

# 面向深度学习的非侵入式负荷监测研究进展<sup>①</sup>



张石清<sup>1,2</sup>, 王伟<sup>1</sup>, 钱亚冠<sup>1</sup>, 赵小明<sup>2</sup>, 杜磊<sup>2</sup>, 章为昆<sup>3</sup>

<sup>1</sup>浙江科技学院 理学院, 杭州 310023)

<sup>2</sup>(台州学院 智能信息处理研究所, 台州 318000)

<sup>3</sup>浙江万胜智能科技股份有限公司, 天台 317200)

通信作者: 张石清, E-mail: [tzczsq@163.com](mailto:tzczsq@163.com)

**摘要:** 非侵入式负荷监测, 是智能用电和节能技术的重要一部分, 备受研究者关注. 由于近年来新发展起来的深度学习方法在各种任务所表现出来的优越性能, 目前已有一些代表性深度学习方法被成功用于非侵入式负荷监测中的负荷分解任务. 为了系统地总结深度学习方法在非侵入式负荷监测领域中的研究现状与进展, 拟对近年来面向深度学习的非侵入式负荷监测研究文献进行分析与归纳. 首先对非侵入式负荷监测的框架进行简要概述; 随后介绍了非侵入式负荷监测的特征提取方法和公开数据集, 并重点分析和归纳了非侵入式负荷监测中面向深度学习的负荷分解方法; 最后对该领域存在的一些挑战及机遇进行了展望, 并指出了其未来的研究方向.

**关键词:** 非侵入式; 负荷分解; 特征提取; 深度学习

引用格式: 张石清,王伟,钱亚冠,赵小明,杜磊,章为昆.面向深度学习的非侵入式负荷监测研究进展.计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/8980.html>

## Deep Learning Based Non-intrusive Load Monitoring: Recent Advances and Perspectives

ZHANG Shi-Qing<sup>1,2</sup>, WANG Wei<sup>1</sup>, QIAN Ya-Guan<sup>1</sup>, ZHAO Xiao-Ming<sup>2</sup>, DU Lei<sup>2</sup>, ZHANG Wei-Kun<sup>3</sup>

<sup>1</sup>(School of Science, Zhejiang University of Science and Technology, Hangzhou 310023, China)

<sup>2</sup>(Institute of Intelligent Information Processing, Taizhou University, Taizhou 318000, China)

<sup>3</sup>(Zhejiang Wellsun Intelligent Technology Co. Ltd., Tiantai 317200, China)

**Abstract:** Non-intrusive load monitoring (NILM) is an important part of intelligent power utilization and energy saving techniques and has attracted extensive attention. Due to the superior performance of newly-developed deep learning methods in various tasks in recent years, some representative deep learning methods have been successfully applied to the load decomposition task in NILM. To systematically summarize the research status and progress of deep learning methods applied to NILM, this study focuses on analyzing and summarizing the research literature on deep learning based NILM in recent years. Firstly, the NILM framework is outlined, and then the feature extraction method and the public data set of NILM are introduced. In addition, the load decomposition methods based on deep learning in NILM are analyzed and summarized. Finally, the study points out several challenges in this field and provides an outlook on its opportunities and future research directions.

**Key words:** non-intrusive; load decomposition; feature extraction; deep learning

非侵入式负荷监测 (non-intrusive load monitoring, NILM), 这个术语最早是由 Hart<sup>[1]</sup> 在 1992 年提出的. 它是一种通过分析某个区域一段时间内总的用电功耗,

来获取该区域内单个负荷的状态和该负荷是否存在的方法. 与侵入式负荷监测相比, 它不需要对所检测的每一个用电设备安装监控装置就可以获取该电器的状

<sup>①</sup> 基金项目: 浙江省自然科学基金重点项目 (LZ22F020007)

收稿时间: 2022-07-17; 修改时间: 2022-08-15; 采用时间: 2022-09-21; csa 在线出版时间: 2022-11-18

态和功耗,是一种低成本、易于部署、可推广性强的监测方法,同时在一些方面加强了对客户隐私的保护.非侵入式负荷监测在实际应用中具有很高的价值:一方面,NILM提供的各种负荷的参数,能够帮助用户及时了解家用电器的详细使用情况,进而培养住户养成合理用电的习惯,从而达到降低电费,节能减排的目的<sup>[2,3]</sup>;另一方面,供电公司可以根据非侵入式负荷监测反馈的结果,精确了解各个用户的电力使用情况,并以此为依据为住户提供安全、精准的服务;此外,企业也可以根据反馈的结果对后续的生产策略进行调整,实现更高的产能和经济效益<sup>[4]</sup>.因此,NILM不仅可以帮助企业达到节能减排、降低成本的目的,还可以预防因用电器故障而引发的火灾,减少不必要的损失<sup>[5]</sup>.近些年国家大力推广节能减排、绿色发展的理念,这使得有关NILM研究备受研究者关注,已成为一个热门的研究课题<sup>[6]</sup>.

图1列出了一般的非侵入式负荷监测框架结构.由图1可知,非侵入式负荷监测包含3个主要的步骤:事件检测、特征提取和负荷识别.

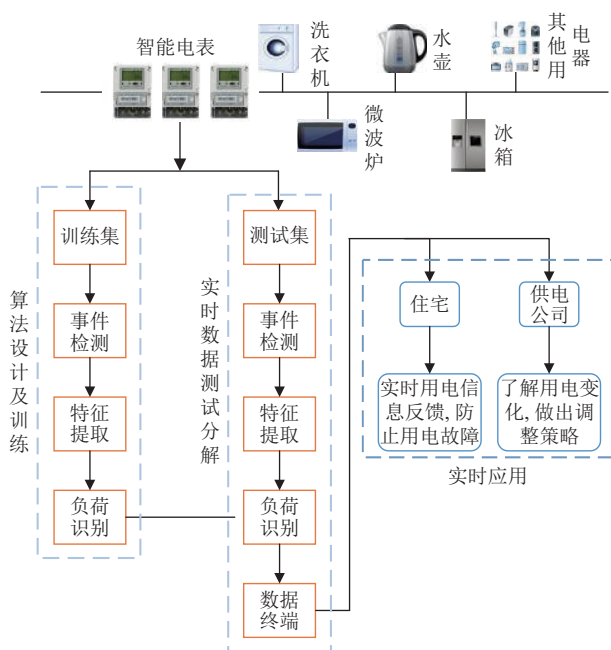


图1 非侵入式负荷监测框架

在非侵入式负荷监测系统中,事件检测是一个重要步骤,其中事件被定义为信号偏离先前的稳态并持续到下一个稳态的暂态变化过程<sup>[7]</sup>.因此,事件检测是指利用所提出的方法去检测负荷数据中这些变化的过

程<sup>[8]</sup>.根据检测方法的不同,事件检测方法可以分为专家启发式方法、概率模型和匹配滤波<sup>[9]</sup>.

专家启发式方法是基于一个事先设置的阈值去判断事件是否发生的方法<sup>[10]</sup>.例如,Hart<sup>[11]</sup>将平滑、归一化后的功率值按照事先设定的规则分割为稳态段和暂态段.然后,利用暂态段信号的平均绝对误差与事先设定的阈值进行比较,检测事件是否发生.但是,基于固定阈值的事件检测并不一定有效,因为功耗可能会根据设备的运行状态而变化.为了克服这个问题,Hamdi等<sup>[11]</sup>设计了一种基于自适应阈值的方法来比较稳态期间的功率样本,用于事件检测.然而,基于单一阈值的事件检测技术在受到功率信号波动或噪声的影响时可能会失效.为解决这一问题,Hamdi等<sup>[11]</sup>引入概率方法进行事件检测.

概率模型是指利用均值、标准差和方差等统计特征来判别负荷运行状态变化的一种方法.它一般采用广义似然比(generalized likelihood ratio, GLR)和卡方拟合优度和累积和(goodness-of-fit and cumulative sum, CUSUM)等方法进行事件检测.例如,De Baets等<sup>[12]</sup>设计了一种基于改进拟合优度(goodness-of-fit, GOF)和倒谱的事件检测模型,用于对负荷的运行状态进行了检测.除此以外,贝叶斯信息准则<sup>[13]</sup>和有效残差<sup>[14]</sup>等方法也被用于负荷的暂态事件检测<sup>[15]</sup>.其中,CUSUM方法在事件检测方面要优于其他算法.

匹配滤波方法是指将已知信号与未知信号相关联,以检测未知信号中相对应的事件是否存在的方法.Rueda等<sup>[16]</sup>基于匹配滤波器理论,使用平均滤波算法来实现事件的检测.在以上所述的事件检测方法中大部分都是基于单变量特征的,但是基于单一特征定义阈值的方法可能对于事件检测并不总是有效的.因此,Houidi等<sup>[17]</sup>设计了一种利用有功、无功功率、谐波等多种特征对事件检测的多元事件检测方法.通过在GLR、CUSUM、贝叶斯信息准则等事件检测算法上的实验证明该方法比单一特征输入方法有效.此外,近些年来一种混合事件检测的方法被运用于更精密的事件检测中<sup>[18,19]</sup>.例如,Zheng等<sup>[18]</sup>设计了一种基于密度的带噪声空间聚类应用(density-based spatial clustering of applications with noise, DBSCAN)事件检测模型,该模型使用时间戳和相邻的稳态波形对混合事件进行检测.实验证明,该混合事件检测算法优于传统的事件检测算法.

NILM 的第 2 个关键步骤是特征提取,它应用信号处理技术从电压 ( $V$ ) 和电流 ( $I$ ) 的测量值中提取一个能够唯一识别单个用电设备的特征. 根据电压 ( $V$ ) 和电流 ( $I$ ) 的采样率,特征提取类型包括稳态特征、暂态特征. 例如,有功和无功功率变化值<sup>[20]</sup>、电压-电流轨迹<sup>[21]</sup>和电流谐波<sup>[22]</sup>等属于稳态特征. 瞬时电流波形<sup>[23]</sup>、电压噪声<sup>[24]</sup>等属于暂态特征. 除此以外,为了更好地提取一些负荷信息,递归图<sup>[25]</sup>、电流波形有限状态机 (finite state machine, FSM)<sup>[26]</sup>、开启暂态能量等方法也相继被提出.

负荷识别是指采用现有的机器学习方法在所提取的设备特征上进行模型训练,以便从总的负荷数据中识别出特定设备的种类和运行状态,并对目标设备的功率进行估计的过程<sup>[27]</sup>. 到目前为止,负荷识别的方法可分为基于组合优化方法<sup>[28]</sup>和模式识别方法<sup>[29]</sup>. 其中,基于组合优化方法是将观测到的功率测量与可能对应的设备功率(特征库中已经存在)进行匹配,使得预测设备功率和观察到的总功率之和之间的差异最小化<sup>[30]</sup>. 然而,基于组合优化方法的一个主要缺点是,特征库中存在未知负荷,使得优化问题变得复杂化. 近些年,模式识别方法已成为负荷识别研究的主流方法. 例如,支持向量机 (support vector machines, SVM)<sup>[31-33]</sup>、随机森林 (random forest, RF)<sup>[34]</sup>、K 最近邻 (K-nearest neighbor, KNN)<sup>[35]</sup>和 K 均值 (K-means)<sup>[36]</sup>聚类等方法被应用于负荷识别领域. Wu 等<sup>[37]</sup>提出一种基于随机森林的多标签分类算法,用于从没有分解的混合信号中识别独立设备的运行状态. 不过,每种模式识别方法都有它的优势和劣势. 因此,为进一步提高负荷识别性能,集成多种模式识别方法也开始备受关注. 例如, Kramer 等<sup>[38]</sup>为了研究集成分类模型的优势,将融合 SVM 和 KNN 的集成分类器和单个随机森林模型的性能进行了比较. 他们通过实验对比发现,集成分类器的性能优于单个分类器. 虽然模式识别在 NILM 领域已经取得了显著的成就,但是其在负荷分解的精度和模型泛化等方面仍然存在着很大的问题.

为了提高非侵入性负荷分解的准确性和泛化能力,近年来研究者将注意力转向了新出现的深度学习领域. 深度学习<sup>[39,40]</sup>是一种通过一系列的线性和非线性变换从低层特征中自动学习出更高层次特征属性的方法<sup>[41]</sup>. 目前,深度学习方法已经在计算机视觉<sup>[42]</sup>、语音信号处理<sup>[43]</sup>、自然语言处理<sup>[44]</sup>等领域取得了显著成就. 鉴

于深度学习方法具有强大的特征学习能力,近年来研究者开始将深度学习方法应用于非侵入式负荷分解方向<sup>[45,46]</sup>. 其中,代表性的深度学习方法主要包括卷积神经网络 (convolutional neural network, CNN)<sup>[47,48]</sup>、长短期记忆神经网络 (long short-term memory, LSTM)<sup>[49-51]</sup>、门控循环网络 (gated recurrent unit, GRU)<sup>[52]</sup>、注意力网络<sup>[53]</sup>、对抗网络<sup>[54]</sup>等.

由于在 NILM 分析过程中,相比较事件检测,负荷分解是 NILM 最核心的一个步骤. 近年来,随着深度学习方法在 NILM 中的成功应用,开展面向深度学习的 NILM 研究已成为一个智能电网、计算机科学等多领域交叉的热点课题,备受关注. 为了系统地综述该领域的研究进展,拟对近年来面向深度学习的 NILM 研究进展进行分析和总结. 第 2 节对特征提取方法进行梳理. 第 3 节对近些年来提出的一些数据集进行了介绍. 第 4 节对近几年面向深度学习方法的非侵入式负荷分解研究进展进行了梳理,并进行了比较. 第 5 节主要分析了现有研究中存在的一些挑战和机遇,包括数据稀疏问题、落地问题、跨库问题. 最后,对全文进行了总结和展望.

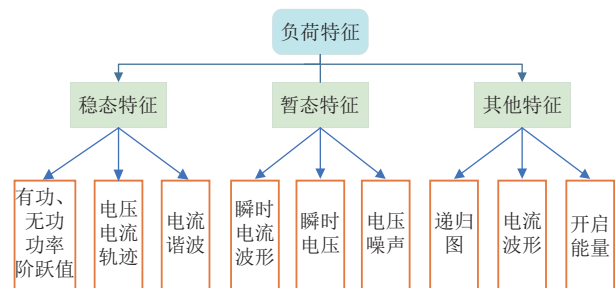


图 2 负荷特征分类

## 1 特征提取

在非侵入式负荷监测中,所有的负荷类型都有一个独特的能耗模式,被称负荷特征. 这种特有的负荷特征常常被用来从聚合负荷数据中唯一地识别负荷的运行状态和其是否存在. 对于 NILM 的这些负荷特征大致可以分为稳态特征、暂态特征和其他的一些非传统特征<sup>[55]</sup>,如图 2 所示.

稳态特征是从波形的平稳波段提取的特征. 这种特征包括功率变化分析<sup>[20]</sup>(如有功功率、无功功率和视在功率的阶跃变化)、稳态电流<sup>[56]</sup>、电流谐波<sup>[22]</sup>和电

压-电流 ( $V-I$ ) 轨迹<sup>[57]</sup> 等. 其中大部分都是使用单一的功率阶跃值用于负荷识别<sup>[58-61]</sup>. 例如, Lindahl 等<sup>[20]</sup> 利用功率的变化量作为特征, 将空调的功耗从总功耗里分离出来. Liao 等<sup>[62]</sup> 利用有功功率的变化量作为动态时间扭曲 (dynamic time warping, DTW) 和决策树 (decision tree, DT) 输入, 用来对负荷进行检测和分解. Zhao 等<sup>[63]</sup> 基于两个有功功率测量数据集实现了自适应域事件检测和负荷识别. Parson 等<sup>[64]</sup> 使用有功功率作为输入并结合期望最大化法 (expectation-maximization, EM) 和维特比算法的扩展方法来分解单个负荷. Yu 等<sup>[60]</sup> 利用一种基于稳态分割的特征对负荷的状态进行表征, 并利用有功功率的变化量对负荷进行分解.

