

基于设备特征多层优选和 CNN-NLSTM 模型的非侵入式负荷分解

王家驹¹, 王竣平¹, 白 泰¹, 张 然¹, 丁熠辉¹, 杨 林², 张 姝²

(1. 国网四川省电力公司计量中心, 四川 成都, 610045; 2. 四川大学电气工程学院, 四川 成都, 610065)

摘 要: 非侵入式负荷分解技术可以有效挖掘用户侧设备信息, 是电网开展用户负荷互动响应的基础。针对目前非侵入式负荷分解模型适应性较差及准确率较低等问题, 提出一种基于设备特征多层优选的非侵入式负荷分解模型。首先, 针对设备运行特性设计自适应滑动数据窗, 进而获取到更加完整的设备功率片段, 同时调整网络输入输出维度; 其次, 通过融合浅层卷积神经网络(CNN)与两层嵌套长短时记忆网络(NLSTM)提取并加深设备特征; 然后, 将其输入到改进的注意力机制中, 通过调配特征权重, 获得最优的设备特征序列; 最后, 在 REDD 数据集上进行实验分析, 通过对设备特征多层选择、加深与复用, 在减小训练时间的同时, 显著地提升负荷分解的准确率。

关 键 词: 非侵入式负荷分解; 自适应滑动窗; 卷积神经网络; 嵌套长短时记忆网络; 改进注意力机制

DOI: 10.19781/j.issn.1673-9140.2023.01.017 中图分类号: TM714 文章编号: 1673-9140(2023)01-0146-08

Non-intrusive load disaggregation based on multiple optimization of appliance features and CNN-NLSTM model

WANG Jiaju¹, WANG Junping¹, BAI Tai¹, ZHANG Ran¹, DING Yihui¹, YANG Lin², ZHANG Shu²

(1. Metering Center, State Grid Sichuan Electric Power Company, Chengdu 610065, China;

2. College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Non-intrusive load disaggregation technology can effectively mine the appliance information of customers, which is the basis to carry out interactive customer load response by the grid company. The conventional non-intrusive load disaggregation technology has several drawbacks, such as limited scope of application and low accuracy. In this paper, a non-intrusive load disaggregation model with multiple optimization selection of appliance characteristics is proposed. First, an adaptive sliding data window is designed for appliance operation characteristics to obtain a more complete power segment and to adjust the network input and output dimensions. Second, the appliance features can be extracted and deepened by fusing shallow convolutional neural networks (CNN) with two-layer nested long and short-term memory networks (NLSTM), which is further fed into an improved attention mechanism to obtain the optimum appliance feature sequence by adjusting the feature weights. Finally, experimental analysis on the REDD dataset shows that the multiple selection, deepening and reusing of appliance features can significantly improve the accuracy of load decomposition while reducing training time.

Key words: non-intrusive load disaggregation; adaptive sliding data window; convolutional neural network; nested long and short-term memory network; improved attention mechanism

收稿日期: 2022-02-17; 修回日期: 2022-04-13

基金项目: 国家电网四川电力公司科技项目(52199720003P)

通信作者: 张 姝(1988—), 女, 博士, 助理研究员, 主要从事负荷建模与调控研究; E-mail: ZS20061621@163.com

非侵入式负荷监测(non-intrusive load monitoring, NILM),又称作负荷分解^[1],可以将用户总耗电量分解为各个设备的功率片段,为用户及负荷聚合商提供清晰、充分的用电信息^[2]。NILM可以帮助居民用户降低至少15%的能源消耗^[3],还可用于设备故障检测、设计电费激励等。NILM最早由Hart于1992年提出^[4],仅需在用户总线入口安装测量点位,具有更加经济、有效的优点。经过长时间的发展与研究,NILM已日趋成熟。与此同时,深度学习在数字图像处理与识别、信号分析等领域已经获得快速发展,为数据处理提供了端对端的处理方案^[1]。文献[5]首次将深度学习应用在NILM任务上,采用长短时记忆网络(long short-term memory, LSTM)、降噪自动编码器(denoising autoencoder, DAE)和一种回归分析的神经网络在UK-DALE数据集上进行验证,在增加神经网络复杂度的代价下,取得了较传统方法更为优秀的分解效果;文献[6]提出序列到点模型,将网络的表达能力集中于输出的中点,以产生更加准确的分解效果,但在此过程未完全利用网络的计算能力;文献[7-8]分别在序列到序列模型(seq2seq)和序列到点模型(seq2point)上进行改进,为模型叠加复杂的时空注意力机制,虽然取得了较好的分解效果,但增加了网络复杂度与训练耗时;文献[9]利用深度循环长短期记忆网络的表征能力,自适应地解决设备数量增加出现的多维问题,取得了较为优越的分解效果。

