

一种新的基于深度置信网络的 电能质量扰动分类方法

王 康, 席燕辉, 胡 康

(长沙理工大学电气与信息工程学院, 湖南 长沙 410114)

摘 要: 针对在噪声干扰下多重扰动识别正确率不高的问题, 提出一种新的基于深度置信网络的电能质量扰动分类方法。首先, 对电能质量扰动信号进行平稳小波多尺度变换, 再利用软阈值函数处理估计小波系数重构原始信号, 从而实现对电能质量扰动信号的去噪。再利用软阈值函数处理估计小波系数重构原始信号, 从而实现对电能质量扰动信号的去噪。然后进一步提出利用深度置信网络对重构后的单一扰动信号和多重扰动信号进行分类识别。最后算例显示, 即使在 20 dB 噪声干扰下, 其分类正确率高达 93% 以上。结果表明该方法对 7 种单一扰动和 13 种多重扰动信号的识别正确率均较高, 验证该方法具有较强的抗噪声干扰能力。

关 键 词: 电能质量; 扰动识别; 软阈值函数; 深度置信网络

DOI: 10.19781/j.issn.1673-9140.2023.01.020 中图分类号: TM743 文章编号: 1673-9140(2023)01-0171-07

A novel classification method for power quality disturbance based on deep belief network

WANG Kang, XI Yanhui, HU Kang

(School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: Aiming at the problem that the recognition accuracy of multiple disturbances is not high under noise interference, a new classification method of power quality disturbances based on deep belief network is proposed. Firstly, the stationary wavelet multi-scale transformation is performed on the power quality disturbance signal, and then the soft threshold function is used to process the estimated wavelet coefficients to reconstruct the original signal, thereby realizing the denoising of the power quality disturbance signal. Moreover, it is further proposed to use the deep belief network to classify and identify the reconstructed single disturbance signal and multiple disturbance signals. The calculation example shows that even under the interference of 20 dB noise, the classification accuracy rate is as high as 93%. The results show that the recognition accuracy of the method is high for 7 kinds of single disturbance and 13 kinds of multiple disturbance signals, which verifies that the method has strong anti-noise interference ability.

Key words: power quality; disturbance recognition; soft threshold function; deep belief network

收稿日期: 2021-05-06; 修回日期: 2021-06-04

基金项目: 国家自然科学基金(51507015, 61673388); 湖南省自然科学基金(2018JJ2439); 湖南省教育厅优秀青年项目(18B130)

通信作者: 席燕辉(1979—), 女, 博士, 副教授, 主要从事复杂系统建模研究; E-mail: xiyanhui@126.com

近些年,迅速发展的信息与工业社会对用电量要求日益增高,随着冲击性和非线性的负荷比例不断增加,使得电能质量扰动问题受到各界关注,同时严重影响了电力系统的安全稳定运行,因此解决电能质量问题迫在眉睫,而对电能质量扰动进行快速精准分类是解决这一问题非常关键的一环^[1-2]。但是在实际应用中,电能质量扰动通常都是由不同类型、不同幅度和不同持续时间的单个干扰组成的多重电能质量扰动,通常还会伴随着噪声的干扰,这无疑对扰动的正确识别造成更大的困难,因此如何去除实际应用中扰动信号的噪声影响的同时,实现对多重扰动正确识别将对解决电能质量问题具有深远意义。

迄今为止,国内外许多学者对电能质量扰动分类进行深入研究,大多都是针对单一扰动质量分类。但在实际电网中,往往是多个单一扰动相互作用,组合形成多重扰动,其特征量相互耦合,使得多重扰动的识别变得更加困难和复杂。传统的扰动识别方法往往包括特征提取和分类。其中特征提取主要是通过变换和重构扰动信号,再从中获取扰动识别的特征量。目前提取特征常用的方法包括S变换、小波变换、傅里叶变换和希尔伯特-黄变换等^[3-6]。而如今用到的扰动识别方法有贝叶斯分类器、支持向量机、决策树、多标签学习、k近邻算法和人工神经网络等^[7-11]。目前,相关学者已经对单一电能质量扰动和少数的多重电能扰动分类进行了大量工作。文献[12]提出了一种基于交叉小波变换的Fischer线性判别方法来对多个电能质量扰动进行分类;文献[13]提出了一种简单有效的方法,该方法使用S变换幅度矩阵和基于规则的决策树来检测具有不同噪声水平的复杂电能质量扰动;文献[14]提出了一种利用压缩感知理论获取稀疏向量来提取信号特征再通过深度置信网络进行训练,仿真结果对5种双重扰动和2种三重扰动进行识别,但分类正确率只能达到92%左右。

