

基于暂态电流的 S 变换与(2D)²PCA 的负荷识别

吕卫, 蔡志强, 褚晶辉*

天津大学电气自动化与信息工程学院, 天津 300072

摘要 针对用户家中电器负荷识别分解问题提出了一种新的特征提取方法。对总线电流进行小波滤波处理, 并根据周期差分的方法除去负荷暂态电流的背景电流, 获取负荷投切后的暂态电流信号。对负荷的暂态电流进行 S 变换获取幅值谐波矩阵, 并使用双向二维主成分分析[(2D)²PCA]对暂态电流的幅值谐波矩阵从行和列方向进行压缩以提取特征。使用支持向量机对样本特征集进行分类。对 BLUED 电力数据集的 6 种家用负荷进行识别, 平均识别率为 99.24%, 最高达到 100%。该方法与其他特征提取方法相比, 对电气特性相似的负荷具有更高的识别率。

关键词 信号处理; 暂态电流; S 变换; 双向二维主成分分析; 模式识别

中图分类号 TP391.42

文献标识码 A

doi: 10.3788/LOP55.080701

Load Identification Based on S-Transform and (2D)²PCA of Transient Current

Lü Wei, Cai Zhiqiang, Chu Jinghui*

School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China

Abstract For identification and decomposition of domestic appliance load, a new feature extraction method is proposed in this paper. First, we adopt wavelet filtering processing on the bus current and remove the background current from the load transient current by periodic difference. Then S-transform is used for the transient current after load switching to obtain an amplitude harmonic matrix. The matrix is dimensionally reduced and the corresponding features are extracted in the row and column directions by the bidirectional two-dimensional principal component analysis. Finally, the feature data is classified by the support vector machine. The experimental results indicate the proposed feature extraction method has an average recognition accuracy of 99.24% and a maximum recognition accuracy of 100% on six kinds of appliance from the BULED dataset. Especially, the proposed method can provide better performance on differentiating the loads with similar electrical characteristics.

Key words signal processing; transient current; S-transform; bidirectional two-dimensional principal component analysis; pattern recognition

OCIS codes 070.5010; 070.2025; 100.4995

1 引言

非侵入式负荷监测(NILM)技术通过对家庭用户电力入口总线的电力监测,实现家用工作电器的负荷分解,是近几年智能微网能源系统研究的热点^[1]。NILM本质是一个分类问题,对负荷的在线识别分类可以得知负荷运行的详细情况,进一步了解用户在该段时间内使用的各个电器的电能消耗。该信息可以提供给用户,形成一份类似于电话清单

的家用电器使用详情清单。用户根据这份清单可以合理规划电器的使用,节约用电。早在 20 世纪 80 年代, Hart^[2]就提出使用功率对负荷进行分解。1999 年, Drenker 等^[3]提取负荷稳态的有功、无功参量,通过计算变化量的方式提取特征。2006 年, Srinivasan 等^[4]从稳态电流谐波出发,对电流进行傅里叶变换,该方法虽然简单便捷,但对多态负荷的识别效果有限。2007 年, Lam 等^[5]根据电压电流曲线,提取描述负荷稳态工作下的电压电流轨迹指标作为

收稿日期: 2017-12-19; 修回日期: 2018-01-11; 录用日期: 2018-01-25

基金项目: 国家自然科学基金(61271069)

* E-mail: cjh@tju.edu.cn

特征,该方法对功率型负荷有较好的区分度。2010年,Gupta等^[6]从负荷的电压噪声出发,通过快速傅里叶变换提取频域特征。近两年来,娄建楼等^[7]通过拟合优化算法,针对功率实现多种负荷的在线分解,但不适用于低功率负荷的识别。孙毅等^[8]采用差量特征提取,通过模糊聚类识别负荷数量及种类。

