

基于模式互相关和时序片段关联机制的多元负荷预测

李整^{1,2}, 李志霄¹, 秦金磊^{1,3}, 郭长珍¹

(1. 华北电力大学计算机系, 河北 保定 071003;

2. 华北电力大学河北省能源电力知识计算重点实验室, 河北 保定 071003;

3. 华北电力大学复杂能源系统智能计算教育部工程研究中心, 河北 保定 071003)

摘要: 针对综合能源系统(IES)负荷噪声大、波动性强、周期信息提取困难问题, 提出一种基于模式互相关和时序片段关联(PCC-TPA)机制的多元负荷预测方法。通过互相关函数分析外界影响因素与多元负荷间的交叉滞后关系, 确定最相关的时滞并据此重构和嵌入数据。在此基础上, 提出 PCC 机制, 根据数据的变化趋势将其抽象为模式数据, 以减轻数据波动与噪声的影响, 基于互相关理论识别和提取关键时刻及周期信息; 同时, 设计时序片段关联机制, 将序列划分为多个子序列, 基于互信息方法分析和筛选子序列, 增强模型对序列局部连续性信息的捕获能力。在美国亚利桑那州立大学坦佩校区综合能源系统数据集上进行多项消融实验和对比实验。实验结果表明, 交叉滞后分析重构的数据有效提升了模型的预测精度, PCC-TPA 机制分别增强模型的关键时刻识别能力和局部信息捕捉能力。所提方法在多项评估指标上优于 5 种主流预测模型, 具有较高的预测精度。

关键词: 多元负荷预测; 交叉滞后分析; 序列分解; 序列模式化; 互相关分析; 深度学习

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0070572

Multiple Loads Forecasting Based on Pattern Cross-Correlation and Temporal Patch Association Mechanism

LI Zheng^{1,2}, LI Zhixiao¹, QIN Jinlei^{1,3}, GUO Changzhen¹

(1. Department of Computer, North China Electric Power University, Baoding 071003, Hebei, China;

2. Hebei Key Laboratory of Knowledge Computing for Energy and Power,
North China Electric Power University, Baoding 071003, Hebei, China;

3. Engineering Research Center of Intelligent Computing for Complex Energy Systems, Ministry of Education,
North China Electric Power University, Baoding 071003, Hebei, China)

【Abstract】 To address the challenges of high noise levels, strong volatility, and difficulties in extracting periodic information from the loads of Integrated Energy Systems (IES), a multivariate load forecasting method based on Pattern Cross-Correlation and Temporal Patch Association (PCC-TPA) mechanisms is proposed. This method analyzes the cross-lag relationships between external influencing factors and multivariate loads using a cross-correlation function to determine the most relevant time lags for data reconstruction and embedding. Building on this, a PCC mechanism is introduced to abstract data into patterns based on their variation trends, thus mitigating the effects of fluctuations and noise. This is followed by the identification and extraction of key moments and periodic information based on the cross-correlation theory. A TPA mechanism is designed to divide a sequence into multiple subsequences using mutual information methods to analyze and filter the subsequences, thereby enhancing the ability of the model to capture local continuity information in sequences. Multiple ablation and comparison experiments are conducted using the comprehensive energy system dataset from the Arizona state university, Tempe campus. The ablation experimental results show that the data reconstructed through cross-lag analysis effectively improved the prediction accuracy of the model. The PCC-TPA mechanisms enhance the ability of the model to identify key moments and capture local information, respectively. The comparison of the experimental results indicates that the proposed method outperforms five mainstream prediction models in terms of multiple evaluation metrics, demonstrating a higher prediction accuracy.

【Key words】 multiple loads forecasting; cross-lagged analysis; series decomposition; series pattern; cross-correlation analysis; deep learning

基金项目: 河北省自然科学基金(F2014502081); 中央高校基本科研业务费专项资金(2020MS120)。

作者简介: 李整, 女, 副教授, 主研方向为智能计算、电力系统负荷预测及优化调度; 李志霄(通信作者), 硕士研究生; 秦金磊, 副教授; 郭长珍, 硕士研究生。

收稿日期: 2024-11-04

修回日期: 2025-02-13

E-mail: lzx21029@163.com

0 引言

近年来,能源短缺和环境污染问题日益加剧,提升能源利用效率和发展可再生能源已成为当今世界的紧要任务^[1-2]。在此背景下,综合能源系统(IES)作为一种新型能源解决方案,通过整合电、冷、热等多种负荷类型,实现了能源在源、网、荷等关键环节的耦合与调度,显著提升能源的利用效率^[3]。准确的多能源负荷预测为系统调度提供了重要指导,是确保 IES 安全稳定运行的前提与基础。然而,受经济、天气等外部因素的影响,显著增加了负荷数据的随机性与波动性,对数据处理和预测分析方法提出了更高的要求。

综合能源负荷预测方法可以分为统计学方法^[4-6]、机器学习方法^[7-9]和深度学习^[10-12]方法。近年来,深度学习方法逐渐成为研究热点,广泛应用于负荷预测领域。深度学习主要基于卷积神经网络(CNN)、循环神经网络(RNN)、Transformer 等模型。文献[13-14]在长短时记忆(LSTM)网络的基础上加入 CNN,增强了模型的特征提取能力。文献[15]结合时序卷积网络和门控循环单元,提升了模型对长序列数据的处理能力。文献[16]采用注意力机制为双向 LSTM 网络的隐藏状态分配权重,提高了预测精度。文献[17]基于 Transformer 模型实现了综合能源负荷的有效预测,但传统自注意力机制存在注意力分数长尾分布等问题,难以同时关注到负荷数据中复杂的周期模式。文献[18]设计了一种自相关机制,能够分析并提取数据的周期信息,但该机制采用的自相关函数可能会受数据波动和噪声的干扰而出现偏差。文献[19]以负荷数据的子序列为基本处理单元,提高了模型对长序列信息和局部连续信息的捕获能力。然而,该方法将所有子序列输入模型进行分析,未能充分考虑部分弱相关子序列对预测结果的干扰。而且,过多的子序列增加了模型的复杂度。

