

DOI: 10.7667/PSPC160189

一种新的电能质量扰动信号压缩感知识别方法

曹思扬¹, 戴朝华^{1,2}, 朱云芳^{1,2}, 陈维荣^{1,2}

(1. 西南交通大学电气工程学院, 四川 成都 610031;
2. 国家轨道交通电气化与自动化工程技术研究中心, 四川 成都 610031)

摘要: 针对现有电能质量扰动信号识别方法存在数据量大、准确率不高的不足, 提出了一种基于压缩感知稀疏向量特征提取的电能质量扰动信号分类识别方法。该方法首先针对原始信号, 利用压缩感知理论获取降维的测量信号, 并基于 ℓ_1 范数正交匹配追踪算法获取稀疏向量。然后针对稀疏向量提取最大值、次大值、均方根、标准差、峭度和裕度因子等特征, 作为神经网络的输入, 实现电能质量扰动信号的分类识别。最后, 针对六类典型电能质量扰动信号, 开展仿真实验验证。仿真结果表明, 现有识别方法需要处理的原始信号长度为1024, 而所提方法特征提取时所处理的数据长度仅有30, 从而大大减少了所需处理的数据量, 并且由于实现了以非常少的数据量保存原有全部有用特征信息, 因而更有利于提高识别准确率。通过与广泛采用的小波变换识别方法进行比较, 所提方法的平均准确率高达98.71%, 远远高于小波变换方法的92.86%。

关键词: 电能质量; 压缩感知; 神经网络; 稀疏向量; 扰动识别

A novel compressed sensing-based recognition method for power quality disturbance signals

CAO Siyang¹, DAI Chaohua^{1,2}, ZHU Yunfang^{1,2}, CHEN Weirong^{1,2}

(1. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China; 2. National Engineering & Technology Research Center of Electrification and Automation in Rail Transit, Chengdu 610031, China)

Abstract: In view of the large amount of data and low accuracy rate of the existing power quality disturbance signal recognition methods, a new recognition method of power quality disturbance signals is proposed by extracting the features from compressed sensing sparse vectors. In this method, the original signals are sampled to obtain the measurement signals based on the theory of compressive sensing, and the sparse vectors are obtained by the orthogonal matching pursuit algorithm of ℓ_1 -minimization. Then the features of the maximum, the second maximum, root mean square, standard deviation, kurtosis and margin factor are extracted as the inputs of the neural networks, and the power quality disturbance signal recognitions are realized. According to 6 kinds of typical power quality disturbance signals, the simulation experiments are conducted. The simulation results show that the data size of the proposed recognition method for feature extraction is greatly reduced with only 30 instead of 1024 for the existing methods. As a result of the realization of a very small amount of data to retain the original all useful feature information, the proposed method is more promising to improve the recognition accuracy. Compared with the widely-used wavelet transform recognition method, the average accuracy rate of this proposed method is as high as 98.71%, which is much higher than 92.86% of the wavelet transform method.

This work is supported by National Natural Science Foundation of China (No. 51307144).

Key words: power quality; compressed sensing; neural network; sparse vector; disturbance recognition

0 引言

随着科学技术的进步和社会发展, 大量的电力电子设备和非线性负载接入电网中, 使得电能质量

问题日益突出, 而用户对电能质量的要求却越来越高, 因此, 电能质量信号检测与分析受到越来越多的关注, 其中电能质量扰动信号的分类识别是改善电能质量问题的重要基础^[1-2]。

目前国内外有大量的学者对电能质量扰动信号的识别进行分析与研究, 现有方法主要有傅里叶变

换^[3]、小波变换^[4]、S变换^[5]等。其中,文献[6]通过短时傅里叶变换,从二维频谱幅值中提取特征向量从而实现电能质量信号扰动识别,但其对于非平稳信号不具有时间局部性,不能满足时频分析要求;文献[7]通过对电能质量扰动信号进行小波分解,从各层小波分解系数中提取特征,进行扰动信号识别,但是小波本身易受噪声影响。总之,以上特征提取的方法都是建立在 Nyquist 采样定理的基础上,采样频率要求在其电能质量扰动信号频率的两倍以上,从而采集到大量电能质量的数据,提高了电能质量扰动信号分析与识别的复杂性^[8]。

