

基于二次模态分解与Informer-BiLSTM的电力负荷预测

许世欣¹, 李雯婷², 彭道刚¹, 税纪钧¹, 刘杰¹, 钟华平¹

(1. 上海电力大学 自动化工程学院, 上海 200090;

2. 国网上海市电力公司金山供电公司, 上海 200540)

摘要: 针对单一深度学习模型特征提取不全面、非线性数据处理能力不足等传统方法存在的问题, 提出一种基于二次模态分解与Informer-BiLSTM的电力负荷预测模型。首先利用CEEMDAN(自适应噪声完备经验模态分解)联合小波阈值对原始数据去噪, 再通过VMD(变分模态分解)将原始数据分解为一组平稳性强的模态分量, 然后利用Informer和BiLSTM并行网络分别捕捉负荷数据集的长期趋势与短期波动, 最后融合两者输出实现更为精准的预测。采用两组特性不同的负荷数据集在不同情境下验证所提模型性能, 结果表明该模型有效提升了负荷预测精度与泛化能力, 可为电力系统优化调度提供可靠的数据支持。

关键词: 电力负荷预测; 二次模态分解; 自适应噪声完备经验模态分解; 变分模态分解; Informer; BiLSTM

DOI: 10.19585/j.zjdl.202510005

开放科学(资源服务)标识码(OSID):



Power load forecasting based on SMD-Informer-BiLSTM

XU Shixin¹, LI Wenting², PENG Daogang¹, SHUI Jijun¹, LIU Jie¹, ZHONG Huaping¹

(1. College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. State Grid Jinshan Power Supply Company, Shanghai 200540, China)

Abstract: To address the limitations of traditional methods—such as inadequate feature extraction and insufficient nonlinear processing capability in single deep learning models—this paper proposes a novel power load forecasting model integrating secondary modal decomposition (SMD) with Informer-BiLSTM. First, complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) combined with wavelet thresholding is applied to denoise the raw data. Next, variational mode decomposition (VMD) decomposes the raw data into a set of highly stable modal components. These components are then processed through a parallel network architecture comprising Informer and BiLSTM to capture long-term trends and short-term fluctuations in the load data set, respectively. Finally, the outputs of both networks are fused to achieve more accurate forecasting. The proposed model is validated under multiple scenarios using two distinct load datasets. Results demonstrate that the model significantly improves forecasting accuracy and generalization capability, providing reliable data support for optimized power system scheduling.

Keywords: power load forecasting; SMD; CEEMDAN; VMD; Informer; BiLSTM

0 引言

随着社会经济的迅猛发展, 建立在化石能源基础上的传统发电模式效率低下与环境污染的双重弊端愈发凸显。全球积极应对气候变化、大力推进能源转型的大背景下, 我国于2020年9月提

出“双碳”政策^[1], 旨在推动经济社会全面绿色转型。为实现电力系统的可持续发展, 需要不断变革以保障电力电量的动态平衡、降低运行过程中的过载隐患、减少能源损耗并提升设备的使用效率。在此转型的进程中, 开展高精度的多维度电力负荷预测研究至关重要, 对于优化系统运行、增强稳定性具有关键意义^[2-4]。高精度的负荷预测作为保障电网电力调度与稳定运行的核心基础, 在智能电网运行的各个环节中均发挥着关键作用,

基金项目: 国家自然科学基金(62373241); 国网上海市电力公司科技项目(520932250002)

也能够为降低供电成本提供重要助力。

目前,电力负荷预测的主流方法^[5]主要有三类,分别为传统预测^[6]、机器学习^[7]与深度学习^[8]。其中,专家系统^[9]、回归分析法^[10]以及时间序列法^[11]等传统预测模型曾被广泛应用。但这些线性模型^[12]在应对电力系统复杂多变的场景时暴露出显著短板,难以精准捕捉负荷变化的非线性特征,导致预测结果与实际情况存在较大偏差,无法满足电力系统精细化调控与高效运行的需求。

伴随着人工智能技术迅猛发展,机器学习模型在处理波动性大的数据时所展现出的良好预测性能,跃升为电力负荷预测领域的核心工具。其中,RF(随机森林)^[13]凭借集成学习优势,构建多个决策树并行处理数据,能有效降低模型方差;SVM(支持向量机)^[14]擅长在高维空间中寻找最优分类超平面,对于小样本电力负荷数据的回归预测具有较高的精度;改进萤火虫算法^[15]有效解决电力负荷预测中的非线性优化问题;梯度提升机^[16]尤其擅长捕捉电力负荷数据中的复杂趋势与细微变化。与此同时,深度学习技术因其强大的特征提取与模式识别能力在电力负荷预测领域掀起研究热潮,其中CNN(卷积神经网络)^[17]能有效捕捉电力负荷数据中的局部关联模式;LSTM(长短期记忆神经网络)^[18]相对于传统循环神经网络而言,解决了梯度消失的问题,并且擅长挖掘负荷数据的长时依赖关系;RNN(循环神经网络)^[19]及其衍生模型凭借对序列数据的天然适应性,在负荷时间序列预测中展现出巨大潜力。例如,张淑娴等^[20]运用CEEMDAN(自适应噪声完备经验模态分解)与VMD(变分模态分解)分解相结合的二次模态分解技术分解原始电负荷,使用LSTM网络对分解的子序列进行训练,最终得到的预测结果与预测精度都有所提升。葛亚明等^[21]利用LSTM建立电力负荷预测模型,在考虑多种影响因子时训练时间成本与计算量显著提升。Wang等^[22]使用改进后的VMD将原始电力负荷分解,在此基础上针对各分量建立CNN与BiLSTM(双向长短期记忆神经网络)相融合的负荷预测模型,提高了预测精度。周磊等^[23]在多重MA(滑动平均)方法支撑下,建立融合自注意力机制的MA-CNN-LSTM-selfattention预测模型,达到了预测

精度提升的效果。杨坚等^[24]为克服分布式电源和用户侧行为的多样性问题,提出基于VMD的RNN负荷预测方法,提高了预测精度。

依靠单一深度学习模型独立处理随机性强、波动性大的电力负荷,往往难以全面捕捉其中蕴含的复杂特征,导致预测结果与实际情况存在偏差^[25-28]。鉴于此,电力负荷预测领域的研究重心逐步从依赖单个模型转向探索多种模型的加权融合方案,这一改进不仅能充分发挥各个单一预测模型的优势,还能提高预测的精准度^[29-32]。