除预测模型以外,输入特征的选择和处理也对提高预测准确性有重要影响^[20-21]。文献[22]采用随机森林方法对负荷特征进行重要性排序和选择。文献[23]采用 Pearson 相关系数评估外界因素与能源负荷之间的交叉相关性。文献[24]采用 Spearman 秩相关系数作为相关性评价指标,筛选关键输入特征。上述特征筛选方法为模型性能带来了一定的提升,但未能充分考虑外部因素变化和综合能源系统响应之间存在的时间滞后问题。

针对以上问题,本文从多元特征交叉滞后分析、序列互相关分析和连续信息提取方面,提出一种基

于模式互相关和时序片段关联(PCC-TPA)机制的多元负荷预测方法。在美国亚利桑那州立大学坦佩校区综合能源系统数据集上,通过消融实验和对比实验验证了模型在预测精度方面的优势。本文主要贡献如下:

- 1) 考虑外界因素对多元负荷影响的滞后性,采用互相关函数确定外界因素与多元负荷最相关的时滞,并结合 Spearman 秩相关系数完成输入特征的选择、重构和嵌入,提升模型整体预测精度。
- 2) 提出模式互相关机制,通过对序列进行模式化操作,有效减弱噪声与随机波动对相关性计算的干扰,增强模型对序列周期信息及关键时刻信息的识别能力。
- 3) 设计时序片段关联机制,增强模型的局部信息捕获能力,同时引入关键序列筛选机制,降低弱相关子序列对预测的干扰。

1 数据分析与处理

本文采用美国亚利桑那州立大学坦佩校区公开的 IES 数据集和美国国家航空航天局(NASA)提供的气象数据集。IES 数据包括电、冷、热负荷数据,采样频率为每小时一次。气象数据包括压强、高度为 10 m 处风速、高度为 50 m 处风速、相对湿度、绝对湿度、湿球温度、露点温度、温度,采样频率同样为每小时一次。为准确预测综合能源系统负荷,本文综合考虑历史负荷数据、气象条件以及日期特征等多重因素的影响,并特别关注多元特征间的交叉滞后效应。

1.1 多元特征相关性分析

常用的相关性分析方法包括 Spearman 秩相关系数、Pearson 相关系数^[25-26]。Spearman 秩相关系数通过对数据排序来评估变量间的关系,相比 Pearson 相关系数,具有不受离群值影响、无量纲依赖、不要求数据服从正态分布等优点,更加适合随机波动较大的综合能源负荷数据和气象数据^[27]。Spearman 秩相关系数的计算如式(1)所示:

$$\rho_{X,Y} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (1)$$

式中: $\rho_{X,Y}$ 表示序列 X 和 Y 的 Spearman 秩相关系数; N 为序列长度; x_i 和 y_i 代表序列 X 和 Y 中的第 i 个值; $\bar{x}$ 和 $\bar{y}$ 分别表示 2 个序列的平均值。

为减少弱相关变量的影响,本文采用 Spearman 秩相关系数分析外界影响因素与多元负荷间的相关性,其结果如图 1 所示。本文选择同时与电、冷、热

负荷相关系数大于 0.4 的特征作为模型的输入,最终选择的影响因素为温室气体、空气温度、湿球温度、露点温度和绝对湿度。

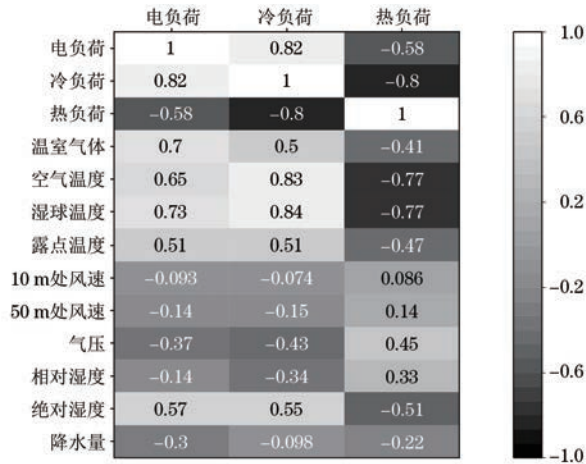


图 1 多元负荷与影响因素相关性

Fig. 1 Correlation between multiple loads and influencing factors

1.2 多元特征交叉滞后分析

综合能源系统的运行性能易受外部因素的影响而出现波动。这些波动常常受系统内部反应时间、能量传输延迟等因素的影响,表现出一种时间上的滞后性,而非即时反应。

为进一步量化这种交叉滞后效应,本文选用互相关函数(CCF)作为主要的分析工具,评估各特征在不同时间滞后下的相关程度。CCF 是一种常用的统计方法,用于度量两个时间序列在不同滞后期下的相关性。通过计算不同滞后期下的相关系数,CCF 可以分析一个变量在历史时刻对另一个变量的影响程度^[28-29]。对于序列 X 和 Y ,其相关性计算方法如式(2)所示:

$$R_{XY}(\tau) = \frac{\sum_{t=1}^{N-\tau} (X_t - \bar{X})(Y_{t+\tau} - \bar{Y})}{\sqrt{\sum_{t=1}^N (X_t - \bar{X})^2} \sqrt{\sum_{t=1}^N (Y_t - \bar{Y})^2}} \quad (2)$$

式中: τ 为时间滞后量; $R_{XY}(\tau)$ 为序列 X 和 Y 在时滞为 τ 时的互相关性; N 为序列的长度; X_t 和 Y_t 分别是序列 X 和 Y 在时刻 t 的值; $\bar{X}$ 和 $\bar{Y}$ 分别是序列 X 和 Y 的平均值。

