

基于电器运行状态和深度学习的非侵入式负荷分解

罗平¹, 樊星驰², 章坚民¹, 李俊杰¹

(1. 杭州电子科技大学自动化学院, 浙江省杭州市 310018; 2. 杭州电子科技大学圣光机联合学院, 浙江省杭州市 310018)

摘要: 根据不同电器运行状态数的差异,将电器分为状态复杂和状态简单2类。状态复杂电器存在多种工作状态,且前后状态有逻辑关联。因此,利用非基于事件的方法,选择能考虑过去和未来运行状态变化的双向长短期记忆网络对其进行分解,并采用树结构Parzen估计算法选择该网络的超参数以提高训练的精度。状态简单电器仅有开关状态,故利用基于事件的方法获得其投切状态,并选择多层感知器网络识别对应电器种类。最后,利用极大似然优化模型求解电器的功率序列。利用参考能量分解数据集对所提方法进行验证,结果表明该方法增强了负荷分解模型的可拓展性和抗噪声能力,在一定程度上提高了负荷分解的精度。

关键词: 深度学习; 双向长短期记忆网络; 多层感知器网络; 超参数优化; 非侵入式负荷分解

0 引言

随着电网中可再生能源渗透率的逐渐提高,需求侧响应作为提高电网运行安全性和经济性的重要手段,越来越得到重视^[1]。为了引导用户有效参与需求侧响应项目,须深入了解用户的用电行为。非侵入式负荷监测(non-intrusive load monitoring, NILM)技术能实时监测用户的用电行为,且设备安装成本低、用户接受度高,已成为实现用户和电网友好互动的重要技术手段^[2]。NILM的实质是将总功率序列进行分解以获得各电器的功率序列^[3]。现有的NILM技术可分为2类:基于事件和非基于事件的方法。两者的区别在于是否需要事件检测过程^[4-5]。

基于事件的方法需先进行事件检测,然后利用分类算法完成负荷识别,最后求解功率序列完成负荷分解。文献[6]通过聚类对数据库中获取到的事件进行标签处理,最后以V-I轨迹作为负荷特征,利用神经网络完成负荷识别。文献[7]以滑动窗检测到的有功功率突变值来判定事件是否发生,选择奇次谐波电流为特征,利用基于自适应增强的反向传播神经网络完成负荷识别。文献[8]提出了一种结合经验规则和统计检验的混合事件检测方法,有效

解决事件检测中的噪声影响,并利用无监督密度聚类算法对获取到的事件进行标签处理,最后通过电器的有功和无功功率对标签进行命名。文献[9]对电器总有功功率进行二分递推奇异值,通过计算奇异熵确定分解层数,并利用硬阈值滤波函数对信号进行滤波,实现事件检测。基于事件的方法运算速度相对较快,但对多状态负荷识别效果相对较差。

非基于事件的方法往往将电器的状态作为变量,通过模式识别的方法实现各电器状态和功率与总功率序列间的匹配。较常见的方法为隐马尔可夫模型(hidden Markov model, HMM)及其变种。文献[10]基于HMM建立相应的电器模型,并通过深度神经网络和高斯估计获得与总功率匹配的电器功率序列。但此类方法的计算量随电器数量的增加呈指数增长。对此,学者们提出了将状态矩阵稀疏化的方法来降低计算的复杂度^[11]。此外,非基于事件的方法还包括利用各种深度学习算法直接对负荷功率进行分解^[12];将各电器的运行状态用状态码表示,并将待分解总信号与电器状态码在深度序列翻译模型上进行映射训练^[13];基于多目标进化算法的分解框架来实现负荷分解^[14]等。非基于事件的方法可以有效处理多状态负荷,但速度较慢,求解模型复杂,不能有效应对电器数较多的场景。

本文以家庭用户为例,根据不同电器的运行状态数将其分为状态复杂和状态简单电器2类,分别选用非基于事件和基于事件的负荷分解方法进行处理。对每个状态复杂电器单独构建一个双向长短期记忆(bidirectional long short-term memory,

收稿日期: 2020-09-29; 修回日期: 2021-01-14。

上网日期: 2021-03-12。

浙江省自然科学基金资助项目(LY20E070004); 国家自然科学基金资助项目(51777047); 已申请国家发明专利(申请号: 202010278775.0)。

BiLSTM)网络,并利用树结构Parzen估计(tree-structured Parzen estimator, TPE)算法^[15]对网络的超参数进行优化。而对状态简单电器在事件检测的基础上,构造一个多层感知器(multilayer perceptron, MLP)网络进行识别,并利用极大似然估计得到对应电器的功率序列。最后,利用参考能量分解数据集(reference energy disaggregation data set, REDD)^[16]对算法进行了验证。