综上所述,为解决现有研究中时间序列分析对非线性数据处理欠佳以及传统机器学习模型构建灵活性不足的问题,本文针对配电网级负荷、新能源渗透场景下的负荷等这类高波动负荷场景,提出一种基于二次模态分解的Informer-BiLSTM电力负荷预测模型,该模型不仅能够充分利用CEEMDAN与VMD的信号分解优势,还能融合Informer^[33-34]与BiLSTM^[35-36]不同的特征提取能力,旨在突破现有负荷预测精度瓶颈。研究将采用理论分析与实验验证相结合的方法,预期为电力系统的优化调度与经济运行提供更为可靠的数据支持,助力电力行业可持续发展。

1 技术原理

如图1技术流程所示,本文提出一种融合CEEMDAN与VMD的二次模态分解方法,并将分解后的数据采用Informer-BiLSTM模型进行负荷预测。

二次模态分解的首次分解,CEEMDAN聚焦于去除噪声并提取稳定子序列,联合小波阈值法将含有噪声的高频分量去噪,保留含有信号的低频分量进行累加重构,目标是将原始电力负荷数据分解为多个IMF(固有模态函数),并通过小波阈值法对高频噪声分量去噪,保留有效低频信号。第二次分解,VMD聚焦于提取去噪后数据的多频率特征分量,目标为对一次分解处理后的信号进一步分解,提取出平稳性更强且具有不同频率的模态分量,用于后续的特征提取、负荷预测。

原始数据经过二次模态分解后,由Informer-BiLSTM模型进行负荷预测,Informer部分聚焦于处理全局时序模式以及长时间序列数据,把握电




图1 总体技术流程

Fig.1 Flowchart of overall technical process

力负荷的长期趋势和整体模式。BiLSTM部分聚焦于处理局部时序模式,可捕捉电力负荷数据中的短期波动和局部特征。并行融合时,可以根据具体任务需求以及数据特点,合理分配两者的计算资源和权重,既能满足实时性的要求,又能保证预测精度。

本文采用7日滚动预测策略,该方法通过滑动窗口与迭代预测结合,以历史7日多特征数据为初始输入序列,随后将预测结果的第1天负荷值加入历史窗口,剔除原始7天的第1天数据,形成新的7天输入序列,重复该操作直至实现210天的长期负荷预测。同时为有效控制误差,每迭代5次,使用实际负荷数据重新训练模型,修正累积误差。

本文设置4组对比试验,并采用两组数据集分别进行对比,所有实验得出的预测值,均采用误差评价指标与拟合优度进行模型预测效果的检验。

1.1 CEEMDAN-VMD 二次模态分解原理

二次模态分解中的首次分解,CEEMDAN结合小波阈值法能够有效去除原始信号中的高频噪声,提升分解精度。多尺度特征分离时,CEEMDAN聚焦于处理非平稳信号,而VMD可实现进一步细化频率成分,最终达到粗粒度去噪与细粒度特征提取的双重目标。该方法还可使平稳性得到提升,VMD输出的模态分量具有严格的带宽限制,适用于需要高平稳性数据的场景。

本文在CEEMDAN一次分解后,原始信号被

分解为IMF1—IMF_n和余项,通过样本熵指标对IMF分量的噪声贡献度进行评估,选择前4个高频IMF进行小波阈值去噪,保留低频IMF和余项的原始形式。经CEEMDAN去噪重构后,送入VMD的信号为去噪后的高频分量IMF1—IMF4、原始低频分量与余项的累加信号,VMD对该混合信号进行整体分解,以提取兼具高低频特征的平稳模态,该方法可避免对低频有效成分的过度分解,同时,还可通过VMD的自适应带宽优化提升高频细节的分辨率。

1.1.1 CEEMDAN分解原理

首先对原始电力负荷信号 $x(t)$ 分解为 N 个IMF和一个Residual(残余分量)。分解后的高频IMF分量主要包含噪声和短期波动,低频IMF和残余分量包含长期趋势和主要信号特征。

联合小波阈值去噪,首先识别含噪声的高频IMF分量,并对每个高频IMF进行小波变换,得到小波系数;之后应用阈值函数对小波系数去噪,保留显著信号成分:

$$\hat{I}_{MF,i}(t) = \text{WaveletThreshold}(I_{MF,i}(t), \lambda) \quad (1)$$

式中: λ 为阈值,根据噪声水平自适应确定,表示为:

$$\lambda = \sigma \sqrt{2 \ln n} \quad (2)$$

式中: σ 为噪声标准差; n 为信号长度。

最后进行低频分量的累加重构,得到去噪后的信号 $x_{\text{denoised}}(t)$ 。

$$x_{\text{denoised}}(t) = \sum_{i=1}^k \hat{I}_{MF,i}(t) + \sum_{i=k+1}^N I_{MF,i}(t) + \text{Residual}(t) \quad (3)$$

该操作可在去除高频噪声的同时保留低频有效信号,为后续VMD分解提供更纯净的输入。

1.1.2 VMD分解原理

VMD在处理非平稳、非线性信号方面优势显著。与传统方法相比,该分解方式有效克服了经验模态分解的缺点,极大提高了信号分解的准确性与可靠性。该算法基于自适应维纳滤波组的创新架构,抗噪性能更强。VMD算法依据各子信号最优参数,将原始信号分解成多个具备不同特征的子信号,每个子信号都对应着原始信号中的特定成分,包括不同频率范围、时间尺度等,从而有效提取原始信号中的各类信息,为后续的信号

分析与处理提供有力支撑。

经变分模态分解和小波阈值法处理后的信号为 $x_{\text{denoised}}(t)$ ，这一信号包含了原始信号的主要特征，但仍会存在一定的频率混叠或非平稳性，因此需要进行VMD的二次特征提取，具体步骤如下。

1) 步骤1: 构建变分模型。

变分模型的构建是为了将 $x_{\text{denoised}}(t)$ 分解为 K 个模态分量 $\{v_1(t), v_2(t), \dots, v_K(t)\}$ ，每个模态 $v_K(t)$ 对应着一个中心频率 ω_k 和带宽，带宽由频率域支撑范围决定。

每个模态 $v_K(t)$ 可视为一个调幅-调频信号，通过执行HHT(希尔伯特-黄变换)^[27]解析其频率特性，为确保频率信息的准确性，利用指数调制将其转换到基频附近。

无约束变分问题的构建数学表达式如式(4)所示。首先最小化各模态的带宽之和，实现频域局部化，同时需要满足信号重构约束，确保分解后的模态分量之和等于原始信号。

$$\begin{cases} \min_{\{v_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot v_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^K v_k = x_{\text{denoised}}(t) \end{cases} \quad (4)$$