本文采用 CCF 分析了 2019—2021 年多元负荷与外界影响因素间的交叉滞后关系,其结果如表 1 所示。图 2 进一步展示了电负荷与外界因素的交叉滞后相关性,其中温室气体在时滞为 17 h 与电负荷相关性最强,空气湿度在时滞为 19 h 与电负荷相关性最强。

表 1 多元负荷与外界因素的交叉滞后关系

Table 1 Cross-lagged relationship between multiple loads and external factors

单位:h

外界因素	电负荷滞后	冷负荷滞后	热负荷滞后
温室气体	17	14	3
空气温度	19	20	10
湿球温度	9	20	10
露点温度	6	1	23
相对湿度	6	6	23




图 2 电负荷交叉滞后分析

Fig. 2 Cross-lagged analysis of electrical loads

根据表 1 的交叉滞后相关性,本文在时间维度上对数据进行滚动重构。考虑到不同类型负荷对外界影响因素变化的灵敏度存在差异,分别对电、冷、热负荷进行了交叉滞后分析、数据重构和嵌入操作。为考虑多元负荷之间的耦合关系,本文同时对多元负荷进行嵌入,并与外部因素的嵌入数据相加,最终得出综合的嵌入结果,该过程如图 3 所示。




图 3 数据处理与嵌入

Fig. 3 Data processing and embedding

1.3 数据标准化

能源数据和气象数据之间的数量级差异较大,在分析其交叉滞后关系时保持数据的原始信息,同时减少量纲差异对模型训练的影响。本文在数据嵌入前一步对数据进行标准化,如式(3)所示:

$$x' = \frac{x - x_{\mu}}{x_{\sigma}} \quad (3)$$

式中: x 为原始数据; x' 为标准化后的值; x_{μ} 为数据均值; x_{σ} 为数据的标准差。

2 PCC-TPA 模型

本文提出一种基于 PCC-TPA 机制的多元负

荷预测方法。该方法主要包括数据预处理、特征选择与嵌入和模型预测与评估,其总体结构如图 4 所示。




图 4 模型总体结构

Fig.4 Overall structure of the model

2.1 序列分解

综合能源负荷受人类日常活动规律和季节性变化等因素的影响,表现出明显的周期性波动和长期趋势变化,适合分解后再预测。本文基于加法分解模型将序列分解为趋势项和季节项。分解模型如式(4)所示:

$$Y_t = T_t + S_t \quad (4)$$

式中: Y_t 表示随时间 t 变化的原始数据; T_t 、 S_t 分别表示随时间 t 变化的趋势项和季节项。

传统的滑动平均窗口分解序列易受噪声干扰,且难以有效提取负荷数据中复杂的周期模式。为弥补这一不足,本文采用双层滑动窗口方法。内层采用滑动平均窗口平滑序列,减轻极端值和噪声的影响;外层采用多尺度窗口提取序列复杂的周期模式信息。本文采用傅里叶变换分析电、冷、热负荷的周期模式以确定外层窗口的尺度。经多次网格搜索,最终内层窗口设置为 3,外层窗口设置为 12 和 24。

2.2 自回归层

自回归由序列分解模块和全连接层构成,其作用包括 2 个方面:1)作为数据旁路,增强模型对线性信息的捕获能力,初步预测负荷;2)在测试时将梯度截断的预测结果反馈给 PCC 机制和 TPA 机制,辅助其完成序列相关性计算。该部分过程如下:

$$X_{\text{seasonal}}, X_{\text{trend}} = \text{Decomp}(X_{\text{input}}) \quad (5)$$

$$X_{\text{AR}} = \text{FeedForward}(X_{\text{seasonal}}) + \text{FeedForward}(X_{\text{trend}}) \quad (6)$$

式中: X_{input} 是数据的原始输入; X_{seasonal} 和 X_{trend} 分别为原始数据分解的周期项和趋势项; X_{AR} 为自回归层预测的输出。

2.3 PCC 层

2.3.1 PCC 机制

本文提出一种 PCC 机制以提取序列的周期信息,该机制由序列模式化部分和互相关分析部分组成,其结构如图 5 所示。该机制将序列抽象为模式,以减轻数据波动和噪声的干扰。通过分析输入序列的历史时滞数据与待预测序列之间的相关性,筛选出相关性较强的时刻,并将其视为潜在的周期点。

传统注意力机制通常采用向量点积计算序列中各个时刻的相关程度。然而,负荷数据包含大量噪声且波动性较强,向量点乘方法易受数值波动和分布差异的影响,难以有效捕获序列的关键时刻及周期性信息。波动数据验证如图 6 所示。数值分布不均数据验证如图 7 所示。

图 6(a)和图 7(a)分别展示了波动较大和数值分布差异较大的一组序列。在时间序列预测任务中,通常认为图 6(a)的序列 y_1 和序列 y_3 更相关,图 7(a)的序列 y_1 和序列 y_3 更相关,因为他们有更相似的周期和趋势,结果如图 6(c)和图 7(c)所示。图 6(a)中序列 y_2 是因为更大的值域在点积操作中,所以获得更高的相关性,由于数值分布和序列 y_1 更相近,因此图 7(a)序列 y_2 获得更高的相关性。这些情况表明,数值波动和数值分布会影响序列相关性的计算,导致结果与预期相悖。




图 5 模式互相关机制结构

Fig. 5 Structure of the pattern cross-correlation mechanism




图 6 波动数据验证

Fig. 6 Validation of fluctuating data




图 7 数值分布不均数据验证

Fig. 7 Validation of non-uniformly distributed numerical data

为此,本文从序列的变化趋势入手,将复杂的负荷数据抽象为模式数据以减轻数值波动和值域的影响,在此基础上,再采用向量点乘方法计算序列间的相关性。图 6(b)和图 7(b)为模式化后的数据,通过分析序列的趋势信息和数值信息,其结果如图 6(c)和图 7(c)所示,得到更准确的相关性判断结果。序列模式化模块将原始序列划分为加速下降、下降、稳定、上升、加速上升 5 种模式。对于序列 X ,其模式化过程如式(7)所示:

$$\tilde{X}_i = \text{dist}(X_i) = \begin{cases} -2, & X_i^{(1)} < 0 \text{ and } X_i^{(2)} < 0 \\ -1, & X_i^{(1)} < 0 \text{ and } X_i^{(2)} > 0 \\ 0, & X_i^{(1)} = 0 \\ 1, & X_i^{(1)} > 0 \text{ and } X_i^{(2)} < 0 \\ 2, & X_i^{(1)} > 0 \text{ and } X_i^{(2)} > 0 \end{cases},$$

$$i \in \{1, 2, \dots, L\}$$

(7)

