

基于多时间尺度深度学习的商业建筑非侵入式 负荷分解方法

王楠¹, 高正浩¹, 蒋思宇², 解戴旭², 胡厚鹏¹, 陈泽瑞¹, 惠红勋²

(1. 贵州电网有限责任公司电力科学研究院, 贵阳 550000; 2. 澳门大学智慧城市物联网国家重点实验室, 澳门 9990781)

摘要: 商业建筑负荷约占城市终端负荷的 25%, 其中包含大量如空调等可灵活调节的负荷, 使得商业建筑具有显著的需求响应调节潜力。负荷分解识别可调资源以支持电网制定响应策略, 而现有非侵入式分解方法受限于建筑设备运行频次差异, 单一时间尺度建模难以在边端设备高效捕捉异步设备特征。为此, 提出基于多时间尺度深度学习的非侵入式负荷分解方法。首先, 构建了卷积神经网络和长短期记忆神经网络融合模型, 实现负荷动态变化中时空特征的协同提取。其次, 通过多时间尺度采样机制进行时间敏感性分析, 选取边端最佳采样时间。最后, 基于商业建筑实际负荷数据的实验表明所提模型在综合性能最优, 当采样时间间隔从 30 s 延长至 60 s 时, 所提模型的马修斯相关系数提升了 7.35%。

关键词: 商业建筑; 非侵入式负荷分解; 卷积神经网络; 长短期记忆神经网络

Multi-Time scale Deep Learning Method for Commercial Building Non-Intrusive Load Disaggregation

WANG Nan¹, GAO Zhenghao¹, JIANG Siyu², XIE Daixu², HU Houpeng¹, CHEN Zerui¹, HUI Hongxun²

(1. Electric Power Research Institute of Guizhou Power Grid Co., Ltd., Guiyang 550005, China; 2. State Key Laboratory of Internet of Things for Smart City, University of Macau, Macau 999078, China)

Abstract: Commercial building loads account for approximately 25 % of the total end-use load in urban areas, with a substantial portion comprising flexible loads such as air conditioning systems. This endows commercial buildings with significant potential for demand response (DR) regulation. Load disaggregation serves as a means of identifying flexible resources to facilitate the formulation of demand response strategies within the power grid. Nevertheless, existing non-intrusive disaggregation approaches are constrained by variations in the operating frequencies of building systems, whereby single time-scale models exhibit limited capability in effectively capturing the asynchronous characteristics of end-use devices. To overcome these limitations, a non-intrusive load disaggregation method based on multi-timescale deep learning is proposed in this paper. Specifically, a hybrid model integrating convolutional neural networks and long short-term memory networks is constructed to enable the collaborative extraction of spatiotemporal features from dynamic load data. Furthermore, a multi-timescale sampling mechanism is employed to conduct temporal sensitivity analysis and to determine the optimal sampling interval at the edge. Finally, experimental results using real-world commercial building load data demonstrate that the proposed model achieves superior comprehensive performance. When the sampling interval is increased from 30 seconds to 60 seconds, the Matthews correlation coefficient of the proposed model is improved by 7.35 %.

Key words: commercial building; non-intrusive load disaggregation; convolutional neural networks; long short-term memory networks

基金项目: 国家自然科学基金资助项目(52407075); 贵州电网有限责任公司电力科学研究院项目(GZKJXM20240010); 澳门特别行政区科学技术发展基金项目(001/2024/SKL)。

Foundation item: Supported by the National Natural Science Foundation of China (52407075); the Project of Electric Power Research Institute of Guizhou Power Grid Co., Ltd. (GZKJXM20240010); the Science and Technology Development Fund of Macau SAR (001/2024/SKL).

0 引言

随着波动性可再生能源的大规模接入,电力系统的稳定运行面临严峻的挑战^[1-2]。近年来,需求响应通过柔性调节终端负荷为电力系统提供灵活调节能力,已成为保持电网供需平衡的一种有效手段^[3]。商业建筑能耗约占城市总能耗的25%,其中空调系统作为可调负荷比例高达40%,展现出可观的需求响应调节潜力^[4]。在需求侧资源中,商业建筑负荷因其强灵活性和高可控性而备受关注。商业建筑总负荷本质上是多种用电设备(空调系统、照明设备、办公电器等)的耦合叠加,直接监测设备总负荷难以分析具体设备的运行特性^[5]。负荷分解技术作为实现设备用能精细化监测的关键,通过将总负荷数据分解为设备级负荷,可以帮助电力公司获得商业建筑的可调资源负荷(如空调系统)动态特性,设计需求响应策略,保障电网稳定运行^[6]。

非侵入式负荷分解(non-intrusive load disaggregation, NILD)是一种通过分析建筑整体电力负荷数据,在不对单个设备独立安装传感器的前提下,分解出各个用电设备运行状态与负荷的方法^[7-8]。NILD方法通常基于设备的静态功率特征(稳态功率、功率因数、谐波等)与动态运行特征(开关瞬态、运行周期、状态序列等)进行负荷分解和设备识别^[9]。文献[10]结合特征提取技术和K近邻算法进行负荷分解。文献[11]提出了一种基于参数化隐马尔可夫(hidden markov model, HMM)的NILD模型,然而,HMM模型在处理大量设备及其状态时存在一定的局限性。文献[12]利用电流谐波值作为输入特征,并采用主成分分析法降低特征空间的维度。尽管上述方法在分解效果上有不错的表现,但大都依赖于人工特征的构建。

