

基于长短时神经网络的居民负荷曲线分解方法

黄佳凌¹, 林顺富^{1,2}, 詹银枫¹, 刘持涛³, 李东东¹

(1. 上海电力大学 电气工程学院, 上海 200090; 2. 上海市智能电网需求响应重点实验室, 上海 200063; 3. 国网上海市电力公司青浦供电公司, 上海 201700)

摘要:面向居民家庭的非侵入式负荷监测,提出一种基于开关事件和长短时神经网络的居民负荷曲线精确分解方法。采用差分算法对居民家庭的总有功功率数据进行计算,采用硬阈值函数滤除差分数据的噪声,通过差分数据突变点实现电器开关事件的准确检测。进一步采用长短时神经网络进行电器负荷曲线数据的预测,可从总负荷曲线中逐一提取出单一电器的负荷曲线,实现居民家庭总负荷功率曲线电器级别的精确分解。通过实验测试数据和参考能量分解公开数据集(REDD)验证了所提方法的有效性。

关键词:非侵入式负荷监测;负荷曲线分解;长短时神经网络;差分;负荷开关事件

中图分类号:TM28 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed23392

Method of Residential Load Profile Decomposition Based on Long Short-term Memory Network

HUANG Jialing¹, LIN Shunfu^{1,2}, ZHAN Yinfeng¹, LIU Chitao³, LI Dongdong¹

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Shanghai Key Laboratory of Smart Grid Demand Response, Shanghai 200063, China;

3. Qingpu Electricity Supply Company of State Grid Shanghai Municipal Electric Power Company, Shanghai 201700, China)

Abstract: Aiming to the non-intrusive load monitoring (NILM) of residential households, a method of load profile decomposition based on the appliance switching events and the long short-term memory networks (LSTM) was proposed. The difference-summation algorithm was performed on the total active power data of a residential household, and the hard threshold function was used to filter the noise of the obtained difference-summation data, so as to accurately detect the switching events with extracting the abrupt change of the difference-summation data. Furthermore, the LSTM method was adopted to forecast the data of the power profile, and the power profile of each individual appliance was extracted from the total power profile of the residential household to realize the appliance-level profile decomposition. The validity of the proposed method was verified by the experimental data and the reference energy disaggregation dataset (REDD).

Key words: non-intrusive load monitoring (NILM); load profile decomposition; long sort-term memory networks(LSTM); difference-summation; load switching event

城乡居民生活用电量在全社会用电量的占比逐年提高。随着智能电网在全球电力工业中的发展与应用^[1], 家庭用户内部电器使用信息的感知与获取成为近年的研究热点。家庭电器使用信息可以让电力公司进一步了解居民负荷组成情况, 有助于节能措施的实施和电网经济运行。传统的侵

入式负荷监测需要为每个居民电器安装智能插座等分离式传感装置, 成本高且不便于维护^[2]。美国麻省理工大学的Hart教授提出的非侵入式负荷监测技术有可能通过家庭总功率、总电流等数据来获取家庭中每个电器耗电数据^[3]。由于基于非侵入式负荷监测(non-intrusive load monitoring, NILM)

基金项目:国家自然科学基金(51977127);上海市科学技术委员会资助项目(19020500800);

上海市教育发展基金会和上海市教育委员会“曙光计划”(20SG52)

作者简介:黄佳凌(1995—),女,硕士,Email:jorinehuang@163.com

通讯作者:林顺富(1983—),男,博士,教授,Email:shunfulin@shiep.edu.cn

技术的居民家庭监测设备具有低成本、易维护的优点,近年来受到广泛的关注^[4]。

非侵入式负荷监测技术主要包括三个技术环节:负荷开关事件检测、负荷特征提取和负荷辨识^[2],其中负荷开关事件检测是重要的基础和前提。当前,负荷开关事件检测方法有谱图理论算法^[5]、双边累加求和算法^[6-7]、小波分解算法^[8]、自适应粒子群算法^[9]及二分递推奇异值分解算法^[10]等。其中,文献[10]提出的二分递推奇异值分解算法能有效降低开关事件检测的漏检、误检率,但是,该方法基于汉克尔矩阵变换和奇异值分解,运算量大且对硬件设备要求高,不便于应用在低成本的监测终端中。