1 负荷分解流程

具体的负荷分解流程主要包括:电器分类、特征提取、深度学习网络搭建与训练以及基于深度学习网络的各电器功率序列的获取,如图1所示。由于

状态复杂或状态简单是电器的自身特性,不受用户行为影响^[4]。因此,首先根据聚类结果对电器进行分类,然后对不同类型的电器选择对应特征向量和深度神经网络进行训练。为了提高BiLSTM网络的性能,对其内部神经元的个数 R 和学习率 L ,这2个超参数进行优化。将待分解的总功率序列 P 输入已训练好的BiLSTM网络中,即可得到状态复杂电器 j 对应的功率序列 $P_{com,j}$ 。利用 P 和 $P_{com,j}$ 得到状态简单电器的总功率序列 P_{sim} ,对该序列进行事件检测,将提取到的负荷特征输入已训练好的MLP网络中得到电器 j 的状态序列 s_j ,利用极大似然估计求取对应状态简单电器 j 的功率序列 $P_{sim,j}$,从而完成所有电器的负荷分解过程。




图1 模型构建和负荷分解流程

Fig. 1 Process of model construction and load decomposition

2 电器模型

2.1 电器分类

状态复杂电器指运行时会出现多个工作状态的电器,如洗衣机在运行时会有蓄水、清洗和甩干等状态。状态简单电器是只有开启状态 s_{on} 和关闭状态 s_{off} 的电器,如照明灯。

为了获取各电器状态个数,本文利用无须事先给定聚类中心的仿射传播(affinity propagation, AP)算法^[17]对电器的历史有功功率数据进行聚类,获得各电器的状态个数和各状态对应的功率均值 μ 与标准差 σ 。依电器状态个数判断电器所属类别。

2.2 负荷特征选取

由于状态复杂电器的运行状态较多,利用基于

事件的方法难以判别检测到的事件是电器投切抑或电器运行状态间的切换。因此,本文对其采用非基于事件的方法,选择有功功率作为深度学习网络输入的负荷特征。

状态简单电器的事件类型仅有电器投切,因此,利用基于事件的方法进行求解。本文利用对数似然比(log likelihood ratio, LLR)检验检测器^[18]对 P_{sim} 进行检测。假设前后窗内的功率服从高斯分布,该检测器对各时刻前后的稳态区域取窗。定义 L_t 为LLR对应的比值,其反映了当前时刻功率 P_t 更属于前窗或后窗,如果 P_t 和前后窗吻合度相似,则 L_t 接近0,表示无事件发生;当 $|L_t| > \theta$ (θ 为阈值)时,则认为此时有电器投切。以检测准确率最优为目标,利

用黄金分割法对 θ 在推荐取值范围 $[0, 10]$ 中进行搜寻,最终选择 $\theta = 2$ 。

选择投切前后总负荷电流的基波和3、5、7次谐波及状态简单电器为开启状态 s_{on} 时的总有功率作为状态简单电器深度学习网络输入的负荷特征。对投切前后总负荷电流的变化量进行快速傅里叶分解即可得到总负荷电流的谐波分量^[19]。附录A图A1展示了不同的奇次谐波电流叠加后得到的电流波形图。从图A1可以看出,叠加到7次谐波后,再叠加更高次的奇数谐波对波形的影响很小。

2.3 电器模块化

现有的深度学习算法在应用NILM时往往利用回归模型或分类模型训练一个网络。当家庭中加入新电器时,整个网络需要重新搭建和训练。因此,本文对每一个状态复杂电器都单独构造一个深度学习网络。而状态简单电器因其负荷特征为总电流的谐波,故将所有状态简单电器构建为一个电器模块。假设家庭中包含 D 个状态复杂电器,则本算法包含 $D+1$ 个电器模块。当有新的状态复杂电器加入时,只要添加一个新电器模块即可,无须修改已经训练好的电器模块。

3 深度学习神经网络的选择和构建

BiLSTM网络是结合了前、后向长短期记忆(LSTM)网络而成的神经网络。它可通过学习样本数据中与此刻数据相关联的过去和未来时间段的信息,更好地训练网络,非常适合处理具有前后逻辑关联性的时序信息。因此,本文使用BiLSTM网络对状态复杂电器进行负荷分解。