如上述所示使用的都是单个负荷参数作为输入, 这有可能造成特征相互遮掩的状况. 而多参数输入和  $V-I$  轨迹在一定程度上能缓解这些问题, 因此很多研究者对此进行了深入研究. 例如, Racines 等<sup>[65]</sup> 将有功功率和电流等稳态负荷参数结合起来作为前馈网络的输入, 用于状态监测和负荷识别. Sun 等<sup>[66]</sup> 利用信号的电流波形、有功功率和无功功率的稳态特征作为反向传播神经网络的 (back propagation neural network, BPNN) 输入, 对负荷的工作模式进行识别. 祁兵等<sup>[67]</sup> 设计了一种通过分析多种负荷稳态波形, 建立稳态波形模板库的方法用于负荷识别. Gray 等<sup>[68]</sup> 通过小波变换提取三相电压和电流信号中的特征, 并用得到的小波系数在细粒度上的能量来构建用于负荷识别的特征集, 用于负荷识别. Timplalexis 等<sup>[69]</sup> 采用由电气特征、时间特征和统计特征等稳态信息组成的混合特征集作为光梯度提升机 (light gradient boosting machine, LGBM) 的输入, 用于提高负荷分类的精度. Wang 等<sup>[57]</sup> 通过平滑和插值的方法从视在功率中提取  $V-I$  轨迹, 并基于  $V-I$  轨迹的物理意义将其分为 10 个  $V-I$  轨迹特征用于负荷识别. De Paula Rodrigues 等<sup>[70]</sup> 提出了两个由  $V-I$  轨迹曲率尺度空间导出的稳态负荷特征. 这些特征包含了与轨迹形状有关的结构元素以及生成过程中忽略的一些特性, 这使得  $V-I$  轨迹的表示能力得到了改善, 提高了识别的精度. 除了上述的时域特征外, 有的作者会将时域特征通过信号变换技术转化成频域特征用于负荷识别. 例如, Djordjevic 等<sup>[71]</sup> 采用电流谐波相量的阶跃变化作为负荷识别的特征. Djordjevic 等<sup>[72]</sup> 利用电流谐波的变化量作为负荷识别的特征, 对用电器进行分类. Bouhouras 等<sup>[73]</sup> 利用奇次谐波的轮廓对具有相近有功

和无功功率的负荷进行识别, 提高了识别的精度. 但是时域数据在转化为频域数据时有可能会丢失时间信息, 因此可以把时域特征与频域特征结合在一起进行负荷识别. 例如, Huang 等<sup>[74]</sup> 设计了一种将频域特征和时域特征相结合的 (负荷识别) 策略, 实现了识别精度提升的效果. 最近稳态电压噪声对于负荷识别也产生了很好的效果. 如 Alcalá 等<sup>[75]</sup> 提出通过分析电源开关运行时产生的稳态电压噪声, 可以对设备进行表征.

当两个或两个以上的设备处于相似的功率范围时, 稳态特性可能无法有效的进行模式识别<sup>[76]</sup>. 而利用波形的暂态段提取的暂态特征可以很好地揭示有关设备的独特信息, 有助于更准确地进行负荷识别, 特征包括瞬时功率、电压噪声、瞬时电流等. 其中瞬时功率特征是模式识别中使用比较普遍的一种. 例如, Cole 等<sup>[77]</sup> 使用过渡阶段的功率尖峰或过冲 (overshoot) 作为检测设备的特征. 朱乔木等<sup>[78]</sup> 设计了一种基于暂态稳定性特征作为输入的深度置信网络 (DBN) 用于负荷监测. 最近在非侵入式负荷监测的过程中基于短时傅里叶变换等波形变换的方法也都被证明是非常有效的. 例如, Drouaz 等<sup>[28]</sup> 通过斯托克威尔变换 (Stockwell transform, ST) 对暂态电流信号在特定频率范围内的形状进行描述, 对用电器进行分类. Lü 等<sup>[79]</sup> 通过使用周期差分的方法将本底电流 (background current) 从暂态电流中去除. 然后对处理后暂态电流进行 S 变换, 得到幅值谐波矩阵. 并通过双向二维主成分分析对矩阵进行降维, 并在矩阵的行、列方向进行相应的特征提取. Sirojan 等<sup>[80]</sup> 使用离散小波变换从高频信号中提取细粒度的暂态特征, 并将其输入到电表的嵌入式神经网络中获取负荷识别的结果. Gulati 等<sup>[81]</sup> 利用快速傅里叶变换 (fast-Fourier transform, FFT) 对高频电磁干扰 (EMI) 信号进行分析, 用于负荷检测. Lee<sup>[82]</sup> 利用用电器特有的相位噪声特性, 用于 NILM. Zhang 等<sup>[83]</sup> 建立了基于有功功率的暂态负荷特征库, 提出了多尺度小波包优化 NILM 方法. 该方法能有效解决特征重叠问题, 提高算法的鲁棒性和负荷识别率. Gillis 等<sup>[84]</sup> 使用普鲁克 (procrustes) 分析得到了滤波器长度为 6 的小波系数, 并将它用于构建新的小波, 以匹配要检测的负荷信号. Chang<sup>[85]</sup> 利用基于时域和频域特征的小波变换 (wavelet transform, WT) 对负荷识别过程中的暂态特征进行分析检测. 实验表明, 暂态响应时间和暂态能量优于稳态特征, 能够

提高识别的精度. Liu 等<sup>[86]</sup>首次采用动态时间规整 (dynamic time warping, DTW) 算法来测量可变量度原始暂态功率波形 (transient power waveform, TPW) 样本与模板时间序列之间的相似, 并通过最近邻方法来识别创建的 TPW 样本时间序列. 除此以外一些统计学的方法也被运用暂态特征的提取中. 如 Rathore 等<sup>[87]</sup>讨论了具有共同暂态特征 (如 RMS、总谐波失真、均值、标准差等) 的电流数据, 用于负荷识别. Rehman 等<sup>[88]</sup>将平均功率作为特征提取过程的输入变量. 他们利用几何、统计的方法提取了功率的瞬态宽度、峰值大小、标准差、方差和平均值等统计特征用于负荷识别.

为了更进一步的提高负荷监测的精度. 有很多研究者将稳态与暂态特征结合起来用于 NILM. 例如, Iksan 等<sup>[89]</sup>利用提取的电流 ( $I$ )、谐波 ( $H$ )、有功和无功功率 ( $P, Q$ )、 $V-I$  轨迹等特征, 对不同的负荷进行识别. Mulinari 等<sup>[90]</sup>除了从瞬时电压和电流波形的  $V-I$  轨迹中提取到的暂态特性之外, 还给出了稳态的新特性. 然后, 通过组合选择一组合适的特征轨迹, 获得了 98% 以上的准确率, 提高了稳态  $V-I$  特征<sup>[57]</sup>的分类性能. Meehan 等<sup>[91]</sup>提出一种使用设备开或关时的电流谐波和暂态信号的变化率去识别不同设备的类型, 可以有效地提高设备分类的精度. Kumar 等<sup>[92]</sup>利用电流谐波的稳态和暂态特征作为前馈网络的输入, 用于对设

备类的识别. Ancelmo 等<sup>[93]</sup>设计了一种利用 Prony 模型 (如多项式、最小二乘、矩阵笔等) 去分析电流信号, 来获取暂态特征和稳态特征的方法用于负荷识别. Andrian 等<sup>[94]</sup>采用了一种基于级联滤波与决策委员会机制 (committee decision mechanism, CDM) 相结合的多标签识别方法, 用于负荷识别. 相对于单个类型的特征, 这些融合特征都取得了更好的分类结果.

除了以上所提到的特征外, 还有一些其他非传统特征被用于负荷分解. 例如, Kim 等<sup>[95]</sup>将开关的持续时间分布, 电器的使用频率, 以及各种电器之间的相关性与实际功率特征相结合, 用于负荷识别. Popescu 等<sup>[25]</sup>使用递归图 (时间序列延迟嵌入后自相关的一些可视化) 来识别用电器. Fan 等<sup>[96]</sup>从电流波形中提取有限状态机模型 (finite state machine, FSM), 然后从这些 FSM 中提取统计特征作为 NILM 的分类特征. 为了降低 NILM 分析过程中的计算量和不必要的内存需求, 主成分分析 (principal component analysis, PCA) 被用于特征降维<sup>[97,98]</sup>. Ahmadi 等<sup>[97]</sup>选取视在功率作为特征信号, 对视在功率进行信号变换, 然后利用 PCA 对提取的特征进行降维处理, 从而在不丢失有效信息的情况下减少特征库的大小. Chang 等<sup>[99]</sup>采用了一种反向传播网络结合暂态能量特征的方法对负荷进行识别. Kong 等<sup>[100]</sup>使用电压信号的主要峰值作为负荷特征来区分设备的运行状态. 表 1 总结了稳态和暂态特征方法.

表 1 稳态和暂态特征方法总结

特征类型	负荷类型	特征	优点	缺点
稳态特征	有功、无功和视在功率 <sup>[59-61]</sup>	有功、无功、视在功率变化量等	大功率负荷易于识别, 采样要求低	低功率负荷容易产生特征重叠, 识别性能差
	$V-I$ 波形的时域与频域 <sup>[69,71,74]</sup>	高阶稳态谐波、功率因子等	抗干扰能力强, 对于负荷分类精度较高	采样率高、无法识别重叠的开关状态
	$V-I$ 轨迹 <sup>[57,70]</sup>	$V-I$ 轨迹的形状, 如不对称性、面积、中段峰值等	独特的 $V-I$ 轨迹可以提高识别的精度	计算量大, 较小的负荷没有明显的规律可循.
	稳态电压噪声 <sup>[75,81]</sup>	EMI信号	基于电机和电源开关的负荷易于识别,	EMI信号重叠, 不是所有的负荷都配有电源开关
暂态特征	暂态功率 <sup>[83-85]</sup>	暂态功率剖面、SFFT、谱包络等	具有相同功耗的负荷易于识别	需要连续监测, 采样率要求高
	$V-I$ 电压噪声 <sup>[81,82]</sup>	噪声FFT	能够对多状态的电器提高识别效率	计算成本高, 数据注释困难
	暂态电流 <sup>[79,85]</sup>	电流峰值、大小、持续时间等	能够很好地识别不同场景下的瞬态负荷行为	对同时发生的事件状态不敏感

## 2 NILM 数据集

由于不同国家的用电指标和用电设备不同, 为了研究的方便, 不同国家的研究者都建立了不同的数据集. 表 2 列出了近年来 NILM 领域中常用数据集的基本情况总结.

REDD<sup>[101]</sup>: 能源分类数据集 (the reference energy disaggregation data set, REDD) 是一个免费提供的数据集. 该数据集是由麻省理工学院在 2011 年发布的第一个公共能源数据集, 包含了 6 个美国家庭在 119 天内测量的高频和低频负荷数据. REDD 收集了以 15 kHz

为采样频率测量的两个总电表的高频数据和以 0.5 Hz 和 1 Hz 为采样率监测的 24 台设备的数据和子电表数据. 该数据集中的用电参数包括电流 ( $I$ )、电压 ( $V$ ) 和有功功率 ( $P$ ) 等.

表 2 现有建筑用电数据集总结

数据集	国家	年份	类型	房间数	用电器数(个)	总时长	参数	采样频率
REDD <sup>[101]</sup>	美国	2011	R	6	92	119天	$I, V, P$	15 kHz (Agg); 0.5 Hz, 1 Hz (Sub)
HES <sup>[102]</sup>	英格兰	2011	R	26/251	5860	12个月	$I, V, P, T$	2–10 min
BLUED <sup>[103]</sup>	美国	2012	R	1	20	1周	$I, V, \text{switch events}$	12 kHz (Agg)
Tracebase <sup>[104]</sup>	德国	2012	R	15	122	1 883 天	$P$	1–8 s
Smart* <sup>[105]</sup>	美国	2012	R	3	21–26/间	3个月	$V, f, P, S$	1 Hz
IHEPCDS <sup>[106]</sup>	法国	2012	R	1	3	47个月	$I, V, P, Q$	1 min
MEULPv1 <sup>[107]</sup>	加拿大	2012	R	11	8	1周	$P$	1 min
MEULPv2 <sup>[108]</sup>	加拿大	2017	R	23	5组	1年	$P$	1 min
AMPds1 <sup>[109]</sup>	加拿大	2013	R	1	21	1年	$I, V, P, S,$ $f, Pf$	1 min
AMPds2 <sup>[110]</sup>	加拿大	2016	R	1	20	1.5–3.5年	$I, V, P, Q,$	1 min
ACS-F1 <sup>[111]</sup>	瑞士	2013	R	—	100 APP (10 类)	1小时(2 sessions)	$I, V, P, Q, f, \Phi$	10 s
ACS-F2 <sup>[112]</sup>	瑞士	2013	R	—	225 APP (15 类)	1小时(2 sessions)	$V, I, f, P, Q, \Phi$	10 s
BERDS <sup>[113]</sup>	美国	2013	R	—	—	1年	$P, Q, S$	20 s
PLAID <sup>[114]</sup>	美国	2014	R	65	1876	180天	$I, V$	30 kHz
SustData <sup>[115]</sup>	葡萄牙	2014	R	50	24	5–21个月	$I, V, P, Q, S,$	2–10 s
Dataport <sup>[116]</sup>	美国	2015	R	1 200+	8598	4+ 年	$P$	1 Hz, 1 min
DRED <sup>[117]</sup>	荷兰	2015	R	1	12	6个月	$P, T, H, W_t,$	1 Hz (Agg) 1 min (Sub)
GREEND <sup>[118]</sup>	意大利	2015	R	8	72+	6个月	$p$	1 Hz
REFIT <sup>[119]</sup>	英国	2016	R	20	177	2年	$P, Pf, T, O$	8s
ECO <sup>[120]</sup>	瑞士	2016	R	6	45	8个月	$V, I, P, Q, \Phi$	1 Hz
UK-DALE <sup>[121]</sup>	英国	2017	R	5	109	2.5年	$P, \text{Agg } P$	6 s (Sub); 16 kHz (Agg)
IMD <sup>[122]</sup>	巴西	2017	I	1	8	111天	$I, V, P, Q, S$	1 Hz
RAE <sup>[123]</sup>	加拿大	2018	R	1	24	72天	$O, V, P, Q, S, f, E$	1 Hz
BLOND <sup>[124]</sup>	德国	2018	R	1	53 (16组)	213天	$I, V, P$	6.4 kSps (Sub) 54 kSps (Agg)
DISEC <sup>[125]</sup>	印度	2018	R	19	—	284天	$P, W_t$	30 s (Sub) 15, 30, 60 min (Agg)
Enertalk <sup>[126]</sup>	韩国	2019	R	22	75	29–122天	$P$	15 Hz
I-BLEND <sup>[127]</sup>	印度	2019	R	7	—	52个月	$P, I, V, Pf, f$	1 min
HUE <sup>[128]</sup>	加拿大 哥伦比亚	2019	R	22	—	3年	$P$	1 h, H1 (1 min) H2 (1 Hz)
QUD <sup>[129]</sup>	卡塔尔	2019	R	3	4	1年	$P, H, T, O$	3 s–30 min
SynD <sup>[130]</sup>	奥地利	2020	R <sub>s</sub>	1	21	180天	$P$	5 Hz
RAPT <sup>[131]</sup>	瑞士	2020	R	5	—	1.5–3.5天	$P, W_t$	5 min
Chen等 <sup>[132]</sup>	中国	2021	R <sub>s</sub>	—	15	—	$I, U$	8 kHz

注: 电流( $I$ )、电压( $V$ )、有功功率( $P$ )、无功功率( $Q$ )、视在功率( $S$ )、归一化功率( $Np$ )、相位角( $\Phi$ )、能量( $E$ )、频率( $f$ )、功率因数( $Pf$ )、天气( $W_t$ )、温度( $T$ )、湿度( $H$ )、占用率( $O$ ); 数据集的类型: R→住宅数据集, R<sub>s</sub>→住宅合成数据集, I→工业数据集. Sub: 子电表表, Agg: 总电表表.

HES<sup>[102]</sup>: 该数据集是在英国 251 户业主家中从 2010 年 4 月到 2011 年 4 月期间监测收集到的负荷数据, 其中 26 家被监测了 12 个月, 225 家被监测了一个月. 对于每个被监测的家庭, 有 13–51 个家电被平均

2–10 分钟监控一次. HES 中包含的参数有电流 ( $I$ )、电压 ( $V$ )、有功功率 ( $P$ ) 和温度 ( $T$ ) 等.

