

DOI: 10.19650/j.cnki.cjsi.J2513802

基于改进通道注意力优化变分自编码器的 居民空调负荷辨识*

王凌云¹, 唐 涛¹, 鲍 刚¹, 阮胜冬², 张 涛¹

(1. 三峡大学电气与新能源学院 宜昌 443002; 2. 国网衢州供电公司 衢州 324000)

摘要:居民空调负荷的准确辨识是挖掘其调控潜力和实现需求响应的关键。针对目前居民空调功率求解方法的精度不足和计算复杂问题,故提出一种基于变分自编码器(VAE)和改进高效通道注意力机制(ECA)的居民空调负荷非侵入式辨识神经网络模型。改进 ECA 采用结合全局平均池化与全局最大池化的双池化策略,既捕获整体统计信息又突出局部显著响应。借助压缩-重构机制,在降维后利用快速动态卷积核自适应捕捉局部通道交互信息,有效聚焦关键信息,为通道赋予合理权重;将改进 ECA 集成在 VAE 解码器中,增强模型对空调负荷的特征重构能力;模型进一步引入多任务学习框架,联合优化功率分解与状态识别任务,实现任务间信息共享和互补,从而提高整体辨识精度。同时,利用输出模块和后处理状态阈值约束,有效抑制非空调负荷的干扰。最后,在真实居民用电数据集上进行实验验证。实验结果表明,相较于两个对比模型,模型在 3 个地区所有居民功率分解的平均绝对误差(MAE)均值分别提升 59.71% 和 9.22%,空调状态识别 F1 值达 84.58%。消融实验表明,改进 ECA 使其中两个地区功率分解 MAE 分别降低 56.23% 和 12.47%,多任务学习框架进一步推动辨识精度提升 3.17% 和 5.90%。所提出的少量侵入式测量方案以 30% 用户侵入式量测数据训练,在保证模型准确性的同时,减少对用户数据的依赖,具有较强的应用潜力。

关键词:居民空调负荷;变分自编码器;非侵入式负荷监测;通道注意力;多任务学习

中图分类号: TM714 TH702 **文献标识码:** A **国家标准学科分类代码:** 470.40

Identification of residential air conditioning loads via channel-attention-optimized variational autoencoder

Wang Lingyun¹, Tang Tao¹, Bao Gang¹, Ruan Shengdong², Zhang Tao¹

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China;

2. State Grid Quzhou Power Supply Company, Quzhou 324000, China)

Abstract: Accurate identification of residential air conditioning load is essential for leveraging their regulation potential and enabling effective demand response. To overcome the limitations of existing residential air conditioning power estimation methods, which often suffer from insufficient accuracy and high computational complexity, this paper proposes a novel non-intrusive neural network model that combines a variational autoencoder (VAE) with an enhanced efficient channel attention (ECA) mechanism. The improved ECA incorporates a dual-pooling strategy-combining global average pooling and global maximum pooling-to capture rich statistical information while highlighting prominent local responses. Additionally, a compression-reconstruction mechanism is introduced; after dimensionality reduction, fast dynamic convolutional kernels adaptively model local channel interactions, focusing on key features and assigning appropriate channel weights. This enhanced ECA module is embedded within the VAE decoder to improve feature reconstruction for air conditioning load estimation. Furthermore, a multi-task learning framework jointly optimizes power disaggregation and state recognition tasks, promoting effective information sharing and complementarity to boost overall identification accuracy. An output module with post-

收稿日期: 2025-03-06 Received Date: 2025-03-06

* 基金项目: 国家自然科学基金(62476153)项目资助

processing state threshold constraints is employed to suppress interference from non-air conditioning loads. The proposed model is validated on real-world residential electricity datasets, showing a mean absolute error (MAE) reduction of 59.71% and 9.22%, respectively, compared to two baseline models across three regions, while achieving an air conditioner state recognition $F1$ score of 84.58%. Ablation studies reveal that the improved ECA contributes to MAE reductions of 56.23% and 12.47% in two regions, and the multi-task learning framework further improves identification accuracy by 3.17% and 5.90%. Moreover, the minimally intrusive measurement approach-training with intrusive data from only 30% of users-significantly reduces reliance on extensive user data while maintaining high accuracy, demonstrating strong potential for practical deployment.

Keywords: residential air conditioning load; variational autoencoder (VAE); non-intrusive load monitoring (NILM); channel attention; multi-task learning

0 引言

近年来,经济社会的发展和极端气候事件的频发导致电力负荷不断攀升,电网运行的稳定性和可靠性面临重大挑战^[1]。城市电网的冬夏用电高峰尤其突出,电力平衡问题日益严峻。为此,多个省市相继颁布了电力需求响应(demand response, DR)政策,以引导用户主动调整用电负荷。居民空调负荷凭借其体量大、占比高,且兼具热储能特性,能够在保证用户舒适度的前提下灵活参与电网调控,是DR中最具潜力的资源^[2-4]。研究空调负荷的调控潜力,不仅有助于缓解电力供应紧张,还能提升电力系统的灵活性和稳定性^[5]。然而,要将居民空调负荷纳入可调控的需求侧柔性资源,首先需要准确辨识用户空调的运行状态和功率。

传统的空调负荷功率求解方法主要分为基准负荷法^[6-7]和等效热参数模型法^[8-11]。基准负荷比较法利用空调负荷的温敏特性计算空调负荷。然而,受用户用电随机性影响,该方法难以满足DR用户级的精细化与精准度要求;等效热参数模型法将建筑围护结构的热力学特性简化为热阻与热容网络,以能量守恒原理推导空调功率。尽管该方法能够提供精确的用户级空调能耗评估,但其缺点在于建模过程需要大量的物理参数,在实际场景中因建筑结构差异而难以推广^[12]。

非侵入式负荷监测(non-intrusive load monitoring, NILM)方法^[13-17]则有效地避免了物理建模和参数设置的问题,同时能够实现用户级的电器用电信息提取。根据是否需要标注数据参与,NILM方法分为无监督和有监督学习方法。比较有代表性的无监督学习方法为隐马尔可夫模型(hidden markov models, HMM)。文献[18]采用HMM无监督地估计不同用户的空调模型参数,并利用维特比算法求解用户空调功率。然而,HMM及其变体在多设备同时运行时难以准确辨识空调设备,且空调状态的复杂转换模式进一步降低了识别精度,这些问题限制了其在空调负荷辨识中的应用。以深度学习为代表的有监督NILM方法已被证明性能是优于隐马尔可夫模型

的^[19]。其中,生成式模型以其出色的数据生成、特征提取和泛化能力的优势在NILM中得到了广泛应用。文献[20]借助多任务学习,设计多个针对空调负荷的损失函数以训练生成对抗网络(generative adversarial network, GAN),从低频智能电表数据中辨识高频空调负荷曲线。然而,GAN的训练过程不稳定,生成器和判别器的对抗可能导致模型难以收敛,且多任务的加入使得模型收敛缓慢。变分自编码器^[21](variational autoencoder, VAE)作为一种生成式模型框架,具有出色的数据生成和特征提取能力,同时在捕捉复杂信号和变化模式方面表现优异。文献[22]提出基于卷积神经网络的VAE负荷分解模型,卷积层增强特征提取的多样性,促进VAE的设备负荷建模。VAE在隐空间中捕捉解释性特征,有助于提取设备类型、工作状态和能耗模式等关键信息,因此适用于空调负荷辨识任务。然而,现有的VAE模型尚未能充分利用通道间的依赖关系,导致对空调启停瞬态特征的捕获不足。引入通道注意力能够改善此类问题,但传统的高效通道注意力机制^[23-24](efficient channel attention, ECA)仅依赖全局平均池化聚合通道特征而忽视局部显著响应,进一步削弱了对关键负荷瞬态特征的表达。

此外,有监督学习方法依赖于收集带有标签的数据,这通常需要硬件安装,并引发时间成本和用户隐私问题。为平衡NILM的实际应用与以上问题之间的矛盾,提出一种折中方案:以少数空调用户侵入式量测为代价,辐射片区内所有用户,精准辨识所有用户的空调负荷。

基于上述原理,为实现用户级居民空调负荷的精准辨识,提出一种基于改进通道注意力优化变分自编码器的空调负荷非侵入式辨识方法。首先,提出改进ECA,其采用结合全局平均池化与全局最大池化的双池化策略,充分捕获整体统计信息与局部显著响应特征;同时引入压缩-重构机制和快速动态卷积核,在降维后自适应捕捉通道间局部交互信息,为各通道赋予精确权重。其次,将改进ECA集成到VAE模型的解码器中,增强解码器对重要特征的重构能力。然后,针对功

