

DOI: 10.19783/j.cnki.pspc.250606

基于模型-数据混合驱动的空调监测及其域适应方法

李钊涛, 罗庆全, 余涛, 梁敏航, 王克英, 潘振宁

(华南理工大学电力学院, 广东 广州 510640)

摘要: 高耗能的空调负荷因其热储特性成为源荷互动的重要对象。作为可调潜力评估的基础, 非侵入式负荷监测仅需总表数据即可获取空调运行信息。然而, 现有监测模型不仅难以捕捉空调的复杂运行特性, 在从源域训练数据迁移到新用户的目标域时, 还高度依赖难以获取的运行功率标签。因此, 提出基于模型-数据混合驱动的空调监测及其域适应方法。首先, 构建融合电气与环境特征长短期关联性的空调监测模型。其次, 通过神经网络辨识空调热力学模型参数, 推算室内温度变化, 进而在训练中交替嵌入温度估计损失以充分利用空调与温度的强相关性。最后, 再以物理模型作为桥梁, 在新用户中采用易获取的温度数据作为监督信号适应新的数据分布。公开及自建数据集实验结果表明, 所提方法在监测精度、可迁移性和域适应性方面均优于现有方法, 展现出良好的应用前景。
关键词: 空调监测; 多元特征; 物理模型; 混合驱动; 域适应

Air conditioner monitoring and its domain adaptation method based on a model-data hybrid-driven approach

LI Zhaotao, LUO Qingquan, YU Tao, LIANG Minhang, WANG Keying, PAN Zhenning

(School of Electric Power, South China University of Technology, Guangzhou 510640, China)

Abstract: Due to their high energy consumption and inherent thermal storage capacity, air conditioning loads have become key resources in source-load interaction. As a foundation for assessing flexible potential, non-intrusive load monitoring (NILM) enables the extraction of air conditioner operating information using only aggregate meter data. However, existing monitoring models not only struggle to capture the complex operating behaviors of air conditioners, but also rely heavily on hard-to-obtain power consumption labels when transferred from a source domain with training data to a new user in the target domains. To address these issues, a model-data hybrid-driven air conditioner monitoring and domain adaptation method is proposed. First, an air conditioner monitoring model integrating long- and short-term correlations between electrical and environmental features is developed. Second, a neural network is employed to identify thermodynamic parameters of air conditioners, enabling indoor temperature estimation. A temperature estimation loss is alternately embedded during training to fully exploit the strong correlation between air conditioner operation and indoor temperature. Finally, the physical model serves as a bridge for domain adaptation in new users, where easily accessible temperature data are used as supervisory signals to adapt to new data distribution. Experiments on both public and self-collected datasets demonstrate that the proposed method outperforms existing approaches in monitoring accuracy, transferability, and domain adaptability, showing promising potential for real-world applications.

This work is supported by the National Natural Science Foundation of China (No. U24B6010).

Key words: air conditioner monitoring; multivariate features; physical model; hybrid-driven; domain adaptation

0 引言

为实现可持续发展, 我国制定了“双碳”目标,

基金项目: 国家自然科学基金企业创新发展联合基金集成项目资助(U24B6010); 广东省基础与应用基础研究基金项目资助(2025A1515010118)

积极推动新能源大规模接入。由于新能源发电的间歇性和不确定性, 传统的“源随荷动”难以为继, 电力系统正向“源荷互动”的机制演进^[1]。实现源荷有效互动需实时获取负荷侧运行信息, 这使得在保障电力安全供应的同时, 推动负荷精细化感知成为关键^[2]。在负荷侧, 空调是住宅与商业建筑中最主要的耗电负荷之一, 尤其在夏季, 其在负荷高峰

中的占比可达 50%^[3]。作为典型的温控型负荷, 空调可将电能转化为储存在室内空间的热能, 具备良好的热储特性。短时调节其运行状态对用户舒适度影响较小, 具有突出的可调节潜力^[4]。因此, 作为空调灵活参与源荷互动的前提, 空调运行信息的精准监测显得尤为重要^[5]。

传统的空调监测依赖于安装专用量测设备, 存在部署困难和成本高昂的问题。作为替代方案, 非侵入式负荷监测^[6-7](non-intrusive load monitoring, NILM) 技术通过分析智能电表的总负荷数据, 分解出单个设备的运行状态和功耗情况, 具有成本低、用户接受度高、维护简便等优势。近年来, 基于深度学习的 NILM 方法因具备复杂时序特征的自学习能力而成为研究重点。文献[8]首先将一维卷积神经网络与长短期记忆神经网络(long short-term memory, LSTM) 应用于负荷监测。文献[9]结合双向 LSTM 与动态时间规整增强对负荷时序特征的建模能力。而文献[10]融合改进的时序卷积网络, 进一步提升对能耗信号时序与特征间耦合关系的建模能力。为捕捉负荷运行的长期特征, 文献[11]引入注意力机制提取并加深设备特征。文献[12]尝试将序列数据转化为图结构, 应用图神经网络进行监测。

尽管 NILM 在洗衣机、洗碗机、冰箱等少数家用电器上取得了可观的性能, 针对空调监测的研究仍较为有限。空调本身的复杂运行特性及其对外部环境的高度敏感性, 为其 NILM 带来了显著挑战。一方面, 空调具有多运行模式、大功率、高变动性等特点, 导致空调监测模型难以捕捉有效的运行特征。另一方面, 高度个性化的用户行为^[13], 以及频繁变化的外界环境均会导致空调运行特征的多样性显著增加。然而, 现有方法不仅难以充分刻画空调不同时间尺度的运行模式, 而且忽视了关联密切的多元外部环境变量。

空调运行特征的多样性不仅导致空调监测模型精度有限, 更限制了其在不同用户间的可迁移性。这是因为新用户数据(目标域)中的空调设备本体、用电行为以及外部环境均与已收集数据(源域)中的不同, 所产生的统计分布差异违背了深度学习中数据同分布的假设, 从而导致模型在新用户中的性能显著下降^[14-15]。为减小该差异对 NILM 模型的影响, 现有研究采用域适应方法根据目标域的数据分布更新模型参数。文献[16]直接根据新用户中的单设备功率标签更新源域中训练得到 NILM 模型以适应目标域分布。这类有监督域适应方法因依赖于在新用户中安装空调运行功率采集设备而难以推广。为降低标注成本, 文献[17-18]仅以新用户中的总线功率

作为输入, 最小化分别由统计分布与神经网络表示的域间差异。然而, 无监督域适应的易用性以监测性能为代价, 如文献[17]的监测误差相较于文献[16]高 37.6%。因此, 针对空调相比其他家庭和商用电气设备更为显著的域间分布差异, 如何在域适应过程中兼顾标注成本与监测性能, 成为空调监测模型在不同用户中推广应用的关键问题。

为提高空调监测模型对运行模式的刻画能力以及在不同用户间的适用性, 本文提出基于模型-数据混合驱动的空调监测及其域适应方法。该方法不仅基于 Transformer 神经网络, 实现对电气数据与多元外部数据的长短期融合, 更首次在训练和域适应过程中嵌入空调的热力学物理模型, 以低成本的温度数据作为提升监测水平的监督信号。与现有研究工作相比, 主要贡献如下。

1) 针对空调运行的电气及外部环境特征提取难的问题, 设计了多元特征融合的空调监测模型。该模型先通过双分支输入模块分别提取电气数据和外部环境数据的短期特征, 再基于 Transformer 在融合多元短期特征的基础上捕捉长期关联性。

2) 为利用空调热储特性与温度的强相关性提高监测精度, 提出了模型-数据混合驱动的交替式训练策略。该策略先由神经网络辨识空调热力学物理模型的参数, 进而根据估计的空调运行功率推算室内温度变化, 基于空调功率与温度估计损失交替地指导模型训练。

3) 针对监测模型迁移至新用户时高度依赖空调运行功率标签的问题, 提出模型-数据混合驱动的域适应策略。该策略先根据室内温度估计误差变化趋势判断域间差异影响, 再由物理模型引入的温度估计损失更新空调监测模型, 从而利用低成本的温度数据提高迁移后的监测性能。

4) 采用公开数据集和自建数据集验证表明, 所提方法在监测精度、可迁移性和域适应性方面均显著优于现有方法。该方法仅需利用新用户中较易获取的温度测量数据进行域适应, 即可使误差的相对降幅至少达到 30.252%。

1 空调监测简介

1.1 空调监测任务

对于非侵入式空调监测, 在 t 时刻输入为多元数据 X_t^s , 包括用户电表总线功率 P_t 与其他外源信息, P_t 由用户的空调负荷功率 P_t^{AC} 与其他负荷用电量 O_t 组成, 如式(1)所示。

$$P_t = P_t^{AC} + O_t \quad (1)$$

空调监测的目标是通过 P_t 及其他外源信息估计用户的空调运行功率 \hat{P}_t^{AC} ，通过数据驱动方法学习两者之间的映射关系 $f_\theta(\cdot)$ ， θ 为参数，如式(2)所示。

$$\hat{P}_t^{AC} = f_\theta(X_t^s) \quad (2)$$

相较于常见的家庭与商业负荷，空调由于系统中的多部件协同运行而展现出复杂的运行模式。图 1 展示了不同空调单周期的运行波形。在短时间尺度上，空调各运行周期的功率波形差异显著，图 1(a)和图 1(b)的峰值约为 1.6 kW，而图 1(c)和图 1(d)的峰值仅为 1.2 kW。图 1(a)中，完整运行周期包含多个持续时间不同的阶跃，而图 1(b)空调运行时功率呈缓慢下降趋势，图 1(c)呈平顶波形，图 1(d)中则在运行初期出现尖峰波动，随后过渡为缓坡上升。在长时间尺度上，空调受建筑物热储特性影响呈现一定的周期性。然而，该周期性同样多变。如图 1 所示，各子图中周期长度从 3 min 到 120 min 不等，反映出空调在热平衡调节中的动态变化。此类周期变化难以通过电气数据准确预测，需结合与使用特性高度相关的外部环境数据。