通常非电阻型电器负荷的投切过程包含丰富的暂态电气信息,这种特征在暂态电流上表现尤为明显,因此负荷的暂态特征受到研究人员的关注。信号的时频域分析是一种有效研究信号特征的方式,且应用广泛^[9-10]。Cox等^[11]通过傅里叶变换提取负荷暂态电压的频域信息;Patel等^[12]对暂态电压噪声进行频谱分析;Saitoh等^[13]根据电流波形提取暂态电流的多维度波形特征。部分学者从负荷信号的时频域特征和谐波特征出发,对负荷进行识别。Martins等^[14]对电流进行S变换获取特征矩阵,通过计算模板数据库中负荷类型之间的最短距离对负荷进行分类,该方法直接使用S变换后的特征,因此计算过程较长且不能识别相似负荷。Lin等^[15]对暂态电流进行离散S变换,通过谐波幅值特征识别负荷,虽然能辨识功耗相近的负荷,但因提取暂态电流特征不充分导致识别准确率不高。Ahmadi等^[16]根据人脸识别的相关技术,将S变换后矩阵转化为图片,将对负荷的识别转化为对图片的分类问题。李雨轩^[17]提取暂态电流均值、方差等多维度波形特征对负荷进行识别。

S变换在局部时频域分析中的优势适用于对家用电器负荷暂态电流信号提取信息较丰富的谐波幅值特征。双向二维主成分分析 $[(2D)^2PCA]$ 是一种优秀的矩阵压缩算法,广泛应用于图像处理,特别是人脸识别中^[18]。针对上述方法不能较好反映家用电器负荷在投切过程中的暂态电流特征信息从而影响非侵入式负荷识别效果的问题,本文提出一种S变换和 $(2D)^2PCA$ 相结合的暂态电流特征提取方法,既能够提取暂态电流信号较全面的主要和局部细节特征,避免人工特征选择不充分的缺陷,又规避了S变换提取的幅值谐波矩阵维数较大的局限。对BLUED公开电力数据集中6类家用负荷进行负荷识别的结果表明,本文算法具备较高的负荷识别率,且对电气特性相似的负荷识别效果尤其明显。

2 暂态电流预处理

2.1 暂态电流小波分解与重构

非侵入式负荷识别的电力数据来源于安装在用户电路入口总线处的非侵入式设备,如智能电表等。

采集的数据中往往含有噪声,常见的噪声包括高斯白噪声以及设备自身在使用过程中产生的尖峰脉冲等。高斯白噪声由电器负荷或者非侵入式测量中的电流互感器产生,白噪声影响暂态事件监测和负荷识别算法的模型建立。为了尽可能降低噪声对后续算法研究的干扰,保证实验的可靠性,避免噪声幅值在多个负荷同时在线工作的情况下成倍增加,需要对总线电流进行去噪处理。另外一方面高频噪声通常也存在于负荷工作中,高频噪声与白噪声混合叠加会使电流信号变得更复杂,在这种情况下提取到的负荷特征必然不稳定。小波变换具有良好的时频局部化特性,小波分解可以减小或过滤若干细节系数^[19]。通过小波分析进行信号重构可以恢复得到接近原始电流的信号。图1和图2为总线电流信号经过5层小波分解与重构前后的电流波形。

2.2 背景电流去除

家庭用户电路入口总线处的非侵入式设备采集到的电流为各个支路上工作的电器负荷工作电流的总和。 I 表示电路总线电流, I_j 为用户家中第 j 个负荷的工作电流。则总线电流模型为

$$I = \alpha_1 I_1 + \alpha_2 I_2 + \dots + \alpha_j I_j, \quad (1)$$

式中: α_j 表示第 j 个电器负荷的开关系数, $\alpha_j = 1$ 表示该负荷处于工作状态, $\alpha_j = 0$ 表示该负荷未工作。通常家用电器负荷的投切动作过程不超过0.01 s。电路总线因投切动作产生的暂态过程可以理解为负荷未发生投切之前该电路总线的稳态与该负荷投切后暂态过程的叠加。对该负荷进行暂态电流特征提取首先需要获取负荷单独投切引起的电流信号,即暂态电流特征提取需要去除暂态事件之前的背景电流。本文采用文献[20]中的周期差分方法去除背景波,此方法简单快捷。




图1 原始总线电流信号

Fig. 1 Raw bus current signal

3 暂态电流特征提取与选择

3.1 S变换原理

由Stockwell等^[21]提出的S变换(ST)是一种可逆的局部时频域分析方法,本质是对短时傅里叶变换(STFT)和小波变换的发展。一维连续信号的




图 2 5层小波分解与重构后的电流信号

Fig. 2 Current signal after 5-layer wavelet decomposition and reconstruction

S变换为

$$\omega(t-\tau) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(t-\tau)^2}{2\sigma^2}\right], \quad (2)$$

$$\left\{ \begin{array}{l} \mathbf{S}\left(jT, \frac{n}{NT}\right) = \sum_{m=0}^{N-1} \mathbf{x}\left(\frac{m+n}{NT}\right) \exp\left(-\frac{2\pi^2 m^2}{n^2}\right) \exp\left(\frac{i2\pi m j}{N}\right), \quad n \neq 0 \\ \mathbf{S}(jT, 0) = \frac{1}{N} \sum_{k=0}^{N-1} \mathbf{x}(kT), \quad n = 0 \end{array} \right., \quad (4)$$

