

DOI: 10.7667/PSPC151825

RPROP 神经网络在非侵入式负荷分解中的应用

李如意¹, 王晓换¹, 胡美璇², 周洪², 胡文山²

(1. 河南许继仪表有限公司, 河南 许昌 461000; 2. 武汉大学发电控制与电网智能化技术研究所, 湖北 武汉 430072)

摘要: 为了解决常用家电设备投切状态辨识问题, 提出一种以神经网络为辨识模型的方法, 增强其快速辨识能力。首先, 从负荷印记出发, 针对各用电设备的稳态电流谐波特性, 建立用电设备特征标签。然后, 采用弹性 BP(Resilient back propagation, RPROP)神经网络, 将输入数据特征向输出层非线性映射, 实现快速收敛至全局最优点。训练中采用多种设备组合方式, 进行用电设备特征辨识。最终, 以五类常用用电设备进行实验, 实验结果表明该算法能够有效地识别家用设备的工作状态组合, 且对功率相近、谐波具有较小差异的用电设备工作状态也具有很好的辨识能力。

关键词: 非侵入式; 负荷分解; 神经网络; RPROP 算法; 系统架构

Application of RPROP neural network in nonintrusive load decomposition

LI Ruyi¹, WANG Xiaohuan¹, HU Meixuan², ZHOU Hong², HU Wenshan²

(1. Henan Xuji Instrument Co., Ltd., Xuchang 461000, China; 2. Laboratory of Generation Control and Smart Grid, Wuhan University, Wuhan 430072, China)

Abstract: In order to identify the common-used household appliances, this paper proposes a kind of neural network which is effective to enhance the identification ability. First of all, based on load signature, aiming at harmonic characteristics of steady-state current in each electrical equipment, the feature tag is thereby established. Then, the RPROP neural network is adopted, which makes the input data feature nonlinearly map to output layer, and guides the neural network to converge to global optimal point rapidly. When training the neural network, the combined features are used to decompose the characteristics of electrical equipment. Finally, the experimental results of five common electrical appliances demonstrate that the proposed algorithm can effectively identify combined working states of household appliances, and it also can decompose the working states of electric appliances with similar power and little different harmonics.

Key words: nonintrusive; load decomposition; neural network; RPROP algorithm; system architecture

0 引言

近年来, 智能用电技术^[1]、需求侧管理技术^[2-3]等受到国内外电力系统领域专家学者的广泛关注。其中, 负荷监测与分解技术使电力用户可获知负荷内部各用电设备的耗能信息, 从而根据耗能信息、电能质量、分时电价、电能计量等综合信息, 电力用户可采取有效措施来减少耗能^[4], 例如调整用电时段或购买节能电器、智能电器^[5]等。因此, 电力负荷监测与分解是鼓励电力用户参与优化电力系统运行调度和协调管理的一项重要技术。负荷监测研

究分为非侵入式^[6]和侵入式两大类。侵入式方法需在用电设备内部安装传感器, 耗费大量资金, 因此不适合推广。目前, 非侵入式负荷监测与分解(Nonintrusive Load Monitoring and Decomposition, NILMD)技术是研究的热点。

通常而言, 一个优良的系统架构能够有利于明确各功能模块之间的关系, 同时, 有利于系统的搭建。为了有效实现负荷监测与分解, 文献[7]提出并构建了基于多智能体(Agent)技术^[8]的 NILMD 系统架构, 并对不同层次的 Agent 的功能进行了详细说明。在该框架中, 开发非侵入负荷分解算法是最为重要的一部分。近年来, 国内外专家学者已提出了很多关于电力负荷用电设备工作状态的识别方法,

例如支持向量机^[9]、整数规划^[10]及贝叶斯算法^[11]等。神经网络起源于对神经元的模仿，具有自适应学习能力，因此是一种高效辨识方法，适合应用在NILMD系统中^[12-14]。文献[12]研究了3种基于神经网络的分类模型—多层感知器、径向基函数网络^[15]和支持向量机对组合用电设备的辨识效果，比较计算量和辨识准确率，得出多层感知器是这3种分类器中性能最优的模型。

然而，文献[12-14]的研究未涉及到对具有相似特性的用电设备的辨识，特别是功率相近的用电设备。另外，目前相关的研究未将非侵入式负荷分解算法融入到NILMD系统架构中，导致NILMD系统不具有较强的实用性。

