

doi:10.16055/j.issn.1672-058X.2021.0005.008

一种新的电能质量扰动识别方法*

武昭旭, 杨岸, 祝龙记

(安徽理工大学 电气与信息工程学院, 安徽 淮南 232000)

摘要:针对电能质量扰动信号数据多、识别速度慢、识别过程复杂等问题,提出一种基于压缩感知理论和一维卷积神经网络的电能质量扰动信号识别分类方法,该方法通过离散傅里叶变换、高斯矩阵获取原始扰动信号的稀疏向量,利用正交匹配追踪算法重构扰动信号,将原始扰动信号和稀疏向量输入一维卷积神经网络分类模型;由仿真结果可知,可充分降低现有识别方法所需处理的扰动信号的数据量,实现了以较少的数据量表达扰动信号的特征信息,对有、无噪声情况下的14种单一、复合扰动信号具有很高的识别率,表明了方法具有采样数据少、特征提取方便、高识别率和较好的噪声鲁棒性的特点。

关键词:压缩感知;一维卷积神经网络;深度学习;电能质量扰动

中图分类号:TM711

文献标志码:A

文章编号:1672-058X(2021)05-0049-06

0 引言

随着电力系统的发展、电源接入形式多样化、负荷种类的增加,电网中的电能质量问题越来越突出。因此,准确、快速地对电能质量扰动信号识别,是保障电网稳定、安全、高效运行的前提。

目前,国内外学者针对电能质量扰动信号识别分类进行了深入研究,方法主要有:傅里叶变换^[1]、小波变换^[2]、S变换^[3]、希尔伯特黄变换^[4]、相空间重构^[5]等。文献[6]利用小波变换将原始扰动信号分解到各个频带,分别计算各个频带的能量值和小波系数熵,将二者及基波频带扰动过程的均方根作为特征值输入到改进神经树进行分类,分类准确率较高,但所选扰动均为单一扰动信号。文献[7]利用稀疏自动编码器对原始扰动信号进行无监督特征学习,自动提取数据特征的稀疏特征表达,随后使用Softmax分类器进行训练,得到各种扰动信号的分类准确率,解决了传统神经网络中权值初始随机性的缺点,但编码过程复杂。

通过对现有电能质量扰动信号识别方法的研究可知,各种识别方法通常可分为两个步骤:特征提取和特征分类。特征提取是使用不同的时域、频域信号分析方法提取能反映不同扰动信号的判别信息,特征分类是通过训练不同的分类器实现对扰动信号特征的识别。本文所提方法可以充分减少扰动识别过程中所需处理的数据量、简化识别过程、提高识别速度和识别准确率。

针对电能质量扰动信号数据多、识别率低、识别速度慢等问题,将基于一维卷积神经网络的压缩感知算法应用于电能质量扰动信号的分类。首先阐述了如何使用压缩感知理论对电能质量扰动信号求解稀疏向量,然后提出了基于一维卷积神经网络的分类模型,实现电能质量扰动信号的分类。

1 基于压缩感知理论的电能质量扰动信号压缩与重构

1.1 压缩感知理论

2006年,Donoho等^[8]提出了压缩感知理论

收稿日期:2020-09-09;修回日期:2020-10-23.

* 基金项目:国家自然科学基金-山西煤基低碳联合基金(U1610120).

作者简介:武昭旭(1993—),男,山西朔州人,硕士,从事电能质量研究.

(Compressed Sensing, CS)。该理论指出如果信号是稀疏的,则可以在远低于 Nyquist 采样频率条件下重构。即:如果一维信号 $X_{N \times 1}$ 在稀疏域 Ψ 是 K -稀疏的($K \ll N$),则构造一个与变换域 Ψ 不相关的观测矩阵 $\Phi_{M \times N}$ ($M \ll N$),对原始信号进行观测:

$$Y = \Phi X = \Phi \Psi S = \Theta S \quad (1)$$

其中, $\Theta = \Phi \Psi$, 称之为感知矩阵, Φ 为测量矩阵, Ψ 为稀疏矩阵, $S_{N \times 1}$ 为稀疏域中的稀疏向量。对求解 ℓ_0 -范数,则可以得到重构信号 $\hat{X} = \Psi \hat{S}$:

$$\hat{S} = \operatorname{argmin} \|S\|_0 \quad (\text{s. t. } Y = \Phi \Psi S) \quad (2)$$

