

考虑综合需求响应的AGCN-TimeXer综合能源系统 多元负荷短期预测

董家铭¹, 韩兴臣², 张智晟¹

(1. 青岛大学 电气工程学院, 山东 青岛 266071; 2. 国网青岛供电公司, 山东 青岛 266002)

摘要:针对综合能源系统中需求响应机制与多元负荷动态耦合特性,提出一种考虑综合需求响应的自适应卷积网络(adaptive graph convolutional network, AGCN)-TimeXer多元负荷预测模型。首先,基于消费者心理学理论对电力需求响应信号建模并量化其不确定性,通过耦合响应原理计算冷负荷与热负荷响应,构建综合需求响应信号。其次,采用自适应图卷积网络构建多元负荷的动态图结构,提取多元负荷间的动态耦合关系。最后利用TimeXer的自注意力机制挖掘负荷数据的时序依赖特性,并通过交叉注意力机制分析多元负荷与外部影响因素(含综合需求响应信号、多元负荷动态耦合关系和气象因素)的关联机制。仿真算例结果表明,该预测模型相较于传统预测模型具有更高的预测精度。

关键词:综合能源系统;综合需求响应;自适应图卷积网络;多元负荷短期预测

AGCN-TimeXer based short-term multi load forecasting of integrated energy system considering integrated demand response

DONG Jiaming¹, HAN Xingchen², ZHANG Zhisheng¹

(1. College of Electrical Engineering, Qingdao University, Qingdao 266071, China; 2. State Grid Qingdao Power Supply Company, Qingdao 266002, China)

Abstract: Considering the demand response mechanism and the dynamic coupling characteristics of multi loads in integrated energy systems, a multi load forecasting model based on an AGCN-TimeXer framework that incorporates integrated demand response is proposed. Firstly, drawing on consumer psychology theories, the electricity demand response signals are modeled and their uncertainty is quantified. Comprehensive demand response signals are then constructed by calculating cooling and heating load responses using the coupling response principle. Secondly, an adaptive graph convolutional network (AGCN) is employed to construct a dynamic adaptive graph structure, thereby facilitating the extraction of dynamic coupling relationships among multi loads. Finally, the self-attention mechanism of TimeXer is utilized to explore the temporal dependence characteristics of load data, and the cross-attention mechanism is adopted to analyze the relationships between multivariate loads and external influencing factors, including integrated demand response signals, dynamic coupling relationships among multivariate loads, and meteorological factors. Simulation results demonstrate that the proposed model significantly outperforms traditional forecasting methods in terms of prediction accuracy.

Key words: integrated energy system; integrated demand response; adaptive graph convolutional network; short-term multi load forecasting

0 引言

随着能源互联网与“双碳”目标的深度融合,综合能源系统(integrated energy system, IES)通过电、冷、热等多能流协同优化显著提升了能源利用效率,成为现代能源体系转型的重要方向。多元负荷作为IES终端需求侧的核心要素,其短期预测精度对系统调度、运行经济性及安全性有关键影响,准确的IES多元负荷短期预测是保证系统安全稳定运

行的基础^[1]。

伴随着电力市场的发展与改革,负荷资源参与电网运行的方式逐渐市场化。需求响应(demand response, DR)作为一种主要参与形式,可以有效挖掘系统需求侧负荷的调节潜力,缓解系统的调节负担^[2]。然而,IES场景下需求响应的引入在增强系统灵活性的同时,亦加剧了多元负荷的耦合复杂性。多元负荷预测面临多能源耦合动态建模与需求响应交互影响的双重挑战。

近年来,深度学习技术被广泛应用于IES多元负荷预测,并展现出良好的预测精度。目前关于IES负荷预测的研究主要使用数据分解和多任务学

习等预测方法。文献[3]提出互补集成经验模态分解的多元负荷预测方法。文献[4]采用多任务学习硬共享机制提取多元负荷间的耦合特性。文献[5]先将多元负荷序列分解为高、中、低3种频段的模态分量,然后构建多任务学习模型对各分量分别进行预测。这两类方法主要围绕多元负荷间的复杂耦合关系。文献[6]提出了多尺度时空图神经网络模型,该模型通过图卷积网络(graph convolutional network, GCN)模块捕获多元负荷数据间的隐藏信息。图神经网络在学习多元负荷的耦合关系方面展现出显著优势。然而,现有图模型多采用静态邻接矩阵刻画负荷关联,无法自适应捕捉需求响应驱动下多元负荷耦合强度的时序动态变化。在需求响应影响方面,文献[7]将市场电价信号与需求响应激励特征进行融合,构建了针对性的电力负荷预测器,有效提升了价格导向场景下单一电力负荷的预测精度。文献[8]进一步拓展研究边界,聚焦 IES 场景,构建了适用于多能源协同优化的需求响应信号,并将其作为输入变量用于多元负荷预测。