近年来,压缩感知(Compressed Sensing, CS)理论^[9-10]将采样与压缩合并进行,通过远低于 Nyquist 采样频率的标准进行数据采样压缩,获得少量数据,就能通过相应的重构算法重构信号,在信号检测与分析领域得到了高度重视。文献[11]中将压缩感知理论应用于电能质量扰动信号识别中,并验证了压缩感知在电能质量扰动信号识别中应用的可行性;文献[12]中提出一种通过随机矩阵降维映射特征来提取电能质量扰动稀疏表示多分类方法,实现了电能质量扰动信号的检测识别。文献[13]通过二维树复小波提取扰动信号特征,代入稀疏表示分类器中实现了对四类瞬时扰动信号的分类识别。

本文提出一种基于压缩感知稀疏向量提取特征作为神经网络输入的电能质量扰动信号识别新方法,并通过仿真实验验证了所提方法的有效性。

1 压缩感知原理

由 Donoho 等^[9]在 2006 年提出的压缩感知,也称压缩传感、压缩采样,其对于稀疏或者可压缩信号突破了传统的 Nyquist 采样定律。该理论认为:如果一维信号 $X_{N \times 1}$ 在稀疏域 Ψ 是 K -稀疏的 ($K \ll N$),则采用一个与稀疏域 Ψ 非相干的观测矩阵 $\Phi_{M \times N}$ ($M \ll N$),对信号执行压缩观测(这里 Φ 的每一行都可以被当作是一个传感器)。

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

式中, $\Theta = \Phi \Psi$, 称之为传感矩阵。得到观测值 $Y_{M \times 1}$, 则通过求解如下 l_0 -范数优化问题,就可以高概率地重构原信号 $\hat{X} = \Psi \hat{S}$ 。

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

式中: $\|S\|_0$ 为 S 的 0 范数; Φ 为测量矩阵; Ψ 为稀疏矩阵; \hat{S} 为待求的稀疏向量。

1.1 稀疏性

信号的稀疏性,可以理解为信号在时域或者存在一个变换域使得信号中只有少数的非 0 元素,剩

下的绝大多数元素为 0 或者很小。其公式为

$$X = \Psi S \quad (3)$$

式中, S 中仅有 K ($K \ll N$) 个不为零的值,满足公式(3)的信号 X 为 K -稀疏的。

电能质量信号的稀疏性是应用压缩感知理论于电能质量扰动信号分类识别的基础,一般的电能质量信号通过傅里叶变换,即可达到稀疏性的效果。本文通过比较傅里叶变换、小波变换、离散余弦变换对电压暂降信号稀疏变换的效果(图 1),可以看出,傅里叶变换基稀疏效果最好,故本文选取傅里叶变换作为稀疏基,这也是目前应用最广泛的稀疏基。

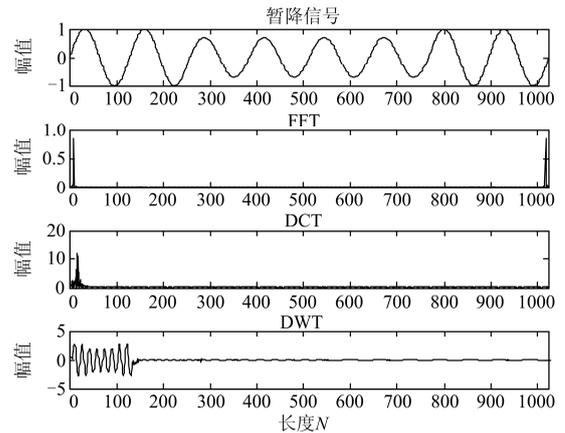


图 1 信号稀疏表示对比图

Fig. 1 Contrast diagrams of the signal sparse representations

1.2 测量矩阵

测量矩阵 Φ , 是用来对 N 维的原始信号 X 进行观测投影成低维度的观测信号 Y 。测量矩阵 Φ 一般是一个 $M \times N$ 矩阵, 为了让得到的观测信号 Y 中的 M 个值能够有效保留原信号 X 中的信息, 测量矩阵 Φ 需要满足受限等距特性准则(Restricted Isometry Property, RIP)^[14], 即存在一个约束等距常数 $\delta_k \in (0, 1)$, 使式(4)对任意 K -稀疏信号都成立。

$$(1 - \delta_k) \|X\|_2^2 \leq \|\Phi X\|_2^2 \leq (1 + \delta_k) \|X\|_2^2 \quad (4)$$

