

DOI: 10.19783/j.cnki.pspc.190550

# 基于特征融合一维卷积神经网络的电能质量扰动分类

王维博<sup>1</sup>, 张斌<sup>1</sup>, 曾文入<sup>1</sup>, 董蕊莹<sup>1</sup>, 郑永康<sup>2</sup>

(1. 西华大学电气与电子信息学院, 四川 成都 610039; 2. 国网四川省电力公司电力科学研究院, 四川 成都 610072)

**摘要:** 现有基于特征选取的电能质量扰动分类算法存在鲁棒性差、抗噪性能不强等问题。提出了一种改进的一维卷积神经网络用于电能质量扰动信号的分类。首先通过三个卷积神经网络子模型分别提取电能质量扰动信号的特征向量, 然后将提取的特征向量融合为一个新的特征向量, 最后通过 BP 神经网络实现分类。与改进前的一维卷积神经网络模型以及现有的电能质量扰动分类算法相比, 该算法提取的特征向量具有更大的区分度。仿真结果表明, 该算法有更好的鲁棒性和识别率, 且抗噪能力强, 为电能质量扰动信号分类提供了一种新思路。

**关键词:** 电能质量; 卷积神经网络; 扰动分类; 特征提取

## Power quality disturbance classification of one-dimensional convolutional neural networks based on feature fusion

WANG Weibo<sup>1</sup>, ZHANG Bin<sup>1</sup>, ZENG Wenru<sup>1</sup>, DONG Ruiying<sup>1</sup>, ZHENG Yongkang<sup>2</sup>

(1. School of Electrical and Electronic Information, Xihua University, Chengdu 610039, China;

2. State Grid Sichuan Electric Power Research Institute, Chengdu 610072, China)

**Abstract:** The existing power quality disturbance classification algorithms based on feature selection have poor robustness and weak anti-noise performance. This paper proposes an improved one-dimensional convolutional neural network model for power quality disturbance classification. Firstly, the eigenvectors of the power quality disturbance signal are extracted by three convolutional neural network sub-models, and then the extracted eigenvector is fused into a new one; finally, the classification is implemented by BP neural network. The result shows that the proposed algorithm has higher robustness, recognition rate and strong anti-noise abilities, because the new eigenvector has greater discrimination, compared with the old one-dimensional CNN models and the existing power quality disturbance classification algorithms. It provides a new idea for classifying power quality disturbance signals.

This work is supported by Sichuan University Key Laboratory Open Fund (No. szjj2017-046), Health Management Center of Xihua University (No. DJKG2019-005), National Natural Science Foundation of China (No. 61571371), and Natural Science Foundation of Guangdong Province (No. 2015A030313853).

**Key words:** power quality; convolutional neural network; disturbance classification; feature extraction

## 0 引言

随着电力电子设备的广泛应用, 电力系统中存在大量的非线性、波动性负载, 电能质量问题日益严重<sup>[1-2]</sup>。电能质量扰动的准确识别是电能质量治理和改善的前提。

目前电能质量扰动信号分类主要采用传统机器学习方法, 其核心是特征选取和分类识别。在电能

质量扰动分类领域, 常用的特征提取算法有傅里叶变换<sup>[3]</sup>、小波变换<sup>[4]</sup>、S 变换<sup>[5-6]</sup>、希尔伯特黄变换<sup>[7]</sup>等。常用的分类识别算法有极限学习机<sup>[8]</sup>、支持向量机<sup>[9]</sup>、BP 神经网络<sup>[10]</sup>等。文献[11]采用 S 变换进行电能质量扰动信号特征提取, 通过 GAP-RBF 神经网络识别, 该方法神经元数量较少, 运算速度快, 但识别率有待提高。文献[12]采用拉格朗日延迟器优化小波基提取电能质量扰动信号特征, 使用基于 K 均值聚类的概率神经网络实现分类, 但其算法需提取较多特征从而导致特征冗余。文献[13]采用压缩感知稀疏向量提取电能质量扰动信号特征, 采用神经网络进行分类, 该方法减少了所需处理的数据量, 但抗噪性能不强。

**基金项目:** 四川省高校重点实验室开放基金项目 (szjj2017-046); 西华大学大健康促进中心 (DJKG2019-005); 国家自然科学基金 (61571371); 广东省自然科学基金 (2015A030313853)

以上算法均需对信号进行特征选取, 易产生特征冗余, 而且会丢失一些其他的特征, 导致识别率下降, 抗噪性能减低。为了避免电能质量扰动特征选取的过程, 文献[14-15]将电能质量扰动信号转换成二维灰度图像, 然后采用二维 CNN 进行图像识别, 但转换过程复杂, 且暂降与中断的灰度图像特征不明显, 导致识别率下降。

对于电能质量扰动这类序列信号, 采用一维 CNN 可加快计算速度。文献[16]采用一维 CNN 对心电图进行分类。文献[17-18]用一维 CNN 实现实时电机故障诊断和轴承故障检测。