其中, $\|S\|_0$ 是 S 的零范数, \hat{S} 为待求解的稀疏向量。

1.2 电能质量扰动信号压缩与重构

电能质量扰动信号并非直接符合稀疏性,但是可以通过某种变换得到稀疏性的效果。即找到一种稀疏变换基 $\Psi = [\psi_1, \psi_2, \dots, \psi_N]$, 将扰动信号 X 表示为

$$X = \Psi S = \sum_{i=1}^N \psi_i S_i \quad (3)$$

其中, $S = [S_1, S_2, \dots, S_N]$ 是电能质量扰动信号 X 在变换域 Ψ 的表示。采用离散傅里叶变换(DFT)作为稀疏变换基^[9]。

测量矩阵是一个 $M \times N$ 的矩阵,设计测量矩阵的目的是获取原始信号 X 的 M 个测量值,使观测信号 Y 中的 M 个值可以有效地保留原始信号 X 中的信息。测量矩阵的优劣直接关系到原始信号的恢复效果,选用高斯随机矩阵作为扰动信号的测量矩阵。

重构算法就是把采集到的观测值 $Y_{M \times 1}$ 利用测量矩阵 Φ 和稀疏变换基 Ψ 来恢复原始信号,使用正交匹配追踪算法(Orthogonal Matching Pursuit, OMP)进行压缩重构^[10]。图 1 为电能质量扰动信号压缩感知流程图。

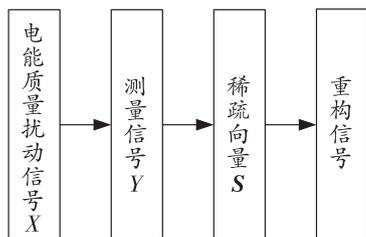
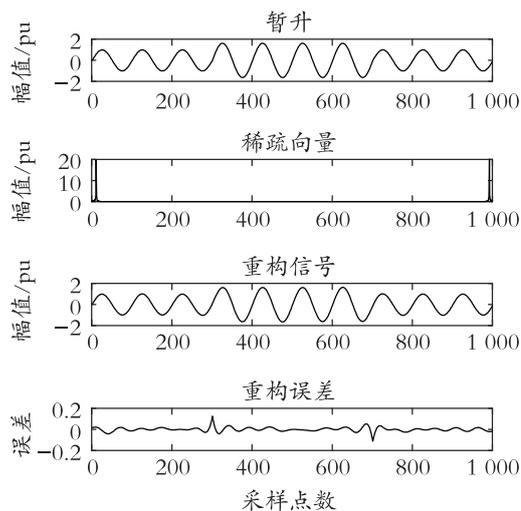


图 1 电能质量扰动信号压缩感知流程

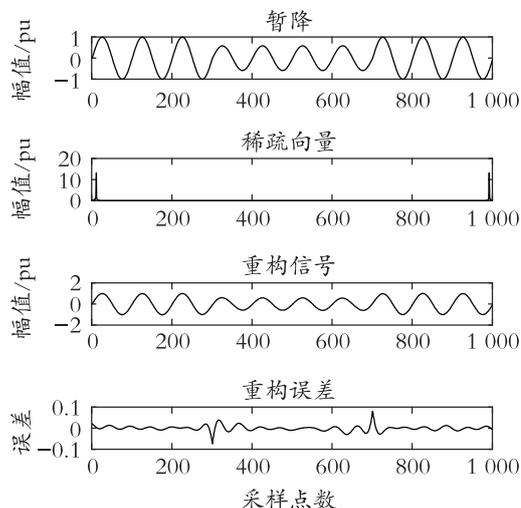
Fig. 1 Power quality disturbance signal compression sensing process