率分解与状态识别任务间的内在互补性,模型采用多任务学习框架实现联合优化,通过共享编码器与解码器提取的特征增强任务协同,从而提高整体辨识精度。同时,利用输出模块和状态阈值约束,有效抑制非空调负荷干扰。最后,基于真实居民负荷数据进行实验分析,实验结果显示,模型对于居民空调负荷的特征提取和分解能力表现优异。

1 居民空调负荷辨识问题描述

居民空调负荷辨识所要解决的问题为:在已知智能电表总负荷 $P_{agg}(t)$ 的情况下,估计出户用空调负荷 $P_{AC}(t)$ 的值。图1展示了典型居民空调的运行功率曲线。




图1 居民空调运行功率曲线

Fig. 1 Operating power curve of residential air conditioners

如图1所示,居民空调周期性启停导致功率曲线在短时间存在较大波动。尽管空调频繁的启停行为导致功率波动显著,但由于压缩机是空调的主要耗电部件,大部分时间以额定功率运行,因此在小时尺度上,空调功率曲线整体轮廓相对平滑。

基于上述空调功率曲线分析,空调负荷辨识问题可被描述为式(1),即:

$$P_{agg}(t) = \alpha_{AC}(t)P_{AC}(t) + P_{other}(t) + e(t) \quad (1)$$

式中: $P_{other}(t)$ 表示除空调外的用电设备功率; $e(t)$ 表示量测噪声; $\alpha_{AC}(t) \in \{0, 1\}$ 表示空调在 t 时刻的开断状态。由此,居民空调负荷非侵入式辨识可顺势分为空调功率分解与状态识别两大任务。

功率分解以非线性回归求解 $P_{AC}(t)$,其精度受多负荷耦合干扰;状态识别则需判别空调的二元运行状态 $\alpha_{AC}(t)$,当空调处于制冷、制热等高功率模式时 $\alpha_{AC}(t) = 1$,停机或待机时 $\alpha_{AC}(t) = 0$ 。状态识别仅需捕捉空调启停特征,实现复杂度远低于功率分解。此外,空调的周期性运行特性(如温控启停规律)进一步增强状态识别的可行性。因此,状态识别的高可靠性结果可为功率分解提供先验约束,在空调关闭时段排除非空调负荷波动干扰,从而提升功率估计精度。

2 基于变分自编码器的居民空调负荷非侵入式辨识模型

本章基于第1章的理论分析提出了一种空调负荷非侵入式辨识模型,并介绍了相关原理。

2.1 变分自编码器

变分自编码器(VAE)是一类基于变分推断的生成式模型框架,如图2所示,其组成包含编码器 $q_{\phi}(z|x)$ 与解码器 $p_{\theta}(y|z)$ 两部分。




图2 VAE框架

Fig. 2 Framework of VAE

该框架中, x 代表输入序列; z 代表隐空间变量,即编码器输出的潜在表示,用于捕捉输入数据的分布特征; y 代表生成序列。编码器 $q_{\phi}(z|x)$ 将输入序列 x 映射为隐变量 z 的分布参数:均值 μ 和方差 σ^2 , ϕ 表示变分参数,用于近似真实后验分布 $p(z|x)$ 。解码器 $p_{\theta}(y|z)$ 根据 z 生成目标序列, θ 表示解码器模型参数。

在标准 VAE 框架中,从编码器随机采样 z 的操作是不可微的,反向传播时无法实现梯度回传。为解决这一问题,文献[21]引入重参数化技巧,将 z 重参数化为 $z = \mu + \sigma \odot \epsilon$,将随机样本 $\epsilon \sim N(0, I)$ 移至输入层, I 为单位矩阵,训练时梯度可由 μ 和 σ 反向传播。并且,所得 z 的新表示形式中添加了一部分高斯噪声,使解码器在解码时对噪声更具鲁棒性。VAE 通过最小化式(2)中的损失函数^[21]训练网络。

$$L = E_{z \sim q_{\phi}(z|x)} [\log p_{\theta}(y|z)] -$$

$$\beta D_{KL}[q_{\phi}(z|x) \parallel p_{\theta}(z)] \quad (2)$$

式中:第1项表示目标序列的重构误差,反映模型重构序列的准确性;第2项作为正则化项,以最小化的 Kullback-Leibler (KL) 散度约束编码器 $q_{\phi}(z|x) \sim N(\mu, \sigma^2)$ 逼近隐变量 z 的先验分布 $p_{\theta}(z) \sim N(0, I)$,防止噪声在后续采样生成序列时趋于0,确保模型具有生成能力; β 为超参数,用于平衡 VAE 的重构误差与正则化项。

2.2 改进通道注意力机制

卷积神经网络在特征提取过程中会生成大量通道信息,而有效利用这些信息对提升模型性能至关重要。通道注意力机制为各通道赋予权重,突出关键信息并抑制冗余噪声,从而提高特征提取的精度。

然而,传统的 ECA^[23] 在处理复杂信号特征时存在不足,其仅基于全局平均池化(global average pooling, GAP)获取全局信息,易导致显著特征捕获不足。此外,其自适应卷积核尺寸的选择有限,且直接作用于全部通道,往往存在信息噪声干扰的问题,难以全面捕捉复杂特征。压缩-激励网络^[24-25](squeeze-excitation net, SENet)基于多层感知机(multi-layer perceptron, MLP)的压缩-重构机制,先将输入特征压缩至低维,再进行重构,能够在降低维度的同时

筛选出更关键的通道信息。但 SENet 本身的模型复杂度较高,不易直接迁移。鉴于此,借助压缩-重构的核心思想,提出改进 ECA,在自适应卷积操作前引入人类策略,以进一步优化 VAE 模型在空调负荷辨识任务中的性能。

如图 3 所示,所提改进 ECA 结合 GAP 和全局最大池化(global maximum pooling, GMP),从不同视角更全面地捕获特征图的整体统计信息和局部显著特征,使模型深入理解输入特征,生成更精确的通道注意力。




图 3 改进 ECA 结构

Fig. 3 Structure of improved ECA

通道注意力权重 $M(F)$ 的计算过程可表达如式(3)所示。

$$M(F) = \sigma(SN(\text{AvgPool}(F)) + SN(\text{MaxPool}(F))) = \sigma(SN(F_{\text{avg}}) + SN(F_{\text{max}})) = \sigma(F'_{\text{avg}} + F'_{\text{max}}) \quad (3)$$

式中: σ 为 Sigmoid 函数; F 为输入特征图。AvgPool(\cdot) 和 MaxPool(\cdot) 分别表示 GAP 和 GMP, $SN(\cdot)$ 表示共享参数网络^[26]。共享参数网络 $SN(\cdot)$ 借助 MLP 构建,在保证高效捕获局部通道交互信息的同时,减少参数量和计算复杂度,网络由两层 1×1 卷积和一层快速动态卷积构成,计算表达式如式(4)所示。

$$\begin{cases} SN(F_{\text{avg}}) = W_1(C1D_k(W_0(F_{\text{avg}}))) \\ SN(F_{\text{max}}) = W_1(C1D_k(W_0(F_{\text{max}}))) \end{cases} \quad (4)$$

式中: $W_0 \in \mathbf{R}^{C/r \times C \times 1}$ 和 $W_1 \in \mathbf{R}^{C \times C/r \times 1}$ 为两个 1×1 卷积核的权重,分别用于降维和升维,既压缩冗余信息,又降低参数和计算开销,有助于去除噪声并突出关键特征; r 为缩减比例; $C1D_k(\cdot)$ 表示快速动态卷积操作,在降维后的特征上捕捉局部通道间细粒度依赖。

快速动态卷积的卷积核大小 k 采用式(5)中的自适应函数来确定。

$$k = \psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (5)$$

式中: γ 和 b 是用于控制卷积核大小的超参数; C 是通道数; $\lfloor \cdot \rfloor_{\text{odd}}$ 表示 k 取最接近的奇数,确保在高通道数下对应较大感受野,而在低通道数下可细致捕捉局部依赖。