为了提高电能质量扰动分类算法的鲁棒性与抗噪性能, 本文提出了基于特征融合的一维卷积神经网络(FCNN), 通过该模型融合多个卷积神经网络子模型提取的特征向量, 实现对电能质量扰动信号在不同噪声情况下的分类。

## 1 一维 CNN 结构与原理

CNN 是受到生物学启发的前馈神经网络, 在模式分类领域被广泛使用。CNN 由特征提取阶段和分类阶段组成, 特征提取阶段用于从输入中提取特征, 其结构主要包含卷积层(Convolutional Layers), 激活层(Activation Layers), 批量归一化层(Batch Normalization Layers, BN), 池化层(Pooling Layers); 分类阶段包含若干个全连接层(Fully Connected Layers, FC)。

### 1.1 卷积层

卷积层将一维输入信号与一维卷积核进行卷积运算, 然后通过激活层提取局部特征。卷积过程如下所述。

$$x'_k = b'_k + \sum_{i=1}^N \text{conv}(w_{ik}^{l-1}, s_i^{l-1}) \quad (1)$$

式中:  $x'_k$ 、 $b'_k$  分别表示第  $l$  层第  $k$  个神经元的输出和偏置;  $s_i^{l-1}$  表示第  $l-1$  层第  $i$  个神经元的输出;  $w_{ik}^{l-1}$  表示第  $l-1$  层的第  $i$  个神经元与第  $l$  层的第  $k$  个神经元的卷积核,  $i=1,2,\dots,N$ ,  $N$  为神经元的个数。

### 1.2 激活层

激活层通过非线性函数对输入信号进行非线性变换, 以增强卷积神经网络的表达能力。目前比较常见的激活函数有 Sigmoid、Tanh、Relu。由于 Relu 函数收敛速度快, 能克服梯度弥散, 被广泛应用, 其公式为

$$y'_k = f(x'_k) = \max\{0, x'_k\} \quad (2)$$

式中,  $y'_k$  是第  $l$  层的激活值。

### 1.3 池化层

池化层通常在卷积层之后添加, 通过下采样减少特征的空间大小和网络的参数, 减少计算量, 防止过拟合。常见的池化操作有均值池化(Average Pooling)和最大值池化(Max Pooling)。最大值池化公式为

$$s_k^{l(j)} = \max_{(j-1)r+1 \leq t \leq jr} \{y_k^{l(t)}\} \quad (3)$$

式中:  $s_k^{l(j)}$  表示池化操作后第  $l$  层第  $k$  个神经元中的第  $j$  个值;  $y_k^{l(t)}$  表示第  $l$  层第  $k$  个神经元中的第  $t$  个激活值;  $r$  为池化区域的宽度。

### 1.4 批量归一化层

BN 层使每一层拥有服从相同分布的输入数据, 从而可以使用较大学习率进行训练, 加快训练速度, 克服协方差偏移的影响, 增强网络的泛化能力<sup>[19]</sup>。其公式为

$$\hat{y}'_k = \frac{y'_k - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \quad (4)$$

$$z'_k = \gamma'_k \hat{y}'_k + \beta'_k \quad (5)$$

式中:  $z'_k$  表示此 BN 层的输出;  $\mu_B = E[y'_k]$ ,  $\sigma_B^2 = \text{Var}[y'_k]$ , 其中  $E$  表示期望,  $\text{Var}$  表示方差。  $\gamma'_k$  表示第  $l$  层第  $k$  个神经元的缩放系数;  $\beta'_k$  表示该 BN 层的偏置;  $\varepsilon$  为常数项。

### 1.5 全连接层

全连接层是对经过特征提取的信号进行分类识别, 其中的输出层可采用 Softmax 激活函数。

$$p_m = \text{Softmax}(a_m) = \frac{\exp(a_m)}{\sum_{j=1}^M \exp(a_j)} \quad (6)$$

式中:  $m=1,2,\dots,M$ , 表示分成  $M$  个类别;  $p_m$  被分为第  $m$  类的概率, 即实际标签值;  $a_m$  为输出层待激活的神经元。

目标函数采用交叉熵损失函数(Cross-entropy Loss Function), 其公式为

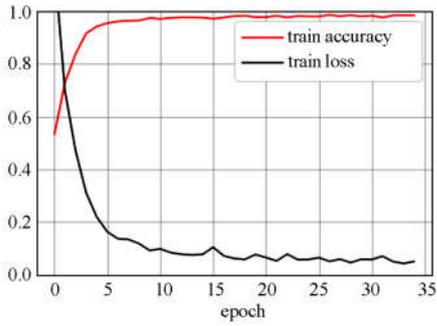
$$L(\theta) = \sum_{m=1}^M y_m \log(p_m) \quad (7)$$

