

DOI: 10.13382/j.jemi.2017.12.018

# 带标签信息子字典级联学习的复合电能质量扰动识别方法\*

刘 慧<sup>1</sup> 李光武<sup>1</sup> 沈 跃<sup>1</sup> 滕成龙<sup>2</sup>

(1. 江苏大学 电气信息工程学院 镇江 212013; 2. 镇江市产品质量监督检验中心 镇江 212132)

**摘 要:**针对传统字典学习方法的训练样本信号单一、重构效果差等缺点,提出一种带标签信息子字典级联的学习方法,对电能质量扰动信号进行扰动识别。该方法首先对不同类别电能质量扰动测试和训练样本采用主成分分析方法进行降维特征提取,对训练样本添加标签信息,其次对不同类别的电能质量样本训练成冗余子字典并级联成结构化学字典,最后将级联的字典优化学习并由冗余误差最小值来判断目标的归属类别。仿真实验结果表明,该方法下的识别效果优于支持向量机(SVM)和稀疏表达分类(SRC),抗噪声鲁棒性更强,在信噪比 20 dB 以上的环境中电能质量复合扰动识别率达到 91.40% 以上。

**关键词:** 标签信息;电能质量;子字典级联学习;特征提取

**中图分类号:** TN911.7; TM712 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Multiple power quality disturbances identification method with label information based on sub dictionary concatenate learning

Liu Hui<sup>1</sup> Li Guangwu<sup>1</sup> Shen Yue<sup>1</sup> Teng Chenglong<sup>2</sup>

(1. School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China;  
2. Zhenjiang Product Quality Supervision and Inspection Center, Zhenjiang 212132, China)

**Abstract:** Aiming at the drawbacks of traditional dictionary learning methods, such as single sample signal and poor reconstruction effect, a new approach of sub-dictionary concatenate learning (SDCL) with label information was proposed to identify the power quality disturbances (PQD) signal. Firstly, the different types of testing and training of the PQD signal samples are dimension reduced feature extraction with principal component analysis (PCA), add the label information to train samples, then the different categories of power quality samples are trained into redundant sub-dictionary and concatenated into structured dictionary. Finally, using dictionary learning algorithm to optimize the structured dictionary and the object class is determined through minimizing the redundant error. The simulation results show that the recognition effect of SDCL method is better than that of SVM and SRC, and has good anti-noise robustness, and the multiple PQD identification rate reaches above 91.4% in the noisy circumstance with the signal to noise ratio above 20 dB.

**Keywords:** label information; power quality; sub-dictionary concatenate learning; feature extraction

## 0 引 言

随着智能电网的快速发展和电力系统自动化水平的不断提高,各种冲击性的非线性负载的大量使用,导致的电能质量污染问题引起了人们的高度关注<sup>[1]</sup>。因此,深

入研究引起电能质量下降的各种因素,监测和分析电能质量潜在问题,对治理电能污染以及提高供电可靠性具有重要的实际意义。其中,电能质量的扰动识别是分析电能问题的一个热点,迄今为止有不少国内外学者进行了相关问题的深入研究,并且取得了较好的识别效果<sup>[2,3]</sup>。

收稿日期:2017-05 Received Date: 2017-05

\* 基金项目:国家自然科学基金(61301138)、江苏省博士后科研项目(1401053C)资助

以信号稀疏性为先验条件的压缩感知 (compressive sensing, CS) 理论<sup>[4-6]</sup>, 通过直接或间接的对信号进行稀疏表示。其中, 字典学习<sup>[7-8]</sup> (dictionary learning, DL) 为信号的稀疏性描述提供了方法, DL 通过优化相应的字典学习代价函数, 获得具有自适应稀疏编码的字典, 从而使得待处理信号能够高概率的被重构。目前, DL 已经广泛运用于图像处理 and 模式识别领域, 例如: Aharon 等人<sup>[9]</sup> 提出了 K-SVD (K-singular value decomposition) 算法, 通过奇异值分解, 将图像训练样本集学习到适合表示图像的过完备字典。

复合电能质量分类识别属于多标签<sup>[10]</sup> 范畴, 已经有不少学者将多标签分类运用到电能质量分类<sup>[11]</sup>, 主流思想是通过小波变换、S 变换<sup>[12]</sup> 等进行特征的提取, 然后通过神经网络、支持向量机 (SVM) 等分类器进行识别。文献<sup>[13]</sup> 提出一种判别字典学习的稀疏表示电能质量扰动识别方法, 相比于稀疏表达分类 (SRC)<sup>[14]</sup> 和 SVM<sup>[15]</sup> 具有更高的分类准确率, 更强的抗噪声鲁棒性。但上述研究大多针对理想单一的扰动, 而实际电能质量扰动往往是复杂多样的, 包含两种及两种以上单一扰动的复合、多种单一扰动的混合。因此, 寻找有效的电能质量特征提取方法是本文研究的一个重点。基于上述思想, 本文提出了一种带标签信息字典级联学习的复合电能质量扰动识别方法。把字典原子贴上标签信息, 在字典学习的过程中加入判别项, 最后级联学习获得一个结构化字典, 这样学习到的优化字典具有更强的扰动识别力, 不仅完对单一扰动的识别, 同时测试了该方法对复合电能质量扰动的识别, 为实际多分类复杂电能质量的多分类检测和分析提供了有效方法。