商业建筑在负荷类型和用电习惯方面的复杂性,使得现有基于人工特征构造的NILD模型难以规模化应用。为了降低对人工构造特征的依赖性,近年来基于深度学习方法的NILD模型快速发展。深度学习方法在处理非线性、时变性的负荷数据时具有明显优势,它能够从数据中分析时间序列模式、频率特征、周期性波动以及设备间的相互影响,识别出设备的运行状态。文献[13]通过扩张因果卷积方法提高了总负荷的分解精确度。文献[14]提出一种基于时间模糊化长短时记忆机器学习模

型,通过编码和解码去除非目标设备信息,并根据用户在不同时间区域的用电习惯来确定模糊策略。文献[15]提出了一种一维卷积堆叠长短时记忆循环神经网络模型进行不同设备的负荷识别。文献[16]提出基于图神经网络(graph neural network, GNN)的负荷分解模型利用图结构表征数据节点间关联信息,以捕捉设备多模态间相关性并保持功率数据时序特性。文献[17]提出基于特征融合与Transformer的模型,通过滑动窗口处理数据、融合多尺度卷积特征及位置信息增强特征表达,精确输出电器负荷序列。文献[18]使用生成对抗网络(generative adversarial network, GAN)深度挖掘电力数据时序特性与电器相关性,通过降维网络压缩高维有功功率序列以降低计算复杂度,并对不同状态电器采用不同学习模型构建负荷分类模型。文献[19]融合了浅层卷积神经网络(convolutional neural networks, CNN)与双层嵌套长短时记忆网络(two-layer nested long and short-term memory networks, NLSTM),并结合注意力机制,实现了设备特征的高精度识别。文献[20]则利用短时傅里叶变换(short time fourier transform, STFT)对负荷功率信号进行特征提取,再结合卷积神经网络与长短期记忆网络(long short-term memory network, LSTM)构建STFT-CNN-LSTM模型实现了负荷分解。文献[21]提出融合压缩-激励网络注意力机制(squeeze and excitation networks, SENet)和CNN的非侵入式负荷识别方法,通过嵌入注意力机制提高关键特征表征能力并利用遗传算法(genetic algorithms, GA)优化模型超参数来实现居民用电负荷的准确识别。文献[22]提出基于多门控混合专家网络(multi-gate mixture-of-experts network, MMoE)和双向长短期记忆网络(bidirectional long short-term memory network, BiLSTM)相结合的多任务非侵入式用电设备检测模型,通过软共享底层参数学习不同电器间的耦合特征并同时输出各电器功率序列来实现用电设备检测。

尽管上述研究通过优化网络结构或引入多样的特征提取方法提升了非侵入式负荷分解的精度,但更复杂的网络结构与多频特征处理也带来了参数量的显著增加(如表1所示),对边缘设备的存储与计算资源提出了更高要求。因此,这些方法在实际边缘部署时,仍面临模型轻量化欠缺和部署灵活性不

足的问题。此外,目前负荷分解系统多依赖低频采集,通过获取典型参数(功率、电量等),其采样间隔覆盖1 s到1 d等多种时段。在保障分解精度的基础上,合理选取采样间隔,是模型在实际边端场景下高效部署与运行的重要前提。

表 1 不同模型参数数量

Tab. 1 Number of model parameters

模型名称	参数数量
CNN-LSTM	15 489
LSTM-GNN ^[16]	38 894
MulTrm ^[17]	734 215
GAN-CNN-GRU ^[18]	325 448
CNN-NLSTM-ATTENTION ^[19]	598 070
STFT-CNN-LSTM ^[20]	3 486 593
SENet-GA-CNN ^[21]	230 676
MMoE-BiLSTM ^[22]	441 733

基于上述分析,本文提出一种基于时间尺度改进的轻量化深度学习负荷分解模型,对商业建筑中的空调空气处理机组(air handling unit, AHU)进行负荷分解,在保证负荷分解精度的前提下,有效降低了模型复杂度。具体贡献如下:1)构建了基于卷积神经网络(convolutional neural network, CNN)和长短期记忆神经网络(long short-term memory, LSTM)的轻量化融合CNN-LSTM模型,实现负荷动态变化中空间特征与时序特征的协同提取;2)通过多时间尺度采样机制进行时间敏感性分析,选取边端最佳采样时间;3)基于商业建筑实际负荷数据,验证了所提方法的有效性,并通过对比不同时间步长的分解效果,选取最佳分解步长。