BLUED<sup>[103]</sup>: 该数据集是在美国宾夕法尼亚州匹兹堡以 12 kHz 为采样频率收集到的单个家庭一周的电

流和电压数据.在此期间,家庭中每个设备的每个状态转换都被标记了出来,数据集还以 1 Hz 的采样频率收集了 20 台设备的用电量.它包含的参数有电流 ( $I$ ) 和电压 ( $V$ ) 等.

Tracebase<sup>[104]</sup>: 该数据集包括各种设备的功耗模式,并以 1 s 的采样间隔采集负荷数据.由于没有提供正在研究的设备及其性能的数据,因此它不能用于设备识别、偏好检测或能量分解.它收集了 43 种不同类别设备的数据,每个设备都记录了几个家庭在几天时间内的用电消耗记录.

Smart\*<sup>[105]</sup>: 该数据集是美国家庭能源优化项目的一部分,收集了 3 个家庭的实时数据.这些数据包括每个家庭平均每秒的用电记录,以及使用在每一个电路和每一个插头的子电表读数,还包括从现场太阳能电池板和风力涡轮机发电的数据,室外气象数据,室内房间温度和湿度数据等,此外该数据集还包括 400 个匿名家庭的用电消耗记录.该数据集中的用电参数包括电压 ( $V$ )、有功功率 ( $P$ )、视在功率 ( $S$ ) 和频率 ( $f$ ) 等.

IHEPCDS<sup>[106]</sup>: 该数据集是在法国巴黎的一个房间中收集到的.它包括 3 个以 1 min 为采样间隔,总时长 47 个月的负荷读数.它包含的用电参数有电流 ( $I$ )、电压 ( $V$ )、有功功率 ( $P$ ) 和无功功率 ( $Q$ ) 等.

MEULPv: 该数据集分为版本: MEULPv1<sup>[107]</sup> 和 MEULPv2<sup>[108]</sup>.其中,MEULPv1 数据集给出了加拿大安大略省渥太华市 12 个家庭的能源消耗读数.数据以 1 min 为采样间隔记录了一年的总用电功耗和用电设备的功耗,包括炉子、空调、炉灶/灶具、干衣机、洗碗机和家用热水器等用电器.测过程中所有房屋都使用天然气作为主要取暖燃料,并且住宅带有中央空调(A/C)和完整的地下室.其中有两个住宅的家庭热水需求通过电加热系统满足,而其余 10 个住宅完全使用天然气系统. MEULPv2 是 MEULPv1 的扩展数据集,该数据集包括了加拿大渥太华市的 23 个家庭一年的监测数据,并以 1 分钟为采样间隔给出了总功耗和用电器功耗读数.

AMPds: 该数据集分为两个版本: AMPds1<sup>[109]</sup> 和 AMPds2<sup>[110]</sup>,其中,AMPds1 数据集是在加拿大温哥华的一个家庭中,从 2012 年 4 月到 2013 年 3 月一年时间内测得的负荷数据集.该数据集包含以 1 min 为采样间隔的总表读数和 19 个独立子电路的负荷数据.负荷参数包括电压 ( $V$ )、电流 ( $I$ )、频率 ( $f$ )、功率因数

( $Pf$ )、有功功率 ( $P$ )、无功功率 ( $Q$ ) 和视在功率 ( $S$ ) 等.在数据集中除了对每个家庭所使用的每种用电器进行测量外,还每分钟测定一次燃气和水的消耗量. AMPds2 是 AMPds1 的扩展数据集,也是在加拿大的一个家庭收集到数据集.其包含了 20 个以 1 min 为采样间隔收集到的负荷功耗读数,包括电流 ( $I$ )、电压 ( $V$ )、有功功率 ( $P$ ) 和视在功率 ( $S$ ) 等用电参数.它的采样总时长为 1.5–3.5 年.

ACS-F: 该数据集分为版本: ACS-F1<sup>[111]</sup> 和 ACS-F2<sup>[112]</sup>.其中,ACS-F1 数据集共测量收集了 10 类 100 个家用电器的功耗数据.在监测采样过程中使用的采样间隔为 10 s,总时长仅为 1 小时.这个数据库特别适合应用于电器识别. ACS-F2 是 ACS-F1 的扩展数据集,它是在低频下获取的负荷读数,包括有功功率 ( $P$ )、无功功率 ( $Q$ )、电流 ( $I$ )、电压 ( $V$ )、频率 ( $f$ ) 和电压相对于电流的相位 ( $\Phi$ ) 等用电参数. ACS-F2 总共包括 15 个类别 225 种用电器在两个一小时的会议中的用电记录.

BERDS<sup>[113]</sup>: 该数据集是在美国加州的伯克利分校收集到的,其包含 4 类子计量负荷数据: 照明,空调,插座等.对于每个子计量类别可以得到许多反馈数据,且这些数据是每隔 20 s 测量一次得到的.该数据集包含的用电参数有有功功率 ( $P$ )、无功功率 ( $Q$ ) 和视在功率 ( $S$ ) 等.

PLAID<sup>[114]</sup>: 该数据集包括来自美国宾夕法尼亚州匹兹堡 56 户家庭的 11 种不同类型电器的电流和电压测量值.每种设备类型都包括数十个不同型号的用电器.对于每个电器,收集了 3–6 个测量值,并且数据的采样频率是 30 kHz.该数据集包含的用电参数有电流 ( $I$ ) 和电压 ( $V$ ) 等.

SustData<sup>[115]</sup>: 该数据集是 NILM 领域里规模较大的数据集.它是由在 50 个家庭中以每分钟为采样间隔收集到 (44 个公寓和 6 个独立住宅) 的 24 886 条负荷数据组成的.在监测的过程中数据每隔 15 min 记录一次,且采样总时长为 5–21 个月.该数据集的用电参数包括有功功率 ( $P$ )、无功功率 ( $Q$ ) 和视在功率 ( $S$ ) 等.

Dataport<sup>[116]</sup>: 该数据集包含 722 户家庭以 1 min 为采样间隔收集到的聚合和设备级电力数据.此外在 2014 年,非侵入式负荷监控工具包 (NILMTK) 被发布,该工具包提供了支持能量分解研究的软件基础设施,如数据集解析器、基准分解算法和评价指标等. NILMTK

格式的数据端口包含了该数据集 669 户家庭一个月的电力数据, 平均每个房子大约有 10 个用电器被监控, 有些房子有多达 23 个用电器被监控。

DRED<sup>[117]</sup>: 该数据集是在荷兰的一个房间收集到的时长 6 个月的负荷数据. 它包括以 1 min 为采样间隔测量的 12 种家用电器的功耗数据和以 1 Hz 为采样频率收集到的总功耗数据. 此外该数据集还包括了环境信息 (室级室内温度, 室外温度, 环境参数), 占用信息 (居住者的位置信息, WiFi 和用于定位的 BT RSSI 信息) 和家庭信息 (户型, 监控设备, 家电等) 等记录。

GREEND<sup>[118]</sup>: 该数据集是在奥地利和意大利两个国家 6 个月时间内以 1 Hz 为采样频率收集到的电力数据. 在收集过程中, 8 个家庭被监测, 每个家庭有多达 9 种不同的设备使用情况被记录。

REFIT<sup>[119]</sup>: 该数据集作为智能家居、减少能源需求项目的一部分. 它是由 University of Strathclyde 的 David Murray 和 Lina Stankovic 共同发布的. 它包括整个房屋的总功耗和每户以 8 s 为采样间隔收集的 9 个单独电器的测量值. 这些数据是在两年时间内从 20 户家庭中连续收集到的. 在监测期间, 居住者正常进行他们的日常活动. 该数据集在超过一年时间内以少于 1 min 的间隔监测了英国最多的家庭, 并且超过 250 000 个监控设备被用于整个实验过程. 该数据集包括的参数有有功功率 ( $P$ )、功率因子 ( $Pf$ )、温度 ( $T$ ) 和占用率 ( $O$ ) 等。

ECO<sup>[120]</sup>: 该数据集是由在瑞士的 6 个家庭中历时 8 个月收集到的负荷数据组成的. 且每个家庭为 ECO 数据集提供了采样频率为 1 Hz 的总功耗数据和每个负荷的功耗数据. 该数据集的用电参数包括电流 ( $I$ )、电压 ( $V$ )、有功功率 ( $P$ ) 和无功功率 ( $Q$ ) 等。

UK-DALE<sup>[121]</sup>: 该数据集是由英国发布的开源数据集, 它收集了采样频率为 16 kHz 的 3 个房屋和采样频率为 1 Hz 的两个房屋总电表的电流和电压数据. 并在 39–655 天的不同时期内, 以 6 s 的采样间隔收集了 5 个家庭单个设备的功耗. 2015 年 8 月发布了对该数据集的更新, 将 1 年可用负荷数据扩大到了 2.5 年。

RAE<sup>[123]</sup>: 该数据集是一个包括两个家庭总功耗和设备级功耗的数据集, 负荷的采样频率为 1 Hz. 在数据集中除了电力信息 (占用率 ( $O$ )、有功功率 ( $P$ )、无功功率 ( $Q$ )、视在功率 ( $S$ )、电压 ( $V$ )、频率 ( $f$ ) 和能量 ( $E$ )) 外, 还包括从房间内调节器中收集的温度 ( $T$ ) 和湿

度 ( $H$ ) 数据。

IMD<sup>[122]</sup>: 该数据集是从 2017 年 12 月至 2018 年 4 月在巴西米纳斯吉拉斯的一家家禽饲料工厂测量得到的一个总时长 111 天的设备级负荷数据集. 在对工厂设备进行检测的一年中, 检测设备对于用电器的监测一直保持良好的运行状态. 该数据集的用电参数包括: 电流 ( $I$ )、电压 ( $V$ )、有功功率 ( $P$ )、无功功率 ( $Q$ ) 和视在功率 ( $S$ ) 等, 并且 IMDELD 数据集经常用于工业场景中的 Fed NILM 训练。

BLOND<sup>[124]</sup>: 该数据集包括了聚合和设备级别电压和电流记录, 拥有来自 16 个设备组的 53 个设备的用电数据. 它包含两个主要的存储库: 1) BLOND-50, 对于分组电路, 以 50 kSps (千采样点每秒) 的采样率获得负荷数据, 对于单个设备, 以 64 kSps 的采样率测量得到负荷数据; 2) BLOND-250, 在聚合级别使用 250 kSps 的采样率, 在设备级别使用 50 kSps 的采样率采集数据。

DISEC<sup>[125]</sup>: 该数据集是在印度新德里的 19 套公寓住房内收集到的总时长 284 天的负荷数据. 在数据集内不同的用电信息被以 30 s 为采样间隔收集到, 如有功功率 ( $P$ ) 和天气数据 ( $W$ ), 而总功耗是以 15 min、30 min 和 60 min 为间隔收集到的。

Enertalk<sup>[126]</sup>: 该数据集是第一个公开可用的韩国电力数据集. 它是由从 22 个家庭以 15 Hz 为采样频率收集到的聚合功耗和单个用电设备的测量值组成的. 在监测过程中, 每 1/15 s 记录一次整栋房子里每台设备的有功和无功功率, 并且把采样的重点放在了大多数韩国家庭都拥有的泡菜冰箱、电饭煲、洗衣机、电视等家电上. 每个房子的测量总时长也不同, 从 29 天到 122 天不等。

I-BLEND<sup>[127]</sup>: 该数据是从印度一个学术机构的 7 栋商业和住宅建筑中以 19 min 为采样间隔收集到的数据集, 其采样总时长为 52 个月. 数据集中的用电参数包括有功功率 ( $P$ )、电流 ( $I$ )、电压 ( $V$ )、功率因子 ( $Pf$ )、频率 ( $f$ ) 等。

HUE<sup>[128]</sup>: 该数据集是由省级电力公司 BCHydro 的住宅客户捐赠的数据所组成的. 目前数据集包含有 22 个住宅用电信息, 大多数房子都有 3 年的用电信息记录. 数据集网站窗口最多只允许用户下载 3 年的数据. 且只有 BCHydro 客户才能捐赠以保持数据质量的一致性. 此外, 数据集中还包括气象站的天气数据。

QUD<sup>[129]</sup>: 该数据集是中东地区的第一个数据集,



它是由在3个房间内以3 s–30 min作为采样间隔测量的4个电器的有功功率组成的。此外温度( $T$ )、湿度( $H$ )和占用率( $O$ )等一些其它的室内参数数据也被包含在其中。该数据集的采样总时长为一年。

SynD<sup>[130]</sup>: 该数据集是一个合成数据集, 它将设备分为自主设备和用户操作设备。自主设备包括持续加载(如路由器)或在其运行模式中循环的设备(如冰箱)。用户操作的设备可能涉及单模式操作(如水壶)或多模式操作(如洗碗机或可编程烤箱)。在设备级别, SynD的功耗检测由作者直接测量并存储。

RAPT<sup>[131]</sup>: 该数据集包括来自瑞士大卢塞恩地区5所房屋的用电测量值, 时间跨度从1.5年到3.5年不等, 采样间隔为5 min。数据集对每间房屋总的家用电器和特定电器(如洗碗机、洗衣机、滚筒式干衣机、热水锅炉或热泵)的电能消耗进行了计量。此外, 数据还包括5栋房屋的所有光伏电池板的发电数据。

除了上述一些已经发布出来的国外公共数据集以外, 一些中国的研究者也采集了一些数据用于研究分析。只是这些数据及并没有像国外的数据集一样形成一个系统的数据集。例如, Chen等<sup>[132]</sup>在一个试验台电源入口安装了一个多通道非侵入式负荷数据采集装置。这个装置通过断路器将电表连接到每个用电器, 然后通过控制用电器的开关状态, 来收集负荷数据。其中负荷的采样频率设定为8 kHz, 实验使用的相关功率测量设备和量规由浙江威尔逊智能技术公司提供。电器包括空调、洗衣机、微波炉、加热器、电磁炉等。

### 3 面向深度学习的NILM方法

近年来, 深度学习方法被广泛应用于非负荷监测领域方向。它通过多个非线性变换可以直接从原始数据当中提取到更高维度的负荷特征, 从而避免了传统特征提取中导致的信号损失和误差累计。而且由于深度学习是一种基于端到端的学习技术, 因此它不需要对事件进行检测就可以对负荷进行分解。此外在现有的一些基于深度学习的NILM中, 我们了解到大部分的网络都是基于单个参数作为输入, 而多输入只占其中很少一部分。因此我们基于这两个方面对在NILM中最常见的深度学习方法进行分析总结。

#### 3.1 面向单输入的NILM

随着负荷在数量和类型上不断增多, 从监测到的功率数据中构造具有代表性的特征变得越来越重要,

为此, Chen等<sup>[133]</sup>提出一种基于双流卷积神经网络(two-stream convolutional neural networks, TSCNN)的时间和光谱特征学习方法用于非侵入式负荷分解。本方法首先使用快速傅里叶变换计算出光谱序列, 在得到时间序列和光谱序列以后, 使用改进的格拉姆角场(Gramian angular field, GAF)模型对时间序列和光谱序列进行编码得到一系列RGB图像。然后, 使用TSCNN从两种负荷特征中提取设备负荷的特征。其中, TSCNN由两个CNN网络组成: 一个为时间流, 另一个为光谱流。将预处理后的RGB图像输入到两个CNN通道中, 利用CNN提取图形的时间和频谱特征。然后, TSCNN将这两个向量连接成一个向量, 并使用完全连接或全局平均池层对其进行处理。最后, TSCNN的输出被传递到Softmax函数, 该函数通过输入的结果生成不同设备类型的分类结果。

为了解决深度学习随着网络深度不断加深出现的梯度爆炸、消失和网络退化等问题, Jia等<sup>[134]</sup>提出了一种双向扩张残差网络, 用于非侵入式负荷分解。该方法使用总有功功率的滑动窗口作为标准卷积的输入来提取低级的负荷特征, 然后将卷积的输出逐步输入8个残差块, 以提取更高级别的负荷特征。残差块是由双向空洞卷积堆叠得到, 这使得卷积网络的接受域比普通的空洞卷积增大了一倍, 可以提取到更长序列上的负荷特征。此外, 在残差块中利用批量归一化和激活函数ReLU解决梯度消失和梯度爆炸问题。为了防止网络退化, 每个残差块之间都使用剩余连接(residual connection)。通过实验证明模型的性能是优于文献[47]里最先进的结果的。

为了解决随着设备数量增加时出现的维度爆炸问题, Kaselimi等<sup>[135]</sup>提出了一种基于Bayes-BiLSTM的回归模型对输入的每一个设备进行建模, 并对所使用LSTM模型进行微调实现输入状态的非因果关系转换。该模型还通过结合负荷的过去与未来状态, 用来处理多状态设备运行问题。此外, 作者使用贝叶斯优化框架来选择所提出回归模型的最佳配置, 从而提高网络的性能。通过实验证明了所提出的模型比传统的隐马尔科夫链模型(factorial hidden Markov model, FHMM)、组合优化方法(combination optimization, CO)、CNN和LSTM等方法的性能更优越。

为了解决设备数量增加时出现的多维度问题, Kaselimi等<sup>[136]</sup>提出一种基于自适应和上下文感知的

双向长短期记忆网络 (context-aware bidirectional LSTM, CoBiLSTM) 模型用于非侵入式负荷分解. 所提出的 CoBiLSTM 模型利用了长短期记忆神经网络的表现能力, 同时考虑了 NILM 问题的两个基本特性: 非因果关系和对环境因素的适应性 (例如季节性). 并在自训练自适应机制的驱动下, 引入贝叶斯优化框架来优化双向 LSTM 的参数配置. 这里参数的优化策略是从初始配置网络开始, 然后以提高模型性能的方式估计下一个网络参数. 因此, 双向 LSTM 网络的参数会动态调整, 以适应特定设备的特性以及当前的上下文属性. 通过实验证明, 与 FHMM、CO、LSTM 和 CNN 等模型水平相比, 该方法具有优越性.