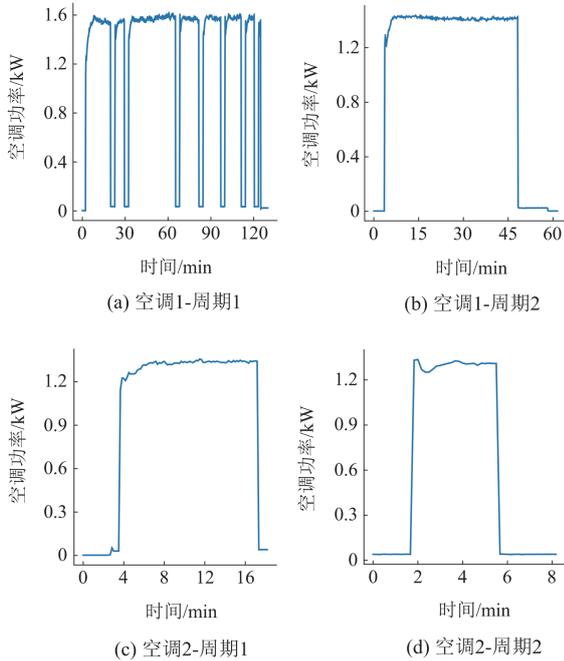


图 1 空调负荷实测功率波形

Fig. 1 Waveforms of air conditioning load measurement data

1.2 空调监测域适应任务

设 $\mathcal{D}^s = \{(P_t^s, z_t^s, y_t^s)\}_{t=1}^n$ 为预先收集的源域数据集，其中 P_t^s 为源域在 t 时刻的用户电表总线功率， z_t^s 为其他外源信息， $y_t^s = P_t^{AC,s}$ 为对应的空调运行功

率标签， n 为样本个数。目标域数据集来自新用户，记作 $\mathcal{D}^{tar} = \{(P_t^{tar}, z_t^{tar})\}_{t=1}^n$ ， P_t^{tar} 为目标域电表总线功率， z_t^{tar} 为可获取的辅助信息。

由于空调类型多样且受用户行为等因素影响，其源域与目标域在统计分布上存在差异，即 P_t 、 z_t 、 y_t 的概率分布不同，不符合深度学习对数据独立同分布的假设，导致模型 $f_\theta(\cdot)$ 在迁移后性能下降^[15,19]。为缓解域间差异的影响，现有 NILM 域适应方法基于目标域的标签 y_t 或最小化输入 P_t 间的分布差异更新监测模型，促使模型将源域学到的知识迁移至分布不同的目标域。本文旨在源域上训练模型 $f_\theta(P_t^s, z_t^s)$ ，并借助目标域中易于获得的间接标签 z_t^{tar} ，引导模型参数 θ 更新。

2 空调监测及其域适应方法整体设计

基于模型-数据混合驱动的空气调节监测整体流程如图 2 所示，包括监测模型的构建、模型-数据混合驱动的训练、模型-数据混合驱动的域适应。

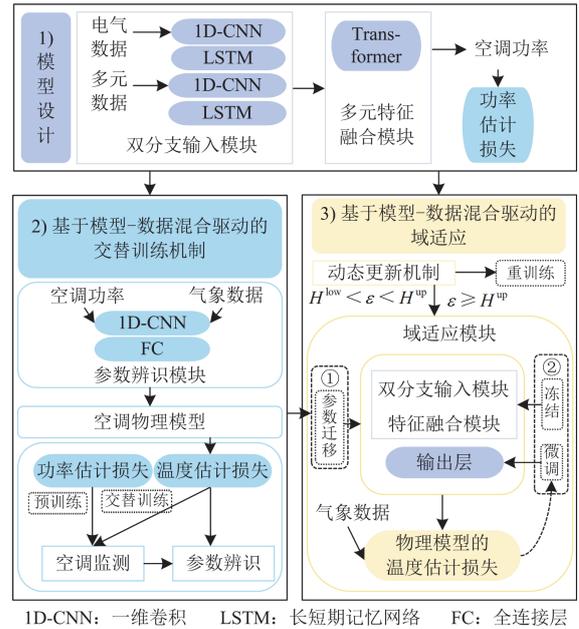


图 2 空调监测整体流程图

Fig. 2 Overall flowchart of air conditioning load monitoring

1) 数据驱动的空气调节监测模型构建。采用双分支输入模块分别提取电气数据与外部气象、时间数据的短期时间尺度特征，再基于 Transformer 神经网络融合短期多元特征的同时，学习空调运行过程长期时间尺度时序特征，并估计空调的运行功率。

2) 模型-数据混合驱动的训练。在构建空调等效热参数模型后，先由可微的参数辨识模型

辨识物理模型参数, 然后根据估计的空调运行功率推算室内温度变化。训练过程中先由空调功率估计损失对监测模型进行预训练, 保证初始训练的稳定性。再交替使用功率估计损失和温度估计损失优化监测模型。

3) 模型-数据混合驱动的域适应。在新场景中通过测量易于获得的室内温度, 根据其误差变化趋势判断域间差异影响, 再由物理模型引入的温度估计损失更新空调监测模型。保持空调监测模型的特征表示层不变, 微调其输出层以适应新的环境, 从而利用少量间接标签数据显著提升模型的泛化能力, 实现低成本的域适应。

3 多元特征融合的空调监测模型构建方法

为更好地捕捉空调运行的复杂动态过程及其与外部因素的相关性, 本文设计了多元特征融合的空调监测模型。如图 3 所示, 该模型由双分支输入模块与多元特征融合模块构成。

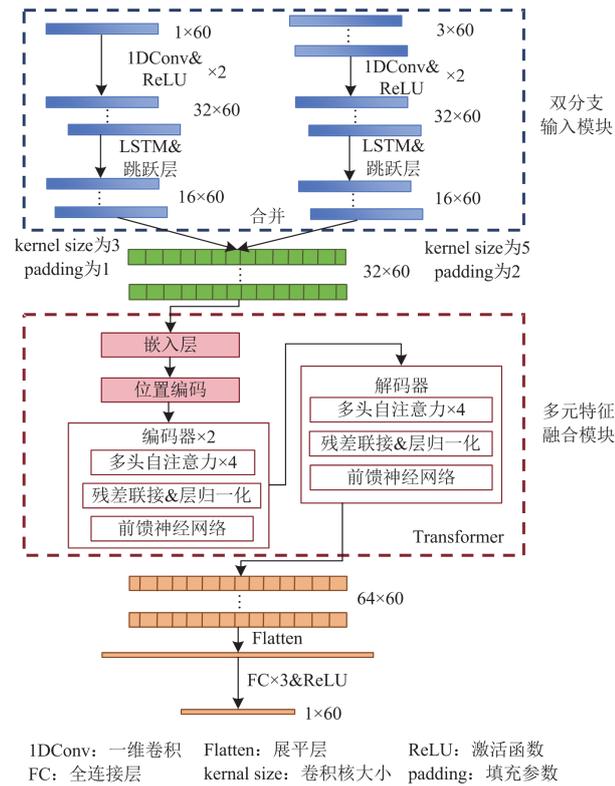


图 3 空调监测神经网络结构图

Fig. 3 Neural network structure of air conditioning load monitoring

电气数据与气象、时间等外部因素在变化特性上差异显著。电气数据反映空调在分钟级的运行状态, 波动性较强, 包括开关机、压缩机调节等模式切换。气象和时间则体现外部环境和用户行为习惯, 表现为小时级的趋势性变化。为适应多源异构特征

分布的差异性, 参考现有多变量时间序列回归问题的输入范式, 本文设计了双分支输入模块^[20-21]。该模块有利于分别学习不同类型输入变量的短期时间尺度模式。双分支模型均采用多层卷积网络结合 LSTM 结构, 先通过卷积层提取局部特征, 再由 LSTM 捕捉时序关联性^[22-23]。其中, 功率分支输入为单维度的电气功率, 学习其自身时序特性。外部特征分支则引入包括室外温度、时间在内的 3 维输入, 提取环境因素与负荷之间的时序关联。具体而言, 外部特征分支的输入特征包括:

室外温度: 指在空调系统运行过程中, 建筑物外部环境的空气温度, 单位为摄氏度。

运行时间戳(正余弦变换): 时间戳以秒为单位进行转换; 并采用正弦和余弦转换, 确保时间的周期性特征得到保留。其变换公式如式(3)和式(4)所示。

$$t^{\sin} = \sin\left(\frac{2\pi k}{T^p}\right) \quad (3)$$

$$t^{\cos} = \cos\left(\frac{2\pi k}{T^p}\right) \quad (4)$$

式中: T^p 为单日的总秒数; k 为当前时间的秒数。

两个分支在卷积核与填充参数上采用差异化设计, 从而分别表征分钟级功率的快速波动特征与环境对空调运行的关联特征。在训练过程中, 两分支的卷积核与 LSTM 权重均通过端到端反向传播自适应优化, 实现功率分支捕捉压缩机启停等快速动态, 外部特征分支突出温度、时间等外部条件与空调运行的关联关系。双分支提取的运行特征与外部因素关联特征在合并后, 为模型提供了空调负荷的动态变化信息及与外部因素的关联信息。