2.3 多任务学习

当前,许多 NILM 方法仍采用单任务学习进行建模^[14],这种方法往往只关注单一任务,容易忽略其他有

助于特征提取的互补信息,并且对噪声十分敏感。多任务学习^[27](multi-task learning, MTL)是一种通过联合训练多个关联任务以提升模型性能的机器学习范式。与传统单任务独立建模不同,MTL 凭借参数共享机制使不同任务共享底层网络特征^[28],从而增强模型的泛化性能与抗干扰能力。

第 1 章探讨的空调负荷辨识问题涉及功率分解和状态判别两大任务。前者目标是从总负荷中解耦出空调功率值,后者则通过分析功率信号的阈值特征对启停状态进行分类。两任务内在耦合,功率回归结果可为状态判别提供阈值依据,而状态判别又能约束噪声干扰,提升功率预测的准确性。由于状态判别仅需捕捉空调启停特征,其模型复杂度显著低于功率分解,因此借助 MTL 框架将状态判别的特征知识迁移至功率分解,可有效提升后者的分解精度。为充分利用该互补效应,在 VAE 模型中引入双任务输出分支,共享编-解码器以捕捉负荷的共性特征,并设计任务特定的损失函数分别适应功率回归与状态分类的差异化需求。多任务优化损失函数表达式如式(6)所示。

$$\min \sum_{k=1}^K w_k L_k(y_k, \hat{y}_k) \quad (6)$$

式中: w_k 代表任务权重; $L_k(\cdot)$ 表示第 k 个任务的损失函数; y_k 与 \hat{y}_k 分别为第 k 个任务的预测值与真实值。

2.4 居民空调负荷辨识模型设计

本研究提出一种基于 VAE 框架和改进 ECA 的居民空调负荷辨识神经网络模型,该模型采用 U 形网络(UNet)结构,整个网络由 3 部分组成,如图 4 所示,其包含编码器、解码器和输出模块。

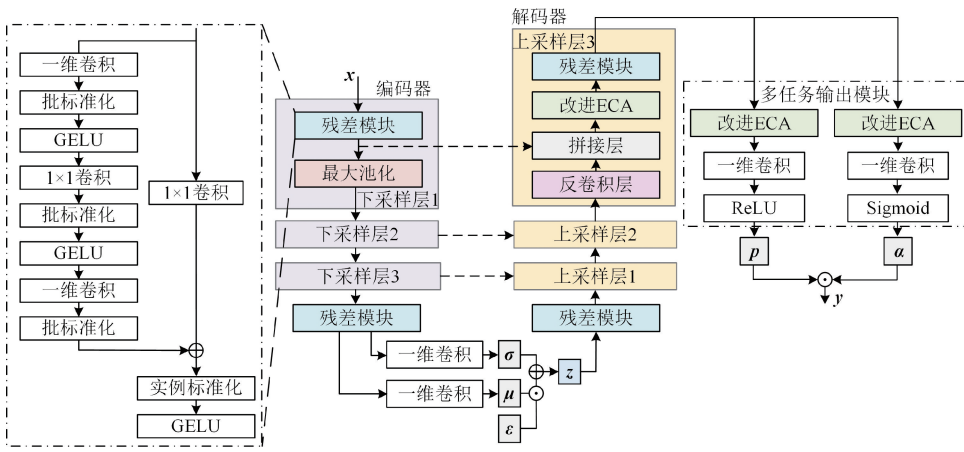


图 4 基于 VAE 和改进 ECA 的空调负荷辨识模型

Fig. 4 Air conditioning load identification model based on VAE and improved ECA

模型通过编码器提取潜在特征并映射至隐空间,解码器基于隐变量 z 重构空调功率序列,最终通过双分支输出模块同步生成预测空调功率 p 和启停状态概率 α 。模型的输入是包含 W 个时间步长的总功率序列 x ,序列通过滑动窗口获得。每个输入序列 $x = [x_1, x_2, \dots, x_w]$ 由模型处理以生成空调的功率序列 $y = [y_1, y_2, \dots, y_w]$ 。

本研究提出的网络模型由残差模块^[29]搭建,所选残差模块由 3 个连续的卷积层结合批标准化、实例标准化和高斯误差线性单元 (gaussian error linear units, GELU) 激活函数组成。如图 4 左侧所示,其中,批标准化增强特征判别性以优化隐空间映射,实例标准化抑制设备功率波动噪声以提升模型泛化能力。残差连接以 1×1 卷积自适应调整通道数,将残差模块输入连接到实例标准化层,在训练过程中促进梯度贯穿整个模型,防止了梯度消失问题。

编码器包含 3 个由残差模块和最大池化组成的下采样层。每经过一次下采样,时间维度降低一倍。经过 3 次下采样后,原始时间序列被压缩为高维抽象特征,并由一维卷积生成隐变量 z 的分布参数 μ 与 σ 传入隐空间。 z 、 μ 、 σ 和 ϵ 形状均为隐空间维度 d 。

解码器包含 3 个由反卷积层、跨层特征拼接层、改进 ECA 层和残差模块组成的上采样层。反卷积层恢复时序细节以捕捉空调功率的局部波动特征,跨层拼接层融合编码器浅层特征与解码器深层特征,实现多尺度上下文信息互补。改进 ECA 层通过动态校准特征通道权重,增强对空调启停瞬态特征的敏感性,从而提升重构精度。解码器输出特征由多任务输出模块并行处理,负荷分解分支通过改进 ECA 层与修正线性单元 (rectified linear unit, ReLU) 激活函数的一维卷积输出连续功率值 p ,状态识别分支则采用相同架构但激活函数为 Sigmoid 的一维卷积,输出表征空调启停状态的二值概率 α 。

为提升状态识别模块输出结果的合理性,采用阈值约束与后处理融合策略。首先设置低判定阈值,将状态识别模块输出的连续概率值 α 转换为 0~1 序列,当 α 超过阈值时判定空调为开启状态,否则标记为关闭,避免因概率波动导致非工作时段误判为运行状态。在此基础上,设计后处理操作将状态序列 α 与负荷分解模块输出的功率序列 p 进行点乘,强制空调关闭时段的功率预测值归 0,抑制虚假开启片段对负荷分解结果的干扰。因此,参照文献[30],定义状态识别模块最输出序列 α 的任一元素 α_i 如式(7)所示。

$$\alpha_i = \begin{cases} 0, & \alpha_i < 0.3 \\ 1, & \alpha_i \geq 0.3 \end{cases} \quad (7)$$

状态识别模块的二值化输出不仅为功率预测提供物理逻辑约束,还可通过多任务损失函数联合优化机制同步提升模型性能。

另外,本研究模型采用全卷积架构,仅由卷积、池化及反卷积层构成。输出模块以单滤波器一维卷积取代传统全连接层,通过局部感受野的权重共享机制,有效压缩参数规模与计算量。这种设计既降低算力门槛,又规避全连接层高维矩阵运算的部署限制,更适配边缘计算等资源受限场景。

2.5 损失函数

本研究模型采用多任务联合训练策略,以复合损失函数同步优化居民空调负荷辨识精度与隐空间分布。针对功率分解任务的回归特性,以均方根误差 (mean square error, MSE) 作为损失函数,最小化空调功率预测值与真实值的偏差;状态识别任务则采用二元交叉熵损失,优化启停状态分类边界;为约束编码器生成隐变量 z 的分布特性,引入 KL 散度正则项,以描述编码器学习的真实数据分布与标准正态分布间的差距,从而提升特征解耦能力与模型鲁棒性。综上,本文模型的多任务损失函数

L_{total} 如式(8)~(12)所示。

$$L_{\text{total}} = L_1 + L_2 + L_3 + L_4 \quad (8)$$

$$L_1 = \frac{1}{T} \sum_{i=1}^T (p_i - \hat{p}_i)^2 \quad (9)$$

$$L_2 = -\frac{1}{2} \sum_{j=1}^d (1 + \log(\sigma_j^2) - \mu_j^2 - \sigma_j^2) \quad (10)$$

$$L_3 = -\frac{1}{T} \sum_{i=1}^T [\alpha_i \ln \hat{\alpha}_i + (1 - \alpha_i) \ln(1 - \hat{\alpha}_i)] \quad (11)$$

$$L_4 = \frac{1}{T} \sum_{i=1}^T (y_i - \hat{y}_i)^2 \quad (12)$$

式中: $\hat{\alpha}_i$ 和 α_i 分别表示空调的真实开断状态与模型状态识别的输出值; \hat{y}_i 和 y_i 分别表示空调功率的真实值与模型最终输出的空调功率值; d 为隐空间的维度。