为了解决输入信号中存在的噪声问题, Kaselimi 等<sup>[54]</sup> 提出一种基于生成对抗网络<sup>[137]</sup> 的 EnerGAN 模型用于非侵入式负荷分解. 该方法包括 3 个部分: Seeder、生成器和鉴别器. 其中, Seeder 是一个由 3 个卷积层组成的结构, 它能够将所有带噪声的输入信息进行编码, 并将编码后的信息输入到生成器. 然后, 生成器通过将 Seeder 提供的数据映射到更高的特征空间, 来生成更长更准确地设备波形. 最后, 将聚合信号和相应设备功率的成对序列作为鉴别器的输入, 并基于地面真实值, 来对设备进行识别.

为了更好地解决序列数据之间的依赖关系, Lin 等<sup>[138]</sup> 提出了一种基于编码器-解码器体系结构的多头注意力网络 (multi-head attention network with encoder-decoder, MAED-net) 用于非侵入式负荷分解, 其中 MAED 网络的编码器由多个编码块组成. 每个编码块由一个多头注意子层和一个位置全连接前馈子层组成. 而解码器是通过在编码器的第 3 个子层中插入一个编码器-解码器注意力层来构建的. 整个网络通过给定来自前一个解码器块输出的查询和来自编码器输出的键值对作为输入, 然后使用编码器-解码器注意力层来帮助解码器块关注输入序列的适当部分, 从而提高 NILM 的识别精度.

为了提高模型的泛化能力以及多状态负荷分解问题, Langevin 等<sup>[139]</sup> 提出了一种基于变分自动编码器 (variational autoencoders, VAE) 神经网络框架的非侵入式负荷分解方法. 该方法由两个部分组成: 将信息映射到潜在空间的编码器和利用潜在特征重构目标设备功率信号的解码器. 他们在编码器中使用了一系列的实例批量标准化网络 (instance batch normalization-net, IBN-

Net) 来增强从总功率中提取的高维特征. 此外, 作者使用跳过连接 (skip connection) 方法, 使得解码器能够像 U-Net 架构<sup>[140]</sup> 一样从编码器中获取特征映射. 这些连接为解码器提供了对总功耗的全局信息, 从而使得解码器能够更好地重构目标信号, 提高了多状态负荷的识别精度以及模型的泛化能力.

为了进一步提升 NILM 的分类精度, Yue 等<sup>[141]</sup> 提出一种基于双向 Transformer 模型的非侵入式负荷分解方法. 这个模型包含嵌入模块、Transformer 层以及 MLP 输出层. 该方法首先采用卷积层提取特征, 并增加一维输入序列的隐藏尺寸, 然后通过卷积的输出上应用平方平均池化以保持特征信息的完整性, 同时将序列的长度减少一半. 池化后的输出被添加到嵌入模块捕捉序列的位置信息, 然后将得到的位置信息矩阵输入到双向 Transformer, 从而实现对输入信息的一系列变换. 最后, 将所得到的特征值输入到 MLP 层. 通过 MLP 里的转置卷积将序列恢复到原始长度, 并使用中间带有 tanh 激活函数的两层 MLP 将输入隐藏大小恢复到期望的输出大小, 以获取最终的预测结果. 通过实验证明该模型的性能比 CNN、LSTM 等网络更优越.

为了解决输入信号噪声而带来的负荷特征不稳定的问题, Kaselimia 等<sup>[142]</sup> 提出了一种用于非侵入式负荷分解的去噪对抗递归模型. 为了更好地实现非线性的负荷分解, 作者将自动编码器 (AE) 和 GAN 网络统一到一个单一的框架中组成了一个新的 EnerGAN++ 模型. 在该模型中, 使用一个编码-解码器作为生成器生成噪声序列, 并使用一个 CNN-GRU 的组合分类模型作为鉴别器. 其中, 使用 CNN-GRU 组合是因为单独的 GRU 网络不能够从输入的序列数据中提取高维的特征向量, 因此这里借助 CNN 作为 GRU 的一个特征提取器, 共同处理功率序列信号的时间动态特性. 整个模型经过不断的对抗训练, 降低了序列噪声的影响, 提高分类的精度.

为了解决模型训练过程中出现的负荷相关性和类标记不平衡的问题, Zhou 等<sup>[143]</sup> 提出了一种由 CNN、LSTM 和随机森林 (RF) 组成的非侵入式负荷分解方法. 该方法通过多特征高维方法 (multi-feature and high-dimensional method, MFHDM) 将一维时间序列数据转换为二维矩阵. 它将输出的数据输入到 CNN 网络进行特征提取, 并将提取后的特征向量输入到 LSTM-RF 网络中, 利用 LSTM 处理输入序列的时间特性, 并

使用 RF 计算出分类的结果. 针对模型中的类不平衡问题, 他们提出了一种复合重加权方法, 然后又通过预训练解决标签相关性问题. 最后实验证明, 所提模型比 KNN、FHMM 和 CNN-LSTM 等方法的性能更优越.

由于大部分的 NILM 方法都是在住宅数据集中得到验证, 而在非住宅数据集中却鲜有研究. 因此, García-Pérez 等<sup>[144]</sup> 基于一种全卷积自动去噪编码器体系 (fully-convolutional denoising auto-encoder, FCN-DAE), 对大型非住宅建筑的功耗进行非侵入式负荷分解. 在这个模型中全卷积架构可以比全连接层更好的保留数据的时间信息, 因此作者将编码器的所有全连接层替换为卷积块. 其中, 卷积块由两个步长为 1 的一维卷积层和一个步长为 2 的一维卷积层组成. 而解码器由一个一维转置卷积层和两个步长为 1 的标准一维卷积层组成. 编码网络在剪切好的不同长度序列窗口上进行特征提取, 然后使用解码器对提取的特征进行信号重建. 通过在大型医院数据集上的实验比较可知, 与普通的 CNN 相比较这种方法是优越的.

为了提高模型的泛化能力, 减小域之间的差距, Çimen 等<sup>[145]</sup> 提出了一种基于对抗自编码器 (adversarial autoencoder, AAE) 的能量分解模型用于非侵入式负荷监测, 该模型是由 VAE 和 GAN 网络构成混合模型, 该模型首先通过引入高斯先验分布对自编码器的潜在空间进行正则化, 以提高泛化性能. 然后, 概率自编码器结构之一的 AAE 通过最小化数据分布和先验分布之间的差异, 将潜在表征的分布匹配到先验分布, 从而学习一种通用表征. 由于 AAE 迫使连续混合表征匹配一个先验概率, 使得潜变量不像 VAE 那样相交, 从而导致模型具有更好的信号重构性能. 此外, 正则化的潜在空间使得从原始数据学习到的模型不会出现过拟合的现象, 从而更好地泛化到不可观测的目标房屋.

为了解决不同数据集在表征分布上存在的差异, 增强模型的可迁移性, Lin 等<sup>[146]</sup> 提出了一种利用域间参数共享来进行 NILM 的新方法. 该方法通过利用来自源域带有标记的和来自目标域未标记的数据作为 5 层带有残差连接的时间卷积神经网络的输入. 然后使用带有标记的源域数据计算有监督的回归损失, 并通过比较源域分布与目标域分布的距离得到域自适应损失. 最后将这些损失结合起来, 利用反向传播网络来确定神经网络的权值对模型进行训练. 注意, 参数的权重在训练和测试之间是共享的. 实验证明, 通过这种联合

优化后的模型在性能和可迁移方面都有很大的提高.

### 3.2 面向多输入的 NILM

为了解决负荷数据的时间依赖性和多输入问题, Kaselimi 等<sup>[147]</sup> 提出了一种多通道循环卷积回归神经网络. 该模型使用带有循环特性的 CNN 作为特征提取的方法, 使得网络可以直接对于输出的权值进行更新. 此外, 对每一种输入的信号参数 (有功功率, 无功功率, 视在功率, 电流) 做抽头延迟 (tapped delay line, TDL) 操作, 使得当前的设备状态都与过去的状态相关, 并且这些输入信号在处理后可以被看成一个融合的张量作为模型的输入. 通过实验证明了所提出的模型比传统的 FHMM、CO、CNN-LSTM 的性能更优越, 平均改进了 40%–50%.

在 NILM 过程中因果关系是非常重要的, 因为它能够保证用户可以获取实时的用电信息. 但是在很多深度学习方法中都忽略了这一点, 因此 Harell 等<sup>[148]</sup> 提出一种基于因果的 CNN 网络用于非侵入性负荷分解. 为了得到足够大的感受野, 该方法利用空洞卷积对卷积神经网络的接受域进行扩张, 并将基于有功功率的过去和现在的时间窗口作为因果卷积的输入, 然后将每个卷积的输出作为 Sigmoid 激活函数和校正的线性激活函数的输入, 并将两个激活函数的结果相乘, 作为因果卷积块的输出. 卷积块输出的一部分被用作下一步的输入, 另一部分通过跳过连接 (skip connection) 直接输入到网络的最后一层. 实验使用  $P$ 、 $Q$ 、 $S$ 、 $I$  这 4 种信号参数作为输入, 所得到的结果超过了 CNN、LSTM、FHMM 以及 CO 等方法. 并且通过实验我们还了解到比起单个  $P$ ,  $P$  和  $Q$  的组合输入精度提高了 6%,  $P$ 、 $Q$ 、 $I$  和  $S$  的组合输入精度提高了 7%.

为了在有限数据量下使 NILM 达到较高的估计精度和最低的泛化误差, Rafiq 等<sup>[149]</sup> 提出了一种基于多特征子空间的深度递归网络 (multi-feature subspace-LSTM, MFS-LSTM) 分解算法. 该模型分为 3 个阶段, 首先利用互信息方法形成多特征输入数据, 然后利用选定的基于多特征输入空间 (MFS) 的稳态参数, 对每个目标负荷的 4 层双向长短期记忆 (LSTM) 模型进行训练, 并进行超参数调优. 其中, 互信息法 (mutual information) 是用来测量稳态电气参数对单个负荷有功功耗的影响. 然后从这些信息中, 选择具有相关性和影响力的负荷特征, 形成多特征输入数据. 最后, 在分解阶段使用后处理技术来消除不相关的预测序列, 提高

了算法的分类和估计精度. 从实验结果可知, 在可见场景下,  $F1$  提升了 30%. 在不可见场景下提升了 28%.

在整个 NILM 的操作过程中, 分类器的性能是影响 NILM 性能的最关键因素, 因此为了克服现有分类算法的局限性, 提高 NILM 分类器的性能, Kim 等<sup>[150]</sup>提出了一种基于多特征融合的多层长短期记忆网络 (multi-feature combination multi-layer long short-term memory, MFC-ML-LSTM), 用于模式分析和负荷识别. 该模型将音频信号处理中常用的各种特征提取技术应用于功率信号, 生成频谱图、梅尔频率 cepstral 系数 (Mel-frequency cepstral coefficients, MFCC) 和梅尔谱图等二维特征, 然后通过多特征组合技术生成新数据, 并将这些新数据作为多层 LSTM (ML-LSTM) 网络的输入, 以此来提高分类器的性能. 通过实验表明本文所提出的方法在精度和  $F1$  分数分别达到了 95%–100% 和 84%–100%, 比起现有 GRU 和单层 LSTM 更优越.

综上所述, 我们了解到 NILM 领域使用的主流深度学习方法包括 CNN、LSTM、自动编码器、注意力网络、对抗网络以及它们的改进和组合模型等. 这些深度模型的使用使得 NILM 领域的识别精度得到了不断的刷新. 表 3 给出了面向深度学习的 NILM 的方法总结. 由表 3 可见: (1) 大部分深度学习方法使用的都是单个有功功率作为输入, 只有少部分使用了多输入. (2) 将其他的一些附加变量作为多输入, 可以有效提高分解精度. 例如, 在 AMPds1 数据集上通过对文献 [147] 和文献 [135,136,142] 比较可以发现, 多输入情况下的平均 MAE 值明显要比单输入的小很多. UK-DALE 数据集也表现出了相同的结果, 不仅平均 MAE 值要明显较低, 而且准确率也是要高于同一数据集的大部分单输入结果. 这些充分证明了多输入的有效性. (3) 单输入条件下, 在数据集 REDD 上 CoBiLSTM<sup>[136]</sup> 所表现出的结果要超过其他方法. 这表明 CoBiLSTM 算法采用动态参数调整的策略比其他方法更有效. 在 UKDALE 数据集上 Bi-TCN 算法<sup>[134]</sup> 表现出了最佳结果. 这表明双倍的感受野对于提升负荷分解的精度非常有效. 在 REFIT 数据集上 VAE 算法<sup>[139]</sup> 表现出较好的结果. 由于不同的数据集差异较大, 因此我们不能简单得出哪种算法最好. 只能在同一数据集下, 找出表现相对较好的算法. 最后, 图信号处理技术<sup>[151]</sup> 在最近的一些年也被用到 NILM 领域, 并且取得了显著的成功. 未来这两个领域方法的结合技术也会成为此领域的一个研究热

门, 使得识别的精度不断提高.

## 4 机遇与挑战

### 4.1 数据集稀疏问题

在非侵入负荷分解的实际应用中, 可以看到标签数据的缺乏是主要挑战之一. 虽然这一挑战并非 DNN 方法所独有, 但由于 DNN 训练过程需要大量的数据, 所以解决 NILM 中标签数据短缺的问题备受关注. 近年来, 采用弱监督和无监督学习方法来解决数据稀疏问题<sup>[152]</sup> 成为一个值得研究的方向. 其中, 半监督学习是指只有部分数据被打上标签, 而其他用于测试的数据是没有被打上标签的方法; 而无监督学习是指没有训练过程的学习, 它是直接使用数据进行建模, 在测量数据中发现规律, 并根据数据点的共同属性对数据点进行分组. 这两种方法在计算机视觉<sup>[153,154]</sup>、自然语言处理<sup>[155]</sup>、语音信号处理<sup>[156]</sup> 等领域用于处理数据稀疏问题, 已经取得不错的性能.