## 1 字典学习模型

CS 理论的核心思想就是利用信号的稀疏特性, 实现信号的低分辨率采样, 从而对信号进行精确的重构。CS 理论主要包括 3 部分: 信号的稀疏表示、观测矩阵的设计和重构算法的选择。字典学习的目的是用少量原子更好地表示原始训练样本, 其稀疏表示过程就是将测试样本表示为训练样本的稀疏线性组合。

假设  $K$  类电能质量扰动信号的训练样本集为,  $\mathbf{E} = [\mathbf{E}_1, \mathbf{E}_2, \dots, \mathbf{E}_k] \in \mathbf{R}^{M \times N}$  第  $i$  类训练样本集为  $\mathbf{E}_i$ , 训练样本集类别分别代表电压暂升, 电压暂降, 电压中断, 电压尖峰, 电压脉冲, 电压振荡, 电压谐波和电压缺口以及相应组合的复合信号构成, 对于标签信息的电能质量模型信号, 附加标签信息矩阵  $\mathbf{H} = [\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_k]$ , 其中  $M$  为采样点数,  $N$  为信号的长度, 经过 PCA 降维<sup>[16-17]</sup> 以后获得的特征矩阵为  $\mathbf{Y} = [\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_k] \in \mathbf{R}^{P \times N}$  其中  $P < M$ ,  $P$  表示降维的维数。选取降维后的特征训练样本的

部分原子作为初始字典  $\mathbf{D}_i$ , 每个特征原子作为作为初始冗余字典的每一列, 为了提高算法的运算效率, 对初始化的字典作归一化处理,  $\|\mathbf{D}_{ij}\|_2 = 1, i = 1, 2, \dots, k, j = 1, 2, \dots, q$ ,  $\mathbf{D}_{ij}$  作为字典的列向量, 于是级联之后的结构化字典  $\mathbf{D} = [\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k]$ ,  $q$  为初始化原子数。字典学习优化问题可以描述为:

$$\begin{aligned} J_{D,A} &= \operatorname{argmin} \{ \|\mathbf{Y}_i - \mathbf{D}_i \mathbf{A}_i\|_F^2 + \lambda_A \|\mathbf{A}\| \} \\ \text{s. t. } \|\mathbf{D}_{ij}\|_2^2 &= 1, i = 1, 2, \dots, k, j = 1, 2, \dots, q \end{aligned} \quad (1)$$

式中:  $\mathbf{D}_{ij}$  表示字典  $\mathbf{D}_i$  列向量,  $\lambda_A$  是平衡误差的正则化参数。在此基础上, 将字典级联之后获得的学习模型为:

$$J = \operatorname{argmin}_{D,W,A} \{ r_1(\mathbf{Y}, \mathbf{D}, \mathbf{A}) + r_2(\mathbf{H}, \mathbf{W}, \mathbf{A}) \} + \lambda \|\mathbf{A}\| \quad (2)$$

式中:  $r_1(\mathbf{Y}, \mathbf{D}, \mathbf{A})$  表示信号保真项,  $r_2(\mathbf{H}, \mathbf{W}, \mathbf{A})$  表示带标签信息线性分类器的识别保真项,  $\lambda$  为正则化参数。

### 1.1 信号保真项

信号保真项不仅对电能质量扰动信号的重构误差有着基本的约束力, 同时对编码的系数大小也有一定的限制。于是信号保真项如式(3)所示。

$$r_1(\mathbf{Y}, \mathbf{D}, \mathbf{A}) = \{ \|\mathbf{Y}_i - \mathbf{D} \mathbf{A}_i\|_F^2 + \|\mathbf{Y}_i - \mathbf{D}_i \mathbf{A}_i^i\|_F^2 + \mu \sum_{j=1, j \neq i} \|\mathbf{A}_i^j\|_F^2 \} + \lambda \|\mathbf{A}\| \quad (3)$$

式中:  $\lambda$  和  $\mu$  权衡误差参数,  $\|\mathbf{Y}_i - \mathbf{D} \mathbf{A}_i\|_F^2$  体现了字典要较好的重构出样本, 是字典学习要达到的基本指标。降维样本  $\mathbf{Y}_i$  在字典  $\mathbf{D}$  上的编码系数  $\mathbf{A}_i: \mathbf{A}_i = [\mathbf{A}_i^1, \mathbf{A}_i^2, \dots, \mathbf{A}_i^k]$ ,  $\mathbf{A}_i^j$  表示  $\mathbf{Y}_i$  在  $\mathbf{D}_j$  上的编码系数, 因此, 降维样本可以表示为  $\mathbf{Y}_i \approx \mathbf{D} \mathbf{A}_i = \mathbf{D}_1 \mathbf{A}_i^1 + \mathbf{D}_2 \mathbf{A}_i^2 + \dots + \mathbf{D}_k \mathbf{A}_i^k$ , 训练样本  $\mathbf{Y}$  的稀疏编码系数  $\mathbf{A}$  可以表示  $\mathbf{A} = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_k]$ 。重构误差的识别准则要求训练样本  $\mathbf{Y}_i$  能够被  $\mathbf{D}_i$  很好的表示, 而  $\mathbf{D}_j (i \neq j)$  不能很好的重构  $\mathbf{Y}_i$ 。因此,  $\mathbf{Y}_i - \mathbf{D}_i \mathbf{A}_i^i$  就体现了子训练样本能够  $\mathbf{Y}_i$  能够被  $\mathbf{D}_i$  很好的表示。 $\mu \sum_{j=1, j \neq i} \|\mathbf{A}_i^j\|_F^2$  表明子训练样本  $\mathbf{Y}_i$  在其他字典  $\mathbf{D}_j (i \neq j)$  上的表示系数很小。 $\lambda \|\mathbf{A}\|$  体现了编码的稀疏性。