3 实验准备

3.1 数据集

目前国内尚未有开放获取的居民空调用电数据集,因此,模型选用美国 Pecan Street 机构提供的真实电力数据集进行训练与测试^[20],该数据集来源于 Pecan Street 网站(<https://www.pecanstreet.org/>) dataport 平台。数据集包含 44 户用户的空调功率和智能电表数据,采样频率 1 min,时间跨度 4 年。用户分别来自美国 3 个地区,数据集还包括家庭住宅区域和建筑类型的信息。为验证模型的准确性和鲁棒性,分别从 3 个地区选取不同房屋类型和不同空调类型的 13 户用户作为少量侵入式用户,将此 13 户数据作为训练集,在剩余 31 户用户数据上分别测试模型性能。

3.2 评价指标

针对模型多任务输出的异构性,性能评估需采用适配任务特性的综合评价指标。功率分解任务以平均绝对误差(mean absolute error, MAE)与信号聚合偏差(signal aggregate error, SAE)为核心评估指标。在家庭电器中,空调被认为是高能耗设备,因此,准确评估空调的电能消耗有益于 DR。NILM 领域内 SAE 指标常用于比较预测电器和真实电器之间的电量误差。二者数值越小代表性能越好,表达式分别为式(13)与(14)。

$$MAE = \frac{1}{T} \sum_{i=1}^T |y_i - \hat{y}_i| \quad (13)$$

$$SAE = \frac{\left| \sum_{i=1}^T y_i - \sum_{i=1}^T \hat{y}_i \right|}{\sum_{i=1}^T y_i} \quad (14)$$

针对空调状态识别任务,选取 $F1$ (F1-Score) 指标评价,其值越高代表状态识别越准确,如式(15)所示。

$$F1 = \frac{2PR}{P + R} \times 100\% \quad (15)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (16)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (17)$$

式中: P 为整体查准率; R 为整体召回率; N_{TP} 表示预测开启且实际开启的样本数; N_{FP} 表示预测开启但实际关闭的样本数; N_{FN} 表示预测关闭但实际开启的样本数; N_{TN} 预测关闭且实际关闭的样本数。准确率(accuracy, ACC)作为经典的二分类评价指标,其表达式为式(18)。

$$ACC = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{FN} + N_{TN}} \quad (18)$$

3.3 训练设置

模型训练采用 RMSprop 优化器,总训练轮次设为 100。学习率初始值设置为 0.001,并采用线性衰减策略,每 10 个训练周期将学习率降低为当前值的 90%,以平衡训练初期快速收敛与后期参数稳定性。为降低随机权重初始化及数据划分对结果的影响,每组实验重复独立训练 5 次,最终结果取 5 次结果的算术平均值,确保结论的统计显著性。为防止模型发生过拟合,设置早停机制以获取训练最优的模型。本研究模型涉及的关键超参数如表 1 所示,其中一维卷积核大小是综合考虑模型特征提取能力和计算复杂度选取的^[31]。

表 1 本文模型超参数设置

Table 1 Hyperparameter settings of the proposed model

名称	参数
批次大小	64
残差模块	3 次卷积操作的卷积核数量: 64、64、256
一维卷积	核大小: 3
滑动窗口	尺寸: 128; 步长: 32
改进 ECA	$\gamma: 2; b: 1$
隐空间维度	$d: 16$
早停机制	容忍迭代轮次: 10; 早停开始轮次: 5

4 算例分析

4.1 综合实验结果分析

为突出所提出模型的优越性,复现了先进的 AAE (adversarial autoencoder)^[14]、TransUnet^[32]作为对比模型,表 2~4 分别展示了本研究模型和对比模型在 3 个地区不同用户中的测试结果,表中粗体代表模型性能最优值。

本研究模型在地区 2 的用户中总体测试结果最优, MAE 均值为 7.95 W 且 $F1$ 均值高达 96.78%,体现了本研究模型在复杂居民空调用电场景下的功率分解精度

表 2 不同模型在地区 1 的测试结果

Table 2 Test results of different models in region 1

用户 编号	开断 比例	TransUnet			AAE			本文模型		
		MAE/W	F1/%	SAE	MAE/W	F1/%	SAE	MAE/W	F1/%	SAE
1417	0.06	66.14±12.55	86.12±1.68	0.287±0.150	9.77±1.94	96.90±2.09	0.042±0.015	11.17±0.62	98.85±0.46	0.069±0.014
27	0.12	235.21±7.39	28.28±1.37	0.322±0.143	147.25±11.79	32.81±13.61	0.777±0.095	198.16±5.19	10.00±1.63	0.781±0.046
3000	0.02	196.23±13.45	30.84±0.49	2.816±0.439	119.25±8.62	43.05±1.06	1.737±0.168	136.33±6.18	40.66±0.87	2.065±0.109
3517	0.04	142.08±12.19	45.29±1.04	1.972±0.285	112.58±9.76	43.52±2.07	1.703±0.157	43.78±13.85	66.76±7.67	0.253±0.262
5058	0.05	148.38±11.08	15.01±1.29	0.585±0.231	128.57±12.53	28.73±1.38	0.719±0.235	92.43±9.72	7.57±1.07	0.364±0.162
5587	0.30	159.13±7.66	87.56±1.04	0.028±0.022	132.01±9.23	83.90±1.16	0.255±0.034	134.45±15.61	84.94±3.09	0.292±0.080
均值	0.10	157.86±10.72	48.85±1.15	1.002±0.212	108.24±8.98	54.82±3.56	0.872±0.117	102.72±8.53	51.46±2.47	0.637±0.112

表 3 不同模型在地区 2 测试结果

Table 3 Test results of different models in region 2

用户 编号	开断 比例	TransUnet			AAE			本文模型		
		MAE/W	F1/%	SAE	MAE/W	F1/%	SAE	MAE/W	F1/%	SAE
1524	0.05	89.09±15.04	77.54±3.28	0.129±0.097	19.10±3.60	96.61±0.57	0.036±0.018	20.63±1.56	97.19±0.42	0.077±0.023
1731	0.04	63.23±14.14	86.76±2.44	0.179±0.197	9.57±0.77	97.67±0.44	0.096±0.008	5.96±0.86	98.03±0.53	0.034±0.005
3687	0.06	81.79±11.27	87.50±1.57	0.109±0.054	20.35±0.77	95.95±0.54	0.099±0.010	20.92±1.97	96.94±0.60	0.053±0.017
3938	0.01	43.242±12.48	89.98±2.14	1.648±1.078	1.15±0.05	98.39±0.16	0.012±0.007	2.44±0.39	95.79±1.25	0.089±0.032
4495	0.001	39.04±12.73	42.10±3.35	27.393±16.074	0.23±0.08	89.86±6.69	0.057±0.045	0.33±0.06	87.25±4.36	0.091±0.072
5938	0.001	37.84±15.14	81.77±2.09	6.289±4.540	0.82±0.04	98.41±0.48	0.169±0.010	0.55±0.09	96.83±1.35	0.098±0.018
7114	0.05	57.65±14.79	92.29±2.37	0.184±0.149	5.83±0.96	99.40±0.19	0.036±0.008	4.17±0.35	99.22±0.11	0.010±0.005
8061	0.03	59.77±13.92	81.41±1.85	0.325±0.286	6.69±1.26	96.89±0.95	0.055±0.005	5.14±0.80	96.51±0.97	0.014±0.010
8342	0.07	61.85±17.90	95.01±2.83	0.127±0.118	10.80±1.32	97.87±0.65	0.035±0.006	8.29±0.80	99.70±0.04	0.037±0.009
8574	0.02	49.76±11.06	86.63±1.94	0.355±0.322	3.71±0.00	98.66±0.13	0.040±0.007	4.47±0.20	97.33±0.52	0.021±0.009
8733	0.08	79.16±9.13	87.54±2.05	0.082±0.056	10.58±0.56	98.34±0.20	0.033±0.003	12.03±0.58	98.03±0.30	0.009±0.005
9612	0.11	95.63±13.71	89.16±3.60	0.089±0.055	15.31±1.17	98.59±0.10	0.053±0.006	10.47±0.85	98.55±0.12	0.022±0.008
均值	0.04	63.19±13.44	83.14±2.46	3.076±1.919	8.68±0.88	97.22±0.93	0.060±0.011	7.95±0.71	96.78±0.88	0.046±0.018