近些年来, 弱监督和无监督学习方法被广泛地迁移到了 NILM 领域, 并展现了其巨大的潜力<sup>[157]</sup>. 例如, Liu 等<sup>[158]</sup> 提出了一种基于对抗训练和无监督联合自适应的 NILM 算法, 该算法通过减小源域和目标域之间特征空间和标签空间的分布差距, 来解决网络泛化和数据稀疏问题. 实验也证明这种方法在无标签的情况下对负荷识别精度的提升是有效的. 但是无监督学习为数据稀疏问题提供一个很好方法的同时, 也存在一个实质性的问题, 由于没有标签的存在使得识别的精度还是很差. 为了解决无监督所带来的问题, 研究者们将新的半监督 DNN 方法从视觉领域迁移到 NILM 领域<sup>[152]</sup>. 例如, Yang 等<sup>[159]</sup> 使用了一种平均教师方法 (mean-teacher), 用于 NILM; Miao 等<sup>[160]</sup> 采用了虚拟对抗训练方法, 来提高 NILM 的识别精度. 通过实验可知这两项工作的结果都证明了半监督学习对于数据稀疏情况是有效的. 但是实验只是对训练中可见的房间进行的, 对于不可见的房间没有考虑. 其中, 可见房间是指在测试中使用的数据是来自训练房间的新数据. 而不可见房间是指在测试中使用的房间数据没有用于训练. 为此, 一种被称为一致性学习的半监督方法<sup>[152]</sup> 被迁移到 NILM 领域用于进一步改进迁移学习算法, 提升负荷识别的精度. 除此以外 GAN 网络<sup>[137]</sup> 的发展对于数据稀疏问题的解决也提供了很大的帮助. 例如, Harell 等<sup>[161]</sup> 利用 TraceGAN 去解决在 NILM 中存在

的由于数据稀疏,而导致的算法泛化能力较弱的问题. TraceGAN 是一个有条件的、逐步增长的 1-D Wasserstein 生成对抗网络. 它通过对 GAN 网络增加一个条件设

置,使得使用者可以通过训练一个模型就可以得到其想要的所有设备类的功率轨迹,经过比较合成的数据具有真实数据的特点,可以用于实验.

表 3 面向深度学习的 NILM 的方法总结

NILM类型	作者	年份	数据集	输入	DNN	负荷识别	输出	平均MAE	准确率(%)
单输入	Kaseliimi等 <sup>[135]</sup>	2019	AMPds1	总有功功率	Bayes-BiLSTM	Softmax	<i>P</i>	32.56	—
	Kaseliimi等 <sup>[136]</sup>	2020	AMPds1	总有功功率	CoBiLSTM	回归层	<i>P</i>	41.3	—
			REFIT REDD					21.5 7.36	
	Lin等 <sup>[138]</sup>	2020	REDD	总有功功率	MAED-net	回归层	<i>P</i>	21.05	93.7
	Yue等 <sup>[141]</sup>	2020	REDD	总有功功率	BERT	MLP	<i>P/on-off</i>	26.35	94.8
			UK-DALE					12.41	
	Kaseliimi等 <sup>[142]</sup>	2021	AMPds1	带有噪声的有功功耗	CNN-GRU	回归层	<i>P</i>	35.26	—
			REFIT					10.51	
	Zhou等 <sup>[143]</sup>	2021	REDD	总有功功率	CNN	RF	<i>P</i>	—	95
			PSD					94	
	Chen等 <sup>[133]</sup>	2021	PLAID	电压-电流 轨迹	TSCNN	Softmax	<i>P/on-off</i>	—	98.42
			WHITED					99.41	
	Langevin等 <sup>[139]</sup>	2021	UK-DALE	总有功功率	VAE	Softmax	<i>P</i>	8.8	—
			REFIT					8.0	
	Jia等 <sup>[134]</sup>	2021	REDD	总有功功率	Bi-TCN	回归层	<i>P</i>	19.17	—
UK-DALE			3.83						
García-Pérez等 <sup>[144]</sup>	2021	proprietary	有功功率	FCN-dAE	Softmax	<i>P</i>	—	—	
		REDD					26.21		
Lin等 <sup>[146]</sup>	2022	UK-DALE	总有功功率	TLN	回归层	<i>P</i>	16.78	—	
		REFIT					15.12		
Çimen等 <sup>[145]</sup>	2022	REDD	总有功功率	AAE	回归层	<i>P</i>	17.35	—	
		UK-DALE					9.15		
多输入	Kaseliimi等 <sup>[147]</sup>	2019	AMPds1	有功功率和电流、无功、视在功率的附加变量	CNN	回归层	<i>P</i>	13.21	—
	Harell等 <sup>[148]</sup>	2019	AMPds2	有功功率和电流、无功、视在功率的附加变量	CNN	Softmax	<i>P</i>	—	99.1
								—	
	Kim等 <sup>[150]</sup>	2019	UK-DALE proprietary	有功功率、频谱图、MFCC、梅尔谱图	ML-LSTM	Softmax	<i>P</i>	—	97.7
Rafiq等 <sup>[149]</sup>	2020	UKDALE	有功、无功、视在功率、电流和功率因子	CNN-biLSTM	Softmax	<i>P</i>	5.91	96.4	
		ECO					8.99		

总之,不论弱监督、无监督方法还是 GAN 网络都为解决 NILM 中的数据稀缺性问题提供了巨大的机遇. 但是我们也能看到弱监督和无监督方法在精度方面存在着一些问题,并且在 DNN 上的运用不是很多<sup>[162,163]</sup>. 因此,在 NILM 领域弱监督与无监督学习和 DNN 模型的研究可能成为一个很好的方向.

#### 4.2 面上实际应用的差距问题

随着深度模型越来越复杂,模型的深度也在不断的增加,这也给训练带来了很大的麻烦,太多的参数会使得训练的时间变得很长. 这对面向深度学习的非侵

入式负荷分解方法走向实际应用带来巨大的挑战,过多的网络参数会使得数据在云端的分析处理过慢,使得信息出现滞后. 但是,与其他传统的机器学习方法相比,深度神经网络 (DNNs) 是解决 NILM 问题最先进的方法之一<sup>[164,165]</sup>. 因此,对于既轻量、精度又高算法的研究在 NILM 中是一个重要突破点. 例如,seq2point<sup>[47]</sup> 包含大约 3 000 万个权重参数. 这些参数使得其实用性大大降低. 为了提供一个可移动能量分解系统,需要尽可能地减少 seq2point 网络中的参数数量. 为了减轻这一限制,很多对网络进行修剪和参数共享的方法被提

了出来. 例如, Barber 等<sup>[166]</sup>在 seq2point 算法基础上研究了 4 种剪枝技术: 结构化概率剪枝<sup>[167]</sup>、基于熵的剪枝<sup>[168]</sup>、相对阈值剪枝<sup>[169]</sup>和恒定稀疏性低幅度剪枝<sup>[170]</sup>. 这些剪枝技术的目的是从网络中删除那些对网络输出没有显著贡献的权值, 从而不会影响算法的性能. 在 REFIT 数据集上实验表明, 与原有网络相比, 该模型在不降低精度的情况下, 模型参数减少了 87%. Wang 等<sup>[171]</sup>提出了一种轻量级、非接触的实时 NILM 解决方案. 该方案同时采用了过滤器剪枝和权值剪枝来减小神经网络的规模. 该方法压缩后的网络有 96.8% 的冗余信息被滤除, 并且负荷识别的准确率也达到了 94.2%.

除了以上几种经典的剪枝方法, 模型压缩的方法还包括低秩分解<sup>[172]</sup>、压缩卷积滤波器<sup>[173]</sup>、知识蒸馏<sup>[174]</sup>等经典方法. 此外, 近几年来对于模型压缩方法的研究一直没有停止, 不断有新的方法被提出, 如基于判别力的通道剪枝算法<sup>[175]</sup>、基于低比特无数据模型量化<sup>[176]</sup>、基于迁移学习的深度模型量化算法<sup>[177]</sup>和面向动态变化数据的模型结构自动调整<sup>[178]</sup>等方法. 因此, 将上述一些新的模型压缩方法用于 NILM 领域, 也是一个很有意义的研究方向.

### 4.3 跨库问题

在非侵入式负荷监测领域, 跨数据库(域)的研究比较少. 目前, 在不同国家数据集中的采样率、设备使用模式、气候、用电器的年限和电气规格(如电压、相位)等方面存在巨大差异. 这给对不同的数据库进行跨库研究带来了很大的挑战. 近些年, 已经有一些研究者针对跨库这方面研究进行了探索. 例如, Murray 等<sup>[179]</sup>使用 CNN 和 GRU 两个模型, 在 REDD、REFIT 和 UKDALE 这 3 个数据集上进行了跨库验证. 实验证明了该 CNN-GRU 模型对不同数据集进行跨库预测的可行性. Ahmed 等<sup>[180]</sup>在对抗网络的基础上提出了两种模型迁移的方法: 一是通过参数共享进行传递学习, 即通过将训练好的模型参数共享到测试的过程; 二是通过学习源域和目标域之间的紧致共享特征, 即通过最小化两个域之间的统计距离, 来学习源域与目标域的共享特征. 实验在 REDD、REFIT 和 UKDALE 这 3 个数据集上验证了该模型用于迁移学习的可行性.

除了以上文献, 文献<sup>[180,181]</sup>也对跨库问题进行了研究, 也都证明了跨数据集验证的可行性. 但是这种验证的精度却很低, 并且没有一个标准的算法可以对这方面的问题进行突破. 因此, 未来在这方面对于算法

的研究还有很多问题有待发掘, 尤其是对跨数据集评价指标的建立, 因为现有指标大部分都是针对同一个数据集相同或是不同房间测试建立的指标, 这使得对于跨数据集的评价变得不准确.

## 5 结论与展望

本文综述了近年来面向深度学习的非侵入式负荷监测研究现状与进展. 通过描述一般非侵入式负荷监测的典型框架, 然后系统阐述了这个领域当中运用到特征提取方法和公开数据集. 其次, 重点对近年来采用的深度学习方法在 NILM 领域的运用进行了系统性分析与归纳. 最后, 指出了该领域存在的一些机遇与挑战, 如数据稀疏, 面向实际应用的差距和跨库等问题.

非侵入式负荷监测算法在实际生活中是被植入到智能电表当中<sup>[182]</sup>, 但是采用深度神经网络处理问题时, 由于参数量过大, 导致 NILM 算法很难被植入到设备当中. 因此, 如何在未来的工作中找到一种既精确、内存量又小的算法将是研究重点. 在第 4.2 节中概述了一些模型压缩的方法, 但是在实际研究中运用的还不多, 这就需要未来的研究中进一步探索. 另一方面, 云设备实时数据共享功能在未来应该是一个比较好的研究方向. 非侵入式负荷分解研究在智能电表端把总功耗分解成各设备类的功耗. 但是我们平时只能在电表上看到一个总功耗, 或是电力局的账单上看到一个总的用电量. 因此, 我们可以建立一个移动设备端, 将实时分解后的电功耗共享到移动设备端让客户可以了解自己的用电情况. 此外, 在未来随着科技的不断发展和算法的不断更新, 我们希望设计一种自主学习的算法可以根据实时数据去学习和改进自身算法上的不足, 以局部的学习去控制和改进全部设备的用电情况<sup>[183]</sup>. 最后, 通过第 2 节可知, 现在国外的 NILM 数据库已经比较完备, 但是国内还没有一个系统的公开数据集. 虽然有些网站或公众号发布了一些电力数据, 但是并没有人对这些数据进行系统整理和标注. 我们可以在未来可以建立更多带有完备标签的中国电力负荷数据库.

### 参考文献

- 1 Hart GW. Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, 1992, 80(12): 1870–1891. [doi: 10.1109/5.192069]
- 2 Batra N, Singh A, Whitehouse K. If you measure it, can you

- improve it? Exploring the value of energy disaggregation. Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-efficient Built Environments. Seoul: ACM, 2015. 191–200. [doi: [10.1145/2821650.2821660](https://doi.org/10.1145/2821650.2821660)]
- 3 Zoha A, Gluhak A, Imran MA, *et al.* Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey. *Sensors*, 2012, 12(12): 16838–16866. [doi: [10.3390/s121216838](https://doi.org/10.3390/s121216838)]
  - 4 Berges ME, Goldman E, Matthews HS, *et al.* Enhancing electricity audits in residential buildings with nonintrusive load monitoring. *Journal of Industrial Ecology*, 2010, 14(5): 844–858. [doi: [10.1111/j.1530-9290.2010.00280.x](https://doi.org/10.1111/j.1530-9290.2010.00280.x)]
  - 5 Papadopoulos PM, Reppa V, Polycarpou MM, *et al.* Scalable distributed sensor fault diagnosis for smart buildings. *IEEE/CAA Journal of Automatica Sinica*, 2020, 7(3): 638–655. [doi: [10.1109/JAS.2020.1003123](https://doi.org/10.1109/JAS.2020.1003123)]
  - 6 邓晓平, 张桂青, 魏庆来, 等. 非侵入式负荷监测综述. *自动化学报*, 2022, 48(3): 644–663. [doi: [10.16383/j.aas.c200270](https://doi.org/10.16383/j.aas.c200270)]
  - 7 Wild B, Barsim KS, Yang B. A new unsupervised event detector for non-intrusive load monitoring. Proceedings of 2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Orlando: IEEE, 2015. 73–77.
  - 8 Pereira L. NILMPEds: A performance evaluation dataset for event detection algorithms in non-intrusive load monitoring. *Data*, 2019, 4(3): 127. [doi: [10.3390/data4030127](https://doi.org/10.3390/data4030127)]
  - 9 Anderson KD, Bergés ME, Ocneanu A, *et al.* Event detection for non intrusive load monitoring. Proceedings of the 38th Annual Conference on IEEE Industrial Electronics Society. Montreal: IEEE, 2012. 3312–3317.
  - 10 Yang CC, Soh CS, Yap VV. Comparative study of event detection methods for non-intrusive appliance load monitoring. *Energy Procedia*, 2014, 61: 1840–1843. [doi: [10.1016/j.egypro.2014.12.225](https://doi.org/10.1016/j.egypro.2014.12.225)]
  - 11 Hamdi M, Messaoud H, Bouguila N. A new approach of electrical appliance identification in residential buildings. *Electric Power Systems Research*, 2020, 178: 106037. [doi: [10.1016/j.epsr.2019.106037](https://doi.org/10.1016/j.epsr.2019.106037)]
  - 12 De Baets L, Ruysinck J, Develder C, *et al.* On the Bayesian optimization and robustness of event detection methods in NILM. *Energy and Buildings*, 2017, 145: 57–66. [doi: [10.1016/j.enbuild.2017.03.061](https://doi.org/10.1016/j.enbuild.2017.03.061)]
  - 13 Ajmera J, McCowan I, Bourlard H. Robust speaker change detection. *IEEE Signal Processing Letters*, 2004, 11(8): 649–651. [doi: [10.1109/LSP.2004.831666](https://doi.org/10.1109/LSP.2004.831666)]
  - 14 Berriri H, Naouar MW, Slama-Belkhdja I. Easy and fast sensor fault detection and isolation algorithm for electrical drives. *IEEE Transactions on Power Electronics*, 2012, 27(2): 490–499. [doi: [10.1109/TPEL.2011.2140333](https://doi.org/10.1109/TPEL.2011.2140333)]
  - 15 Houidi S, Auger F, Sethom HBA, *et al.* Statistical assessment of abrupt change detectors for non-intrusive load monitoring. Proceedings of 2018 IEEE International Conference on Industrial Technology (ICIT). Lyon: IEEE, 2018. 1314–1319. [doi: [10.1109/ICIT.2018.8352368](https://doi.org/10.1109/ICIT.2018.8352368)]
  - 16 Rueda L, Cardenas A, Kelouwani S, *et al.* Transient event classification based on wavelet neuronal network and matched filters. Proceedings of the 44th Annual Conference of the IEEE Industrial Electronics Society. Washington: IEEE, 2018. 832–837. [doi: [10.1109/IECON.2018.8591684](https://doi.org/10.1109/IECON.2018.8591684)]
  - 17 Houidi S, Auger F, Sethom HBA, *et al.* Multivariate event detection methods for non-intrusive load monitoring in smart homes and residential buildings. *Energy and Buildings*, 2020, 208: 109624. [doi: [10.1016/j.enbuild.2019.109624](https://doi.org/10.1016/j.enbuild.2019.109624)]
  - 18 Zheng Z, Chen HN, Luo XW. A supervised event-based non-intrusive load monitoring for non-linear appliances. *Sustainability*, 2018, 10(4): 1001. [doi: [10.3390/su10041001](https://doi.org/10.3390/su10041001)]
  - 19 Afzalan M, Jazizadeh F, Wang J. Self-configuring event detection in electricity monitoring for human-building interaction. *Energy and Buildings*, 2019, 187: 95–109. [doi: [10.1016/j.enbuild.2019.01.036](https://doi.org/10.1016/j.enbuild.2019.01.036)]
  - 20 Lindahl PA, Ali MT, Armstrong P, *et al.* Nonintrusive load monitoring of variable speed drive cooling systems. *IEEE Access*, 2020, 8: 211451–211463. [doi: [10.1109/ACCESS.2020.3039408](https://doi.org/10.1109/ACCESS.2020.3039408)]
  - 21 Liu YC, Wang X, You W. Non-intrusive load monitoring by voltage-current trajectory enabled transfer learning. *IEEE Transactions on Smart Grid*, 2019, 10(5): 5609–5619. [doi: [10.1109/TSG.2018.2888581](https://doi.org/10.1109/TSG.2018.2888581)]
  - 22 Tayal A, Dewan L, Lather JS. Artificial neural network-based source identification producing harmonic pollution in the electric network. In: Dewan L, Bansal RC, Kalla UK, eds. *Advances in Renewable Energy and Sustainable Environment*. Singapore: Springer, 2021. 49–58.
  - 23 Inagaki S, Egami T, Suzuki T, *et al.* Nonintrusive appliance load monitoring based on integer programming. *Electrical Engineering in Japan*, 2011, 174(2): 18–25. [doi: [10.1002/ej.21040](https://doi.org/10.1002/ej.21040)]
  - 24 Leeb SB, Shaw SR, Kirtley JL. Transient event detection in spectral envelope estimates for nonintrusive load