式中： N 为采样点数； T 为时域采样间隔； $j, m, n = 0, 1, \dots, N-1$ ； $\mathbf{X}(n/NT)$ 为 $\mathbf{x}(kT)$ 的 N 点离散傅里叶变换。经过S变换提取的负荷暂态特征是一个复数矩阵，矩阵列表示信号时间，即采样点数。矩阵行表示暂态电流频率，行列对应的元素模值为暂态电流幅值。通常家用电器负荷在投切瞬间产生的暂态电流信号不仅含有尖峰脉冲信号，还具备局部特征。使用S变换既可以提取到暂态电流每一个采样点在不同频率下的幅值，又可以提取到同一频率下所有采样点的幅值特征，能够提取暂态电流信号足够充分的时频域特征信息。图3为S变换提取负荷暂态电流信号的三维图。

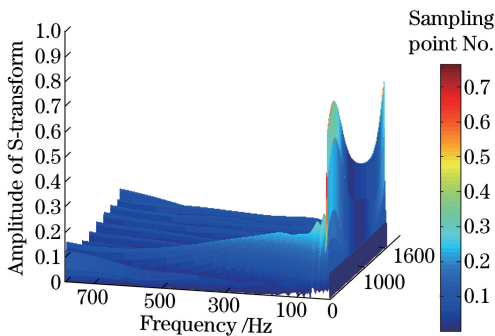


图 3 S变换时频分布三维图

Fig. 3 Time-frequency distribution of S-transform

3.2 (2D)²PCA原理

3.2.1 PCA

一维PCA适用于处理一维特征向量，目标是求取一个投影矩阵 \mathbf{U} ，使得均方误差最小。这样原始

$$\mathbf{S}(t, f) = \int_{-\infty}^{\infty} \mathbf{x}(t)\omega(t-\tau) \exp(-i2\pi ft) dt, \quad (3)$$

式中： $\omega(t-\tau, f)$ 为高斯窗口，窗口宽度 $\sigma = 1/|f|$ 为频率倒数。负荷的暂态电流信号包含丰富的谐波频率成分，在波形形态上存在局部特征。使用S变换对负荷暂态提取时频域特征会使暂态信号的高次谐波部分获取较高的时间分辨率，在低频获得较高的频率分辨率，克服了STFT窗口高度和宽度固定的缺陷。 $\mathbf{x}(kt)$ 为负荷暂态信号，其S变换的离散形式为

一维特征向量经过矩阵 \mathbf{U} 投影后，不仅能够缩减特征维数，还能保留原始特征向量中的主要信息。在多元统计分析中，PCA能够使用较少的特征描述样本，减小了后续样本分类的难度，PCA在人脸识别中有广泛的应用。PCA的核心在于通过较低维数的向量和投影矩阵，可以重构出对应的原始多维特征向量。

设有 M 个暂态电流的负荷样本，经过S变换后，得到 M 个原始特征矩阵，构成样本数据集为 $\{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M\}$ ，首先计算样本集的平均特征矩阵：

$$\bar{\mathbf{X}} = \frac{1}{M} \sum_{i=1}^M \mathbf{X}_i. \quad (5)$$

计算样本的协方差矩阵 \mathbf{C} 为

$$\mathbf{C} = \frac{1}{M} \sum_{i=1}^M (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})^T. \quad (6)$$

对 \mathbf{C} 求取特征向量 \mathbf{u}_i 和对应的特征值 λ_i ，使用这些特征向量之间的线性组合可以重构样本中任意的负荷暂态电流样本。对矩阵 \mathbf{C} 的特征值进行降序排列：

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d \geq \dots \geq \lambda_r. \quad (7)$$

在(7)式中选择大于 λ_d 的特征值对应的特征向量构成主要特征矩阵 \mathbf{U} ：

$$\mathbf{U} = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d). \quad (8)$$