针对 IES 运行过程中的需求侧响应与多能流动态耦合特征,本文提出一种考虑综合需求响应(integrated demand response, IDR)的 AGCN-TimeXer 多元负荷短期预测方法。首先通过消费者心理学理论^[9]构建电力需求响应率,并量化其不确定性。再通过耦合响应原理求解冷、热负荷的需求响应率,从而构建 IDR 信号。在此基础上,使用自适应图卷积网络(adaptive graph convolutional network, AGCN)^[10]捕捉多元负荷的动态耦合特性。AGCN 构建的自适应邻接矩阵突破传统 GCN 模型对固定拓扑关系的依赖,可以更好地表达多元负荷的复杂动态耦合关系。随后,将多元负荷耦合特性、IDR 信号以及气象因素作为 TimeXer^[11]模型的外生输入变量,历史多元负荷作为内生变量,共同输入 TimeXer 模型。这种内外生变量分离的架构,使 TimeXer 能有效利用外部信息增强对内生序列的预测能力。仿真结果表明,所提模型具有较好的预测性能。

1 综合需求响应模型

1.1 电力需求响应

电力需求响应主流分为价格型与激励型两类。本文聚焦价格型需求响应中的分时电价机制,该机制通过峰谷差异化电价信号引导用户调整用能行为。消费者心理学理论可有效刻画用户对该类价格信号的响应特征,根据该理论,用户的需求

响应情况可划分为死区、响应区和饱和区。基于 Sigmoid 函数的用户需求响应模型在第一象限的图像如图 1 所示,模型在第三象限的图像与第一象限关于原点中心对称。




图1 用户需求响应模型(第一象限)

Fig. 1 Users' demand response model (Quadrant I)

用户的需求响应率受到电价差的影响。全年根据季节被划分为 n 个峰谷段,不同时段电价差可表示为

$$\Delta p_{nt} = \begin{cases} p_{np} - p_{nv} & t \in T_{nv} \\ p_{nv} - p_{np} & t \in T_{np} \end{cases} \quad (1)$$

式中: T_{nv} 为第 n 个峰谷段的谷时段; T_{np} 为第 n 个峰谷段的峰时段; p_{np} 和 p_{nv} 分别为第 n 个峰谷段的峰时段电价和谷时段电价。当 $t \in T_{nv}$ 时, $\Delta p_{nt} > 0$; 当 $t \in T_{np}$ 时, $\Delta p_{nt} < 0$ 。

将需求响应划分为死区、响应区、饱和区后,需求响应率可用式(2)~式(5)表示

$$\lambda_{opt} = \alpha \sigma(k(|\Delta p_{nt}| - \Delta p_{mido})) \quad (2)$$

$$\lambda_{pess} = \alpha \sigma(k(|\Delta p_{nt}| - \Delta p_{midp})) \quad (3)$$

$$\lambda_{base} = \frac{\lambda_{opt} + \lambda_{pess}}{2} \quad (4)$$

$$\lambda_o = \begin{cases} 0 & |\Delta p_{nt}| < \Delta p_a \\ c\lambda_{base} & \Delta p_a \leq |\Delta p_{nt}| < \Delta p_b \\ c\alpha & |\Delta p_{nt}| \geq \Delta p_b \end{cases} \quad (5)$$

式中: Δp_{nt} 为第 n 个峰谷段的电价差; λ_o 为中心需求响应率; λ_{opt} 和 λ_{pess} 分别为乐观和悲观需求响应率; α 为最大需求响应率; σ 为 Sigmoid 函数; k 为控制函数陡峭程度的参数; Δp_{mido} 和 Δp_{midp} 分别为 λ_{opt} 和 λ_{pess} 函数值为 $\alpha/2$ 时对应的横坐标; λ_{base} 为中心需求响应率; Δp_a 和 Δp_b 分别为死区与响应区分界点和响应区与饱和区分界点; c 为控制 λ 正负的参数,当 $\Delta p_{nt} \geq 0$ 时, c 为 1,当 $\Delta p_{nt} < 0$ 时, c 为 -1。