而对于状态简单电器则选择结构简单、运行速度较快,并可有效处理时序问题的MLP网络来对其进行负荷分解。

3.1 构建BiLSTM网络

3.1.1 BiLSTM网络的结构

BiLSTM网络结构如图1所示。该网络包含输入层、隐藏层和输出层。隐藏层里每个节点都被一个记忆单元所代替,记忆单元按上下层排列^[20],其内部结构如图2所示。从图2可以看出,每个记忆单元由遗忘门、输入门、输出门和输入节点组成,对应的权重分别为 W_i 、 W_h 、 W_o 和 W_b 。

本文BiLSTM网络的输入层和输出层包含 $k+1$ 个神经元,隐藏层由 $2k+2$ 个记忆单元按上下层排列,其中 k 为输入向量的维数。上下层记忆单元同时进行运算,且内部神经元个数 R 和学习率 L_r 相同,但权重不同。

对给定电器的有功功率序列 P ,构造一个长度




图2 记忆单元内部结构
Fig. 2 Internal structure of memory unit

为 $k+1$ 的时间窗。从初始时刻开始,该时间窗会获得第1个功率序列 $P_1 = [P_1, P_2, \dots, P_{k+1}]^T$ 。将时间窗沿时间轴方向向前平移一个采样点,获得长度为 $k+1$ 的向量 $P_2 = [P_2, P_3, \dots, P_{k+2}]^T$ 。重复上述操作,最终形成 $T-k+1$ 个长度为 $k+1$ 的功率序列向量 $P = [P_1, P_2, \dots, P_k, \dots, P_{T-k+1}]$,其中 T 为终止时刻,滑动时间窗的处理使得网络能充分学习每个时刻电器功率的变化。

每个下层记忆单元的输入除 P_t 外,还有上一时刻的隐层状态 u'_{t-1} 和细胞状态 m'_{t-1} ;同理,每个上层记忆单元的输入除了 P_t 外,还有下一时刻的隐层状态 u'_{t+1} 和细胞状态 m'_{t+1} 。 u'_{t-1} 和 m'_{t-1} 在初始时刻时为零向量; u'_{t+1} 和 m'_{t+1} 在终止时刻为零向量。每个记忆单元的输出为当前时刻的隐层状态 u'_t, u''_t 及细胞状态 m'_t 和 m''_t 。电器模块 j 的网络输出为 $P_{com,j}$ 。

3.1.2 BiLSTM网络超参数优化

BiLSTM网络中有各种超参数,如 L_r 、 R 、丢弃比率等,超参数的取值会在不同程度上影响网络性能。有研究^[21]表明, L_r 和 R 对网络性能即模型损失值的影响最大,甚至决定网络是否能够收敛。因此,本文选用TPE算法对超参数 L_r 和 R 进行优化,其他超参数则根据网络训练过程中模型损失值的变化情况在文献[21]建议的取值范围内进行设置。

构造一个关于超参数的向量 $v = [R, L_r]$,且超参数优化的目标函数为:

$$v^* = \underset{v \in \mathcal{X}}{\operatorname{argmin}} f(v) \quad (1)$$

式中: $f(v) = y$ 为需最小化的目标,文中为网络输出

的功率预测值和实际值的归一化均方根误差(normalized root mean square error, NRMS); $\mathbf{v}^*$ 为最佳超参数组合; χ 为超参数的搜索空间。

TPE 算法并非直接对式(1)进行求解, 而是最大化预期改进(expected improvement, EI)指标。EI 指标的定义为:

$$E_{y^*}(\mathbf{v}) = \int_{-\infty}^{y^*} (y^* - y) F(y|\mathbf{v}) dy \quad (2)$$

式中: y^* 是根据 $D = \{[v_1, y_1], [v_2, y_2], \dots, [v_Q, y_Q]\}$ 中 y 的中位数来确定, 其中 v_Q 和 y_Q 分别为第 Q 组超参数和其对应的 NRMS 值; $F(y|\mathbf{v})$ 为给定 NRMS 下 $\mathbf{v}$ 的概率, 其是未知的。

$$F(\mathbf{v}|\mathbf{y}) = \begin{cases} l(\mathbf{v}) & y < y^* \\ g(\mathbf{v}) & y \geq y^* \end{cases} \quad (3)$$