每一个S变换后的暂态电流样本投影到 \mathbf{U} 可以构成暂态电流S变换矩阵子空间。通过该降维后的子空间，S变换负荷矩阵都可以进行投影。设 \mathbf{X}_i 为任一暂态电流样本， \mathbf{Y}_i 为 \mathbf{X}_i 经过一维PCA变换

后的特征矩阵:

$$\mathbf{Y}_i = \mathbf{X}_i \mathbf{U}. \quad (9)$$

3.2.2 2DPCA

通常来说,由于受到物理结构和电气特性的影响,不同的家用负荷电器的暂态电流信号有所不同,不同的家用负荷的暂态电流信号可以通过时频域特征表征区分其差异性。2DPCA 的本质在于对特征矩阵进行横向压缩,以样本的总体分散程度为目标,寻找一组最优的单位正交投影向量作为最优投影向量组,最终实现信号的特征提取。除此之外,2DPCA 可以在不损害原始特征矩阵的几何结构信息的条件下,获得更本征的特征表示。使用 2DPCA 压缩暂态电流 S 变换矩阵可以提取不同负荷的暂态电流之间的差异信息。

对于 S 变换暂态电流样本矩阵 \mathbf{X}_i ,其特征矩阵为 $m \times n$ 维,选取 Q 个负荷样本构建协方差矩阵 \mathbf{C} , \mathbf{C} 的大小为 $n \times n$,与一维 PCA 相似,从协方差矩阵 \mathbf{C} 的特征值选择前 d 个最大特征值对应的特征向量构建 $n \times d$ 维最佳投影矩阵 \mathbf{U} ,对于每一个 S 变换负荷样本矩阵 \mathbf{X}_i ,经过 2DPCA 压缩后的特征矩阵为 $\mathbf{Y}_i = \mathbf{X}_i \mathbf{U}$ 。

使用 2DPCA 对 S 变换暂态电流样本提取主成分,样本特征矩阵由 $m \times n$ 维降低为 $m \times d$ 维特征矩阵 \mathbf{Y}_i 。从降维后的结果可以看出,原始特征矩阵仅在列的维数上有所缩减,也就是说仅仅提取了原始特征矩阵列向量的主成分,没有考虑水平方向的维数压缩。

3.2.3 (2D)²PCA

对 2DPCA 进行改进,同时从 S 变换暂态电流矩阵的行和列方向进行维数压缩,去除特征矩阵整体的相关性,在 2DPCA 的基础上进一步压缩特征维数,加快计算速率。双向 2DPCA 的本质是从特征矩阵的两个方向进行 2DPCA 运算,在压缩特征维数方面达到较好的效果。双向 2DPCA 的实现过程如下。

1) 对于 M 个 S 变换暂态电流负荷样本矩阵,分别从行和列两个方向上计算协方差矩阵 \mathbf{C} 和 \mathbf{G} 。 \mathbf{C} 计算过程参见(6)式。

$$\mathbf{G} = \frac{1}{M} \sum_{i=1}^M (\mathbf{X}_i - \bar{\mathbf{X}})^T (\mathbf{X}_i - \bar{\mathbf{X}}). \quad (10)$$

从 2DPCA 的原理可知,协方差矩阵 \mathbf{C} 和 \mathbf{G} 的大小分别为 $n \times n$ 和 $m \times m$ 。

2) 与 2DPCA 算法流程一致,分别获取协方差矩阵 \mathbf{C} 和 \mathbf{G} 的前 d_1 个最大特征值和前 d_2 个最大

特征值。获取 d_1 个 \mathbf{C} 的特征值对应的特征向量组成列方向压缩最佳投影矩阵 \mathbf{H} ,获取 d_2 个 \mathbf{G} 的最大特征值对应的特征向量组成行方向上压缩最佳投影矩阵 \mathbf{V} 。

3) 对于每一个 S 变换暂态电流样本矩阵 \mathbf{X}_i ,经过双向 2DPCA 进行两个方向特征压缩之后的特征矩阵为 \mathbf{Y}_i ,表示为

$$\mathbf{Y}_i = \mathbf{V}^T \mathbf{X}_i \mathbf{H}. \quad (11)$$

4) $m \times n$ 维原始 S 变换暂态电流样本矩阵经过双向 2DPCA,得到最终降维的矩阵大小为 $d_1 \times d_2$,且经过双向 2DPCA 后,去除了原始特征矩阵两个方向的数据相关性,最后将此特征矩阵展成一维矩阵时,不会造成较大影响。与最初的特征矩阵相比, $d_1 \times d_2$ 维提取矩阵主成分后的特征矩阵不仅可以去除次要特征,保留重要特征,还可以加速后续的分类识别过程。