目前, 测量矩阵一般采用高斯随机矩阵、随机伯努利矩阵等具有一致分布的随机矩阵, 但这类矩阵计算复杂度高, 硬件实现困难, 难以适用于实际工程。本文在结构化原理的基础上^[15], 从易实现、低复杂度出发, 构造了一个稀疏循环结构化矩阵: 1) 产生 $1 \times N$ 零向量 A_0 , 以及一个 $N \times N$ 只含 ± 1 的随机对角矩阵 R ; 2) 在 A_0 中随机赋值 K 个 1 值 ($K \ll N$), 得到了一个 0-1 稀疏矩阵, 再通过向右循环位移 c 位构成 0-1 稀疏循环矩阵 A ; 3) 将得到的矩阵 A 右乘上随机对角结构化矩阵 R , 得到了稀疏循环结构化矩阵 $\Phi_{M \times N} = AR$ 。

1.3 重构算法

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 和稀疏基 Ψ 来恢复原始信号 X , 这是一个解压缩的过程, 其与传统信号采样解压缩过程不同, 如图 2 所示。

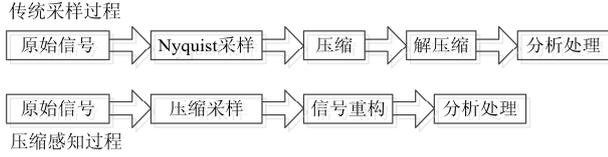


图 2 数据采样框图

Fig. 2 Block diagrams of data sampling

通过式(2)求解稀疏向量是一个 ℓ_0 范数求解的过程, 而 ℓ_0 范数求解本身是一个 NP 难问题^[16], 故通常将其转换为 ℓ_1 范数, 变成求解一个凸优化问题, 其数学模型为

$$\hat{S} = \arg \min \|S\|_1 \quad (\text{s.t. } Y = \Phi\Psi X) \quad (5)$$

本文选取正交匹配追踪算法(OMP)^[17]来解决上式的凸优化问题, 从而实现压缩采样信号的精确重构。

1.4 压缩采样算例

以电压暂降信号为例, 其时长为 0.16 s, 频率为 50 Hz, 共 8 个周期, 1024 个数据点, 选取压缩率(M/N)为 25%, 进行压缩采样与重构实验, 仿真结果如图 3 所示。

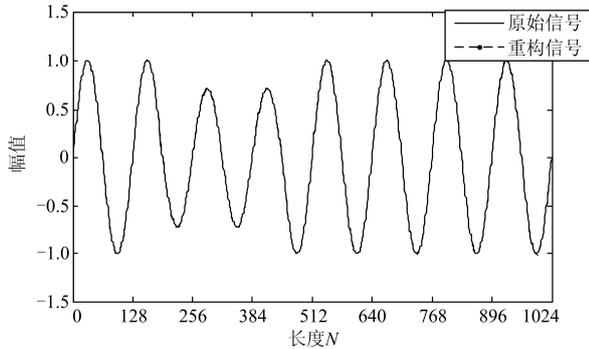


图 3 压缩感知重构对比图

Fig. 3 Contrast diagram of compressed sensing reconstruction

利用均方误差百分值(MSE)和重构信噪比(SNR)来评价重构效果的指标。

$$E_{\text{MSE}} = \sqrt{\frac{\sum_{i=1}^N |x(i) - \hat{x}(i)|^2}{\sum_{i=1}^N |x(i)|^2}} \times 100\% \quad (6)$$

$$R_{\text{SNR}} = 10 \lg \left[\frac{\sum_{i=1}^N |x(i)|^2}{\sum_{i=1}^N |x(i) - \hat{x}(i)|^2} \right] \quad (7)$$

