李晓明, 等. 一种电能质量多扰动分类中特征组合优化方法[J]. 电力自动化设备, 2017, 37(3):146-152.
QU Hezuo, LIU Heng, LI Xiaoming, et al. Feature combination optimization for multi-disturbance classification of power quality [J]. Electric Power Automation Equipment, 2017, 37(3):146-152.
- [7] 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.
- [8] 李宝琴, 吴俊勇, 邵美阳, 等. 基于集成深度置信网络的精细化电力系统暂态稳定评估[J]. 电力系统自动化, 2020, 44(6):17-26.
LI Baoqin, WU Junyong, SHAO Meiyang, et al. Refined transient stability evaluation for power system based on ensemble deep belief network[J]. Automation of Electric Power Systems, 2020, 44(6):17-26.
- [9] KUMAR R, SINGH B, SHAHANI D T, et al. Recognition of power-quality disturbances using S-transform-based ANN classifier and rule-based decision tree[J]. IEEE Transactions on Industry Applications, 2015, 51(2):1249-1258.
- [10] 丁建光, 张沛超. 基于Hoeffding Tree的电能质量在线扰动分类[J]. 电力自动化设备, 2014, 34(9):84-89.
DING Jianguang, ZHANG Peichao. Online power quality disturbance classification based on Hoeffding Tree [J]. Electric Power Automation Equipment, 2014, 34(9):84-89.
- [11] 屈相帅, 段斌, 尹桥宣, 等. 基于稀疏自动编码器深度神经网络的电能质量扰动分类方法[J]. 电力自动化设备, 2019, 39(5): 157-162.
QU Xiangshuai, DUAN Bin, YIN Qiaoxuan, et al. Classification method of power quality disturbances based on deep neural network of sparse auto-encoder[J]. Electric Power Automation Equipment, 2019, 39(5):157-162.
- [12] 柯鹏飞, 蔡茂国, 吴涛. 基于改进卷积神经网络与集成学习的人脸识别算法[J]. 计算机工程, 2020, 46(2):262-267, 273.
KE Pengfei, CAI Maoguo, WU Tao. Face recognition algorithm based on improved convolutional neural network and ensemble learning[J]. Computer Engineering, 2020, 46(2):262-267, 273.
- [13] 杨帆, 王干军, 彭小圣, 等. 基于卷积神经网络的高压电缆局部放电模式识别[J]. 电力自动化设备, 2018, 38(5):123-128.
YANG Fan, WANG Ganjun, PENG Xiaosheng, et al. Partial discharge pattern recognition of high-voltage cables based on convolutional neural network[J]. Electric Power Automation Equipment, 2018, 38(5):123-128.
- [14] RAWAT W, WANG Zenghui. Deep convolutional neural networks for image classification:a comprehensive review[J]. Neural Computation, 2017, 29(9):2352-2449.
- [15] 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.
- [16] WANG Jidong, XU Zhiniu, CHE Yanbo. Power quality disturbance classification based on compressed sensing and deep convolution neural networks[J]. IEEE Access, 2019, 7:78336-78346.
- [17] IEEE. IEEE recommended practice for monitoring electric power quality:IEEE Std 1159-2019[S]. New York, USA:IEEE, 2019.
- [18] QIU Wei, TANG Qiu, LIU Jie, 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.
- [19] WANG Shouxiang, CHEN Haiwen. A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network[J]. Applied Energy, 2019, 235:1126-1140.
- [20] MOHAN N, SOMAN K P, VINAYAKUMAR R. Deep power: deep learning architectures for power quality disturbances classification[C]//2017 International Conference on Technological Advancements in Power and Energy(TAP Energy). Kollam, India:IEEE, 2017:1-6.
- [21] WANG Huihui, WANG Ping, LIU Tao. Power quality disturbance classification using the S-transform and probabilistic neural network[J]. Energies, 2017, 10(1):1-19.
- [22] 杨晓梅, 郭林明, 肖先勇, 等. 基于可调品质因子小波变换和随机森林特征选择算法的电能质量复合扰动分类[J]. 电网技术, 2020, 44(8):3014-3020.
YANG Xiaomei, GUO Linming, XIAO Xianyong, et al. Classification of multiple power quality disturbances based on TQWT and random forest feature selection algorithm[J]. Power System Technology, 2020, 44(8):3014-3020.