4 负荷分类

支持向量机(SVM)是 Corinna Cortes 和 Vapnik 等基于统计学习理论提出的一种机器学习方法。采用 SVM 作为分类器进行小样本、非线性模式识别时有诸多优势。常见的分类策略有一对一策略(OAO)和一对多策略(OAA)。本文选择一对多策略对多种负荷进行分类。

设训练样本集为负荷暂态融合特征 \mathbf{Z} ,其中第 i 个输入负荷融合特征样本为 $\mathbf{Z}_i \in \mathbf{R}^d$,对于二分类,SVM 超平面方程为 $\mathbf{Z}_i \mathbf{w} + b = 0$,融合特征权值向量为 \mathbf{w} ,偏差项为 b 。经过规范化后的超平面分类间隔为 $2/\|\mathbf{w}\|$ 。为得到融合特征最优分类函数式

$$f(\mathbf{Z}_i) = \text{sgn} \left[\sum_{i=1}^l \mathbf{y}_i \alpha_i (\mathbf{Z}_i, \mathbf{Z}) + b \right], \text{ 转化为求解}$$

$$\min \Phi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2, \text{ s.t.}$$

$$\mathbf{y}_i [(\mathbf{Z}_i \cdot \mathbf{w}) + b] \geq 1, i = 1, 2, \dots, l \quad (12)$$

的极值问题。(12)式中: \mathbf{y}_i 为 \mathbf{Z}_i 的目标值; l 为训练负荷样本数目。

在最优分类函数中,引入拉格朗日乘子 $\alpha_i \geq 0$,只有 $\alpha_i > 0$ 对应负荷暂态电流样本 \mathbf{Z}_i 被称为支持向量。实际中负荷暂态电流融合后的特征集可能并不是简单线性可分,而对于非线性情况,SVM 的处理方法是选择一个核函数 $K(\cdot, \cdot)$,将矩阵压缩后的暂态特征映射到高维空间,解决在原始空间中线性不可分的负荷识别问题。SVM 基本形式为

$$f(x) = \text{sgn} \left[\sum_{i=1}^l \alpha_i \mathbf{y}_i K(x_i, x_j) + b \right]. \quad (13)$$

5 实验结果与分析

5.1 数据集介绍

BLUED(Building-Level Fully-Labeled Dataset for Electricity Disaggregation)数据库是2012年 Kyle Anderson 等公开的专门用于负荷识别的电力数据库。该数据库提供了美国一个家庭在一周之内 AB 相上 12 kHz 采集的真实家用等级电压电流测量值。在该时间段内,用户家中大多数用电负荷的投切动作都被标记并给出时间戳。与其他几种电力数据库相比,BLUED 数据集总线电流采样频率较高,监测时间长,适合对家用负荷投切过程进行暂态分析。从 BLUED 数据库中选择 6 种负荷样本,以验证本文提出暂态电流特征提取与选择算法的识别性能。表 1 列出了 6 类负荷样本的训练集和测试集组成,在同等实验环境下重复 10 次实验。图 4 为 6 类负荷样本的暂态电流波形,样本中 Refrigerator 2 与 Light 暂态电流相似,用来验证本文特征选择方法对相似电器的识别性能。