为此，本文在基于多Agent技术的NILMD系统架构的基础上，将非侵入式负荷分解算法嵌入到NILMD系统架构的监测分解层，并说明基于负荷分解算法的NILMD系统的工作流程。进一步地，本文提出基于RPROP神经网络的非侵入式负荷分解算法。首先，考虑到噪声和误差，构建非线性负荷分解模型。同时，以稳态电流谐波分量为负荷印记，对相似特性的用电设备稳态电流进行快速傅立叶变换^[16]，得到各谐波分量。采用多层神经网络将差距较小的稳态电流谐波特征作为输入，非线性映射到输出层，得到恰当的分类面，从而有效辨识相似的用电设备。最后，实例验证基于RPROP神经网络的非侵入式负荷分解算法的高辨识能力。

1 NILMD 系统架构

NILMD系统的监测分解层由终端监测单元、模型库管理单元和方法库管理单元组成，负荷统计单元和数据库管理单元位于地区统计层，这些单元结构上具有多层次、分布式、交互性等特点。因此，可将多Agent技术应用到NILMD系统^[7]。本文将非侵入式负荷分解算法嵌入到NILMD系统中，如图1所示。

NILMD系统的主要功能是实现负荷分解。本文以基于神经网络的非侵入式负荷分解算法为例，说明NILMD系统的工作流程如下：

- (1) 确定负荷内部用电设备的种类。
- (2) 不同负荷事件重叠时，终端监测Agent离线统计得到负荷内部不同用电设备工作状态组合所对应的负荷电源入口处稳态电流。
- (3) 模型库管理Agent与终端监测Agent交互信息，下载得到稳态电流数据，并将其作为组合负荷印记。与此同时，模型库管理Agent对电流数据进行快速傅立叶变换等处理后，得到稳态电流的谐波

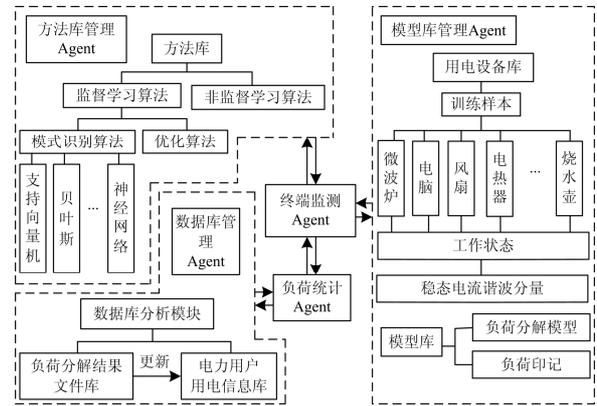


图1 基于负荷分解算法的系统架构

Fig. 1 System architecture based on load decomposition algorithm

分量，并将谐波分量的幅值数据作为训练样本存储在用电设备库中。

(4) 终端监测Agent下载得到不同用电设备工作状态组合所对应的训练样本，并将其上传至方法库管理Agent中。

(5) 针对多组训练样本，方法管理库Agent可训练得到不同的网络。训练结果与各用电设备实际的工作状态对比，当均方误差在规定值以内时，训练结束。方法管理库Agent将训练好的网络保存，并贴上标识(时间、用户信息编码等)。

(6) 终端监测Agent从方法库管理Agent下载得到训练好的网络，从而将实时监测的稳态电流信号经过数字化、规范化等处理后，作为非侵入式负荷分解算法的负荷特征输入。根据网络的输出，可得到相应的负荷分解结果。

(7) 将负荷分解结果上传至负荷统计Agent，并在数据库管理Agent中建立电力用户用电信息库，更新和存储各用电设备的耗能信息。

因此，根据上述流程，能为RPROP神经网络提供一个辨识的系统框架。在该框架中，NILMD系统学习基于RPROP神经网络的负荷分解算法的能力尤为重要。

2 负荷分解模型

2.1 负荷印记

用电设备从开启到关停通常会经历若干个过渡区段和稳态区段。当过渡区段的负荷特征作为负荷分解依据时，“混叠特征”的出现会导致单个用电设备的数据特征受到其他用电设备的干扰，从而辨识失效。另一方面，在实际工作过程中，过渡区段很短，用电设备长期工作在稳态区段。因此，本文利用用电设备的稳态区段特征作为辨识负荷内部用电设备状态的依据。其中，稳态功率波形、电流波