式中: L 为序列长度; $X_i^{(1)}$ 和 $X_i^{(2)}$ 分别表示序列 X 第 i 个位置的一阶导数和二阶导数; $\tilde{X}_i$ 表示模式化后第 i 个位置的值; $\text{dist}(\cdot)$ 为模式化函数。

互相关理论可以计算 2 个序列在不同时刻的相关程度。通过分析输入序列在不同滞后期与待预测序列之间的互相关性,确定最相关的滞后时间,从而识别出输入序列中对预测最为关键的点。输入序列经线性变换生成查询向量 Q 、 K 和值向量 V 。 Q 与预测时刻数据 P 拼接以构建未来序列 $\tilde{Q}$ 。在模型测试时,待预测时刻的数据未知,因此采用自回归模块的初步预测数据进行替代。 K 通过在时间维度上滚动得到不同滞后的状态 $\tilde{K}$ 。该部分的过程如式(8)~式(11)所示:

$$[Q, K, V] = X[W_Q, W_K, W_V] \quad (8)$$

$$P = \text{detach}(X_{AR}) \quad (9)$$

$$\tilde{Q} = [q_{O+1}, q_{O+2}, \dots, q_L, p_1, \dots, p_O] \quad (10)$$

$$\tilde{K}_t = [k_{t+1}, k_{t+2}, \dots, k_L, k_1, \dots, k_t] \quad (11)$$

式中: X 为输入序列; W_Q, W_K, W_V 为线性变换矩阵; Q, K, V 为线性变换后的矩阵; $\text{detach}(\cdot)$ 为梯度截断函数; $P = [p_1, p_2, \dots, p_O]$ 为自回归层预测结果; X_{AR} 由梯度截断获得; O 为预测长度; $\tilde{Q}$ 是由 Q 和 P 拼接成的未来待预测序列; $\tilde{K}_t$ 表示 K 在时滞为 t 时的状态。

模式化 $\tilde{Q}$ 和 $\tilde{K}$ 计算在各个时滞下输入序列与待预测序列的相关性, 为每个时刻分配权重。采用 Softmax 函数计算权重前, 标准化数据以减轻极端值的影响, 其过程如式(12)和式(13)所示:

$$C_t = \frac{\text{dist}(\tilde{Q}) \cdot \text{dist}(\tilde{K}_t^T)}{\sqrt{d_{\text{model}}}}, t \in \{1, 2, \dots, L\} \quad (12)$$

$$\alpha = \text{Softmax}\left(\frac{C - C_\mu}{C_\sigma}\right) \quad (13)$$

式中: d_{model} 为矩阵 Q, K 的维度; C_t 表示时滞为 t 的输入序列与未来序列的相关程度; C_μ 和 C_σ 为 C 的均值和标准差; α 为计算得到的权重。

2.3.2 关键权重选择

并非所有的输入序列时刻都对预测有积极贡献。为减轻弱相关时刻对预测的影响, 本文挑选出 k 个相关性最高的值作为关键权重, 其余时刻的权重使用平均权重替代。

虽然上述模式化操作导致 Q 和 K 中的部分细节信息损失, 但序列的关键信息依然保留在值向量 V 中。当权重确定后, 将其与值向量 V 相乘, 得到模式互相关机制的输出。该部分如式(14)~式(16)所示:

$$\tau_1, \tau_2, \dots, \tau_k = \text{argtop-}k(\alpha) \quad (14)$$

$$\tilde{\alpha} = \begin{cases} \alpha_i = \{\alpha_1, \alpha_2, \dots, \alpha_L\}, & \text{if } i \in \{\tau_1, \tau_2, \dots, \tau_k\} \\ \alpha_{\text{mean}}, & \text{others} \end{cases} \quad (15)$$

$$X_{\text{PCC}} = \tilde{\alpha}V \quad (16)$$

式中: $\tau_1, \dots, \tau_k$ 表示最大的前 k 个权重对应的时刻; $\text{argtop-}k(\alpha)$ 表示获取权重的前 k 个值; α_{mean} 表示权重的均值; $\tilde{\alpha}$ 为最终得到的权重; X_{PCC} 为 PCC 层的输出。

2.3.3 PCC 层结构

PCC 机制整体基于编码器-解码器结构。其中, 编码器由多层堆叠而成, 每层包括序列分解模块、PCC 机制模块和前馈神经网络。不同的是, 本文的编码器需要接受自回归层的预测结果, 用于模型测

试时 PCC 机制序列相关性计算。此外, 编码器还会输出 PCC 机制学习到的权重分布, 为后续的线性变换提供参考。

解码器同样由多层堆叠而成, 每层包括序列分解模块、PCC 机制模块和前馈神经网络。在解码器后设有一个线性输出层。该线性输出层参考编码器得到的序列权重分布信息, 将序列映射到预测序列的长度, 得到编码器-解码器部分的预测结果。该过程如式(17)所示:

$$X_{\text{pred}} = \text{Softmax}(W_p + \lambda W_{\text{attn}}) \cdot X_{\text{dec}} \quad (17)$$

式中: X_{dec} 为 Decode 的输出, $X_{\text{dec}} \in \mathbb{R}^{L \times d_{\text{model}}}$; W_p 为可学习矩阵, $W_p \in \mathbb{R}^{O \times L}$; W_{attn} 为多个解码器中模式互相关机制得到的权重均值; λ 为可学习参数, $\lambda \in (0, 1)$; X_{pred} 为最终的预测结果, $X_{\text{pred}} \in \mathbb{R}^{O \times d_{\text{model}}}$ 。