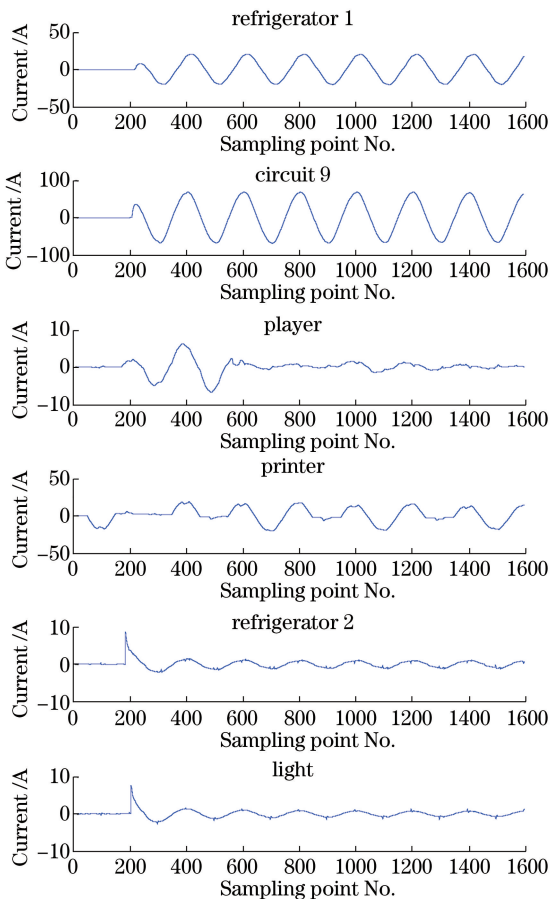


图 4 6 种不同负荷的暂态电流波形

Fig. 4 Transient current waveforms of 6 different loads

表 1 实验数据集组成

Table 1 Composition of the data set

Loads	Refri_1	Refri_2	Player	Printer	Light	Circuit
Train set	126	90	38	46	52	34
Test set	42	30	13	16	18	12

5.2 负荷识别

图 4 中的 1600 个暂态电流信号离散点经过 S 变换后时频域矩阵维数为 801×1600 ,如果直接使用模式识别方法对负荷进行分解会加大计算量,且 S 变换谐波幅值矩阵中冗余信息较多,负荷识别效果也有限,识别效率较低,常见的做法是对 S 变换谐波幅值矩阵进行降维处理。

根据 2.2.3 节可知,一个 $m \times n$ 维的矩阵经过 $(2D)^2$ PCA 双向压缩后得到一个 $d_1 \times d_2$ 维特征矩阵。为了探究不同的 d_1 与 d_2 取值对负荷识别的影响规律,选取 $(5,5)$ 、 $(5,8)$ 、 $(6,5)$ 、 $(6,8)$ 、 $(8,5)$ 、 $(8,6)$ 6 种 (d_1, d_2) 组合方式。将每种组合下的 $d_1 \times d_2$ 维暂态电流负荷样本按照行向量的方式展成 $1 \times (d_1 \times d_2)$ 维行向量。在 6 类负荷样本中随机抽取训练集,通过 10 次计算的平均识别率(ACC)来表征负荷识别性能。使用 SVM 分类器对 6 种 (d_1, d_2) 组合下的样本进行负荷识别,结果如表 2 所示。

从表 2 可以看出,不同组合下的负荷识别效果不同,整体取得了较好的识别效果。其中 $(6,8)$ 组合下的识别效果最佳。这说明 S 变换和双向 2DPCA 提取负荷暂态电流特征的方法适用于负荷识别。另外,基于暂态电流的负荷识别并不是特征维数越多识别效果越好。表 3 列出了 6×8 特征组合下的分类性能,此时最大识别率、最小识别率、平均识别率分别为 100%、98.47% 和 99.24%,特征维数为 48。

由表 3 可知,使用双向 2DPCA 对 S 变换暂态电流样本矩阵提取主成分能够实现较好的分类效果,特别是电气特性相似的负荷,如 Refri_2 和

表 2 不同特征下的负荷识别效果(单位:%)

Table 2 Average recognition accuracy with different features (unit: %)

(d_1, d_2)	(5,5)	(5,8)	(6,5)	(6,8)	(8,5)	(8,6)	(8,8)
ACC	97.40	98.17	97.86	99.24	98.46	97.71	98.47

表 3 双向 2DPCA 下的分类指标(单位:%)

Table 3 Classification performance with $(2D)^2$ PCA (unit: %)

Load	Refri_1	Refri_2	Player	Printer	Light	Circuit
Sensitivity	97.62	100	100	100	100	100
Specificity	100	100	100	99.13	100	100

Light, 可以将这两种负荷从电路总线上正确地分离开来。不仅如此, 使用双向 2DPCA 使特征维数压缩, 801×1600 维的特征矩阵压缩为 6×8 维特征矩阵。使用该特征矩阵来表征负荷的暂态电流样本, 经过 SVM 分类器, 分类结果表明, 该方法能够达到较好的分类效果。由此可见使用双向 2DPCA