与状态识别鲁棒性。并且,本研究模型在大部分用户中 F1 指标均值均达到 90% 以上,所有用户测试结果的 MAE 平均值达到 66.19 W,SAE 平均值达到 0.181,性能整体优于 TransUnet 模型和 AAE 模型。这是因为采用的 VAE 框架通过潜在空间解耦约束,有效分离负荷数据的稳态特征与瞬态噪声,解决特征耦合导致的模式混淆问题;其次,改进 ECA 结合多尺度池化与共享网络中的特征降维和动态卷积核,通过跨关键通道交互优化使非稳态负荷关键特征识别准确率提升;同时,MTL 框架借助负荷分解与状态识别的双向引导机制,在仅有少量标注数据时即可实现物理约束的特征解耦。

在评价指标层面,MAE 反映预测波形与真实波形的逐点差异,SAE 表征总量偏差。实验发现,部分用户如用户 5587,本研究模型的 SAE 和 MAE 均值分别为 0.292、134.45 W,而 TransUnet 测试结果为 0.028、159.13 W,在 SAE 较低的情况下 MAE 反而较高,表明 SAE 低值可能源

于正负误差抵消效应,需结合 MAE 综合判断曲线贴合度。此外,空调开关事件中存在显著的类别不平衡问题,在此情况下,ACC 指标可能会产生误导性结果。以用户 3517、3000 和 3938 为例,空调开断比例分别占 0.04、0.02 和 0.01,是由于负样本数量占比过大,且导致了传统 ACC 指标较高,分别为 0.975、0.935 和 0.998。相较之下,本研究模型的 F1 均值分别为 66.76%、40.66% 和 95.79%,更能准确反映模型在类别不平衡条件下的性能。因此,ACC 指标并不能充分体现算法在处理类别不平衡数据时的表现,F1 指标则提供了更精确的评估。

针对具体用户测试案例,本研究模型在用户 7114 和 2818 上表现较好,F1 值高达 99%,并且在大部分用户中能够保持在 90% 以上,这表明本研究模型能够精准提取用户空调的状态。模型在用户 7951 和 9922 上测试结果明显比其他用户差,这是因为这 2 个用户都装设了超过 2 台空调,有多台同种空调设备导致模型难以分解 2 台

表4 不同模型在地区3的测试结果

Table 4 Test results of different models in region 3

用户编号	开断比例	TransUnet			AAE			本文模型		
		MAE/W	F1/%	SAE	MAE/W	F1/%	SAE	MAE/W	F1/%	SAE
1642	0.20	195.45±11.16	78.34±1.45	0.140±0.041	47.16±1.87	95.05±0.44	0.006±0.002	56.77±7.15	92.59±1.18	0.071±0.018
2335	0.19	199.66±12.19	84.99±1.24	0.138±0.029	78.20±9.76	95.53±1.33	0.124±0.012	40.49±5.23	98.43±0.35	0.048±0.019
2818	0.39	131.99±19.32	92.72±1.64	0.058±0.027	28.88±0.93	99.44±0.14	0.027±0.002	36.96±6.00	99.52±0.06	0.022±0.012
3039	0.39	347.83±19.88	77.59±1.35	0.029±0.019	194.92±13.81	90.73±0.44	0.117±0.014	128.47±14.78	94.11±1.57	0.035±0.014
3538	0.15	94.85±12.85	90.76±2.75	0.164±0.073	14.42±1.08	98.26±0.40	0.042±0.005	17.11±2.03	98.78±0.10	0.053±0.009
5746	0.21	105.86±15.26	93.51±1.56	0.032±0.018	35.38±2.35	98.26±0.26	0.062±0.006	24.73±1.88	98.99±0.16	0.047±0.007
6139	0.15	245.32±10.89	68.93±0.75	0.069±0.030	131.43±24.34	84.89±2.61	0.171±0.070	204.76±24.98	81.29±2.61	0.270±0.080
661	0.26	173.33±10.87	84.66±1.06	0.174±0.035	41.97±1.05	96.82±0.22	0.031±0.010	48.10±5.55	95.40±0.94	0.054±0.019
7719	0.26	323.91±25.45	70.89±1.27	0.070±0.025	84.22±7.76	88.36±1.87	0.074±0.011	77.76±10.40	92.47±1.19	0.041±0.014
7951	0.12	309.17±19.21	57.01±1.61	0.897±0.188	157.34±5.05	74.03±1.36	0.435±0.032	147.03±4.64	76.36±0.87	0.404±0.037
8386	0.09	104.91±10.77	82.59±2.08	0.108±0.079	23.19±1.35	95.65±0.48	0.035±0.002	17.10±1.38	96.22±0.62	0.014±0.006
9019	0.15	100.66±12.87	88.48±1.77	0.077±0.071	21.64±1.05	98.12±0.14	0.053±0.006	20.93±3.11	98.06±0.34	0.033±0.021
9922	0.09	768.61±26.77	28.24±0.48	1.238±0.106	703.93±29.23	15.26±2.23	0.370±0.064	519.83±48.20	29.59±3.42	0.144±0.061
均值	0.20	238.58±15.96	76.82±1.46	0.246±0.057	120.21±7.66	86.95±0.92	0.119±0.018	103.08±10.41	88.60±1.03	0.095±0.024

目标空调的功率序列。另外,用户 27、5058 和 5679 的结果明显比其他用户差。分析发现,这 3 个用户都包含电动汽车充电负荷,与多台空调原因类似,电动汽车相似的

充电功率也掩盖了空调的负荷特性。

图 5 展示了本研究模型与对比模型在具有代表性用户中的空调负荷分解曲线。

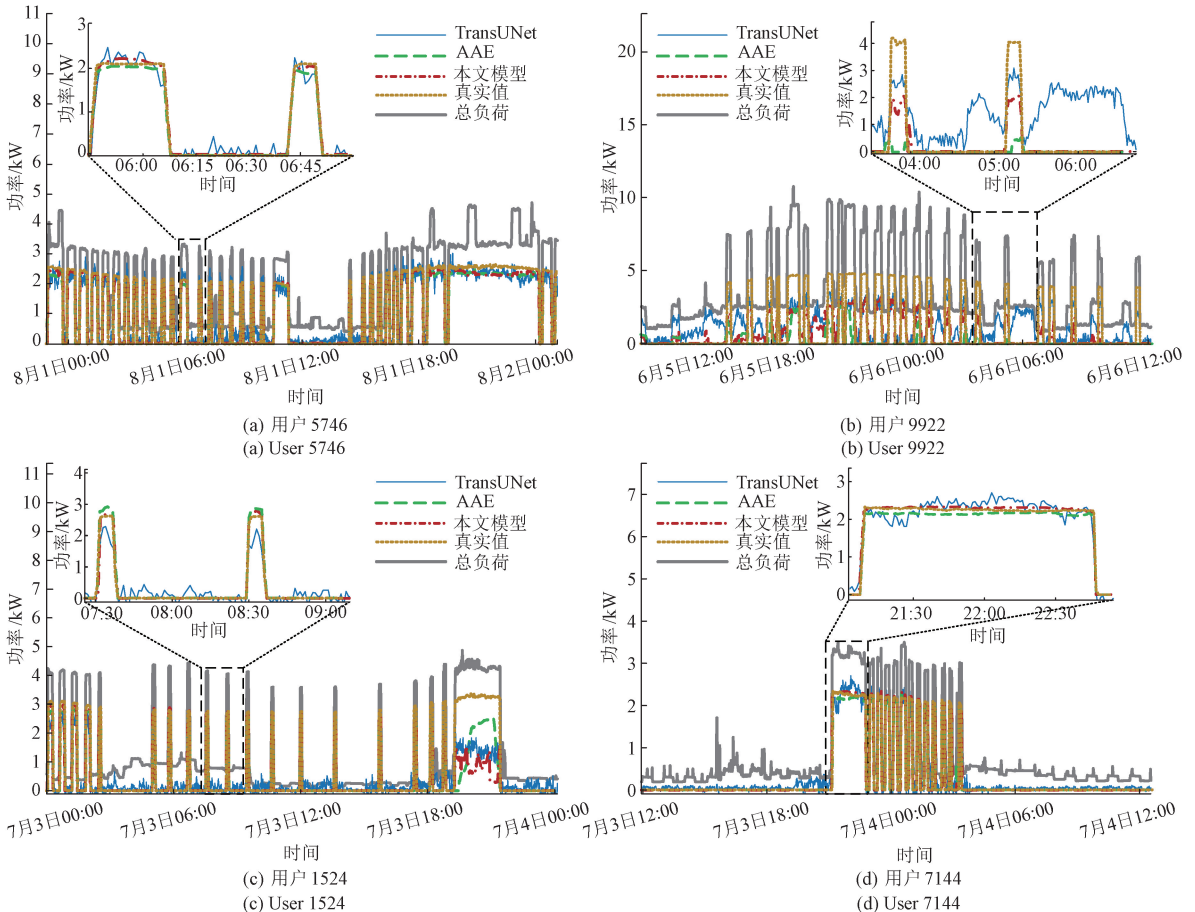


图 5 不同模型在不同用户的空调功率分解曲线

Fig. 5 Air conditioning power decomposition curves of different models across various users