式中, $x(i)$ 和 $\hat{x}(i)$ 分别为原始信号和压缩采样后的重构信号。本次实验中, 均方误差百分值为 0.90%,

重构信噪比为 40.96 dB, 再结合图 3 的曲线对比, 充分体现了压缩感知重构恢复原始信号的准确性。

2 电能质量扰动识别方法

2.1 识别方法原理

压缩感知理论表明^[14], 当传感矩阵满足 RIP 准则时, 其得到的稀疏向量可以保留原始信号的相应特征, 并可以从稀疏向量精确重构出原始信号。而稀疏向量 S 的维数 $K \ll N$; 也就是说, K 维稀疏向量 S 保留了 N 维原始信号 X 的所有有用特征, 且信息量更集中。有理由相信, 基于特征更集中的信号进行分类识别, 要优于特征分散的信号。因此, 不同于传统方法, 基于 K -稀疏向量 S 提取特征, 作为神经网络输入, 提出一种新的压缩感知电能质量扰动信号识别方法, 其流程图如图 4 所示, 其中左边箭头表示训练过程, 右边箭头为测试过程。

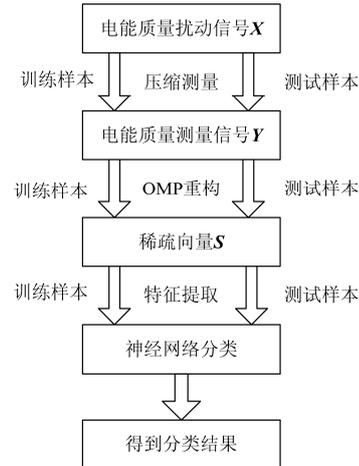


图 4 电能质量扰动信号识别流程图

Fig. 4 Flow chart of power quality disturbance signal recognition

2.2 特征提取

由于选取的稀疏基为傅里叶基, 故在通过正交匹配追踪算法恢复出来的稀疏向量 S 中存在 K 对共轭复数($s(i)=a \pm bj, i=1, 2, \dots, K$), 并且保留着原有信号的相关特征。故在提取特征前, 先对稀疏向量 S 进行求模值处理, 并且去除共轭复数中的另一半的模值, 从大到小排列, 组成新的 K -稀疏向量 S' 。然后, 基于得到的新向量 S' 进行特征提取。本文选取以下六类特征: 最大值 T_{MAX} 、次大值 T_{SEC} 、标准差 T_{STD} 、均方根 T_{RMS} 、峭度 T_{KU} 以及裕度因子 T_{YU} 。

$$T_{\text{STD}} = \sqrt{\frac{\sum_{i=1}^K (s'(i) - \bar{s}')^2}{K}} \quad (8)$$

$$T_{\text{RMS}} = \sqrt{\sum_{i=1}^K s'(i)^2} / K \quad (9)$$

$$T_{\text{KU}} = \sum_{i=1}^K ((s'(i) - \bar{s}')^4 / T_{\text{STD}}) / K \quad (10)$$

$$T_{\text{YU}} = K^2 (T_{\text{MAX}} - T_{\text{MIN}}) / (\sum_{i=1}^K \sqrt{s'(i)})^2 \quad (11)$$