1 非侵入式负荷分解

1.1 负荷分解技术对比

负荷分解通常可分为两类:侵入式负荷分解(intrusive load disaggregation, ILD)和非侵入式负荷分解(non-intrusive load disaggregation, NILD)。传统的ILD方法通过在每个设备上安装传感器,分别监测每个设备的数据,如图1(a)所示^[23]。然而,随着商业建筑中电气设备数量的快速增加以及用户对隐私保护意识的提升,这种方法不再适用。相比之下,NILD只需在电表前安装监控设备,即可收集聚合负载的功率、电压和电流信息。通过对这些数据的处理,NILD能够将整体负荷信息分解为单

个设备的负荷数据,从而实现对各个设备的用电情况进行精准监控和分析,如图1(b)所示。与传统方法相比,NILD在显著降低部署成本的同时更好地保障了用户隐私,因此具备较高的实际应用可行性。




图 1 侵入式与非侵入式负荷分解对比

Fig. 1 Comparison between ILD and NILD

1.2 非侵入式负荷分解流程

NILD的实现过程包括数据采集、数据处理、事件检测、特征提取和负荷识别5个步骤^[24]。现阶段,NILD的主要研究方向集中在探寻高效的事件检测、负荷特征提取和负荷识别的方法。在NILD方法中,事件检测步骤不是必需的。根据是否需要检测设备状态变化,NILD方法可分为基于事件的方法^[25]和与事件无关的方法。基于事件的NILD方法首先检测设备的开关事件,接着依据识别的事件进行特征提取和负荷设备识别。相比之下,与事件无关的NILD方法直接从原始功耗数据中提取特征,而无需事先进行事件检测,如图2所示。事件检测算法、特征提取方法和负载识别模型的设计对NILD系统的性能至关重要。

2 CNN-LSTM 负荷分解模型构建

本文针对商业建筑AHU系统的启停与功率波动特性,提出一种融合多时间尺度特征的CNN-LSTM改进模型,用于从总负荷数据中分离空调负荷,模型结构如图3所示。

2.1 卷积神经网络

卷积神经网络(convolutional neural network, CNN)是一种前馈神经网络,包括卷积计算并具有




图2 非侵入式负荷分解过程

Fig. 2 NILD process




图3 CNN-LSTM模型结构图

Fig. 3 Structure of CNN-LSTM model

深层结构。CNN作为深度学习中的代表性算法之一,在计算机视觉领域得到了广泛的应用,最近在NILD中也取得了良好的效果^[26]。

CNN网络主要由卷积层、池化层和全连接层组成。卷积层是CNN网络的核心组件,每个卷积

层包含多个卷积核。不同的卷积核可以提取不同的特征,并负责从输入数据中捕获特征。具体如式(1)所示。

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} * w_{ij}^l + b_j^l\right) \quad (1)$$

式中: $f(\cdot)$ 为非线性激活函数; i 为上一层输入特征图的索引; M_j 为与当前层第 j 个输出特征图相连接的上一层特征图集合; x_j^l 为当前层的第 j 个输出; x_i^{l-1} 为上一层的输出特征; $*$ 为卷积符号; w_{ij}^l 为相应的卷积核; b_j^l 为当前层的偏置参数。

2.2 长短期记忆网络

长短期记忆(long short-term memory, LSTM)网络是循环神经网络的一种改进结构,它解决了梯度消失或爆炸的问题,并且可以捕捉连续数据中的长期依赖关系。

LSTM单元的内部结构如图4所示。 σ 为代表公式 sigmoid 激活函数 $\tanh$ 中的双曲正切激活函数。LSTM单元有3个门:遗忘门、输入门和输出门,用于控制信息流。输入门对当前输入值进行操作,而遗忘门则对之前的记忆值进行操作。这两个门的加权和提供汇总信息,然后由输出门决定网络的输出值。




图4 LSTM结构图

Fig. 4 Structure of LSTM

输入门在LSTM网络中起着关键作用,它控制着信息如何被写入到记忆单元中。具体来说,输入门决定当前输入信息的哪些部分应该被存储在单元状态中。

$$i_t = \text{Sigmoid}(W_i[h_{t-1}, X_t] + b_i) \quad (2)$$

式中: $\text{Sigmoid}(\cdot)$ 为 Sigmoid 激活函数,用于将输入映射到 0 到 1 之间,以控制门控信息的保留或遗

忘程度； i_t 为输入门的激活值； $\mathbf{W}_i$ 为权重矩阵； $\mathbf{b}_i$ 为输入门的偏置向量； h_{t-1} 为前一个时间步的隐状态； X_t 为当前时间步的输入。

与此同时，生成一个候选记忆单元 $\tilde{c}$ 。

$$\tilde{c} = \tanh(\mathbf{W}_c[h_{t-1}, X_t] + \mathbf{b}_c) \quad (3)$$

式中： $\tanh(\cdot)$ 为双曲正切激活函数，用于将输入映射到-1到1之间，以生成候选记忆信息或更新隐状态； $\mathbf{W}_c$ 为候选记忆单元的权重矩阵； $\mathbf{b}_c$ 为输入门的偏置向量； $[h_{t-1}, X_t]$ 表示前一时刻隐状态与当前输入的拼接。