1.3 算例分析

根据 IEEE 建立 8 种单一电能质量扰动信号和 6 种复合电能质量扰动信号,分别为正常信号(C_1)、暂升(C_2)、暂降(C_3)、中断(C_4)、谐波(C_5)、脉冲(C_6)、振荡(C_7)、波动(C_8)、暂升+脉冲(C_9)、暂降+脉冲(C_{10})、谐波+波动(C_{11})、波动+脉冲(C_{12})、谐波+暂升+脉冲(C_{13})和谐波+波动+振荡(C_{14}),以 3 种电能质量扰动信号(暂升、暂降、谐波+波动)为例,分别进行仿真,其中电能质量扰动信号长度 $N = 1\,000$,测量数 $M = 256$,稀疏度 $K = 16$ 。图 2 为 3 种扰动信号的压缩重构图,对比 3 种稀疏向量波形可知,使用稀疏向量不仅极大地减少了分类过程中处理的数据量,而且不同扰动信号的稀疏向量特征分明,便于后续分类;重构信号的重构误差相对较小,可以精确地恢复原始信号。



(a) 暂升



(b) 暂降

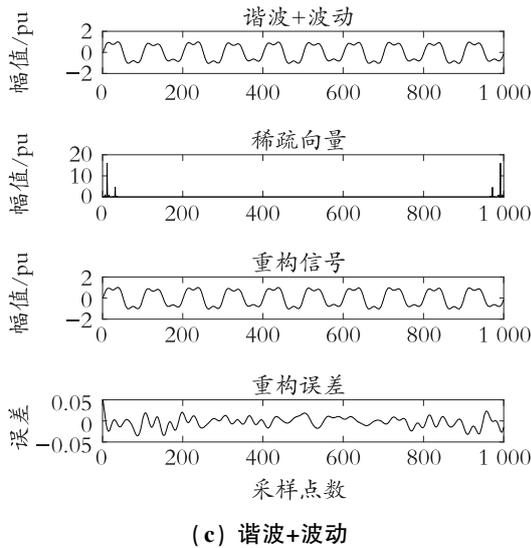


图 2 3 种电能质量扰动信号的压缩重构图

Fig. 2 Compression reconstruction of three power quality disturbance signals

2 基于一维卷积神经网络的电能质量扰动信号分类

2.1 一维卷积神经网络

深度学习^[11-14] (Deep Learning, DL) 作为一种机器学习方法,在图像识别、语音处理等领域都取得了不错的成果。其中常用于图像识别领域的卷积神经网络,被发现对时间序列数据同样有效,因此使用一维卷积神经网络^[15-16] (One-Dimensional Convolutional Neural Network, 1D-CNN) 处理一维电能质量扰动信号数据。1D-CNN 可以自动学习、提取电能质量扰动信号的时序特征,实现对扰动信号的分类。

1D-CNN 与二维卷积神经网络类似,由卷积层、池化层、Dropout 层和全连接层等组成。卷积层通过卷积操作实现对输入层的特征提取。池化层对卷积层生成的特征图进行压缩,简化网络计算复杂度和提取主要特征,实现对特征图的降维。卷积层与池化层的堆叠组成深层的神经网络结构,实现对输入数据特征的组合和局部不变。

卷积层做卷积运算时,需要将卷积核放在输入数据上,二者的中心位置需要重合。依次计算卷积核与其对应位置数据值的积并求和,最后计算得到

的是特征图中该位置的值。由式(4)可知,如果 $X_{1,m}$ 表示输入数据的第 1 行第 m 列的值; $W_{1,n}$ 表示卷积核的第 1 行第 n 列的权重值; W_b 表示卷积核的偏置值; $a_{1,m}$ 表示特征图的第 1 行第 m 列的值; 用 f 表示网络使用的 Relu 激活函数,则一维卷积如图 3 所示。

$$a_{1,m} = f\left(\sum_{n=1}^N W_{1,n} X_{1,m+n-1} + W_b\right) \quad (4)$$

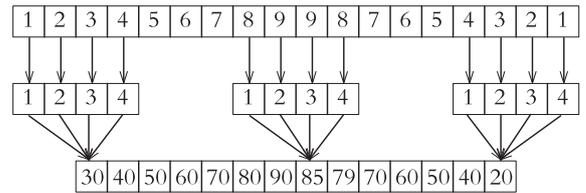


图 3 一维卷积

Fig. 3 One-dimensional convolution

池化 (Pooling) 也称为下采样。池化可以理解为在不影响对数据的特征收集条件下对数据降维,即减小特征图的大小,池化可分为均值池化 (Mean Pooling)、最大池化 (Max Pooling) 等。一维池化如图 4 所示,池化核大小和池化步长均为 3,采用最大池化。