针对实际电网中噪声干扰下的多重扰动(例如三重和四重干扰)分类正确率低的问题,本文提出了一种结合小波变换^[15]和深度置信网络^[16](deep belief network, DBN)的多重扰动识别方法。该方法通过小波变换重构信号波形来保留原始多重扰

动信号中的关键有效特征,然后利用深度置信网络对重构后的扰动信号进行分类。为验证本文所提方法的有效性,以7种单一扰动和13种多重扰动为例进行了仿真分析,仿真结果表明了本文提出的基于深度网络的多重扰动分类方法在不同的噪声情况下均具有较好的鲁棒性,且识别正确率较高。

1 基于小波变换的深度置信网络识别方法

1.1 小波软阈值去噪原理

在电能质量扰动识别过程中通常会受到噪声的影响,其中的噪声多为高斯白噪声。利用小波分解受到噪声污染的电能质量信号时,有用信号和噪声的小波系数拥有不同的特征,分别表现在不同尺度上,在较大和较小的系数上分别分布着有用信号和噪声的能量。从这个特点可知,量化处理小波系数^[17]就可以完成信号的去噪。

设实际情况下一维的非平稳信号模型为

$$x(t) = f(t) + \varepsilon(t) \quad (1)$$

式中, $f(t)$ 为原始信号; $\varepsilon(t)$ 为高斯白噪声; $x(t)$ 为含噪信号。对 $x(t)$ 进行离散小波变换^[18]为

$$\int x(t) \phi_{j,k}(t) dt = \int f(t) \phi_{j,k}(t) dt + \int \varepsilon(t) \phi_{j,k}(t) dt \quad (2)$$

式中, $\phi_{j,k}(t)$ 为离散小波基函数。式(2)可表示为

$$d_{j,k} = u_{j,k} + e_{j,k} \quad (3)$$

式中, $d_{j,k}$ 为包含噪声的信号; $x(t)$ 为经过小波变换后的各层小波系数; $u_{j,k}$ 为原始信号 $f(t)$ 的小波变换系数; $e_{j,k}$ 为噪声信号 $\varepsilon(t)$ 的小波变换系数。

根据统计这些有显著特点的有用信号和噪声小波系数,对其进行分析研究就可以得到一个合适的数 λ 作为阈值^[19],其中小于阈值的小波系数可认为是由噪声导致了该系数,应该去除这部分系数;而大于阈值的小波系数可认为主要是由有用信号引起了此系数,保留这些系数或按固定量收缩这些系数向零靠近,从而达到去噪的目的。小波阈值去噪的关键就是阈值的大小与阈值函数的选择,其中前者会影响去噪效果,当阈值过大,则会损失部分有用信号;当阈值过小,则会保留较多噪声,而后者

是修正小波系数的规则,会直接影响重构信号^[20]的高频信息及其平滑性。本文采用的是软阈值函数^[21]去噪,其中小波分解采用的小波基为 *coif5*^[22],软阈值函数为

$$d'_{j,k} = \begin{cases} \text{sgn}(d_{j,k})(|d_{j,k}| - \lambda), & |d_{j,k}| > \lambda \\ 0, & |d_{j,k}| < \lambda \end{cases} \quad (4)$$

式中, $d'_{j,k}$ 为软阈值量化处理后的各层小波系数; λ 为通用阈值, $\lambda = \sigma \sqrt{2 \ln N}$; N 为信号长度; σ 为噪声标准差。

本文以暂降信号为例,其采集的总数据点为 1 024 个,总时长为 0.16 s,频率为 50 Hz,总共有 8 个周期,选取信噪比(SNR)为 20 dB,进行软阈值去噪实验,仿真结果如图 1、2 所示。