式中: $l(\mathbf{v})$ 和 $g(\mathbf{v})$ 为服从高斯混合模型的概率密度函数。

令 $\gamma = F(y < y^*)$, 由式(2)和贝叶斯公式 $F(\mathbf{v}) = F(\mathbf{v}|\mathbf{y})F(\mathbf{y})$ 可得:

$$F(\mathbf{v}) = \gamma l(\mathbf{v}) + (1 - \gamma)g(\mathbf{v}) \quad (4)$$

将式(3)和式(4)代入式(2)有:

$$E_{y^*}(\mathbf{v}) = \frac{\gamma y^* l(\mathbf{v}) - l(\mathbf{v}) \int_{-\infty}^{y^*} F(y) dy}{\gamma l(\mathbf{v}) + (1 - \gamma)g(\mathbf{v})} \propto \left[\gamma + \frac{g(\mathbf{v})}{l(\mathbf{v})} (1 - \gamma) \right]^{-1} \quad (5)$$

式(5)表明 $l(\mathbf{v})/g(\mathbf{v})$ 越大, $E_{y^*}(\mathbf{v})$ 也越大。因在每次迭代的过程中, 寻找具有最大 $E_{y^*}(\mathbf{v})$ 的 $\mathbf{v}^*$ 。将 $\mathbf{v}^*$ 和对应的 y 加入 D 并重新拟合 $l(\mathbf{v})$ 和 $g(\mathbf{v})$, 不断更新 $\max(l(\mathbf{v})/g(\mathbf{v}))$ 和 $\mathbf{v}^*$, 直到完成最大迭代次数。

3.2 构建 MLP 网络

MLP 网络是将单一感知器模型经多层叠加而形成的前馈神经网络^[22]。本文搭建的 MLP 网络输出层使用 sigmoid 激活函数, 使得网络输出一个概率向量。定义交叉熵损失函数作为网络误差评估指标, 在训练过程利用梯度下降法使该损失函数不断下降直至收敛, 并由此确定网络的权重参数。

本文搭建的 MLP 网络输入层包含 $a+1$ 个神经元 (a 为状态简单电器负荷特征向量的维数), 隐藏层神经元个数为 $2a+1$, 输入层和隐藏层都包含一个用于计算偏差的神经元, 输出层神经元个数为状态简单电器个数 M 。MLP 网络的超参数根据文献[23]中的推荐值进行设置, 其中 L_r 设定为 0.02, 隐藏层设置为 3 层。

MLP 网络的输入为状态简单电器 j 的特征向量 $\mathbf{x}_j = [x_{j,1}, x_{j,2}, \dots, x_{j,a}]$, 输出 $\mathbf{y} = [y_1, y_2, \dots, y_M]$ 为该负荷特征属于各状态简单电器的概率序列。 $\mathbf{y}$ 中最大值所对应的电器即为输入负荷特征所属的电器类别。根据事件检测时记录的时间点获得状态简单电器 j 的状态序列 $\mathbf{s}_j = [s_{j,1}, s_{j,2}, \dots, s_{j,T}]$, 该序列中仅包含 s_{on} 和 s_{off} 这 2 个状态。

3.3 求解状态简单电器功率序列

假设状态简单电器 j 在 s_{off} 状态消耗的功率为 0, s_{on} 状态时的有功功率服从均值为 μ_j 、标准差为 σ_j 的高斯分布^[24]。此时只要求解各状态简单电器在开启状态下消耗的功率。

利用极大似然估计构建对 P_{sim} 进行分解的求解模型^[10]如下。

$$\begin{cases} \max_{P_{M+1}, P_{M+2}, \dots, P_D} \sum_{j=M+1}^D \ln f_j(P_{sim,j,t} | s_{j,t}) \\ \text{s.t.} \quad \sum_{j=M+1}^D P_{sim,j,t} = P_{sim,t} \end{cases} \quad (6)$$

式中: $P_{sim,j,t}$ 为状态简单电器 j 在 t 时刻的功率; $P_{sim,t}$ 为 t 时刻所有状态简单电器消耗的总功率; $f_j(\cdot)$ 为状态简单电器 j 在 s_{on} 状态下的高斯概率密度函数; $f_j(P_{sim,j,t} | s_{j,t})$ 为状态 $s_{j,t}$ 下消耗功率为 $P_{sim,j,t}$ 的概率。求解此模型即可得到功率序列 $P_{sim,j}$ 。

4 算例分析

选用 REDD 中家庭 3 的数据作为本文训练和测试的主要数据^[16]。将前 90% 的功率和电流数据作为训练集和验证集, 其中训练集和验证集数据各占 1/2; 后 10% 的功率和电流数据作为测试集。

利用 Pytorch 搭建 BiLSTM 网络和 MLP 网络, 在一台配有 Nvidia RTX2080 GPU 的服务器上对其进行训练和测试, 每个网络所需的显存为 800 MB。