空调不仅存在短期的启停波动, 更受到环境变化及用户生活习惯等长期时间尺度因素的影响, 呈现出明显的长短期时序特征。为此, 本文设计了基于 Transformer 神经网络的多元特征融合模块^[24-26]。

Transformer 主要由编码器和解码器组成。其中编码器和解码器均由多个层堆叠而成, 每层包括多头自注意力机制和前馈神经网络。其中, 注意力机制通过计算输入中各时刻的重要性, 聚焦功率序列中的关键波动, 以提升空调监测模型对运行状态变化的感知能力。多头注意力进一步并行计算多个子注意力空间, 每个注意力头专注于特定的时间尺度, 从而捕捉功率与外部因素之间的多种高阶交互关系。该机制增强了模型对复杂模式和长期时间尺度依赖的建模能力, 有助于实现更准确的空调监测。最终, 输出层通过全连接网络将高维特征转换为空调功率估计结果。

模型的优化过程基于空调监测模型的功率估计损失 L^{reg} ，并采用 Adam 优化器对网络中的参数进行优化。其中， L^{reg} 是预测功率 \hat{P}_i^{AC} 与实际功率 P_i^{AC} 的误差，如式(5)所示。

$$L^{\text{reg}} = \frac{1}{n} \sum_{i=1}^n (\hat{P}_i^{\text{AC}} - P_i^{\text{AC}})^2 \quad (5)$$

4 模型-数据混合驱动交替式训练

近年来，物理引导神经网络^[27]融合物理先验知识与数据驱动方面展现出应对复杂系统问题的潜力。值得注意的是，空调具备明确的物理模型与强相关的物理信息，有望指导空调监测模型训练并提高可迁移性。因此，本文提出基于模型-数据混合驱动的交替式训练方法。利用空调运行状态与温度的强相关性，先由空调热力学模型构建可微的参数辨识模型，接着根据功率估计推算室内温度估计损失，在训练中通过预训练和交替使用空调功率估计损失和温度估计损失实现数据驱动模型与物理先验知识的融合，从而降低过拟合风险。后文将分别介绍空调物理模型、等效热参数辨识、交替式训练策略 3 个部分。

4.1 空调物理模型

等效热参数模型(equivalent thermal parameters, ETP)通过微分方程描述室内空气、外墙和内墙之间的热交换过程。综合考虑工程应用的可行性，选取结构简洁、计算高效的一阶 ETP 模型作为参数辨识的对象^[28]。值得注意的是，本文虽因上述优势选用一阶 ETP 模型，但所提出的方法具有良好的通用性，可扩展至更高阶的热参数模型。如图 4 所示，其表达如式(6)所示。

$$\frac{dT^{\text{in}}}{dt} = \frac{1}{RC} (T^{\text{out}} - T^{\text{in}}) - \frac{Q}{C} \quad (6)$$

式中： C 为等效热容； R 为等效热阻； Q 为制冷/制热量； T^{out} 为外界温度； T^{in} 为室内气体温度。将 C 移动至左侧后，方程右侧由两部分热交换过程组成，其一是室内外温度差通过热阻 R 引起的传热过程，其二为空调功率直接作用于室内的制冷过程。左端项则刻画了室内温度变化所需的能量累积效应。转换为差分方程如式(7)和式(8)所示。

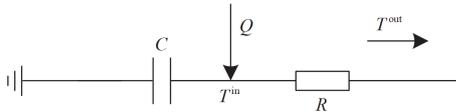


图 4 ETP 一阶模型示意图

Fig. 4 Schematic diagram of the first-order ETP model

$$T_{t+1}^{\text{in}} = T_{t+1}^{\text{out}} - Q_t \cdot R - (T_t^{\text{out}} - Q_t \cdot R - T_t^{\text{in}}) \cdot e^{-\frac{\Delta t}{R \cdot C}} \quad (7)$$

$$Q_t = P_t^{\text{AC}} \cdot \eta \quad (8)$$

式中： T_t^{in} 为 t 时刻的室内温度； T_t^{out} 为 t 时刻的室外温度； Q_t 为 t 时刻的空调制冷量； Δt 为离散时间步长； P_t^{AC} 为空调 t 时刻的功率； η 为空调制冷能效比。其中的模型参数包括房间等效热容 C 、房间等效热阻 R 、空调制冷能效比 η 。

4.2 等效热参数辨识模型构建

本文采用基于神经网络方法辨识 ETP 模型参数。相较于现有基于数学优化或启发式算法的参数辨识方法，神经网络的优势有：1) 具备出色的非线性映射能力，能够通过大量数据学习输入与输出之间的稳定特征关系，从而在面对噪声时仍能保持良好的拟合效果，具有较强的鲁棒性^[29-30]；2) 在训练后仅需单次前向传播即可辨识空调等效物理参数，计算效率高，适合部署应用^[31]；3) 神经网络使参数辨识环节可微，并通过梯度参与后续空调监测模型的反向传播，从而实现整体模型参数的联合优化。

由 4.1 节可知，室内温度变化由等效热容 C 、等效热阻 R 以及空调制冷能效比 η 决定。已知量包括室外温度序列 T_t^{out} 以及空调功率 P_t^{AC} 。参数辨识任务可定义为：在给定初始室内温度的条件下，学习从输入量 $(T_t^{\text{out}}, P_t^{\text{AC}})$ 到 (C, R, η) 的映射。该映射能够将观测的外部量转化为热力学参数，从而驱动 ETP 模型进行室内温度估计。

参数辨识模型的结构主要包括 1 维卷积层、池化层以及自定义激活函数，如图 5 所示。该模型以室外温度和负荷识别后的空调功率作为输入，首先通过多层一维卷积提取局部时序特征，并结合 ReLU 激活函数引入非线性变换。随后，采用最大池化和展平操作压缩关键特征，经由输出层输出制冷效率 η 、等效热容 C 、等效热阻 R ，为参数辨识提供有效表征。

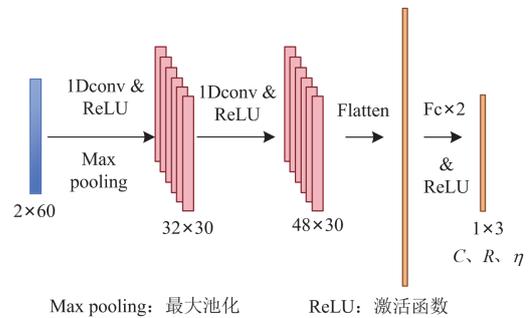


图 5 参数辨识神经网络结构

Fig. 5 Neural network structure for parameter identification

模型的优化过程由物理模型的温度估计损失决定。首先, 参数辨识神经网络根据输入的时序数据输出空调的物理模型参数。随后, 这些参数被代入空调和建筑物的热力学模型, 以计算室内温度的估计值。温度估计损失 L^{phy} 用于衡量预测的室内温度与实际测量温度之间的误差。

$$L^{\text{phy}} = \frac{1}{n} \sum_{i=1}^n (\hat{T}_i^{\text{in}} - T_i^{\text{in}})^2 \quad (9)$$

式中: \hat{T}_i^{in} 为基于物理模型参数计算得到的第 i 个室内温度; T_i^{in} 为实际测量的室内温度。

4.3 交替式训练策略

由于温度估计损失与功率估计损失在梯度方向和量级上存在差异, 若直接联合训练, 易导致某一目标主导优化过程, 引发训练振荡, 进而影响模型训练过程的稳定性和收敛效率。因此, 交替训练空调监测模型与参数辨识模型, 如图 6 所示。

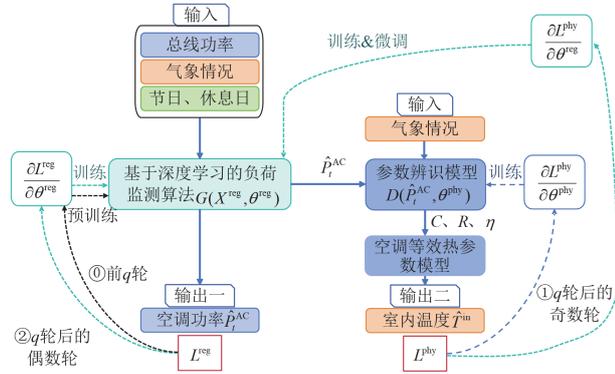


图 6 基于模型-数据混合驱动的空调监测模型梯度传播图

Fig. 6 Gradient propagation diagram of the air conditioning monitoring model based on a model-data hybrid-driven approach

由于初始阶段空调监测模型误差较大, 若过早联合训练可能导致其难以收敛, 因此, 在训练前 q 轮, 对空调监测模型进行预训练, 仅基于功率估计损失 L^{reg} 对空调监测模型参数 θ^{reg} 进行优化。经此, 空调估计功率作为参数辨识模型的输入逐步收敛到合理范围, 使得参数辨识模型可以在空调的功率运行范围内辨识物理模型参数。

$$\theta_{e+1}^{\text{reg}} = \theta_e^{\text{reg}} - \omega_1 \cdot \frac{\partial L^{\text{reg}}}{\partial \theta^{\text{reg}}} \quad (10)$$

式中: e 为训练轮次; ω_1 为采用 L^{reg} 的学习率。

在进入第 $q+1$ 轮后, 引入交替式训练策略。

1) 流程①: 在训练奇数轮, 同时更新参数辨识和空调监测模型的网络参数。由参数辨识模型得到温度估计损失 L^{phy} , 使用 L^{phy} 的梯度反向传播更新参数辨识和负荷监测的参数。