为了获得更好的性能,网络的深度不断增加。同时,模型在训练过程中面临着梯度爆炸和梯度消失的退化问题^[10]。虽然现有的一些模型在简单设备的混合情况下可以获得良好的分解性能^[11],但在不同的目标设备或环境下迁移性差,并不能表现出较好的分解准确率。这是因为它们仅关注网络结构对当前设备的拟合性,没有针对设备特征进行自适应提取与应用。良好的设备特征序列可以使网络模型更具表征能力,在提升负荷分解准确率的同时,减少时间损耗。

针对此问题,本文对设备特征的提取、选择与加深,充分利用不同网络层的特性,在网络层中形成良好的特征流,从而达到更加准确、快速的负荷

分解效果。

本文将针对目标设备采用4次特征提取措施。首先,seq2seq^[12]、seq2point^[6]等模型通过神经网络模型学习总负荷与目标设备功率序列间的非线性关系。若采集时间较长,输入输出的数据量也会显著增加,造成时间与运算资源的损耗。通过对输入序列进行滑窗分割^[13]可以有效解决该问题。但目前多数模型的窗宽较为固定,不能有效针对目标设备进行调整,无法获得更加准确的分解效果。因此,本文通过设计自适应滑窗,根据设备特性对窗宽进行调节,以囊括更加完整的功率片段,并借此优化网络模型输入、输出维度。这样不仅可以减小网络复杂度,同时带来时间收益。其次,采用浅层卷积网络(convolutional neural networks, CNN)将经由滑窗输入的设备序列片段抽象化,提取包括时间特征、运行特征、使用特征等在内的各项隐含特征,并将逐层加深的设备特征流输入到两层嵌套长短时记忆网络(nested long short-term memory, NLSTM)内。由于NLSTM特有的内外存储单元,将进一步对时间特征进行强化记忆,并送入到改进的注意力机制内。最后,通过改进的注意力机制将原特征流与权值调配后的特征流融合,在增强全局特征的同时,有效地利用局部特征,从而较大程度提升负荷分解正确率。

该模型通过信号处理技术与神经网络层特性完成四层设备特征提取、加深与选择,与目前使用广泛的seq2point、seq2seq模型及基于注意力机制的seq2seq模型^[7]相比,取得了更加准确和快速的负荷分解效果。

1 算法原理

1.1 自适应设备滑窗

本文依据设备类型对窗宽自适应调整,以使滑窗分割得到的功率片段更加完整,这将利于模型学习设备功率序列与总负荷间的非线性映射关系。针对设备特性自适应更改滑窗窗宽,可以保证输入深度学习模型内的设备功率序列更具代表性,完成第一层设备特征的选择与加深。

自适应调整窗宽需要考虑原始数据的采样频

率,其决定着采集过程中负荷片段中的可用数据量。同时,若在预处理过程中使用欠采样,数据点数也会相应地更改。除开采样因素外,设备的类型也需要纳入考虑范围内,其独特的使用特征或者运行特征都将影响其正常运行的功率片段长度,则自适应滑窗宽定义为

$$W' = W \cdot f_s \cdot f_R + L_A \quad (1)$$

式中, f_s 为原始数据的采样频率; f_R 为欠采样频率(若不使用,则为1); W 为原始窗宽(一般取为599); L_A 为设备特性序列长度,其取决于设备的特征,其对应关系如表1所示。

表1 设备类别及 L_A 取值

Table 1 Appliance class and L_A value

设备类别	L_A	相关设备
永久激活	399	冰箱, 净水器
多状态运行	250~399	洗衣机
状态持续变化	0~250	空调
开/关两态	0	水壶, 白炽灯

1.2 CNN-NLSTM 模型

CNN-NLSTM 模型由 CNN、NLSTM^[14] 组成,其架构如图1所示。




图1 CNN-NLSTM 架构

Figure 1 CNN-NLSTM architecture

经由滑窗分割后的总负荷及目标设备功率片段输入到 CNN 中,经由 CNN 将多个时间点下的负荷数据抽象,对全局特征进行抽取并逐层加深,完成第2次设备特征的抽取与选择。设备特征继续输入到 NLSTM 中,根据其特性,对设备功率的时间特征进一步提取与加深,完成第3次设备特征的抽取、选择与融合。