形和电压波形都能可靠标志用电设备的工作状态。通常能较好地标记用电设备的工作状态, 在此, 称之为负荷印记。

用电设备接入到家用电源线路中, 由于并联特性, 一般可以认为各用电设备的电压是一致的。为此, 将一个电压周期内的稳态电流波形作为负荷印记。

2.2 分解模型

在某一稳态区段内, 负荷总电流按用电设备组成分解为如下模型。

$$i_L(t) = \sum_{h=1}^N \sum_{m=1}^{M(h)} s_{h,m}(t) [\alpha_{h,m}(t) i_{h,m}(t)] + e(t) \quad (1)$$

式中: $i_L(t)$ 表示 t 时刻电力负荷的总电流; $i_{h,m}(t)$ 表示 t 时刻第 h 类用电设备工作在 m 状态的电流; $\alpha_{h,m}(t)$ 表示 t 时刻第 h 类用电设备工作在 m 状态的电流权重系数, $\alpha_{h,m}(t) \in (0, \infty)$; N 表示负荷内部用电设备总数。假设第 h 类用电设备的工作状态分为 $M(h)$ 种, 其中 $M(h) \in \{2, 3, 4, \dots\}$ 。用电设备处于停机状态时, $m=1$ 。当 t 时刻第 h 类用电设备工作在 m 状态时, 令 $s_{h,m}(t)=1$; 其余状态下为 0。 $e(t)$ 表示噪声或误差。

负荷分解模型通常是具有非线性特性的复杂函数。当负荷内部含有相似特性的用电设备时, 一般识别方法很难准确辨识。本文考虑输入与输出间复杂的非线性映射关系, 提出采用多层架构, 辨识具有相似特性的用电设备。

3 基于 RPROP 神经网络的负荷分解算法

3.1 分解负荷模型输入变量的选择

在负荷分解模型中, 负荷电源入口处可监测得到总电流, 而负荷内部各用电设备的工作状态是未知的所求值。通常用电设备具有投切特性, 以投切二状态为例, 则 $M(h)=2$ 。当负荷内部具有 N 类用电设备时, 则所有工作状态组合有 2^N 种。在对神经网络进行训练的阶段, 需要选取合适的训练样本。神经网络作为分类器运用在 NILMD 系统中, 要求训练样本至少包含 2^N 种, 才能完整地包含负荷内部用电设备的工作状态组合。

对于工作在稳态区段的不同用电设备, 即使是具有相似特性的用电设备, 其各次谐波也表现出一定的差异。因此, 在负荷工作的某一稳态区段内, 对已知的负荷总电流进行快速傅立叶变换得到其谐波分量, 选取总电流的谐波分量^[17]作为神经网络的输入变量。

3.2 神经网络

多层神经网络将输入向输出非线性映射, 逼近

非线性负荷分解模型, 从而实现将具有相似特征的样本数据尽可能准确地分类。因此, 将多层神经网络应用到非侵入式负荷分解智能算法的研究中, 可以为解决不同用电设备处于各工作状态的分类问题奠定基础。

3.2.1 输入层

以家庭电力负荷的常见 5 类用电设备: 微波炉、烧水壶、电脑、风扇、电热器为例进行研究与分析, 通常用电设备具有投切特性, 控制用电设备的二状态组合, 监测每一种组合电源入口处电力负荷的总电流 $i_L(t)$, 对其进行快速傅立叶变换, 一般地, 16 次谐波分量足以完整表达谐波信号的特征

$$i_L(t) = \sum_{k=1}^{16} I_{L,k} \cos(k\omega t + \theta_{L,k}) \quad (2)$$

式中: $I_{L,k}$ 表示电力负荷电源入口处总电流的 k 次谐波分量的幅值; ω 表示稳态电流中基波分量的角频率; $\theta_{L,k}$ 表示 k 次谐波分量的初相角。

设计神经网络的输入层的神经元为 2^5 个, 输入变量分别为 $I_L^{(1)} = [I_{L,1}^{(1)}, I_{L,2}^{(1)}, \dots, I_{L,16}^{(1)}]^T$, \dots , $I_L^{(32)} = [I_{L,1}^{(32)}, I_{L,2}^{(32)}, \dots, I_{L,16}^{(32)}]^T$, 构成输入矩阵 $I_L = [I_L^{(1)}, I_L^{(2)}, \dots, I_L^{(32)}]$ 。