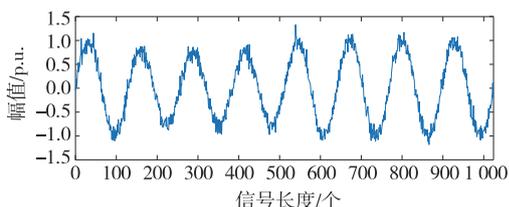


图 1 20 dB 噪声干扰的信号

Figure 1 20 dB noise interfering signal

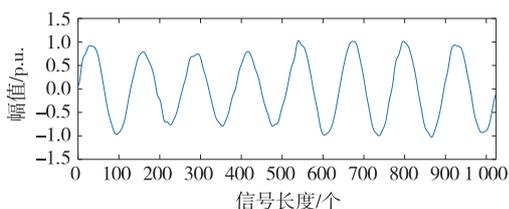


图 2 小波软阈值去噪信号

Figure 2 Wavelet soft threshold denoising signal

1.2 深度置信神经网络(DBN)

DBN是由若干层的受限波尔兹曼机和一层BP组成的一种深度神经网络,其中RBM包含可见层和隐藏层2个层,共同组成的一个概率图模型^[23-25],通过权值连接可见层和隐含层的神经元,一般来说,先利用可见层单元去描述数据的特征,然后通过隐藏层单元对特征进行提取。假设 m 为可见层包含神经元的数目, $\mathbf{v} = (v_1, v_2, \dots, v_m)^T$ 为可见层的状态向量, $\mathbf{a} = (a_1, a_2, \dots, a_m)^T$ 为可见层的偏置向量,其中 n 为隐藏层包含神经元的数目, $\mathbf{h} = (h_1, h_2, \dots, h_n)^T$ 表示为隐藏层的状态向量, $\mathbf{b} = (b_1, b_2, \dots, b_n)^T$ 为隐藏层的偏置向量,可见层单元 i 连接隐藏层单元 j 之间权重设为 w_{ij} 。RBM模型如图3所示。

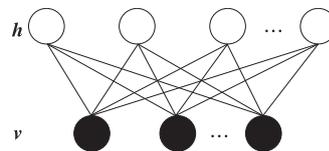


图 3 RBM模型

Figure 3 RBM model

对于一组给定的状态 (\mathbf{v}, \mathbf{h}) ,RBM系统的能量为

$$E(\mathbf{v}, \mathbf{h}) = -\sum_{i=1}^m \sum_{j=1}^n v_i w_{ij} h_j - \sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j \quad (5)$$

可见层与隐藏层在这组状态中的联合概率分布为

$$p(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} e^{-E(\mathbf{v}, \mathbf{h})} \quad (6)$$

式中, Z 为归一化系数,定义为

$$Z = \sum_{\mathbf{v}, \mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})} \quad (7)$$

RBM层层之间都是全连接,层内之间是未连接的,当可见层的神经元与隐藏层的神经元任意一方被给定状态时,则另一方将会被激活,且满足条件独立。由此可以得到激活隐藏层神经元的概率为

$$p(h_j = 1 | \mathbf{v}) = \sigma\left(\sum_{i=1}^m v_i w_{ij} + b_j\right) \quad (8)$$

可见层神经元被激活的概率为

$$p(v_j = 1 | \mathbf{h}) = \sigma\left(\sum_{j=1}^n w_{ij} h_j + a_i\right) \quad (9)$$

式中, σ 为 Sigmoid 激活函数,即

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (10)$$

本文使用的DBN是由三层RBM和一层BP神经网络组成。三层RBM进行无监督的特征学习,独立训练各层RBM,通过由低到高的逐层训练,直至完成DBN中所有RBM层的训练。最后一层连接上BP神经网络,然后通过后向传播算法与类别标签数据来微调DBN。

2 算法仿真与分析

2.1 电能质量扰动模型

为方便进行对比和分析,根据IEEE电能质量标准,对暂升(swell)、中断(interruption)、暂降

(sag)、短时谐波(harmonic)、短时振荡(oscillatory transient)、脉冲(impulse)、电压闪变(flicker)等7种典型扰动信号分别进行构造,其数学表达式如表1所示。

