

面向非平稳热负荷序列的多模态分解与 双路径预测框架

杨 博¹, 李晨晓¹, 徐嘉骋¹, 刘长良²

(1. 国能宁夏供热有限公司, 宁夏 银川 750001; 2. 华北电力大学 控制与计算机工程学院, 北京 102206)

摘 要:为解决因受天气变化、季节波动、设备故障等多因素影响的热负荷数据非平稳性和噪声干扰问题,应对传统预测模型在该场景下预测精度不足的挑战,提出一种基于 CEEMDAN 分解、PatchTST-iTransformer 双分支建模及 Bagging 融合的混合模型框架。通过 CEEMDAN 将热负荷数据分解为多个本征模态函数(IMF),以抑制非平稳性和噪声;利用 PatchTST 的分块策略与自注意力机制捕捉数据多尺度依赖,处理长期周期性和短期局部波动;借助 iTransformer 调整 IMF 分量的注意力权重,减少预测误差累积,并增强多分量信号融合能力;通过 Bagging 策略提升模型鲁棒性。预测结果表明,该模型在热负荷预测任务中 MSE 和 MAE 分别低至 0.007 6 和 0.195 6,较 TSMixer, LSTM, DLinear, Transformer 和 Informer 模型降低了 45%~70% 的预测误差,大幅提升了预测精度与稳定性。

关 键 词:热负荷预测;非平稳时间序列;模态分解;注意力机制

中图分类号:TP18;TU995

文献标识码:A

DOI:10.16146/j.cnki.rndlgc.2025.11.021

[引用本文格式]杨 博,李晨晓,徐嘉骋,等.面向非平稳热负荷序列的多模态分解与双路径预测框架[J].热能动力工程,2025,40(11):191-198. YANG Bo, LI Chenxiao, XU Jiacheng, et al. A multi-modal decomposition and dual-path prediction framework for non-stationary heat load time series[J]. Journal of Engineering for Thermal Energy and Power, 2025, 40(11):191-198.

A Multi-Modal Decomposition and Dual-Path Prediction Framework for Non-Stationary Heat Load Time Series

YANG Bo¹, LI Chenxiao¹, XU Jiacheng¹, LIU Changliang²

(1. National Energy Ningxia Heating Co., Ltd., Yinchuan, China, Post Code: 750001;

2. School of Control and Computer Engineering, North China Electric Power University, Beijing, China, Post Code: 102206)

Abstract: To address the non-stationarity and noise interference in heat load data caused by weather changes, seasonal fluctuations, equipment failures, and other factors, as well as the challenge of insufficient prediction accuracy of traditional prediction models in this scenario, a hybrid model framework based on CEEMDAN decomposition, PatchTST-iTransformer dual branch modeling and Bagging fusion was proposed. CEEMDAN was used to decompose the heat load data into multiple intrinsic mode functions (IMFs) to suppress non-stationarity and noise; PatchTST's block strategy and self-attention mechanism were utilized to capture multi-scale dependencies in the data, handling long-term periodicity and short-term local fluctuations; iTransformer was employed to adjust the attention weights of the IMF components, reducing the accumulation of prediction errors and enhancing the fusion ability of multi-component signals; and the Bagging strategy was adopted to improve the robustness of model. Prediction results show that the model achieves mean-square error (MSE) and mean absolute error (MAE) as low as 0.007 6

收稿日期:2025-06-08; 修订日期:2025-07-11

基金项目:国能宁夏供热有限公司项目(NXDL-2024-44)

Fund-supported Project: The Project of National Energy Ningxia Heating Co., Ltd. (NXDL-2024-44)

作者简介:杨 博(1990-),男,国能宁夏供热有限公司初级工程师。

通信作者:刘长良(1966-),男,华北电力大学教授。

and 0.195 6 respectively in the heat load prediction task, reducing the prediction errors by 45% to 70% compared with TSMixer, LSTM, DLinear, Transformer and Informer models, and significantly improving prediction accuracy and stability.