LSTM 是典型具有改善梯度消失的记忆神经单元,能够较好地根据此前的经验知识对内部存储单元状态进行调整,完成对长短期记忆的自适应与使用。但是,在面对较长时间序列时,不能完成特征的整合与传递^[15]。而 NLSTM 则通过将 LSTM 单元进行嵌套,构成内外记忆单元,方便存储并随时提取长期的时间特征,其结构如图2所示。




图2 NLSTM 单元架构

Figure 2 NLSTM unit architecture

NLSTM 由内外两层存储单元嵌套而成,图2中虚线包裹的为内部存储单元。外部存储单元可随时访问并修改内部存储单元,二者共同完成与当前情景最为相关的长期信息的选择与存储,短暂的信息将会被遗忘,从而形成对目标设备长期时间特征的选择与强记忆。较传统的 LSTM 具有了更强的鲁棒性。

NLSTM 记忆单元的输入与隐藏状态的更新方式为

$$\tilde{h}_{t-1} = f_i \odot c_{t-1} \quad (2)$$

$$\tilde{x}_t = i_t \odot \sigma_c(x_t W_{xc} + h_{t-1} W_{hc} + b_c) \quad (3)$$

式(2)、(3)中, \tilde{h}_{t-1} 为 $t-1$ 时刻记忆单元的输出,其由激活函数 f_i 及存储单元状态 c_{t-1} 决定; \tilde{x}_t 为 t 时刻记忆单元的输入,其由外部数据输入 x_t 、输入到记忆权重 W_{xc} 、输出到记忆权重 W_{hc} 、 $t-1$ 时刻 NLSTM 单元的输出 h_{t-1} 、偏置 b_c 、激活函数 σ_c 及外部单元输入 i_t 计算得到。而传统的 LSTM 的记忆单元更新仅为

$$c_t = \tilde{h}_{t-1} + \tilde{x}_t \quad (4)$$

相较之下, NLSTM 可以对输入的信息及此前的记忆信息进行丰富的比对,并对其进行选择记忆。不同于 LSTM 纯粹的相加,它不仅可以节约运算资源,还能对长期时间特征进行强记忆,利于对设备特征的全局把控,从而提高负荷分解的准确率。

CNN-NLSTM 模型作为特征提取中重要一环,其输入输出维度取决于自适应设备滑窗窗宽 W' 。卷积层性能主要由卷积核个数、尺寸决定。卷积核

个数决定其提取特征的能力,个数较多时将可以提取到更多的特征。而过多将会导致过拟合,因为本模型卷积核个数逐层增加,提取到更加完整的设备特征。使用多种尺寸的卷积核可以有效捕捉数据的多尺度特征,弥补单尺度卷积层信息不足的缺陷,进一步提升模型性能。

NLSTM 仅需设置隐藏单元数,其值决定着对设备时间特征提取的能力,过大将涵盖较多的短时信息,过小将无法完整提取长时特征。故最终 CNN-NLSTM 模型各网络层参数设定如表 2 所示。

表 2 CNN-NLSTM 参数

Table 2 Parameters for CNN-NLSTM

网络层	参数	输出
input	(None, W')	(None, W')
conv1	30,10,步长为 1	(None, W' ,30)
conv2	40,8,步长为 1	(None, W' ,40)
conv3	50,5,步长为 1	(None, W' ,50)
NLSTM1	隐藏单元数:128	(None, W' ,256)
NLSTM2	隐藏单元数:128	(None, W' ,256)

1.3 改进注意力机制

注意力机制本质上是对特征权重的再次分配,将根据特征的重要性以调配不同的计算资源^[16],等同于对特征的再一次选择与复用。传统的注意力机制在完成对输入特征的偏好后,仅输出被偏好后的特征,此时的特征并没有完全结合目标设备,仅能代表其部分特征。为消除这种影响,本文通过对传统注意力机制的输入输出进行更改,将输入到注意力机制的特征与经注意力机制调配权值的特征进行融合,以达到更加准确的特征偏好,改进后的注意力机制架构如图 3 所示。