压缩暂态电流 S 变换特征矩阵在负荷特征提取与选择中具有显著的优势。表 4 列出了负荷样本双向 2DPCA 变换后经过 SVM 分类的混淆矩阵。为了进一步比较分类性能, 表 5 列出了同等实验条件下本文方法与文献[15-17]方法的负荷识别性能。

表 4 负荷分类混淆矩阵(单位: %)

Table 4 Confusion matrix of load classification (unit: %)

Load	Predicted activity type					
	Refri_1	Refri_2	Player	Printer	Light	Circuit
Refri_1	97.62	0	0	0	2.38	0
Refri_2	0	100	0	0	0	0
Player	0	0	100	0	0	0
Printer	0	0	0	100	0	0
Light	0	0	0	0	100	0
Circuit	0	0	0	0	0	100

表 5 不同特征选择方法下的负荷识别性能比较

Table 5 Comparison of classification performance with different feature selection methods

Method	ACC / %	Sensitivity / %	Specificity / %	Dimension	Time / s
Ref. [15]	96.18	97.33	99.33	16	0.490
Ref. [16]	96.64	94.45	99.01	100	4.710
Ref. [17]	95.42	95.93	99.08	12	0.020
Proposed	99.23	99.45	99.85	48	0.629

文献[16]方法对暂态电流波形提取 S 变换特征后, 将其幅值矩阵转化为图片, 采用 Eigenloads 方法进一步提取特征。与本文方法不同的是, 文献[16]方法将 S 变换后的矩阵直接转化为图片, 将图像矩阵展成向量并使用 PCA 进行特征降维, 使用 SVM 进行分类识别。在将图像矩阵直接展成向量的过程中, 难免破坏原始数据之间的结构信息。文献[15]方法针对 S 变换幅值矩阵提取前 8 次谐波幅值均值和方差, 该方法虽然在运行时间和特征维数上占有优势, 但是识别准确度不高, 因为仅通过人工选择的前 8 次谐波特征不能充分表征负荷暂态电流的细节信息, 不足以区分不同负荷之间的差异。文献[17]方法提取的多维度暂态电流波形特征适用于一般暂态电流波形相差较大的负荷, 对于电气特性相似的负荷识别能力有限。本文方法针对 S 变换幅值矩阵, 使用 $(2D)^2$ PCA 压缩特征矩阵, 从数学角度对特征进行选择, 显著降低特征维数的同时从较多的谐波和幅值特征中过滤掉众多次要或不重要的谐波幅值, 保留主要的谐波和对应幅值信息, 避免了人工选择谐波幅值特征不完整的缺陷。与文献[15-17]方法相比, 本文方法的识别率较高, 同时具备较好的暂态电流细节表征能力, 对于电气特性相似的

负荷有较好的区分度。

6 结 论

提出结合 S 变换和双向 2DPCA 的负荷暂态电流特征提取方法, 通过 SVM 分类器实现了对非侵入式家用负荷的识别分解。通过 BLUED 公开电力数据集中的 6 类家用电器进行负荷识别实验, 验证了算法的有效性, 特别是对电气特性相似的负荷的识别, 本文算法效果明显。与现有基于暂态电流的负荷识别方法相比, 提出的特征提取方法具备更高的识别率, 尤其对电气特性相似的负荷的识别效果最为显著。本文方法仍需进一步改进, 结合负荷稳态特征以实现暂态信息较少或不含暂态信息的电阻型负荷的识别。

参 考 文 献

- [1] Xu Z R, Yang P, Zhao Z L, *et al.* Analysis on the development of multi-microgrid in China [J]. Automation of Electric Power Systems, 2016, 40(17): 224-231.
许志荣, 杨苹, 赵卓立, 等. 中国多微网系统发展分析[J]. 电力系统自动化, 2016, 40(17): 224-231.
- [2] Hart G W. Nonintrusive appliance load monitoring