式中,  $y_m$  为期望标签值。

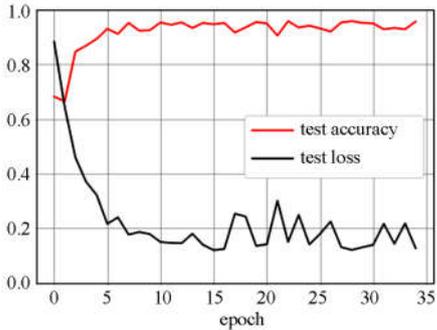
## 2 基于特征融合的一维 CNN(FCNN)

### 2.1 FCNN 算法的提出

将经典卷积神经网络 LeNet\_5 模型修改为一维模型, 训练并测试电能质量扰动信号, 得到的识别率曲线和损失曲线如图 1 所示。



(a) 在 LeNet\_5 模型上的训练情况



(b) 在 LeNet\_5 模型上的测试情况

图 1 在 LeNet\_5 模型上的训练与测试情况

Fig. 1 Training and testing results of the LeNet\_5

由图 1 可知, LeNet-5 在测试集上识别率仅为 96.11%, 且曲线波动较大, 这表明单个卷积神经网络模型在训练时鲁棒性较差。为此, 本文提出 FCNN 算法。

### 2.2 FCNN 结构图

基于 FCNN 的电能质量扰动分类结构如图 2 所示。FCNN 模型由三个已训练完成的子模型 Net\_21、Net\_18、Net\_6, 以及融合层(Merge 层)、Dropout 层、全连接层组成。各子模型的输入是长度为 1000 的电能质量扰动信号, 子模型最后一个池化层的输

出向量长度为 256, 等价于特征向量提取。Merge 层将其首尾拼接成长度为 768 的向量, 从而实现特征融合。Dropout 层能减少过拟合, 提高神经网络的泛化能力, Dropout 率为 0.5。全连接层的输出神经元节点数设置为 8。

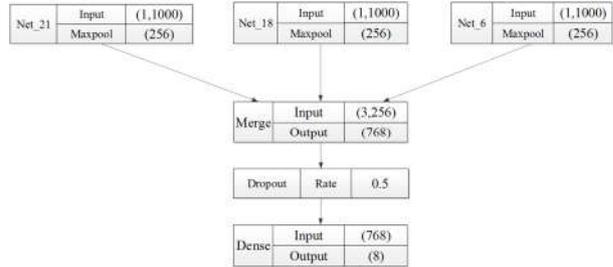


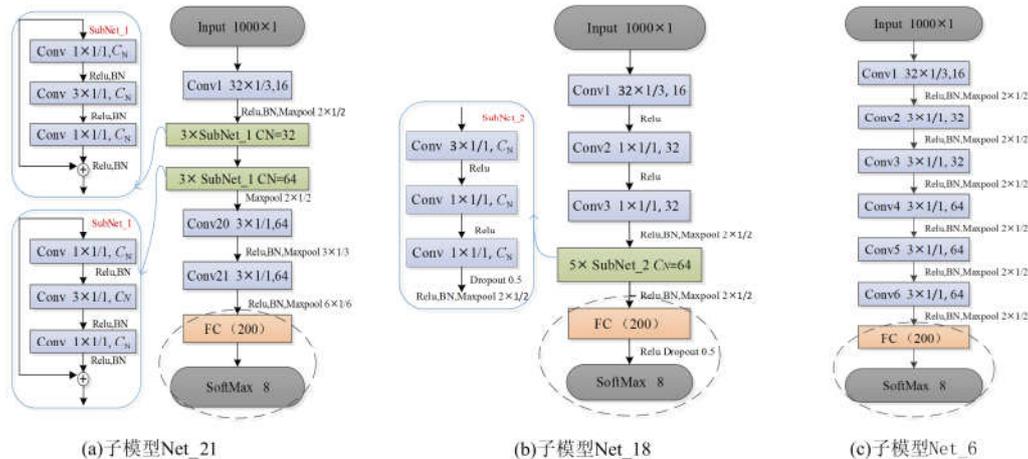
图 2 FCNN 结构图

Fig. 2 Structure chart of the FCNN

### 2.3 子模型结构

综合考虑训练时间与识别精度, 本文选择在三个经典模型 LeNet-5<sup>[20]</sup>、VGGNet<sup>[21]</sup>、ResNet<sup>[22]</sup>的基础上进行调试得出子模型结构。LeNet-5 首次在手写数字识别中取得巨大成功, VGGNet 在 2014 年 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)比赛中取得亚军, ResNet 在 2014 年 ILSVRC 比赛中取得冠军。