### 1.2 识别保真项

本文将多标签引入到复合电能质量扰动识别, 即复合信号可以由两种及以上的单一信号对应的标签信息组成。传统的多标签分类方法旨在对每个样本确定或者随机的分配一个标签, 这种方法会在样本训练的时候导致样本信息的丢失。为了使得识别的精度进一步的提高, 本文给降维的电能质量扰动信号添加了标签信息, 学习得到带标签信息的字典间接具有较强的识别能力。

对于降维的电能质量扰动样本, 其标签矩阵  $\mathbf{H}_i$ , 于是得到识别保真项如式(4)所示。

$$r_2(\mathbf{H}, \mathbf{W}, \mathbf{A}) = \gamma \|\mathbf{H}_i - \mathbf{W}\mathbf{A}_i\|_F^2 + \beta \|\mathbf{W}\|_F^2 \quad (4)$$

式中:  $\gamma, \beta$  是正则化参数,  $\mathbf{W}$  是线性分类器  $\mathbf{H} - \mathbf{W}\mathbf{A}$  的参数矩阵,  $\mathbf{H}$  为类别标签矩阵, 其每一列都是一个列向量  $\mathbf{H}_i = [0, 0, \dots, 1, \dots, 0, 0]$ , 其非零元素 1 的位置标志着类别信息, 这样编码系数  $\mathbf{A}$  和对应的类别标签矩阵  $\mathbf{H}$  就建立了一个线性分类器,  $\|\mathbf{H}_i - \mathbf{W}\mathbf{A}_i\|_F^2$  的值越小, 则表示该分类器的识别精度越高, 通过学习后该分类器对编码系数具有良好的识别力, 这样学习得到的线性分类器对最终的电能质量扰动识别具有良好的促进作用。

### 1.3 字典模型

于是将式(3)和(4)联合起来就得到式(5)的字典学习模型:

$$J = \underset{\mathbf{D}, \mathbf{W}, \mathbf{A}}{\operatorname{argmin}} \{ \|\mathbf{Y}_i - \mathbf{D}\mathbf{A}_i\|_F^2 + \|\mathbf{Y}_i - \mathbf{D}_i\mathbf{A}'_i\|_F^2 + \mu \sum_{j=1, j \neq i} \|\mathbf{A}'_j\|_F^2 + \gamma \|\mathbf{H}_i + \mathbf{W}\mathbf{A}_i\|_F^2 + \beta \|\mathbf{W}\|_F^2 \} + \lambda \|\mathbf{A}\|_1$$

s. t.  $\|\mathbf{D}_{ij}\|_2^2 = 1, i = 1, 2, \dots, k, j = 1, 2, \dots, q \quad (5)$

由于式(5)中字典迭代会有 3 个变量, 对于目标函数的优化, 可以设置  $\mathbf{Y}' = (\frac{\mathbf{Y}}{\sqrt{\gamma\mathbf{H}}})$ ,  $\mathbf{D}' = (\frac{\mathbf{D}}{\sqrt{\gamma\mathbf{W}}})$ , 则式(5)可以进一步转化为式(6)的模型。

$$J = \underset{\mathbf{D}', \mathbf{A}'}{\operatorname{argmin}} \sum_{i=1}^k \{ \|\mathbf{Y}'_i - \mathbf{D}'\mathbf{A}'_i\|_F^2 + \|\mathbf{Y}'_i - \mathbf{D}'_i\mathbf{A}'_i\|_F^2 + \mu \sum_{j=1, j \neq i} \|\mathbf{A}'_j\|_F^2 + \gamma \|\mathbf{H}_i + \mathbf{W}\mathbf{A}_i\|_F^2 + \beta \|\mathbf{W}\|_F^2 \} + \lambda \|\mathbf{A}\|_1$$

s. t.  $\|\mathbf{D}'_{ij}\|_2^2 = 1, i = 1, 2, \dots, k, j = 1, 2, \dots, q \quad (6)$

式中:  $\mu$  和  $\lambda$  式正则化参数, 是权衡误差的常量, 由于  $\mathbf{D}'$  做了归一化处理,  $\|\mathbf{W}\|_F^2$  就可以直接省略。通过上述换元, 将降维训练样本  $\mathbf{Y}$  转化为带标签信息的样本  $\mathbf{Y}'$ , 将字典  $\mathbf{D}$  转化为带线性分类器参数的字典  $\mathbf{D}'$ , 这样就将 3 个变量  $\mathbf{D}$ 、 $\mathbf{A}$ 、 $\mathbf{W}$  转变为两个变量  $\mathbf{D}'$ 、 $\mathbf{A}'$ , 提高了字典求解的效率。

同 K-SVD 字典训练算法思想一样, 运用奇异值分解法进行字典的更行与迭代, 算法分为稀疏编码和字典更行。所以字典训练算法的流程如图 1 所示。

上述算法的具体步骤描述如下:

1) 初始化级联字典  $\mathbf{D}'$ , 由字典训练算法学习得到的子字典, 设置初始迭代次数  $t$ 、迭代总次数  $s$  和迭代的阈值  $J_s$ , 目标函数为  $J$ 。