基于开关事件检测和长短时神经网络将家庭总有功功率曲线分解,可以获得单一电器的耗电数据。基于此耗电数据,用户可以改变用电习惯以节约电费;电网公司制定合理的需求响应策略,实现削峰填谷。家庭总有功功率曲线电器级别的分解将是非侵入式监测技术中的研究热点。文献[11]基于暂态功率波形和功率变化量作为负荷特征,利用动态时间规整(dynamic time warping, DTW)和聚类算法与历史波形数据库对比后得到相似事件集,得到开关事件的检测后,最终实现负荷分解。但上述两篇文献均只实现了能量的分解。文献[12]将电器根据运行状态数分布分类并选择负荷分解的方式,对于多状态电器使用双向长短期记忆网络和树结构 Parzen 估计算法进行优化参数,对于单一状态的电器则引入电流、功率作为负荷特征,最后使用多层感知器和极大似然估计分解出负荷的耗能量。该算法实现了单一电器曲线分解。

综上所述,本文提出一种基于开关事件和长短时神经网络的居民家庭负荷曲线分解方法,还原组合功率曲线中单一负荷的运行曲线,计算出其耗电量,同时提出一种基于差分和方法的非侵入式负荷开关事件检测方法。首先,基于差分和方法检测居民家庭总有功功率曲线中的突变特征,并采用硬阈值函数滤除细节信号的噪声,实现突变点位置的准确检测;其次,利用居民电器组合开关模型和长短时神经网络对多负荷功率曲线进行负荷曲线分解;最后,用实验测试数据和 REDD 数据库对所提方法进行验证,与已有算法进行分析对比,结果证明所提方法具有更高的准确性。

1 差分 and 开关事件检测

总有功功率是检测负荷开关事件的重要分析对象,其伴随着用电设备电流、电压值的变化而产生相应的变化,在居民负荷开关状态变化时存在着突变点^[7]。因此,负荷开关事件的检测即为总有功功率曲线中突变点的检测。

1.1 差分 and 数学定义

差分是研究离散数学的一种算法,是对离散信号求微分运算,反映了离散量之间的一种变化。差分可以分为前向差分 ΔP^+ 和后向差分 ΔP^- ,差分 and 信号 $S(i)$ 定义为

$$S(i) = \begin{cases} P(i+1) - P(i) & i=1 \\ P(i) - P(i-1) & i=N \\ \sum_{k=1}^H [P(i+k) - P(i) + P(i) - P(i-k)] & \text{其它} \end{cases} \quad (1)$$

其中

$$H = \begin{cases} i-1 & 1 < i < \omega \\ \omega & \omega < i < N - \omega \\ N-i & N - \omega < i < N-1 \end{cases} \quad (2)$$

式中: P 为居民家庭有功功率; i 为采样点序号($i=1, 2, 3, \dots, N$); N 为采样总点数; H 为以某一时间点为中心的最大差分半径; ω 为局部分析窗口长度。

1.2 差分 and 开关事件检测步骤

基于差分 and 算法的开关事件检测流程图如图1所示。




图1 差分 and 算法流程图

Fig.1 Flow chart of difference summation method

具体步骤如下:

1) 对居民负荷总有功功率 P 进行差分 and 运算,得到差分 and 信号 $S(i)$;

2) 对 $S(i)$ 进行硬阈值滤波,得到全新的差分 and 信号 $S'(i)$;

3)对 $S'(i)$ 中所有的值进行判断,若为变号零点,则为负荷开关事件。

1.3 开关事件检测评价指标

选用混淆矩阵^[11]来评估负荷开关事件检测的准确率,如表1所示。表中,1为真,0为假。

表1 混淆矩阵

Tab.1 Confusion matrix

		检测值	
		1	0
真实值	1	TP	FN
	0	FP	TN

真阳性(true positive, TP)表示算法检测出开关事件存在,真实情况中也发生开关事件;假阴性(false negative, FN)表示算法未检测出开关事件,而真实情况发生开关事件,即漏检事件;假阳性(false positive, FP)表示算法检测出开关事件,而真实情况未发生开关事件,即误检事件;真阴性(true negative, TN)表示算法中未检测出开关事件,真实情况也未发生开关事件。