2) 步骤2: 引入拉格朗日乘子与二次惩罚项。

为将有约束优化问题转化为无约束优化问题，得到修正后的增广拉格朗日函数，需引入拉格朗日乘子 $\lambda(t)$ 和二次惩罚因子 α 。

当信号存在噪声或分解误差时，二次惩罚因子 α 可平衡带宽约束与重构误差，避免过拟合或欠拟合。

3) 步骤3: 优化交替迭代。

采用ADMM(交替方向乘子法)迭代优化各模态分量 $v_K(t)$ 、中心频率 ω_k 和拉格朗日乘子 λ 。

4) 步骤4: 输出结果。

符合收敛条件迭代结束后，得到 K 个模态分量 $\{v_1(t), v_2(t), \dots, v_K(t)\}$ 。这些模态分量具有频域成分不重叠、平稳性强特性，并且不同的模态可对应原始信号中不同时间尺度的成分，有利于后续的特征分析。

1.2 Informer 算法

Informer 改进于传统 Transformer 架构的基础之上。其作为一种现阶段较先进的序列建模框架，

采用多头概率稀疏自注意力机制替代传统自注意力机制是其核心创新点，这一设计可以显著降低模型计算的复杂度以及有效提升整体运行效率。

图2所示为Informer的整体架构，编码器与解码器之间通过位置信息嵌入层、多头概率稀疏自注意力层以及自注意力蒸馏层实现交互连接。这种逐层叠加的结构不仅减轻了模型计算负担，还增强了模型的鲁棒性。




图2 Informer 算法结构

Fig.2 Structure of the Informer algorithm

Informer能够解决输入序列太长导致无法堆叠的问题，得益于其在相邻的注意力机制之间加入卷积池化层，将蒸馏模块引入到编码器中，降低了空间复杂度。与传统自注意力机制^[28]基于KVQ(键-值-查询)运作模式不同，Informer模型的多头概率稀疏自注意力机制^[29]在筛选得分较高的键-查询对的同时将低得分的配对组合舍弃，能够有效降低计算过程和存储的复杂度。在此过程中，如式(5)所示，自注意力机制的运算逻辑被转化为概率表达形式，通过概率公式实现对关键信息的聚焦与高效处理。

$$A(Q^*, K, V) = \sum_j \frac{k(q_i, k_j)}{\sum_l k(q_i, k_l)} v_j = E_{p(k_j|q_i)}[v_j] \quad (5)$$

式中： Q^* 、 K 、 V 分别为查询矩阵、键矩阵和值矩阵。

针对电力负荷数据的复杂特性，Informer模型需通过合理参数配置，以平衡长依赖捕捉能力与计算效率。本文实验中两组数据集分别采用的相应参数值总结如表1所示，其中两组数据集均采用

7 日滚动预测策略, 第一组数据集输入 7 日, 每日采用 1 个平均负荷数据, 输入时间步长 $L_{in}=7$; 第二组数据集输入 7 日, 每日采用 24 个负荷数据, 输入时间步长 $L_{in}=168$ 。

表 1 Informer 模型参数设置

Table 1 Parameter settings of the Informer model

参数类别	参数名称	数据集 1	数据集 2
时序窗口	输入时间步 L_{in}	7	168
	输出时间步 L_{out}	7	168
模型结构	编码层数	2	3
	注意力头数	8	8
训练优化	学习率 η	$1e^{-4}$	$1e^{-4}$

1.3 BiLSTM 模型

如图 3 所示, BiLSTM 网络模型采用独特的双向结构设计。该结构融合了 LSTM 与 BIRNN(双向循环神经网络)^[40]的优势。将两个 LSTM 单元相互连接的同时, 又分别构建正向传播与反向传播的隐藏层。这种结构形成了双向的数据流动路径, 通过这种创新的双向信息交互机制, BiLSTM 能够使当前时间节点的输出充分融合前后两个方向的序列信息, $\vec{h}_{t-1}$, $\vec{h}_{t+1}$, $\vec{h}_t$ 时间序列中的特征更能全面捕捉。




图 3 BiLSTM 神经网络结构

Fig.3 Structure of BiLSTM neural network

BiLSTM 网络模型在本文实验中, 主要用于捕捉高频波动分量, 其参数需与分解模态数匹配, 旨在平衡拟合与泛化, 聚焦短期波动, 两组数据集分别采用的相应参数值总结如表 2 所示。

2 基于二次模态分解与 Informer-BiLSTM 的电力负荷预测模型

Informer 基于 Transformer 架构, 针对长序列

表 2 BiLSTM 模型参数设置

Table 2 Parameter settings of the BiLSTM model

参数类别	参数名称	数据集 1	数据集 2
输入维度	模态数 K_{IMF}	3.0	3.0
网络结构	隐藏层维度 d_{hidden}	12.0	12.0
	层数 N_{LSTM}	1.0	1.0
正则化	丢弃率 $p_{dropout}$	0.2	0.2

方面具有独特优势, 但在电力负荷预测时存在一定的局限性。由于包含大量注意力机制计算, 导致其消耗极高的计算资源, 对硬件方面的要求也更高。Informer 聚焦于捕捉长序列的长期依赖关系, 而现实中电力负荷受到许多因素影响, 短期波动较大, Informer 对这种短期快速变化的局部依赖关系难以精准捕捉。

BiLSTM 凭借双向结构的支持, 能够处理一定程度的长期依赖关系, 但是对长期信息的记忆与传递能力存在局限性。通常面对包含复杂长期趋势和季节性变化的电力负荷数据, BiLSTM 难以充分捕捉。基于时间步逐个计算的特性, 导致其并行计算能力差, 在大规模电力负荷数据的处理时, 训练速度明显较缓慢, 训练和预测的时间成本较高的同时, 还不利于模型及时更新以适应动态变化的负荷情况, 进而影响模型的时效性与预测准确性。

综上, 本文采用一种将其优势互补并提高预测精度、增强鲁棒性的预测模型, 即基于二次模态分解的 Informer-BiLSTM 多特征电力负荷预测模型。该模型结构如图 4 所示。其在数据处理上采用二次模态分解方法, 该方法能将用电负荷的时间序列分解为多个具有不同特征尺度的模态分量, 如短期波动、中期趋势和长期季节性, 每个分量又对应着不同时间尺度的信息, 这有助于后续 Informer 和 BiLSTM 更有针对性地对不同特征进行提取和建模, 提高模型对复杂用电负荷数据的特征提取能力。研究中并行使用 Informer 和 BiLSTM, 通过两个分支并行学习, 使模型可在不同的时间尺度上进行信息提取和处理。