FCNN 中的三个子模型结构如图 3 所示。卷积核的参数为  $C_L \times C_W / C_S, C_N$ 。其中  $C_L$  为卷积核的长度,  $C_W$  为卷积核的宽度,  $C_S$  为步长,  $C_N$  为该层输出特征空间的数量。为了增强模型对原始数据的特征表达能力, 本文在经典模型 LeNet-5 的结构上增加网络层数, 搭建出子模型 Net\_6。子模型 Net\_18 借鉴经典 VGGNet 模型结构, 反复叠加 3×1 的卷积核, 通过不断加深网络结构来提升识别率。为了可



(a) 子模型 Net\_21

(b) 子模型 Net\_18

(c) 子模型 Net\_6

图 3 FCNN 中的子模型结构图

Fig. 3 Sub-model structures of the FCNN

以训练更深的网络,在经典模型 ResNet 的基础上优化网络层数和超参数,搭建出子模型 Net\_21。为了减少模型训练时间,三个子模型的第一个卷积层的卷积核长度设为 32。为了使曲线收敛更快,在模型中加入 BN 层。

### 2.4 FCNN 算法训练流程图(图 4)

首先,使用训练集 1 训练图 3 中的三个子模型待训练完成后,把训练集 2 输入到子模型中,取子模型最后一个池化层作为输出层,即丢弃子模型中虚线椭圆框中的部分,该过程就是通过三个子模型提取特征向量。然后经过 Merge 层把这三个输出层的特征向量融合为训练集 3。最后,使用训练集 3 训练最后的全连接层。FCNN 算法通过三个不同的子模型提取特征向量,不仅能够丰富每个样本的特征,而且能提高识别率,改善鲁棒性。

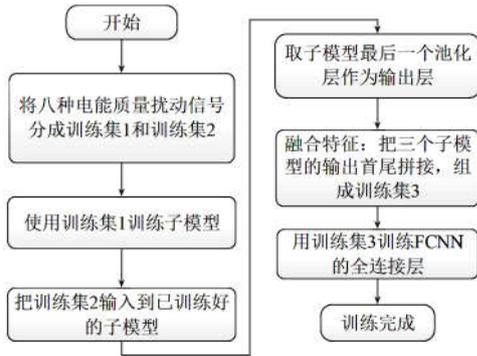


图 4 基于 FCNN 的训练流程图

Fig. 4 Training flowchart of the FCNN

## 3 方法验证

### 3.1 模型的训练与测试

在信噪比为 25 dB 和 15 dB 时,分别测试八类电能质量扰动信号,包括暂升(C0)、暂降(C1)、中断(C2)、谐波(C3)、闪变(C4)、振荡(C5)、暂升+谐波(C6)、暂降+谐波(C7)<sup>[23]</sup>。每类扰动信号有 1 000 个样本,随机选取其中 600 个样本组成训练集,剩下的样本组成测试集。其中采样频率为 3 200 Hz,单个样本数据长度为 1 000 个点,其频率  $f$  为 50 Hz<sup>[24]</sup>;在 Keras 中搭建 FCNN 模型,随机梯度下降优化算法(Stochastic Gradient Descent)的学习速率(Learning Rate)设置为 0.005;小批量(Mini-Batch)大小为 30;选择 Relu 作为激活函数。

图 5、图 6 为预训练子模型过程中,子模型在测试集和训练集上的识别率曲线(Accuacy)及损失曲线(Loss)。

由图 5 可知,在信噪比为 25 dB 时,三个子模型分别训练 12、30、40 代后,对训练集的识别率会趋于稳定,在测试集上的识别率能达到 99%以上。由图 6 可知,在信噪比为 15 dB 时,三个子模型分别训练到 17、40、50 代后,对训练集的识别率会趋于稳定,测试集的识别率依然能够达到 98%以上,表明这三个子模型具有比较高的抗噪性能。但单个子模型在测试集上识别率稳定性不高,曲线波动较大,这是由于在训练过程中模型参数不断更新导致所提取的特征不断变化。这和图 1 的分析结果是一致的。