Key words: heat load prediction, non-stationary time series, modal decomposition, attention mechanism

引 言

随着区域能源管理的迅速发展,热负荷预测作为关键的决策支持工具,广泛应用于能源调度、需求响应和负荷平衡等领域^[1-3]。准确的预测不仅有助于动态调控区域能源供给,提高能源利用效率,降低能源成本,还能提升供给系统的稳定性。

但是,热负荷数据本身受多种因素的影响,不仅具有长期的周期性变化,还常包含短期的局部波动^[4]。现有研究往往侧重于某一类特征的建模,忽视了数据的复杂特性,这使得模型在面对这些变化时往往反应迟钝,难以快速适应新的变化模式^[5-6]。此外,采用如自适应噪声完备集合经验模态分解 CEEMDAN 等信号分解方法时,分解出的本征模态函数(IMF)需要分别进行预测,而这些单独预测的误差可能会相互累积,导致最终的预测结果偏差^[7-9]。尽管近年来兴起的 Transformer 模型^[10-12]在处理时间序列数据方面具有较高的建模能力,但其计算复杂度较高,尤其在长序列的处理上存在巨大的计算开销,难以满足实时预测的要求^[13]。

为了解决这些问题,本研究创造性地结合了 CEEMDAN^[14]、PatchTST^[15] 模型、iTransformer^[16] 模型和 Bagging^[17] 融合策略,分别针对数据的多尺度特性进行建模。不同于常规分解后直接建模的模式,先通过 CEEMDAN 的噪声辅助递归分解机制,将热负荷数据自适应转化为多尺度平稳 IMF 分量,既解决传统 EMD 模态混叠问题,又为后续精准建模提供结构化数据基础;创新性引入 PatchTST 的序列分块与自注意力协同机制,不再依赖单一尺度特征捕捉,而是同步挖掘热负荷的长期周期性变化与短期局部动态波动,弥补传统模型对多尺度依赖建模不充分的缺陷;进一步设计 iTransformer 的实例依赖型分词与注意力权重动态调整模块,摒弃各 IMF 分量预测结果简单拼接的方式,通过自适应优化分量重要性权重,从机制上抑制独立预测带来的误差累积,强化多分量信号的深度融合效果;最后通过

Bagging 策略对双分支输出进行针对性加权集成,并非采用普通集成的泛化处理,而是精准匹配 PatchTST 局部-全局建模与 iTransformer 分量融合的互补优势,形成从数据预处理到建模融合的全流程创新设计,为非平稳热负荷序列的高精度、高稳定预测提供突破性技术路径。

1 多模态分解与双路径预测框架

1.1 多扰动分解与去噪预处理

在热负荷预测中,原始时间序列通常受到天气变化、用户行为和季节性波动等多重因素影响,呈现出显著的非平稳性与高噪声特性。这种复杂信号结构使得传统 EMD 经验模态分解在应用中面临模态混叠、端点效应严重、分解不彻底等问题,进而导致后续建模的精度下降^[18]。

本研究引入了 CEEMDAN 模态分解作为模型前端的多扰动预处理机制。图 1 为 CEEMDAN 算法流程,该方法在传统经验模态分解(EMD)基础上,通过多次加入小幅度白噪声并进行集合平均,有效缓解了模态混叠、端点效应严重及分解不完备等问题,提升了信号分解的稳定性与可解释性。




图 1 CEEMDAN 算法流程图

Fig. 1 Flowchart of CEEMDAN algorithm

CEEMDAN 通过在每步递归过程中引入小幅度的白噪声扰动,显著提高了分解的稳定性和完备性。具体而言,其分解流程可分为如下两个阶段:

(1) 初始 IMF 提取

对于原始热负荷信号 $x(t)$, 首先进行多次独立白噪声扰动, 每一次扰动发生 $i = 1, \dots, N$, 都会构造如下信号:

$$x(t) \leftarrow x(t) + \varepsilon \omega_i(t) \quad (1)$$

式中: ε —强度系数; $\omega_i(t)$ —独立同分布的白噪声, 起到控制噪声规模的作用。随后, 对每个 $x_i(t)$ 分别施加 EMD 分解, 提取其首个本征模态函数 IMF $c_{i,1}(t)$ 。最终, 对所有扰动样本的第一 IMF 取均值, 得到整体的第一 IMF:

$$c_1(t) = \frac{1}{N} \sum_{i=1}^N c_{i,1}(t) \quad (2)$$

(2) 递归分解后续 IMF

提取第 k 个 IMF 时, 首先计算当前残差信号:

$$r_{k-1}(t) = x(t) - \sum_{j=1}^{k-1} c_j(t) \quad (3)$$

随后, 对每次扰动 i , 在残差 $r_{k-1}(t)$ 上叠加独立白噪声, 得到扰动残差 $r_{k-1,i}(t)$, 并添加 EMD 提取的第一 IMF, 即 $c_{i,k}(t)$ 。所有扰动样本的 IMF 取平均值, 得到第 k 个 IMF:

$$c_k(t) = \frac{1}{n} \sum_{i=1}^n c_{i,k}(t) \quad (4)$$

上述过程递归进行, 直至残差信号 $r_k(t)$ 转化为单调趋势或不再含有极值点。

通过这种噪声辅助、集合平均的方法, CEEMDAN 有效克服了单次分解的不稳定性和模态混叠问题, 同时保证了分解的完备性, 即所有 IMF 与最终残差之和能够精确重构原始信号。这一特性在热负荷预测场景中尤为关键, 可显著提升后续建模阶段对局部变化(如早晚峰值)、周期性成分(日、周、季节波动)及长期趋势的捕捉能力。

在本研究的整体网络模型结构中, 经过 CEEMDAN 处理后的各 IMF 分量(包括高频噪声成分与低频趋势成分)将分别输入到后续的 PatchTST 和 iTransformer 模型中进行独立建模。

1.2 多尺度依赖建模与局部模式提取

本研究同时引入了基于 PatchTST 架构的局部

—全局联合建模方法, 如图 2 所示。PatchTST 结合了局部片段建模与 Transformer 的全局依赖捕捉能力, 能够有效提取热负荷时间序列中的多尺度特征信息, 从而实现对未来热负荷的高精度多步预测, 有效提升模型在复杂供热工况下的预测准确性和鲁棒性。




图 2 PatchTST 结构图

Fig. 2 Structure diagram of PatchTST

首先, 利用 Patch 进行分割与嵌入, 将输入的多变量热负荷历史序列 $X \in R^{L \times C}$ (其中 L, C 分别是时间跨度和特征维度) 划分为若干个互不重叠的局部 patch, 每个 patch 的长度为 p , 划分后得到 patch 的数量为 $N = \lceil \frac{L}{p} \rceil$ 。划分后的数据表示为:

$$X = [P_1, P_2, \dots, P_N] \quad (5)$$

式中: 每个 $P_i \in R^{p \times C}$ 。

随后, 用线性映射将每个 patch 编码为固定维度 D 的特征向量:

$$z_i = \text{Linear}(P_i), z_i \in R^D \quad (6)$$

最终得到的 patch 序列为:

$$Z = [z_1, z_2, \dots, z_N] \in R^{N \times D} \quad (7)$$

在此基础上增加可学习的位置编码信息以保留时间顺序性:

$$Z \leftarrow Z + PE \quad (8)$$

其次, 利用 Transformer 编码, 将上一步的结果序列 Z 输入给堆叠的 Transformer Encoder 模块中。每一层 Encoder 包含多头注意力机制(MHSA)、前馈神经网络(FFN)以及标准的残差连接与层归一化(Residual + LayerNorm)结构, 其基本变换公式为:

$$Z' = \text{TransformerLayer}(Z) \tag{9}$$

多头注意力 MHSA 的公式为:

$$\text{Attention}(Q,K,V) = \text{softmax}\left(\frac{QK^T}{\sqrt{D}}\right)V \tag{10}$$

式中:Attention—自注意机制的计算过程; Q —查询; K —键; V —值; Q,K,V 分别由输入 Z 经过线性映射获得。

PatchTST 通过自注意力机制在 patch 级别捕获长距离跨 patch 的依赖关系,从而实现长期趋势的建模,同时由于 patch 本身包含局部连续时间步的信息,也保留了细粒度的局部动态特征。