3.2.2 输出层

本文设计的多层神经网络分类器输出层的神经元为 2^5 个, 输出变量设计如表 1。

表 1 负荷分解模型输出层定义

Table 1 Output of load decomposition model

工作状态组合	输出矩阵 $E_{32 \times 32}$					输出变量意义				
						电热器	电脑	风扇	微波炉	水壶
S_1	1	0	0	...	0	0	0	0	0	0
					$m=1$	$m=1$	$m=1$	$m=1$	$m=1$	$m=1$
S_2	0	1	0	...	0	0	0	0	1	
					$m=1$	$m=1$	$m=1$	$m=1$	$m=2$	
S_3	0	0	1	...	0	0	0	1	0	
					$m=1$	$m=1$	$m=1$	$m=2$	$m=1$	
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	
S_{32}	0	0	0	...	1	1	1	1	1	
					$m=2$	$m=2$	$m=2$	$m=2$	$m=2$	

3.2.3 隐含层

据研究, 三层神经网络基本可以逼近非线性负荷分解模型^[18], 因此, 本文设计的多层神经网络为三层。通常, 神经网络由输入层、隐含层和输出层组成, 如图 2 所示。

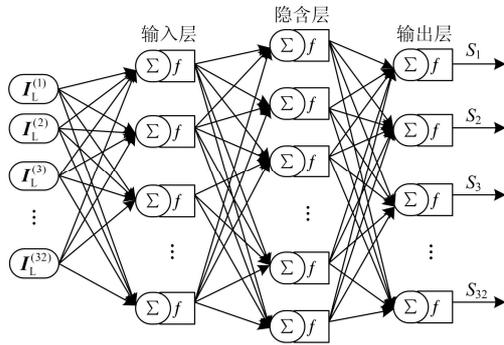


图 2 三层神经网络

Fig. 2 Three-layer neural network

一般地，隐含层的神经元个数设计为4到60个之间。经过多次训练，并根据经验确定隐含层神经元个数为40个。

隐含层的传输函数需满足处处可微的条件，一般选择对数Sigmoid函数。同样地，输出层神经元传输函数也选择对数Sigmoid函数。

综上所述，本文设计的多层神经网络的结构为32-40-32，即输入层有32个节点，隐含层有40个节点，输出层有32个节点。

3.3 学习算法

BP算法训练神经网络的过程主要是通过调整每层神经元的状态，即权值和阈值，从而使误差函数趋于最小值。然而，当训练次数很多时，其学习效率低，收敛速度较慢。另外，误差函数容易达到局部极小值而达不到全局最优值^[19]。

因此，本文采用RPROP算法来训练多层前馈神经网络。RPROP算法采用启发式的训练模式，根据误差偏导的符号信息调整网络的权值大小，从而可避免网络处于局部极小值或误差曲面的平坦区，并加快网络收敛的速度。

3.4 负荷分解算法

基于RPROP神经网络的负荷分解算法主要分为两个过程：训练和辨识。NILMD系统采集到负荷电源入口处的总电流，对总电流进行快速傅立叶变换，可以得到稳态电流谐波分量，从而将其作为多层前馈网络的输入，利用RPROP算法快速训练神经网络，一旦达到训练目标，训练过程即结束。将测试数据导入训练好的网络，根据辨识输出可以得到有效的负荷分解结果。该智能算法的流程图如图3所示。