最终输入门与候选记忆单元相结合，更新记忆单元的状态 c_t 。

$$c_t = c'_{t-1} + (i \odot \tilde{c}_t) \quad (4)$$

式中： c'_{t-1} 为上一时刻记忆单元状态； $\tilde{c}_t$ 为 t 时刻候选记忆单元状态； $\odot$ 表示逐元素乘法。

遗忘门的主要功能是控制哪些信息从记忆单元中被删除。遗忘门的作用确保了模型能够有效地管理记忆，以适应动态变化的输入数据。

$$f_t = \text{sigmoid}(\mathbf{W}_f[h_{t-1}, X_t] + \mathbf{b}_f) \quad (5)$$

式中： f_t 为遗忘门的激活值； $\mathbf{W}_f$ 为遗忘门的权重矩阵； $\mathbf{b}_f$ 为遗忘门的偏置向量。

之后更新状态单元 c'_{t-1} 的计算公式如式(6)所示，遗忘门的输出与前一时间步的单元状态 c_{t-1} 相乘，来决定哪些信息将被遗忘。

$$c'_{t-1} = c_{t-1} \odot f_t \quad (6)$$

输出门负责决定哪些信息将从记忆单元传递到网络的下一层，进而影响后续的隐状态输出。

$$o_t = \text{sigmoid}(\mathbf{W}_o[h_{t-1}, X_t] + \mathbf{b}_o) \quad (7)$$

式中： o_t 为输出门的激活值； $\mathbf{W}_o$ 为输出门的权重矩阵； $\mathbf{b}_o$ 为输出门的偏置向量。

在输出门的控制下，当前的隐状态 h_t 通过式(8)计算。

$$h_t = o_t \odot \tilde{c}_t \quad (8)$$

2.3 评价指标

本文对于分解模型的输出状态定义为两种状态，即开和关。所以本文对于该分类问题使用4种常见的评价指标：精度(precision)，记作 m_{pre} ；召回率(recall)，记作 m_{rec} ；F1分数(F1 score)，记作 m_{F1} ；马修斯相关系数(Matthews correlation coefficient, MCC)，记作 m_{MCC} ^[27]。同时，给出NILD混淆矩阵如表2所示。

表2 NILD混淆矩阵

Tab. 2 Confusion matrix of NILD

真实值 \ 分解值	开	关
开	T_p	F_N
关	F_p	T_N

表2中表示具体含义如下。

T_p ：真正(true positive)，代表AHU被正确分解为开状态的次数。

T_N ：真负(true negative)，代表AHU被正确分解为关状态的次数。

F_p ：假正(false positive)，代表AHU是关闭状态却分解为开起状态的次数。

F_N ：假负(false negative)，代表AHU是开起状态却被分解成关闭状态的次数。

m_{pre} 定义为 T_p 与全部分解为开状态总数的比率。它测量AHU开启检测的准确性，计算公式如式(9)所示。

$$m_{\text{pre}} = \frac{T_p}{T_p + F_p} \quad (9)$$

式中 m_{rec} 为召回率或称为真正率，它表示 T_p 与全部实际状态为开启状态总数的比率，计算公式如式(10)所示。

$$m_{\text{rec}} = \frac{T_p}{T_p + F_N} \quad (10)$$

式中 m_{F1} 为 m_{rec} 和 m_{pre} 的加权调和平均值，为综合评价指标。它的取值范围在0~1之间，越高的值意味着越好的模型效果，其计算公式如式(11)所示。

$$m_{\text{F1}} = \frac{2 \times T_p}{2T_p + F_N + F_p} \quad (11)$$

式中 m_{MCC} 可以用于衡量分类性能的指标，它同时考虑了 T_p 、 T_N 、 F_p 、 F_N ，其计算公式如式(12)所示。

$$m_{\text{MCC}} = \frac{T_p \times T_N - F_p \times F_N}{\sqrt{(T_p + F_p)(T_p + F_N)(T_N + F_p)(T_N + F_N)}} \quad (12)$$

3 算例分析

3.1 数据集描述

本文选择了商业建筑能源数据集(COMBED)^[28]。该数据集从智能电表收集了不同建筑物内的多个AHU用电量。该数据集包含了

2014年6月—2014年7月的数据。表3展示了数据集中包含的特定特征和变量。

表 3 COMBED 数据集描述

Tab. 3 COMBED dataset description

数据集描述	数值
建筑数	1
分电表数量	8
采样频率/s	30
采样时间	2014. 06—2014. 07

楼内设备主要包括空调、照明和电梯等, 其中空调通常用于需求响应, 本文将空调中的 AHU 作为研究对象。具体而言, AHU0、AHU1、AHU2 和 AHU5 是选择用于分析的 4 个负载, 每个分表的位置与总表与所有 AHU 负荷情况分别如图 5 所示。