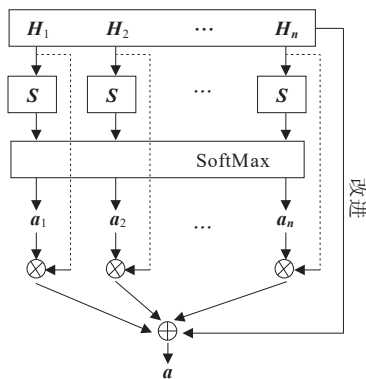


图 3 改进注意力机制架构

Figure 3 Improved attention mechanism architecture

其中, S 为注意力打分函数, a_i 构成的概率向量即为注意力分布, H_i 为前置 NLSTM 输出的特征流。

本文将经由 NLSTM 提取后的设备特征输入到注意力机制中,根据特征重要性分配不同权值,凸显全局特征,隐匿局部特征。但这一步骤可能会忽略某些特征的重要性,通过将输入注意力机制前后的特征融合,构成融合特征。此时的全局特征同样会更加明显,而局部特征也会占有一定权值,可以达到更加准确的特征提取与融合。

1.4 负荷分解流程

本文不依赖于对网络的加深与复杂化,合理地利用不同网络层特性,着眼于设备特征提取、选择与运用,逐步加深,进而提高负荷分解的准确率。同时,为了防止过拟合,在网络模型中添加随机辍学(dropout)机制。如图 4 所示,其完整的流程如下:

- 1) 根据设备类别自适应计算网络窗宽,增加对设备正常运行时功率数据的读入率;
- 2) 利用浅层 CNN 提取并加深设备特征,并将其流入 NLSTM 网络;
- 3) NLSTM 网络进一步加深其时间特征,将特征混合后流入改进注意力机制;
- 4) 改进注意力机制将原始特征与偏好特征再次融合,送入全连接层;
- 5) 全连接利用激活函数(linear)完成预测。

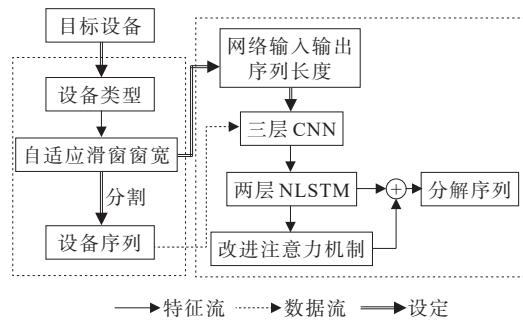


图 4 负荷分解算法流程

Figure 4 Load disaggregation algorithm process

2 实例分析

2.1 实验环境

本文硬件环境为 Intel(R) Core™ i9-9900K CPU @3.6 GHz, 32G DDR4 内存及 GeForce RTX 2080 Super(16 GB 显存)的 64 位计算机。软件平台

为 Windows-10 专业版操作系统, Python 3.6.2(64 位)及 TensorFlow 1.4 深度学习框架。

2.2 数据集

本文选取麻省理工学院 2011 年发布的 REDD 数据集^[17]进行模型的训练和测试,从 2011 年 4 月到 2011 年 5 月对 5 户美国家庭的总功率及常用设备的有功功率信息进行统计,总功率采样间隔为 1 s,设备采样间隔为 3 s。

本文将训练数据及测试数据完全分离,训练及测试样本选择如表 3 所示。

表 3 训练及测试集选取

Table 3 The selection for training and testing dataset

设备	训练	测试
冰箱	1,3,6	2,5
微波炉	1,3	2,5
洗衣机	1,3,4,6	2,5
洗碗机	1,3,4	2,5

利用 NILM-TK^[18]内的 Electric.get_activation() 从原始数据集中提取目标设备正常运行阶段时的各项指标,为了保证提取到的目标设备的功率片段与实际情况接近,各设备的激活参数如表 4 所示。

网络的输入序列样本由总数据滑窗分割得到,标签序列由设备级数据滑窗分割得到。在开始训练模型前,对每一对训练样本进行归一化,所有的训练及标签样本都减去均值。而后除以标准差,使得所有值均落在 $[0,1]$ 内,测试集同理。

表 4 REDD 负荷激活提取参数

Table 4 REDD parameters for extracting load activations

设备	W'/ 点	功率阈值/ W	功率均值/ W	功率方差/ W
冰箱	599	50	200	400
微波炉	200	200	500	800
洗衣机	500	20	400	700
洗碗机	450	10	700	1 000