4 实例验证

4.1 用电设备运行情况

本文研究五类用电设备投切状态的辨识，由图4所示的装置采集得到400组样本数据，其中，每组样

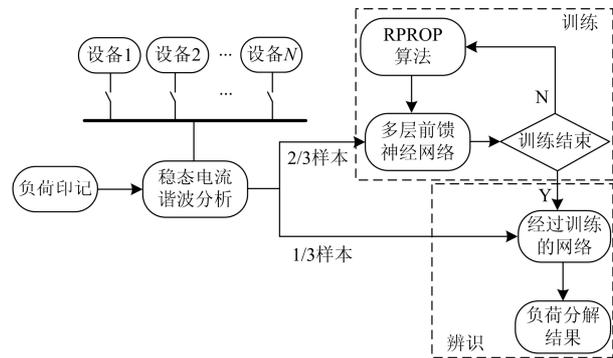


图 3 非侵入式负荷分解智能算法流程图

Fig. 3 Flowchart of non-intrusive load decomposition intelligent algorithm

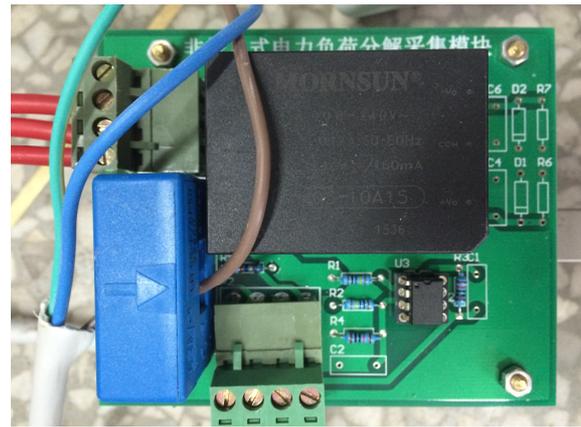


图 4 非侵入式负荷特征采集装置

Fig. 4 Non-intrusive load characteristic acquisition device

本数据均包含各用电设备的32种工作状态组合。由于电脑处于待机状态时与风扇处于运行状态时的输出特征相似，因此电脑和风扇是一组具有相似特性的用电设备，其功率变化曲线如图5所示。图5(a)描述了只有电脑和风扇工作时的功率曲线，可见具有相似特性的用电设备的功率曲线几乎重合。相应地，相似用电设备的组合会产生更多相似的功率值，则每组样本数据包含16种相似用电设备的工作状态组合。图5(b)~5(d)以同一时刻只有两类用电设备工作为例，描述了电脑和风扇分别与其余3种用电设备同时工作的功率曲线。

对采集得到的稳态电流进行快速傅立叶变换得到各次谐波分量的幅值，将这400组样本数据作为训练样本。用电设备在稳态区段所具有的谐波特性如图6所示。图6(a)~6(e)分别描绘了电热器、电脑、风扇、水壶和微波炉稳态工作时电流谐波分量的幅值特征。可见具有相似功率的电脑和风扇的谐波特征具有微弱的区别。另外，图6(f)描绘了无设备工

作时仍然存在微弱的电流信号。因此, 对样本数据进行分类时, 应首先规范化处理。

将电力负荷电源入口处稳态电流的谐波分量特征作为神经网络输入, 采用 RPROP 算法训练网络, 使得网络快速收敛。从而, 寻找到恰当的分类面, 为后续的测试样本进行分解辨识奠定基础。训练网络的回归曲线如图 7 所示, 网络的输出曲线基本与目标输出曲线重合, 输出值 $\approx 1 \times$ 目标值 $+1.9e^{-5}$, 并且相关系数 R 高达 100%。

比较标准 BP 算法和 RPROP 算法训练网络的性能, 如图 8 和图 9 所示。可见, RPROP 算法能够避免误差曲面的平坦区, 并快速使网络收敛于期望值。