4.1 聚类结果

附录 B 图 B1 展示了对家庭 3 中各电器有功功率聚类的结果和不同状态聚类下的 μ 和 σ 。由图 B1 可知: 家庭 3 中的状态复杂电器有冰箱、电脑、热水器、洗衣机、微波炉、洗碗机。状态简单电器有卧室照明灯、大门照明灯、垃圾处理器、烟雾报警器。

家庭 3 中各状态简单电器运行时的有功功率为几瓦到十几瓦, 远小于状态复杂电器运行时几百到上千瓦的有功功率。这些电器运行时有功功率的差异性也间接证明了将电器进行分类处理的必要性。对于类似于变频空调的具有连续变化状态的电器(如洗碗机)仍可根据聚类后状态的个数来判定其分类。

4.2 评价指标

使用功率分解准确率 c_p 和能量分解准确率 c_e 作为本文算法性能的评价指标^[23]。

$$c_p = 1 - \frac{\sum_{t=1}^T |\hat{P}_{j,t} - P_{j,t}|}{2 \sum_{t=1}^T P_{j,t}} \quad (7)$$

$$c_e = 1 - \frac{|\hat{E}_j - E_j|}{2E_j} \quad (8)$$

式中: $\hat{P}_{j,t}$ 和 $P_{j,t}$ 分别为电器 j 在 t 时刻所消耗功率的预测值和实际值; $\hat{E}_j = \sum_{t=1}^T \hat{P}_{j,t}$ 和 $E_j = \sum_{t=1}^T P_{j,t}$ 分别为电器 j 在时间 T 内所消耗电能的预测值和实际值。

4.3 不同算法负荷分解准确率对比

选择文献[6-7, 10, 12]中的算法以及仅使用 BiLSTM 和 MLP 网络的算法与本文算法进行对比, 结果如表 1 所示。由于文献[6-7]和单独使用 MLP 网络算法不能直接分解出电器在每个时刻的功率, 故无法计算其 c_p 指标。附录 C 图 C1 和图 C2 展示了

本文算法具体的分解过程。附录 C 图 C3 给出了本文算法分解获得的功率数据和实际功率数据。由上述结果可知:

1) 本文算法 c_e 和 c_p 的均值分别为 99.14% 和 97.52%, 较其他算法分别高 1%~7% 和 2%~7%。

2) 文献[6-7]和 MLP 网络都使用基于事件的方法。文献[6]对大门照明灯和垃圾处理器以及文献[9]对垃圾处理器和烟雾报警器的 c_e 高达 100%。但对冰箱、电脑、微波炉、洗碗机识别的 c_e 不超过 90%, 这是由于这些电器谐波特征较为相似, 从而导致识别算法发生误判。

3) 文献[10, 12]和 BiLSTM 网络使用非基于事件的方法将所有电器一起构建模型, 极易将状态复杂电器低功率的待机状态和状态简单电器的开启状态发生混淆。如附录 C 图 C3 所示, 除电脑外, 其他状态复杂电器都有很长时间处于低功率待机状态, 这段时间的功率和状态简单电器运行时的功率 (0~10 W) 非常接近, 如热水器和大门照明灯。因此, 这些算法在总功率分解过程中, 容易将热水器的待机状态误认为是大门照明灯的开启状态。

表 1 不同算法负荷分解准确率对比
Table 1 Comparison of load decomposition accuracy with different algorithms

电器	$c_e/\%$						$c_p/\%$				
	本文算法	文献[6]	文献[7]	文献[10]	文献[12]	BiLSTM	MLP	本文算法	文献[10]	文献[12]	BiLSTM
冰箱	99.20	80.03	97.44	95.12	94.87	96.23	98.99	96.59	93.25	89.87	93.32
电脑	97.80	90.31	72.30	95.37	97.56	97.31	83.41	95.11	92.18	93.21	94.17
热水器	98.97	95.31	98.91	92.51	96.25	96.53	94.11	96.04	92.53	90.46	91.25
洗衣机	98.12	85.42	95.47	96.00	93.17	95.71	90.79	97.90	92.22	90.05	91.96
微波炉	99.74	95.64	83.11	95.80	96.71	93.04	98.51	97.23	92.07	94.88	90.02
洗碗机	99.17	75.04	90.65	95.64	96.35	94.68	98.55	96.00	93.34	92.34	90.05
卧室照明灯	99.91	98.10	99.17	88.31	95.62	98.05	99.60	99.24	85.81	91.05	96.28
大门照明灯	99.80	100.00	90.11	85.02	96.17	98.47	99.14	99.09	80.38	93.21	96.59
垃圾处理器	99.01	100.00	100.00	94.97	95.14	98.94	83.33	98.97	89.25	90.19	96.43
烟雾报警器	99.71	98.43	100.00	94.25	95.28	98.30	98.43	99.05	86.19	91.30	95.98
平均值	99.14	91.78	92.71	93.40	95.71	96.72	94.49	97.52	89.72	91.65	93.60