同时,引入真阳性率(true positive rate, TPR)、准确率(accuracy rate, PR)、F1分数和绝对时间偏差(absolute time deviation, ATD)4个指标,如下式所示:

$$a_{\text{TPR}} = \frac{\text{TP}}{\text{TP} + \text{FN}} \in [0, 1] \quad (3)$$

$$a_{\text{PR}} = \frac{\text{TP}}{\text{TP} + \text{FP}} \in [0, 1] \quad (4)$$

$$a_{\text{F1}} = 2 \frac{a_{\text{TPR}} a_{\text{PR}}}{a_{\text{TPR}} + a_{\text{PR}}} \quad (5)$$

$$a_{\text{ATD}} = \sqrt{\frac{\sum_{i \in T} [t(i) - \hat{t}(i)]^2}{T}} \quad (6)$$

式中: $t(i)$ 为所有TP样本中负荷真实开关时刻; $\hat{t}(i)$ 为所有TP样本中算法检测出的开关时刻; T 为数据总时长。

如果 a_{TPR} 越大, a_{PR} 越大, a_{F1} 越大,而 a_{ATD} 越小,则说明检测算法的综合评价越好。

2 开关事件匹配模型

开关事件匹配模型是指将组合数据中同一类型负荷开和关事件的匹配。由于负荷类型辨识工作非讨论重点,在此不过多阐述。开关事件匹配模型可以还原负荷运行的真实情况,了解负荷使用先后顺序。

2.1 负荷开关事件匹配方法

恒功率负荷指在运行工作时,功率稳定输出的负荷。对于恒功率负荷,其运行周期及工况相

对稳定。检测到开事件后,可直接与后续开关事件中出现的第一个同类型负荷的关事件匹配。

变功率负荷的运行周期及工况均不稳定。在某一个运行周期中,常出现多个干扰事件,则选取这一运行周期内最后一个同类型负荷的关事件匹配检测到的开事件。根据实验室采集数据,典型负荷运行周期如表2所示。以变功率负荷空调举例说明,检测到空调的开事件后,在28 800 s内以检测到的最后一个空调关事件匹配该开事件。

表2 典型负荷数据的运行周期

Tab.2 Operation cycle of typical load data

负荷类型	是否为恒功率负荷	周期/s
电水壶	是	180 ~ 360
饮水机	是	60 ~ 120, 600 ~ 900
微波炉	是	10 ~ 600
智能HI电饭煲	否	2 700 ~ 3 600
洗衣机	否	600 ~ 3 600
空调	否	3 600 ~ 28 800

2.2 开关事件匹配步骤

开关事件匹配具体步骤如图2所示。具体步骤如下:

- 1)对开关事件集合进行开与关事件判断;
- 2)若为开事件,记录该开事件负荷类型,若为关事件,则返回判断下一个开关事件;
- 3)根据开事件负荷类型,判断其是否为恒功率负荷;
- 4)若为恒功率负荷,则匹配开关事件集合中该开事件后的第一个同类型负荷关事件;若为非线性变功率负荷,则匹配开关事件集合中该类型负荷运行周期内的最后一个关事件。




图2 开关事件匹配流程图

Fig.2 Flow chart of switch event matching

3 长短时神经网络负荷曲线分解

3.1 长短时神经网络

长短时神经网络(long short-term memory networks, LSTM)是基于循环神经网络(recurrent neural network, RNN)的一类特殊神经网络,可解决RNN中出现的长期依赖问题。长短时神经网络的内部构造中含有4个相互交错的神经网络层,分别为遗忘层、输入层、更新层和输出层。其具体计算过程如下:

1)遗忘层最终传递信息 f_t 表示为

$$f_t = \sigma(W_f[h_{t-1} \ x_t] + b_f) \quad (7)$$

式中: σ 为sigmoid函数; W_f 为遗忘层的权重向量; $[h_{t-1} \ x_t]$ 为将先前输出信息与当前输入信息结合成一个信息向量; b_f 为遗忘层的偏置项。

2)输入层最终更新信息 i_t 和候选信息 $\tilde{C}_t$ 表示为

$$i_t = \sigma(W_i[h_{t-1} \ x_t] + b_i) \quad (8)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1} \ x_t] + b_c) \quad (9)$$

式中: W_i, W_c 为输入层两个函数的不同权重向量; b_i, b_c 为输入层两个函数的偏置项。

3)更新层最终输入下一层的信息 C_t 表示为

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (10)$$

式中: C_{t-1} 为先前单元信息。

4)输出层是决定最后的输出信息,最后输出中间信息 o_t 和输入下一单元的信息 h_t 表示为

$$o_t = \sigma(W_o[h_{t-1} \ x_t] + b_o) \quad (11)$$

$$h_t = o_t \tanh(C_t) \quad (12)$$

式中: W_o 为输出层的权重向量; b_o 为输出层的偏置项。

3.2 负荷曲线分解流程

差分法和长短时神经网络的负荷曲线分解流程图如图3所示。具体由以下4步组成:

1)根据开关事件集合和负荷总功率数据 P 选择数据样本 X ,划分训练集和验证集;

2)对训练集和验证集进行归一化处理;

3)进行神经网络训练,当误差值或者训练次数满足判定条件后,停止训练,得到预测的负荷数据;

4)利用预测的负荷数据和开关事件进行负荷曲线分解,得到单一负荷曲线。

3.3 负荷曲线分解评价指标

文献[13-14]均采用功率分解准确率和能量分解准确率作为非侵入式负荷分解的评价指标。功率分解准确率的公式表示为




图3 负荷曲线分解流程图

Fig.3 Flow chart of load curve decomposition

$$a_{\text{power}} = \left[1 - \frac{\sum_{t \in T} |P(t) - \hat{P}(t)|}{2 \sum_{t \in T} P(t)} \right] \times 100\% \quad (13)$$

式中: $\hat{P}(t)$ 为 t 时刻功率的估计值; $P(t)$ 为 t 时刻功率的实际值。

能量分解准确率的公式表示为

$$a_{\text{energy}} = \left[1 - \frac{|\sum_{t \in T} P(t) - \sum_{t \in T} \hat{P}(t)|}{2 \sum_{t \in T} P(t)} \right] \times 100\% \quad (14)$$

式中: $\sum_{t \in T} P(t)$ 为 T 时段所消耗电能的实际值, $\sum_{t \in T} \hat{P}(t)$ 为 T 时段所消耗电能的估计值。

4 实验室数据验证

在实验室内利用泰克P5201电压采集设备和泰克A622电流探头采集各类负荷的数据,每秒钟连续采集10个周期,每个周期64个数据点,每秒钟总共640个数据点。所采集的电器共5种:电水壶、电饭锅、饮水机、微波炉和空调。在实验算法中,通过实验室实验数据,选择差分和分析窗口长度 ω 的值为3。

4.1 差分和开关事件检测

4.1.1 单个线性恒功率负荷开关事件检测

以恒功率电水壶为例,叙述所提差分和分析的检测过程。电水壶开启时,有功功率曲线出现第1个突变点,开启时刻为17 s;关闭时,有功功率曲线出现第2个突变,关闭时刻为186 s。功率曲线如图4a所示。对电水壶的有功功率数据进行差

分和计算,获得差分信号如图4b所示。




图4 电水壶有功功率曲线和差分信号图

Fig.4 Active power curves and difference summation signal figure of electric kettle

在电水壶开关时刻,差分信号出现对应的变号零点,开启时刻为17.5 s,关闭时刻为186.5 s。

将所提算法(方法4)与滑动双边累积和(cumulative sum, CUSUM)算法^[6-7](方法1)、小波分解算法^[8](方法2)和奇异值分解(singular value decomposition, SVD)分解算法^[10](方法3)进行对比。