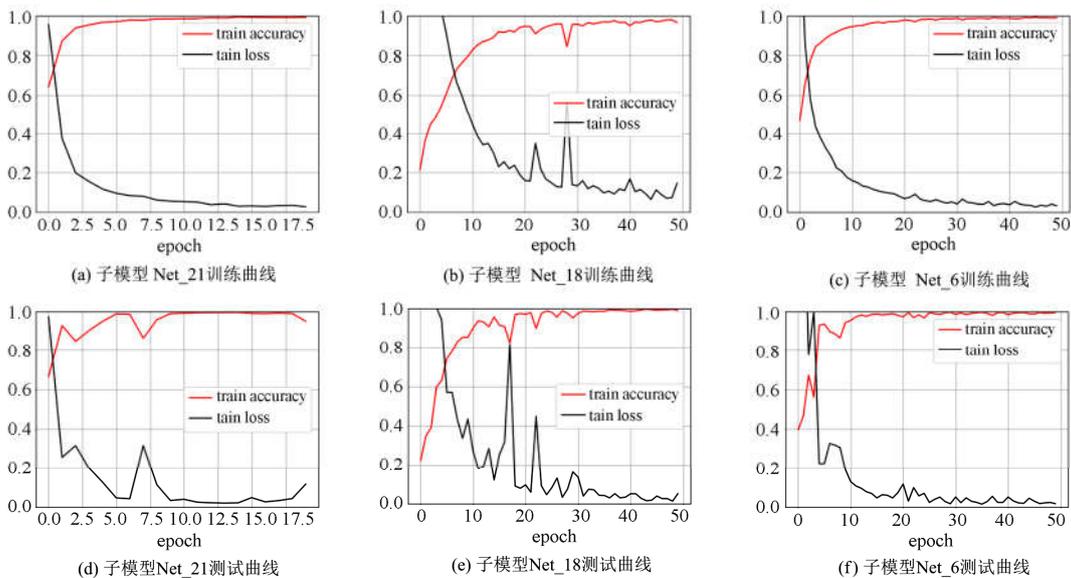


图 5 子模型在信噪比 25 dB 的训练曲线与测试曲线

Fig. 5 Training and test results of sub-model with 25 dB SNR

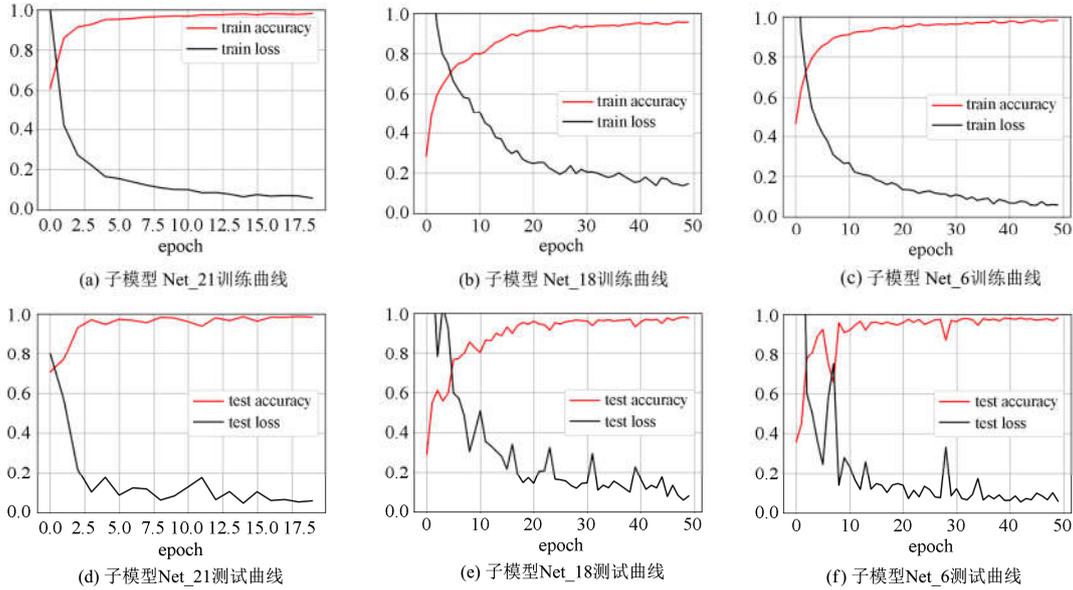


图 6 子模型在信噪比 15 dB 的训练曲线与测试曲线  
Fig. 6 Training and test results of sub-model with 15 dB SNR

### 3.2 特征可视化分析

为了能直观地理解特征融合对特征区分度影响的情况, 本文采用 t-SNE 降维技术<sup>[25]</sup>, 将子模型提取的特征以及融合后的特征降成二维并可视化, 图 7 为子模型特征可视化图, 图 8 为融合之后的特征

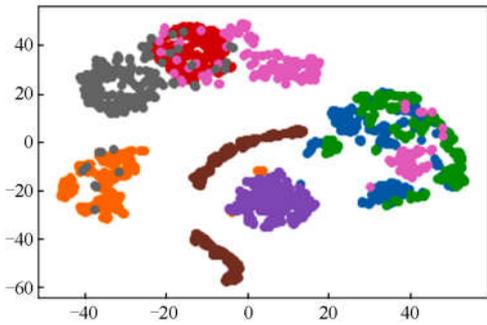


图 7 子模型特征可视化图  
Fig. 7 sub-model feature visualization

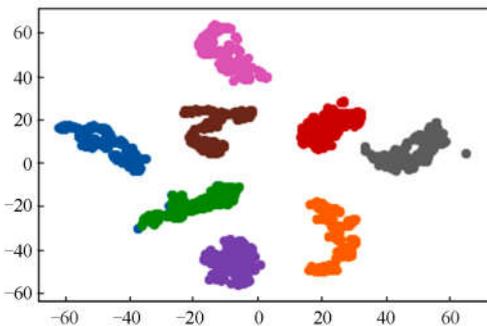


图 8 特征融合之后的特征可视化图  
Fig. 8 Feature visualization after feature fusion

可视化图。从图中可以看出, 特征融合之后, 重合的部分变少, 而且不同类别之间的距离加大。这表明, 采用特征融合之后, 特征表达能力加强, 特征变得更加可分。这也印证了特征融合的有效性, 解释了上文中第 2 小节单个模型训练时鲁棒性差的原因。