2.4 TPA 层

除关键时刻信息和周期性信息以外, 历史数据中的某些连续时间段信息同样对预测起关键作用, 如待预测时刻前的一段数据或相似日同时段的数据。然而, 传统的注意力机制计算出的权重相对离散, 难以有效捕捉连续时段内部及其之间的相关性。

为此, 本文设计 TPA 机制提升模型对连续时间段信息的捕获能力, 作为 PCC 机制的补充。该机制根据待预测序列的长度将原始序列划分为多个子序列, 基于互信息理论分析不同子序列间的相关性并挑选出关键子序列。时序片段关联流程如图 8 所示。




图 8 时序片段关联

Fig.8 Temporal patch association

TPA 机制需要接受历史数据和待预测数据 2 个输入。历史数据根据预测长度划分为多个子序列,计算多个子序列与待预测序列间的互信息值,挑选相关性最高的 n 个序列作为关键子序列,并采用 Softmax 函数为其分配权重。序列 X 和 Y 间互信息的计算如式(18)所示:

$$I(X;Y) = \sum_{x \in X} \sum_{y \in Y} p_{x,y} \log_a \frac{p_{x,y}}{p_x p_y} \quad (18)$$

式中: $I(X;Y)$ 是 X 和 Y 的互信息值; $p_{x,y}$ 是 X 和 Y 的联合概率分布; p_x 是 X 的边缘概率分布; p_y 是 Y 的边缘概率分布。

对关键子序列加权后采用输入通道为 n , 输出通道为 1 的卷积层合并 n 个序列数据,获得 TPA 层的输出。该模块计算过程如式(19)~式(23)所示:

$$X_{i,i+O} = [x_i, x_{i+1}, \dots, x_{i+O}] \quad (19)$$

$$M = \text{argtop-}k(I(X_{i,i+O}; P)), \\ i \in \{1, 2, \dots, L-O\} \quad (20)$$

$$\tilde{X}_{\text{window}} = \{X_{i,i+O} | i \in M\} \quad (21)$$

$$\alpha = \{\text{Softmax}(I(X_{i,i+O}; P)) | i \in M\} \quad (22)$$

$$X_{\text{TPA}} = \text{Conv}(\alpha \cdot \tilde{X}_{\text{window}}) \quad (23)$$

式中: $X_{i,i+O}$ 为历史数据中第 i 个长度为 O 的子序列; M 记录了与预测序列互信息值最高的前 k 个关键子序列的位序信息; $\tilde{X}_{\text{window}}$ 记录了关键子序列信息; α 为关键子序列的权重; $\text{Conv}(\cdot)$ 为输入通道为 n , 输出通道为 1 的卷积层; X_{TPA} 为时序片段关联模块的输出。

3 实验

3.1 数据设置

本文采用美国亚利桑那州立大学坦佩校区公开的 IES 数据集和美国国家航空航天局(NASA)提供的气象数据集。数据集时间范围为 2019 年 1 月 1 日—2022 年 1 月 1 日,按 75%、25%的比例划分训练集和测试集。

本文实验使用 PyTorch2.0.1 框架进行训练,硬件配置为 Intel Core i7-9700H CPU 和 NVIDIA GeForce RTX 2080Ti GPU。

3.2 评估标准

为检验模型效果,本文选用均方根误差(RMSE, R_{RMSE})、平均绝对误差(MAE, R_{MAE})、平均绝对百分比误差(MAPE, R_{MAPE})、决定系数(R^2)作为模型的评估标准。具体来说, RMSE、MAE 和 MAPE 的值越小,表示预测值与真实值之间的差异

越小,预测精度越高; R^2 的值越接近 1,表示模型的拟合效果越好。各项评估指标的计算过程如式(24)~式(27)所示:

$$R_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2} \quad (24)$$

$$R_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_i - y'_i| \quad (25)$$

$$R_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y'_i}{y_i} \right| \times 100\% \quad (26)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - y'_i)^2}{\sum_{i=1}^N (y_i - \bar{y}')^2} \quad (27)$$

式中: y_i 为实际负荷值; y'_i 为预测负荷值; $\bar{y}'$ 为 y' 平均值; N 为序列长度;

3.3 消融实验

为验证 PCC-TPA 机制各模块改进的有效性,本文设计多个对比模型,根据各模型在电、冷、热负荷上的实验结果进行分析评估。

模型 1 作为基础模型,在特征选择部分采用 Spearman 秩相关函数选择特征,数据嵌入采用 token 嵌入,嵌入维度为 512,网络模型采用如图 4 所示的结构,但将 PCC 模块替换为自注意力机制模块,编码器为 2 层,解码器为 1 层。模型 2 在模型 1 的基础上添加 1.2 节所提的多元特征交叉滞后分析模块,分别对电、冷、热负荷数据进行交叉滞后分析、数据重构和嵌入。模型 3 使用 PCC 机制替换自注意力机制, PCC 机制的关键权重参数经多次网格搜索获得,最终设置为 33。模型 4 在模型 3 的基础上添加 TPA 模块,经多次实验分析,关键子序列数量设置为 33。

各个模型在测试集上的实验结果如表 2 所示,加粗表示最优数据(下同)。冷负荷对气象变化的敏感性较高,通过引入交叉滞后分析模块,模型 2 能够有效捕捉外界因素对冷负荷影响的滞后效应,提高预测的准确性,其 RMSE 和 MAPE 指标相对于基础模型分别降低了 6.79% 和 9.04%。模型 3 采用 PCC 机制替换自注意力机制后,各类型负荷的预测精度均有所提升。其中,相比模型 1 电、冷、热负荷的 RMSE 指标分别下降了 12.18%、13.74% 和 12.12%。这是因为 PCC 机制的序列模式化模块有效减弱了噪声和异常值对关键时刻识别的干扰。此外, PCC 的互相关机制和关键权重筛选机制与自注意力机制相比,在缓解权重长尾分布问题上表现更优,能够更准确地