最后通过 HEAD 输出,Transformer 编码后特征 的表示经简单映射后输出未来预测结果,形式为:

$$\hat{y} \in R^{O \times D} = \text{FFN}(Z') \tag{11}$$

式中: O —预测步长,与输入维度 D 保持一致。

1.3 多分量信号融合与误差抑制

在基于 CEEMDAN 分解的热负荷预测任务中,原始时间序列被分解为若干 IMF 分量。每个 IMF 分量捕捉了不同频率层次的动态变化,理论上有助于模型更细致地理解数据的多尺度特性。然而,在实际应用中,由于各 IMF 分量需要分别建模与预测,其独立误差的累积常常导致最终重构热负荷序列时出现显著偏差,影响整体预测精度和稳定性。为有效缓解这一问题,本研究引入 iTransformer 结构,如图 3 所示。




图 3 iTransformer 结构图

Fig. 3 Structure diagram of iTransformer

通过引入实例依赖型分词(Instance-Dependent Tokenization)机制,自适应地对各 IMF 分量进行特征重组,并利用 Transformer 编码器对多分量特征进行统一建模,从而在建模过程中动态调整各 IMF 分量的重要性,削弱局部预测误差对整体结果的累积效应。

细节上来说,iTransformer 首先对输入的序列 X 添加数据驱动的局部聚合方法 $f(\cdot)$,将长序列压缩成更短的、局部特征更强烈的 Token 序列:

$$T \in R^{N \times D} = f(X) \tag{12}$$

式中: T —生成的 Token 序列; N —Token 的数量; D —每个 Token 的特征维度。

随后,生成的 Token 序列 T 被送入标准的 Transformer Encoder 中进行深度建模。该 Encoder

首先通过 MHSA 计算各 Token 之间的相互依赖关系,捕捉跨 IMF 分量以及不同时间尺度间的复杂交互模式。

在完成注意力建模后,输出特征经过标准的前馈神经网络 FFN 进行进一步的非线性增强:

$$Z = \text{FFN}(x) = \text{ReLU}(xW_1 + b_1)W_2 + b_2 \tag{13}$$

式中: W_1, W_2 —可学习的权重矩阵; b_1, b_2 —可学习的偏置项。

1.4 基于 Bagging 的分支融合

在完成两个分支 PatchTST 与 iTransformer 的独立建模后,为了充分发挥各自对于热负荷数据不同特征层面的建模优势,本研究基于 Bagging 思想的简单融合策略对两路预测结果进行集成。考虑到 PatchTST 更擅长捕捉局部动态与周期性变化,而

iTransformer 则在跨分量建模与异常动态捕捉方面具有优势,通过对两个分支的 HEAD 输出进行加权平均,可以在一定程度上互补不同建模策略的偏差,提升整体预测的稳定性与泛化能力。

设 PatchTST 分支的预测输出为 $\hat{y}^{(1)}$,iTransformer 分支的预测输出为 $\hat{y}^{(2)}$,最终的融合预测结果 $\hat{y}$ 为:

$$\hat{y} = \frac{1}{2}(\hat{y}^{(1)} + \hat{y}^{(2)})$$

(14)

式中: $\hat{y}$ —最终预测结果; $\hat{y}^{(1)}$ —PatchTST 分支的预测结果; $\hat{y}^{(2)}$ —iTransformer 分支的预测结果。

2 实验方法

2.1 实验设置

本研究选取国能宁夏供热有限公司某供热区域综合能源系统的热负荷数据作为实验对象,如图 4 所示,数据采样间隔为 1 h,总计包含 8 760 条记录,覆盖全年完整的时间范围。数据格式包括时间信息及对应时刻的热负荷值,具有显著的季节性波动与非平稳特征,能够真实反映区域综合能源系统的运行负荷状态。在进行数据分析之前对热负荷数据集进行清洗,去除噪声或离群值。数据集无缺失数据,分别采用线性插值和 3σ 法则填充和检测离群值。本研究实验过程中,以时间为单位划分了训练集、验证集和测试集,各子集占整体的时间比例为 70%,10% 和 20%。训练集为 1 月 1 日至 9 月 12 日,验证集为 9 月 13 日至 10 月 19 日,测试集为 10 月 20 日至 12 月 31 日。对划分后的数据进行归一化处理,并进行时间序列滑窗。