2.3 评价指标

为了更加直观地对比各模型的性能表现,本文选取 F_1 分数、准确率 A_{cc} 、平均绝对误差 M_{AE} 作为评价模型的 3 个指标:

$$F_1 = 2 \times \frac{P_{re} \cdot R_{ec}}{P_{re} + R_{ec}} \quad (5)$$

$$A_{cc} = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (6)$$

$$M_{AE} = \frac{1}{T} \sum_{t=0}^T |\hat{y}_t - y_t| \quad (7)$$

精准率 P_{re} 及召回率 R_{ec} 分别为

$$P_{re} = \frac{T_P}{T_P + F_P} \quad (8)$$

$$R_{ec} = \frac{T_P}{T_P + F_N} \quad (9)$$

式(5)~(9)中, y_t 为 t 时刻目标设备的真实有功功率; \hat{y}_t 为 t 时刻模型的分解功率; M_{AE} 为时间 T 内分解值与真实值间的平均绝对误差,其值越小,分解值与真实值越接近,模型的拟合能力则越强; T_P 、 F_P 、 F_N 、 T_N 分别为真阳性、假阳性、假阴性与真阴性,其统计方式如图 5 所示。




图 5 T_P 、 F_P 、 F_N 、 T_N 统计方式


Figure 5 Statistics of T_P 、 F_P 、 F_N 、 T_N

2.4 负荷分解结果


本文选取 2、5 号家庭用电情况作为测试样本,将家庭总负荷输入到训练后的模型中,分解得到目标设备在每个采样点的有功功率。将 2 号家庭总功率序列输入到训练后的设备模型中,分解得到各设备功率序列,截取其中部分工作区间,真实功率与分解功率对比如图 6 所示,

由图 6 可知,对于选定的 4 种设备,本文模型负荷分解准确性较高,且跟踪趋势好。对于冰箱,虽然其出现了功率尖刺,但本文模型的功率分解值依然保持正常,这说明本文模型不存在过拟合现象,能够较好地保证分解功率的正确性。


2、5 号家庭所选取的设备相同,不重复展示其可视化结果,其中 2 号家庭设备序列数据共 150 181 条,5 号家庭设备序列数据共 183 544 条。经模型分解后的详细指标如表 5 所示。




(a) 洗衣机



(b) 洗碗机



(c) 冰箱



(d) 微波炉

图 6 2号家庭各用电器真实功率与模型分解功率对比

Figure 6 Comparison of actual working power and predicted working power of 4 electric appliances in house 2

表 5 不同测试集下指标对比

Table 5 Comparison of metrics under different test sets

设备	2号家庭			5号家庭		
	M_{AE}	A_{cc}	F_1	M_{AE}	A_{cc}	F_1
洗衣机	8.90	98.03	87.12	9.13	97.12	86.33
洗碗机	13.41	94.52	91.03	11.37	95.47	92.56
冰箱	8.60	96.47	90.34	8.45	96.99	90.85
微波炉	13.10	93.30	88.49	12.61	92.75	89.03

由表 5 可知,本文模型在完成训练后具有较好的迁移能力,能够在不同测试集中发挥出较好的分解效果,不存在对某一测试集过拟合现象。

2.5 性能对比

模型主体由自适应滑窗与 CNN-NLSTM 网络构成,改进的注意力机制优化了设备特征权值的分配,进一步提升了负荷分解的准确率。其中,微波炉、洗碗机与洗衣机的 M_{AE} 明显减小。冰箱由于其功率特性稳定且永久激活,设备特征提取完整,故指标提升不明显。加入注意力机制前、后的 M_{AE} 如图 7 所示, F_1 分数与 A_{cc} 如表 6 所示。




图 7 添加注意力机制前、后 M_{AE} 对比

Figure 7 Comparison of M_{AE} before and after adding the attention mechanism

表 6 添加注意力机制前、后 F_1 与 A_{cc} 对比

Table 6 Comparison of F_1 and A_{cc} before and after adding the attention mechanism



设备	F_1		A_{cc}	
	添加前	添加后	添加前	添加后
洗衣机	86.73	87.12	96.91	98.03
洗碗机	89.94	91.03	93.72	94.52
冰箱	90.19	90.34	96.25	96.47
微波炉	86.51	88.49	91.06	93.30

为了全面评价模型的整体性能,选取 RNN、GRU 算法、seq2seq、seq2point、基于注意力机制的 seq2seq 模型与本文算法进行对比,上述模型参数均按照原文献进行设定。各模型 M_{AE} 如表 7 所示。