由于本文模型的参数敏感性, 需通过系统化训练配置以及超参数调优, 特别在针对电力负荷数据的周期性特征和多模态特性方面, 要求模型参数与数据特性深度适配, 本文模型训练配置参数从 3 个方面展开设计, 设置如表 3 所示。同时,

为确定本文模型的最优参数组合,制定采用贝叶斯优化与网络搜索混合的超参数调优策略,对分解模块参数、时序建模参数以及训练参数进行系统性调优,其关键参数如表4所示。

表3 模型训练配置参数设置

Table 3 Parameter settings for model training configuration

参数类别	参数名称	数据集1取值	数据集2取值
优化器设置	优化器类型	Adam	Adam
	初始学习率	$1e^{-4}$	$1e^{-4}$
	权重衰减系数	$1e^{-5}$	$1e^{-5}$
训练策略	批大小	32	64
	训练轮数	100	100
	早停耐心值	10	10
学习率调度	衰减策略	余弦退火	余弦退火
	周期长度	20	20

表4 本文模型关键参数

Table 4 Key parameters of the proposed model

参数类别	参数名称		
分解模块参数	CEEMDAN集成次数	VMD分解层数	
时序建模参数	Informer编码层数	注意力头数	输入时间步
训练参数	学习率	批大小 Batch Size	

在实际应用方面,由于该模型充分融合了几种单一模型的优点,因此模型的鲁棒性和泛化功能更强,对于不同类型的用电负荷数据,该模型

都能通过二次模态分解、Informer以及BiLSTM的协同作用,减少单一模型对特定类型用电负荷数据的局限性,有效地提取特征并进行准确预测。

3 实验验证

3.1 数据来源

为检验模型的负荷预测效果与泛化功能,采用两组数据集,分别进行对比实验。第一组数据集采用某地区的电力负荷数据,该数据集采样周期为24 h,取2012年1月1日—2015年1月10日每天的平均负荷,总共为1 107组电力负荷数据。将原始数据按7:1:2的比例划分训练集、验证集与测试集;第二组数据集采用某地区的128 544组电力负荷数据,涵盖2016年1月1日—2019年8月31日的天气和电力负荷为数据样本,同样对该数据集按7:1:2的比例划分训练集、验证集与测试集,滚动多步预测。

为清晰观察两组数据集的不同特点,首先分别对两组数据集进行整理,绘制出如图5、图6所展示的原始电力负荷数据图像。

3.2 特征处理

第一组数据集涵盖最高温度、最低温度等6个特征;第二组数据集包含天气状况、最高温度、




图4 基于二次模态分解与Informer-BiLSTM的电力负荷预测模型结构

Fig.4 Structure of the power load forecasting model based on secondary modal decomposition and Informer-BiLSTM




图 5 第一组数据原始负荷数据
Fig.5 Original load data of the first dataset




图 6 第二组数据原始负荷数据
Fig.6 Original load data of the second dataset

最低温度等 6 个特征。采用拉格朗日插值法对该数据集 中的 412 个缺失值进行处理。

数据处理过程中, 采用 MIC(最大信息系数)方法进行特征筛选, 该方法能够充分度量变量间非线性与线性关系的强度, 相较于传统相关系数, MIC 对电力负荷与天气、节假日等特征的非线性关联更为敏感, 可剔除冗余特征, 降低模型计算复杂度并提升预测精度。本实验中设定 MIC 阈值为 0.3, 保留与负荷相关性大于阈值的特征。第一组数据集中各特征变量的 MIC 值排名如表 5 所示, 分析 6 个特征的 MIC 值与排序可知, 温度与负荷的相关性最强, 相对湿度、日期等特征与负荷的相关性较弱, 考虑后续实验的预测精度和时间成本, 将温度作为最主要的预测特征。第二组数据集中各特征 MIC 值排名如表 6 所示, 分析 6 个特征的 MIC 值与排序可知, 干球温度与负荷的相关性最强, 其余特征与负荷的相关性较弱。实验过程中最高温度数据的时间尺度与负荷预测目标严格对齐, 针对第一组日负荷预测数据集, 采用每日最高气温值, 时间精度为日; 针对第二组逐小时负荷预测数据集, 采用逐小时最高气温值。

表 5 第一组数据集 MIC 值排序

Table 5 MIC value ranking of the first dataset

排序	名称	得分	正负相关性
1	最高温度	0.649 4	正
2	平均温度	0.557 6	正
3	最低温度	0.546 4	正
4	相对湿度	0.340 2	正
5	日期特征	0.102 4	正
6	电价	0.042 1	正

表 6 第二组数据集 MIC 值排序

Table 6 MIC value ranking of the second dataset

排序	名称	得分	正负相关性
1	干球温度	0.628 1	正
2	湿球温度	0.576 3	正
3	露点温度	0.503 6	正
4	相对湿度	0.332 1	正
5	电价	0.181 2	正
6	日期特征	0.102 4	正

3.3 基于 CEEMDAN-VMD 的二次模态分解

CEEMDAN-VMD 二次模态分解是处理电力负荷等非平稳时间序列的有效方法。

3.3.1 CEEMDAN 分解与小波阈值去噪

通过 CEEMDAN 可对数据实现初步的特征提取与噪声分离, 该算法作为一种改进算法, 引入自适应噪声克服了模态混叠问题, 对原始负荷数据添加白噪音并进行多次 EMD 分解, 然后取集成平均得到各 IMF 分量。如图 7、图 8 所示, 对两组数据集进行 CEEMDAN 一次模态分解, 其中 IMF1 通常为最高频噪声分量, 后续的 IMF 则依次包含较低频率成分, 残余项可反应信号的长期趋势。

为了去除高频噪声, 实验过程中联合小波阈值技术对前 4 个 IMF 进行小波变换, 之后通过阈值法筛选小波系数, 最后通过逆变换重构去噪后的 IMF。低频 IMF 和残余项因包含主要负荷特征而保留原始形式, 通过将去噪后的高频分量与未处理的低频分量累加, 完成第一次信号重构。这一操作有效抑制了随机噪声, 同时也保留了负荷变化的主要趋势和周期特征。

3.3.2 VMD 二次分解与特征提取

利用 VMD 对去噪后的数据进行二次分解, 可以提取具有明确频率特性的平稳分量。在本文实




图7 第一组数据集CEEMDAN分解结果

Fig.7 CEEMDAN decomposition results of the first dataset

验中, VMD将信号自适应地分解为5个本征模态函数, 且各模态间带宽最小化。分解过程中的迭代优化通过ADMM(交替方向乘法)实现, 该方法可使各模态分量的估计带宽之和最小, 同时保证所有分量之和等于原始信号。分解层数 K 需根据信号特性和应用需求调整, K 会影响其对数据的分解效果。当 K 较大时, 容易导致混频现象; 当 K 选取太小时, 则容易丢失原始信号, 本研究利用中心频率法确定分解效果最佳时的分解层数, 以第一组数据集为例, 如表7所展示: 当分解层数为5层时, 中心频率为0.428, 分解层数为6层时, 中心频率也为0.428, 由此可知分解层数为5层时, 中心频率达到稳定, 此时的分解层数为最佳分解层数。第二组数据集同样采用该方法, 其中心频率如表8所示, 由此可知最佳分解层数同样为5