2) 固定字典  $\mathbf{D}'$  更新系数  $\mathbf{A}' = [\mathbf{A}'_1, \mathbf{A}'_2, \dots, \mathbf{A}'_k]$ , 稀疏系数按照各类别依次更新, 更新  $\mathbf{A}'_i$  时,  $\mathbf{A}'_j (i \neq j)$  保持不变则目标函数可以表示为:

$$J = \underset{\mathbf{A}'}{\operatorname{argmin}} \{ \|\mathbf{Y}'_i - \mathbf{D}'\mathbf{A}'_i\|_F^2 + \|\mathbf{Y}'_i - \mathbf{D}'_i\mathbf{A}'_i\|_F^2 + \mu \sum_{j=1, j \neq i} \|\mathbf{A}'_j\|_F^2 \} + \lambda \|\mathbf{A}'_i\|_1 \quad (7)$$

3) 固定  $\mathbf{A}'$  来更新字典  $\mathbf{D}' = [\mathbf{D}'_1, \mathbf{D}'_2, \dots, \mathbf{D}'_k]$ , 字典更新也按照各类别依次更新, 更新  $\mathbf{D}'_i$  时,  $\mathbf{D}'_j (i \neq j)$  保持不变, 则目标函数可以表示为:

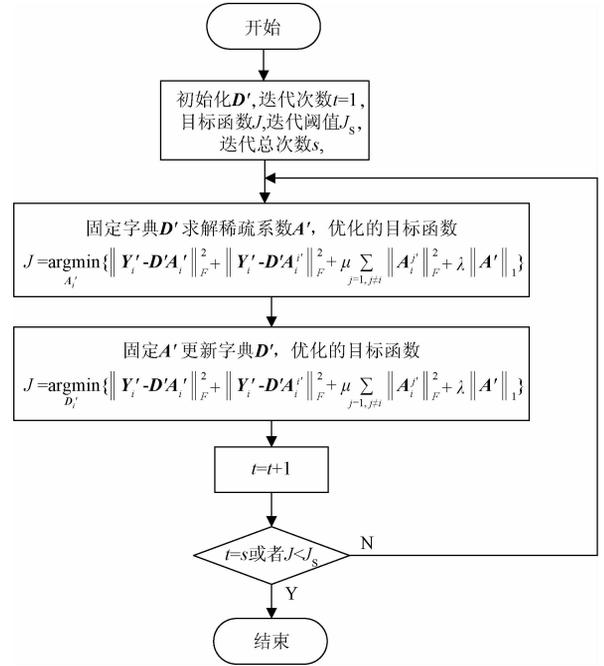


图 1 字典训练算法流程

Fig. 1 Flow chart of the dictionary training algorithm

$$J = \underset{\mathbf{D}'}{\operatorname{argmin}} \{ \|\mathbf{Y}'_i - \sum_{j=1, j \neq i}^k \mathbf{D}'_j \mathbf{A}'_j - \mathbf{D}'_i \mathbf{A}'_i\|_F^2 + \|\mathbf{Y}'_i - \mathbf{D}'_i \mathbf{A}'_i\|_F^2 \} \quad (8)$$

4) 若相邻两次迭代的误差达到设置的阈值  $J_s$ , 或者达到最大迭代次数  $s$ , 则停止算法的迭代, 直接输出字典  $\mathbf{D}'$ , 否则循环步骤 2)。

通过算法迭代得到的字典  $\mathbf{D}'$  后, 由于  $\mathbf{D}'$  通过字典  $\mathbf{D}$  和线性分类器参数  $\mathbf{W}$  组成  $\mathbf{D}' = (\frac{\mathbf{D}}{\sqrt{\gamma\mathbf{W}}})$ , 即  $\frac{\mathbf{D}_{ij}}{\sqrt{\gamma\mathbf{W}_{ij2}}} = 1$ 。 $\mathbf{D}'$  做了归一化处理, 所以要获得稀疏编码  $\hat{\mathbf{D}}$  和分类器参数  $\hat{\mathbf{W}}$ , 必须进行如下的数学处理  $\hat{\mathbf{D}} = \frac{\mathbf{D}_{ij}}{\|\mathbf{D}_{ij}\|}$ ,  $\hat{\mathbf{W}} = \frac{\mathbf{W}_{ij}}{\|\mathbf{W}_{ij}\|}$ 。

最后由冗余误差球的目标的归属类:

$$\operatorname{identity}(y) = \underset{y}{\operatorname{argmin}} \{ \|\mathbf{Y} - \hat{\mathbf{D}}\hat{\mathbf{A}}\| + \|\mathbf{H} - \hat{\mathbf{W}}\hat{\mathbf{A}}\| \} \quad (9)$$

## 2 电能质量扰动识别框架

一种带标签信息子字典级联学习的复合电能质量扰动识别方法, 其具体过程如图 2 所示电能质量扰动识别方法的框架图。

1) 首先建立多类别电能质量扰动信号模型,  $\mathbf{E} = [\mathbf{E}_1, \mathbf{E}_2, \dots, \mathbf{E}_k] \in \mathbf{R}^{M \times N}$ , 生成相应的训练样本集和测试样本集, 训练样本采用单一扰动信号, 测试样本采用复合