当电价差处于响应区时,用户的实际响应行为

受到环境、偏好等非经济因素的影响,真实需求响应率存在一定的不确定性。这种不确定性具体表现为真实需求响应率会在中心需求响应率附近波动,但介于乐观需求响应率和悲观需求响应率之间^[9]。针对IES中用户的聚合效应,确定电价差下的需求响应率趋近于正态分布^[12]。为参数化此分布,进行如下设定:①以中心需求响应率作为分布的期望(均值 μ);②依据统计学的 3σ 原则,将乐观与悲观需求响应率之差的绝对值定义为6倍标准差(6σ),从而确定标准差 σ 的值。由此构建的需求响应率概率密度函数如图2所示。




图2 电力需求响应率概率密度分布

Fig. 2 Probability density distribution of power demand response rate

通过图2可以量化不同概率区间下的需求响应率的波动范围。为了在后续计算中有效计入此不确定性,需要将其从连续分布转化为离散样本。为此,本文采用蒙特卡罗模拟方法,从该正态分布定义的 $[\mu - 3\sigma, \mu + 3\sigma]$ 区间内进行抽样,以生成一组离散的需求响应率样本集。综上所述,计及不确定性的电力需求响应率可表示为

$$\lambda_e = \lambda_o + \delta \quad (6)$$

式中: δ 为电力需求响应的不确定性,当电价差位于死区和饱和区时, δ 为0。

1.2 耦合响应

在IES中,多元负荷之间存在着复杂的耦合关系,电负荷的需求响应也会引发耦合响应^[13],即电负荷的用能变化会导致冷、热负荷的用能变化,从而引发冷、热负荷的需求响应。在实际过程中,冷、热负荷的需求响应率受设备运行状况、用户行为等多种因素影响,为了量化冷负荷和热负荷的需求响应率,使用式(7)和式(8)进行计算。电负荷、冷负荷和热负荷的需求响应率共同构成了IDR信号,用式(9)表示。

$$\lambda_{ch} = \frac{\lambda_e - B}{\eta_c \beta_c + \eta_h \beta_h} \quad (7)$$

$$\begin{cases} \lambda_c = \eta_c \beta_c \lambda_{ch} \\ \lambda_h = \eta_h \beta_h \lambda_{ch} \end{cases} \quad (8)$$

$$\lambda_m = [\lambda_c, \lambda_e, \lambda_h] \quad (9)$$

式中: λ_{ch} 为冷负荷和热负荷的耦合响应率; λ_e 为电负荷的需求响应率; B 为 λ_e 对冷负荷和热负荷响应率之和的偏移量; η_c 和 η_h 分别为冷负荷和热负荷设备的运行效率; β_c 和 β_h 分别为耦合响应率对冷负荷和热负荷响应率的分配比例; λ_c 和 λ_h 分别为冷负荷和热负荷的需求响应率; λ_m 为IDR信号; B 、 β_c 和 β_h 分别为模型的待优化参数,在训练过程中通过迭代寻优动态调整,以增强模型对多元负荷需求响应间耦合机制的学习能力。

2 多元负荷与气象数据预处理

IES的数据在测量、传输和存储过程中可能会因传感器故障、数据传输故障等因素而产生异常值。为降低异常值对模型预测过程的干扰,需要对负荷和气象数据实施预处理,涵盖异常数据识别与处理,缺失值插补等。为降低异常值对模型预测过程的干扰,需要对负荷和气象数据实施预处理,涵盖异常数据识别与处理、缺失值插补、归一化,具体步骤见附录A。

为提高模型对气象数据的利用效率,本文使用最大信息系数法(maximal information coefficient, MIC)来分析输入多元负荷数据和气象数据间的相关性,MIC可以有效捕捉变量间的线性及非线性关系,计算得到的数据间的相关性如图3所示。



图3 多元负荷与气象数据MIC分析结果

Fig. 3 MIC analysis results of multi loads and meteorological data

由图3可知,多元负荷之间存在较强的相关性。将图3各行数据求和计算各气象因素与电、冷、热负荷相关性之和,选取与多元负荷相关性较强的3种气象因素(温度、相对湿度、可降水量)作为气象输入数据。