表7 各模型 M_{AE} 对比Table 7 Comparison of each mode's M_{AE}

设备	各模型 M_{AE}					
	RNN	GRU	seq2seq	seq2point	文献[7]	本文
洗衣机	19.1	29.5	23.3	13.7	9.14	8.90
洗碗机	44.8	32.6	27.7	15.1	14.27	13.41
冰箱	38.4	28.8	28.1	23.8	12.61	8.60
微波炉	37.8	30.2	23.69	28.4	15.49	13.10

结果表明,相较于其他方法,本文模型的平均绝对误差更小,识别的准确率更高;而seq2point模型与基于注意力机制的seq2seq模型次之,能取得较好的负荷分解准确率。因此,本文着重选取这2种方法进一步对比分析,3种方法在 F_1 分数与 A_{cc} 的结果如图8所示。洗碗机在原基础上提高了对工作状态的准确判断,提升功率序列拟合程度;冰箱减少了对异常状态特征的提取;微波炉分解效果提升较为显著,能够稳定分解工作时功率;洗衣机进一步增加对正常工作时的有功功率的跟踪能力。

(a) F_1 分数(b) A_{cc} 图8 各模型 F_1 分数与 A_{cc} 对比Figure 8 Comparison of F_1 score and A_{cc} of each model

深度学习依赖于大量数据及网络结构,若其超参数众多,则造成训练时间的大量损耗。而轻量级模型超参数较小,时间损耗低,且迁移性更强。本文模型、seq2point模型与基于注意力机制的seq2seq模型在超参数数量和训练时间的对比如表8所示。模型的训练并未采用GPU加速^[20],故训练时间计量单位为min。训练后的模型可以直接用于实际使用,无需再次训练。

结果表明,本文模型相对于seq2point模型和基于注意力机制的seq2seq模型,可以较好地减少超参数数量和训练时间,并且保证较高的分解准确率。因此,本文模型不仅减少了运算资源与训练时间的消耗,而且保证了较高的负荷分解准确率。

表8 模型的超参数及训练时间对比

Table 8 Comparison of hyperparameters and training time of models

设备	本文		seq2point		文献[7]	
	训练参数	训练时间/min	训练参数	训练时间/min	训练参数	训练时间/min
洗衣机	29 044 153	49	30 708 249	61	31 321 199	167
洗碗机	26 164 153	37	30 708 249	61	31 321 199	99
冰箱	19 488 427	26	30 708 249	61	31 321 199	52
微波炉	5 363 653	12	30 708 249	61	31 321 199	86

3 结语

本文提出一种基于设备特征多层优选的非侵入式负荷分解方法。该方法仅需要将低频采样的设备有功功率序列数据经自适应滑窗送入CNN-NLSTM模型中,进行多次的特征选择与复用,并在输出前由改进注意力机制对其进行特征权重调配,达到更加高效准确的辨识。在整个模型中,总共实现了四层设备特征的选择与复用。该模型充分利用设备特征及网络层特性,大幅度减小训练参数。通过在REDD数据集进行实验,可以得到本文模型与目前使用广泛的seq2seq、seq2point模型以及基于注意力机制的seq2seq模型相比,有效提升了负荷辨识精度,并减少了网络模型复杂度,具有较好的普适性。未来可通过迁移学习进一步减少训练成本,增强模型的实用性。

参考文献:

[1] 邓晓平,张桂青,魏庆来,等.非侵入式负荷监测综述[J].