表1 7种单一的电能质量扰动模型

Table 1 Seven single power quality disturbance models

扰动类型	模型	参数
暂升(C ₁)	$\{1+a[u(t-t_1)-u(t-t_2)]\}\sin(\omega_0 t)$	$a=0.1\sim 0.9$ $T<t_1-t_2<8T$
中断(C ₂)	$\{1-a[u(t-t_1)-u(t-t_2)]\}\sin(\omega_0 t)$	$a=0.9\sim 1.0$ $T<t_1-t_2<8T$
暂降(C ₃)	$\{1-a[u(t-t_1)-u(t-t_2)]\}\sin(\omega_0 t)$	$a=0.1\sim 0.9$ $T<t_1-t_2<8T$
谐波(C ₄)	$\sin(\omega_0 t)+a_1\sin(3\omega_0 t)+a_2\sin(5\omega_0 t)+a_3\sin(7\omega_0 t)$	$a_1=0.02\sim 1.00$ $a_2=0.02\sim 1.00$ $a_3=0.02\sim 1.00$
振荡(C ₅)	$\sin(\omega_0 t)+a\exp[-(t-t_1)]\cdot\sin\omega_n(t-t_1)[u(t-t_1)-u(t-t_2)]$	$\omega_n=(10\sim 16)\omega_0$ $a=0.1\sim 0.8$ $0.5T<t_1-t_2<3T$
脉冲(C ₆)	$\sin(\omega_0 t)=a[u(t-t_1)-u(t-t_2)]$	$a=1\sim 3$ $t_1-t_2=1\sim 3\text{ ms}$
波动(C ₇)	$(1+a\sin(b\omega_0 t))\sin(\omega_0 t)$	$a=0.1\sim 0.2$ $b=0.1\sim 0.5$

根据实际工况,本文生成上述7类单一扰动以及由上述7种单一扰动在表1各时间段叠加的13类多重扰动,每一类1 800组样本数据,其中训练样本数据为1 000组,剩下的800组作为测试样本数据。其中单一扰动和多重扰动依据不同信噪比噪声的干扰分别对网络进行训练。

2.2 网络参数设置

设置深度置信网络输入为1 024个数据点,输出层是K维,即K类扰动的输出,选用sigmoid激活函数。单一和多重电能质量扰动的DBN层次结构分别采用200-100-100和1 000-100-50。其中,DBN无监督学习阶段的迭代次数为200次,学习率为0.1。监督学习阶段的迭代次数为200次,采用的算法为梯度下降。

2.3 扰动识别仿真实例

2.3.1 单一扰动

针对7类典型的单一扰动,考虑到实际工况含有噪声干扰,特以对抗扰动信号施加信噪比为20 dB

的噪声进行干扰为例,然后对噪声干扰情况下的扰动进行小波变换重构。同时,为了检验本文所提方法的抗噪能力,再分别对各种不同信噪比(40、30、20 dB)干扰的扰动信号进行测试。其训练样本和测试样本均为在各种噪声下通过小波变换重构处理后的数据集,如图2所示的20 dB噪声下的暂降信号通过小波变换重构处理,总共1 024个数据点,分别为7 000×1 024训练数据集和5 600×1 024的测试数据集,最后再把数据集放到深度置信网络中分别进行训练和测试。其分类测试结果如表2所示。

表2 训练数据在单一扰动下的测试分类正确率

Table 2 Classification accuracy when training data is disturbed under single disturbance %

扰动类型	不同噪声(dB)干扰下的测试分类正确率/%			
	无噪声	40	30	20
C ₁	100.00	100.00	100.00	100.00
C ₂	100.00	100.00	100.00	100.00
C ₃	92.50	86.50	89.00	100.00
C ₄	100.00	100.00	100.00	100.00
C ₅	98.50	100.00	100.00	100.00
C ₆	100.00	100.00	100.00	98.00
C ₇	100.00	100.00	100.00	100.00
平均正确率	98.71	98.07	98.42	99.71

由表2可知,对于典型的7类单一扰动,在不同噪声条件下的分类正确率均超过98%,因此,所提出的方法具有较高的分类能力,并且受噪声的影响较小。此外,表2的最高分类正确率为99.71%,可以看出当测试数据的噪声水平与训练数据的噪声水平相同时,所提出的方法可获得最佳性能。而且,当测试数据的噪声水平越接近训练数据的噪声水平时,性能会变得越好,此识别分类过程具有一定的创新性且识别正确率均较高。