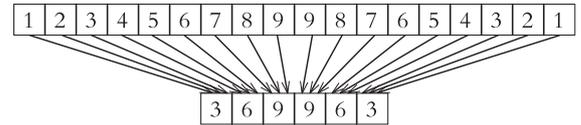


图 4 一维池化

Fig. 4 One-dimensional pooling

全连接层将卷积层、池化层提取到的局部特征通过权值矩阵形成完整的图形,在整个卷积神经网络中起到“分类器”的作用,层中的每个神经元与前一层所有神经元进行连接。全连接层的输出值传递到输出层,输出层激活函数通常是 Softmax 函数,输出各分类类别的概率。

2.2 一维卷积神经网络模型结构

通过 Tensorflow 中的 Keras 框架实现卷积神经网络,该网络有 4 个卷积层、2 个池化层和 1 个全连接层。输入 1D-CNN 的电能质量扰动信号大小为 1×1000 ,卷积层采用 1×10 卷积核,步长为 1,选择 ReLU 函数为激活函数;池化层采用 Max-Pooling,池化窗口大小为 1×3 ,步长为 1;全连接层的输出结果

是一个 1×14 的向量,即输入样本属于对应标签的可能性大小,最后输出扰动信号的 14 分类识别率。分别设置参数:Epoch 为 50,损失函数为 Categorical_crossentropy,Optimizer 为 Adam,Dropout 为 0.5。

3 仿真分析

采用 MATLAB 生成 14 种电能质量扰动信号,正常信号和每类扰动信号各生成 1 000 个随机样本,共 14 000 个样本。每类扰动分别叠加信噪比(SNR)为 30 dB 的噪声信号。每类扰动选取 800 个样本作为训练集,200 个样本作为测试集。再通过压缩感知理论计算每个扰动信号的稀疏向量,形成基于稀疏向量的样本集。将原始信号和对应的稀疏向量数据作为一维卷积神经网络的输入,运行并训练搭建好的网络分类模型。

为了评估网络的分类性能,绘制训练损失曲线和识别率曲线。训练损失曲线如图 5 所示,识别率曲线如图 6 所示。从图 5 可以看出,原始数据和稀疏向量的训练损失均在不断下降,其中原始数据对应的损失曲线快速下降并保持在一个较低的数值;稀疏向量对应的损失曲线下降缓慢,但最终仍保持在一个较低的数值,说明预测标签与实际标签的差距很小,网络的分类性能很好。由图 6 可知,其中原始数据对应的识别率经过约 10 代的训练,快速上升并保持在一个较高的数值,此后网络参数不断进行微调,识别率趋于稳定,大约为 99%;稀疏向量对应的识别率则由一个较低的初始值缓慢上升,经过 50 代的训练后,保持在一个较高的数值。