- 自动化学报,2022,48(3):644-663.
- DENG Xiaoping, ZHANG Guiqing, WEI Qinglai, et al. A survey on the non-intrusive load monitoring[J]. Acta Automatica Sinica,2022,48(3):644-663.
- [2] 杨世海,纪峰,曹晓冬,等.基于层次分析法和熵权法的非侵入式负荷辨识终端综合评价方法研究[J].电测与仪表,2021,58(4):17-23.
- YANG Shihai, JI Feng, CAO Xiaodong, et al. Study on comprehensive evaluation method of NILM terminal based on analytic hierarchy process and entropy weight method[J]. Electrical Measurement & Instrumentation, 2021,58(4):17-23.
- [3] 仲立军,周晓琴,顾曦华,等.基于负荷分解技术的小区电能替代需求分析[J].电力系统保护与控制,2021,49(17):147-153.
- ZHONG Lijun, ZHOU Xiaoqin, GU Xihua, et al. Non-intrusive load monitoring using low sampling-rate data for electric energy substitution demand analysis[J]. Power System Protection and Control,2021,49(17):147-153.
- [4] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE,1992,80(12):1870-1891.
- [5] KELLY J, KNOTTENBELT W. Neural NILM: Deep neural networks applied to energy disaggregation[C]// Proceedings of the 2nd ACM international conference on embedded systems for energy-efficient built environments, Seoul, South Korea, 2015.
- [6] ZHANG C, ZHONG M, WANG Z, et al. Sequence-to-point learning with neural networks for non-intrusive load monitoring[C]// Proceedings of the AAAI conference on artificial intelligence, Louisiana, USA, 2018.
- [7] 王轲,钟海旺,余南鹏,等.基于 seq2seq 和 Attention 机制的居民用户非侵入式负荷分解[J].中国电机工程学报,2019,39(1):75-83+322.
- WANG Ke, ZHONG Haiwang, YU Nanpeng, et al. Nonintrusive load monitoring based on sequence-to-sequence model with attention mechanism[J]. Proceedings of the CSEE,2019,39(1):75-83+322.
- [8] 徐晓会,赵书涛,崔克彬.基于卷积块注意力模型的非侵入式负荷分解算法[J].电网技术,2021,45(9):3700-3706.
- XU Xiaohui, ZHAO Shutao, CUI Kebin. Non-intrusive load disaggregate algorithm based on convolutional block attention module[J]. Power System Technology, 2021,45(9): 3700-3706.
- [9] KASELIMI M, DOULAMIS N, VOULODIMOS A, et al. Context aware energy disaggregation using adaptive bidirectional LSTM models[J]. IEEE Transactions on Smart Grid,2020,11(4):3054-3067.
- [10] 栗磊,王廷涛,殷浩然,等.基于 GWO-LSTM 与 NKDE 的变压器油中溶解气体体积分数点—区间联合预测方法[J].高压电器,2022,58(11):88-97.
- LI Lei, WANG Tingtao, YIN Haoran, et al. Point-interval joint prediction method of dissolved gas volume fraction in transformer oil based on GWO-LSTM and NKDE[J]. High Voltage Apparatus,2022,58(11):88-97.
- [11] 姚欣,邢砾云,辛平.基于小波特征提取与深度学习的微电网故障诊断与分类方法[J].智慧电力,2021,49(12):17-24.
- YAO Xin, XING Liyun, XIN Ping. Fault diagnosis and classification of microgrid based on wavelet feature extraction and deep learning[J]. Smart Power,2021,49(12): 17-24.
- [12] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[C]// Proceedings of the 27th International Conference on Neural Information Processing System, Montreal, Canada: ACM, 2014.
- [13] D'INCECCO M, SQUARTINI S, ZHONG M. Transfer learning for non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid,2019,11(2):1419-1429.
- [14] MONIZ J R A, KRUEGER D. Nested LSTMS[J]. PMLR, 2017,77:530-544.
- [15] LI Y, YU Z, CHEN Y, et al. Automatic seizure detection using fully convolutional nested LSTM[J]. International Journal of Neural Systems,2020,30(4):2050019.
- [16] XIA M, LIU W, XU Y, et al. Dilated residual attention network for load disaggregation[J]. Neural Computing and Applications,2019,31(12):8931-8953.
- [17] KOLTER J Z, JOHNSON M J. REDD: a public data set for energy disaggregation research[C]// Workshop on Data Mining Applications in Sustainability (SIGKDD), San Diego, Canada, 2011.
- [18] BATRA N, KELLY J, PARSON O, et al. NILMTK: an open-source toolkit for non-intrusive load monitoring[C]// Proceedings of the 5th international conference on Future energy systems, Cambridge, United Kingdom, 2014.
- [19] KRISTALAKOS O, NALMPANTIS C, VRAKAS D. Sliding window approach for online energy disaggregation using artificial neural networks[C]// Proceedings of the 10th Hellenic Conference on Artificial Intelligence, Patras, Greece, 2018.
- [20] 陈铨,阚博文,刘广一. GPU 技术的最新进展及其在电力系统中的应用前景探讨[J]. 电力信息与通信技术, 2018,16(3):16-25.
- CHEN Xuan, KAN Bowen, LIU Guangyi. The latest development of GPU and its prospective application in power system[J]. Electric Power Information and Communication Technology,2018,16(3):16-25.