图 5 建筑电表分布

Fig. 5 Location of submeters in building

根据图 6(a)可知 AHU 只有开启和关闭两种状态, 运行状态稳定, 且在这两种状态中负荷的功率保持在某一数值附近, 因此空调空气处理单元机组属于开关型负荷。基于此特性, 我们将各机组的负荷均值取为阈值, 进行机组状态转换为图 6(b), 大于该阈值的机组状态为开启状态“1”, 小于阈值的机组状态为关闭状态“0”。其中 AHU0、AHU1、AHU2 和 AHU5 的阈值分别为 1.13 kW、1.19 kW、1.71 kW 和 4.65 kW。

3.2 数据处理

针对商业建筑负荷样本稀缺性问题, 本文将电梯、照明等可独立计量的低关联性负荷归类为噪声负荷, 随后通过总负荷差分运算生成合成样本: 从原始总负荷数中逐时扣除指定噪声负荷分量, 构建虚拟建筑总负荷。具体计算方法如表 4 所示。

在进行实验之前, 对 COMBED 数据集中的每个商用空调机组和商用建筑中获取的数据进行了数





图 6 商业建筑 AHU 分项负荷与状态

Fig. 6 AHU loads and status in commercial buildings

表 4 扩充数据集描述

Tab. 4 Synthetic dataset description

对比项	描述	电表
真实建筑	总负荷	表 1
虚拟 1	总负荷-电梯	表 1-表 6
虚拟 2	总负荷-照明	表 1-表 7
虚拟 3	总负荷-插座 1	表 1-表 8
虚拟 4	总负荷-插座 2	表 1-表 9

据预处理, 具体步骤如下。

1) 缺失值处理: 实验选择使用数据中时间最接近的可用样本来填补缺失值。这种方法可确保用时间上最接近的值替换缺失值, 从而保持数据集的顺序完整性。

2) 序列对齐: 为确保不同变量的采样排列一致, 实验选取了 2014 年 6 月 2 日上午 08:00 至 2014 年 6 月 30 日下午 00:00 的数据。通过统一采样时间范围, 实验可以有效地分析和比较 AHU 的负荷模式、总负荷和其他分表的负荷模式。

3) AHU 状态编码: 根据空调机组的负荷特征提取其状态。空调机组的状态可分为两种: 开和关。为了确定状态, 实验为 4 台自动空调机组分别设定了不同的阈值。如果自动空调机组的耗电量超过了相应的阈值, 则被归类为开状态。相反地, 如果负荷低于阈值, 则被视为处于关闭状态。

4) 滑动窗口划分: 为了有效地捕获数据中的时序特征, 实验设置了大小为 96 的滑动窗口, 且对输入数据使用最大最小归一化方法。

3.3 模型训练

本文所使用的网络是一种 CNN-LSTM 融合模型, 该模型的内部结构如图 7 所示。




图 7 CNN-LSTM 模型结构

Fig. 7 Structure of CNN-LSTM model

对于实际数据, 实验采用了标准的训练-验证-测试拆分。为了提供足够的训练数据, 实验分配了 70 % 的真实数据以及另外 4 个虚拟建筑的数据进行训练。其余 30 % 在验证数据集和测试数据集之间平均分配^[26], 如表 5 所示。

表 5 数据集划分

Tab. 5 Partition of dataset

对比项	真实建筑	虚拟 1	虚拟 2	虚拟 3	虚拟 4
训练	70	100	100	100	100
验证	15				
测试	15				

3.4 模型分解效果对比

为了对比模型的分解效果, 本文选用了多种模型进行分析对比, 包括隐马尔可夫模型 (factorial hidden Markov model, FHMM)、决策树 (decision tree, DT)、极限梯度提升 (eXtreme gradient boosting, XGB)、轻量级梯度提升机 (light gradient boosting machine, LightGBM)、文献 [21] 提出的 SENet-GA-CNN 方法、文献 [22] 提出的 MMoe-BiLSTM 方法、文献 [30] 提出的序列到点 (sequence

to point, S2P) 方法和文献 [31] 提出的支持向量机 (support vector machine, SVM) 方法。这些模型被广泛应用于各种数据分析任务中, 具有不同的优势和特性。通过对这些模型的 m_{Pre} 、 m_{Rec} 、 m_{F1} 和 m_{MCC} 性能指标进行对比分析, 可以全面评估各模型在分解任务中的表现, 从而为模型选择和优化提供支持。

表 6 从整体结果来看, 深度学习方法普遍优于传统机器学习模型。传统机器学习模型如 DT、SVM、XGB 和 LightGBM 在部分指标上表现尚可, 但在综合指标 m_{MCC} 上均未能突破 0.53, 尤其是 FHMM 模型, 整体性能较弱。MMoe-BiLSTM 等混合模型在 m_{Rec} 上表现突出为 0.80, 但在精确率和 m_{F1} 方面略逊于 CNN-LSTM, 反映出其对正负样本的敏感性较高。同时, 相较于 S2P 模型, CNN-LSTM 模型在 m_{Pre} 、 m_{Rec} 、 m_{F1} 和 m_{MCC} 上分别提升了 30.65 %、5.80 %、16.92 % 和 36.00 %。总体来看, CNN-LSTM 模型在平衡各种性能指标方面均具有优势。