实验表明,相较于对比模型,本研究模型的空调分解值与真实值贴合度更高,更进一步证明本研究模型具有良好的分解精度与泛化能力。TransUNet 模型虽然能辨识出部分用户的空调状态,例如在用户 7114 测试, $F1$ 均值达到 92.29%,但是 TransUNet 模型的空调分解功率性能整体低于 AAE 和本研究模型,与真实值差距较大。AAE 模型性能虽有部分优于本研究模型,但是 AAE 由于

缺乏通道注意力,其对空调负荷显著特征重构能力不强,导致在 5 次实验中失效了 2 次,即模型输出全为 0,而本研究模型在改进 ECA 的加持下,对捕获空调负荷关键暂态特征更加敏感,5 轮次实验均未失效,具有较强的鲁棒性能。

图 6 进一步展示了不同模型对于定频空调和变频空调的空调功率辨识结果以及空调用电量变化。

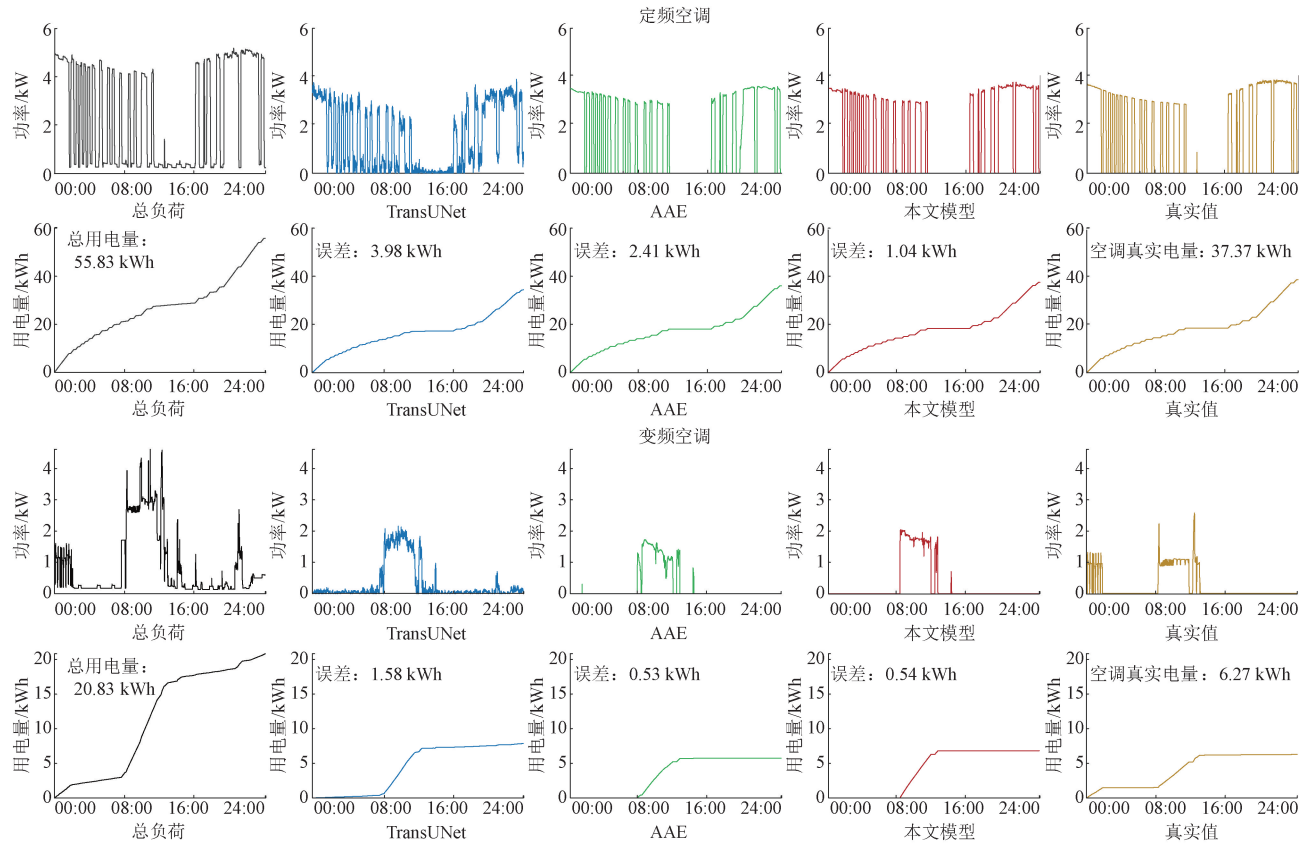


图 6 不同模型辨识的变频空调与定频空调功率曲线与用电量曲线

Fig. 6 Power and energy consumption curves of variable-frequency and fixed-frequency air conditioners identified by different models

分析可知,本研究模型对定频空调的辨识效果要优于变频空调,这是因为,定频空调的功率曲线开断状态明显且较为平滑,而变频空调的运行状态较为复杂,不易被模型感知。但是相较对比模型,本研究模型对变频空调的能耗误差评估是较优的。

结合图 5 和 6 不难发现,空调关机状态比例较高的居民的总负荷普遍较低,空调关机状态比例较低的居民的总负荷普遍较高,印证了空调作为高能耗设备对居民总负荷的显著影响。

图 7 展示了本研究模型的不同居民空调状态辨识结果的 $F1$ 值的频数分布和概率密度分布。从图中可以看出, $F1$ 的平均值为 84.58%,所有 $F1$ 值主要分布在 85%~100%,这表明,提出的居民空调状态辨识模型具有一定准确性和鲁棒性。




图 7 空调状态辨识结果的 $F1$ 值的分布
Fig. 7 Distribution of $F1$ -scores for air conditioner state identification results

4.2 消融实验

为验证模型核心组件的有效性,设计消融实验对比基准模型与完整模型的性能差异,其中基准模型由残差模块和

UNet 组成,实验分别对 ECA、改进 ECA 和 MTL 这 3 个组件进行消融分析,以评估每个组件对模型性能的影响。实验结果如表 5 所示(其中加粗为最优值,下划线为次优值)。

表 5 模型结构消融实验结果

Table 5 Ablation experiment results on model structures

基准模型	ECA	改进 ECA	MTL	地区 1			地区 2			地区 3		
				MAE/W	F1/%	提升值/%	MAE/W	F1/%	提升值/%	MAE/W	F1/%	提升值/%
✓	—	—	—	103.43±10.91	47.34±7.24	0.00/0.00	19.58±10.25	91.91±5.66	0.00/0.00	126.27±37.82	<u>88.71±2.71</u>	0.00/0.00
✓	✓	—	—	98.86±7.80	<u>52.38±2.22</u>	4.42/10.64	10.18±1.98	96.13±1.07	48.01/4.59	121.50±10.44	87.77±0.86	3.78/-0.01
✓	—	✓	—	103.68±13.38	52.41±3.66	-0.24/10.70	<u>8.57±1.59</u>	<u>96.73±1.02</u>	56.23/5.24	<u>110.52±15.16</u>	88.35±1.51	12.47/-0.01
✓	✓	—	✓	109.07±13.55	51.35±3.74	-5.45/8.47	10.21±1.98	95.50±0.97	47.85/3.91	125.05±17.98	87.10±1.44	0.01/-0.02
✓	—	✓	✓	<u>102.72±8.53</u>	51.46±2.47	0.69/8.70	7.95±0.71	96.78±0.88	59.40/5.27	103.08±10.41	88.60±1.03	18.37/-0.01

注:采用“/”分隔不同地区不同组件的 MAE 和 F1 百分比提升值

实验结果表明,在仅拥有残差模块与 UNet 相结合的基准模型时,其依然能够较好地完成居民空调负荷辨识任务,在各评价指标上的表现均高于本研究所对比的 TransUNet 模型,这也进一步说明了本研究所提模型的有效性。