图8 第二组数据集CEEMDAN分解结果

Fig.8 CEEMDAN decomposition results of the second dataset

层。在针对两组数据集的实验过程中, 其余参数设置相同, 起始中心频率 ω 设置为0, 惩罚因子 α 设置为2500, 收敛判据 ϵ 设置为 1×10^{-7} 。

图9、图10所展示的分别为两组数据集过二次模态分解后的结果。分解后得到的各模态分量具有良好的频谱特性和平稳性, 可分别对应负荷中的日周期分量、周周期分量、季节趋势以及随机波动等不同特征成分。通过计算各模态的能量占比和中心频率, 可进一步分析其物理意义, 为后续负荷预测、故障诊断或模式识别提供高质量的特征输入。这种去噪与特征提取相互结合的二

表 7 第一组数据集中心频率

Table 7 Central frequencies of the first dataset

k 层	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6
1	5.52E-05					
2	6.22E-05	0.278				
3	6.22E-05	0.144	0.289			
4	6.21E-05	0.140	0.280	0.416		
5	4.01E-05	0.028	0.143	0.285	0.428	
6	3.86E-05	0.024	0.141	0.284	0.186	0.428

表 8 第二组数据集中心频率

Table 8 Central frequencies of the second dataset

k 层	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6
1	5.65E-05					
2	6.65E-05	0.296				
3	6.63E-05	0.264	0.326			
4	6.35E-05	0.250	0.320	0.473		
5	4.05E-05	0.038	0.184	0.285	0.542	
6	4.15E-05	0.028	0.172	0.276	0.342	0.542

次分解架构, 可充分发挥 CEEMDAN 的自适应分解能力和 VMD 的严格数学理论优势, 特别适合处理电力负荷这种具有多尺度变化特性的复杂时间序列。




图 9 第一组数据集二次模态分解结果

Fig.9 Secondary modal decomposition results of the first dataset




图 10 第二组数据集二次模态分解结果

Fig.10 Secondary modal decomposition results of the second dataset

3.4 结果分析

本文实验过程中为充分验证模型的有效性以及关键因素影响, 设计了 4 组梯度对照实验, 分别为参数调优策略对照实验、核心特征剔除对照实验、模态分解层数对照实验以及模型架构对照实验, 通过变量控制与交叉验证构建完整证据链。

对照实验一设置目的为确定模型的最优参数组合。实验制定了超参数调优策略, 通过控制变量法测试关键参数对模型性能的影响。测试过程中, 当输入时间步长过长时, 性能提升有限, 但计算成本显著增加; 当注意力头数 H 采用设定的最优参数时, 模型对多特征的捕捉能力最佳, 继续增加头数则会导致过拟合。最优参数组合验证结果如表 9 所示。采用调优后的参数配置, 无论训练集、验证集还是测试集的性能均得到明显提升, 第一组数据集在调优后, 测试集 RMSE (均方根误差) 降低 12.8%; 第二组数据集在调优后, 测试集 RMSE 降低 15.3%, 表明本文实验所设置的参数数据与电力负荷数据特性的适配性显著提升。

对照实验二设置目的为验证最高气温对长时负荷预测的必要性, 针对两组数据集, 分别执行移除最高气温特征的对照实验。第一组数据集移

除该特征后,测试集 RMSE 上升 9.7%,由 114.82 升至 125.97, MAPE(平均绝对百分比误差)由 4.143% 升至 4.589%;第二组数据集移除该特征后,测试集 RMSE 上升 10.3%,由 42.14 升至 46.59, MAPE 由 5.620% 升至 6.217%。该结果证明最高气温为负荷趋势预测的显著影响因素。

表9 最优参数组合验证结果

Table 9 Validation results of the optimal parameter combination

数据集	参数组合	训练集	验证集	测试集	训练时
		RMSE/kW	RMSE/kW	RMSE/kW	间/min
第一组数据集	初始配置	95.53	113.42	131.76	342
	调优后配置	83.42	105.64	114.82	245
第二组数据集	初始配置	32.71	45.63	49.74	456
	调优后配置	21.57	32.99	42.14	372

对照实验三设置目的为验证对本文所提模型中添加二次模态分解的效果,分别对两组数据集在不做模态分解以及只做一次模态分解的前提下进行负荷预测,并执行严格的统计显著性检验。本文模型相较于无模态分解和一次模态分解,在 MAPE 和拟合优度上的提升均具有统计学意义且效应量较大。第一组数据集的 MAPE 值因不服从正态分布特性,选用 Kruskal-Wallis 检验,统计量 $H=28.7$, p 值小于 0.001;第二组数据集 MAPE 值近似正态分布,故选用单因素 ANOVA 检验,统计量 $F=35.2$, p 值小于 0.001。经整体差异检验证明,两组数据集的 3 组模型 MAPE 均存在显著性差异。同时, t 检验显示本文模型与两组对照模型的拟合优度提升 p 值均小于 0.05。如表 10、表 11 所示,运用本文模型时,第一组数据集的 MAPE 分别降低了 23.199% 和 12.57%,拟合优度 R^2 分别提升 0.125 和 0.099;第二组数据集的 MAPE 分别降低了 26.831% 和 17.805%,拟合优度 R^2 分别提升 0.163 和 0.134。如图 11、图 12 所示,该模型的预测曲线与真实值曲线拟合性更佳。

对照实验四设置目的为检验本文所提模型的整体预测效果与泛化能力。首先用该模型对两组数据集进行负荷预测,并分别将单一模型 BiLSTM、Informer,组合模型 VMD-Informer、VMD-BiLSTM、Informer-BiLSTM、CEEMDAN-




图 11 第一组数据集 3 种模态分解预测结果对比

Fig.11 Comparison of forecasting results from three modal decomposition methods for the first dataset




图 12 第二组数据集 3 种模态分解预测结果对比

Fig.12 Comparison of forecasting results from three modal decomposition methods for the second dataset