表 6 不同模型分解结果

Tab. 6 Results of different NILD models

模型名称	m_{Pre}	m_{Rec}	m_{F1}	m_{MCC}
FHMM	0.49	0.54	0.49	0.11
DT	0.64	0.54	0.61	0.48
XGB	0.76	0.62	0.66	0.53
LightGBM	0.70	0.60	0.63	0.50
SENet-GA-CNN ^[21]	0.79	0.78	0.73	0.66
MMoe-BiLSTM ^[22]	0.77	0.80	0.68	0.62
S2P ^[30]	0.62	0.69	0.65	0.50
SVM ^[31]	0.90	0.63	0.69	0.42
CNN-LSTM	0.81	0.73	0.76	0.68

图 8 中结果可以看出, CNN-LSTM、SENet-GA-CNN 和 MMoe-BiLSTM 都能够有效捕捉到 AHU1 机组负荷下降时的变化, 并且在 4 台机组的整体分解结果上, 相较于 SVM 和 S2P, 它们的精度更高。具体而言, CNN-LSTM 能够有效识别机组的启停变化; SENet-GA-CNN 在 AHU5 机组上则出现了将负荷波动错误识别为机组启停的情况; MMoe-BiLSTM 在 AHU0 和 AHU2 机组上出现了较大的随机波动。总体 MMoe-BiLSTM 的稳定性较 CNN-LSTM 较低。




图8 AHU机组功率分解结果图

Fig. 8 NILD results of AHU

3.5 多时间尺度敏感性分析

本节通过逐步增加采样时间间隔来分析时间尺度信息的影响。具体做法是使原始数据的采样步长从1依次提升到10不等,每个间隔代表着30 s。这样相当于采样间隔从30 s逐渐增加到300 s,实验结果如表7和图9所示。

图9直观地展现出不同时间尺度下的分解结果,可以看出,除了 m_{Pre} 其余的3个指标都在采样频率在步长2(60 s)的时候达到了该模型的最优分解效果。

随着采样时间间隔的增大,单位时间内可获得的训练数据点减少,这可能导致模型所能学习和利用的历史信息量降低。但是,步长3至步长10并没有随着时间间隔的增加而提升分解精度。如表7所示,在实验过程中可以看出采样间隔为60 s的时候模型在 m_{Rec} 、 m_{F1} 与 m_{MCC} 3个指标上均达到了最优值。对比采样间隔为30 s,在 m_{Rec} 指标上提升了16.44%, m_{F1} 与 m_{MCC} 分别提升了6.58%和7.35%。

表7 不同时间尺度部分结果对比

Tab. 7 Result comparison under different timesteps

步长	时间间隔/s	m_{Pre}	m_{Rec}	m_{F1}	m_{MCC}
1	30	0.81	0.73	0.76	0.68
2	60	0.78	0.85	0.81	0.73
3	90	0.75	0.71	0.72	0.63
4	120	0.56	0.59	0.57	0.47
5	150	0.57	0.47	0.48	0.40
6	180	0.55	0.46	0.47	0.41
7	210	0.69	0.78	0.71	0.64
8	240	0.58	0.80	0.66	0.57
9	270	0.77	0.70	0.71	0.64
10	300	0.69	0.61	0.62	0.56

该实验表明该模型在采样频率为60 s时,模型达到了最佳的效果。

考虑到边端设备实际部署在商业建筑中需要设计合理采样频次以减少存储负担,在没有显著损失模型精度的前提下,使用采样频率60 s可以减少边端设备的数据传输和存储压力,优化硬件资源的利用效率。

4 结论

本文提出了一种基于多时间尺度深度学习的非侵入式负荷分解方法。在基于实际商业建筑负荷数据集的实验中,所提轻量化模型在设备开关状态识别任务相较于其他基线方法,在综合指标上表现出较高精度。其中,在采样间隔为60 s的设置下,模型在精度 m_{Pre} 、召回率 m_{Rec} 、F1分数 m_{F1} 和马修斯相关系数 m_{MCC} 等指标较其他采样间隔显著提升,验证了模型结构与时间尺度设计的合理性。

该方法通过构建轻量化CNN-LSTM融合模型实现了对负荷数据的局部空间特征与长期时序依赖的协同建模。针对不同时间采样间隔对分解性能的影响,筛选了合理的时间尺度采样机制,为实际轻量化部署提供了技术依据。

在未来的工作中,将考虑多时间尺度时序信息融合的自适应采样机制,结合不同时间尺度的数据特征,通过动态调整权重,在不增加边端设备的存储和计算压力负担的前提下,使模型能够平衡精度和召回率。通过这种方式,模型将在不增加资源消耗的前提下,充分利用不同时间尺度的信息互补性,更好地适应实际应用场景中的资源限制。