4.4 超参数优化前后负荷分解准确率对比

超参数优化的目的在于找到一组超参数向量, 使得 BiLSTM 网络在验证集上的 NRMS 最小。附录 D 图 D1 展示了所有状态复杂电器 BiLSTM 网络超参数优化的结果, 其中 N_{RMS} 为对应的 NRMS 值。由图 D1 可知, 经多次迭代后, 所有状态复杂电器的 N_{RMS} 均逐渐降低并收敛。

表 2 给出了本文算法中超参数优化前后 BiLSTM 网络对状态复杂电器分解的 c_e 和 c_p 。

从表 2 可以看出, 超参数优化后各状态复杂电

表 2 超参数优化前后算法性能对比
Table 2 Performance comparison of proposed algorithm before and after hyper-parameter optimization

电器	$c_e/\%$		$c_p/\%$	
	优化前	优化后	优化前	优化后
冰箱	97.22	99.20	94.43	96.59
电脑	96.88	97.80	95.60	96.11
热水器	96.79	98.97	95.31	96.04
洗衣机	98.09	98.12	96.34	97.90
微波炉	97.69	99.74	96.25	97.23
洗碗机	96.14	99.17	94.25	96.00

器的 c_e 和 c_p 较优化前上升了 1%~3%。

4.5 不同负荷特征下电器识别准确率对比

为了验证所选简单电器负荷特征的有效性,使用电器识别准确率 A_c 这一指标来对不同负荷特征的有效性进行评价。

$$A_c = \frac{A'_j}{A_j} \quad (9)$$

式中: A_j 为待识别电器 j 的负荷特征样本数; A'_j 为正确识别电器 j 的次数,对比结果如表 3 所示。其中,文献[7]选择了基波和 3、5、7、9 次电流谐波作为负荷特征。

表 3 不同负荷特征下电器识别准确率对比
Table 3 Comparison of identification accuracy of electrical appliances with different load characteristics

电器	$A_c/\%$			
	文献[7]	基波+3次谐波+功率	基波+3、5、7次谐波	本文算法
卧室照明灯	99.49	95.17	99.48	100.00
大门照明灯	100.00	96.04	99.69	99.89
垃圾处理器	100.00	100.00	99.03	100.00
烟雾报警器	99.17	100.00	98.93	100.00

由表 3 可知,几种算法识别状态简单电器的 A_c 都很高,最小的也超过 95%,但本文算法对 4 种电器的 A_c 几乎都是 100%,说明本文选择电流谐波和功率特征作为状态简单电器识别的负荷特征是合理的。

4.6 算法抗噪声能力对比

在数据集中加入高斯白噪声,噪声强度用信噪比(signal-to-noise ratio, SNR)来表示。用 R_{SN} 表示噪声强度, R_{SN} 越小则说明噪声越大。各算法的 c_e 与 R_{SN} 的关系如图 3 所示。




图 3 7 种算法抗噪声能力对比
Fig. 3 Comparison of anti-noise ability among seven algorithms

从图 3 可以看出,随着噪声强度的增加,各算法的 c_e 均减小。文献[10, 12]和 BiLSTM 算法在

24 dB 左右时 c_e 便开始减少;文献[7]和 MLP 算法在 20 dB 附近的 c_e 开始下降;而文献[6]和本文算法在 15 dB 时 c_e 才开始下降,说明这 2 种算法的抗噪声能力优于其他算法。在 SNR 从 15 dB 到 0 dB 的过程中,本文和文献[6]算法的 c_e 分别降低了 6% 和 8%,说明本文算法可提高模型的抗噪声能力。

4.7 算法可扩展性对比

随着居民生活水平不断提高,家庭电器的数量会不断增加。因此在家庭 3 中加入家庭 1 和家庭 2 的电器(共 10 个电器),研究不同算法可扩展性。对比网络训练时长 t_e 和电器增加后网络训练时长 t'_e ,判断增加新电器是否需要重新构建网络(需重新构建用 Y 表示,否则用 N 表示),结果如表 4 所示。