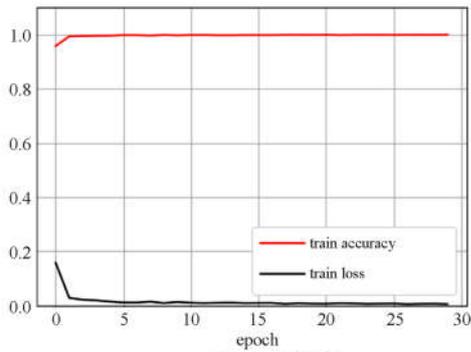
### 3.3 识别率比较

图 9、图 10 是 FCNN 在 25 dB 和 15 dB 的噪声环境下的识别率曲线和损失曲线。对比单个子卷积神经网络得到的结果, 可以看出 FCNN 在融合了三个子模型提取的特征后, 鲁棒性能良好, 在测试集上的识别率、曲线稳定性都得到提高。

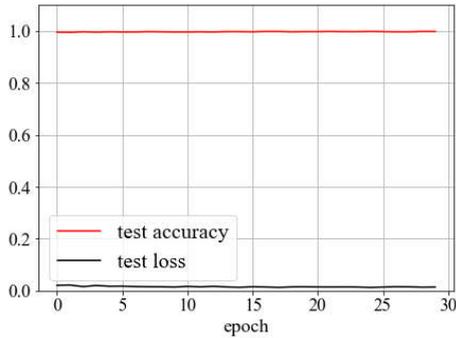
采用 FCNN 算法, 文献[11-12]中的电能扰动分类算法来训练和测试本文的数据集, 表 1 为对比结果。由表 1 可知, 30 dB 下的 FCNN 分类识别率为 99.53%, 而文献[11-12]的算法得到的识别率分别只有 95.63%和 92.00%。并且文献[11]和文献[12]的算法需根据其算法特点选取合适的特征向量, 这容易产生冗余特征, 导致识别率下降, 受噪声影响大。而本文提出的 FCNN 算法不需要人为提前选取特征向量。

表 1 不同方法的识别率

Table 1 Classification accuracy of different methods			
扰动类型	分类识别率/%		
	无噪声	40 dB	30 dB
FCNN	99.88	99.62	99.53
文献[11]	96.00	95.87	95.63
文献[12]	99.13	93.50	92.00



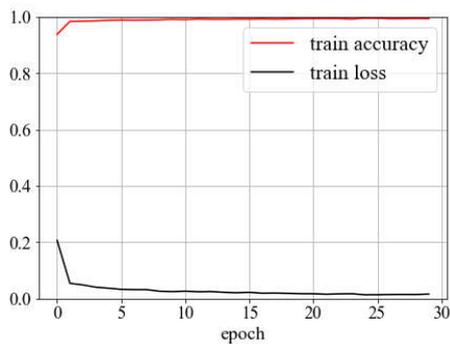
(a) FCNN 训练曲线



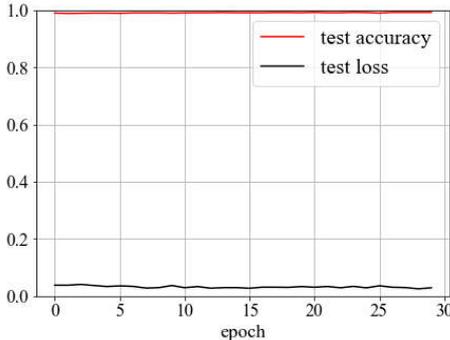
(b) FCNN 测试曲线

图 9 FCNN 在信噪比 25 dB 的训练曲线与测试曲线

Fig. 9 Training and test results of FCNN with 25 dB SNR



(a) FCNN 训练曲线



(b) FCNN 测试曲线

图 10 FCNN 在信噪比 15 dB 的训练曲线与测试曲线

Fig. 10 Training and test results of FCNN with 15 dB SNR

表 2 为不同信噪比下 FCNN 的识别率，可以看出 FCNN 在信噪比为 25 dB 和 15 dB 的较强噪声环境下总体分类识别率仍然能保持在 99% 以上。从单一扰动的角度分析，暂降和中断的分类识别率较低，这是由于在噪声环境下，暂降信号和中断信号的空间特征比较相似。文献[14]所提出的分类方法在 40 dB 下的总体分类识别率只有 98.51%，在 20 dB 下暂降的分类识别率分别只有 95.80%。可知，FCNN 的总体分类识别率，单一扰动分类识别率以及抗噪性能都明显高于文献[14]所提算法。