VMD-Informer、CEEMDAN-VMD-BiLSTM 的预测效果作为对照组,并执行严格的统计显著性检验。本文模型相较于其他单一模型、融合模型,在 MAPE 和拟合优度上的提升均具有统计学意义且效应量较大。对两组数据集分别采用 Kruskal-Wallis 检验和单因素 ANOVA 检验,第一组数据集统计量 $H=51.3$, p 值小于 0.001;第二组数据集 $F=42.6$, p 值小于 0.001,结果显示 8 组模型间差异极显著。同时,符号秩检验显示本文模型与其余 7 组模型的拟合优度提升 p 值均小于 0.05。如表 12、表 13 所展示,运用本文模型的预测结果,精度均比其他单一模型、组合模型更高。如图 13、图 14 所展示,该模型的预测曲线与真实值曲线拟

合性更佳。




图 13 第一组数据集各模型预测结果对比
Fig.13 Comparison of forecasting results from different models for the first dataset




图 14 第二组数据集各模型预测结果对比
Fig.14 Comparison of forecasting results from different models for the second dataset

表 10 第一组数据集 3 种模态分解预测模型精度对比
Table 10 Comparison of forecasting accuracy of three modal decomposition models for the first dataset

序号	预测模型	MAPE /%	RMSE /kW	MAE /kW	R^2
1	Informer-BiLSTM	27.342	775.64	576.98	0.827
2	VMD-Informer-BiLSTM	16.713	726.65	543.72	0.853
3	CEEMDAN-VMD-Informer-BiLSTM	4.143	114.82	82.37	0.952

4 结语

基于二次模态分解的 Informer-BiLSTM 多特征电力负荷预测模型通过二次模态分解方法与并

表 11 第二组数据集 3 种模态分解预测模型精度对比
Table 11 Comparison of forecasting accuracy of three modal decomposition models for the second dataset

序号	预测模型	MAPE /%	RMSE /kW	MAE /kW	R^2
1	Informer-BiLSTM	32.451	115.63	176.84	0.794
2	VMD-Informer-BiLSTM	23.425	96.65	143.62	0.823
3	CEEMDAN-VMD-Informer-BiLSTM	5.620	42.14	31.11	0.957

表 12 第一组数据集各模型预测精度对比
Table 12 Comparison of forecasting accuracy of different models for the first dataset

序号	预测模型	MAPE /%	RMSE /kW	MAE /kW	R^2
1	BiLSTM	57.852	978.66	872.97	0.764
2	Informer	55.113	926.61	842.71	0.782
3	VMD-BiLSTM	39.264	921.52	712.84	0.791
4	CEEMDAN-VMD-BiLSTM	35.147	913.47	694.33	0.796
5	Informer-BiLSTM	27.342	775.64	576.98	0.827
6	VMD-Informer	26.812	764.34	563.45	0.839
7	CEEMDAN-VMD-Informer	25.337	746.79	527.61	0.859
8	CEEMDAN-VMD-Informer-BiLSTM	4.143	114.82	82.37	0.952

表 13 第二组数据集各模型预测精度对比
Table 13 Comparison of forecasting accuracy of different models for the second dataset

序号	预测模型	MAPE /%	RMSE /kW	MAE /kW	R^2
1	BiLSTM	55.862	245.78	257.53	0.708
2	Informer	48.224	235.18	232.15	0.713
3	VMD-BiLSTM	42.752	198.33	189.92	0.742
4	CEEMDAN-VMD-BiLSTM	40.365	195.34	184.33	0.768
5	CEEMDAN-VMD-Informer	39.875	190.75	180.42	0.734
6	VMD-Informer	38.544	183.02	178.53	0.782
7	Informer-BiLSTM	32.451	115.63	176.84	0.794
8	CEEMDAN-VMD-Informer-BiLSTM	5.620	42.14	31.11	0.957

行融合使用的 Informer、BiLSTM 构建, 有效实现了各自优势的互补, 对于进一步提升负荷预测精度具有重要的理论研究意义和实际应用价值。理论分析与案例研究表明, 相比较于传统单一模型 BiLSTM、Informer 与组合模型 VMD-BiLSTM、VMD-Informer, 本文所提出的模型预测精度更高, 泛化能力更强, 克服了单一模型对特定类型用电负荷数据的局限性, 在实际应用中能够更好

地适应各种复杂的用电场景,无论是工业用电、商业用电还是居民用电等不同类型的用电负荷数据,该模型均能有效提取特征并进行更精准的预测,在实际应用中能够更好地适应各种复杂的用电场景。

然而本文模型仍存在一定局限性:计算复杂度较高的同时融合多个模块导致参数总量大,训练耗时较长,在实时预测场景中应用受限;存在误差累积风险。未来可从模型轻量化、小样本学习方面开展研究,并结合物理模型与数据模型,降低纯数据驱动的误差。