识别关键时刻及周期性信息。在模型 3 的基础上,模型 4 引入 TPA 机制,进一步增强模型对局部连续信息的捕获能力。引入 TPA 机制后,电、

冷、热负荷的预测精度均有所提升。相比基础模型,其 RMSE 指标分别下降了 15.88%、13.81%和 13.64%。

表 2 消融实验结果

Table 2 Ablation experiment results

对比模型	电负荷			冷负荷			热负荷		
	RMSE	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE	MAE	MAPE/%
模型 1	1 429.81	1 044.08	5.84	601.33	425.07	7.53	0.66	0.42	7.00
模型 2	1 378.45	997.67	5.57	560.47	392.16	6.85	0.65	0.41	6.84
模型 3	1 255.53	918.72	5.24	518.68	361.04	6.30	0.58	0.35	5.75
模型 4	1 202.70	877.36	5.06	518.31	354.00	6.10	0.57	0.34	5.65

3.4 PCC 机制验证

为验证 PCC 机制在关键时刻及周期模式信息识别方面的有效性,本文对比了自注意力机制和 PCC 机制学习到的权重。以测试集第 1 个窗口的冷负荷数据为例,图 9 和图 10 分别展示了自注意力机制和 PCC 机制学习到的序列权重信息。




图 9 自注意力机制权重分布

Fig.9 Weight distribution of the self-attention mechanism

图 9 和图 10 中由浅色到深色表示模型学习到的权重占比程度。自注意力机制的权重几乎全部聚集到待预测时刻的前 24 个小时内,出现较为严重的权重长尾分布情况,忽略了大部分的时刻信息。相比之下,PCC 机制采用序列模式化和互相关分析,有效减轻了数据波动和数值分布差异对相关性计算




图 10 PCC 机制权重分布

Fig.10 Weight distribution of the PCC mechanism

的干扰,更精准地识别到历史数据中的日周期模式等关键时刻信息,有效验证 PCC 机制在关键时刻及周期信息识别与提取方面的有效性。

3.5 预测模型对比

本文将 PCC-TPA 预测方法与当前主流预测方法对比,进行 5 次重复实验并取平均值作为最终实验结果。为最大限度地保证对比实验的公平性,实验过程中的数据预处理、数据嵌入等步骤采用相同的处理方法,为不同模型设置同级别的超参数,各模型主要参数设置如表 3 所示。为验证本文所提模型的有效性,本文分别从电、冷、热负荷预测 3 个方面对模型性能进行深入分析。

表 3 各模型主要参数

Table 3 Key parameters of each model

模型	主要参数设置
PCC-TPA	d_{model} 为 512; n_{head} 为 8; out_window 为 [12,24]
Autoformer	d_{model} 为 512; n_{head} 为 8; move window 为 25; top- k 为 5
Informer	d_{model} 为 512; n_{head} 为 8; attn=prod
Reformer	d_{model} 为 512; n_{head} 为 8; bucket_size 为 21; n_{hashes} 为 4
LSTM	LSTM layers 为 3; hidden_size 为 512
TCN-GRU	TCN layers 为 4; kernel size 为 2; channels=[512,2048,2048,512]

电力负荷受多种因素影响,波动性强且包含较多噪声,预测相对困难。电负荷在测试集上的预测效果

如表 4 所示。图 11 和图 12 分别为测试集中夏季和冬季某周的电负荷预测效果。从图 11 和图 12 可知,

预测误差主要发生在电负荷突然波动的时刻。相比其他模型,PCC-TPA 模型通过 PCC 机制,能极大减轻数据波动和随机噪声的影响,提取准确的周期模式信息,更好地拟合波动位置的负荷。此外,TPA 机制能有效捕获突变位置一段时间内的信息,快速反应并跟踪负荷的变化。结合表 4 可知,相较于对比模型,PCC-TPA 模型在各项评估指标上均有所提升,其中 RMSE 指标分别下降了 10.46%、34.86%、51.03%、31.59%和 31.84%,具有最佳的预测精度。

表 4 各模型电负荷预测误差

Table 4 Prediction errors of electric loads for each model

预测模型	RMSE	MAE	MAPE/%	R ²
Autoformer	1 343.225 1	968.363 1	5.61	0.916 9
Informer	1 846.323 6	1 402.103 9	7.82	0.843 0
Reformer	2 456.083 2	1 931.978 9	11.26	0.722 2
TCN-GRU	1 758.205 1	1 347.939 6	7.62	0.857 6
LSTM	1 764.464 8	1357.315 8	7.82	0.856 6
PCC-TPA	1 202.703 4	877.360 8	5.06	0.933 4




图 11 电负荷夏季预测结果

Fig.11 Summer prediction results of electrical loads




图 12 电负荷冬季预测结果

Fig.12 Winter prediction results of electrical loads

表 5 为冷负荷在测试集上的预测结果。冷负荷主要用于空调系统、制冷设备等方面,对气象因素较为敏感且易受人类作息规律影响。冷负荷的典型时期主要在夏季,图 13 为测试集中夏季某周的冷负荷预测结果。从图 13 可以看出,PCC-TPA 模型能更准确地预测冷负荷的整体变化趋势,精确拟合波峰和波谷位置,避免出现预测偏高或偏低的情况。分析表 5 和图 13 可知,PCC-TPA 模型通过交叉滞后分析,选择并嵌入与冷负荷最相关时刻的输入特征,提升了整体预测精度,其 MAPE 指标相较于对比模型分别提升了 19.20%、58.16%、79.37%、55.8%和 50.76%,