图9 不同时间尺度的分项指标结果

Fig. 9 Results of sub-indicators at different time scales

参考文献

- [1] AL-SHETWI Q, HANNAN M A, JERN K P, et al. Grid-connected renewable energy sources: Review of the recent integration requirements and control methods [J]. Journal of Cleaner Production, 2020(253): 119831.
- [2] DUAN W, KHURSHID A, NAZIR N, et al. From gray to green: energy crises and the role of CPEC [J]. Renewable Energy, 2022(190): 188 – 207.
- [3] AGHAEI J, ALIZADEH M I. Demand response in smart electricity grids equipped with renewable energy sources: a review [J]. Renewable and Sustainable Energy Reviews, 2013 (18): 64 – 72.
- [4] ZHENG S, JIN X, HUANG G, et al. Coordination of commercial prosumers with distributed demand-side flexibility in energy sharing and management system [J]. Energy, 2022 (248): 123634.
- [5] LIU C, AKINTAYO A, JIANG Z. Multivariate exploration of non-intrusive load monitoring via spatiotemporal pattern network [J]. Applied Energy, 2018(211): 1106 – 1122.
- [6] 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 [J]. 电力系统自动化, 2018, 42(3): 70 – 76.
QI Bing, DONG Chao, WU Xin, et al. Non-intrusive load identification method based on DTW algorithm and steady-state current waveform [J]. Automation of Electric Power Systems, 2018, 42(3): 70 – 76.
- [7] WELIKALA S, DINESH C, EKANAYAKE M P B, et al. Incorporating appliance usage patterns for non-intrusive load monitoring and load forecasting [J]. IEEE Transactions on Smart Grid, 2017, 10(1): 448 – 461.
- [8] WELIKALA S, THELASINGHA N, AKRAM M, et al. Implementation of a robust real-time non-intrusive load monitoring solution [J]. Applied Energy, 2019(238): 1519 – 1529.
- [9] GOPINATH R, KUMAR M, JOSHUA C P C, et al. Energy management using non-intrusive load monitoring techniques – State-of-the-art and future research directions [J]. Sustainable Cities and Society, 2020(62): 102411.
- [10] HART G W. Nonintrusive appliance load monitoring [J]. Proceedings of the IEEE, 1992, 80(12): 1870 – 1891.
- [11] 伍双喜, 谭嫣, 刘思宁, 等. 风电机组参与调频的系统频率响应模型 [J]. 南方电网技术, 2022, 16(10): 48 – 56.
WU Shuangxi, TAN Yan, LIU Sining, et al. System frequency response model with wind turbines participating in frequency regulation [J]. Southern Power System Technology, 2022, 16(10): 48 – 56.
- [12] SEMWAL S, SINGH M, PRASAD R S. Group control and identification of residential appliances using a nonintrusive method [J]. Turkish Journal of Electrical Engineering & Computer Sciences, 2015(23): 1805 – 1816.
- [13] 余昊杨, 武昕, 郭一凡, 等. 基于事件感知的钢厂工业用户非侵入式负荷检测分解算法 [J]. 南方电网技术, 2022, 16 (11): 29 – 36.
YU Haoyang, WU Xin, GUO Yifan, et al. Non-intrusive load detection decomposition algorithm for industrial users of steel mill based on event perception [J]. Southern Power System