参考文献

- [1] 谭显东,刘俊,徐志成,等.“双碳”目标下“十四五”电力供需形势[J].中国电力,2021,54(5):1-6.
TAN Xiandong, LIU Jun, XU Zhicheng, et al. Power supply and demand balance during the 14th Five-Year Plan period under the goal of carbon emission peak and carbon neutrality[J]. Electric Power, 2021, 54(5): 1-6.
- [2] 黄雨薇,彭道刚,姚峻,等.基于SSA和K均值的TD-BP神经网络超短期光伏功率预测[J].太阳能学报,2021,42(4):229-238.
HUANG Yuwei, PENG Daogang, YAO Jun, et al. Ultra-short-term photovoltaic power forecast of td-bp neural network based on ssa and k-means[J]. Acta Energetica Sinica, 2021, 42(4): 229-238.
- [3] 张未,余成波,王士彬,等.基于VMD-LSTM-LightGBM的多特征短期电力负荷预测[J].南方电网技术,2023,17(2):74-81.
ZHANG Wei, YU Chengbo, WANG Shibin, et al. Multi-featured short-term power load forecasting based on VMD-LSTM-LightGBM [J]. Southern Power System Technology, 2023, 17(2): 74-81.
- [4] 马传杰,孙宇贞,彭道刚,等.基于XGBoost-MTL的综合能源系统多元负荷预测[J].电力工程技术,2023,42(5):158-166.
MA Chuanjie, SUN Yuzhen, PENG Daogang, et al. Multi-variate load forecasting for integrated energy system based on XGBoost-MTL [J]. Electric Power Engineering Technology, 2023, 42(5): 158-166.
- [5] 程明,翟金星,马骏,等.基于迁移学习的CNN-GRU短期电力负荷预测方法[J].武汉大学学报(工学版),2024,57(6):812-820.
CHENG Ming, ZHAI Jinxing, MA Jun, et al. Transfer learning based CNN-GRU short-term power load forecasting method [J]. Engineering Journal of Wuhan University, 2024, 57(6): 812-820.
- [6] 杨丽徙,张永锋,许向伟,等.半参数回归分析法在电力负荷预测中的应用[J].郑州大学学报(工学版),2010,31(3):29-32.
YANG Lixi, ZHANG Yongfeng, XU Hongwei, et al. Application of semi-parametric regression analysis method in electric power load forecasting [J]. Journal of Zhengzhou University (Engineering Science), 2010, 31(3): 29-32.
- [7] 侯慧,王晴,赵波,等.关键信息缺失下基于相空间重构及机器学习的电力负荷预测[J].电力系统保护与控制,2022,50(4):75-82.
HOU Hui, WANG Qing, ZHAO Bo, et al. Power load forecasting without key information based on phase space reconstruction and machine learning [J]. Power System Protection and Control, 2022, 50(4): 75-82.
- [8] 叶远胜,张静.基于时间序列的SVM短时电力负荷预测[J].现代信息科技,2020,4(24):17-19.
YE Yuansheng, ZHANG Jing. SVM short term power load forecasting based on time series [J]. Modern Information Technology, 2020, 4(24): 17-19.
- [9] 姚博骞.基于SSA优化CNN-GRU的短期电力负荷预测[D].西安:西安理工大学,2024.
YAO Bojian. Optimization of CNN-GRU short-term power load forecasting based on SSA [D]. Xi'an: Xi'an University of Technology, 2024.
- [10] 吴梦凯.新常态下中长期电力负荷分析与预测方法研究[D].北京:华北电力大学,2018.
WU Mengkai. Research on medium and long-term power load analysis and forecasting methods under the new normal [D]. Beijing: North China Electric Power University, 2018.
- [11] HE C B, JIA Z H, HU J, et al. CDTDNet: a neural network for capturing deep temporal dependencies in time series [J]. Information Sciences, 2025, 706: 121995.
- [12] ZHUANG W, XI Q Y, LU C X, et al. A novel trend and periodic characteristics enhanced decoupling framework for multi-energy load prediction of regional integrated energy systems [J]. Electric Power Systems Research, 2024, 237: 111028.
- [13] CUI J P, KUANG W, GENG K, et al. Advanced short-term load forecasting with XGBoost-RF feature selection and CNN-GRU [J]. Processes, 2024, 12(11): 2466.
- [14] 钱仲文,陈浩,纪德良.一种基于XGBoost算法的月度负荷预测方法[J].浙江电力,2019,38(5):77-82.
QIAN Zhongwen, CHEN Hao, JI Deliang. A monthly load forecasting method based on XGBoost algorithm [J]. Zhejiang Electric Power, 2019, 38(5): 77-82.
- [15] 范玲.基于萤火虫算法的光伏配电网负荷过载预测研究[J].电子设计工程,2023,31(23):95-99.
FAN Ling. Research on load overload prediction of photo-

- voltaic distribution network based on firefly algorithm[J]. Electronic Design Engineering, 2023, 31(23): 95-99.
- [16] 刘瑾, 赵晶, 冯瑛敏, 等. 基于梯度提升决策树的电力物联网用电负荷预测[J]. 智慧电力, 2022, 50(8): 46-53.
LIU Jin, ZHAO Jing, FENG Yingmin, et al. Power load forecasting in power Internet of Things based on gradient boosting decision tree[J]. Smart Power, 2022, 50(8): 46-53.
- [17] 黄晓燕, 郭洒洒, 陈成优, 等. 考虑时空关联及气象耦合的区域分布式光伏功率预测[J]. 浙江电力, 2025, 44(3): 79-89.
HUANG Xiaoyan, GUO Sasa, CHEN Chengyou, et al. Regional distributed photovoltaic power forecasting considering spatiotemporal correlation and meteorological coupling[J]. Zhejiang Electric Power, 2025, 44(3): 79-89.
- [18] HU J X, DUAN P F, CAO X D, et al. A multi-energy load forecasting method based on the Mixture-of-Experts model and dynamic multilevel attention mechanism[J]. Energy, 2025, 324: 135947.
- [19] 温静. 基于RNN的电力负荷波动分析及预测研究[J]. 电气开关, 2024, 62(5): 13-15.
WEN Jing. Analysis and prediction of power load fluctuation based on RNN[J]. Electric Switchgear, 2024, 62(5): 13-15.
- [20] 张淑娴, 江文韬, 陈玉花, 等. 基于二次模态分解的LSTM短期电力负荷预测[J]. 科学技术与工程, 2024, 24(7): 2759-2766.
ZHANG Shuxian, JIANG Wentao, CHEN Yuhua, et al. Short-term power load forecasting based on quadratic mode decomposition through LSTM[J]. Science Technology and Engineering, 2024, 24(7): 2759-2766.
- [21] 葛亚明, 仇晨光, 谢丽荣, 等. 基于K-means聚类与LSTM模型的多能源耦合电力负荷预测[J]. 现代电力, 2025, 42(2): 369-376.
GE Yaming, QIU Chenguang, XIE Lirong, et al. Research on multi-energy coupled power load prediction based on K-means clustering and LSTM model[J]. Modern Electric Power, 2025, 42(2): 369-376.
- [22] WANG N E, LI Z M. Short term power load forecasting based on BES-VMD and CNN-Bi-LSTM method with error correction[J]. Frontiers in Energy Research, 2023, 10: 1076529.
- [23] 周磊, 竺筱晶. 基于MA-CNN-LSTM和自注意力机制的单变量短期电力负荷预测[J]. 科学技术与工程, 2024, 24(22): 9408-9416.
ZHOU Lei, ZHU Xiaojing. Univariate short-term electrical load based on MA-CNN-LSTM-self attention[J]. Science Technology and Engineering, 2024, 24(22): 9408-9416.
- [24] 杨坚, 赵洁, 汤义勤, 等. 基于序列分解的母线负荷降噪预测方法[J]. 浙江电力, 2023, 42(12): 81-87.
YANG Jian, ZHAO Jie, TANG Yiqin, et al. A noise reduction forecasting method of bus load based on sequence decomposition[J]. Zhejiang Electric Power, 2023, 42(12): 81-87.
- [25] 唐竹, 肖宇航, 郭淳, 等. 基于CEEMDAN模态分解和TCN-BiGRU的短期电力负荷预测[J]. 智慧电力, 2024, 52(12): 59-64.
TANG Zhu, XIAO Yuhang, GUO Chun, et al. Short-term electricity load forecasting based on CEEMDAN decomposition and TCN-BiGRU model[J]. Smart Power, 2024, 52(12): 59-64.
- [26] 李志军, 徐博, 张家安, 等. 基于TD3可变长度时间窗口最优加权的短期负荷预测策略[J]. 电力建设, 2024, 45(6): 140-148.
LI Zhijun, XU Bo, ZHANG Jiaan, et al. Short-term load optimal weighted forecasting strategy based on TD3 variable length time window[J]. Electric Power Construction, 2024, 45(6): 140-148.
- [27] 庄立生. 融合气象特征的BP神经网络电力系统短期负荷预测[J]. 山东电力技术, 2023, 50(11): 51-59.
ZHUANG Lisheng. Short-term load forecasting for power systems based on BP neural networks[J]. Shandong Electric Power, 2023, 50(11): 51-59.
- [28] 寿绍安, 罗海荣, 王晓康, 等. 基于VMD-ISODATA-DBN的配电台区短期负荷预测方法[J]. 智慧电力, 2023, 51(11): 53-60.
SHOU Shaoan, LUO Hairong, WANG Xiaokang, et al. Forecasting method of short-term load in distribution station area based on VMD-ISODATA-DBN[J]. Smart Power, 2023, 51(11): 53-60.
- [29] 袁郁, 杨超, 郑伟铭, 等. 基于Bi-SRNN的联邦学习区域电力短期负荷预测模型[J]. 电网与清洁能源, 2023, 39(10): 45-55.
YUAN Yu, YANG Chao, ZHENG Weiming, et al. The federated learning power short term load forecasting model based on Bi-SRNN[J]. Power System and Clean Energy, 2023, 39(10): 45-55.
- [30] 朱海南, 李丰硕, 孙华忠, 等. 基于改进AlexNet-GRU深度神经网络的配电网短期负荷预测方法[J]. 电力电容器与无功补偿, 2023, 44(4): 48-54.
ZHU Hainan, LI Fengshuo, SUN Huazhong, et al. Short-term load prediction method of distribution network based on improved AlexNet-GRU deep learning network[J]. Power Capacitor & Reactive Power Compensation, 2023, 44(4): 48-54.
- [31] 向德军, 张维静, 冯歆尧, 等. 考虑特征值细分的广义加性短期负荷预测模型[J]. 电力需求侧管理, 2023, 25(1): 46-51.