采用非参数化的滑动双边 CUSUM 变点检测方法对电水壶的开关事件进行检测,设定阈值 $h=80$ W,当功率变化值 E_n 超过阈值 h 时,则判定出现开关事件,其开启事件结果局部图如图5所示,此方法检测出电水壶的开启时刻为18 s,关闭时刻为186 s。




图5 CUSUM算法检测结果局部图

Fig.5 Partial details of the detection results of the CUSUM algorithm

采用具有二阶消失矩阵的 Daubechies 2号小波^[8]对电水壶的有功功率曲线进行分解,得到细节信号 w_1 ,同时采用硬阈值滤波函数对细节信号进行过滤。如图6所示,小波分解在四个尺度细节信号中可识别的突变点位置并不相同,所以得到的检测结果也不一致,增加了漏检、误检的可能性,同时也无法保证开关时刻的准确率。

SVD 分解算法^[10]是一种基于二分递推奇异值分解的突变点检测方法,用不同层次空间的细节信号体现原始信号的突变点特征,图7为SVD 四层^[10]信号分解后的细节信号图,其在开关事件处出现明显的变号零点,此方法检测出电水壶的开启时刻为17.5 s,关闭时刻为186.5 s。




图6 小波分解四个尺度细节信号图

Fig.6 Detailed signal diagram at four scales of wavelet transform




图7 SVD细节信号图

Fig.7 Detailed signal diagram of SVD

使用4种方法对电水壶开关事件进行检测,结果如表3所示。

表3 电水壶开关事件检测结果对比

Tab.3 Comparison of detection results of electric kettle

	TP	FN	FP	$a_{TPR}/\%$	$a_{PR}/\%$	a_{F1}	a_{ATD}/s
方法1	2	0	1	100	66.67	80.00	0.71
方法2	2	0	1	100	66.67	80.00	1.50
方法3	2	0	0	100	100.00	100.00	0.50
方法4	2	0	0	100	100.00	100.00	0.50

4.1.2 单个非线性变功率负荷开关事件检测

非线性变功率负荷的运行工况比较复杂,在实际应用中为开关事件检测的一个难点。以非线性变功率负荷空调数据为例,图8为实验室测试环境下的空调有功功率曲线图。




图8 空调总有功功率曲线

Fig.8 Active power curve of air conditioner

由图8可知,空调的运行特性较明显,空调开启后,出现多次上升突变,且呈现一个爬坡状态,增加了检测难度,这使得绝对时间偏差的计算无法准确进行,选择第一个突变点作为开启时刻,同时在表4中我们只选用其中3个评价指标。

表4 空调开关事件检测结果对比

Tab.4 Comparison of detection results of air conditioner

	TP	FN	FP	$a_{TPR}/\%$	$a_{PR}/\%$	a_{F1}
方法1	11	1	139	91.67	7.30	13.52
方法2	5	7	12	41.67	29.41	34.48
方法3	7	5	2	58.33	77.78	66.67
方法4	11	1	0	91.67	100.00	95.65

由表4可知,对于空调这样运行工况复杂的负荷,方法1出现了多次误检事件;方法2出现了多次漏检事件;方法3和方法4相比,所提方法4的 a_{TPR} 、 a_{PR} 和 a_{F1} 均大于方法3。因此,方法4在这四种方法中综合评价最高。

4.1.3 组合负荷开关事件检测

为说明算法流程,选用实验室测量的较为理想的负荷组合场景,负荷类型及开关顺序如图9所示。




图9 组合场景功率曲线图

Fig.9 Power curve of the combined scene

用四种方法分别对组合场景进行检测分析,结果如表5所示。当检测时刻与真实开关时刻的绝对误差大于3 s时,视为漏检。

表5 组合场景开关事件检测结果对比

Tab.5 Comparison of detection results of combination scene

	TP	FN	FP	$a_{\text{TPR}}/\%$	$a_{\text{PR}}/\%$	a_{F1}	a_{ATD}/s
方法1	7	1	8	87.50	46.67	60.87	0.00
方法2	7	1	3	87.50	70.00	77.78	1.83
方法3	7	1	0	87.50	100.00	93.33	0.00
方法4	8	0	1	100.00	88.89	94.12	0.00