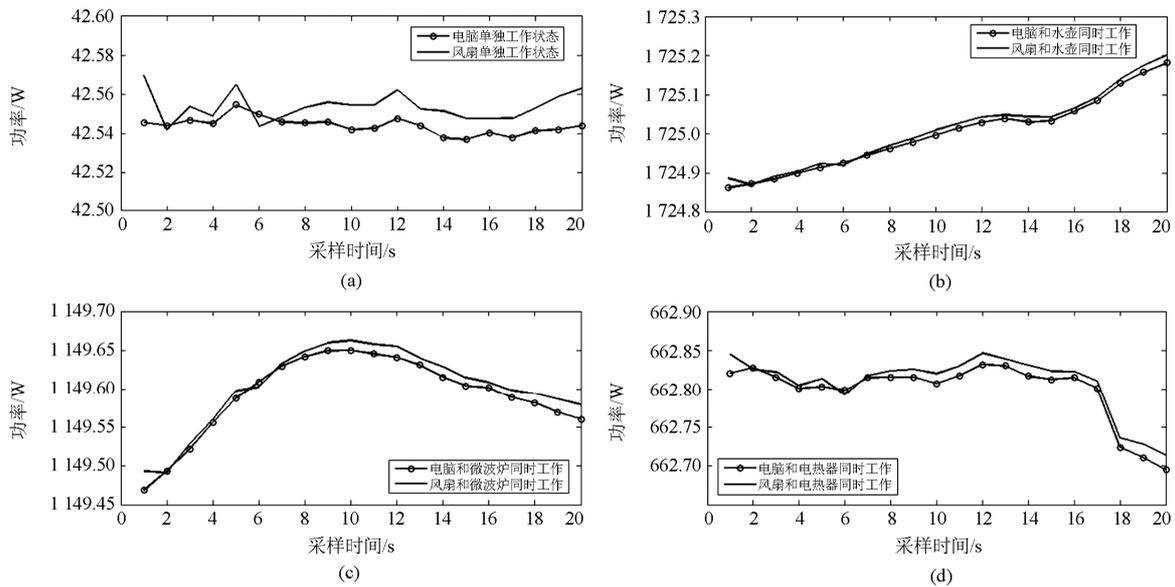


图 5 相似用电设备的功率曲线

Fig. 5 Power curve of similar electrical equipments

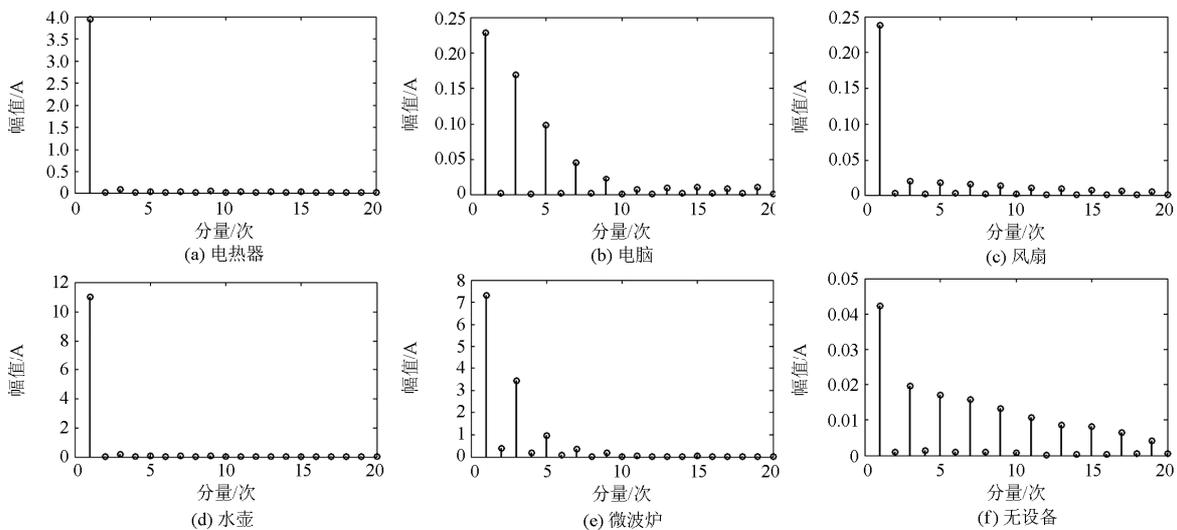


图 6 5 类用电设备稳态电流的谐波分量

Fig. 6 Steady current harmonics of five electrical equipments

4.2 负荷分解结果

以一个电压周期内的电流数据作为辨识系统的一组测试输入, 将 196 组测试样本输入到训练好的网络, 统计发现, 其中 90 组测试结果准确, 58 组准确率高达为 96.875%, 33 组测试结果准确率高达 93.75%, 如图 10 所示。由于每组样本数据均包含各用电设备的 32 种工作状态组合, 因此对组合用电设备工作状态的识别准确率为加权平均值 97.162%, 如表 2 所示。采用基于 RPROP 神经网络的负荷分解算法对用电设备工作状态进行辨识, 即使对具有相似特性用电设备的辨识, 仍然具有较高的准确率。