先由温度估计损失分别计算各模块的梯度。

$$\frac{\partial L^{\text{phy}}}{\partial \theta^{\text{phy}}} = \frac{\partial L^{\text{phy}}}{\partial \hat{T}^{\text{in}}} \cdot \frac{\partial D}{\partial \theta^{\text{phy}}} \quad (11)$$

$$\frac{\partial L^{\text{phy}}}{\partial \theta^{\text{reg}}} = \frac{\partial L^{\text{phy}}}{\partial \hat{T}^{\text{in}}} \cdot \frac{\partial D}{\partial \hat{P}^{\text{AC}}} \cdot \frac{\partial G}{\partial \theta^{\text{reg}}} \quad (12)$$

由梯度更新参数辨识和空调监测的权重参数。

$$\theta_{e+1}^{\text{phy}} = \theta_e^{\text{phy}} - \omega_2 \cdot \frac{\partial L^{\text{phy}}}{\partial \theta^{\text{phy}}} \quad (13)$$

$$\theta_{e+1}^{\text{reg}} = \theta_e^{\text{reg}} - \omega_2 \cdot \frac{\partial L^{\text{phy}}}{\partial \theta^{\text{reg}}} \quad (14)$$

式中: ω_2 为采用 L^{phy} 的学习率; $\theta_{e+1}^{\text{phy}}$ 为参数辨识模型 $D(\cdot)$ 更新后的网络权重参数; $\theta_{e+1}^{\text{reg}}$ 为空调监测模型 $G(\cdot)$ 更新后的网络权重参数。

2) 流程②: 在训练偶数轮, 仅更新空调监测模型的网络参数。使用功率估计损失 L^{reg} 的梯度反向传播更新负荷监测的参数, 更新公式与预训练阶段相同。

在交替式训练过程中, 空调监测模型 $G(\cdot)$ 由功率估计损失 L^{reg} 与温度估计损失 L^{phy} 交替指导, 参数辨识模型 $D(\cdot)$ 由温度估计损失 L^{phy} 单独指导。空调监测模型 $G(\cdot)$ 的空调运行功率估计、与真实室外温度作为参数辨识模型 $D(\cdot)$ 的输入。在偶数轮次时, 当功率估计误差较大时, 空调监测模型 $G(\cdot)$ 直接通过误差反向传播提高了功率估计的精度, 从而为参数辨识模型 $G(\cdot)$ 提供更精准的输入。在奇数轮次, 当功率估计误差较大时, 参数辨识模型 $D(\cdot)$ 由于不能获得准确的输入而传递至室内温度估计误差。该误差通过反向传播反馈至空调监测模型 $G(\cdot)$ 和参数辨识模型 $D(\cdot)$, 推动其参数更新, 一方面提升功率估计的准确性, 由此为参数辨识模型 $D(\cdot)$ 提供更可靠的输入; 另一方面也优化了参数辨识模型 $D(\cdot)$ 的网络参数。此过程中, 模型不仅不易过拟合功率训练数据中的噪声, 也实现了空调监测和参数辨识模型的协同优化, 其最终目标均趋于温度估计损失的最小化。随着监测模型的精度提升, 参数辨识模型的输入误差减小, 精度亦随之提升, 从而增强模型整体的监测性能和泛化能力, 确保模型在多样化场景下的适应性。

5 模型-数据混合驱动的域适应

现有的有监督域适应方法由于高度依赖新用户的空调功率标签, 导致迁移成本较高; 而无监督域适应方法受限于性能, 且需要与源域同时训练, 计算开销较大。针对上述问题, 本节提出一种模型-

数据混合驱动的空调监测模型域适应策略，以利用空调运行状态与温度的强相关性，包括域间差异检测与域适应两个关键环节。

在域适应之前，通过低成本实际测量的室内温度标签，与参数辨识模型得到的室内温度估计求得误差。根据室内温度估计误差检测域间差异，若误差超过相应阈值则需更新或重训练模型。该阈值可根据实践经验与实际应用的精度要求灵活确定。

如图 7 所示， H^{low} 为初始阈值， H^{up} 为重训练阈值。为避免因误差的短期波动频繁触发更新，引入基于历史误差的自适应阈值调整。通过滚动窗口计算室内温度误差，根据其变化趋势动态调整阈值，误差偏大时放宽阈值以避免频繁更新，较小时收紧阈值以加强监控。

$$H^{\text{low}}(t) = \mu(t-n:t) + \alpha \cdot \sigma(t-n:t) \quad (15)$$

式中： $\mu(t-n:t)$ 为前 n 个点内的误差均值； $\sigma(t-n:t)$ 为标准差； α 为调节参数，决定阈值的灵敏度。

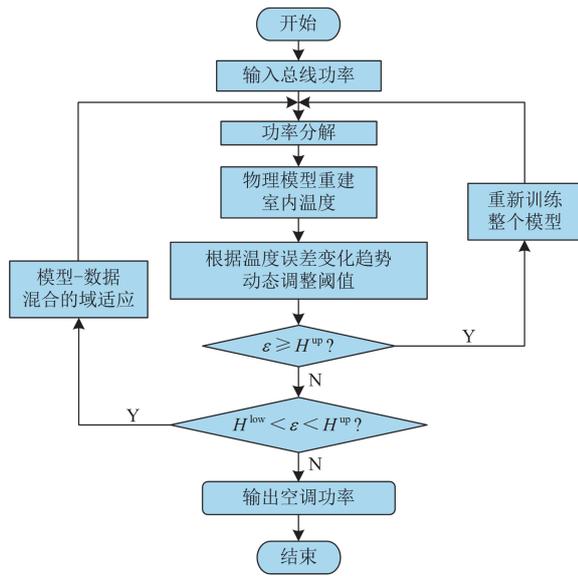


图 7 算法更新流程图

Fig. 7 Algorithm update flowchart

当误差值超过设定阈值时，触发模型域适应或重训练。首先，计算当前时间段的室内温度估计误差 ε 。当 $\varepsilon \leq H^{\text{low}}$ ，误差在可接受范围内，无需更新模型。当 $H^{\text{low}} < \varepsilon < H^{\text{up}}$ ，模型-数据混合驱动的域适应，修正模型在当前环境下的估计偏差。当 $\varepsilon \geq H^{\text{up}}$ ，触发重训练，使用新的数据重新训练整个模型。

在域适应中，采用易于获取的室内温度数据，并基于温度估计损失对空调监测模型进行微调，实现低成本域适应。该方法减少了对空调功率标签的依赖，利用物理模型的先验知识，提高了模型在新

用户下的监测性能。具体如下：首先利用物理模型参数重建室内温度 \hat{T}^{in} ，结合实际测量的室内温度 T^{in} 计算物理模型损失 L^{phy} 。为保留源域知识，冻结负荷监测模型的双分支输入模块和多元特征融合模块的参数 θ^{feat} ，及参数辨识模型的权重 θ^{phy} 。这是因为空调监测模型的这部分参数主要用于建模多元输入的通用特征，具有较强的领域不变性。而参数辨识模型基于物理模型构建，且通过仿真方式生成多样化的训练样本，因此更具可迁移性。最后基于温度估计损失进行反向传播，更新空调监测模型的输出层参数 θ^{out} 。

$$\theta_{e+1}^{\text{out}} = \theta_e^{\text{out}} - \omega^{\text{out}} \cdot \frac{\partial L^{\text{phy}}}{\partial \theta^{\text{out}}} \quad (16)$$

式中： ω^{out} 表示输出层的学习率。

综上，尽管目标域缺乏功率标签，但本文假设可低成本地获得室内温度的真实测量值。通过参数辨识模型的温度估计损失，模型依旧能够利用低成本获得的室温标签来监督修正参数，从而维持负荷监测和参数辨识的准确性。有效缓解了监测模型迁移至新用户时高度依赖空调运行功率标签的问题。

6 实验设置

6.1 实验数据制备

6.1.1 公开数据集简介

本研究采用美国奥斯汀市的公开数据集，该数据集包含 24 户家庭的智能电表监测数据与空调运行功率数据，数据时间分辨率为 1 min。本文选取了 8 间具有不同特征的房屋作为实验对象，实验数据采集时间为 5 月至 8 月，涵盖了当地夏季空调使用的主要时段，期间当地气温范围为 15 °C 至 41 °C。鉴于原始数据集中缺乏当地气象信息，本文补充来自美国国家海洋和大气管理局的室外温度数据，采样间隔为 1 h。室内温度数据则通过仿真方法生成^[28]。为保证仿真温度的合理性，基于空调物理模型，结合典型值与正态分布生成等效热容 C ，等效热阻 R ，制冷能效比 η 。采用以参数中心值为 $(C R \eta) = (0.56 \ 1.56 \ 2.04)$ 、标准差为中心值 10% 的正态分布进行采样，生成 363 组参数，单位分别为 kWh/°C、°C/kW、W/W。随后，基于数据集中的空调功率和室外温度，设定初始室内温度，并采用数值求解方法逐步计算各时间步的室内温度变化。

6.1.2 自建数据集简介

本文在广州实验室开展为期 4 周的实地测试，借助多源数据采集系统，评估模型的实际应用能力，如附录 A 所示。

1) 数据采集方式。空调运行功率采用 16 A 智能

插座进行记录, 总电表数据由智能空气开关监测, 气象数据由高精度电子温度计自动采集, 包括室外温度和房间温度, 数据分辨率均为 10 s/点。

2) 测试场景设计。为验证模型的可迁移性, 实验包括办公场景、会议室及夜间休息场景的空调运行情况。各类场景体现出显著的用户行为多样性, 办公场景集中于工作日白天, 会议室人员流动频繁且使用时段不固定, 夜间休息场景则主要出现在夜间及周末。各场景中室内平均温度范围为 20.58℃至 27.00℃, 能效等级包含二级与五级, 人员数量 3 至 12 人, 覆盖多种典型使用条件。