- Technology, 2022, 16(11): 29–36.
- [14] NORFORD L K, LEEB S B. Non-intrusive electrical load monitoring in commercial buildings based on steady-state and transient load-detection algorithms [J]. Energy and Buildings, 1996, 24(1): 51–64.
- [15] ZAERI N, ASHOURI A, GUNAY H B, et al. Disaggregation of electricity and heating consumption in commercial buildings with building automation system data [J]. Energy and Buildings, 2022(258): 111791.
- [16] JIAO X, CHEN G, LIU J. A non-intrusive load monitoring model based on graph neural networks [C]//2023 IEEE 2nd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA), February 24–26, 2023, Changchun, China. New York: IEEE, 2023: 245–250.
- [17] 王丹宇, 刘君, 周亚同, 等. 面向用电负荷分解的特征融合与Transformer模型[J]. 电力系统及其自动化学报, 2024, 36(6): 129–136.
- WANG Danyu, LIU Jun, ZHOU Yatang, et al. Feature fusion and Transformer model for electricity load decomposition [J]. Proceedings of the CSU-EPSA, 2024, 36(6): 129–136.
- [18] 罗平, 朱振宇, 樊星驰, 等. 基于时序生成对抗网络的居民用户非侵入式负荷分解[J]. 电力系统自动化, 2024, 48(2): 71–81.
- LUO Ping, ZHU Zhenyu, FAN Xingchi, et al. Non-intrusive load decomposition for residential users based on time-series generative adversarial network [J]. Automation of Electric Power Systems, 2024, 48(2): 71–81.
- [19] 王家驹, 王竣平, 白泰, 等. 基于设备特征多层优选和CNN-NLSTM模型的非侵入式负荷分解[J]. 电力科学与技术学报, 2023, 38(1): 146–153.
- WANG Jiaju, WANG Junping, BAI Tai, et al. Non-intrusive load disaggregation based on multiple optimization of appliance features and CNN-NLSTM model [J]. Journal of Electric Power Science and Technology, 2023, 38(1): 146–153.
- [20] 刘仲民, 赵丹阳. 基于STFT-CNN-LSTM的非侵入式负荷监测方法研究[J]. 华中科技大学学报(自然科学版), 2023, 51(8): 128–134.
- LIU Zhongmin, ZHAO Danyang. Research on non-intrusive load monitoring method based on STFT-CNN-LSTM [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2023, 51(8): 128–134.
- [21] 沈鑫, 王钢, 赵毅涛, 等. 融合SENet注意力机制和GA-CNN的非侵入式负荷识别方法[J]. 中国电力, 2025, 58(5): 33–42.
- SHEN Xin, WANG Gang, ZHAO Yitao, et al. A non-invasive load recognition approach incorporating SENet attention mechanism and GA-CNN [J]. Electric Power, 2025, 58(5): 33–42.
- [22] 刘辉, 高放, 赵国, 等. 基于MMoE-BiLSTM的非侵入式用电设备检测方法研究[J]. 武汉大学学报(工学版), 2024, 57(3): 372–379.
- LIU Hui, GAO Fang, ZHOA Guo, et al. Research on non-intrusive electrical equipment detection method based on MMoE-BiLSTM [J]. Engineering Journal of Wuhan University, 2024, 57(3): 372–379.
- [23] 徐利美, 赵金, 李裕民, 等. 考虑多变量建模的中期负荷预测模型[J]. 南方电网技术, 2024, 18(11): 79–87.
- XU Limei, ZHAO Jin, LI Yumin, et al. Medium-term load forecasting model considering multivariate modeling [J]. Southern Power System Technology, 2024, 18(11): 79–87.
- [24] 王守相, 郭陆阳, 陈海文, 等. 基于特征融合与深度学习的非侵入式负荷辨识算法[J]. 电力系统自动化, 2020, 44(9): 103–110.
- WANG Shouxiang, GUO Luyang, CHEN Haiwen, et al. Non-intrusive load identification algorithm based on feature fusion and deep learning [J]. Automation of Electric Power Systems, 2020, 44(9): 103–110.
- [25] 凌家源. 基于事件检测与深度学习的非侵入式负荷监测算法[D]. 杭州: 浙江大学, 2021.
- [26] 凌家源, 彭勇刚. 基于事件检测与CNN模型的非侵入式负荷识别方法及实现[J]. 电工电能新技术, 2021, 40(3): 46–54.
- LING Jiayuan, PENG Yongguang. Implementation of a non-intrusive load identification method based on event detection and CNN model [J]. Advanced Technology of Electrical Engineering and Energy, 2021, 40(3): 46–54.
- [27] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. 电网技术, 2016, 40(10): 3108–3117.
- CHENG Xiang, LI Linzhi, WU Hao, et al. A survey of the research on non-intrusive load monitoring and disaggregation [J]. Power System Technology, 2016, 40(10): 3108–3117.
- [28] 徐健, 胡博, 邢作霞, 等. 基于GCN-BiLSTM的非侵入式负荷分解[J]. 南方电网技术, 2025, 19(6): 135–144.
- XU Jian, HU Bo, XING Zuoxia, et al. Non-intrusive load disaggregation based on GCN-BiLSTM [J]. Southern Power System Technology, 2025, 19(6): 135–144.
- [29] BATRA N, PARSON O, BERGES M, et al. A comparison of non-intrusive load monitoring methods for commercial and residential buildings [DB/OL]. (2014–8–27). <https://arxiv.org/abs/1408.6595>.
- [30] 陈慷, 宋梦, 高赐威. 知识与数据联合驱动的中央空调系统建模与调控方法[J]. 南方电网技术, 2022, 16(10): 120–129, 150.
- CHEN Kang, SONG Meng, GAO Ciwei. Modeling and control method of HVACs driven by knowledge and data [J]. Southern Power System Technology, 2022, 16(10): 120–129, 150.
- [31] ZHANG C, ZHONG M, WANG Z, et al. Sequence-to-point learning with neural networks for non-intrusive load monitoring [C]//National Conference on Artificial Intelligence, February 02, 2018, New Orleans. New York: AAAI Press, 2018: 2604–2611.
- [32] 江友华, 叶梦豆, 赵乐, 等. 基于seq2seq和SVM双层融合的非侵入式用户异常行为检测[J]. 计算机应用与软件, 2024, 41(9): 97–105.
- JIANG Youhua, YE Mengdou, ZHAO Le, et al. Non-intrusive abnormal user behavior detection based on double layer fusion of seq2seq and SVM [J]. Computer Applications and Software, 2024, 41(9): 97–105.

收稿日期: 2025-05-14; 网络首发日期: 2025-08-05

作者简介:

王楠(1997), 女, 工程师, 硕士, 研究方向为数字化转型及人工智能, 764657828@qq.com;

高正浩(1979), 男, 高级工程师, 学士, 研究方向为电力系统网络化和智能通信技术, 30065604@qq.com;

惠红勋(1992), 男, 通信作者, 助理教授, 博士生导师, 博士, 研究方向为灵活负荷资源的画像、建模、优化和市场策略, hongxunhui@um.edu.mo.