表 4 不同算法的可扩展性对比
Table 4 Scalability comparison of different algorithms

算法	t_e/h	t'_e/h	是否需要重新构建网络
本文算法	1	1.0	N
文献[6]	1	1.5	Y
文献[7]	1	1.5	Y
文献[10]	1	2.0	Y
文献[12]	1	2.0	Y
BiLSTM	1	3.0	Y
MLP	1	1.5	Y

由表 4 可知,除本文算法外,其他 6 种算法在新增状态复杂电器后网络的训练时长都有不同程度的增加,并且在新增电器时本文算法无须重新构建已经训练好的电器网络。

5 结语

由于不同的电器运行状态数不同,因此本文在 NILM 时将电器分成 2 类,并根据电器运行状态数的不同分别选择基于事件和非基于事件的方法分别对其进行负荷分解。对于多状态过程的状态复杂电器利用能有效学习前后状态变化过程的 BiLSTM 网络及贝叶斯框架下的 TPE 算法来优化该网络的超参数;对于仅有开关 2 个状态的状态简单电器,在进行事件检测后,考虑使用投切前后总电流的基波、奇次谐波和有功功率组成负荷特征,使用 MLP 网络和极大似然估计进行负荷分解。

仿真结果表明,本文算法的 c_e 和 c_p 指标平均值都优于文献中的其他算法。同时,整体分解结果的稳定性高于其他算法,未出现某几个电器分解准确率极低的问题。此外,抗噪声能力和对状态复杂电器的可扩展性也优于其他算法。因此,本文算法具有更好的负荷分解效果,而且模块化的处理可以极

大减少新电器加入时训练网络的工作量。

但本文模型依赖用户的先验数据,后续可考虑与厂家合作调研市场上热销电器的电压、电流和功率特性,并通过深度学习的方法在云端建立各电器的运行模型库,利用迁移学习得到不同家庭的电器模型库,从而获得模型中所需的先验数据。此外,还可以考虑对简单电器也进行模块化处理,进一步提高算法的拓展性。

本文在撰写过程中得到国电南瑞科技股份有限公司科技项目(综合能源系统仿真评估关键技术研究)的资助,特此感谢!

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参考文献

- [1] CORBETT J, WARDLE K, CHEN C. Toward a sustainable modern electricity grid: the effects of smart metering and program investments on demand-side management performance in the US electricity sector 2009—2012[J]. IEEE Transactions on Engineering Management, 2018, 65(2): 252-263.
- [2] HART G W. Non-intrusive appliance load monitoring [J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [3] 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.
- [4] 邓晓平, 张桂青, 魏庆来, 等. 非侵入式负荷监测综述[J/OL]. 自动化学报 [2020-09-07]. <https://doi.org/10.16383/j.aas.c200270>.
DENG Xiaoping, ZHANG Guiqing, WEI Qinglai, et al. A survey on the non-intrusive load monitoring [J/OL]. Acta Automatica Sinica [2020-09-07]. <https://doi.org/10.16383/j.aas.c200270>.
- [5] 武昕, 于金莹, 彭林, 等. 基于用户边缘侧事件解析的工业电力负荷非侵入式感知辨识[J]. 电力系统自动化, 2021, 45(4): 29-37.
WU Xin, YU Jinying, PENG Lin, et al. Non-intrusive perception and identification of industrial power load based on event analysis on user edge [J]. Automation of Electric Power Systems, 2021, 45(4): 29-37.
- [6] HASAN T, JAVED F, ARSHAD N. An empirical investigation of *V-I* trajectory based load signatures for intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2014, 5(2): 870-878.
- [7] 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.
- [8] 徐志翔. 基于机器学习的非侵入式负荷监测技术研究[D]. 杭州: 浙江大学, 2020.
XU Zhixiang. Research on the non-intrusive load monitoring based on machine learning[D]. Hangzhou: Zhejiang University, 2020.
- [9] 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.
- [10] 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): 126-132.
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): 126-132.
- [11] MAKONIN S, POPOWICH F, BAJIC I V, et al. Exploiting HMM sparsity to perform online real-time nonintrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2016, 7(6): 2575-2585.
- [12] TONGTA A, CHOORUANG K. Long short-term memory (LSTM) neural networks applied to energy disaggregation [C]// International Electrical Engineering Congress, March 4-6, 2020, ChiangMai, Thailand: 1-4.
- [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, 2020, 44(1): 27-34.
REN Wenlong, XU Gang. Non-intrusive load decomposition method based on deep sequence translation model [J]. Power System Technology, 2020, 44(1): 27-34.
- [14] 杨立余, 陈昊, 黎明, 等. 非侵入式电力负荷多目标分解框架[J]. 电力系统保护与控制, 2020, 48(6): 100-107.
YANG Liyu, CHEN Hao, LI Ming, et al. A framework for non-intrusive load monitoring using multi-objective evolutionary algorithms [J]. Power System Protection and Control, 2020, 48(6): 100-107.
- [15] BERGSTRA J, BARDENET R, BENGIO Y, et al. Algorithms for hyper-parameter optimization [C]// 25th Annual Conference on Neural Information Processing Systems, December, 2011, Granada, Spain: 1-9.
- [16] KOLTER J Z, JOHNSON M J. REDD: a public data a set for energy disaggregation research [C]// SustKDD Workshop, 2011, San Diego, USA.
- [17] FREY B J, DUECK D. Clustering by passing messages between data points[J]. Science, 2007, 315(5814): 972-976.
- [18] CONZALEZ M E B. A framework for enabling energy-aware facilities through minimally-intrusive approaches [D]. Pittsburgh, USA: Carnegie Mellon University, 2010.
- [19] LE T T H, KANG H, KIM H. Household appliance classification using lower odd-numbered harmonics and the bagging decision tree [J]. IEEE Access, 2020, 8: 55937-55952.
- [20] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks [C]// IEEE