6.1.3 预处理方法

为保障数据质量, 本文对原始数据进行了清洗、对齐与标准化等预处理。鉴于该公开数据集的缺失值较少, 直接剔除包含缺失项的样本。在异常值方面, 对于如空调功率小于 0 等不合理数据, 将其替换为 0。针对功率数据与气象数据在时间分辨率上的差异, 通过时间戳匹配实现数据对齐, 并对气象数据中的缺失项采用向后填充策略进行补全。最终, 为消除特征间量纲差异、提升模型训练效果, 采用 Z-score 标准化方法对所有特征数据进行归一化处理。

6.1.4 数据多样性分析

为验证算法对不同分布的适应能力, 首先对实验数据进行多样性分析。与传统均值检验或距离度量方法相比, Kolmogorov-Smirnov(KS)检验作为一种非参数统计方法, 具备对数据分布无依赖、全局敏感、结果直观的优势。因此, 本文采用 KS 检验中的 D 值量化两个样本分布间的差异, 其计算公式如式(17)所示。

$$D = \sup_x |F_i(x) - F_j(x)| \quad (17)$$

式中: $F_i(x)$ 、 $F_j(x)$ 分别代表两个数据分布的累积分布函数; \sup 代表对所有可能位置 x 取最大值。 D 值越大, 表示两个样本分布之间的差异越显著。在评估模型泛化能力时, 利用具有分布差异的数据进行验证是关键。图 8 展示了源数据 8 间房屋的 KS 检验热图, 不同房屋间的 D 值分布在 0.1~0.6, 表明不同用户间的用电数据存在显著差异, 这意味着模型在目标域上的表现能够有效评估其可迁移性。

6.2 评价指标

为评估模型性能, 本文采用均方误差(mean square error, MSE)和平均归一化误差(average normalized error, ANE)作为评价指标。

其中 MSE 衡量空调监测算法在每个时间点对功率的估计值与实际功率间的误差, 如式(18)所示。

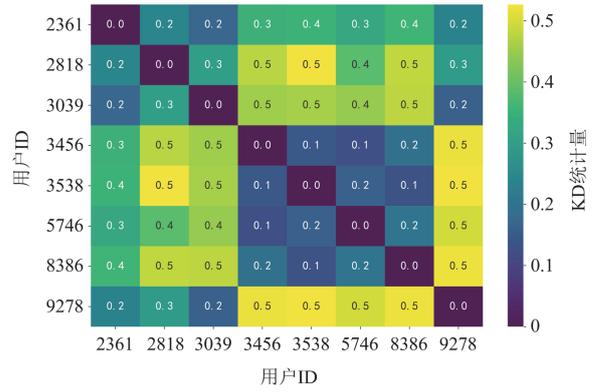


图 8 8 间房屋热图对比

Fig. 8 Comparison of heat maps for 8 houses

$$E_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (\hat{p}_i - \bar{p}_i)^2 \quad (18)$$

式中: \hat{p}_i 为在时刻 i 从总线功率中估计出来的空调运行功率; \bar{p}_i 为空调负荷在时刻 i 实际消耗的功率。

ANE 衡量空调监测算法估计的功率与实际消耗的功率之间的总功率差, 定义为

$$E_{\text{ANE}} = \frac{\sum_{i=1}^n |\bar{p}_i - \hat{p}_i|}{\sum_{i=1}^n \bar{p}_i} \quad (19)$$

为便于比较各模型与基线模型性能的差异, 定义绝对降幅 Δ_E 和相对降幅 δ_E 。

$$\Delta_E = E_{\text{base}} - E_{\text{test}} \quad (20)$$

$$\delta_E = \frac{\Delta_E}{E_{\text{base}}} \quad (21)$$

式中: E_{base} 为基线模型的评价指标结果; E_{test} 为所讨论方法的评价指标结果。两者正值表示性能提升, 负值表示性能下降。

MSE 和 ANE 从不同维度评估模型误差。MSE 侧重局部拟合精度, 衡量每个数据点估计值与真实值之间的偏差, 对异常值更敏感, 适用于细粒度误差分析。相比之下, ANE 关注整体误差, 通过计算估计值与实际值的归一化偏差, 提供更直观的整体表现评估。

6.3 实验设计

6.3.1 空调监测精度评估

为验证所提模型在已收集的源域数据上的识别精度, 本文设计了如下实验方案。

1) 基于数据驱动的空调监测模型性能评估。选取 2361 与 3456 号房屋的用电数据作为源域数据, 并按 4:1 的比例划分训练集和测试集。除特殊说明

外,所有实验均在 50 个训练周期内完成,采用学习率为 5×10^{-5} 的 Adam 优化器进行模型参数更新,实验环境基于 Python 3.9 和 Pytorch 框架,在 NVIDIA GeForce RTX 3060 显卡上运行。在相同数据分布下测试模型性能,验证其在已知场景中的表现。

2) 基于模型-数据混合驱动交替式训练的空调监测性能评估。为验证模型-数据混合驱动在利用空调运行状态与温度的强相关性、引导深度学习模型遵循物理规律以及缓解模型过拟合方面的有效性,并评估其在监测精度上的提升效果,本文基于设置多组物理模型参数生成室内温度数据的 2361 和 3456 号房屋数据进行训练,对比测试集实验结果。

对比组设置:选取 3 种典型模型作为基线: CNN^[32]、LSTM^[33]、基于 Transformer 的双向编码器 (bidirectional encoder representations from Transformers, BERT)^[34],与本文方法进行比较。文献[32]基于 CNN 提取空调负荷的局部特征,用于作为评估所提方法特征提取能力的基准;文献[33]采用 LSTM 建模空调运行状态的时序特性,用于对比所提模型的时序建模能力。BERT 擅长长期特征捕捉,用于评估所提模型在空调的长短期特征、用户使用习惯等方面的性能表现。

6.3.2 空调监测模型可迁移性评估

为验证所提空调监测模型迁移至新用户时的可迁移性,本文设计了如下实验方案。

1) 基于数据驱动的空调监测模型迁移测试。在 3039 号房屋(目标域)中,选择 5—8 月份(空调使用频繁的时段)进行测试,评估在源域数据上训练后的模型在不同用户下的可迁移性。

2) 基于模型-数据混合驱动交替式训练的监测模型迁移测试。为进一步验证基于模型-数据混合驱动的交替式训练对模型可迁移性的提升,在数据集中的 3039 号房屋(目标域)上进行测试。评估在源域数据上训练后的模型在不同用户下的可迁移性。

6.3.3 空调监测域适应有效性评估

为验证物理模型在新用户下对监测模型的域适应效果,本文基于公开数据集中的 8 间房屋数据,选取 2361、3456 号房屋作为源域,其他房屋作为目标域。在每个目标域房屋中,选取 10% 的室内温度数据作为域适应样本,进行 20 轮域适应训练,对比域适应前后的监测精度。最后进一步验证模型在实际场景中的部署效果。

对比方法:为验证所提方法在迁移至新用户时相较于传统方法的性能优势,本文与两种具有代表性的域适应方法,文献[17]的深度域适应 (deep domain adaptation, DDA) 和文献[18]的无监督域适应

(unsupervised domain adaptation, UDA)进行了对比实验。文献[17]联合优化领域自适应和功率估计损失,学习单个设备状态跨领域的不变表示。文献[18]则通过对抗网络和联合自适应方法,减小源域和目标域特征空间和标签空间的分布差距。在公开数据集中的 2361、3456 号房屋(源域)上进行训练,DDA 和 UDA 分别使用 3039 号房屋(目标域)10% 的数据进行 20 轮域适应。

6.3.4 消融实验

为验证所提模型各模块的必要性,设计消融实验,分别去除以下模块,分析其对模型性能的影响:去除双分支输入模块,评估其在短期时间尺度特征提取的作用;去除 Transformer 模块,分析其对长期时间尺度特征提取与特征融合的贡献。仅采用电气量输入,评估数据输入多样性对模型性能的影响。将电气量、外部因素信息等全部输入直接作为单一分支输入,验证双分支结构的有效性。实验数据选择 2361 房屋,按照 4:1 的比例划分训练集和测试集。

7 实验结果

7.1 监测精度实验

1) 基于数据驱动的空调监测模型性能评估结果:实验结果如表 1 所示。所提方法在源域中的误差显著优于对比方法,包括 CNN、LSTM 和 BERT。在 ANE 方面,绝对降幅分别为 9.782%、3.700%、8.251%,相对降幅达 69.996%、46.877%、66.305%,表明其在整体功率估计精度方面更具优势。MSE 绝对降幅分别为 0.122、0.033、0.185,相对降幅为 85.315%、61.111%和 89.806%,反映出其对空调运行功率的短期波动特征具有更强的提取能力。从图 9 中可以进一步观察到,在空调启停状态的识别方面,所提方法表现出更高的准确性。相比之下,LSTM、BERT 均存在多次误识别情况,1D-CNN 虽然未出现明显的启停误判,但其在空调运行功率估计上偏差较大,说明其在复杂时序特征捕捉方面仍存在局限性。