2.3.2 多重扰动

由于实际工况中,扰动往往是多类扰动同时发生。为此,针对13类典型的多重扰动进行了分类,其训练样本和测试样本分别为13 000×1 024训练数据集和10 400×1 024的测试数据集均已通过小波变换重构处理。特以对抗扰动信号施加信噪比为20 dB的噪声进行干扰为例,然后对噪声干扰情况下的扰动进行小波变换重构。同时,为了检验本文

所提方法的抗噪能力,其分类测试结果如表 3 所示。

由表 3 可知,多重扰动的分类正确率也均超过 95%,和单一扰动的效果基本一致,表 2 的最高分类正确率为 99.65%。并且,当测试数据的噪声水平与训练数据相同时,所提出的方法可获得最佳性能。而当测试数据的噪声水平接近训练数据的噪声水平时,性能会变得更好,此识别分类过程具有一定的创新性且识别正确率均较高。

表 3 训练数据在多重扰动下的测试分类正确率

Table 3 Classification accuracy when training data is disturbed under multiple perturbations %

扰动类型	不同噪声(dB)干扰下的测试分类正确率			
	无噪声	40	30	20
C ₂ +C ₄	100.00	100.00	100.00	100.00
C ₁ +C ₄	100.00	100.00	100.00	100.00
C ₃ +C ₅	94.50	100.00	100.00	100.00
C ₆ +C ₄	100.00	100.00	100.00	100.00
C ₅ +C ₄	84.50	100.00	100.00	100.00
C ₇ +C ₄	100.00	100.00	100.00	99.50
C ₅ +C ₆	97.50	100.00	100.00	100.00
C ₇ +C ₆	66.00	100.00	100.00	98.50
C ₇ +C ₅	97.00	100.00	100.00	100.00
C ₄ +C ₅ +C ₆	100.00	100.00	100.00	100.00
C ₄ +C ₆ +C ₇	100.00	88.50	93.50	97.50
C ₅ +C ₆ +C ₇	99.00	100.00	100.00	100.00
C ₁ +C ₅ +C ₆ +C ₇	99.50	100.00	100.00	100.00
平均正确率	95.23	99.12	99.50	99.65

2.4 扰动识别精度对比

为了验证本文方法的有效性,其分类结果与文献[1]的分类结果进行对比,如表 4、5 所示。其中文献[1]中采用的是压缩感知提取信号特征然后再结合 BP 神经网络进行训练。

表 4 单一扰动分类正确率对比

Table 4 Comparison of classification accuracy under single disturbance %

方法	不同噪声(dB)干扰下的平均分类正确率			
	无噪声	40	30	20
文献[1]	99.43	98.86	98.57	96.43
20 dB	98.71	98.07	98.42	99.71
本文 30 dB	99.92	100.00	100.00	93.78
40 dB	99.92	100.00	100.00	93.14

表 5 多重扰动分类正确率对比

Table 5 Comparison of classification accuracy under multiple perturbations %

方法	不同噪声(dB)干扰下的平均分类正确率			
	无噪声	40	30	20
文献[1]	96.54	95.69	95.23	93.31
20 dB	95.23	99.12	99.50	99.65
本文 30 dB	96.34	99.76	99.88	98.76
40 dB	95.57	100.00	99.69	98.15

由表 4、5 可知,本文提出的方法比其他方法效果要好,特别是在高噪声下(20、30 dB)情况下单一扰动和其他方法分类正确率相当,而多重扰动识别效果相对明显,且在各种噪声(20、30、40 dB)影响下的识别正确率其最高准确性随着 SNR 的升高而有所升高。由比较结果表明,该分类方法对噪声具有较高的抗干扰性,可用于高噪声环境。特别说明一下,表 3、4 中,文献[1]未给出训练数据的噪声强度,本文方法对不同噪声强度(20、30、40 dB)训练数据进行了仿真验证。

3 结语

本文提出一种新的基于深度置信网络电能质量扰动分类方法。在此方法中,原始扰动信号由小波变换重构后并通过 DBN 进行分类识别,适用于对不同噪声水平污染后的单一和多重扰动识别。仿真对比分析结果表明,该分类方法即使在高噪声环境下,也具有较高的分类正确率,对噪声具有较好的鲁棒性。

参考文献:

[1] 曹思杨,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.