3 考虑综合需求响应的 AGCN-TimeXer 模型

3.1 AGCN 模型

针对 IES 多元负荷间的复杂耦合关系,本文提出基于 AGCN 的图结构建模方法。本文以电、冷、热负荷为节点,以负荷数据为节点特征来构建 IES 的图结构。

鉴于 IES 图结构中节点数量较少的特性,本文对标准 AGCN 架构进行了精简与优化,优化后的 AGCN 模型由个性化节点权重矩阵与数据自适应图生成 (data adaptive graph generation, DAGG) 模块构成。其中,个性化节点权重矩阵在标准 GCN 架构的基础上,为每个节点配置独立的可学习权重矩阵,进而实现对电、冷、热负荷因设备特性与用户行为差异所产生的特征异质性的有效建模。计算如下

$$Z = \left(I_N + D^{-\frac{1}{2}} A D^{-\frac{1}{2}} \right) X \theta' + b \quad (10)$$

式中: X 和 Z 分别为输入和输出数据; A 为图的预定义邻接矩阵; I_N 为单位矩阵; D 为度矩阵; θ' 为改进后的权重矩阵; b 表示偏置。

DAGG 模块使用节点嵌入矩阵通过数据驱动的方式自适应学习邻接矩阵的表示,能更好表达多元负荷复杂动态关系。DAGG 模块的公式如下

$$D^{-\frac{1}{2}} A D^{-\frac{1}{2}} = \text{soft max}(\text{Re LU}(E E^T)) \quad (11)$$

式中: E 为节点嵌入矩阵,该矩阵在训练中自适应学习; ReLU 为非线性激活函数; softmax 为归一化指数函数。

通过式(10)和式(11),可得自适应图卷积如下

$$Z = \left(I_N + \text{soft max}(\text{Re LU}(E E^T)) \right) X \theta' + b \quad (12)$$

3.2 TimeXer 模型

本文采用 TimeXer 模型作为核心预测模型,相较于传统时序预测模型,该模型通过并行提取时间依赖关系,有效克服了传统循环神经网络在捕捉长周期序列依赖时的局限性。在变量输入方式上,TimeXer 模型摒弃了将内外生变量简单拼接输入的传统做法,而是将内外生变量分离输入模型,旨在利用外生变量来提高内生变量的预测精度。在模型结构上,该模型以 Transformer 架构为基础,针对内生序列采用 patch 级嵌入以有效捕获局部时间依赖性,针对外生序列则采用变量级嵌入。最终,模型通过多头交叉注意力机制实现了内、外生变量间的高效信息融合。其模型结构如图4所示,其中 N 表示框内模块的堆叠层数。




图4 TimeXer模型结构

Fig. 4 Structure of the TimeXer model

3.2.1 内生变量嵌入

内生变量嵌入模块负责将原始的内生输入序列转换为模型可处理的表示。对于给定的时间维度为 T 的输入序列 X_{en} ,内生变量嵌入模块将其分割成 $L(L=T/P)$ 个长度为 P (P 为预设的片段长度) 的不重叠的连续片段 x_i 。每个片段随后通过一个共享的线性投影层被映射到模型的隐藏维度。随后,为了注入序列的顺序信息,为每个片段加上一个可学习的位置编码。最后对于每个变量在其分段序列的末尾放置一个特殊且可学习的全局标记。其计算公式如下

$$\tilde{X}_{en} = [x_1, x_2, \dots, x_L] \quad (13)$$

$$h_i = x_i W_{en} + PE \quad (14)$$

$$H_{en} = [h_1, h_2, \dots, h_L, h_{gbl}] \quad (15)$$

式中: W_{en} 为线性投影层; PE 为可学习的位置编码; h_{gbl} 为可学习的全局标记; H_{en} 为内生变量嵌入模块的输出。

3.2.2 外生变量嵌入

与内生变量采用的分块嵌入策略不同,外生变量输入序列 X_{ex} 直接通过一个线性层投影到模型的隐藏层维度。其计算公式为

$$H_{ex} = X_{ex} W_{ex} \quad (16)$$

$$X_{ex} = [Z, P, \lambda_m] \quad (17)$$

式中: W_{ex} 为线性投影层; H_{ex} 为外生变量嵌入模块

的输出; $\mathbf{Z}$ 为 AGCN 输出的多元负荷耦合关系特征向量; $\mathbf{P}$ 为预处理后的气象数据; λ_m 为 IDR 信号。

3.2.3 多头自注意力机制

为有效捕捉内生变量的长期时间依赖性,模型将前序步骤生成的片段序列与全局标记向量进行整合,并输入至一个多头自注意力层,表示如下

$$\mathbf{H}_{\text{en}}[\mathbf{W}^q, \mathbf{W}^k, \mathbf{W}^v] = [\mathbf{Q}, \mathbf{K}, \mathbf{V}] \quad (18)$$

$$\mathbf{A}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{soft max} \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}} \right) \mathbf{V} \quad (19)$$

$$\mathbf{A}_i = \mathbf{A}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) \quad (20)$$

$$\mathbf{A}_M = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_n] \mathbf{W}^o \quad (21)$$