2) 基于模型-数据混合驱动交替式训练的空调监测性能评估结果。表 4 展示了嵌入物理模型后,本文方法在源域测试集上的监测性能,结果显著优于基线方法。在 MSE 和 ANE 指标上,所提方法为 0.015、3.082%。对比 CNN、LSTM、BERT 及未嵌

表 1 各方法在测试集的结果

Table 1 Results of various methods on the test set

指标	CNN	LSTM	BERT	本文方法
MSE	0.143	0.054	0.206	0.021
ANE/%	13.975	7.893	12.444	4.193

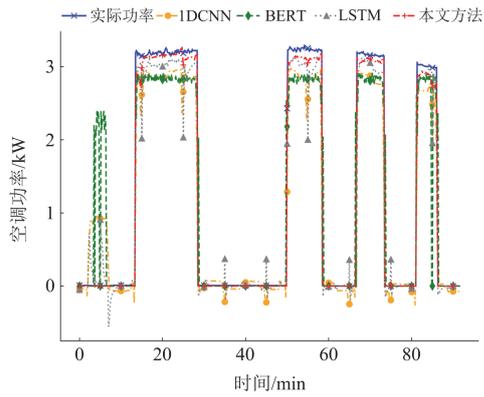


图 9 基于数据驱动的监测模型源域估计结果及
基线方法对比

Fig. 9 Estimation results of the data-driven monitoring model in the source domain and its comparison with the baseline method

入物理模型的方法,其 MSE 绝对降幅分别为 0.128、0.039、0.191 和 0.006, ANE 绝对降幅分别为 10.893%、4.811%、9.362%和 1.111%, 验证了模型-数据混合驱动在提升估计精度方面的作用,充分利用了空调运行状态与温度之间的强相关性。此外,物理模型室内温度估计误差为 0.1534,说明其与数据驱动模块能够有效协同工作。图 10(a)和图 10(b)分别为所提方法在源域的监测结果和室内温度估计结果,与未嵌入物理模型的方法相比,本方法在功率估计精度上均有小幅度提升,进一步证明其对增强模型精度的积极作用。

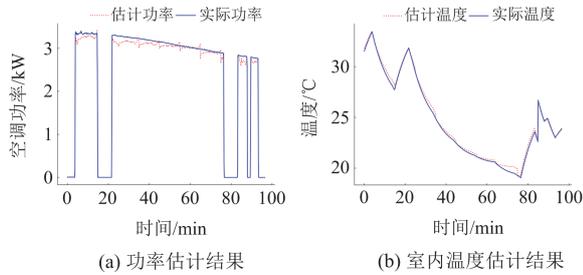


图 10 模型-数据混合驱动的监测模型在源域功率及
室内温度估计结果

Fig. 10 Estimation results of power and indoor temperature in the source domain using the model-data hybrid-driven monitoring model

7.2 可迁移性实验

1) 基于数据驱动的空调监测模型泛化实验。为保证可比性,目标域选取与源域相同时间点的数据进行测试,结果见表 2。在目标域上,本文方法显著优于其他对比方法,表现出较强的泛化性。其中 MSE 绝对降幅分别为 0.321、0.299、0.225,相对降幅分别为 71.973%、70.518%和 64.285%; ANE 绝

对降幅分别为 11.760%、6.637%、3.735%,相对降幅分别为 52.015%、37.956%和 25.610%。值得注意的是,如图 11 所示,传统方法存在不同程度的“过度分解”现象,即在空调处于停机状态时仍估计出非零功率(误将其他设备功率归因于空调),导致估计偏差加剧。本文方法结合注意力机制,能够更精准地提取全屋负荷中的空调能耗模式,从而缓解过度分解问题,提高空调监测的精度。

表 2 各方法在新场景(3039 号房屋)的结果

Table 2 Results of various methods in new scenarios (House 3039)

指标	CNN	LSTM	BERT	本文方法
MSE	0.446	0.424	0.350	0.125
ANE/%	22.609	17.486	14.584	10.849

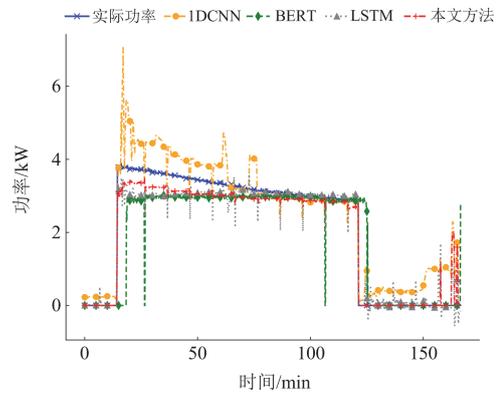


图 11 基于数据驱动的监测模型直接迁移至 3039 号
房屋估计结果及基线方法对比

Fig. 11 Estimation results of the data-driven monitoring model when directly transferred to House 3039 and its comparison with the baseline method

2) 基于模型-数据混合驱动交替式训练的空调监测可迁移性实验。如表 4 所示,与基线方法相比,本文通过引入物理模型的普适性规律,有效缓解了源域的过拟合问题,使得各项指标显著优化。其中 MSE 绝对降幅分别为 0.333、0.311、0.237, ANE 绝对降幅分别为 12.437%、7.314%、4.412%。进一步地,对比未嵌入物理模型的本文方法上,当前策略在 MSE 和 ANE 绝对降幅分别为 0.012、0.677%,验证了模型-数据混合驱动在促进模型迁移适应方面的有效性,充分利用了空调运行与温度的相关性,也为基于温度估计损失进行模型动态更新提供了有力支撑。

7.3 域适应实验

1) 公开数据集实验

如表 3、图 12(a)和图 12(b)所示,本文方法相较于传统域适应策略,在训练效率与估计精度方面均

展现出显著优势。首先,在训练效率方面,所提方法利用目标域约 12 天的数据进行一次轻量级微调,耗时仅为秒级(约 100 s)。而传统域适应方法需在源域与目标域数据的基础上进行联合训练,训练时间达到小时级(约 1 小时 41 分 40 秒)。这一差异使得本文方法在实际部署中更具可操作性,尤其适用于资源受限的场景。其次,在监测精度上,本文方法在源域和目标域上的表现均优于传统方法。在域适应后,本文方法在源域上的 MSE 和 ANE 绝对降幅分别为 0.045 和 5.321%,在目标域上,绝对降幅分别为 0.131 和 7.744%。相比之下,传统方法需同时优化源域的回归误差与源-目标域的分布误差,可能导致其在训练过程的收敛性和最终性能受限。

表 3 域适应方法与本文方法误差

Table 3 Error between domain adaptation methods and the proposed method

指标	域别	本文	DDA	UDA
MSE	源域	0.017	0.059	0.064
	目标域	0.097	0.215	0.240
ANE/%	源域	3.691	9.972	8.051
	目标域	8.437	16.023	16.338

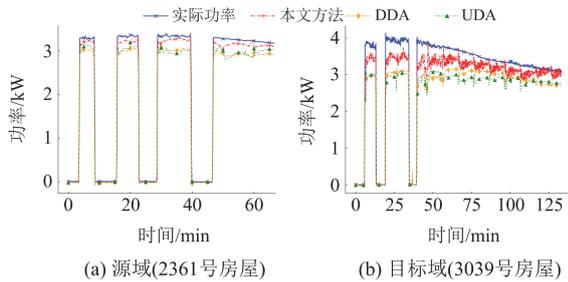


图 12 本文方法与传统域适应方法在源域与目标域的空调估计功率

Fig. 12 Air conditioning power estimation in source and target domains: proposed method vs. traditional domain adaptation methods

从图 13 及表 4 可以看出,通过引入目标域的温度数据进行域适应后,模型的 ANE 显著降低。这一性能提升主要得益于物理模型的嵌入,使模型能够更准确地捕捉目标建筑空调所受的环境变化规律,通过温度估计误差感知目标域的数据分布特征,提升监测准确性。实验数据显示,域适应后模型的 MSE 和 ANE 平均相对降幅分别为 4.946%、8.356%。该方法为模型在迁移至新场景时提供了一种低成本且高效的更新机制,有效缓解了由空调型号、用户使用习惯和行为模式所带来的模型性能下降问题。

以 5746 号房屋为例,其在域适应前的误差最

低,这主要是由于其数据分布与源域较接近(KS 值为 0.1,参见图 8),因此直接迁移时模型性能下降最小。总体而言,不同目标房屋的性能下降与其数据分布的相似程度呈负相关。通过域适应,模型进一步调整匹配该房屋的环境与使用模式,有效降低了分布偏差,提升了功率估计精度。

此外,如表 4 所示,模型在源域的温度估计误差最大为 0.1534,为保证当误差略高于源域水平时即可触发域适应,可将初始阈值 T^{low} 设置为 0.16。模型在目标域尚未域适应时的最大温度估计误差为 0.596,因此可将重训练阈值 T^{up} 设定为 0.6,用于判定模型在目标域已明显失效的情况。

综上所述,基于模型-数据混合驱动的域适应方法在多个新用户中均展现出强适应性,尤其在数据分布差异较大的场景中,优势更加显著。结合源域和目标域的对比结果,本文方法在所有测试中均取得最低的 MSE 和 ANE,充分验证了其在负荷监测任务中的准确性和可迁移性,展现出在实际部署应用中的高度可靠性。

2) 自建数据集实验

如表 5 所示,本文在多个场景实地采集数据,并在此基础上对在公开数据集中显著优于现有方法的所提模型进行测试,结果包括模型直接迁移与域适应后的性能表现。结果表明,模型经过域适应后,MSE 和 ANE 相对降幅分别达 14.191%和 42.431%。图 14 展示了监测结果的局部放大图,可见,虽然直接迁移模型基本能够识别出空调的启停状态,但在