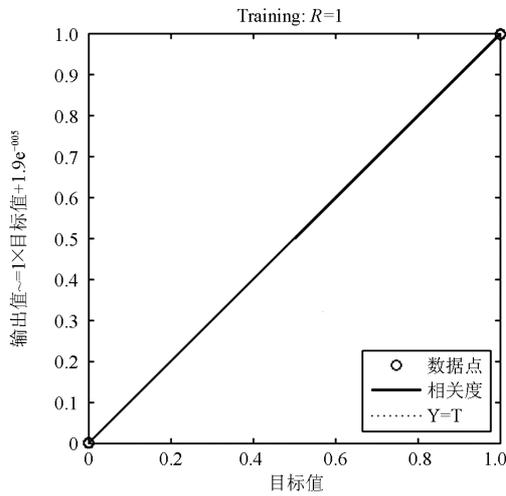


图 7 回归曲线

Fig. 7 Regression curve

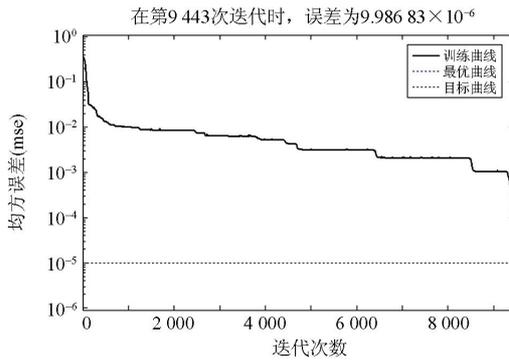


图 8 标准BP算法的误差曲线

Fig. 8 Error curve of standard BP algorithm

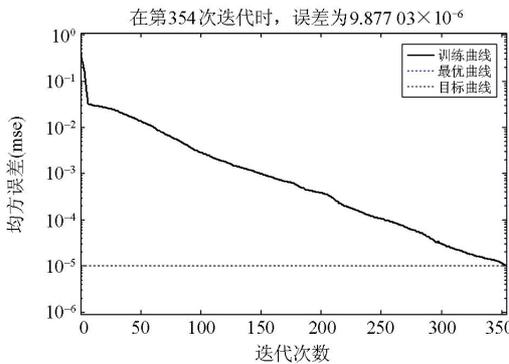


图 9 RPROP 算法的误差曲线

Fig. 9 Error curve of RPROP algorithm

表 2 辨识结果

Table 2 Identification results

测试样本数/组	90	58	33	9	3	3
准确率(%)	100	96.875	93.75	90.625	87.5	84.375
加权平均准确率(%)	97.162%					

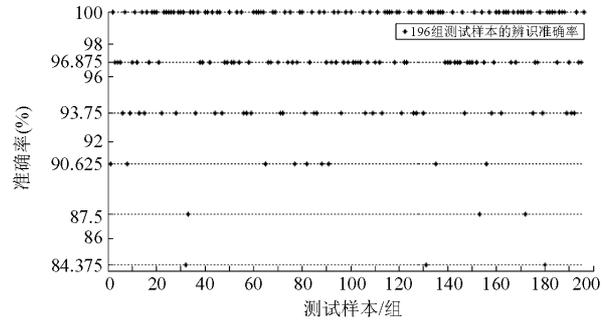


图 10 辨识率的散点图

Fig. 10 Scatter diagram of recognition rate

5 总结

本文从构建 NILMD 系统监测分解层框架出发, 采用基于 RPROP 神经网络的负荷分解算法对负荷内部各用电设备的工作状态组合进行分类。并将稳态电流谐波分量作为负荷特征值, 输入到多层前馈神经网络中。在 RPROP 算法的反复训练下, 神经网络对实际采集到的测试样本数据进行辨识, 辨识率高达 97.162%。实例结果验证了本文提出的非侵入式负荷分解智能算法的有效性, 且发现该算法对具有相似功率、较小谐波分量差距的用电设备也有很好的辨识效果。在下一步研究工作中, 我们将进一步增加用电设备, 期望该算法对大规模的组合用电设备的工作状态组合也能实现较高的辨识水平。

参考文献

[1] 王继东, 杨羽昊, 周越, 等. 家庭智能用电系统建模及优化策略分析[J]. 电力系统及其自动化学报, 2014, 26(11): 63-66, 71.
WANG Jidong, YANG Yuhao, ZHOU Yue, et al. Model and optimization strategy for smart home power consumption system[J]. Proceedings of the CSU-EPSSA, 2014, 26(11): 63-66, 71.

[2] 汤庆峰, 刘念, 张建华. 计及广义需求侧资源的用户侧自动响应机理与关键问题[J]. 电力系统保护与控制, 2014, 42(24): 138-147.
TANG Qingfeng, LIU Nian, ZHANG Jianhua. Theory and key problems for automated demand response of user side considering generalized demand side resources[J]. Power System Protection and Control, 2014, 42(24): 138-147.

[3] 张建华, 曾博, 张玉莹, 等. 主动配电网规划关键问题与研究展望[J]. 电工技术学报, 2014, 29(2): 13-23.
ZHANG Jianhua, ZENG Bo, ZHANG Yuying, et al. Key issues and research prospects of active distribution