式中, $s'(i)$, \bar{s}' , T_{MAX} , T_{MIN} 分别是稀疏向量 \mathbf{S}' 中的元素、平均值、最大值和最小值。

3 仿真实验分析

3.1 电能质量扰动信号模型

用于仿真验证的电能质量扰动信号包括: 电压暂降、电压暂升、电压中断、短时谐波、电压尖峰以及电压缺口等, 六类信号模型如表 1 所示。

表 1 电能质量扰动信号

Table 1 Power quality disturbance signals

信号类型	公式表达	参数范围
电压暂降	$f(t) = \begin{cases} \sin(2\pi ft), t \in [0, t_1] \cup [t_2, T] \\ a \sin(2\pi ft), t \in [t_1, t_2] \end{cases}$	$0.2 < a < 0.8$ $0.01 < t_2 - t_1 < 1.05$
电压暂升	$f(t) = \begin{cases} \sin(2\pi ft), t \in [0, t_1] \cup [t_2, T] \\ a \sin(2\pi ft), t \in [t_1, t_2] \end{cases}$	$1.2 < a < 1.8$ $0.01 < t_2 - t_1 < 1.05$
电压中断	$f(t) = \begin{cases} \sin(2\pi ft), t \in [0, t_1] \cup [t_2, T] \\ a \sin(2\pi ft), t \in [t_1, t_2] \end{cases}$	$0.00 < a < 0.1$ $0.01 < t_2 - t_1 < 1.05$
短时谐波	$f(t) = \begin{cases} \sin(2\pi ft), t \in [0, t_1] \cup [t_2, T] \\ \sum_{i=1,3,5,7} a_i \sin(2\pi i ft), t \in [t_1, t_2] \end{cases}$	$0.05 < a_i < 0.3$ $0.01 < t_2 - t_1 < 1.05$
电压尖峰	$f(t) = \sin(2\pi ft) - \text{sgn}(\sin(2\pi ft)) \cdot \sum_{i=0}^7 a[u(t-t_1-0.02i) - u(t-t_2-0.02i)]$	$0.3 < a < 0.4$ $0.0005 < t_2 - t_1 < 0.0006$
电压缺口	$f(t) = \sin(2\pi ft) + \text{sgn}(\sin(2\pi ft)) \cdot \sum_{i=0}^7 a[u(t-t_1-0.02i) - u(t-t_2-0.02i)]$	$0.3 < a < 0.4$ $0.0005 < t_2 - t_1 < 0.0006$
正常电压	$f(t) = \sin(2\pi ft)$	--

为了模拟实际情况, 针对表 1 的每类信号模型, 对其参数在一个允许的范围内随机变化(如扰动起止时间、扰动持续时间与幅值等), 得到六类扰动信号以及正常信号各 600 个样本, 每个样本的数据长度 N 为 1024 点, 随机选取每类样本中的 500 个作为训练样本, 剩下的 100 个作为测试样本。

3.2 仿真参数

采用三层 BP 神经网络作为分类器, 其中隐层选取 S 型传递函数(logsig), 输出层选取线性传递函数(purelin), 性能函数选择均方误差(MSE), 训练次数(Epoch)设为 1000 次, 隐层节点神经元数目通过实验分析比较最终选取为 30 个, 输入维数为 6 维, 输出维数为 7 维, 分别把电压暂升、电压暂降、电压中断、短时谐波、电压尖峰、电压缺口以及正常信号的训练输出设置为 $(1\ 0\ 0\ 0\ 0\ 0\ 0)^T$, $(0\ 1\ 0\ 0\ 0\ 0\ 0)^T$, $(0\ 0\ 1\ 0\ 0\ 0\ 0)^T$, $(0\ 0\ 0\ 1\ 0\ 0\ 0)^T$, $(0\ 0\ 0\ 0\ 1\ 0\ 0)^T$, $(0\ 0\ 0\ 0\ 0\ 1\ 0)^T$, $(0\ 0\ 0\ 0\ 0\ 0\ 1)^T$, 采用竞争输出机制进行训练测试。

3.3 结果分析

为了便于比较, 同时将文献[7]中四层小波分解的小波系数能量与系数熵作为特征代入到 BP 神经网络里进行训练分类。本文方法和文献[7]的特征提取方法的神经网络训练误差收敛曲线如图 5 所示, 测试结果如表 2 所示。从图 5 中可以看出, 本文方法一开始迭代误差就下降明显, 并且在迭代 50 次以内误差就达到了 0.01, 最后逐渐收敛稳定在 0.005 左右, 而文献[7]方法虽然也在 100 次以内将误差减小到 0.02, 但在接下来的迭代中误差减小不明显, 最终稳定在 0.019 左右。故可知本文方法无论是神经网络训练性能的速度还是精度都要明显高于文献[7]方法。从表 2 可知, 本文方法的平均识别率高达 98.71%, 而文献[7]方法仅为 92.86%。同时, 文献[7]中的特征提取方法无法准确实现电压暂降和电压中断的分类, 其识别准确率分别仅为 86%和 70%, 而本文方法的识别准确率则有明显提高, 分别达到 99%和 98%。