表 2 不同信噪比下的识别率

Table 2 Classification accuracy with different SNRs

扰动类型	分类识别率/%	
	25 dB	15 dB
C0	100	100
C1	96.83	97.50
C2	98.96	97.00
C3	100	100
C4	100	100
C5	100	100
C6	100	100
C7	100	100
平均值	99.47	99.31

#### 4 结论

为了避免人工选取特征向量导致识别率下降的问题，本文采用 CNN 对电能质量扰动进行识别，通过训练 CNN 实现特征提取。为了增强算法鲁棒性、提高识别率，本文提出了 FCNN 算法。

仿真结果表明，与单一的一维 CNN 模型相比，FCNN 的识别率和鲁棒性更好。通过 T-SNE 降维技术将模型提取的特征转换成二维并可视化，表明融合后的特征区分度更大。FCNN 在信噪比为 25 dB 时分类识别率能达到 99.47%，在信噪比为 15 dB 时识别率能达到 99.31%。

与文献[11-12]所提传统机器学习算法相比，FCNN 在无噪声、40 dB、30 dB 三种噪声环境下的识别率比文献[11]分别高出 3.88%、2.75%、3.90%，比文献[12]分别高出 0.75%、6.12%、7.53%。

与文献[14]所提算法相比，FCNN 算法不需进行二维图像转换。文献[14]所提出算法在信噪比为 40 dB 时的总体分类识别率分别仅有 98.51%，而 FCNN 在 15 dB 的总体分类识别率为 99.31%。

综上所述，本文提出的 FCNN 算法能有效提高鲁棒性和分类识别率，并具有较强的抗噪性能。

## 参考文献

- [1] 黄南天, 彭华, 蔡国伟, 等. 电能质量复合扰动特征选择与最优决策树构建[J]. 中国电机工程学报, 2017, 37(3): 776-786.  
HUANG Nantian, PENG Hua, CAI Guowei, et al. Feature selection and optimal decision tree construction of complex power quality disturbances[J]. Proceedings of the CSEE, 2017, 37(3): 776-786.
- [2] 姚建刚, 郭知非, 陈锦攀. 基于小波和 BP 神经网络的电能扰动分类新方法[J]. 电网技术, 2012, 36(5): 139-144.  
YAO Jiangan, GUO Zhifei, CHEN Jinpan. A new approach to recognize power quality disturbances based on wavelet transform and BP neural network[J]. Power System Technology, 2012, 36(5): 139-144.
- [3] 黄建明, 瞿合祚, 李晓明. 基于短时傅里叶变换及其谱峭度的电能质量混合扰动分类[J]. 电网技术, 2016, 40(10): 3184-3191.  
HUANG Jianming, QU Hezuo, LI Xiaoming. Classification for hybrid power quality disturbance based on STFT and its spectral kurtosis[J]. Power System Technology, 2016, 40(10): 3184-3191.
- [4] 袁莉芬, 孙业胜, 何怡刚, 等. 基于小波包优选的模拟电路故障特征提取方法[J]. 电工技术学报, 2018, 33(1): 158-165.  
YUAN Lifen, SUN Yesheng, HE Yigang, et al. Fault feature extraction method for analog circuit based on preferred wavelet packet[J]. Transactions of China Electrotechnical Society, 2018, 33(1): 158-165.
- [5] 许立武, 李开成, 罗奕, 等. 基于不完全 S 变换与梯度提升树的电能质量复合扰动识别[J]. 电力系统保护与控制, 2019, 47(6): 24-31.  
XU Liwu, LI Kaicheng, LUO Yi, et al. Classification of complex power quality disturbances based on incomplete S-transform and gradient boosting decision tree[J]. Power System Protection and Control, 2019, 47(6): 24-31.
- [6] 尹柏强, 何怡刚, 朱彦卿. 一种广义 S 变换及模糊 SOM 网络的电能质量多扰动检测和识别方法[J]. 中国电机工程学报, 2015, 35(4): 866-872.  
YIN Baiqiang, HE Yigang, ZHU Yanqing. Detection and classification of power quality multi-disturbances based on generalized S-transform and fuzzy SOM neural network[J]. Proceedings of the CSEE, 2015, 35(4): 866-872.
- [7] 曹玲芝, 刘俊飞, 郑晓婉. 基于 EEMD 的 HHT 在电能质量多扰动分类识别中的应用[J]. 电气技术, 2017(4): 66-70.  
CAO Lingzhi, LIU Junfei, ZHENG Xiaowan. Classification and recognition of power quality multi-disturbance based on EEMD-HHT[J]. Electrical Engineering, 2017(4): 66-70.
- [8] 陈晓静, 李开成, 肖剑, 等. 一种实时电能质量扰动分类方法[J]. 电工技术学报, 2017, 32(3): 45-55.  
CHEN Xiaojing, LI Kaicheng, XIAO Jian, et al. A method of real-time power quality disturbance classification[J]. Transactions of China Electrotechnical Society, 2017, 32(3): 45-55.
- [9] DE YONG D, BHOWMIK S, MAGNAGO F. An effective power quality classifier using wavelet transform and support vector machines[J]. Expert Systems with Applications, 2015, 42(15): 6075-6081.
- [10] LEE I W C, DASH P K. S-transform-based intelligent system for classification of power quality disturbance signals[J]. IEEE Transactions on Industrial Electronics, 2003, 50(4): 800-805.
- [11] 王慧慧, 王萍, 刘涛, 等. 基于生长-修剪优化 RBF 神经网络的电能质量扰动分类[J]. 电网技术, 2018, 42(8): 2408-2415.  
WANG Huihui, WANG Ping, LIU Tao, et al. Power quality disturbance classification based on growing and pruning optimal RBF neural network[J]. Power System Technology, 2018, 42(8): 2408-2415.
- [12] SAINI M K, BENIWAL R K. Optimum fractionally delayed wavelet design for PQ event detection and classification[J]. International Transactions on Electrical Energy Systems, 2017, 27(10): 2408-2419.
- [13] 曹思扬, 戴朝华, 朱云芳, 等. 一种新的电能质量扰动信号压缩感知识别方法[J]. 电力系统保护与控制, 2017, 45(3): 7-12.  
CAO Siyang, DAI Chaohua, ZHU Yunfang, et al. A novel compressed sensing-based recognition method for power quality disturbance signals[J]. Power System Protection and Control, 2017, 45(3): 7-12.
- [14] 陈伟, 何家欢, 裴喜平. 基于相空间重构和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, 2018, 46(14): 87-93.  
CHEN Wei, HE Jiahuan, PEI Xiping. Classification for power quality disturbance based on phase-space reconstruction and convolution neural network[J]. Power System Protection and Control, 2018, 46(14): 87-93.
- [15] 瞿合祚, 李晓明, 陈陈, 等. 基于卷积神经网络的电能质量扰动分类[J]. 武汉大学学报: 工学版, 2018, 51(6): 534-539.  
QU Hezuo, LI Xiaoming, CHEN Chen, et al. Classification of power quality disturbances using convolutional neural network[J]. Engineering Journal of Wuhan University,