同时,对仿真算法运行时间进行对比,使用Inter(R)Pentium(R)CPU G3250@3.20GHz 3.20GHz 64位计算机,每种方法做5组实验,最后取平均值。最后,4种方法所耗时间分别为:0.046 s, 0.364 s, 0.642 s, 0.241 s。结合表3~表5和运行耗时可知,在检测准确度较高的方法3与方法4中,方法4的耗时小于方法3,并且在仿真算法中具有更简单的程序,方法3运算所占内存更大,应用于多用户终端时,方法4的适用性更强。

4.2 负荷曲线分解仿真及算法对比

4.2.1 长短时神经网络负荷曲线分解

为了说明提取方法,以4.1.3节中所提理想组合场景的曲线作为分析对象,提取微波炉的功率曲线,如图10所示。利用长短时神经网络对功率曲线空缺部分(图10b黑色表示部分)进行预测填补,再将总功率曲线与填补后的曲线进行相减,即可通过该两条曲线提取出单一负荷的运行曲线。




图10 应用于负荷曲线分解的长短时神经网络

Fig.10 Application of load curves decomposition of LSTM

4.2.2 单一负荷曲线分解

用所提方法对单一负荷电水壶、电饭锅、微波炉和空调进行负荷曲线分解,并计算出评价指标功率分解准确率和能量分解准确率。

表6显示,对于线性负荷的曲线分解,所提方法的功率分解准确率和能量分解准确率都达到99%,而对于非线性负荷,准确率也达到96%。

表6 单一负荷的功率分解准确率和能量分解准确率

Tab.6 Accuracies of power and energy estimation of a single load

负荷类型	$a_{\text{power}}/\%$	$a_{\text{energy}}/\%$
电水壶	99.99	99.99
电饭锅	99.96	99.84
微波炉	99.12	99.12
空调	96.95	96.92

4.2.3 组合数据负荷分解

对4.1.3节中所提组合场景进行负荷曲线分解,将分解后的单一负荷曲线和原始功率曲线进行叠加对比,如图11所示。




图11 长短时神经网络在组合场景下的负荷曲线分解图

Fig.11 Load curves decomposition diagram of the combined scene of LSTM

4.2.4 与线性差值算法对比

为了说明所提负荷曲线分解算法的准确度,采用线性插值(linear interpolation, LI)的方法提取单一负荷曲线,分解结果如图12所示。




图12 线性插值负荷曲线分解图

Fig.12 Load curves decomposition diagram of linear interpolation

对比图11和图12,可以看出,利用长短时神经网络分解出的各个单一负荷功率曲线更平稳。

表7展示了LSTM与LI的功率分解和能量分解的结果。对比结果显示,在组合场景下,LSTM也具有明显的优势,每一种负荷的准确率均在90%以上。

表7 组合场景下的功率分解准确率和能量分解准确率

Tab.7 Accuracies of power and energy decomposition of load combination scene

负荷类型	$a_{\text{power}}/\%$		$a_{\text{energy}}/\%$	
	LI	LSTM	LI	LSTM
电水壶	93.10	97.60	93.30	97.60
微波炉	79.60	99.00	80.60	99.30
饮水机	85.90	99.00	86.40	90.40
均值	86.20	98.50	86.80	95.80

5 REDD数据库验证

REDD数据集单个负荷有功功率采样时间每个相隔3s,对于其中缺失的数据,因为小于2min的数据缺失主要由无线传输的故障导致,可直接使用线性插值法补全数据^[11]。选用REDD数据库中的低频功率数据进行验证,由于不涉及负荷辨识,因此本次验证将用负荷1、负荷2、负荷3代表不同的负荷。REDD数据功率曲线图如图13所示。