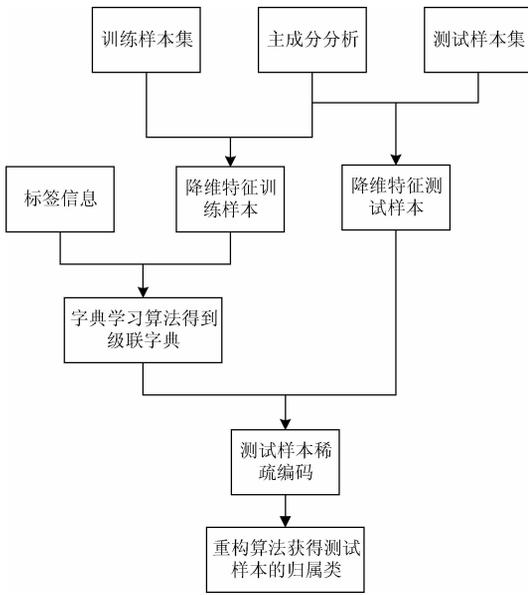


图2 电能质量扰动识别方法的框架

Fig.2 Frame of power quality disturbance identification method

扰动信号,其中  $k$  表示训练样本集的种类数,  $M$  为采样点数,  $N$  为信号的长度。

2) 对测试样本和训练样本集利用主成分分析 PCA 降维特征提取,并对训练样本贴入标签信息。

对于生成了的训练样本和测试样本,由于电能质量数据长度较大,需要对采样数据进行降维特征提取,并且对降维的数据分配标签信息,标签矩阵为  $\mathbf{H} = [\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_k]$ ,从而方便后面的字典优化,获得较高的识别率。

3) 利用字典学习算法对训练进行学习,获得级联的字典,让测试样本在级联字典下进行稀疏编码。

对于不同的单一扰动信号测试样本进行字典学习,获得相应的子字典,然后将子字典级联获得一个结构化字典,再利用奇异值分解的方法对结构化字典进行更新迭代,最后将复合测试样本进行稀疏编码。

4) 利用重构方法计算冗余残差来获得测试信号的归属类。

对每一类复合扰动信号利用正交匹配追踪算法进行重构,计算相应的冗余残余项,最终确定测试信号的归属类别。

### 3 仿真实验验证

#### 3.1 电能质量扰动信号的生成

单一的电能质量扰动信号主要有电压暂升、电压暂降、电压中断、电压尖峰、电压脉冲、电压振荡、电压谐波和电压缺口等。联想 Ideapad Y480 笔记本、i5-3210M、

2.5 GHz CPU, 4G DDR3 内存,运用 MATLAB 2013A 产生以上 8 类典型的电能质量扰动信号训练样本,采样频率是 1 600 Hz,每一类采样 10 个周期,数据长度为 320 个采样点。产生的 8 类典型电能质量扰动波形如图 3 所示。

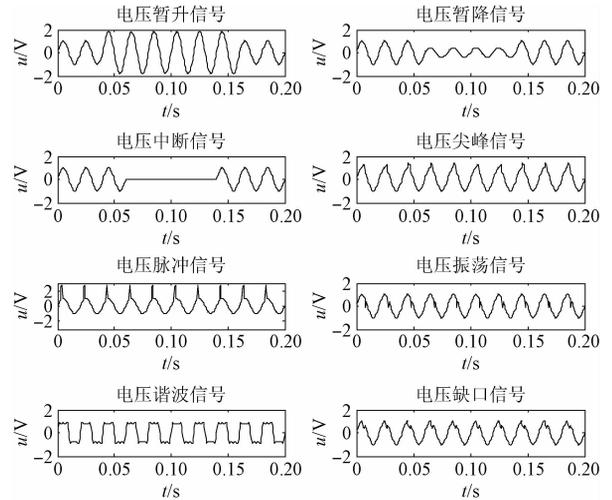


图3 8类单一电能质量扰动信号

Fig.3 8 types of single PQD signals

由上述单一信号组合得到的 8 类复合扰动信号的样本集为  $\mathbf{E} = [E_1, E_2, \dots, E_8]$ ,分别是暂升 & 谐波、暂降 & 谐波、中断 & 谐波、尖峰 & 谐波、脉冲 & 谐波、振荡 & 谐波、暂降 & 中断 & 谐波、暂升 & 中断 & 振荡 & 谐波。产生的 8 类电能质量扰动信号波形如图 4 所示。

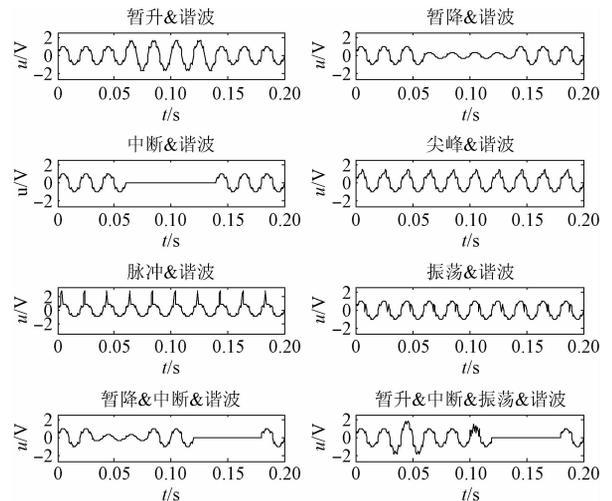


图4 8类复合电能质量扰动信号

Fig.4 8 types of multiple PQD signals

#### 3.2 降维维数的选取

目前用于分类的降维方式比较多样化,有随机高斯矩阵降维、线性判别式分析降维<sup>[18]</sup>、PCA 降维等,本文选取 PCA 降维方法来实现特征的提取。仿真实验以不同