展现出较强的预测准确性和实际应用价值。

表 5 各模型冷负荷预测误差

Table 5 Prediction errors of cooling loads for each model

预测模型	RMSE	MAE	MAPE/%	R ²
Autoformer	570.484 7	413.052 8	7.55	0.978 5
Informer	1121.455 2	852.450 3	14.58	0.916 8
Reformer	1786.322 0	1427.592 3	29.58	0.788 9
TCN-GRU	1098.848 6	819.561 1	13.79	0.920 1
LSTM	843.507 7	646.036 5	12.39	0.952 9
PCC-TPA	518.311 4	354.001 5	6.10	0.982 2




图 13 冷负荷预测结果

Fig. 13 Prediction results of cooling load

表 6 为热负荷在测试集上的预测结果,热负荷的典型时期主要在冬季。图 14 为测试集上冬季某周的热负荷预测结果。从图 14 可以看出,对比模型在日间预测中对第 2 个小波峰的预测存在峰值偏高或偏低的问题。相比之下,PCC-TPA 模型借助 TPA 机制,能有效捕获日内连续信息,展现出较强的追踪能力,能准确地预测日间多处波峰和波谷位置的负荷。相较于最优对比模型,本文模型的 RMSE 和 MAPE 指标分别下降了 7.05% 和 10.52%,具有最优的预测精度。

表 6 各模型热负荷预测误差

Table 6 Prediction errors of heating loads for each model

预测模型	RMSE	MAE	MAPE/%	R^2
Autoformer	0.614 7	0.379 1	6.31	0.936 3
Informer	0.949 4	0.660 2	11.24	0.848 0
Reformer	1.433 8	1.046 1	17.93	0.653 4
TCN-GRU	0.752 3	0.535 1	9.43	0.904 6
LSTM	0.800 7	0.560 1	9.58	0.891 9
PCC-TPA	0.571 3	0.341 6	5.65	0.945 0




图 14 热负荷预测结果

Fig. 14 Prediction results of heating load

4 结束语

针对综合能源负荷随机噪声多、波动性强、周期模式复杂的问题,本文提出一种基于 PCC-TPA 机制的预测方法。外界因素变化对综合能源负荷具有滞后效应,基于交叉滞后关系进行特征筛选和嵌入,可以有效提升负荷预测的准确性。此外,序列模式化操作显著减轻了数据波动和噪声对相关计算的影响,使 PCC 机制在识别和提取序列

关键时刻信息及周期信息方面表现出更高的精度。同时,TPA 机制通过分析子序列内部及其间的关系,能够有效捕获预测前时段和相似日等关键信息,进一步增强模型对序列连续信息的提取能力。多项消融实验和对比实验结果表明,该方法在多元负荷预测任务中有更高的预测精度。后续将在数据处理与分析阶段考虑经济发展水平、电价等外部因素,为模型提供更全面的参考信息,以提高预测精度。