图13 REDD数据功率曲线图

Fig.13 Power curve of REDD data

分别用四种方法对REDD数据库中60min的负荷功率数据进行开关事件检测,检测结果如表8所示。

表8 REDD数据开关事件检测结果对比

Tab.8 Comparison of detection results of REDD data

	TP	FN	FP	$a_{\text{TPR}}/\%$	$a_{\text{PR}}/\%$	$a_{\text{FI}}/\%$	a_{ATD}/s
方法1	52	8	34	86.67	60.47	71.24	1.32
方法2	59	1	19	98.33	75.64	85.51	1.78
方法3	60	0	1	100.00	98.36	99.17	0.41
方法4	59	1	0	98.33	100.00	99.15	0.57

重复进行5次实验,并记录下运算时长,最后求出平均值,四种方法所耗时间分别为:0.056 s, 0.599 s, 3.347 s, 0.393 s。结合表8可以看出,相对于方法1和方法2,方法3、方法4有效提高了检测精度,并且更为准确地还原了负荷开关的具体时刻,然而方法3运行时间明显长于方法4,应用于实际情况时,方法4会使设备运行更快,能有效节约时间和设备使用内存。

REDD数据的功率分解准确率和能量分解准确率如表9所示。由结果可以看出,相比于LI方法,所提分解算法对于复杂混合功率曲线具有更好的分解效果,再次证明所提方法的有效性。

表9 REDD数据下的功率分解准确率和能量分解准确率

Tab.9 Accuracies of power and energy estimation of REDD data

负荷类型	$a_{\text{power}}/\%$		$a_{\text{energy}}/\%$	
	LI	LSTM	LI	LSTM
负荷1	97.50	99.70	97.70	99.90
负荷2	90.90	96.30	96.30	97.80
负荷3	42.60	88.20	67.90	96.80
均值	77.00	94.70	87.30	98.20

6 结论

针对当前负荷开关事件检测算法准确度不高、实用性差的问题,利用负载特征及开关响应特征,提出一种基于差分和计算的检测方法。差分和检测负荷开关事件算法可降低现有方法的漏检,提高负荷开关事件发生时刻的检测准确率,并在此基础上,提高了运行速度,减小了程序运算内存,针对未知负载也具有的检测准确度,在实际情况下具有更好的适用性。同时,为了分解出总有功功率下单一负荷的曲线,提出一种基于开关事件匹配和利用长短时神经网络的负荷曲线分解方法。基于开关事件匹配和长短时神经网络的负荷曲线分解可将混合负荷曲线较为精确地分解成单一负荷曲线,并计算出单一负荷的耗能。最后,通过实验数据和REDD数据库验证了方法的有效性。

由于不涉及负荷辨识,下一步将完善负荷辨识的方法,提高辨识的准确率,在此基础上开展闭环非侵入式检测系统研究,同时,跟进实际设备产品的研发与应用。

参考文献

- [1] 王彤,许晓彦,吴明明.家庭储能系统的两级功率变化器研究[J].电气传动,2019,49(7):38-42.