图 4 热负荷数据图

Fig.4 Data graph of heat load

2.2 评价指标

为了评价 CEEMDAN-PatchTST-iTransformer 模型的预测性能,采用均方误差(MSE)和平均绝对误差(MAE)作为模型评价指标。相关公式如下:

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2$$

(15)

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i|$$

(16)

式中: $\hat{y}_i$ —热负荷的预测值; y_i —热负荷的实际值。

2.3 CEEMDAN 分解实验

为有效抑制热负荷序列中非平稳性和噪声带来的影响,将热负荷数据进行 CEEMDAN 算法分解。选取 1 000 个采样点的分解结果做可视化处理,原始热负荷和分解结果如图 5 所示。




图 5 CEEMDAN 分解结果

Fig.5 Result of CEEMDAN decomposition

在图 5 中,IMF1 分量波动频繁且幅度小,反映

瞬间扰动或测量噪声等高频随机波动。IMF2 ~ IMF4 在数据波动方面具有相似的周期性和复杂程度,数据水平对称,一定程度上展现了供热负荷的规律性。IMF5 ~ IMF6 波动平缓,周期长,IMF6 近似趋势项,体现热负荷随时间的总体变化走向。每个 IMF 分量都能体现出供热负荷的特征。经过分解后各分量曲线明显平滑,有效提高热负荷预测准确率,并降低预测难度。

2.4 消融实验

采用消融实验来验证各个创新点模块的实际作用,逐步剔除模型框架中的核心组件,分析其对整体预测性能的影响。表 1 为消融实验结果,展示了不同模块组合下的模型性能变化,评价指标包括均方误差与平均绝对误差。

表 1 中,组合 A 在移除 iTransformer 模块的基础上,仅保留 PatchTST 与 CEEMDAN,作为多尺度建模与非平稳性处理的组合基线;组合 B 去除 PatchTST,仅保留 CEEMDAN 与 iTransformer;组合 C 则移除了 CEEMDAN,考察在不进行信号分解的前提下,PatchTST 与 iTransformer 组合的表现;组合 D 为完整模型,集成了 CEEMDAN 分解、PatchTST 多尺度建模与 iTransformer 融合预测机制。

表 1 消融实验结果

Tab.1 Results of the ablation experiment

方 案	MSE	MAE
组合 A	0.093 3	0.226 5
组合 B	0.080 0	0.206 3
组合 C	0.093 3	0.227 0
组合 D	0.076 6	0.195 6

实验结果表明,完整模型在两个指标上均取得最优结果,显著优于任一单独或部分组合模块。从组合 A/B/C 的结果对比可以看出,单独移除任一模块都会导致性能明显下降,说明 CEEMDAN 分解、PatchTST 的局部建模能力以及 iTransformer 的多分量融合机制在本任务中均发挥了互补的作用,共同促进了模型的整体性能提升。

2.5 对比实验

选取 Transformer^[10]、TSMixer^[19]、LSTM^[20]、DLinear^[21]和 Informer^[22]等具有代表性的时间序列

预测方法进行对比,结果如表 2 所示。

表 2 对比试验结果

Tab.2 Results of comparative experiment

方 法	MSE	MAE
TSMixer ^[19]	0.231 3	0.384 6
LSTM ^[20]	0.209 1	0.359 3
DLinear ^[21]	0.200 7	0.358 6
Transformer ^[10]	0.257 8	0.390 3
Informer ^[22]	0.247 3	0.375 9
本文模型	0.076 6	0.195 6

从对比结果来看,本研究模型在 MSE 和 MAE 两个指标上均显著优于其他模型。本研究模型的 MSE 达到 0.076 6,大幅领先次优的 Dlinear 约 60%。MAE 降至 0.195 6,相比其他方法提升稳定且显著。

从模型结构的角度来看,传统 Transformer 与 Informer 在长序列建模中存在冗余注意力计算,难以捕捉短期变化;而 LSTM 则对复杂周期性变化适应不足;DLinear 和 TSMixer 尽管结构简洁、推理高效,但在非平稳信号建模方面能力有限。本文方法通过 CEEMDAN 提前分离信号成分,结合 PatchTST 提取多尺度局部依赖,并通过 iTransformer 自适应融合不同 IMF 分量,显著增强了模型的表达能力与预测鲁棒性。