- International Conference on Acoustic, October 21, 2013, Piscataway, USA.
- [21] MONTAVON G, ORR G B, MULLER K R, et al. Neural networks: tricks of the trade[M]. New York, USA: Springer-Verlag Berlin Heidelberg, 2012.
- [22] CAGLI E, DUMAS C, PROUFF E. Convolutional neural networks with data augmentation against jitter-based countermeasures [C]// International Conference on Cryptographic Hardware and Embedded Systems, September 25-27, Taipei, China: 45-68.
- [23] MAVROKEFALIDIS C, AMPELIOTIS D, VLACHOS E, et al. Supervised energy disaggregation using dictionary-based modelling of appliance states[C]// PES Innovative Smart Grid Technologies Conference Europe, October 9-12, 2017, Ljubljana, Slovenia.
- [24] KONG W, DONG Z, MA J, et al. An extensible approach for non-intrusive load disaggregation with smart meter data [J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3362-3372.
- 罗 平(1978—),女,通信作者,博士,副教授,硕士生导师,主要研究方向:能源互联网的优化调度、智能用电与需求响应。E-mail:luoping@hdu.edu.cn
- 樊星驰(1997—),男,硕士研究生,主要研究方向:非侵入式负荷分解。E-mail:fandy1117@163.com
- 章坚氏(1962—),男,教授,博士生导师,主要研究方向:智能电网信息物理系统建模与态势感知可视化、信息安全与防护。E-mail:zhangjmhcn@hdu.edu.cn
- (编辑 王梦岩)

Non-intrusive Load Decomposition Based on Operation State of Electrical Appliances and Deep Learning

LUO Ping¹, FAN Xingchi², ZHANG Jianmin¹, LI Junjie¹

(1. School of Automation, Hangzhou Dianzi University, Hangzhou 310018, China;

2. School of ITMO Joint Institute, Hangzhou Dianzi University, Hangzhou 310018, China)

Abstract: According to the number of operation states of different electrical appliances, electrical appliances are divided into two types: complex-state and simple-state. Complex-state electrical appliances have multiple working states, and the prior and subsequent states are logically related. Therefore, a non-event-based method is adopted and the bidirectional long short-term memory network considering past and future operation state changes is chosen to decompose the load. In order to improve the training accuracy, the hyper-parameters of the network are chosen by using the tree-structured Parzen estimator algorithm. The simple-state electrical appliances only have on or off state, so the switching states are obtained by the event-based method. Then, the multilayer perceptron network is selected to identify the corresponding electrical appliance type. Finally, the maximum likelihood optimization model is used to solve the power sequence of the electrical appliances. The proposed method is verified by using the reference energy disaggregation data set. The results show that the method enhances the scalability and anti-noise ability of the load decomposition model, and improves the accuracy of the load decomposition to a certain extent.

This work is supported by Zhejiang Provincial Natural Science Foundation of China (No. LY20E070004) and National Natural Science Foundation of China (No. 51777047).

Key words: deep learning; bidirectional long short-term memory network; multilayer perceptron network; hyper-parameter optimization; non-intrusive load decomposition