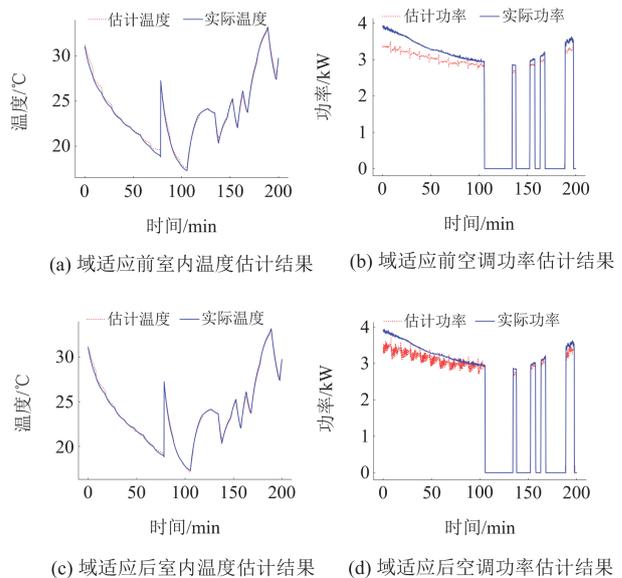


图 13 新场景下(3039 号房屋)域适应前后模型效果对比

Fig. 13 Comparison of model performance before and after domain adaptation in the new scenario (House 3039)

表 4 源域用户以及目标域新用户的测试结果

Table 4 Model test results for source-domain users and target-domain new users

指标	房屋编号							
	2361	3456	2818	3039	3538	5746	8386	9278
域适应前温度估计误差	0.1534	0.0574	0.3594	0.2840	0.0359	0.1729	0.041	0.596
域适应前 ANE/%	3.082	3.440	7.570	10.172	6.784	5.800	6.739	13.273
域适应前 MSE	0.015	0.006	0.051	0.113	0.010	0.019	0.018	0.254
域适应后 ANE/%	—	—	6.814	8.437	5.683	5.714	6.380	13.104
域适应后 MSE	—	—	0.051	0.097	0.009	0.018	0.017	0.250
域适应后温度估计误差	—	—	0.2822	0.2409	0.0350	0.1448	0.0373	0.5775

表 5 域适应模型在自建数据集的实验效果

Table 5 Experimental performance of the domain adaptation model on the custom dataset

指标	直接迁移	模型微调
MSE	0.0909	0.078
ANE/%	24.944	14.360

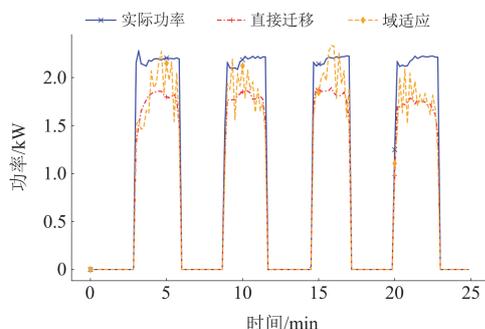


图 14 直接迁移模型与经域适应后的空调监测效果

Fig. 14 Air conditioning monitoring performance between the direct transfer model and the domain-adapted model

运行功率的估计上仍存在明显偏差。相比之下, 域适应后的模型能够更好地感知新环境的特征信息, 从而显著提升了准确性。验证了所提方法在实际部署场景中的有效性和适应能力, 体现出良好的工程应用潜力。

7.4 消融实验

表 6 展示了在 2361 号房屋测试集上进行的消融实验结果, 图 15 则呈现了某一时段的功率估计结果。由表 6 可见, 当分别去除双分支输入模块和去除多元特征融合模块后, 模型的 MSE 接近, 说明两者在异常值的估计方面表现接近。然而, 在 ANE 上两者绝对幅值相差 1.108%, 反映出它们在不同数值区间样本的估计倾向, 双分支模块更擅长低值样本, 多元特征融合模块更擅长高值样本。结合图 15 可知, 去除双分支模块后, 预测结果更倾向于负偏差(低估功率); 去除多元特征融合模块后, 则更容

易出现正偏差(高估功率), 最终导致两者在 ANE 上的差异。该现象与本文提出的模块功能分工一致, 前者擅长短期时间时序特征提取(如短期波动、周期细节), 其缺失使得模型更加依赖全局均值或平滑趋势, 从而倾向于保守估计。而后的自注意力机制更擅长捕捉长期时间尺度依赖和关键事件, 其缺失使得模型更易陷入对历史高值的过度拟合, 导致功率估计存在惯性外推。因此, 所提方法能够有效解决空调长短期时序建模问题, 通过局部-全局特征融合实现均衡预测。

表 6 消融实验结果

Table 6 Results of ablation experiments

指标	去除双分支	去除多元特征融合	仅采用电气量输入的本文方法	单分支输入	本文方法
MSE	0.056	0.060	0.026	0.043	0.021
ANE/%	8.061	9.169	5.205	7.584	4.193

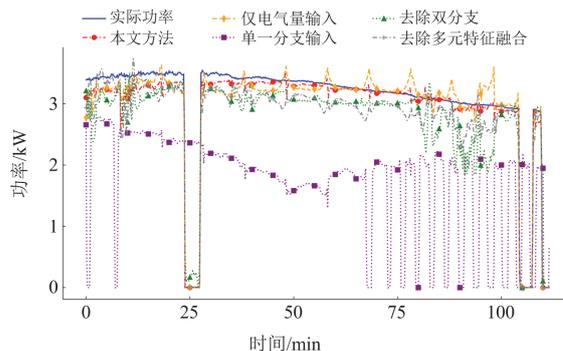


图 15 消融实验结果对比

Fig. 15 Comparison of ablation experiment results

进一步对比仅采用电气量输入的基线方法, 本文方法的 ANE 绝对降幅为 1.012%, 相对降幅为 19.443%, 说明多元数据输入在提升模型预测精度方面具有重要作用。多元数据能够提供更丰富的外部驱动因素, 辅助模型识别空调运行的周期性规律。同时单分支输入的功率估计误差高于基线模型,

MSE 和 ANE 绝对降幅分别为-0.017、-2.379%，这表明不同类型的输入在单一分支中混合会导致特征干扰。如图 15 所示，对比方法的结果波动较大，易受局部功率变化和噪声干扰。本文方法与实际值更贴合，表明多模态数据有效抑制了噪声干扰，提高了模型的鲁棒性。

8 结论

为提高空调监测模型对运行模式的刻画能力并降低其迁移至新用户时对运行功率标签的依赖，本文提出了一种基于模型-数据混合驱动的空调监测及其域适应方法。该方法通过双分支结构与多元特

征融合模块，有效提取空调的复杂动态特性及其与环境因素的耦合关系。其次，神经网络辨识空调物理模型的等效热参数，并在训练中交替使用功率估计损失和室内温度估计损失。最后在新用户中基于室内温度变化趋势判断域间差异影响，利用温度数据与总线量测数据动态更新空调监测模型。与现有方法相比，所提方法在已收集的源域数据上误差的相对降幅至少为 46.877%。在域适应新用户的目标域数据后，公开数据集与自建数据集上的功率估计误差相对降幅分别至少为 30.252%和 14.191%。综上，所提方法为空调监测模型的构建与域适应提供了新的思路，展现出较高的实际应用价值。

附录 A

表 A1 各实验场景的基本情况

Table A1 General overview of various experimental scenarios

场景	空调型号	最高温度/℃	最低温度/℃	平均温度/℃	人数	额定功率/W	采样时长/天	能效
办公室 1	KF-50GW/ Y-IA(R2)	29.49	22.84	27.00	3	1447	28	二级
办公室 2	KF-50LW/K(50348L)-N5	27.57	22.51	24.07	3	1860	28	五级
会议室	KF-50GW/ Y-IA(R2)	27.18	17.13	20.58	12	1447	28	二级
夜间休息室	KF-35GW/ (35370)Aa-2	29.30	23.36	25.88	5	1002	28	二级



图 A1 实验室场景下空调智能插座实际部署图

Fig. A1 Actual deployment diagram of the air conditioning smart socket in the lab scenario



图 A3 办公室场景 2

Fig. A3 Office scenario 2



图 A2 办公室场景 1

Fig. A2 Office scenario 1

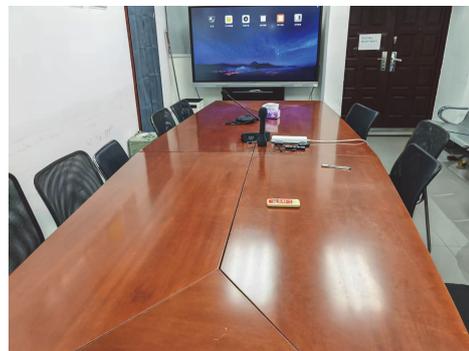


图 A4 会议室场景

Fig. A4 Conference room scenario



图 A5 夜间休息场景(宿舍)

Fig. A5 Nighttime resting scenario (dormitory)