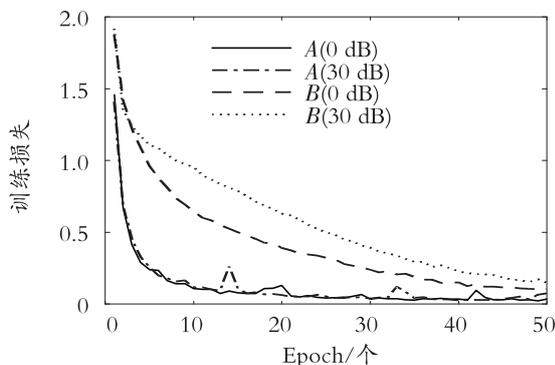


图 5 训练损失曲线

Fig. 5 Training loss curve

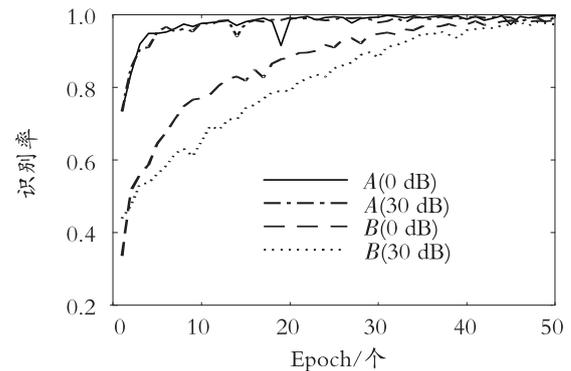


图 6 识别率曲线

Fig. 6 Recognition rate curve

不同的噪声强度下,各类电能质量扰动信号的分类准确率结果如表 1 所示。其中,A 为原始数据,B 为稀疏向量。

表 1 不同信噪比下扰动信号的分类准确率

Table 1 Classification accuracy of perturbed signals under different SNR

扰动类型	A(0 dB) 识别率/%	B(0 dB) 识别率/%	A(30dB) 识别率/%	B(30 dB) 识别率/%
C_1	100.00	100.00	100.00	100.00
C_2	100.00	100.00	100.00	99.50
C_3	98.00	99.50	95.50	97.50
C_4	98.50	98.50	99.50	100.00
C_5	100.00	96.00	100.00	93.50
C_6	100.00	100.00	100.00	97.50
C_7	100.00	100.00	100.00	99.50
C_8	100.00	100.00	100.00	100.00
C_9	100.00	99.00	100.00	93.00
C_{10}	100.00	98.00	100.00	99.00
C_{11}	100.00	94.50	99.50	99.50
C_{12}	100.00	99.50	100.00	96.50
C_{13}	100.00	99.50	100.00	100.00
C_{14}	100.00	94.50	98.50	87.50
平均	99.75	98.50	99.50	97.36

由表 1 可以看出:本方法在不同的噪声强度下对扰动分类的总体准确率均较高,多种扰动在不同噪声情况下均可达到较高的识别率,说明该方法具有较好的抗噪性能。但是稀疏向量较原始数据输入的识别率有所下降,这是因为重构过程中产生了重构误差,导致了扰动信号中信息的丢失。

4 结束语

使用一维卷积神经网络对扰动信号经压缩感知生成的稀疏向量进行学习,可以有效地提取扰动的特征。通过处理长度仅为16的稀疏向量而不是长度为1000的原始信号,减少了分类过程中需要处理的数据量,提高了识别速度。在不同的噪声情况下,将原始数据和稀疏向量分别作为网络的输入,由实验结果可知,该方法能获得较高的识别率,具有良好的抗噪能力。

参考文献(References):

- [1] 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 J M, QU H Z, LI X M. Classification for Hybrid Power Quality Disturbance Based on STFT and Its Spectral Kurtosis [J]. Power System Technology, 2016, 40(10): 3184—3191 (in Chinese)
- [2] 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, V47(2): 80—86
XIE S Y, XIAO F, AI Q, et al. Parallel Hidden Markov Model Based Classification of Power Quality Disturbance Events [J]. Power System Protection and Control, 2019, 47(2): 80—86 (in Chinese)
- [3] 杨丹丹,关维国. 基于S变换模矩阵的电能质量暂态检测. 计算机系统应用, 2017, 26(7): 183—188
YANG D D, GUAN W G. Detection of Transient Power Quality Disturbances Based on S-Transform Module Matrices [J]. Computer Systems & Applications, 2017, 26(7): 183—188 (in Chinese)
- [4] 胡雷,殷礼胜,陈湘波,等. 基于改进HHT的电能质量扰动检测方法[J]. 电测与仪表, 2018, 55(21): 105—111
HU L, YIN L S, CHEN X B, et al. Power Quality Disturbance Detection Method Based on Improved HHT [J]. Electrical Measurement & Instrumentation, 2018, 55(21): 105—111 (in Chinese)
- [5] 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 W, HE J H, PEI X P. 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 (in Chinese)
- [6] 吴兆刚,李唐兵,姚建刚,等. 基于小波和改进神经树的电能质量扰动分类[J]. 电力系统保护与控制, 2014, V42(24): 86—92
WU Z G, LI T B, YAO J G, et al. Power Quality Disturbance Classification Based on a Wavelet and Improved Neural Tree [J]. Power System Protection and Control, 2014, 42(24): 86—92 (in Chinese)
- [7] 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 X S, DUAN B, YIN Q X, 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 (in Chinese)
- [8] 朱云芳,戴朝华,陈维荣,等. 压缩感知理论及其电能质量应用与展望[J]. 电力系统及其自动化学报, 2015, 27(1): 80—85
ZHU Y F, DAI C H, CHEN W R, et al. Present Status and Prospect on Compressed Sensing in Power Systems [J]. Proceedings of the CSU-EPSC, 2015, 27(1): 80—85 (in Chinese)
- [9] 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, V45(3): 7—12
CAO S Y, DAI C H, ZHU Y F, 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 (in Chinese)
- [10] 陈伟,何家欢,裴喜平. 深度信念网络在电能质量复合扰动识别中的应用[J]. 电力系统及其自动化学报, 2018, 30(9): 75—82
CHEN W, HE J H, PEI X P. Application of Deep Belief Network in Power Quality Compound Disturbance Identification [J]. Proceedings of the CSU-EPSC, 2018, 30(9): 75—82 (in Chinese)
- [11] ZHU X B, LI Z Z, ZHANG X Y, et al. Deep Convolutional Representations and Kernel Extreme