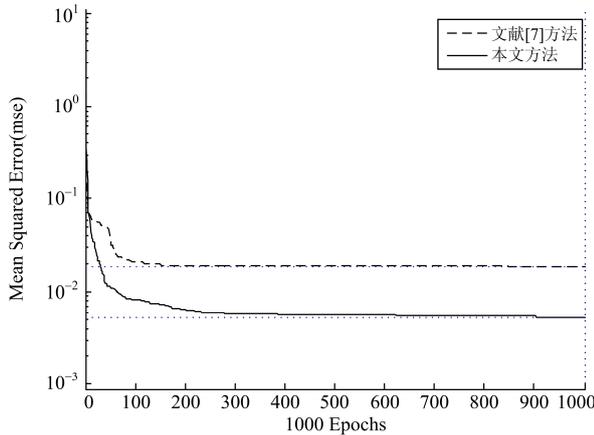


图 5 训练性能对比图

Fig. 5 Comparison chart of training performances

表 2 不同方法的识别率

Table 2 Recognition rate of different methods

信号类型	本文方法	文献[7]方法
电压暂降	99%	86%
电压暂升	99%	96%
电压中断	98%	70%
短时谐波	98%	100%
电压尖峰	99%	99%
电压缺口	98%	99%
正常电压	100%	100%
平均	98.71%	92.86%

考虑到实际情况中的噪声污染问题, 分别在扰动信号中加入 40 dB, 30 dB, 20 dB 的高斯白噪声进行扰动识别。从表 3 中可以看出, 本文方法在 40 dB 与 30 dB 噪声的环境下, 平均的分类精度有一定的下降, 但是下降并不明显, 仍保持在 96% 以上, 充分体现本文的方法具有稳健性以及一定的抗噪性。在 20 dB 的情况下, 电压暂降、电压暂升、电压中断、短时谐波的识别准确率比前面两种噪声情况下的有所下降, 但电压尖峰与电压缺口的识别准确率是大幅下降的, 造成这种情况的主要原因是电压尖峰与电压缺口信号本身就是正常电压情况下的一个较小的暂态抖动, 在噪声比较严重的情况下, 出现了噪声与扰动特征重叠的情况, 导致在神经网络分类的时候难以把这几类电能质量信号相互识别出来。但是, 就不同信噪比下的识别率而言, 本文方法仍然总体优于文献[7]方法。

表 3 不同信噪比下的识别率

Table 3 Recognition rate under different signal-to-noise ratio

信号类型	信噪比		
	40 dB	30 dB	20 dB
电压暂降	99%(87%)	94%(77%)	92%(71%)
电压暂升	99%(96%)	98%(94%)	96%(95%)
电压中断	98%(68%)	97%(74%)	96%(71%)
短时谐波	99%(100%)	96%(100%)	90%(95%)
电压尖峰	99%(99%)	94%(99%)	77%(97%)
电压缺口	97%(99%)	94%(93%)	73%(90%)
正常电压	100%(100%)	100%(100%)	89%(80%)
平均	98.7%(92.7%)	96.1%(91.0%)	87.6%(85.6)

注: 括号内为文献[7]方法在各噪声环境下的识别率。

4 结论

本文提出了一种新的电能质量扰动信号压缩感知识别方法。该方法通过压缩感知算法获取保留原始电能质量扰动信号的 K -稀疏向量 \mathbf{S} , 再提取稀疏向量的数理统计特征, 代入到 BP 神经网络中进行训练学习, 进而实现电能质量扰动信号的分类识别。本文方法特征提取时通过处理长度仅为 30 的稀疏向量替代长度为 1024 的原始信号, 从而大大减轻了特征提取时所需处理的数据量, 从六类典型电能质量扰动信号仿真实验中, 可知该方法在无噪声的环境下识别率高达 98.71%, 在 30 dB 与 40 dB 的噪声环境下仍达到 96% 以上, 表明本文所提方法的有效性, 为电能质量扰动信号提供了一种新的分类识别方法, 具有较好的参考价值。