- network planning[J]. Transactions of China Electrotechnical Society, 2014, 29(2): 13-23.
- [4] 阳小丹, 李扬. 家庭用电响应模式研究[J]. 电力系统保护与控制, 2014, 42(12): 51-56.
YANG Xiaodan, LI Yang. Research on household electricity response mode[J]. Power System Protection and Control, 2014, 42(12): 51-56.
- [5] 王建华, 张国钢, 耿英三, 等. 智能电器最新技术研究及应用发展前景[J]. 电工技术学报, 2015, 30(9): 1-11.
WANG Jianhua, ZHANG Guogang, GENG Yingsan, et al. The latest technology research and application prospects of the intelligent electrical apparatus[J]. Transactions of China Electrotechnical Society, 2015, 30(9): 1-11.
- [6] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [7] 黎鹏. 非侵入式电力负荷分解与监测[D]. 天津: 天津大学, 2009.
LI Peng. Non-intrusive method for power load disaggregation and monitoring[D]. Tianjin: Tianjin University, 2009.
- [8] 窦春霞, 李娜, 徐晓龙. 基于多智能体系统的微电网分散协调控制策略[J]. 电工技术学报, 2015, 30(7): 125-134.
DOU Chunxia, LI Na, XU Xiaolong. Multi-agent system based decentralized coordinated control strategy for micro-grids[J]. Transactions of China Electrotechnical Society, 2015, 30(7): 125-134.
- [9] LIN Y H, TSAI M S. Applications of hierarchical support vector machines for identifying load operation in nonintrusive load monitoring systems[C] // World Congress on Intelligent Control and Automation (WCICA), 2011: 688-693.
- [10] SUZUKI K, INAGAKI S, SUZUKI T, et al. Nonintrusive appliance load monitoring based on integer programming[C] // SICE Annual Conference, 2008: 2742-2747.
- [11] MARCHIORI A, HAKKARINEN D, HAN Q, et al. Circuit-level load monitoring for household energy management[J]. IEEE Pervasive Computing, 2011, 10(1): 40-48.
- [12] 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.
- [13] CHANG H H. Non-intrusive demand monitoring and load identification for energy management systems based on transient feature analyses[J]. Energies, 2012, 5(11): 4569-4589.
- [14] LIN Y H, TSAI M S. A novel feature extraction method for the development of nonintrusive load monitoring system based on BP-ANN[C] // 2010 International Symposium on Computer Communication Control and Automation (3CA), 2010: 215-218.
- [15] 马斌, 张丽艳. 一种基于径向神经网络的短期风电功率直接预测方法[J]. 电力系统保护与控制, 2015, 43(19): 78-82.
MA Bin, ZHANG Liyan. Short-term wind power direct forecasting based on RBF neural network[J]. Power System Protection and Control, 2015, 43(19): 78-82.
- [16] 王凯亮, 曾江, 王克英. 一种基于 BP 神经网络的谐波检测方案[J]. 电力系统保护与控制, 2013, 41(17): 44-48.
WANG Kailiang, ZENG Jiang, WANG Keying. A harmonic detecting scheme based on BP neural network[J]. Power System Protection and Control, 2013, 41(17): 44-48.
- [17] 郑小霞, 刘庆强, 林顺富, 等. 面向非干预式负荷监测的居民负荷微观特性研究[J]. 电力系统保护与控制, 2014, 42(10): 62-70.
ZHENG Xiaoxia, LIU Qingqiang, LIN Shunfu, et al. Research of the microscopic signatures of residential loads for NILM[J]. Power System Protection and Control, 2014, 42(10): 62-70.
- [18] 王好娜, 毕志周, 付志红, 等. 基于 BP 神经网络和线性神经网络的间谐波分析方法[J]. 高压电器, 2013, 49(2): 19-24.
WANG Haona, BI Zhizhou, FU Zhihong, et al. Analysis approach for inter-harmonic with BP neural network and linear neural network[J]. High Voltage Apparatus, 2013, 49(2): 19-24.
- [19] 徐志钮, 律方成. 基于 RPROP 神经网络的电力系统谐波分析[J]. 电力系统保护与控制, 2011, 39(15): 13-16.
XU Zhiniu, LÜ Fangcheng. Power system harmonic analysis based on RPROP ANNs[J]. Power System Protection and Control, 2011, 39(15): 13-16.

收稿日期: 2015-10-16; 修回日期: 2015-12-17

作者简介:

李如意(1965-), 男, 硕士, 高工, 研究方向为机电控制及自动化; E-mail: liry_2005@126.com

王晓换(1985-), 女, 硕士, 从事电能仪表行业项目管理工作; E-mail: wangxiaohuan@xjgc.com

胡文山(1980-), 男, 通信作者, 博士, 副教授, 研究方向为网络化控制系统。E-mail: wenshan.hu@whu.edu.cn

(编辑 葛艳娜)