式中: $\mathbf{Q}$ 、 $\mathbf{K}$ 和 $\mathbf{V}$ 分别为查询向量、键向量和值向量; $\mathbf{W}^q$ 、 $\mathbf{W}^k$ 和 $\mathbf{W}^v$ 为其对应的参数矩阵; d_k 为 $\mathbf{K}$ 的维度;多头自注意力机制将 $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 矩阵分别分割成 n 个头向量 (n 为头数); $\mathbf{A}_i$ 为第 i 个头的自注意力计算结果;将 n 个头的结果拼接后,通过参数矩阵 $\mathbf{W}^o$ 进行线性变换; $\mathbf{A}_M$ 为多头自注意力的输出。

3.2.4 多头交叉注意力机制

TimeXer 模型通过一个多头交叉注意力层来促进内生变量与外生变量之间的信息融合。该层的结构与自注意力层类似,关键区别在于其输入源的非对称性:查询向量由内生变量的全局标记生成,而键和值向量则由整个外生序列投影得到。形式上,交叉注意力的计算仅需将自注意力计算中的式(18)替换为

$$[\mathbf{H}_{\text{glb}} \mathbf{W}^q, \mathbf{H}_{\text{ex}} \mathbf{W}^k, \mathbf{H}_{\text{ex}} \mathbf{W}^v] = [\mathbf{Q}, \mathbf{K}, \mathbf{V}] \quad (22)$$

式中: $\mathbf{H}_{\text{glb}}$ 为前一自注意力层输出的全局标记。

模型预测流程见附录 B。

4 算例分析

4.1 实验设置和仿真评价指标

实验采用 Python3.11.9 编程语言和 Pytorch2.4.0 框架搭建模型。硬件配置为 NVIDIA GeForce RTX 4060 Laptop GPU 和 Intel Core i7-14650HX CPU。

为了验证所提出模型的有效性,本文采用美国亚利桑那州立大学坦佩校区 IES 的数据作为算例。多元负荷数据来自亚利桑那州立大学校园代谢项目网络平台^[14],包括电、冷、热 3 种负荷类型。气象数据来自美国国家太阳辐射数据库^[15]。负荷数据和气象数据的采样间隔均为 1 h,选取 2019 年 9 月 22 日 00:00—2020 年 9 月 28 日 23:00 的负荷数据和气象数据为数据集,其中最后一周的数据作为测试集,其余部分为训练集。电、冷、热负荷之间的单位换算关系为 1 kW=0.284 Ton=3.4×10⁻³ MMBtu/h。本

文所用电价数据基于美国 SRP(salt river project)的分时电价政策。SRP 是美国亚利桑那州的一家大型公用事业公司,主要负责电力和水资源供应与管理。

本文采用平均绝对百分比误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)、加权平均绝对百分比误差(weighted mean absolute percentage error, WMAPE)作为多元负荷预测的评价指标。在下文分别用 E_{MAPE} 、 E_{RMSE} 及 E_{WMAPE} 代表 MAPE、RMSE 及 WMAPE。各评价指标计算见附录 C。

4.2 模型参数设置

Sigmoid 函数的 k 值设为 8; Δp_{mido} 和 Δp_{midp} 分别取 0.02 和 0.06; α 为 0.1。

本文通过遍历预设的超参数组合空间确定模型超参数。模型的最大训练次数为 100 次,丢弃率设为 0.1,训练批次为 64,学习率为 0.000 8。模型主要超参数设置如表 1。

表 1 AGCN-TimeXer 模型主要超参数

Table 1 Main hyperparameters of AGCN-TimeXer

模型	超参数名称	数值
AGCN	切比雪夫多项式阶数	1
	节点嵌入维度	10
TimeXer	编码器层数	4
	隐藏层维度	64
	多头注意力头数	8
	时间序列分片长度	6
	全连接层维度	256

为实现高效且稳健的模型训练,优化器选择 AdamW 优化器。该优化器辅以一个复合学习率调度策略,该策略包含线性预热(linear warmup)阶段和余弦退火(cosine annealing)阶段。