由表 5 可知,在基准模型的基础上增加 ECA 之后,模型整体在 MAE 指标和 F1 均略有提升,增加改进 ECA 后,模型性能显著提升,在 MAE 指标上地区 2 和 3 分别提升了 8.22% 和 8.69%,这得益于改进 ECA 通过 GAP-GMP 双池化融合策略同步捕获全局统计特征与局部显著性响应,配合动态卷积核的自适应通道交互机制,有效强化了空调启停瞬态特征的权重分配,这也与前文理论分析一致。在上述基础上增加 MTL 后,在地区 2 的 MAE 指标均值进一步从 8.57 降低到 7.95,这表明,相较于单任务学习,MTL 利用状态识别任务的特征信息来提升空调负荷分解的性能,对于辨识具有明显启停特征的空调负荷非常有利。由于空调负荷正负样本存在极不平衡的现象,即使采用随机降采样方法^[19],基准模型仍出现失效情况,即分解值全为 0,而在采用 ECA 后模型不再失效,体现其具有较好的关键特征提取能力。

4.3 空调用户侵入式测量比例对精度的影响

本研究提出了一种通过监测少量空调用户数据,并采用 NILM 方法提取同地区其他用户空调功率曲线的方案。因此,侵入式测量用户数量在实际场景中是影响算法有效性和普适性的重要因素。本节将评估训练集中不同比例的侵入式测量用户对算法性能的影响。

随机选择全部用户中的不同比例用户作为训练集,分别以 5% 的跨度逐渐增加比例进行实验,每个实验重复 5 次,并取平均值来比较空调状态识别和功率分解方法的性能。实验结果如图 8 所示,随着侵入式测量比例的增加,模型的 MAE 值和 F1 值呈现不同的变化趋势。

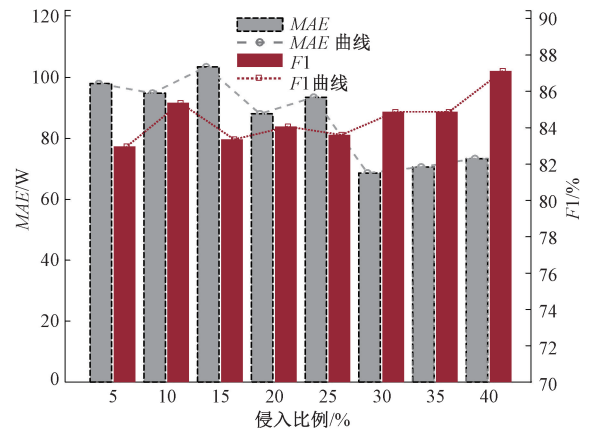


图 8 不同侵入比例下的状态识别精度与重建误差
Fig. 8 State identification accuracy and reconstruction error under varying intrusion ratios

分析图 8 可知,随着侵入比例的增长,模型的重建误差基本呈现下降趋势。随着侵入比例从 5% 增长至 30%,模型的平均预测误差显著下降,在 30% 时达到最低值 66.19 W,而后在 30%~40% 内,模型的预测误差呈现出波动上升的趋势。这表明,30% 的侵入式测量比例已能满足模型的高效训练需求,进一步增加比例精度提升已不明显。总体来看,虽然 F1 值的生长变化不大,但整体保持在较高水平,表明本研究模型在极少侵入比例用户的情况下也具有一定的状态辨识精度和鲁棒性。综上所述,在本文所提少量侵入式方案下,适当比例的侵入式测量能够有效提升模型的居民空调负荷辨识精度。在实际应用中,应根据具体情况选择合适的侵入式测量比例,以确保模型的预测精度和稳定性。

4.4 模型计算复杂度分析

表 6 展示了本研究模型以及对比模型的可训练参数量、训练一轮所需时间、测试时每户居民的平均预测时间以及模型大小。

表6 不同模型的计算资源对比

Table 6 Comparison of computational resources among different models

模型	参数量 /10 ⁶	训练时间 /min	每户平均 预测时间/s	模型大小 /Mb
TransUNet	13.53	6.12	2.58	54.89
AAE	1.82	26.07	2.79	7.13
本文模型	1.99	34.13	7.35	7.93

其中,TransUNet 的训练耗时最低,这是因为此模型是典型的序列到子序列模型^[32],其计算复杂度要显著低于类型为序列到序列模型的 AAE 和本研究模型,但由于序列到子序列模型的输出取中间子序列片段,使得此类模型不具备实时性^[14],因此不利于 DR 中对用户空调负荷的实时监控和管理。

本研究模型和 AAE 可训练参数量相近,均少于 TransUNet,并且本研究模型借助轻量化的改进 ECA 以及多任务共享参数机制,以少量的参数量增长换取较高的性能提升,并且和 AAE 对比平均预测时间差距在 5 s 以内,综合考虑模型精度,本研究模型仍适用于空调负荷辨识任务。

5 结 论

为实现用户级别的非侵入式空调负荷精准辨识,提出了一种通过少量空用户侵入式量测辐射所有用户的方案,结合 VAE 框架和改进 ECA 建立了针对空调负荷的 NILM 神经网络模型。改进 ECA 捕获全局与突出特征,增强了模型对通道相关性的理解。多任务学习框架结合功率分解和状态识别任务,为 VAE 增加输出模块,进一步提升模型性能。输出模块共享编码器与解码器提取的特征,并分别输出空调功率和开断状态,显著提高了模型在空调负荷辨识中的准确性和鲁棒性。

实验结果表明,本研究模型在不同测试区域的 MAE 和 F1 指标均优于对比模型,MAE 平均提升了 59.71% 和 9.22%,特别是在侵入式测量比例达到 30% 时,模型表现最佳,MAE 值最低为 66.19 W,显示出其高效的特征提取和分解能力。消融实验进一步验证了改进 ECA 和多任务学习框架在提升模型性能方面的显著效果。少量侵入式测量方案在保证模型准确性的同时,减少对用户数据的依赖,具有较好的应用潜质。

未来研究将聚焦空调负荷的调控潜力评估,实现更全面的能量管理和低碳减排目标。本研究结果为 NILM 领域提供了新的思路和参考,并为智能电网中的空调负荷辨识和调控提供了有力支持。

参考文献

- [1] 董昱,孙大雁,许丹,等. 新型电力系统电力电量平衡的挑战、应对与展望[J]. 中国电机工程学报,2025,45(6): 2039-2057.
DONG Y, SUN D Y, XU D, et al. Challenges, solutions and prospects of power-energy balance in new power systems[J]. Proceedings of the CSEE, 2025, 45(6): 2039-2057.
- [2] 刘伟峰,范帅,田济源,等. 面向需求响应的空调智能体:概念、构建和应用[J]. 电力系统自动化,2024,48(22): 70-83.
LIU W F, FAN SH, TIAN J Y, et al. Air conditioner intelligent agents for demand response: Concept, construction and application[J]. Automation of Electric Power Systems, 2024, 48(22): 70-83.
- [3] 刘广生,李成鑫,侯治吉,等. 计及用户舒适度的空调负荷可调节能力评估及响应策略[J]. 电力系统自动化,2023,47(21): 58-66.
LIU G SH, LI CH X, HOU ZH J, et al. Evaluation of adjustable capacity and response strategy for air conditioning load considering comfort of customers[J]. Automation of Electric Power Systems, 2023, 47(21): 58-66.
- [4] CHEN Y B, XU P, CHEN ZH, et al. Experimental investigation of demand response potential of buildings: Combined passive thermal mass and active storage[J]. Applied Energy, 2020, 280: 115956.
- [5] 周特,周意,王帅,等. 变频温控负荷参与电力系统调频的综合惯量支撑技术评述[J/OL]. 中国电机工程学报,1-26[2025-01-13].
ZHOU T, ZHOU Y, WANG SH, et al. Review on synthetic inertia support of inverter-based thermostatically controlled loads participating in power system frequency regulation [J/OL]. Proceedings of the CSEE, 1-26 [2025-01-13].
- [6] 李天阳,赵兴旺,肖文学. 面向峰谷平衡的商业楼宇空调负荷调控技术[J]. 电力系统自动化,2015,39(17): 96-102.
LI T Y, ZHAO X W, XIAO W J. Regulation technology of air-conditioning load in commercial buildings for balance of power grid peak and valley[J]. Automation of Electric Power Systems, 2015, 39(17): 96-102.
- [7] 王瑞妙,姚欣思,赵小娟,等. 考虑温度和负荷相关性的重庆冬季空调负荷计算[J]. 电力科学与技术学报,2021,36(6): 157-163.
WANG R M, YAO X Y, ZHAO X J, et al. Calculation of Chongqing winter air conditioning load considering the correlation between temperature and load[J]. Journal of