类电能质量扰动信号进行降维维数的测试,通过 10 次 10 倍交叉验证法进行维数的估计,其中数据的产生依然运用上述基频 50 Hz,采样频率 1 600 Hz,每个周期是 32 个点,每类电能质量扰动信号选取 1 000 个数据,其中 900 作为训练样本,100 个作为测试样本,选取 10 ~ 150 的不同维数重复 10 次试验求出平均值,从而获得理想的降维维数。最终得到平均识别率随维数的关系(如图 5 所示)。

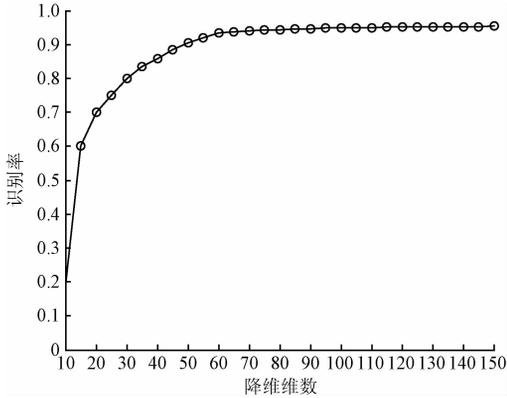


图 5 平均识别率与维数的关系

Fig.5 Relationship between the average identification rate and the dimension

由图 5 中平均识别率与维数关系曲线可以看出,识别率是随着降维维数的增加而逐渐的变高,当维数达到 50 以上时,识别率基本稳定在 90% 以上,在样本规模不大的条件下,考虑既能满足实际的识别精度要求,又能减少字典迭代的时间跨度,本实验选取维数为  $P = 60$ 。

### 3.3 实验验证

仿真试验对图 4 中的 8 类复合扰动信号进行采样,采样频率是 1 600 Hz 其中采样维数为 320,采样时,每一类含有训练样本数 500 个,则数据维度  $M = 320$ ,总训练样本数  $N = 4\ 000$ ,PCA 降维为  $P = 60$  维,获得的降维训练样本为  $Y = [Y_1, Y_2, \dots, Y_8]$ 。

对每一类训练样本贴上标签信息,于是得到的标签矩阵为  $H = [H_1, H_2, \dots, H_8]$ ,其中类别  $i$  为  $H_i = [0, 0, \dots, 1, \dots, 0]$ ,其中非零位置代表的元素代表的就是类别。运用字典训练算法分别训练各类别的冗余子字典,其中各个类别的初始原子数  $q = 20$ ,训练得到 8 个冗余子字典,于是级联的结构化字典为  $D = [D_1, D_2, \dots, D_8]$ 。再通过奇异值分解的方法进行字典的更新迭代,设置迭代阈值  $J_s = 0.005$ ,最大迭代次数  $s = 30$ ,初始化的迭代次数  $t = 1$ ,正则化参数  $\mu = 0.1$ ,  $\lambda = 0.1$ , $W$  是线性分类器的参数矩阵,通过标签矩阵和初始原子求出最优值获得,样本的归属类别最终通过残差最小来确定。

最终仿真实验得到的 8 类复合电能质量扰动信号重

构的测试样本与原信号的残差值如分别图 6 所示。其中用数字 1, 2, ..., 8 分别表示电压暂升、电压暂降、电压中断、电压尖峰、电压脉冲、电压振荡、电压谐波和电压缺口信号。可以看出 8 类复合电能质量扰动信号的残差值在相应的位置其残差值达到最小。

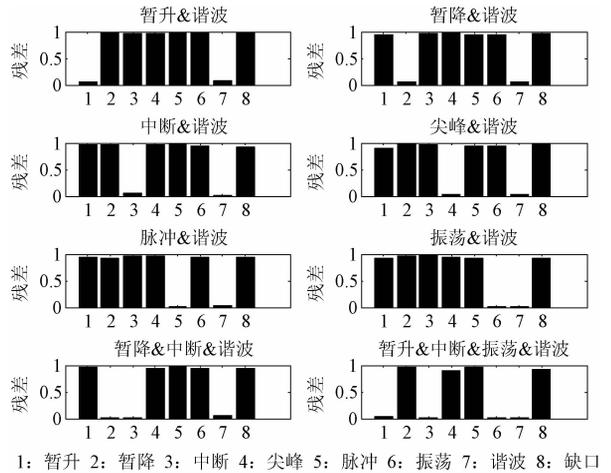


图 6 8 类复合电能质量扰动信号的残差

Fig.6 8 types of multiple PQD signals residual error

接下来采用 8 类扰动信号分别在 20、30、40 dB 信噪比的情况下进行扰动识别,得到平均识别率的如表 1 所示。可以看出在信噪比递增的情况下,信号的识别率呈现递增趋势,其中当信噪比在 20 dB 以上环境中,实验中测试的复合扰动信号的识别率都在 91.40% 以上,平均识别率达到 93.47%。

表 1 电能质量扰动信号在不同信噪比下的平均识别率

Tab 1 The average identification rate of signal under different PQD signal to noise ratio

扰动类型	识别率/%		
	20 dB	30 dB	40 dB
暂升 & 谐波	94.20	95.80	97.64
暂降 & 谐波	93.14	96.43	97.20
中断 & 谐波	94.80	95.93	97.12
尖峰 & 谐波	94.85	95.82	96.96
脉冲 & 谐波	93.25	95.60	97.35
振荡 & 谐波	93.94	94.62	96.75
暂降 & 中断 & 谐波	92.20	93.25	95.66
暂升 & 中断 & 振荡 & 谐波	91.40	92.85	93.54
平均识别率%	93.47	95.04	96.53