- 2018, 51(6): 534-539.
- [16] KIRANYAZ S, INCE T, GABBOUJ M, et al. Real-time patient-specific ECG classification by 1-D convolutional neural networks[J]. IEEE Transactions on Biomedical Engineering, 2016, 63(3): 664-675.
- [17] ZHANG Wei, PENG Gaoliang, LI Chuanhao, et al. A new deep learning model for fault diagnosis with good anti-Noise and domain adaptation ability on raw vibration signals[J]. Sensors, 2017, 17(2): 425-436.
- [18] INCE T, KIRANYAZ S, EREN L, et al. Real-time motor fault detection by 1-D convolutional neural networks[J]. IEEE Transactions on Industrial Electronics, 2016, 63(11): 7067-7075.
- [19] ZHANG Wei, LI Chuanhao, PENG Gaoliang, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load[J]. Mechanical Systems and Signal Processing, 2018, 100: 439-453.
- [20] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [21] KE Hengjin, CHEN Dan, LI Xiaoli, et al. Towards brain big data classification: epileptic ECG identification with a lightweight VGGNet on global MIC[J]. IEEE Access, 2018, 99: 1-12.
- [22] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [23] 谢善益, 肖斐, 艾芊, 等. 基于并行隐马尔科夫模型的电能质量扰动事件分类[J]. 电力系统保护与控制, 2019, 47(2): 80-86.
- XIE Shanyi, XIAO Fei, AI Qian, et al. Parallel hidden Markov model based classification of power quality disturbances events[J]. Power System Protection and Control, 2019, 47(2): 80-86.
- [24] RAHUL, KAPOOR R, TRIPATHI M M. Detection and classification of multiple power signal patterns with Volterra series and interval type-2 fuzzy logic system[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 92-101. DOI: 10.1186/s41601-017-0039-z.
- [25] ZHANG Lefei, ZHANG Liangpei, TAO Dacheng, et al. A modified stochastic neighbor embedding for multi-feature dimension reduction of remote sensing images[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2013, 83: 30-39.
- 
- 收稿日期: 2019-05-16; 修回日期: 2019-11-11
- 作者简介:
- 王维博(1977—), 男, 通信作者, 博士, 副教授, 硕士生导师, 研究方向为电能质量检测与分析、智能电网信息通信技术、智能优化算法; E-mail: wangweibo@mail.xhu.edu.cn
- 张 斌(1995—), 男, 硕士研究生, 研究方向为电能质量检测与分析。E-mail: 540814983@qq.com
- (编辑 姜新丽)