- XIANG Dejun, ZHANG Weijing, FENG Xinyao, et al. Generalized additive short-term load forecasting model considering eigenvalue subdivision [J]. Power Demand Side Management, 2023, 25(1): 46-51.
- [32] 唐晓, 陈芳, 许强, 等. 改进鲸鱼算法优化的多维度深度极限学习机短期负荷预测[J]. 山东电力技术, 2023, 50(1): 1-7.
- TANG Xiao, CHEN Fang, XU Qiang, et al. Short-term load forecasting based on multi-dimensional deep extreme learning machine optimized by improved whale algorithm [J]. Shandong Electric Power, 2023, 50(1): 1-7.
- [33] 付泉泳, 秦晓, 张导, 等. 基于GCN-Informer模型的电力负荷短期预测[J]. 电力大数据, 2024, 27(7): 22-34.
- FU Quanyong, QIN Xiao, ZHANG Dao, et al. Short term forecasting of power load based on GCN-informer model [J]. Power Systems and Big Data, 2024, 27(7): 22-34.
- [34] 李甲祎, 赵兵, 刘宣, 等. 基于DWT-Informer的台区短期负荷预测[J]. 电测与仪表, 2024, 61(3): 160-166.
- LI Jiayi, ZHAO Bing, LIU Xuan, et al. Short-term substation load forecasting based on DWT-Informer model [J]. Electrical Measurement & Instrumentation, 2024, 61(3): 160-166.
- [35] 曹帅, 尹杰, 李艺丰, 等. 基于VMD-SSA-BiLSTM的多维时序电力负荷预测[J]. 电力需求侧管理, 2024, 26(6): 88-93.
- CAO Shuai, YIN Jie, LI Yifeng, et al. Multi-featured power load forecasting based on VMD-SSA-Bi LSTM [J]. Power Demand Side Management, 2024, 26(6): 88-93.
- [36] 袁玉宝, 屈海云, 任庆峰. 考虑分时段变化趋势的PCA-SABO-BiLSTM短期电力负荷预测方法研究[J]. 电气自动化, 2025, 47(1): 82-85.
- YUAN Yubao, QU Haiyun, REN Qingfeng. Research on PCA-SABO-BiLSTM short term power load forecasting method considering time period trends [J]. Electrical Automation, 2025, 47(1): 82-85.
- [37] 杨城, 刁艳美, 刘颂. 基于VMD-希尔伯特变换的机车信号解调方法[J]. 铁路计算机应用, 2025, 34(2): 76-82.
- YANG Cheng, DIAO Yanmei, LIU Song. Cab signal demodulation method based on VMD and Hilbert transform [J]. Railway Computer Application, 2025, 34(2): 76-82.
- [38] 张征鑫, 张笃振. 基于键值注意力机制的目标检测算法性能优化[J]. 计算机系统应用, 2025, 34(4): 195-206.
- ZHANG Zhengxin, ZHANG Duzhen. Performance optimization of object detection algorithm based on key-value attention mechanism [J]. Computer Systems and Applications, 2025, 34(4): 195-206.
- [39] 韩宝慧, 陆玲霞, 包哲静, 等. 基于多头概率稀疏自注意力模型的综合能源系统多元负荷短期预测[J]. 电力建设, 2024, 45(2): 127-136.
- HAN Baohui, LU Lingxia, BAO Zhejing, et al. Short-term forecasting of multienergy loads of integrated energy system based on multihead probabilistic sparse self-attention model [J]. Electric Power Construction, 2024, 45(2): 127-136.
- [40] 张钰声, 曹敏, 雷宇, 等. 基于SSA-BiGRU-CNN神经网络和波动数据修正的电动汽车短期负荷预测模型[J]. 电网与清洁能源, 2025, 41(2): 67-74.
- ZHANG Yusheng, CAO Min, LEI Yu, et al. A short-term load forecasting model for electric vehicles based on the SSA-BiGRU-CNN neural network and fluctuation data correction [J]. Power System and Clean Energy, 2025, 41(2): 67-74.

收稿日期: 2025-05-27; 修回日期: 2025-06-18

作者简介:

许世欣(2000), 女, 硕士研究生, 研究方向为虚拟电厂、负荷预测、数字孪生等。

彭道刚(1977), 男, 教授, 博士生导师, 研究方向为低碳智能发电、综合智慧能源与虚拟电厂等。(通信作者)

(本文编辑: 徐 聆)