[2] 王仁明,汪宏阳,张赞宁,等.基于分段改进 S 变换和随机森林的复合电能质量扰动识别方法[J].电力系统保护与控制,2020,48(7):19-28.

- WANG Renming, WANG Hongyang, ZHANG Yunning, et al. Composite power quality disturbance recognition based on segmented modified S-transform and random forest[J]. Power System Protection and Control, 2020, 48(7):19-28.
- [3] 杨剑锋, 姜爽, 石戈戈. 基于分段改进S变换的复合电能质量扰动识别[J]. 电力系统保护与控制, 2019, 47(9):64-71.
- YANG Jianfeng, JIANG Shuang, SHI Gege. Classification of composite power quality disturbances based on piecewise-modified S transform[J]. Power System Protection and Control, 2019, 47(9):64-71.
- [4] 关维国, 姚清志, 高阳, 等. 基于db4小波的配电网暂态电能质量扰动的检测与定位[J]. 电力系统保护与控制, 2015, 43(8):102-106.
- GUAN Weiguo, YAO Qingzhi, GAO Yang, et al. Transient power quality detection and location of distribution network based on db4 wavelet transform[J]. Power System Protection and Control, 2015, 43(8):102-106.
- [5] 陈和洋, 郑文迪, 吴文宣. 采用直流分量恢复法的直流系统谐波分析[J]. 电测与仪表, 2021, 58(1):96-103.
- CHEN Heyang, ZHENG Wendi, WU Wenxuan. Harmonic analysis of DC system using DC component recovery method[J]. Electrical Measurement & Instrumentation, 2021, 58(1):96-103.
- [6] 张杨, 刘志刚. EEMD在电能质量扰动检测中的应用[J]. 电力自动化设备, 2011, 31(12):86-91.
- ZHANG Yang, LIU Zhigang. Application of EEMD in power quality disturbance detection[J]. Electric Power Automation Equipment, 2011, 31(12):86-91.
- [7] WU J F, LI Y Z, QUEVEDO D E, et al. Data-driven power control for state estimation: a bayesian inference approach [J]. Automatica, 2015, 54:332-339.
- [8] 赵洛印, 庄磊, 丁建顺, 等. 基于S&TT变换与PSO-SVMs的电能质量混合扰动识别[J]. 电测与仪表, 2020, 57(4):78-86.
- ZHAO Luoyin, ZHUANG Lei, DING Jianshun, et al. Identification of power quality hybrid disturbances based on S&TT transform and PSO-SVMs[J]. Electrical Measurement & Instrumentation, 2020, 57(4):78-86.
- [9] 马翔匀, 鲍颜红, 张金龙, 等. 基于支持向量机和决策函数的暂态稳定评估方法[J]. 电测与仪表, 2019, 56(23):48-53.
- MA Xiangyun, BAO Yanhong, ZHANG Jinlong, et al. Transient stability assessment based on support vector machine and decision function[J]. Electrical Measurement & Instrumentation, 2019, 56(23):48-53.
- [10] 张巧革, 刘志刚, 朱玲, 等. 基于多标签Rank-WSVM的复合电能质量扰动分类[J]. 中国电机工程学报, 2013, 33(28):114-120.
- ZHANG Qiaoge, LIU Zhigang, ZHU Ling, et al. Recognition of multiple power quality disturbances using multi-label wavelet support vector machine[J]. Proceedings of the CSEE, 2013, 33(28):114-120.
- [11] KUMAR R, SINGH B, SHAHANI D T, et al. Recognition of power-quality disturbance using S-transform-based ANN classifier and rule-based decision tree[J]. IEEE Transactions on Industry Applications, 2015, 51(2):1249-1258.
- [12] DALAI S, DEY D, CHATTERJEE B, et al. Cross-spectrum analysis-based scheme for multiple power quality disturbance sensing device[J]. IEEE Sensors Journal, 2015, 15(7):3989-3997.
- [13] KUBENDRAN A K, LOGANATHAN A K. Detection and classification of complex power quality disturbances using S-transform amplitude matrix-based decision tree for different noise levels[J]. International Transactions on Electrical Energy Systems, 2017, 27(4):e2286.
- [14] 陈伟, 何家欢, 裴喜平, 等. 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 Wei, HE Jiahuan, PEI Xiping, et al. Application of deep belief network in power quality compound disturbance identification[J]. Proceedings of the CSU-EPSA, 2018, 30(9):75-82.
- [15] 吴兆刚, 李唐兵, 姚建刚, 等. 基于小波变换和改进神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2014, 42(24):86-92.
- WU Zhaogang, LI Tangbing, YAO Jiangang, 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.
- [16] 马建, 陈克绪, 肖露欣, 等. 基于受限玻尔兹曼机的电能质量复合扰动识别[J]. 南昌大学学报(理科版), 2016, 40(1):30-34.
- MA Jian, CHEN Kexu, XIAO Luxin, et al. Classification on mixed disturbances of power quality based on restricted Boltzmann machine[J]. Journal of Nanchang University (Natural Science), 2016, 40(1):30-34.