4.3 综合需求响应模型预测性能影响分析

为了验证 IDR 对多元负荷预测模型精度的积极作用,本文将考虑 IDR 的 AGCN-TimeXer 模型与传统 AGCN-TimeXer 模型进行对比。对比结果如表 2 所示。

表 2 考虑 IDR 与不考虑 IDR 预测指标

Table 2 Prediction indicators with and without IDR

评价指标	负荷类型	不考虑 IDR	考虑 IDR
$E_{\text{MAPE}}/\%$	电负荷	2.088	1.605
	冷负荷	1.762	1.523
	热负荷	2.214	2.108
$E_{\text{RMSE}}/\text{kW}$	电负荷	569.245	448.902
	冷负荷	753.123	659.492
	热负荷	44.402	42.904
$E_{\text{WMAPE}}/\%$	综合能源	1.983	1.673

从表 2 可以看出,考虑 IDR 后,预测模型的电、冷、热负荷 E_{MAPE} 分别降低了 23.13%、13.56%、4.79%,

E_{RMSE} 分别降低了21.14%、12.43%、3.37%, E_{WMAPE} 降低了15.63%。综合分析各项指标,在预测精度方面,考虑IDR的预测模型显著优于不考虑IDR的预测模型。

4.4 不同模型预测性能分析

为了验证 AGCN-TimeXer 在 IES 多元负荷短期预测中的优势,本文选用卷积神经网络(convolutional neural network, CNN)、门控循环单元(gated recurrent unit, GRU)、Transformer、AGCN 和 TimeXer 与 AGCN-TimeXer 进行预测性能对比。6种模型选用相同的训练集和测试集,输入量均为多元负荷、气象数据以及 IDR 信号,以相同的预测流程对算例 IES 多元负荷进行预测。

各模型的预测指标对比如表3所示。分析表3可知,与基础的 CNN 模型相比,GRU 和 Transformer 均展现出更低的预测误差,这初步证实了门控机制与注意力机制在捕获时间序列依赖关系中的有效性。其次,TimeXer 相较于标准 Transformer 模型进一步降低了误差,这凸显了其独特的序列嵌入与交叉注意力机制在融合多维信息方面的优势。AGCN 作为独立模型取得了较好的预测效果,而将其融入 TimeXer 也带来了显著的性能提升。具体而言,AGCN-TimeXer 的 E_{WMAPE} 相较于 CNN、GRU、Transformer、AGCN 和 TimeXer 分别降低 33.90%、27.73%、26.07%、22.22%和 20.64%,验证了所提模型架构的优越性。这一结果有效证明,通过图神经网络建模多元负荷间的内在关联,能够有效提升 IES 预测精度。

图5给出了6种模型的预测结果。由图5可知,AGCN-TimeXer 模型的预测轨迹与真实曲线吻合度最高。此外,热负荷受到用户行为等随机干扰表现出更强的波动性,导致所有模型的预测难度均增加。

4.5 AGCN 模型输出可视化分析

为验证 AGCN 模型对多元负荷耦合关系的表征能力,本文选取 AGCN 模块输出的连续3天电、冷、热负荷特征时间序列进行了可视化分析,结果如图6所示。由图6可知,冷负荷特征在午后时段出现显著峰值,而电负荷特征并未独立变化,而是同步呈




图5 各模型预测曲线

Fig. 5 Prediction curves for each model

现了与之高度相关的波动模式。此外,热负荷与电负荷特征在部分时段也表现出一定的协同变化趋势。该模式与空调制冷、电制热等实际系统的能量转换逻辑一致,证明模型能从数据中有效学习多元负荷间的能量耦合机制。

表3 各模型预测指标对比

Table 3 Comparison of prediction indicators of each model

模型	$E_{MAPE}/\%$			E_{RMSE}/kW			$E_{WMAPE}/\%$
	电负荷	冷负荷	热负荷	电负荷	冷负荷	热负荷	
CNN	2.230	2.207	3.782	588.823	945.375	68.261	2.531
GRU	2.008	2.069	3.418	593.283	827.572	61.743	2.315
Transformer	1.905	2.282	2.940	525.415	988.022	57.392	2.263
AGCN	2.356	1.888	2.268	646.730	803.042	46.173	2.151
TimeXer	2.097	2.063	2.221	571.977	815.163	45.028	2.108
AGRN-TimeXer	1.605	1.523	2.108	448.902	659.492	42.904	1.673




图6 AGCN输出特征曲线

Fig. 6 Output feature curves of AGCN

5 结束语

本文针对IES中需求响应机制与多元负荷动态耦合特性,提出一种考虑综合需求响应的AGCN-TimeXer多元负荷预测模型,经过算例分析,主要结论如下:

(1) 通过消费者心理学原理和耦合响应原理构建的综合需求响应信号可显著提升需求响应场景下多元负荷短期预测的精确性;

(2) 通过个性化节点权重矩阵和多元负荷动态图结构可以充分考虑多元负荷间动态关联,提高模型预测性能;

(3) TimeXer模型利用其多头自注意力机制实现了对多元负荷时间依赖关系的有效建模,并借助交叉注意力机制有效融合外部影响因素。D

附录见本刊网络版(<http://dsm.ijournals.cn>)。

参考文献:

- [1] ZHANG Y, CUI Q, SHI L, et al. PPenergy NET: privacy-preserving multi-energy load forecasting in energy internet considering energy coupling[J]. IEEE Transactions on Power Systems, 2024, 39(5): 6 235–6 248.
- [2] 陈浩, 李晨阳, 陈光, 等. 基于消费者心理学模型与自适应图注意力网络的负荷集群时变需求响应潜力评估[J]. 电力需求侧管理, 2025, 27(4): 42–48.
CHEN Hao, LI Chenyang, CHEN Guang, et al. Evaluation of time-varying demand response potential of load clusters based on consumer psychology model and adaptive graph attention network[J]. Power Demand Side Management, 2025, 27(4): 42–48.
- [3] SHI J, TEH J. Load forecasting for regional integrated energy system based on complementary ensemble empirical mode decomposition and multi-model fusion[J]. Applied Energy, 2024, 353: 122 146.
- [4] 宋峥峥, 辛锐, 赵黎媛, 等. 基于SEResNet-BiLSTM网络的综合能源系统多元负荷预测方法[J]. 电力需求侧管理, 2025, 27(3): 58–64.
SONG Zhengzheng, XIN Rui, ZHAO Liyuan, et al. Integrated energy system load forecasting based on SEResNet-BiLSTM network[J]. Power Demand Side Management, 2025, 27(3): 58–64.
- [5] 张玉敏, 孙猛, 吉兴全, 等. 基于模态分解与多任务学习模型的综合能源系统多元负荷短期预测[J]. 高电压技术, 2025, 51(7): 3 488–3 499.
ZHANG Yumin, SUN Meng, JI Xingquan, et al. Short-

term load forecasting of integrated energy system based on modal decomposition and multi-task learning model[J]. High Voltage Engineering, 2025, 51(7): 3 488–3 499.

- [6] ZHUANG W, FAN J, XIA M, et al. A multi-scale spatial-temporal graph neural network-based method of multi-energy load forecasting in integrated energy system[J]. IEEE Transactions on Smart Grid, 2024, 15(3): 2 652–2 666.
- [7] 田年杰, 苏祥瑞, 姚文峰, 等. 一种考虑需求响应的新型短期负荷预测器DR-ELITE[J]. 电力系统及其自动化学报, 2024, 36(12): 74–84.
TIAN Nianjie, SU Xiangrui, YAO Wenfeng, et al. Novel predictor DR-ELITE for short-term load with consideration of demand response[J]. Proceedings of the CSU-EPSA, 2024, 36(12): 74–84.
- [8] 李云松, 张智晟. 考虑综合需求响应的Transformer-图神经网络综合能源系统多元负荷短期预测[J]. 电工技术学报, 2024, 39(19): 6 119–6 128.
LI Yunsong, ZHANG Zhisheng. Trans-GNN based multi load short-term forecasting of integrated energy system considering integrated demand response[J]. Transactions of China Electrotechnical Society, 2024, 39(19): 6 119–6 128.
- [9] 范添圆, 王海云, 王维庆, 等. 计及主/被动需求响应下基于合作博弈的微网-配电网协调优化调度[J]. 电网技术, 2022, 46(2): 453–463.
FAN Tianyuan, WANG Haiyun, WANG Weiqing, et al. Coordinated optimization scheduling of microgrid and distribution network based on cooperative game considering active/passive demand response[J]. Power System Technology, 2022, 46(2): 453–463.
- [10] BAI L, YAO L, LI C, et al. Adaptive graph convolutional recurrent network for traffic forecasting[C]//Advances in Neural Information Processing Systems 33. Virtual, 2020: 17 804–17 815.
- [11] WANG Y, WU H, DONG J, et al. TimeXer: empowering transformers for time series forecasting with exogenous variables[C]//Thirty-Eighth Annual Conference on Neural Information Processing Systems, Vancouver, Canada, December 10–15, 2024.
- [12] 崔永玲, 王成福, 牛远方, 等. 考虑综合需求响应不确定性的综合能源系统两阶段随机优化决策[J]. 电网技术, 2025: 1–14.
CUI Yongling, WANG Chengfu, NIU Yuanfang, et al. Two-stage stochastic optimization decision of integrated energy system considering the uncertainty of integrated demand response[J]. Power System Technology, 2025: 1–14.
- [13] 赵海彭, 苗世洪, 李超, 等. 考虑冷热电需求耦合响应特性的园区综合能源系统优化运行策略研究[J]. 中国电机工程学报, 2022, 42(2): 573–589.
ZHAO Haipeng, MIAO Shihong, LI Chao, et al. Research on optimal operation strategy for park-level integrated energy system considering cold-heat-electric demand coupling response characteristics[J]. Proceedings of the CSEE, 2022, 42(2): 573–589.
- [14] ASU. Campus metabolism[EB/OL]. <http://cm.asu.edu/>, 2025–04–14.
- [15] NSRDB. data viewer[EB/OL]. <https://nsrdb.nrel.gov/data-viewer>, 2025–04–15.