Wang Tong, Xu Xiaoyan, Wu Mingming. Research on two stage

- power converter of home energy storage system[J]. *Electric Drive*, 2019, 49(7): 38-42.
- [2] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. *电网技术*, 2016, 40(10): 3108-3117.
- Cheng Xiang, Li Linzhi, Wu Hao, *et al.* A survey of the research on non-intrusive load monitoring and disaggregation[J]. *Power System Technology*, 2016, 40(10): 3108-3117.
- [3] 刘耀先, 孙毅, 李彬, 等. 基于边缘嵌入深度学习的非侵入式负荷分解方法[J]. *电网技术*, 2019, 43(12): 4329-4336.
- Liu Yaoxian, Sun Yi, Li Bin, *et al.* Non-intrusive load disaggregation method based on edge embedded deep learning[J]. *Power System Technology*, 2019, 43(12): 4329-4336.
- [4] 燕续峰, 翟少鹏, 王治华, 等. 深度神经网络在非侵入式负荷分解中的应用[J]. *电力系统自动化*, 2019, 43(1): 126-137.
- Yan Xufeng, Zhai Shaopeng, Wang Zhihua, *et al.* Application of deep neural network in non-intrusive load disaggregation[J]. *Automation of Electric Power Systems*, 2019, 43(1): 126-137.
- [5] 彭显刚, 郑凯, 林哲昊, 等. 基于谱图理论的居民用户侵入式负荷分解[J]. *电网技术*, 2018, 42(8): 2674-2680.
- Peng Xiangang, Zheng Kai, Lin Zhehao, *et al.* Non-intrusive residential load monitor based on spectral graph theory[J]. *Power System Technology*, 2018, 42(8): 2674-2680.
- [6] 周明, 宋旭帆, 涂京, 等. 基于非侵入式负荷监测的居民用电行为分析[J]. *电网技术*, 2018, 42(10): 3268-3274.
- Zhou Ming, Song Xufan, Tu Jing, *et al.* Residential electricity consumption behavior analysis based on non-intrusive load monitoring[J]. *Power System Technology*, 2018, 42(10): 3268-3274.
- [7] 曲禾笛, 李坚, 张志豪, 等. 服务于用电设备的快速辨识边缘检测方法研究[J]. *中国电机工程学报*, 2018, 42(15): 4566-4575.
- Qu Hedi, Li Jian, Zhang Zhihao, *et al.* Study of fast identification edge detection method for electrical equipment[J]. *Proceedings of the CSEE*, 2018, 38(15): 4566-4575.
- [8] Gills J M, Chung J A, Morsi W G. Designing new orthogonal high-order wavelets for non-intrusive load monitoring[J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(3): 2578-2589.
- [9] 孙毅, 张璐, 赵洪磊, 等. 基于动态自适应粒子群算法的非侵入式家居负荷分解方法[J]. *电网技术*, 2018, 42(6): 1819-1826.
- Sun Yi, Zhang Lu, Zhao Honglei, *et al.* A non-intrusive household load monitoring method based on dynamic adaptive particle swarm optimization algorithm[J]. *Power System Technology*, 2018, 42(6): 1819-1826.
- [10] 林顺富, 于俊苏, 李东东, 等. 基于二分递归SVD分解的居民电器开关事件检测方法[J]. *电网技术*, 2020, 44(4): 1534-1542.
- Lin Shunfu, Yu Junsu, Li Dongdong, *et al.* Method of switching events detection of residential appliances based on binary recursive SVD decomposition[J]. *Power System Technology*, 2020, 44(4): 1534-1542.
- [11] 赵文清, 张诗满, 李刚. 基于聚类和相关分析的居民用户非侵入式负荷分解[J]. *电力自动化设备*, 2020, 40(6): 8-19.
- Zhao Wenqing, Zhang Shiman, Li Gang. Non-intrusive load decomposition of residential users based on cluster and association analysis[J]. *Electric Power Automation Equipment*, 2020, 40(6): 8-19.
- [12] 罗平, 樊星驰, 章坚民, 等. 基于电器运行状态和深度学习的非侵入式负荷分解[J]. *电力系统自动化*, 2021, 45(12): 49-56.
- Luo Ping, Fan Xingchi, Zhang Jianmin, *et al.* Non-intrusive load decomposition based on operation state of electrical appliances and deep learning[J]. *Automation of Electric Power System*, 2021, 45(12): 49-56.
- [13] 任文龙, 许刚. 基于深度序列翻译模型的非侵入式负荷分解方法[J]. *电网技术*, 2019, 44(1): 27-34.
- Ren Wenlong, Xu Gang. Non-intrusive load decomposition method based on deep sequence translation model[J]. *Power System Technology*, 2019, 44(1): 27-34.
- [14] Wittmann F M, Camilo L J, Rider M J. Non-intrusive load monitoring algorithm using mixed-integar linear programming[J]. *IEEE Transactions on Consumer Electronics*, 2018, 64(2): 180-187.

收稿日期: 2021-04-21

修改稿日期: 2021-05-12