- Electric Power Science and Technology, 2021, 36(6): 157-163.
- [8] 包宇庆, 成丽珉. 空调负荷二阶等效热参数模型参数辨识方法[J]. 电力系统自动化, 2021, 45(11): 37-43.
BAO Y Q, CHENG L M. Parameter identification method for second-order equivalent thermal parameter model of air conditioning load[J]. Automation of Electric Power Systems, 2021, 45(11): 37-43.
- [9] 龙寰, 赵烁, 吴志, 等. 考虑反弹效应的空调负荷可调潜力评估与控制策略研究[J]. 电网技术, 2023, 47(9): 3638-3648.
LONG H, ZHAO SH, WU ZH, et al. Adjustable potential evaluation and control strategy of air conditioning load considering rebound effect [J]. Power System Technology, 2023, 47(9): 3638-3648.
- [10] 李占培, 刘廷章, 张颖婷. 基于频域分解的房间冷负荷建模及软测量技术[J]. 仪器仪表学报, 2015, 36(5): 1031-1038.
LI ZH P, LIU T ZH, ZHANG Y Q. Modeling and soft sensing for room cooling load based on frequency domain decomposition[J]. Chinese Journal of Scientific Instrument, 2015, 36(5): 1031-1038.
- [11] 吴承鑫, 沈海军, 王治华, 等. 数据驱动的变频空调负荷模型参数在线辨识方法[J]. 电力系统自动化, 2022, 46(1): 120-129.
WU CH X, SHEN H J, WANG ZH H, et al. Data-driven online identification method for parameters of inverter air-conditioning load model[J]. Automation of Electric Power Systems, 2022, 46(1): 120-129.
- [12] SONG ZH F, SHI J, LI SH J, et al. Data-driven and physical model-based evaluation method for the achievable demand response potential of residential consumers' air conditioning loads[J]. Applied Energy, 2022, 307: 118017.
- [13] XIONG J, HONG T Q, ZHAO D B, et al. MATNilm: Multi-appliance-task non-intrusive load monitoring with limited labeled data[J]. IEEE Transactions on Industrial Informatics, 2023, 20(3): 3177-3187.
- [14] ÇIMEN H, WU Y, WU Y P, et al. Deep learning-based probabilistic autoencoder for residential energy disaggregation: An adversarial approach [J]. IEEE Transactions on Industrial Informatics, 2022, 18(12): 8399-8408.
- [15] 陈军锋, 王雪, 张效天. 非侵入式负荷识别边缘计算颜色编码研究[J]. 仪器仪表学报, 2020, 41(9): 12-19.
CHEN J F, WANG X, ZHANG X T. Non-intrusive load recognition using color encoding in edge computing[J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 12-19.
- [16] 吴昭. 面向智能用电的非侵入式负荷分解关键技术研究[D]. 重庆: 重庆大学, 2022.
WU ZH. Study on key technologies in non-intrusive load disaggregation for intelligent power utilization [D]. Chongqing: Chongqing University, 2022.
- [17] 徐彤, 刘建宇, 汤立志, 等. 基于三元特征量的非侵入式定频空调辨识研究[J]. 电子测量技术, 2018, 41(3): 69-73.
XU T, LIU J Y, TANG L ZH, et al. Research on non-intrusive identification for fixed-frequency air conditioner based on its ternary features[J]. Electronic Measurement Technology, 2018, 41(3): 69-73.
- [18] 金旭, 张远实, 李明, 等. 考虑热舒适度的居民空调负荷调控潜力差异化评估[J]. 电力系统自动化, 2024, 48(1): 50-58.
JIN X, ZHANG Y SH, LI M, et al. Differentiation evaluation of regulation potential for residential air conditioning load considering thermal comfort [J]. Automation of Electric Power Systems, 2024, 48(1): 50-58.
- [19] 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: 55-64.
- [20] CHEN H W, GUO L Y, BAO W Y, et al. Extraction of high-resolution air conditioning load profiles from low-resolution smart meter: A semi-supervised nonintrusive approach[J]. IEEE Transactions on Industrial Informatics, 2024, 20(6): 8294-8305.
- [21] KINGMA D P, WELING M. Auto-encoding variational bayes[J]. ArXiv preprint arXiv:1312.6114, 2014.
- [22] LANGEVIN A, CARBONNEAU M A, CHERIET M, et al. Energy disaggregation using variational autoencoders[J]. Energy and Buildings, 2022, 254: 111623.
- [23] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11531-11549.
- [24] 王凌云, 李婷宜, 李阳, 等. 基于FEF-DeepLabV3+的电力金具锈蚀分割方法[J]. 电子测量与仪器学报, 2023, 37(7): 166-176.
WANG L Y, LI T Y, LI Y, et al. Segmentation method of power armor clamp corrosion based on FEF-

- DeepLabV3+[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 166-176.
- [25] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [26] CAI Z CH, CHEN L, LIU H L. EPC-DARTS: Efficient partial channel connection for differentiable architecture search[J]. Neural Networks, 2023, 166: 344-353.
- [27] ZHANG Y, YANG Q. A survey on multi-task learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 34(12): 5586-5609.
- [28] 谢平, 胡锦涛, 江国乾, 等. 基于多任务学习的快速序列视觉呈现脑电图分类[J]. 仪器仪表学报, 2023, 44(11): 215-223.
- XIE P, HU J CH, JIANG G Q, et al. Classification of rapid serial visual presentation based EEG with multi-task learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(11): 215-223.
- [29] ZHANG Y SH, QIAN W Y, YE Y J, et al. A novel non-intrusive load monitoring method based on ResNet-seq2seq networks for energy disaggregation of distributed energy resources integrated with residential houses [J]. Applied Energy, 2023, 349: 121703.
- [30] 陈嘉伟, 季天瑶, 梅广, 等. 基于多尺度特征融合与多任务学习框架的非侵入式负荷监测方法[J]. 电网技术, 2024, 48(5): 2074-2083.
- CHEN J W, JI T Y, MEI G, et al. Multi-scale feature fusion and multi-task learning architecture for non-intrusive load monitoring[J]. Power System Technology, 2024, 48(5): 2074-2083.
- [31] 韩林池, 高放, 赵子巍, 等. 基于多尺度卷积与Informer混合模型的非侵入式负荷监测方法[J]. 电力自动化设备, 2024, 44(3): 134-141.
- HAN L CH, GAO F, ZHAO Z W, et al. Non-intrusive load monitoring method based on multi-scale convolution

and Informer hybrid model[J]. Electric Power Automation Equipment, 2024, 44(3): 134-141.

- [32] ZHOU K L, ZHANG ZH Y, LU X H. Non-intrusive load monitoring based on an efficient deep learning model with local feature extraction[J]. IEEE Transactions on Industrial Informatics, 2024, 20(7): 9497-9507.

作者简介



王凌云, 2003年于三峡大学获得学士学位, 2009年于中南大学获得博士学位, 现为三峡大学教授, 主要研究方向为电力系统运行与优化。

E-mail: wly@ctgu.edu.cn

Wang Lingyun received his B. Sc. degree from China Three Gorges University in 2003 and Ph. D. degree from Central South University in 2009, respectively. Now he is a professor at China Three Gorges University. His main research interests include the operation and optimization of power systems.



唐涛(通信作者), 2023年于江苏大学获得学士学位, 现为三峡大学硕士研究生, 主要研究方向为电力负荷监测与需求响应。

E-mail: 2279828510@qq.com

Tang Tao (Corresponding author) received his B. Sc. degree from Jiangsu University in 2023. Now he is a M. Sc. candidate at China Three Gorges University. His main research interests include the power load monitoring and demand response.



阮胜冬, 2003年于三峡大学获得学士学位, 现为国网衢州供电公司高级工程师, 主要研究方向为电力系统运行规划。

E-mail: rsd352@sohu.com

Ruan Shengdong received his B. Sc. degree from China Three Gorges University in 2003. Now he is a senior engineer in State Grid Quzhou Power Supply Company. His main research interest includes the operation and planning of power systems.