- monitoring. *IEEE Transactions on Power Delivery*, 1995, 10(3): 1200–1210. [doi: [10.1109/61.400897](https://doi.org/10.1109/61.400897)]
- 25 Popescu F, Enache F, Vizitiu IC, *et al.* Recurrence plot analysis for characterization of appliance load signature. *Proceedings of 2014 10th International Conference on Communications*. Bucharest: IEEE, 2014. 1–4. [doi: [10.1109/ICComm.2014.6866747](https://doi.org/10.1109/ICComm.2014.6866747)]
- 26 Du L, Yang Y, He DW, *et al.* Feature extraction for load identification using long-term operating waveforms. *IEEE Transactions on Smart Grid*, 2015, 6(2): 819–826. [doi: [10.1109/TSG.2014.2373314](https://doi.org/10.1109/TSG.2014.2373314)]
- 27 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述. *电网技术*, 2016, 40(10): 3108–3117. [doi: [10.13335/j.1000-3673.pst.2016.10.026](https://doi.org/10.13335/j.1000-3673.pst.2016.10.026)]
- 28 Drouaz M, Colicchio B, Moukadem A, *et al.* New time-frequency transient features for nonintrusive load monitoring. *Energies*, 2021, 14(5): 1437. [doi: [10.3390/en14051437](https://doi.org/10.3390/en14051437)]
- 29 Hernandez AS, Ballado AH, Heredia APD. Development of a non-intrusive load monitoring (NILM) with unknown loads using support vector machine. *Proceedings of 2021 IEEE International Conference on Automatic Control & Intelligent Systems (I2CACIS)*. Shah Alam: IEEE, 2021. 203–207. [doi: [10.1109/I2CACIS52118.2021.9495876](https://doi.org/10.1109/I2CACIS52118.2021.9495876)]
- 30 Liang J, Ng S, Kendall G, *et al.* Load signature study  $\downarrow$  V part I: Basic concept, structure and methodology. *Proceedings of IEEE PES General Meeting*. Minneapolis: IEEE, 2010. 1. [doi: [10.1109/PES.2010.5589406](https://doi.org/10.1109/PES.2010.5589406)]
- 31 Dufour L, Genoud D, Jara A, *et al.* A non-intrusive model to predict the exible energy in a residential building. *Proceedings of 2015 IEEE Wireless Communications and Networking Conference Workshops (WCNCW)*. New Orleans: IEEE, 2015. 69–74. [doi: [10.1109/WCNCW.2015.7122531](https://doi.org/10.1109/WCNCW.2015.7122531)]
- 32 Jiang L, Li JM, Luo SH, *et al.* Power load event detection and classification based on edge symbol analysis and support vector machine. *Applied Computational Intelligence and Soft Computing*, 2012, 2012: 742461. [doi: [10.1155/2012/742461](https://doi.org/10.1155/2012/742461)]
- 33 Jiang L, Luo SH, Li JM. An approach of household power appliance monitoring based on machine learning. *Proceedings of 2012 5th International Conference on Intelligent Computation Technology and Automation*. Zhangjiajie: IEEE, 2012. 577–580. [doi: [10.1109/ICICTA.2012.151](https://doi.org/10.1109/ICICTA.2012.151)]
- 34 汪繁荣, 向堃, 吴铁洲. 基于 VMD 样本熵与随机森林的非侵入式设备状态检测方法. *现代电子技术*, 2021, 44(15): 104–108. [doi: [10.16652/j.issn.1004-373x.2021.15.021](https://doi.org/10.16652/j.issn.1004-373x.2021.15.021)]
- 35 宋旭帆, 周明, 涂京, 等. 基于 KNN 结合核 Fisher 判别非侵入式负荷监测方法. *电力系统自动化*, 2018, 42(6): 73–80. [doi: [10.7500/AEPS20170627011](https://doi.org/10.7500/AEPS20170627011)]
- 36 刘玲. 基于稳态特征的非侵入式负荷监测算法研究 [硕士学位论文]. 广州: 华南理工大学, 2019.
- 37 Wu X, Gao YC, Jiao D. Multi-label classification based on random forest algorithm for non-intrusive load monitoring system. *Processes*, 2019, 7(6): 337. [doi: [10.3390/pr7060337](https://doi.org/10.3390/pr7060337)]
- 38 Kramer O, Klingenberg T, Sonnenschein M, *et al.* Non-intrusive appliance load monitoring with bagging classifiers. *Logic Journal of the IGPL*, 2015, 23(3): 359–368. [doi: [10.1093/jigpal/jzv016](https://doi.org/10.1093/jigpal/jzv016)]
- 39 Hinton GE, Osindero S, Teh YW. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006, 18(7): 1527–1554. [doi: [10.1162/neco.2006.18.7.1527](https://doi.org/10.1162/neco.2006.18.7.1527)]
- 40 LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521(7553): 436–444. [doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539)]
- 41 Pouyanfar S, Sadiq S, Yan YL, *et al.* A survey on deep learning: Algorithms, techniques, and applications. *ACM Computing Surveys*, 2018, 51(5): 92.
- 42 Zhu CC, Chen FY, Ahmed U, *et al.* Semantic relation reasoning for shot-stable few-shot object detection. *Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville: IEEE, 2021. 8782–8791.
- 43 Lee CC, Sridhar K, Li JL, *et al.* Deep representation learning for affective speech signal analysis and processing: Preventing unwanted signal disparities. *IEEE Signal Processing Magazine*, 2021, 38(6): 22–38. [doi: [10.1109/MS P.2021.3105939](https://doi.org/10.1109/MS P.2021.3105939)]
- 44 Khurana S, Moritz N, Hori T, *et al.* Unsupervised domain adaptation for speech recognition via uncertainty driven self-training. *Proceedings of 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Toronto: IEEE, 2021. 6553–6557. [doi: [10.1109/ICASSP39728.2021.9414299](https://doi.org/10.1109/ICASSP39728.2021.9414299)]
- 45 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. *电力系统自动化*, 2019, 43(1): 126–132, 167. [doi: [10.7500/AEPS20180629004](https://doi.org/10.7500/AEPS20180629004)]
- 46 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. *电网技术*, 2020, 44(1): 27–34. [doi: [10.13335/j.1000-3673.pst.2019.0645](https://doi.org/10.13335/j.1000-3673.pst.2019.0645)]



- 47 Zhang CY, Zhong MJ, Wang ZZ, *et al.* Sequence-to-point learning with neural networks for non-intrusive load monitoring. Proceedings of the AAAI Conference on Artificial Intelligence (AAAI-18). Palo Alto: AAAI Press, 2018. 2604–2611. [doi: [10.1609/aaai.v32i1.11873](https://doi.org/10.1609/aaai.v32i1.11873)]
- 48 Qian YC, Yang QY, Li DH, *et al.* An improved temporal convolutional network for non-intrusive load monitoring. Proceedings of 2021 33rd Chinese Control and Decision Conference (CCDC). Kunming: IEEE, 2021. 2557–2562.
- 49 Tongta A, Chooruang K. Long short-term memory (LSTM) neural networks applied to energy disaggregation. Proceedings of 2020 8th International Electrical Engineering Congress (iEECON). Chiang Mai: IEEE, 2020. 1–4. [doi: [10.1109/iEECON48109.2020.229559](https://doi.org/10.1109/iEECON48109.2020.229559)]
- 50 De Diego-Otón L, Fuentes-Jimenez D, Hernández Á, *et al.* Recurrent LSTM architecture for appliance identification in non-intrusive load monitoring. Proceedings of 2021 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). Glasgow: IEEE, 2021. 1–6. [doi: [10.1109/I2MTC50364.2021.9460046](https://doi.org/10.1109/I2MTC50364.2021.9460046)]
- 51 Akarsh C, Varma SH, Rao PV. Time series analysis using LSTM for elderly care application. Proceedings of 2nd International Conference on Advances in Computer Engineering and Communication Systems. Singapore: Springer, 2022. 471–479.
- 52 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. 电网技术, 2019, 43(12): 4329–4336. [doi: [10.13335/j.1000-3673.pst.2019.1510](https://doi.org/10.13335/j.1000-3673.pst.2019.1510)]
- 53 Duan QY, Zhang F, Ren XY, *et al.* A non-intrusive loading monitoring method based on attention mechanism and denoising-autoencoder. Journal of Physics: Conference Series, 2021, 2005: 012224. [doi: [10.1088/1742-6596/2005/1/012224](https://doi.org/10.1088/1742-6596/2005/1/012224)]
- 54 Kaselimi M, Voulodimos A, Protopapadakis E, *et al.* EnerGAN: A generative adversarial network for energy disaggregation. Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Barcelona: IEEE, 2020. 1578–1582. [doi: [10.1109/ICASSP40776.2020.9054342](https://doi.org/10.1109/ICASSP40776.2020.9054342)]
- 55 Zeifman M, Roth K. Nonintrusive appliance load monitoring: Review and outlook. IEEE Transactions on Consumer Electronics, 2011, 57(1): 76–84. [doi: [10.1109/TCE.2011.5735484](https://doi.org/10.1109/TCE.2011.5735484)]
- 56 安国庆, 梁宇飞, 蒋子尧, 等. 基于 CF-MF-SE 联合特征的非侵入式负荷辨识. 河北科技大学学报, 2021, 42(5): 462–469. [doi: [10.7535/hbkd.2021yx05004](https://doi.org/10.7535/hbkd.2021yx05004)]
- 57 Wang AL, Chen BX, Wang CG, *et al.* Non-intrusive load monitoring algorithm based on features of  $V-I$  trajectory. Electric Power Systems Research, 2018, 157: 134–144. [doi: [10.1016/j.epsr.2017.12.012](https://doi.org/10.1016/j.epsr.2017.12.012)]
- 58 Kolter JZ, Jaakkola T. Approximate inference in additive factorial HMMs with application to energy disaggregation. Proceedings of the 15th International Conference on Artificial Intelligence and Statistics. La Palma: JMLR.org, 2012. 1472–1482.
- 59 Basu K, Debusschere V, Bacha S, *et al.* A generic data driven approach for low sampling load disaggregation. Sustainable Energy, Grids and Networks, 2017, 9: 118–127. [doi: [10.1016/j.segan.2016.12.006](https://doi.org/10.1016/j.segan.2016.12.006)]
- 60 Yu JY, Gao YC, Wu YX, *et al.* Non-intrusive load disaggregation by linear classifier group considering multi-feature integration. Applied Sciences, 2019, 9(17): 3558. [doi: [10.3390/app9173558](https://doi.org/10.3390/app9173558)]
- 61 Tabatabaei SM, Dick S, Xu W. Toward non-intrusive load monitoring via multi-label classification. IEEE Transactions on Smart Grid, 2017, 8(1): 26–40. [doi: [10.1109/TSG.2016.2584581](https://doi.org/10.1109/TSG.2016.2584581)]
- 62 Liao J, Elafoudi G, Stankovic L, *et al.* Non-intrusive appliance load monitoring using low-resolution smart meter data. Proceedings of 2014 IEEE International Conference on Smart Grid Communications (SmartGridComm). Venice: IEEE, 2014. 535–540. [doi: [10.1109/SmartGridComm.2014.7007702](https://doi.org/10.1109/SmartGridComm.2014.7007702)]
- 63 Zhao BC, Stankovic L, Stankovic V. Blind non-intrusive appliance load monitoring using graph-based signal processing. Proceedings of 2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Orlando: IEEE, 2015. 68–72. [doi: [10.1109/GlobalSIP.2015.7418158](https://doi.org/10.1109/GlobalSIP.2015.7418158)]
- 64 Parson O, Ghosh S, Weal M, *et al.* Non-intrusive load monitoring using prior models of general appliance types. Proceedings of the 26th AAAI Conference on Artificial Intelligence. Toronto: AAAI Press, 2012. 356–362.
- 65 Racines D, Candelo JE, Montaña J. Non-intrusive electrical load monitoring system applying neural networks with combined steady-state electrical variables. Tehnički Vjesnik, 2018, 25(5): 1321–1329.
- 66 Sun W, Pang XF, Geng HN, *et al.* Non-intrusive residential load decomposition method based on steady state feature extraction. Proceedings of 2021 33rd Chinese Control and Decision Conference (CCDC). Kunming: IEEE, 2021. 1425–1430. [doi: [10.1109/CCDC52312.2021.9601439](https://doi.org/10.1109/CCDC52312.2021.9601439)]
- 67 祁兵, 董超, 武昕, 等. 基于 DTW 算法与稳态电流波形的