图 6 展示了采用不同模型对热负荷的预测结果,图 7 则呈现了每天逐时预测误差绝对值的平均。




图 6 各方法对热负荷的预测结果对比图

Fig.6 Comparison chart of prediction results of heat load by each method




图 7 各方法热负荷日均预测误差对比

Fig.7Comparison of daily average prediction errors of heat load by each method

由图 6 和图 7 可知,本研究的方法在预测结果的准确性与稳定性方面均优于对比模型。首先,从图 6 中,在热负荷实际波动较为剧烈的时间段,例如12月23日至24日和12月29日至30日,本文模型能够较为准确地跟踪真实负荷的峰谷变化,表现出良好的动态响应能力,而传统模型如 Transformer 和 Informer 在高峰阶段普遍存在滞后或振幅不足的现象。其次,从图 7 可以看出,本文方法的误差波动相对平稳,幅度较小,绝大多数日均误差控制在 1 MW 以内,而对比方法如 TSMixer 和 LSTM 的日均误差波动较大,甚至出现接近 4MW 的极端误差。

3 结 论

本文针对非平稳热负荷序列预测中存在的波动复杂、多尺度特征耦合及误差累积等核心挑战,构建了一套融合模态分解、多路径建模与集成学习的创新框架。通过 CEEMDAN 自适应分解非平稳信号、PatchTST 捕捉多尺度时空依赖、iTransformer 优化分量融合权重,并结合 Bagging 策略提升模型鲁棒性,最终实现了热负荷预测精度与稳定性的显著突破。具体结论如下:

- (1) 分解结果显示,各 IMF 分量分别捕捉了高频随机波动、周期性变化及长期趋势特征,显著降低了单一模型处理复杂信号的难度。
- (2) 设计融合 PatchTST 与 iTransformer 的双分

支预测网络。其中 PatchTST 通过序列分块与自注意力机制实现局部动态与全局周期的协同建模,iTransformer 则通过实例依赖型分词机制自适应调整分量权重。

(3) 引入 Bagging 融合机制对双路径输出进行加权集成,通过互补不同模型的偏差特性进一步提升预测稳定性。

(4) 在实际供热系统数据集上的对比实验表明,所提模型在实际供热数据集上的 MSE 和 MAE 分别达到 0.0076 和 0.1956,较传统方法和现有 SOTA 模型降低 45% ~ 70% 的预测误差,显著优于 Transformer、LSTM 等方法。

未来的工作可以进一步探索如何结合更多类型的先验知识,如天气预测、设备状态等,进一步增强模型的泛化能力。此外,随着智能电网和能源管理系统的发展,如何在更复杂和大规模的实际应用中实现模型的高效部署,将是未来的研究重点。

参考文献:

[1] 朱继忠,董瀚江,李盛林,等.数据驱动的综合能源系统负荷预测综述[J].中国电机工程学报,2021,41(23):7905-7923.
ZHU Jizhong,DONG Hanjiang,LI Shenglin,et al. Review of data-driven load forecasting for integrated energy system[J]. Proceedings of the CSEE,2021,41(23):7905-7923.

[2] SCHACHTER J,MANCARELLA P. A short-term load forecasting model for demand response applications[C]//11th International Conference on the European Energy Market (EEM14). IEEE, 2014:1-5.

[3] 周小光,资 慧,金 田,等.双碳目标下电网异址双活调控中心负载均衡控制方法[J].电测与仪表,2023,60(7):107-115.
ZHOU Xiaoguang,ZI Hui,JIN Tian,et al. Load balancing control method for remote active-active control centers of power grid with carbon peak and neutrality targets[J]. Electrical Measurement & Instrumentation,2023,60(7):107-115.

[4] DONG H,GAO Y,MENG X,et al. A multifactorial short-term load forecasting model combined with periodic and non-periodic features-a case study of qingdao, China[J]. IEEE Access,2020,8: 67416-67425.

[5] 陈飞翔,胥建群,王晨杨,等.能源互联网系统用户侧冷热负荷预测模型研究[J].中国电机工程学报,2015,35(14): 3678-3684.
CHEN Feixiang,XU Jianqun,WANG Chenyang,et al. Research on building cooling and heating load prediction model on user's side

in energy internet system [J]. Proceedings of the CSEE, 2015, 35(14):3678–3684.