作者简介:



王继东

王继东(1977—),男,山东邹城人,教授,博士,主要研究方向为电能质量、分布式发电和微电网、智能用电等(**E-mail**: jidongwang@tju.edu.cn);

张迪(1997—),女,辽宁锦州人,硕士研究生,主要研究方向为电能质量(**E-mail**: zhangdihh@tju.edu.cn)。

(编辑 任思思)

(下转第126页 continued on page 126)

Fault line selection method of grounding fault with high resistance in resonant grounding system based on intensive zero-sequence impedance characteristics

SHAO Wenquan¹, LIU Yihuan¹, CHENG Yuan^{1,2}, ZHANG Zhihua³, CHENG Chang¹

(1. School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China;

2. School of Electrical Engineering, Xi'an University of Technology, Xi'an 710048, China;

3. Electric Power Research Institute of State Grid Shaanxi Electric Power Company, Xi'an 710110, China)

Abstract: In order to solve the difficulties of faulty line selection of grounding fault with high resistance in resonant grounding system of distribution network, it is proposed to enhance the zero-sequence impedance characteristics of the line by using the short-time switching of resistance connected in parallel with arc suppression coil. In the case of single-phase grounding fault, the zero-sequence impedance characteristics of the healthy and faulty lines on the same bus before and after switching the parallel resistance are analyzed. The analysis shows that the zero-sequence impedance of any healthy line remains unchanged before and after switching the parallel resistance, which is composed of its own capacitance impedance to ground, while the zero-sequence impedance of the faulty line decreases significantly after the parallel resistance is put into operation, which is composed of the parallel equivalent resistance of all the healthy lines, arc suppression coil branch and the parallel resistance branch. In addition, the range of parallel resistance is analyzed by considering the limiting requirements of fault current and the start-up requirements of zero-sequence voltage. Therefore, according to the change characteristics of zero-sequence impedance of the faulty line before and after switching the parallel resistance, an improved faulty line selection method is proposed, which can theoretically adapt to the grounding fault with high resistance that lower than 3000 Ω . The effectiveness of the proposed method is verified by MATLAB simulation.

Key words: distribution network; grounding fault with high resistance; fault line selection; zero-sequence impedance; parallel resistance

(上接第112页 continued from page 112)

Power quality disturbance classification method based on side-output fusion convolutional neural network

WANG Jidong, ZHANG Di

(Key Laboratory of Smart Grid of Ministry of Education, Tianjin University, Tianjin 300072, China)

Abstract: Aiming at the disadvantages of the traditional power quality disturbance classification methods, such as low classification accuracy and difficulty in manually selecting features, a SFCNN (Side-output Fusion Convolutional Neural Network) based on deep learning is proposed for power quality disturbance classification. Firstly, the power quality disturbance signal is preprocessed to standardize the input signal data, which is beneficial to improve the convergence speed and accuracy of the proposed method. Then, the side-output fusion structure is introduced into the traditional convolutional neural network, and feature fusion is carried out by combining the information of the low, middle and high layers of convolution to better classify and recognize the input signal. Aiming at the problems of insufficient measured data and unbalanced distribution of signal data types, the data enhancement method is used to process the signal. Simulation and actual data verification show that the proposed method can automatically perform feature extraction and optimization, and has the advantages of fast classification speed and high classification accuracy.

Key words: power quality; disturbance classification; side-output fusion convolutional neural network; deep learning; feature extraction