- [17] 黄建招,谢建,高钦和,等.基于改进阈值的平移不变小波压力脉动去噪研究[J].机床与液压,2012,40(15):161-164+144.
HUANG Jianzhao,XIE Jian,GAO Qinhe,et al.Research of pressure fluctuation signal denoising based on translation invariance wavelet and improved threshold method[J].Machine Tool & Hydraulics,2012,40(15):161-164+144.
- [18] 邬春明,谢妮娜.改进的小波阈值在电能质量信号去噪中的应用[J].计算机工程与应用,2012,48(3):114-116.
WU Chunming,XIE Nina.Application of improved wavelet threshold in power quality signal denoising[J].Computer Engineering and Applications,2012,48(3):114-116.
- [19] 刘卫东,刘尚合,胡小锋,等.小波阈值去噪函数的改进方法分析[J].高电压技术,2007,33(10):59-63.
LIU Weidong,LIU Shanghe,HU Xiaofeng,et al.Analysis of modified methods of wavelet threshold de-noising function [J].High Voltage Engineering,2007,33(10):59-63.
- [20] 吴志宇,朱云芳,侯怡爽,等.电能质量扰动识别的小波压缩感知方法[J].电力系统及其自动化学报,2019,31(5):1-7.
WU Zhiyu,ZHU Yunfang,HOU Yishuang,et al.Power quality disturbance recognition method based on wavelet compressive sensing[J].Proceedings of the CSU-EPSA,2019,31(5):1-7.
- [21] 王维博,董蕊莹,曾文入,等.基于改进阈值和阈值函数的电能质量小波去噪方法[J].电工技术学报,2019,34(2):409-418.
WANG Weibo,DONG Ruiying,ZENG Wenru,et al. A wavelet de-noising method for power quality based on an improved threshold and threshold function[J].Transactions of China Electrotechnical Society,2019,34(2):409-418.
- [22] 王宏伟,荣航,孙朋.Coif5小波在煤岩声发射源定位中的应用研究[J].计算机工程与应用,2014,50(23):215-219.
WANG Hongwei,RONG Hang,SUN Peng. Research on application of Coif5 wavelet to locate acoustic emission source in coal-rock[J]. Computer Engineering and Applications,2014,50(23):215-219.
- [23] 朱云芳,吴志,高岩,等.多尺度稀疏的电能质量扰动深度识别方法[J].西南交通大学学报,2020,55(1):18-26.
ZHU Yunfang,WU Zhiyu,GAO Yan,et al. Recognition method for multi-scale sparse power quality disturbance [J]. Journal of Southwest Jiaotong University,2020,55(1):18-26.
- [24] 李丹奇,梅飞,张宸宇,等.基于深度置信网络的电压暂降特征提取及源辨识方法[J].电力系统自动化,2020,44(4):150-1158.
LI Danqi,MEI Fei,ZHANG Chenyu,et al. Deep belief network based method for feature extraction and source identification of voltage sag[J]. Automation of Electric Power Systems,2020,44(4):150-158.
- [25] 徐春华,陈克绪,马建,等.基于深度置信网络的电力负荷识别[J].电工技术学报,2019,34(19):4135-4142.
XU Chunhua,CHEN Kexu,MA Jian,et al. Recognition of power loads based on deep belief network[J].Transactions of China Electrotechnical Society,2019,34(19):4135-4142.