- [J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [3] Drenker S, Kader A. Nonintrusive monitoring of electric loads [J]. IEEE Computer Applications in Power, 1999, 12(4): 47-51.
- [4] Srinivasan D, Ng W S, Liew A C. Neural-network-based signature recognition for harmonic source identification [J]. IEEE Transactions on Power Delivery, 2006, 21(1): 398-405.
- [5] Lam H Y, Fung G S K, Lee W K. A novel method to construct taxonomy electrical appliances based on load signatures[J]. IEEE Transactions on Consumer Electronics, 2007, 53(2): 653-660.
- [6] Gupta S, Reynolds M S, Patel S N. ElectriSense: single-point sensing using EMI for electrical event detection and classification in the home [C] // ACM International Conference on Ubiquitous Computing, ACM, 2010: 139-148.
- [7] Lou J L, Yu H T, Qu Z Y. Load decomposition method for non-intrusive household system [J]. Journal of Jilin University (Science Edition), 2015, 53(4): 744-753.
 娄建楼, 于华涛, 曲朝阳. 面向家庭用户的用电负荷分解方法 [J]. 吉林大学学报(理学版), 2015, 53(4): 744-753.
- [8] Sun Y, Cui C, Lu J, *et al.* Non-intrusive load monitoring method based on delta feature extraction and fuzzy clustering [J]. Automation of Electric Power Systems, 2017, 41(4): 86-91.
 孙毅, 崔灿, 陆俊, 等. 基于增量特征提取与模糊聚类的非侵入式负荷监测方法 [J]. 电力系统自动化, 2017, 41(4): 86-91.
- [9] Zhu C H, Wang J P, Li Q Y, *et al.* Recognition and localization of intrusion vibration signal based on time-frequency characteristics in optical fiber perimeter security [J]. Chinese Journal of Lasers, 2016, 43(6): 0610001.
 朱程辉, 王建平, 李奇越, 等. 基于时频特征的光纤周界入侵振动信号识别与定位 [J]. 中国激光, 2016, 43(6): 0610001.
- [10] Tan Z, Xiangli B, Lü Q B, *et al.* A sequence images super-resolution enhancement approach based on frequency-domain [J]. Acta Optica Sinica, 2017, 37(7): 0710001.
 谭政, 相里斌, 吕群波, 等. 一种基于频域的序列图像超分辨率增强方法 [J]. 光学学报, 2017, 37(7): 0710001.
- [11] Cox R, Leeb S B, Shaw S R, *et al.* Transient event detection for nonintrusive load monitoring and demand side management using voltage distortion [C] // 21st Annual IEEE Applied Power Electronics Conference and Exposition, IEEE, 2006: 1751-1757.
- [12] Patel S N, Robertson T, Kientz J A, *et al.* At the flick of a switch: detecting and classifying unique electrical events on the residential power line [C] // International Conference on Ubiquitous Computing, Springer, 2007: 271-288.
- [13] Saitoh T, Aota Y, Osaki T, *et al.* Current sensor based non-intrusive appliance recognition for intelligent outlet [C] // 23rd International Technical Conference on Circuits/Systems, Computers and Communications, 2008: 349-352.
- [14] Martins J F, Lopes R, Lima C, *et al.* A novel nonintrusive load monitoring system based on the S-transform [C] // 13th International Conference on Optimization of Electrical and Electronic Equipment, IEEE, 2012: 973-978.
- [15] Lin Y H, Tsai M S. Development of an improved time-frequency analysis-based nonintrusive load monitor for load demand identification [J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(6): 1470-1483.
- [16] Ahmadi H, Marti J R. Load decomposition at smart meters level using eigenloads approach [J]. IEEE Transactions on Power Systems, 2015, 30(6): 3425-3436.
- [17] Li Y X. Research on algorithms of non-intrusive load decomposition [D]. Beijing: Beijing Jiaotong University, 2016.
 李雨轩. 非侵入式负荷分解算法的综合研究 [D]. 北京: 北京交通大学, 2016.
- [18] Zhang D, Zhou Z H. (2D)²PCA: two-directional two-dimensional PCA for efficient face representation and recognition [J]. Neurocomputing, 2005, 69(1): 224-231.
- [19] Sun C X, Pan J X, Chen P. Segmental multi-energy computed tomography imaging based on wavelet analysis [J]. Laser & Optoelectronics Progress, 2016, 53(9): 093401.
 孙春霞, 潘晋孝, 陈平. 基于小波分析的分能段计算机断层扫描成像 [J]. 激光与光电子学进展, 2016, 53(9): 093401.
- [20] Tsai M S, Lin Y H. Modern development of an adaptive non-intrusive appliance load monitoring system in electricity energy conservation [J]. Applied Energy, 2012, 96: 55-73.
- [21] Stockwell R G, Mansinha L, Lowe R P. Localization of the complex spectrum: the S-transform [J]. IEEE Transactions on Signal Processing, 1996, 44(4): 998-1001.