不同信噪比下单一电能质量扰动识别方法的结果比较如图 7 所示,可以看出本文的 SDCL 方法在

20、30、40 dB 和无噪声的环境下识别率略高于 SRC, 但明显优于 SVM, 同时具有对复合电能质量扰动识别的优势。

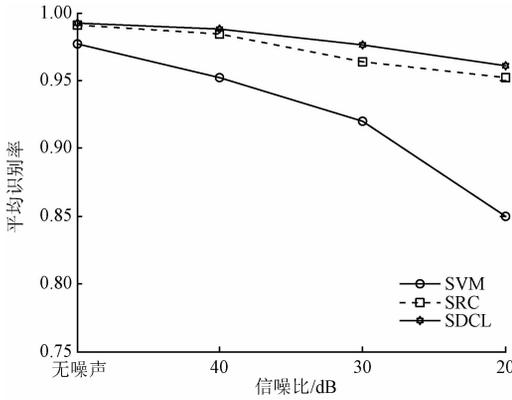


图7 不同信噪比下单一电能质量扰动识别方法结果比较

Fig. 7 Comparison of recognition results for single PQD identification methods under different signal to noise ratio

尽管上述实验模拟了复合电能质量扰动信号的识别, 为了使试验更具充分性, 采用了来自 IEEE 工作组 (<http://grouper.ieee.org/groups/1159/3>, 2016) 的实际电能质量数据, 对本文中的算法进行进一步验证。实验中采用缺口和脉冲、缺口和振荡的复合扰动信号, 如图 8 (a)、9(a) 所示, 经过降维特征提取, 获得图 8 (b)、9 (b) 所示, 最后计算残余项, 如图 8 (c)、9 (c) 所示的识别结果也表明了本算法的有效性。对不同扰动类型进行多次实验, 获得平均识别率如表 2 所示。

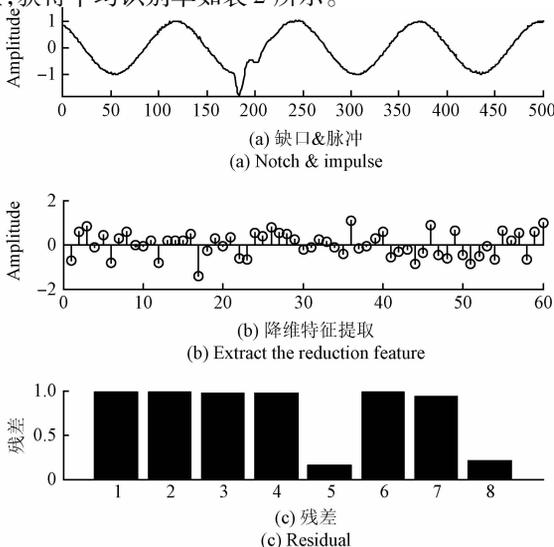
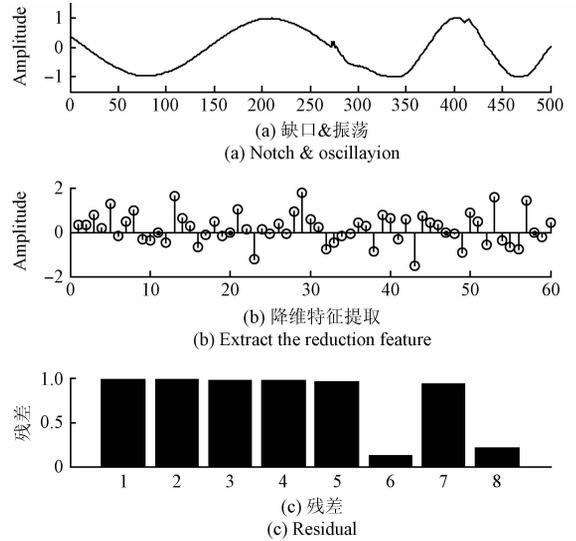


图8 缺口和脉冲电能质量扰动信号识别结果  
Fig. 8 Identification results of notch and impulsive PQD signal



1: 暂升 2: 暂降 3: 中断 4: 尖峰 5: 脉冲 6: 振荡 7: 谐波 8: 缺口

图9 缺口和振荡电能质量扰动信号识别结果

Fig. 9 Identification results of notch and oscillation PQD signal

表2 实际复合电能质量扰动信号的平均识别率  
Table 2 The average identification rate of signal under practical multiple PQD signal

扰动类型	缺口 & 振荡	缺口 & 脉冲	暂降 & 振荡	中断 & 振荡	中断 & 暂升
平均识别率/%	93.15	92.25	93.24	92.28	93.35

## 4 结论

本文在对单一电力系统电能质量扰动识别的基础上加入了复合信号的扰动识别, 首先通过 PCA 对各种类型的电能质量扰动样本进行降维特征提取并添加标签信息, 运用字典训练算法对子字典进行学习, 获得级联的结构化字典, 最后通过奇异值分解对字典进行优化并利用冗余误差最小值来获得目标的归属类。该方法在字典训练的过程中加入了与类别有关的标签信息, 相比于传统扰动识别方法, 不仅提高了识别的精度, 而且对复合扰动也具有比较好的识别效果。仿真实验结果表明, 本文方法下的识别效果优于 SVM 和 SRC, 抗噪声鲁棒性更强, 同时为电能质量复合扰动信号的识别提供了有效的途径。