- Learning Machines for Image Classification [J]. Multimedia Tools and Applications, 2019, 78(20): 29271—29290
- [12] WANG D L, CHEN J T. Supervised Speech Separation Based on Deep Learning: An Overview. [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2018, 26(10): 1702—1726
- [13] QAISAR A, MOSTAFA E, ARFAN J. Video Scene Analysis: An Overview and Challenges on Deep Learning Algorithms [J]. Multimedia Tools and Applications, 2018, 77(16): 20415—20453
- [14] CONNOR S, TAGHI M. A Survey on Image Data Augmentation for Deep Learning [J]. Journal of Big Data, 2019, 6(1): 1—48
- [15] 赵璐, 马野. 基于一维卷积神经网络的齿轮箱故障诊断研究[J]. 测试技术学报, 2019, 33(4): 302—306
- ZHAO L, MA Y. Fault Diagnosis of Gear Box Based on One-Dimensional Convolutional Neural Networks [J]. Journal of Test and Measurement Technology, 2019, 33(4): 302—306(in Chinese)
- [16] 高昆仑, 杨帅, 刘思言, 等. 基于一维卷积神经网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2019, 43(12): 18—26
- GAO K L, YANG S, LIU S Y, et al. Transient Stability Assessment for Power System Based on One-Dimensional Convolutional Neural Network [J]. Automation of Electric Power Systems, 2019, 43(12): 18—26(in Chinese)

A New Method for Identifying Power Quality Disturbances

WU Zhao-xu, YANG An, ZHU Long-ji

(School of Electrical and Information Engineering, Anhui University of Science and Technology, Anhui Huainan 232000, China)

Abstract: Aiming at the problems of multiple power quality disturbance signals, slow recognition speed, and complicated recognition process, a power quality disturbance signal recognition and classification method based on compressed sensing theory and one-dimensional convolutional neural network is proposed. This method uses discrete Fourier transform and Gaussian matrix to obtain the sparse vector of the original disturbance signal, uses the orthogonal matching pursuit algorithm to reconstruct the disturbance signal, and inputs the original disturbance signal and the sparse vector into the one-dimensional convolutional neural network classification model. It can be seen from the simulation results that this method can fully reduce the data volume of the disturbance signal to be processed by the existing recognition method, and realize the expression of the characteristic information of the disturbance signal with a small amount of data. It has high recognition rate for 14 types of single and compound disturbance signals with and without noise, which shows that the method has the characteristics of less sampling data, convenient feature extraction, high recognition rate and better noise robustness.

Key words: compressed sensing; one-dimensional convolutional neural network; deep learning; power quality disturbance

责任编辑: 罗姗姗

引用本文/Cite this paper:

武昭旭, 杨岸, 祝龙记. 一种新的电能质量扰动识别方法[J]. 重庆工商大学学报(自然科学版), 2021, 38(5): 49—54

WU Z X, YANG A, ZHU L J. A New Method for Identifying Power Quality Disturbances[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2021, 38(5): 49—54