附录 A

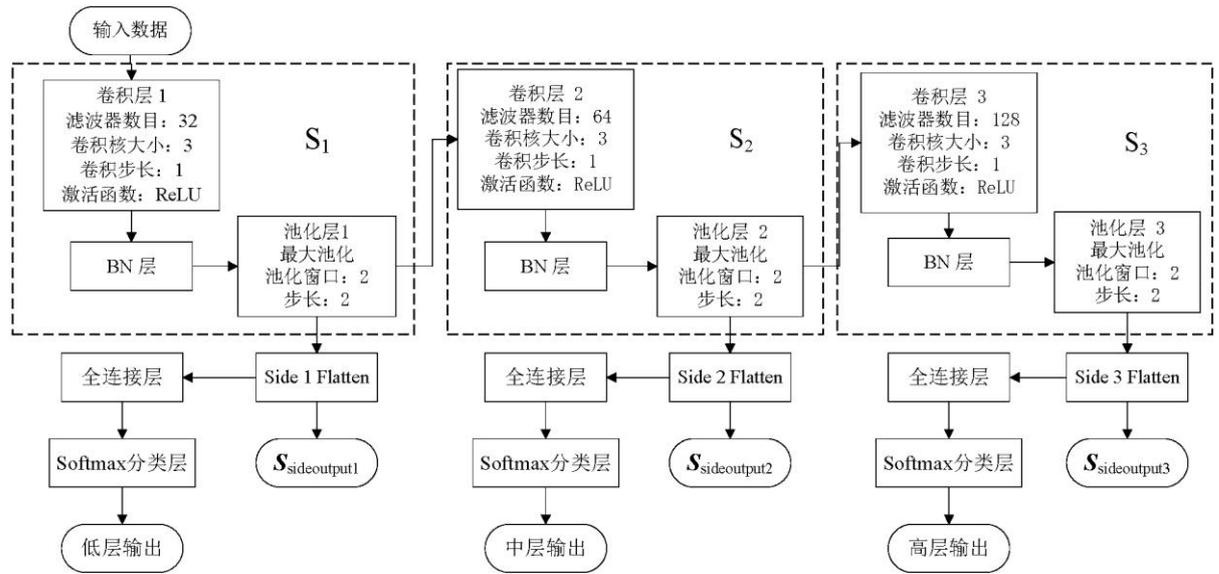


图 A1 SFCNN 结构
Fig.A1 Structure of SFCNN

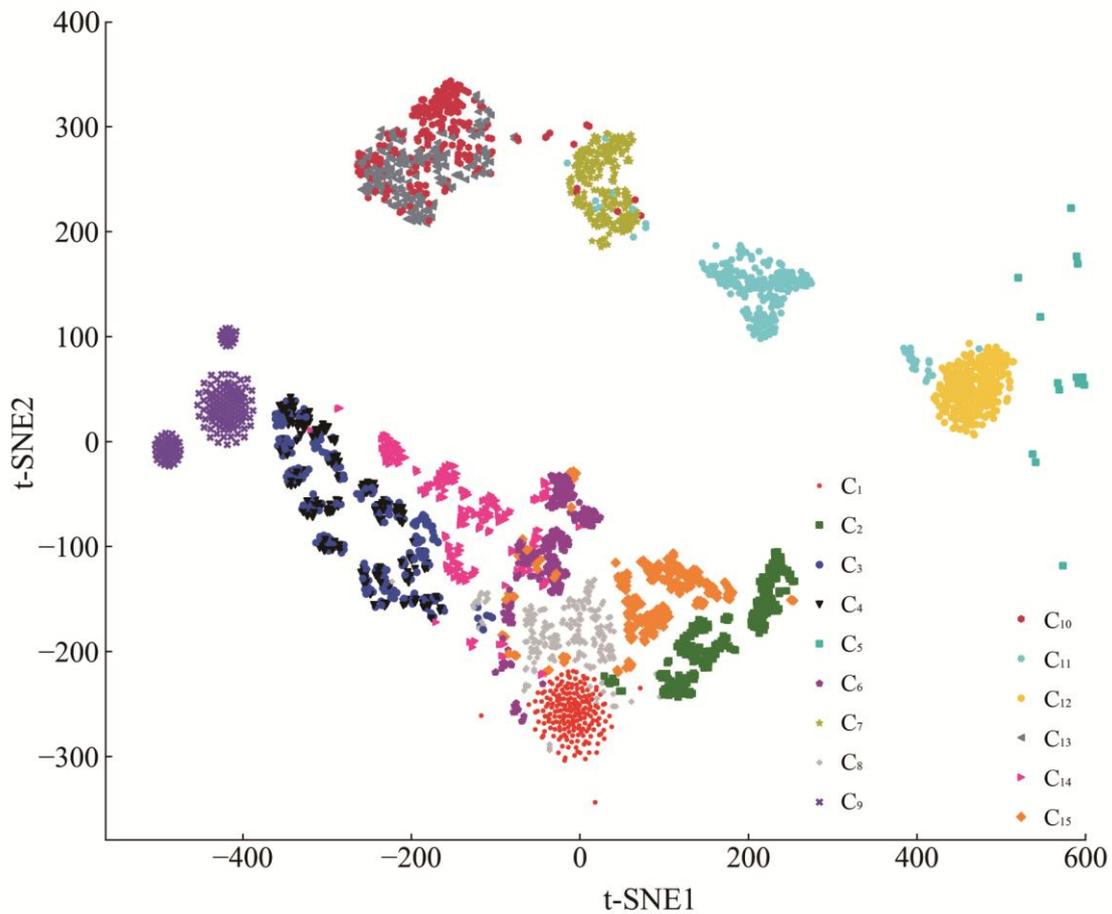


图 A2 原始输入数据可视化