参考文献

- [1] 张逸, 林焱, 吴丹岳. 电能质量监测系统研究现状及发展趋势[J]. 电力系统保护与控制, 2015, 43(2): 138-147.
ZHANG Yi, LIN Yan, WU Danyue. Current status and development trend of power quality monitoring system[J]. Power System Protection and Control, 2015, 43(2): 138-147.
- [2] 贾清泉, 于连富, 王宁, 等. 原子稀疏分解算法在电力系统扰动信号分析中的应用[J]. 电力系统保护与控制, 2010, 38(19): 17-21.
JIA Qingquan, YU Lianfu, WANG Ning, et al. Application of atomic sparse decomposition to power systems disturbance analysis[J]. Power System Protection and Control, 2010, 38(19): 17-21.
- [3] WEN H, GUO S, TENG Z, et al. Frequency estimation of distorted and noisy signals in power systems by

- FFT-based approach[J]. IEEE Transactions on Power Systems, 2014, 29(2): 765-774.
- [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] 王宇, 赵庆生, 郭贺宏, 等. 离散正交 S 变换在电能质量扰动检测中的应用[J]. 电力系统保护与控制, 2015, 43(17): 93-97.
WANG Yu, ZHAO Qingsheng, GUO Hehong, et al. Application of discrete orthonormal S-transform in detection of power quality disturbances[J]. Power System Protection and Control, 2015, 43(17): 93-97.
- [6] 徐永海, 赵燕. 基于短时傅里叶变换的电能质量扰动识别与采用奇异值分解的扰动时间定位[J]. 电网技术, 2011, 35(8): 174-180.
XU Yonghai, ZHAO Yan. Identification of power quality disturbance based on short-term Fourier transform and disturbance time orientation by singular value decomposition[J]. Power System Technology, 2011, 35(8): 174-180.
- [7] 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, 42(24): 86-92.
WU Zhaogang, LI Tangbing, YAO Jiangan, 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.
- [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 Yunfang, DAI Chaohua, CHEN Weirong, et al. Present status and prospect on compressed sensing in power systems[J]. Proceedings of the CSU-EPSA, 2015, 27(1): 80-85.
- [9] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [10] CANDÈ E J, WAKIN M B. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 21-30.
- [11] 王学伟, 王琳, 苗桂君, 等. 暂态和短时电能质量扰动信号压缩采样与重构方法[J]. 电网技术, 2012, 36(3): 191-196.
WANG Xuwei, WANG Lin, MIAO Guijun, et al. An approach for compressive sampling and reconstruction of transient and short-time power quality disturbance signals[J]. Power System Technology, 2012, 36(3): 191-196.
- [12] 沈跃, 刘国海, 刘慧. 随机降维映射稀疏表示的电能质量扰动多分类研究[J]. 仪器仪表学报, 2011, 32(6): 1371-1376.
SHEN Yue, LIU Guohai, LIU Hui. Study on classification method of power quality disturbances based on random dimensionality reduction projection and sparse representation[J]. Chinese Journal of Scientific Instrument, 2011, 32(6): 1371-1376.
- [13] CHAKRABORTY S, CHATTERJEE A, GOSWAMI S K. A sparse representation based approach for recognition of power system transients[J]. Engineering Applications of Artificial Intelligence, 2014, 30(3): 137-144.
- [14] ALDROUBI A, CHEN X, POWELL A M. Perturbations of measurement matrices and dictionaries in compressed sensing[J]. Applied & Computational Harmonic Analysis, 2012, 33(2): 282-291.
- [15] DO T T, GAN L, NGUYEN N H, et al. Fast and efficient compressive sensing using structurally random matrices[J]. IEEE Transactions on Signal Processing, 2011, 60(1): 139-154.
- [16] JOHN W, YANG A Y, ARVIND G, et al. Robust face recognition via adaptive sparse representation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 44(12): 2368-2378.
- [17] BRUCKSTEIN A M, ELAD M. From sparse solutions of systems of equations to sparse modeling of signals and images[J]. Siam Review, 2009, 51(1): 34-81.

收稿日期: 2016-02-04; 修回日期: 2016-03-25

作者简介:

曹思扬(1991-), 男, 硕士研究生, 研究方向为电能质量, 压缩感知等; E-mail: cao163_@163.com

戴朝华(1973-), 男, 通信作者, 博士, 副教授, 研究方向为智能电网规划与运行优化、电能质量、智能信息处理等。E-mail: daichaohua@swjtu.edu.cn

(编辑 魏小丽)