参考文献

- [1] SAXENA A, SHANKAR R. An interactive operating demand response approach for hybrid power systems integrating renewable energy sources[J]. *Protection and Control of Modern Power Systems*, 2024, 9(3): 174-194.
- [2] 程松, 周鑫, 任景, 等. 面向多级市场出清的负荷聚合商联合交易策略[J]. *电力系统保护与控制*, 2022, 50(20): 158-167.
CHENG Song, ZHOU Xin, REN Jing, et al. Bidding strategy for load aggregators in a multi-stage electricity market[J]. *Power System Protection and Control*, 2022, 50(20): 158-167.
- [3] 杨梓俊, 丁小叶, 陆晓, 等. 面向需求响应的变频空调负荷建模与运行控制[J]. *电力系统保护与控制*, 2021, 49(15): 132-140.
YANG Zijun, DING Xiaoye, LU Xiao, et al. Inverter air conditioner load modeling and operational control for demand response[J]. *Power System Protection and Control*, 2021, 49(15): 132-140.
- [4] 刘彦伶, 武志刚, 赖翔, 等. 异质空调负荷参与多区域电力系统频率调节的协同控制策略[J]. *电力系统保护与控制*, 2025, 53(3): 47-57.
LIU Yanling, WU Zhigang, LAI Xiang, et al. Cooperative control strategy for heterogeneous air-conditioning loads participating in frequency regulation of multi-area power systems[J]. *Power System Protection and Control*, 2025, 53(3): 47-57.
- [5] 范德金, 张姝, 王杨, 等. 考虑用户调节行为多样性的空调负荷聚合商日前调度策略[J]. *电力系统保护与控制*, 2022, 50(17): 133-142.
FAN Dejin, ZHANG Shu, WANG Yang, et al. Day ahead scheduling strategy for air conditioning load aggregators considering user regulation behavior diversity[J]. *Power System Protection and Control*, 2022, 50(17): 133-142.
- [6] 蔡清淮, 罗庆全, 余涛, 等. 基于主动迁移学习的负荷辨识泛化方法[J]. *电力自动化设备*, 2025, 45(3): 209-216.
CAI Qinghuai, LUO Qingquan, YU Tao, et al. Generalization method for load identification based on active transfer learning[J]. *Electric Power Automation Equipment*, 2025, 45(3): 209-216.
- [7] 程志友, 胡乐乐, 陈思源, 等. 基于多 V-I 轨迹融合的非侵入式负荷识别方法[J]. *电力系统保护与控制*, 2025, 53(11): 63-71.
CHENG Zhiyou, HU Lele, CHEN Siyuan, et al. Non-intrusive load identification method based on multiple V-I trajectory fusion[J]. *Power System Protection and Control*, 2025, 53(11): 63-71.
- [8] KELLY J, KNOTTENBELT W. Neural NILM: deep neural networks applied to energy disaggregation[C]// *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-efficient Built Environments*, 2015, Seoul, South Korea.
- [9] 林顺富, 詹银枫, 李毅, 等. 基于 CNN-BiLSTM 与 DTW 的非侵入式住宅负荷监测方法[J]. *电网技术*, 2022, 46(5): 1973-1981.
LIN Shunfu, ZHAN Yinfeng, LI Yi, et al. Non-intrusive residential load monitoring method based on CNN-BiLSTM and DTW[J]. *Power System Technology*, 2022, 46(5): 1973-1981.
- [10] ZHU Z, ZHOU M, HU F, et al. TSILNet: a novel hybrid model for energy disaggregation based on two-stage improved TCN combined with IECA-LSTM[J]. *Advances in Modeling and Simulation Tools*, 2024, 17: 2083-2096.
- [11] ZHOU Y, JI C, DONG Z, et al. Non-intrusive load disaggregation based on multiple optimization of appliance features and CNN-NLSTM model[C]// *2022 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia)*, July 8-11, 2022, Shanghai, China: 871-876.
- [12] 彭秉刚, 潘振宁, 余涛, 等. 图数据建模与图表示学习方法及其非侵入式负荷监测问题的应用[J]. *中国电机工程学报*, 2022, 42(17): 6260-6274.
PENG Binggang, PAN Zhenning, YU Tao, et al. Graph data modeling and graph representation learning methods and their application in non-intrusive load monitoring problem[J]. *Proceedings of the CSEE*, 2022, 42(17): 6260-6274.
- [13] 陈泽旭. 聚合空调负荷参与需求响应的控制及应用研究[D]. 武汉: 华中科技大学, 2022.
CHEN Zexu. Research on the control and application of aggregated air conditioning load participating in demand response[D]. Wuhan: Huazhong University of Science and Technology, 2022.
- [14] LUAN W, WEI Z, LIU B, et al. Non-intrusive power waveform modeling and identification of air conditioning load[J]. *Applied Energy*, 2022, 324.
- [15] LUAN W, WEI Z, LIU B, et al. A training-free non-intrusive air conditioning load monitoring method

- based on fuzzy comprehensive evaluation[J]. Applied Energy, 2024, 376.
- [16] LI D, LI J, ZENG X, et al. Transfer learning for multi-objective non-intrusive load monitoring in smart building[J]. Applied Energy, 2023, 329.
- [17] LIN J, MA J, ZHU J, et al. Deep domain adaptation for non-intrusive load monitoring based on a knowledge transfer learning network[J]. IEEE Transactions on Smart Grid, 2021, 13(1): 280-292.
- [18] LIU Y, ZHONG L, QIU J, et al. Unsupervised domain adaptation for nonintrusive load monitoring via adversarial and joint adaptation network[J]. IEEE Transactions on Industrial Informatics, 2021, 18(1): 266-277.
- [19] D'INCECCO M, SQUARTINI S, ZHONG M. Transfer learning for non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2019, 11(2): 1419-1429.
- [20] 刘熙鹏, 罗庆全, 余涛, 等. 基于多尺度特征融合的负荷辨识及其可解释交互增强方法[J]. 电力系统自动化, 2024, 48(2): 105-117.
- LIU Xipeng, LUO Qingquan, YU Tao, et al. Load identification and its interpretable interactive enhancement method based on multi-scale feature fusion[J]. Automation of Electric Power Systems, 2024, 48(2): 105-117.
- [21] YU B, LI J, LIU C, et al. A novel short-term electrical load forecasting framework with intelligent feature engineering[J]. Applied Energy, 2022, 327.
- [22] GUO F, CHEN J, WANG Y, et al. A new LSTNet-based temperature prediction model for permanent magnet[J]. Measurement Science and Technology, 2024, 35(6).
- [23] LIU R, CHEN L, HU W, et al. Short-term load forecasting based on LSTNet in power system[J]. International Transactions on Electrical Energy Systems, 2021, 31(12).
- [24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in neural information processing systems, 2017, 30.
- [25] GAO J, CHEN Y, HU W, et al. An adaptive deep-learning load forecasting framework by integrating transformer and domain knowledge[J]. Advances in Applied Energy, 2023, 10.
- [26] LI Y, CAO J, XU Y, et al. Deep learning based on Transformer architecture for power system short-term voltage stability assessment with class imbalance[J]. Renewable and Sustainable Energy Reviews, 2024, 189.
- [27] LUO X, WANG Y, ZHU Q, et al. Physics-informed neural network for parameter identification of air conditioning load models[C]// 2024 7th International Conference on Energy, Electrical and Power Engineering (CEEPE), 2024: 948-953.
- [28] 杨秀, 傅广努, 刘方, 等. 考虑多重因素的空调负荷聚合响应潜力评估及控制策略研究[J]. 电网技术, 2022, 46(2): 699-714.
- YANG Xiu, FU Guangnu, LIU Fang, et al. Potential evaluation and control strategy of air conditioning load aggregation response considering multiple factors[J]. Power System Technology, 2022, 46(2): 699-714.
- [29] 王义国, 林峰, 李琦, 等. 基于 TCN-LSTM 模型的电网电能质量扰动分类研究[J]. 电力系统保护与控制, 2024, 52(17): 161-167.
- WANG Yiguo, LIN Feng, LI Qi, et al. Classification of power quality disturbances in a power grid based on the TCN-LSTM model[J]. Power System Protection and Control, 2024, 52(17): 161-167.
- [30] 李虹, 韩雨萌. 基于 LSTM-CGAN 的多微网数据驱动分布鲁棒协同优化运行策略[J]. 电力系统保护与控制, 2024, 52(18): 133-148.
- LI Hong, HAN Yumeng. Data-driven distributionally robust collaborative optimization operation strategy for a multi-microgrid based on LSTM-CGAN[J]. Power System Protection and Control, 2024, 52(18): 133-148.
- [31] GAO G, LI J, WEN Y. Energy-efficient thermal comfort control in smart buildings via deep reinforcement learning[J]. arXiv preprint arXiv:1901.04693, 2019.
- [32] PAPAGEORGIOU P, MYLONA D, STERGIOU K, et al. A time-driven deep learning NILM framework based on novel current harmonic distortion images[J]. Sustainability, 2023, 15(17).
- [33] ZHOU D, WU Y, ZHOU H. A nonintrusive load monitoring method for microgrid EMS using Bi-LSTM algorithm[J]. Complexity, 2021, 2021(1).
- [34] YUE Z, WITZIG C R, JORDE D, et al. Bert4nilm: a bidirectional transformer model for non-intrusive load monitoring[C]// Proceedings of the 5th International Workshop on Non-intrusive Load Monitoring, 2020: 89-93.

收稿日期: 2025-03-31; 修回日期: 2025-08-25

作者简介:

李钊涛(2000—), 男, 硕士研究生, 研究方向为基于机器学习的负荷辨识; E-mail: lizhaotao2022@qq.com

罗庆全(1999—), 男, 博士研究生, 研究方向为配用电系统深度感知与智能决策; E-mail: epqqluo@qq.com

余涛(1974—), 男, 通信作者, 博士, 教授, 研究方向为复杂电力系统的非线性控制理论、优化与机器学习。E-mail: taoyu1@scut.edu.cn

(编辑 石晋美)