Fig.A2 Visualization of original input data

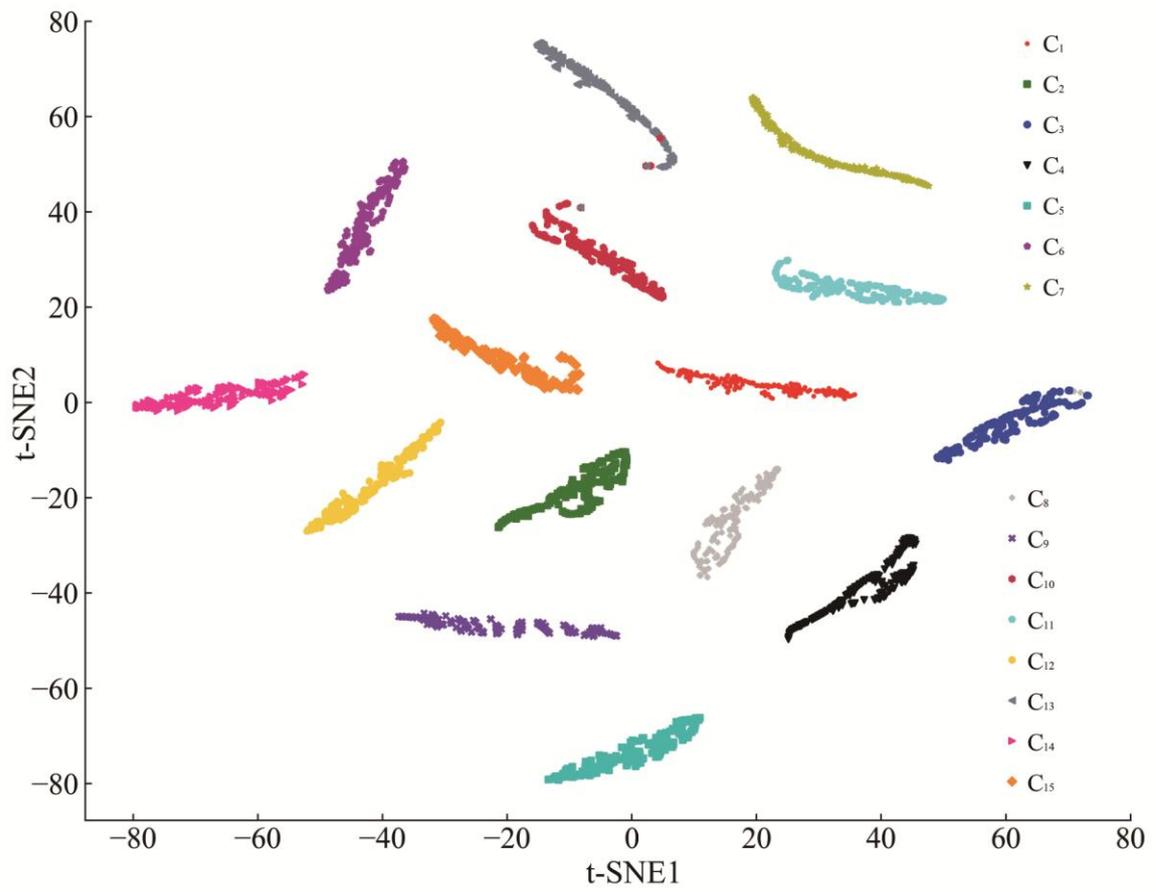


图 A3 融合层输出可视化
Fig.A3 Visualization of output of fusion layer