- 非侵入式负荷辨识方法. 电力系统自动化, 2018, 42(3): 70–76. [doi: [10.7500/AEPS20170103001](https://doi.org/10.7500/AEPS20170103001)]
- 68 Gray M, Morsi WG. Application of wavelet-based classification in non-intrusive load monitoring. Proceedings of 2015 IEEE 28th Canadian Conference on Electrical and Computer Engineering (CCECE). Halifax: IEEE, 2015. 41–45. [doi: [10.1109/CCECE.2015.7129157](https://doi.org/10.1109/CCECE.2015.7129157)]
- 69 Timplalexis C, Angelis GF, Krinidis S, *et al.* Low frequency residential non-intrusive load monitoring based on a hybrid feature extraction tree-learning approach. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, 2022, 44(1): 493–514. [doi: [10.1080/15567036.2022.2046663](https://doi.org/10.1080/15567036.2022.2046663)]
- 70 De Paula Rodrigues R, Da Silveira PM. Curvature scale space-based signatures for electrical load classification in NILM. Electrical Engineering, 2021, 103(2): 1239–1252. [doi: [10.1007/s00202-020-01183-4](https://doi.org/10.1007/s00202-020-01183-4)]
- 71 Djordjevic S, Simic M. Nonintrusive identification of residential appliances using harmonic analysis. Turkish Journal of Electrical Engineering & Computer Sciences, 2018, 26(2): 780–791. [doi: [10.3906/elk-1705-262](https://doi.org/10.3906/elk-1705-262)]
- 72 Djordjevic S, Simic M. Appliance level load monitoring based on the steady-state harmonic analysis. Proceedings of XIV International Conference SAUM. Niš, 2018.
- 73 Bouhouras AS, Vaggos M, Poulakis N, *et al.* Load signatures enhancement via odd-order harmonic currents. Proceedings of 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC). Florence: IEEE, 2016. 1–6. [doi: [10.1109/EEEIC.2016.7555497](https://doi.org/10.1109/EEEIC.2016.7555497)]
- 74 Huang XQ, Yin B, Zhang R, *et al.* Study of steady-state feature extraction algorithm based on EMD. IOP Conference Series: Materials Science and Engineering, 2019, 490(6): 062036.
- 75 Alcalá J, Ureña J, Hernández Á, *et al.* Event-based energy disaggregation algorithm for activity monitoring from a single-point sensor. IEEE Transactions on Instrumentation and Measurement, 2017, 66(10): 2615–2626. [doi: [10.1109/TIM.2017.2700987](https://doi.org/10.1109/TIM.2017.2700987)]
- 76 Sadeghianpourhamami N, Ruysinck J, Deschrijver D, *et al.* Comprehensive feature selection for appliance classification in NILM. Energy and Buildings, 2017, 151: 98–106. [doi: [10.1016/j.enbuild.2017.06.042](https://doi.org/10.1016/j.enbuild.2017.06.042)]
- 77 Cole AI, Albicki A. Data extraction for effective non-intrusive identification of residential power loads. Proceedings of IEEE Instrumentation and Measurement Technology Conference. Where Instrumentation is Going (Cat. No. 98CH36222). Paul: IEEE, 1998. 812–815. [doi: [10.1109/IMTC.1998.676838](https://doi.org/10.1109/IMTC.1998.676838)]
- 78 朱乔木, 党杰, 陈金富, 等. 基于深度置信网络的电力系统暂态稳定评估方法. 中国电机工程学报, 2018, 38(3): 735–743. [doi: [10.13334/j.0258-8013.pcsee.162436](https://doi.org/10.13334/j.0258-8013.pcsee.162436)]
- 79 Lü W, Cai ZQ, Chu JH. Load Identification based on S-transform and (2D)<sup>2</sup>PCA of transient current. Laser & Optoelectronics Progress, 2018, 55(8): 080701.
- 80 Sirojan T, Phung T, Ambikairajah E. Intelligent edge analytics for load identification in smart meters. Proceedings of 2017 IEEE Innovative Smart Grid Technologies-Asia (ISGT-Asia). Auckland: IEEE, 2017. 1–5.
- 81 Gulati M, Ram SS, Singh A. An in depth study into using EMI signatures for appliance identification. Proceedings of the 1st ACM Conference on Embedded Systems for Energy-efficient Buildings. Memphis: ACM, 2014. 70–79. [doi: [10.1145/2674061.2674070](https://doi.org/10.1145/2674061.2674070)]
- 82 Lee D. Phase noise as power characteristic of individual appliance for non-intrusive load monitoring. Electronics Letters, 2018, 54(16): 993–995. [doi: [10.1049/el.2018.5331](https://doi.org/10.1049/el.2018.5331)]
- 83 Zhang L, Shi SW. A non-intrusive load monitoring method based on multi-scale wavelet packet optimization and transient feature matching. Proceedings of 2021 IEEE 12th International Conference on Software Engineering and Service Science (ICSESS). Beijing: IEEE, 2021. 113–117. [doi: [10.1109/ICSESS52187.2021.9522251](https://doi.org/10.1109/ICSESS52187.2021.9522251)]
- 84 Gillis JM, Alshareef SM, Morsi WG. Nonintrusive load monitoring using wavelet design and machine learning. IEEE Transactions on Smart Grid, 2016, 7(1): 320–328. [doi: [10.1109/TSG.2015.2428706](https://doi.org/10.1109/TSG.2015.2428706)]
- 85 Chang HH. Non-intrusive demand monitoring and load identification for energy management systems based on transient feature analyses. Energies, 2012, 5(11): 4569–4589. [doi: [10.3390/en5114569](https://doi.org/10.3390/en5114569)]
- 86 Liu B, Luan WP, Yu YX. Dynamic time warping based non-intrusive load transient identification. Applied Energy, 2017, 195: 634–645. [doi: [10.1016/j.apenergy.2017.03.010](https://doi.org/10.1016/j.apenergy.2017.03.010)]
- 87 Rathore V, Jain SK. Non intrusive load monitoring and load disaggregation using transient data analysis. Proceedings of 2018 Conference on Information and Communication Technology (CICT). Jabalpur: IEEE, 2018. 1–5. [doi: [10.1109/INFOCOMTECH.2018.8722382](https://doi.org/10.1109/INFOCOMTECH.2018.8722382)]
- 88 Rehman AU, Lie TT, Vallès B, *et al.* Comparative evaluation of machine learning models and input feature space for non-intrusive load monitoring. Journal of Modern

- Power Systems and Clean Energy, 2021, 9(5): 1161–1171. [doi: [10.35833/MPCE.2020.000741](https://doi.org/10.35833/MPCE.2020.000741)]
- 89 Iksan N, Sembiring J, Haryanto N, *et al.* Appliances identification method of non-intrusive load monitoring based on load signature of  $V-I$  trajectory. Proceedings of 2015 International Conference on Information Technology Systems and Innovation (ICITSI). Bandung: IEEE, 2015. 1–6. [doi: [10.1109/ICITSI.2015.7437744](https://doi.org/10.1109/ICITSI.2015.7437744)]
- 90 Mulinari BM, De Campos DP, Da Costa CH, *et al.* A new set of steady-state and transient features for power signature analysis based on V-I trajectory. Proceedings of 2019 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America). Gramado: IEEE, 2019. 1–6. [doi: [10.1109/ISGT-LA.2019.8895360](https://doi.org/10.1109/ISGT-LA.2019.8895360)]
- 91 Meehan P, McArdle C, Daniels S. An efficient, scalable time-frequency method for tracking energy usage of domestic appliances using a two-step classification algorithm. *Energies*, 2014, 7(11): 7041–7066. [doi: [10.3390/en7117041](https://doi.org/10.3390/en7117041)]
- 92 Kumar DS, Low KL, Sharma A, *et al.* Non-intrusive load monitoring using feed forward neural network. Proceedings of 2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia). Chengdu: IEEE, 2019. 4065–4069.
- 93 Ancelmo HC, Grando FL, Mulinari BM, *et al.* A transient and steady-state power signature feature extraction using different Prony's methods. Proceedings of the 2019 20th International Conference on Intelligent System Application to Power Systems (ISAP). New Delhi: IEEE, 2019. 1–6. [doi: [10.1109/ISAP48318.2019.9065959](https://doi.org/10.1109/ISAP48318.2019.9065959)]
- 94 Andrian V, Zhao XH, Teshome DF, *et al.* A hybrid method of cascade-filtering and committee decision mechanism for non-intrusive load monitoring. *IEEE Access*, 2018, 6: 41212–41223. [doi: [10.1109/ACCESS.2018.2856278](https://doi.org/10.1109/ACCESS.2018.2856278)]
- 95 Kim H, Marwah M, Arlitt M, *et al.* Unsupervised disaggregation of low frequency power measurements. In: Liu B, Liu H, Clifton C, eds. Proceedings of the 2011 SIAM International Conference on Data Mining. Mesa: SIAM, 2011. 747–758. [doi: [10.1137/1.9781611972818.64](https://doi.org/10.1137/1.9781611972818.64)]
- 96 Fan YC, Liu X, Lee WC, *et al.* Efficient time series disaggregation for non-intrusive appliance load monitoring. Proceedings of 2012 9th International Conference on Ubiquitous Intelligence and Computing and 9th International Conference on Autonomic and Trusted Computing. Fukuoka: IEEE, 2012. 248–255. [doi: [10.1109/UIC-ATC.2012.122](https://doi.org/10.1109/UIC-ATC.2012.122)]
- 97 Ahmadi H, Marti JR. Load decomposition at smart meters level using eigenloads approach. *IEEE Transactions on Power Systems*, 2015, 30(6): 3425–3436. [doi: [10.1109/TPWRS.2014.2388193](https://doi.org/10.1109/TPWRS.2014.2388193)]
- 98 Bellasi D, Crescentini M, Cristaudo D, *et al.* A broadband multi-mode compressive sensing current sensor SoC in 0.16  $\mu\text{m}$  CMOS. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2019, 66(1): 105–118. [doi: [10.1109/TCSI.2018.2846573](https://doi.org/10.1109/TCSI.2018.2846573)]
- 99 Chang HH, Chen KL, Tsai YP, *et al.* A new measurement method for power signatures of nonintrusive demand monitoring and load identification. *IEEE Transactions on Industry Applications*, 2012, 48(2): 764–771. [doi: [10.1109/TIA.2011.2180497](https://doi.org/10.1109/TIA.2011.2180497)]
- 100 Kong S, Kim Y, Ko R, *et al.* Home appliance load disaggregation using cepstrum-smoothing-based method. *IEEE Transactions on Consumer Electronics*, 2015, 61(1): 24–30. [doi: [10.1109/TCE.2015.7064107](https://doi.org/10.1109/TCE.2015.7064107)]
- 101 Kolter JZ, Johnson MJ. REDD: A public data set for energy disaggregation research. Proceedings of Workshop on Data Mining Applications in Sustainability. San Diego, 2011. 59–62.
- 102 Zimmermann JP, Evans M, Griggs J, *et al.* Household electricity survey: A study of domestic electrical product usage. Intertek Testing & Certification Ltd, 2012: 213–214.
- 103 Anderson K, Ocleanu A, Benitez D, *et al.* BLUED: A fully labeled public dataset for event-based non-intrusive load monitoring research. Proceedings of the 2nd KDD Workshop on Data Mining Applications in Sustainability (SustKDD). Beijing: ACM, 2012. 12–16.
- 104 Reinhardt A, Baumann P, Burgstahler D, *et al.* On the accuracy of appliance identification based on distributed load metering data. Proceedings of 2012 Sustainable Internet and ICT for Sustainability (SustainIT). Pisa: IEEE, 2012. 1–9.
- 105 Barker S, Mishra A, Irwin D, *et al.* Smart\*: An open data set and tools for enabling research in sustainable homes. Proceedings of ACM SustKDD. Beijing: ACM, 2012. 108.
- 106 Bache K, Lichman M. Individual household electric power consumption dataset. Technical Report, Irvine: University of California, 2013.
- 107 Saldanha N, Beausoleil-Morrison I. Measured end-use electric load profiles for 12 Canadian houses at high temporal resolution. *Energy and Buildings*, 2012, 49: 519–530. [doi: [10.1016/j.enbuild.2012.02.050](https://doi.org/10.1016/j.enbuild.2012.02.050)]
- 108 Johnson G, Beausoleil-Morrison I. Electrical-end-use data from 23 houses sampled each minute for simulating micro-

- generation systems. *Applied Thermal Engineering*, 2017, 114:1449–1456. [doi: [10.1016/j.applthermaleng.2016.07.133](https://doi.org/10.1016/j.applthermaleng.2016.07.133)]
- 109 Makonin S, Popowich F, Bartram L, *et al.* AMPds: A public dataset for load disaggregation and eco-feedback research. *Proceedings of 2013 IEEE Electrical Power & Energy Conference*. Halifax: IEEE, 2013. 1–6. [doi: [10.1109/EPEC.2013.6802949](https://doi.org/10.1109/EPEC.2013.6802949)]
- 110 Makonin S, Ellert B, Bajić IV, *et al.* Electricity, water, and natural gas consumption of a residential house in Canada from 2012 to 2014. *Scientific Data*, 2016, 3(1): 160037. [doi: [10.1038/sdata.2016.37](https://doi.org/10.1038/sdata.2016.37)]
- 111 Gisler C, Ridi A, Zufferey D, *et al.* Appliance consumption signature database and recognition test protocols. *Proceedings of 2013 8th International Workshop on Systems, Signal Processing and their Applications (WoSSPA)*. Algiers: IEEE, 2013. 336–341. [doi: [10.1109/WoSSPA.2013.6602387](https://doi.org/10.1109/WoSSPA.2013.6602387)]
- 112 Ridi A, Gisler C, Hennebert J. ACS-F2—A new database of appliance consumption signatures. *Proceedings of 2014 6th International Conference of Soft Computing and Pattern Recognition (SoCPar)*. Tunis: IEEE, 2014. 145–150. [doi: [10.1109/SOCPAR.2014.7007996](https://doi.org/10.1109/SOCPAR.2014.7007996)]
- 113 Maasoumy M, Sanandaji B, Poolla K, *et al.* BERDS-BERkeley energy disaggregation data set. *Proceedings of the Workshop on Big Learning at the Conference on Neural Information Processing Systems (NIPS)*. Berkely: NIPS, 2013. 1–6.
- 114 Gao JK, Giri SM, Kara EC, *et al.* PLAID: A public dataset of high-resolution electrical appliance measurements for load identification research: Demo abstract. *Proceedings of the 1st ACM Conference on Embedded Systems for Energy-efficient Buildings*. Memphis: ACM, 2014. 198–199. [doi: [10.1145/2674061.2675032](https://doi.org/10.1145/2674061.2675032)]
- 115 Pereira L, Quintal F, Gonçalves R, *et al.* SustData: A public dataset for ICT4S electric energy research. *Proceedings of ICT for Sustainability 2014 (ICT4S-14)*. Stockholm: Atlantis Press, 2014.
- 116 Parson O, Fisher G, Hersey A, *et al.* Dataport and NILMTK: A building data set designed for non-intrusive load monitoring. *Proceedings of 2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. Orlando: IEEE, 2015. 210–214. [doi: [10.1109/GlobalSIP.2015.7418187](https://doi.org/10.1109/GlobalSIP.2015.7418187)]
- 117 Batra N, Gulati M, Singh A, *et al.* It’s different: Insights into home energy consumption in India. *Proceedings of the 5th ACM Workshop on Embedded Systems for Energy-efficient Buildings*. Roma: ACM, 2013. 1–8.
- 118 Monacchi A, Egarter D, Elmenreich W, *et al.* GREEND: An energy consumption dataset of households in Italy and Austria. *Proceedings of 2014 IEEE International Conference on Smart Grid Communications (SmartGridComm)*. Venice: IEEE, 2014. 511–516.
- 119 Murray D, Stankovic L, Stankovic V. An electrical load measurements dataset of United Kingdom households from a two-year longitudinal study. *Scientific Data*, 2017, 4(1): 160122. [doi: [10.1038/sdata.2016.122](https://doi.org/10.1038/sdata.2016.122)]
- 120 Beckel C, Kleiminger W, Cicchetti R, *et al.* The ECO data set and the performance of non-intrusive load monitoring algorithms. *Proceedings of the 1st ACM Conference on Embedded Systems for Energy-efficient Buildings*. New York: ACM, 2014. 80–89.
- 121 Kelly J, Knottenbelt W. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. *Scientific Data*, 2015, 2(1): 150007. [doi: [10.1038/sdata.2015.7](https://doi.org/10.1038/sdata.2015.7)]
- 122 De Mello Martins P, Nascimento VB, De Freitas AR, *et al.* Industrial Machines Dataset for Electrical Load Disaggregation. New York: IEEE DataPort, 2020.
- 123 Makonin S, Wang ZJ, Tumpach C. RAE: The rainforest automation energy dataset for smart grid meter data analysis. *Data*, 2018, 3(1): 8. [doi: [10.3390/data3010008](https://doi.org/10.3390/data3010008)]
- 124 Kriechbaumer T, Jacobsen HA. BLOND, a building-level office environment dataset of typical electrical appliances. *Scientific Data*, 2018, 5(1): 180048. [doi: [10.1038/sdata.2018.48](https://doi.org/10.1038/sdata.2018.48)]
- 125 Chen VL, Delmas MA, Locke SL, *et al.* Dataset on information strategies for energy conservation: A field experiment in India. *Data in Brief*, 2018, 16: 713–716. [doi: [10.1016/j.dib.2017.11.084](https://doi.org/10.1016/j.dib.2017.11.084)]
- 126 Shin C, Lee E, Han J, *et al.* The ENERTALK dataset, 15 Hz electricity consumption data from 22 houses in Korea. *Scientific Data*, 2019, 6(1): 193. [doi: [10.1038/s41597-019-0212-5](https://doi.org/10.1038/s41597-019-0212-5)]
- 127 Rashid H, Singh P, Singh A. I-BLEND, a campus-scale commercial and residential buildings electrical energy dataset. *Scientific Data*, 2019, 6(1): 190015. [doi: [10.1038/sdata.2019.15](https://doi.org/10.1038/sdata.2019.15)]
- 128 Makonin S. HUE: The hourly usage of energy dataset for buildings in British Columbia. *Data in Brief*, 2019, 23: 103744. [doi: [10.1016/j.dib.2019.103744](https://doi.org/10.1016/j.dib.2019.103744)]
- 129 Himeur Y, Alsalemi A, Bensaali F, *et al.* Building power consumption datasets: Survey, taxonomy and future