作者简介:

董家铭(2000), 男, 山东济宁人, 硕士研究生, 研究方向为区域综合能源系统多元负荷预测;

张智晟(1975), 男, 通信作者, 山东青岛人, 博士, 教授, 研究方向为电力系统负荷预测和经济调度。

(责任编辑 水 鹤)

附录 A

本文采用 3σ 准则对输入数据进行检测,为规避季节性负荷波动引起的误判风险,按季节划分分别计算均值与标准差以确定动态阈值,其判定规则如下

$$|x_k - \bar{x}| = |v_k| > 3\sigma \quad (\text{A-1})$$

式中: x_k 为第 k 个观测数据; $\bar{x}$ 为样本均值; v_k 为第 k 个数据的剩余误差; σ 为样本标准差。当满足 $|v_k| > 3\sigma$ 时,判定该数据为粗大误差,予以删除处理。针对异常值剔除后引发的数据缺失问题,本文采用线性插值法对空缺值进行填补。

为消除数据量纲差异及增强模型的泛化能力,将填充后的数据使用最小-最大归一化处理,其计算公式为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (\text{A-2})$$

式中: x 为样本观测数据; x^* 为归一化后的数据; $x_{\min}$ 和 $x_{\max}$ 分别为 x 的最小值和最大值。

附录 B

基于 AGCN-TimeXer 的多元负荷预测模型流程如图 B-1 所示。其核心步骤如下:

(1) 首先根据输入数据求解 IDR 信号,并对历史多元负荷和气象数据实施预处理操作;

(2) 处理后的历史多元负荷数据一方面作为 TimeXer 模型的内生变量输入,另一方面输入到 AGCN 模型中捕获电、冷、热负荷之间潜在的动态耦合关系;

(3) 由 AGCN 输出的图增强特征向量与处理后的气象数据及 IDR 信号进行拼接,这个融合的高维向量作为 TimeXer 模型的外生变量输入;

(4) TimeXer 模型集成内生变量和外生变量,经迭代训练后保存误差最小的模型为最优模型。最后使用最优预测模型对目标时间点的多元负荷进行预测并反归一化输出结果。




图 B-1 AGCN-TimeXer 模型预测流程

Fig. B-1 Flow of the AGCN-TimeXer prediction model

附录 C

各评价指标的计算公式如下

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (\text{C-1})$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (\text{C-2})$$

$$E_{\text{WMAPE}} = \alpha_e E_{\text{MAPEe}} + \alpha_c E_{\text{MAPEc}} + \alpha_h E_{\text{MAPEh}} \quad (\text{C-3})$$

式中: E_{MAPE} 、 E_{RMSE} 和 E_{WMAPE} 分别为 MAPE、RMSE 和 WMAPE; n 为预测样本数量; $\hat{y}_i$ 和 y_i 分别为 i 时刻多元负荷的预测值和真实值; E_{MAPEe} 、 E_{MAPEc} 、 E_{MAPEh} 分别为电、冷、热负荷的 MAPE; α_e 、 α_c 、 α_h 分别为 E_{MAPEe} 、 E_{MAPEc} 、 E_{MAPEh} 的权重,根据 3 种负荷在算例 IES 中的占比, α_e 、 α_c 、 α_h 分别取 0.4、0.4、0.2。