参考文献

- [1] 史佳琪, 谭涛, 郭经, 等. 基于深度结构多任务学习的园区型综合能源系统多元负荷预测[J]. 电网技术, 2018, 42(3): 698-707.
SHI J Q, TAN T, GUO J, et al. Multi-task learning based on deep architecture for various types of load forecasting in regional energy system integration [J]. Power System Technology, 2018, 42(3): 698-707. (in Chinese)
- [2] 叶剑华, 曹旌, 杨理, 等. 基于变分模态分解和多模型融合的用户级综合能源系统超短期负荷预测[J]. 电网技术, 2022, 46(7): 2610-2622.
YE J H, CAO J, YANG L, et al. Ultra short-term load forecasting of user level integrated energy system based on variational mode decomposition and multi-model fusion [J]. Power System Technology, 2022, 46 (7): 2610-2622. (in Chinese)
- [3] LIU Y J, LI Y, LIU G L, et al. Review of multiple load forecasting method for integrated energy system [J]. Frontiers in Energy Research, 2023, 11: 101-120.
- [4] ZHANG J Z, DONG H J, ZHANG W Y, et al. Review and prospect of data-driven techniques for load forecasting in integrated energy systems [J]. Applied Energy, 2022, 321: 119269.
- [5] 邓带雨, 李坚, 张真源, 等. 基于 EEMD-GRU-MLR 的短期电力负荷预测[J]. 电网技术, 2020, 44(2): 593-602.
DENG D Y, LI J, ZHANG Z Y, et al. Short-term electric load forecasting based on EEMD-GRU-MLR [J]. Power System Technology, 2020, 44(2): 593-602. (in Chinese)
- [6] ANTONIO B, PIERLUIGI C, PASQUALE F D, et al. Multivariate quantile regression for short-term probabilistic load forecasting [J]. IEEE Transactions on Power Systems, 2020, 35(1): 628-638.
- [7] 万灿, 崔文康, 宋永华. 新能源电力系统概率预测: 基本概念与数学原理[J]. 中国电机工程学报, 2021, 41(19): 6493-6509.
WAN C, CUI W K, SONG Y H. Probabilistic forecasting for power systems with renewable energy sources: basic concepts and mathematical principles [J]. Proceedings of CSEE, 2021, 41(19): 6493-6509. (in Chinese)
- [8] JASON R, ETIENNE S. A comparison of prediction and forecasting artificial intelligence models to estimate the future energy demand in a district heating system [J]. Energy, 2023, 269: 126661.
- [9] 史佳琪, 张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报, 2019, 39(14): 4032-4041.
SHI J Q, ZHANG J H. Load forecasting based on multi-model by Stacking ensemble learning [J]. Proceedings of the CSEE, 2019, 39(14): 4032-4041. (in Chinese)
- [10] 王伟, 冯斌, 黄刚, 等. 基于自注意力编码器和深度神经网络的短期净负荷预测[J]. 中国电机工程学报, 2023, 43(23): 9072-9084.
WANG W, FENG B, HUANG G, et al. Short-term net load forecasting based on self-attention encoder and deep neural network [J]. Proceedings of the CSEE, 2023, 43 (23): 9072-9084. (in Chinese)
- [11] 李丹, 孙光帆, 缪书唯, 等. 基于多维时序信息融合的短期电力负荷预测方法[J]. 中国电机工程学报, 2023, 43(S1): 94-106.
LI D, SUN G F, MIAO S W, et al. A short-term power load forecasting method based on multidimensional temporal information fusion [J]. Proceedings of the CSEE, 2023, 43(S1): 94-106. (in Chinese)
- [12] NADA M, HAMID O, ISMAEL J. Short-term electric load forecasting using an EMD-BI-LSTM approach for smart grid energy management system [J]. Energy and Buildings, 2023, 288: 113022.
- [13] LIU H X, SHEN X D, TANG X S, et al. Day-ahead electricity price probabilistic forecasting based on SHAP feature selection and LSTNet quantile regression [J]. Energies, 2023, 16(13): 101-109.
- [14] 王琛, 王颖, 郑涛, 等. 基于 ResNet-LSTM 网络和注意力机制的综合能源系统多元负荷预测[J]. 电工技术学报, 2022, 37(7): 1789-1799.
WANG C, WANG Y, ZHENG T, et al. Multi-energy load forecasting in integrated energy system based on ResNet-LSTM network and attention mechanism [J]. Transactions of China Electrotechnical Society, 2022, 37 (7): 1789-1799. (in Chinese)
- [15] CAI C C, LI Y J, SU Z H, et al. Short-term electrical load forecasting based on VMD and GRU-TCN hybrid network [J]. Applied Sciences, 2022, 12(13): 6647.
- [16] CHEN W H, HAN G J, ZHU H B, et al. Short-term load forecasting with an ensemble model using densely residual block and Bi-LSTM based on the attention mechanism [J]. Sustainability, 2022, 14(24): 16433.
- [17] QIN Y, LU Z Y, LIU H, et al. An improved feature-time Transformer encoder-Bi-LSTM for short-term forecasting of user-level integrated energy loads [J]. Energy & Buildings, 2023, 297: 113396.
- [18] WU H X, XU J H, WANG J M, et al. Autoformer: decomposition Transformers with auto-correlation for long-term series forecasting [EB/OL]. [2024-10-01]. <https://arxiv.org/pdf/2106.13008>.
- [19] CEN S F, LIM C G. Multi-task learning of the PatchTCN-TST model for short-term multi-load energy forecasting considering indoor environments in a smart building [J]. IEEE Access, 2024, 12: 19553-19568.
- [20] 鲁斌, 霍泽健, 俞敏. 基于 LSTNet-Skip 的综合能源系统多元负荷超短期预测[J]. 中国电机工程学报, 2023, 43(6): 2273-2283.
LU B, HUO Z J, YU M. Multi load ultra short-term forecasting of integrated energy system based on LSTNet-Skip [J]. Proceedings of the CSEE, 2023, 43 (6): 2273-2283. (in Chinese)
- [21] ZUO C H, WANG J L, LIU M P, et al. An ensemble framework for short-term load forecasting based on TimesNet and TCN [J]. Energies, 2023, 16(14): 5330.
- [22] 石卓见, 冉启武, 徐福聪. 基于聚合二次模态分解及 Informer 的短期负荷预测[J]. 电网技术, 2023, 48(6): 2574-2583.
SHI Z J, RAN Q W, XU F C. Short-term load forecasting based on aggregated secondary decomposition and Informer [J]. Power System Technology, 2023, 48(6): 2574-2583. (in Chinese)
- [23] NIU D X, YU M, SUN L J, et al. Short-term multi-energy load forecasting for integrated energy systems based on CNN-BiGRU optimized by attention mechanism [J]. Applied Energy, 2022, 313: 118801.
- [24] HE F F, ZHOU J Z, FENG Z K, et al. A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm [J]. Applied Energy, 2019, 237: 103-116.
- [25] 李云松, 张智晟. 基于 GRU-TGTransformer 的综合能源系统多元负荷短期预测[J]. 电力系统保护与控制, 2023, 51(15): 33-41.
LI Y S, ZHANG Z S. Multi load short-term forecasting of an integrated energy system based on a GRU-TGTransformer [J]. Power System Protection and Control, 2023, 51(15): 33-41. (in Chinese)
- [26] 李鹏, 罗湘淳, 孟庆伟, 等. 基于 Spearman 相关性阈值寻优和 VMD-LSTM 的用户级综合能源系统超短期负荷预测[J]. 全球能源互联网, 2024, 7(4): 406-420.
LI P, LUO X C, MENG Q W, et al. Ultra short-term load

- forecasting of user level integrated energy system based on Spearman threshold optimization and variational mode decomposition, and long short-term memory [J]. Journal of Global Energy Interconnection, 2024, 7(4): 406-420. (in Chinese)
- [27] 张大海, 杨宇辰, 刘艳梅, 等. 基于 EMD 与 Spearman 相关系数的混合直流线路纵联保护方法[J]. 电力系统保护与控制, 2021, 49(9): 1-11.
ZHANG D H, YANG Y C, LIU Y M, et al. Hybrid HVDC line pilot protection method based on EMD and Spearman correlation coefficient [J]. Power System Protection and Control, 2021, 49(9): 1-11. (in Chinese)
- [28] ZHENG X Y, CHEN Q Q, SUN M C, et al. Exploring the influence of environmental indicators and forecasting influenza incidence using ARIMAX models [J]. Frontiers in Energy Research, 2024, 12: 1441240.
- [29] 管奔, 臧勇, 吴迪平. 基于互相关函数的轧机振动传递时间滞后分析[C]//第七届中国钢铁年会. 北京: 冶金工业出版社, 2009: 345-350.
GUAN B, ZANG Y, WU D P. Study of delay time of transfer of rolling mill vibration based on cross-correlation function[C]//Proceedings of the 7th China Steel Annual Conference. Beijing: Metallurgical Industry Press, 2009: 345-350. (in Chinese)

文字编辑 薛晋栋
栏目编辑 赖玉玲