## 参考文献

[ 1 ] BOLLEN M. What is power quality [J]. Electric Power Systems Research, 2003, 66(1) :5-14.  
[ 2 ] XIONG S C, XIA L, BU L P. An effective s-transform feature extraction method for classification of power

1: 暂升 2: 暂降 3: 中断 4: 尖峰 5: 脉冲 6: 振荡 7: 谐波 8: 缺口

- quality disturbance signals [C]. Chinese Automation Congress (CAC), 2015:1555-1560.
- [3] TULJAPURKAR M, DHARME A A. Wavelet based signal processing technique for classification of power quality disturbances[C]. Fifth International Conference on Signal and Image Processing (ICSIP 2014), 2014: 337-342.
- [4] CANDÈS J E, TAO T. Near-optimal signal recovery from random projections: Universal encoding strategies [J]. IEEE Transactions on Information Theory, 2006, 52(12):5406-5425.
- [5] DONOHO D L. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [6] 孙斌, 马春晖, 金心宇, 等. 传感器网络中基于压缩感知的压缩域目标跟踪算法研究与应用[J]. 电子测量与仪器学报, 2016, 30(11):1617-1625.
- SUN B, MA CH H, JIN X Y, et al. Research and application of target tracking algorithm based on compressed domain in wireless sensor network [J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(11):1617-1625.
- [7] YAGHOUBI M, BLUMENSATH T, DAVIES M E. Dictionary learning for sparse approximations with the majorization method [J]. IEEE Transactions on Signal Processing, 2009, 57(6): 2178-2191.
- [8] MAIRAL J, BACH F, PONCE J, et al. Online learning for matrix factorization and sparse coding [J]. Journal of Machine Learning Research, 2010, 11(1): 19-60.
- [9] AHARON M, ELAD M, BRUCKSTEIN A M. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54(11):4311-4322.
- [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 Q G, LIU ZH G, ZHU L, et al. Recognition of multiple power quality disturbances using multi-label wavelet support vector machine [J]. Proceeding of the CSEE, 2013, 33(28):114-120.
- [11] 周维维, 管春, 卢伟国. 基于多标签 RBF 神经网络的电能质量复合扰动分类方法 [J]. 电工技术学报, 2011, 26(8):198-204.
- ZHOU L W, GUAN CH, LU W G. Recognition of multiple power quality disturbances using multi-label RBF neural networks [J]. Transactions of China Electrotechnical Society, 2011, 26(8):198-204.
- [12] 叶明, 唐敦兵. 区域清晰度的小波变换图像融合算法研究 [J]. 电子测量与仪器学报, 2015, 29(9): 1328-1333.
- YE M, TANG D B. Image fusion algorithm based on wavelet transform and region image definition [J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(9):1328-1333.
- [13] 沈跃, 张瀚文, 刘国海, 等. 基于判别字典学习的电能质量扰动识别方法 [J]. 仪器仪表学报, 2015, 36(10): 2167-2173.
- SHEN Y, ZHANG H W, LIU G H, et al. Power quality disturbance identification method based on discriminative dictionary learning [J]. Chinese Journal of Scientific Instrument, 2015, 36(10): 2167-2173.
- [14] 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 Y, LIU G H, LIU H. 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.
- [15] 秦业, 袁海文, 袁海斌, 等. 基于优化最小二乘支持向量机的电能质量扰动分类 [J]. 电工技术学报, 2012, 27(8):209-214.
- QIN Y, YUAN H W, YUAN H B, et al. Classification of power quality disturbances based on optimized least squares support vector machine [J]. Transactions of China Electrotechnical Society, 2012, 27(8): 209-214.
- [16] NEDEVSCHI S, PETER I R, MANDRU A. PCA type algorithm applied in face recognition [C]. IEEE International Conference on Intelligent Computer Science and Automation Engineering (CSAE), 2012: 586-590.
- [17] LIAO P, LIU J, WANG M Y. Ensemble local fractional LDA for face recognition [C]. IEEE International Conference on Computer Science and Automation Engineering (CSAE), 2012: 586-590.
- [18] 翟旭平, 杨兵兵, 孟田. 基于 PCA 和混合核函数 QPSO-SVM 频谱感知算法 [J]. 电子测量技术, 2016, 39(9): 87-90.
- ZHAI X P, YANG B B, MENG T. Spectrum sensing based on PCA and QPSO-SVM with mixed kernel [J]. Electronic Measurement Technology, 2016, 39(9): 87-90.

## 作者简介



刘慧,2001年于江苏理工大学获得学士学位,分别在2004和2009年于江苏大学获得硕士学位和博士学位。现为江苏大学副教授,主要研究方向为电能质量检测与分析、农业信息化与自动化、生物医学信号处理等。

E-mail: amity@ujs.edu.cn

**Liu Hui** received B. Sc. from Jiangsu University of Science and Technology in 2001, and M. Sc. and Ph. D. both from Jiangsu University in 2004 and 2009, respectively. She is currently an associate professor and M. Sc. supervisor in School

of Electrical and Information, Jiangsu University. Her research interests include power quality analysis, agricultural information automation, and biomedical signal processing.



李光武,2015年于常州工学院获得学士学位,现为江苏大学硕士研究生,主要研究方向为电能质量检测与分析。

E-mail: wgllyg@163.com

**Li Guangwu** received B. Sc. from Changzhou Institute of Technology in 2015. Now he is a M. Sc. candidate in Jiangsu University. His main research interest is power quality detection and analysis.