[6] 郝有志,李德英. 热负荷预测方法评析[J]. 建筑热能通风空调,2003,22(1):26–27.

HAO Youzhi,LI Deying. Estimation of heat load forecast methods [J]. Building Energy & Environment,2003,22(1):26–27.

[7] TORRES M E,COLOMINAS M A,SCHLOTTHAUER G,et al. A complete ensemble empirical mode decomposition with adaptive noise [C] // 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE,2011:4144–4147.

[8] 陈锦鹏,胡志坚,陈纬楠,等. 二次模态分解组合 DBiLSTM-MLR 的综合能源系统负荷预测[J]. 电力系统自动化,2021,45(13):85–94.

CHEN Jinpeng,HU Zhijian,CHEN Weinan,et al. Load prediction of integrated energy system based on combination of quadratic modal decomposition and deep bidirectional long short-term memory and multiple linear regression [J]. Automation of Electric Power Systems,2021,45(13):85–94.

[9] 李玉凯,韩佳兵,于春浩,等. 基于随机森林和长短期记忆网络多元负荷预测的综合能源三层规划调度[J]. 现代电力,2021,38(6):695–703.

LI Yukai,HAN Jiabing,YU Chunhao,et al. Three-level planning and scheduling of comprehensive energy based on random forest regression-long- and short-term memory network multivariate load forecasting [J]. Modern Electric Power,2021,38(6):695–703.

[10] VASWANI A,SHAZEER N,PARMAR N,et al. Attention is all you need [J]. Advances in Neural Information Processing Systems,2017,30:6000–6010.

[11] 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):6119–6128.

LI Yunsong,ZHANG Zhisheng. Transformer based multi load short-term forecasting of integrated energy system considering integrated demand response [J]. Transactions of China Electrotechnical Society,2024,39(19):6119–6128.

[12] 黄文琦,梁凌宇,王鑫,等. 基于变量选择与 Transformer 模型的中长期电力负荷预测方法[J]. 浙江大学学报(理学版),2024,51(4):483–491,500.

HUANG Wenqi,LIANG Lingyu,WANG Xin,et al. Mid-long term power load forecasting based variable selection and transformer model [J]. Journal of Zhejiang University (Science Edition),2024,51(4):483–491,500.

[13] PENG B,NARAYANAN S,PAPADIMITRIOU C. On limitations of the transformer architecture [C] // First Conference on Language Modeling,2024.

[14] NIE Y,NGUYEN N H,SINTHONG P,et al. A time series is worth 64 words; long-term forecasting with transformers [J]. arXiv preprint arXiv,2022:2211.14730.

[15] LIU Y,HU T,ZHANG H,et al. iTransformer; Inverted transformers are effective for time series forecasting [J]. arXiv preprint arXiv,2023:2310.06625.

[16] SHAW P,USZKOREIT J,VASWANI A. Self-attention with relative position representations [J]. arXiv preprint arXiv,2018:1803.02155.

[17] DENG X,YE A,ZHONG J,et al. Bagging-XGBoost algorithm based extreme weather identification and short-term load forecasting model [J]. Energy Reports,2022,8:8661–8674.

[18] RILLING G,FLANDRIN P,GONCALVES P. On empirical mode decomposition and its algorithms [C] // Proceedings of IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing NSIP-03,2003.

[19] EKAMBARAM V,JATI A,NGUYEN N,et al. Tsmixer; Lightweight MLP-mixer model for multivariate time series forecasting [C] // Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining,2023:459–469.

[20] GRAVES A. Long short-term memory [J]. Supervised Sequence Labelling with Recurrent Neural Networks,2012:37–45.

[21] ZHOU N,ZENG H,ZHOU J. DLinear-based prediction of the RUL of PEMFC [C] // 2024 4th International Conference on Consumer Electronics and Computer Engineering (ICCECE). IEEE,2024:221–224.

[22] ZHOU H,ZHANG S,PENG J,et al. Informer; Beyond efficient transformer for long sequence time-series forecasting [J]. Proceedings of the AAAI Conference on Artificial Intelligence,2021,35(12):11106–11115.

(姜雪梅 编辑)