- directions. *Energy and Buildings*, 2020, 227: 110404. [doi: [10.1016/j.enbuild.2020.110404](https://doi.org/10.1016/j.enbuild.2020.110404)]
- 130 Klemenjak C, Kovatsch C, Herold M, *et al.* A synthetic energy dataset for non-intrusive load monitoring in households. *Scientific Data*, 2020, 7(1): 108. [doi: [10.1038/s41597-020-0434-6](https://doi.org/10.1038/s41597-020-0434-6)]
- 131 Huber P, Ott M, Friedli M, *et al.* Residential power traces for five houses: The iHomeLab RAPT dataset. *Data*, 2020, 5(1): 17. [doi: [10.3390/data5010017](https://doi.org/10.3390/data5010017)]
- 132 Chen C, Gao PH, Jiang JG, *et al.* A deep learning based non-intrusive household load identification for smart grid in China. *Computer Communications*, 2021, 177: 176–184. [doi: [10.1016/j.comcom.2021.06.023](https://doi.org/10.1016/j.comcom.2021.06.023)]
- 133 Chen JF, Wang X, Zhang XT, *et al.* Temporal and spectral feature learning with two-stream convolutional neural networks for appliance recognition in NILM. *IEEE Transactions on Smart Grid*, 2022, 13(1): 762–772. [doi: [10.1109/TSG.2021.3112341](https://doi.org/10.1109/TSG.2021.3112341)]
- 134 Jia ZY, Yang LF, Zhang ZR, *et al.* Sequence to point learning based on bidirectional dilated residual network for non-intrusive load monitoring. *International Journal of Electrical Power & Energy Systems*, 2021, 129: 106837. [doi: [10.1016/j.ijepes.2021.106837](https://doi.org/10.1016/j.ijepes.2021.106837)]
- 135 Kaselimi M, Doulamis N, Doulamis A, *et al.* Bayesian-optimized bidirectional LSTM regression model for non-intrusive load monitoring. *Proceedings of 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Brighton: IEEE, 2019. 2747–2751. [doi: [10.1109/ICASSP.2019.8683110](https://doi.org/10.1109/ICASSP.2019.8683110)]
- 136 Kaselimi M, Doulamis N, Voulodimos A, *et al.* Context aware energy disaggregation using adaptive bidirectional LSTM models. *IEEE Transactions on Smart Grid*, 2020, 11(4): 3054–3067. [doi: [10.1109/TSG.2020.2974347](https://doi.org/10.1109/TSG.2020.2974347)]
- 137 Goodfellow IJ, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets. *Proceedings of the 27th International Conference on Neural Information Processing Systems*. Montreal: MIT Press, 2014. 2672–2680.
- 138 Lin N, Zhou BG, Yang GH, *et al.* Multi-head attention networks for nonintrusive load monitoring. *Proceedings of 2020 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)*. Macao: IEEE, 2020. 1–5. [doi: [10.1109/ICSPCC50002.2020.9259533](https://doi.org/10.1109/ICSPCC50002.2020.9259533)]
- 139 Langevin A, Carbonneau MA, Cheriet M, *et al.* Energy disaggregation using variational autoencoders. *Energy and Buildings*, 2022, 254: 111623. [doi: [10.1016/j.enbuild.2021.111623](https://doi.org/10.1016/j.enbuild.2021.111623)]
- 140 Faustine A, Pereira L, Bousbiat H, *et al.* UNet-NILM: A deep neural network for multi-tasks appliances state detection and power estimation in NILM. *Proceedings of the 5th International Workshop on Non-intrusive Load Monitoring*. ACM, 2020. 84–88. [doi: [10.1145/3427771.3427859](https://doi.org/10.1145/3427771.3427859)]
- 141 Yue ZR, Witzig CR, Jorde D, *et al.* BERT4NILM: A bidirectional transformer model for non-intrusive load monitoring. *Proceedings of the 5th International Workshop on Non-intrusive Load Monitoring*. ACM, 2020. 89–93. [doi: [10.1145/3427771.3429390](https://doi.org/10.1145/3427771.3429390)]
- 142 Kaselimi M, Voulodimos A, Doulamis N, *et al.* A robust to noise adversarial recurrent model for non-intrusive load monitoring. *Proceedings of 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Toronto: IEEE, 2021. 3335–3339. [doi: [10.1109/ICASSP39728.2021.9413663](https://doi.org/10.1109/ICASSP39728.2021.9413663)]
- 143 Zhou X, Li SJ, Liu CX, *et al.* Non-intrusive load monitoring using a CNN-LSTM-RF model considering label correlation and class-imbalance. *IEEE Access*, 2021, 9: 84306–84315. [doi: [10.1109/ACCESS.2021.3087696](https://doi.org/10.1109/ACCESS.2021.3087696)]
- 144 García-Pérez D, Pérez-López D, Díaz-Blanco I, *et al.* Fully-convolutional denoising auto-encoders for NILM in large non-residential buildings. *IEEE Transactions on Smart Grid*, 2021, 12(3): 2722–2731. [doi: [10.1109/TSG.2020.3047712](https://doi.org/10.1109/TSG.2020.3047712)]
- 145 Çimen H, Wu Y, Wu YP, *et al.* Deep learning-based probabilistic autoencoder for residential energy disaggregation: An adversarial approach. *IEEE Transactions on Industrial Informatics*, 2022, 18(12): 8399–8408. [doi: [10.1109/TII.2022.3150334](https://doi.org/10.1109/TII.2022.3150334)]
- 146 Lin J, Ma J, Zhu JG, *et al.* Deep domain adaptation for non-intrusive load monitoring based on a knowledge transfer learning network. *IEEE Transactions on Smart Grid*, 2022, 13(1): 280–292. [doi: [10.1109/TSG.2021.3115910](https://doi.org/10.1109/TSG.2021.3115910)]
- 147 Kaselimi M, Protopapadakis E, Voulodimos A, *et al.* Multi-channel recurrent convolutional neural networks for energy disaggregation. *IEEE Access*, 2019, 7: 81047–81056. [doi: [10.1109/ACCESS.2019.2923742](https://doi.org/10.1109/ACCESS.2019.2923742)]
- 148 Harell A, Makonin S, Bajić IV. Wavenilm: A causal neural network for power disaggregation from the complex power signal. *Proceedings of 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Brighton: IEEE, 2019. 8335–8339.
- 149 Rafiq H, Shi XH, Zhang HX, *et al.* A deep recurrent neural network for non-intrusive load monitoring based on multi-feature input space and post-processing. *Energies*, 2020,

- 13(9): 2195. [doi: [10.3390/en13092195](https://doi.org/10.3390/en13092195)]
- 150 Kim JG, Lee B. Appliance classification by power signal analysis based on multi-feature combination multi-layer LSTM. *Energies*, 2019, 12(14): 2804. [doi: [10.3390/en12142804](https://doi.org/10.3390/en12142804)]
- 151 He KH, Stankovic L, Liao J, *et al.* Non-intrusive load disaggregation using graph signal processing. *IEEE Transactions on Smart Grid*, 2018, 9(3): 1739–1747. [doi: [10.1109/TSG.2016.2598872](https://doi.org/10.1109/TSG.2016.2598872)]
- 152 Ouali Y, Hudelot C, Tami M. An overview of deep semi-supervised learning. *arXiv:2006.05278*, 2020.
- 153 Li MX, Zhu XT, Gong SG. Unsupervised person re-identification by deep learning tracklet association. *Proceedings of the 15th European Conference on Computer Vision*. Cham: Springer, 2018. 772–788.
- 154 Chen XK, Yuan YH, Zeng G, *et al.* Semi-supervised semantic segmentation with cross pseudo supervision. *Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Glasgow: IEEE, 2021. 2613–2622.
- 155 Zhu S, Cao RS, Yu K. Dual learning for semi-supervised natural language understanding. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2020, 28: 1936–1947. [doi: [10.1109/TASLP.2020.3001684](https://doi.org/10.1109/TASLP.2020.3001684)]
- 156 Ling SS, Liu YZ, Salazar J, *et al.* Deep contextualized acoustic representations for semi-supervised speech recognition. *Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Barcelona: IEEE, 2020. 6429–6433. [doi: [10.1109/ICASSP40776.2020.9053176](https://doi.org/10.1109/ICASSP40776.2020.9053176)]
- 157 张致强, 周步祥, 张冰, 等. 计及小波设计和半监督机器学习非侵入式负载识别. *电力系统及其自动化学报*, 2020, 32(5): 143–150. [doi: [10.19635/j.cnki.csu-epsa.000253](https://doi.org/10.19635/j.cnki.csu-epsa.000253)]
- 158 Liu YY, Zhong L, Qiu J, *et al.* Unsupervised domain adaptation for nonintrusive load monitoring via adversarial and joint adaptation network. *IEEE Transactions on Industrial Informatics*, 2022, 18(1): 266–277. [doi: [10.1109/TII.2021.3065934](https://doi.org/10.1109/TII.2021.3065934)]
- 159 Yang YD, Zhong J, Li W, *et al.* Semisupervised multilabel deep learning based nonintrusive load monitoring in smart grids. *IEEE Transactions on Industrial Informatics*, 2020, 16(11): 6892–6902. [doi: [10.1109/TII.2019.2955470](https://doi.org/10.1109/TII.2019.2955470)]
- 160 Miao N, Zhao SJ, Shi QJ, *et al.* Non-intrusive load disaggregation using semi-supervised learning method. *Proceedings of 2019 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC)*. Guangzhou: IEEE, 2019. 17–22. [doi: [10.1109/SPAC49953.2019.237865](https://doi.org/10.1109/SPAC49953.2019.237865)]
- 161 Harell A, Jones R, Makonin S, *et al.* TraceGAN: Synthesizing appliance power signatures using generative adversarial networks. *IEEE Transactions on Smart Grid*, 2021, 12(5): 4553–4563. [doi: [10.1109/TSG.2021.3078695](https://doi.org/10.1109/TSG.2021.3078695)]
- 162 Chang FY, Chen C, Lin SD. An empirical study of ladder network and multitask learning on energy disaggregation in Taiwan. *Proceedings of 2018 Conference on Technologies and Applications of Artificial Intelligence (TAAI)*. Taichung: IEEE, 2018. 86–89. [doi: [10.1109/TAAI.2018.00028](https://doi.org/10.1109/TAAI.2018.00028)]
- 163 Miyato T, Maeda SI, Koyama M, *et al.* Virtual adversarial training: A regularization method for supervised and semi-supervised learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(8): 1979–1993. [doi: [10.1109/TPAMI.2018.2858821](https://doi.org/10.1109/TPAMI.2018.2858821)]
- 164 余登武, 刘敏. 基于深度卷积神经网络与支持向量机的变电站非侵入式负荷分解. *电力科学与工程*, 2020, 36(6): 24–30. [doi: [10.3969/j.issn.1672-0792.2020.06.004](https://doi.org/10.3969/j.issn.1672-0792.2020.06.004)]
- 165 刘仲民, 侯坤福, 高敬更, 等. 基于时间卷积神经网络的非侵入式居民用电负荷分解方法. *电力建设*, 2021, 42(3): 97–106. [doi: [10.12204/j.issn.1000-7229.2021.03.012](https://doi.org/10.12204/j.issn.1000-7229.2021.03.012)]
- 166 Barber J, Cuayáhuitl H, Zhong MJ, *et al.* Lightweight non-intrusive load monitoring employing pruned sequence-to-point learning. *Proceedings of the 5th International Workshop on Non-intrusive Load Monitoring*. ACM, 2020. 11–15. [doi: [10.1145/3427771.3427845](https://doi.org/10.1145/3427771.3427845)]
- 167 Wang H, Zhang QM, Wang YH, *et al.* Structured probabilistic pruning for convolutional neural network acceleration. *Proceedings of British Machine Vision Conference 2018*. Newcastle: BMVA Press, 2018. 149.
- 168 Hur C, Kang S. Entropy-based pruning method for convolutional neural networks. *The Journal of Supercomputing*, 2019, 75(6): 2950–2963. [doi: [10.1007/s11227-018-2684-z](https://doi.org/10.1007/s11227-018-2684-z)]
- 169 Ashouri AH, Abdelrahman TS, Dos Remedios A. Retraining-free methods for fast on-the-fly pruning of convolutional neural networks. *Neurocomputing*, 2019, 370: 56–69. [doi: [10.1016/j.neucom.2019.08.063](https://doi.org/10.1016/j.neucom.2019.08.063)]
- 170 Shabarinath BB, Muralidhar P. Convolutional neural network based traffic-sign classifier optimized for edge inference. *Proceedings of 2020 IEEE Region 10 Conference (Tencon)*. Osaka: IEEE, 2020. 420–425. [doi: [10.1109/TENCON50793.2020.9293767](https://doi.org/10.1109/TENCON50793.2020.9293767)]
- 171 Wang XY, Zhou H, Freris NM, *et al.* LCL: Light contactless low-delay load monitoring via compressive

- attentional multi-label learning. Proceedings of 2021 IEEE/ACM 29th International Symposium on Quality of Service (IWQOS). Tokyo: IEEE, 2021. 1–6. [doi: [10.1109/IWQOS52092.2021.9521262](https://doi.org/10.1109/IWQOS52092.2021.9521262)]
- 172 Denton E, Zaremba W, Bruna J, *et al.* Exploiting linear structure within convolutional networks for efficient evaluation. Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2014. 1269–1277.
- 173 Zhao J, Chevalier F, Collins C, *et al.* Facilitating discourse analysis with interactive visualization. IEEE Transactions on Visualization and Computer Graphics, 2012, 18(12): 2639–2648. [doi: [10.1109/TVCG.2012.226](https://doi.org/10.1109/TVCG.2012.226)]
- 174 何健明, 李梦诗, 张禄亮, 等. 基于知识蒸馏和半监督学习的非侵入式负荷分解. 广东电力, 2021, 34(9): 60–70. [doi: [10.3969/j.issn.1007-290X.2021.009.008](https://doi.org/10.3969/j.issn.1007-290X.2021.009.008)]
- 175 Zhuang ZW, Tan MK, Zhuang BH, *et al.* Discrimination-aware channel pruning for deep neural networks. Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal: Curran Associates Inc., 2018. 883–894.
- 176 Xu SK, Li HK, Zhuang BH, *et al.* Generative low-bitwidth data free quantization. Proceedings of 16th European Conference on Computer Vision. Cham: Springer, 2020. 1–17.
- 177 Xie Z, Wen ZQ, Liu J, *et al.* Deep transferring quantization. Proceedings of 16th European Conference on Computer Vision. Cham: Springer, 2020. 625–642.
- 178 Niu SC, Wu JX, Xu GH, *et al.* Adaxpert: Adapting neural architecture for growing data. Proceedings of the 38th International Conference on Machine Learning. PMLR, 2021. 8184–8194.
- 179 Murray D, Stankovic L, Stankovic V, *et al.* Transferability of neural network approaches for low-rate energy disaggregation. Proceedings of 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Brighton: IEEE, 2019. 8330–8334. [doi: [10.1109/ICASSP.2019.8682486](https://doi.org/10.1109/ICASSP.2019.8682486)]
- 180 Ahmed AMA, Zhang Y, Eliassen F. Generative adversarial networks and transfer learning for non-intrusive load monitoring in smart grids. Proceedings of 2020 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm). Tempe: IEEE, 2020. 1–7. [doi: [10.1109/SmartGridComm47815.2020.9302933](https://doi.org/10.1109/SmartGridComm47815.2020.9302933)]
- 181 D’Incecco M, Squartini S, Zhong MJ. Transfer learning for non-intrusive load monitoring. IEEE Transactions on Smart Grid, 2020, 11(2): 1419–1429. [doi: [10.1109/TSG.2019.2938068](https://doi.org/10.1109/TSG.2019.2938068)]
- 182 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. 电网技术, 2018, 42(10): 3268–3274. [doi: [10.13335/j.1000-3673.pst.2017.3009](https://doi.org/10.13335/j.1000-3673.pst.2017.3009)]
- 183 McMahan B, Moore E, Ramage D, *et al.* Communication-efficient learning of deep networks from decentralized data. Proceedings of the 20th International Conference on Artificial Intelligence and Statistics. Lauderdale: PMLR, 2017. 1273–1282.

(校对责编: 孙君艳)