

基于 WTCN-BiGRU 的 CatBoost 短期负荷预测方法

李子乾, 张才俊, 王殊, 王亦秋, 徐胤, 赵金利

(国家电网有限公司客户服务中心, 天津 300300)

摘要:电力系统中短期负荷波动性强、随机性大, 给其预测带来一定困难。由此, 提出一种基于多模型融合的 WTCN-BiGRU-Attention-CatBoost 短期电力负荷预测方法。通过变分模态分解(VMD)对原始负荷数据进行分解, 提取其固有模态分量, 有效缓解数据非平稳性, 将分解后数据送入 WTCN-BiGRU-Attention 神经网络, 利用改进鲸鱼优化算法优化网络超参数, 接着将其与 CatBoost 回归模型并行结合, 之后引入平均绝对百分比误差倒数加权(MAPE-RW)融合算法对融合权重进行搜索, 构建最佳融合策略, 形成最终输出。仿真结果表明, 所提出的融合模型的 MAPE 和 RMSE 分别为 0.625 5% 与 72.654 MW, 相较于单一模型误差指标上均明显降低, 表明其短期具备更强的泛化能力和抗干扰性能。

关键词:短期负荷预测; VMD 方法; WTCN 深度学习架构; 鲸鱼优化算法; CatBoost 算法

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqcd26669

Short-term Electricity Load Forecasting Method Based on Multi-model Fusion WTCN-BiGRU-Attention-CatBoost

LI Ziqian, ZHANG Caijun, WANG Shu, WANG Yiqiu, XU Yin, ZHAO Jinli

(Customer Service Centre of State Grid Corporation, Tianjin 300300, China)

Abstract: Short-term load forecasting in power systems is challenging due to its strong volatility and high randomness. A short-term power load prediction method based on multi-model fusion was proposed, specifically the WTCN-BiGRU-Attention-CatBoost approach. The original load data was decomposed using variational mode decomposition (VMD) to extract its intrinsic modal components, effectively mitigating data non-stationarity. The decomposed data was then fed into the WTCN-BiGRU-Attention neural network, the network hyperparameters were optimized using an improved whale optimization algorithm, followed by parallel integration with the CatBoost regression model. Subsequently, the MAPE-RW fusion algorithm was introduced to search for fusion weights, establishing the optimal fusion strategy and generating the final output. Simulation results show that the proposed fusion model achieves MAPE and RMSE values of 0.625 5% and 72.654 MW, respectively, both significantly lower than those of single models, indicating its superior short-term generalization capability and interference resistance.

Key words: short-term load forecasting; variational mode decomposition (VMD) method; wavelet temporal convolutional network (WTCN) deep learning architecture; whale optimization algorithm; CatBoost algorithm

随着科技的不断发展与社会结构的演进, 电力行业已成为支撑现代工业、商业及民生的重要基础, 其系统的稳定性与可靠性更被视为衡量国家综合实力的重要指标^[1-2]。作为保障生产生活运转的核心支柱, 电力系统在“十四五”规划中被赋予战略转型目标, 明确提出要推动能源结构优化, 逐步摆脱对化石能源的依赖, 全面发展光伏、风能、潮汐能等可再生能源, 以实现电力行业的

绿色低碳转型。面对能源类型多样、地域分布广泛、接入方式复杂等新特征, 传统电力系统的运行模式逐渐暴露出适应性不足的局限, 而准确高效的负荷预测则成为支撑新型能源系统调控与运行优化的关键基础^[3]。

近年来, 机器学习与深度神经网络在电力预测领域得到了广泛应用^[4-5]。相较于传统统计方法, 智能算法能够更好地捕捉负荷数据中的非线性

基金项目: 国网客户服务中心项目(SGKFYY00TGJS23100085)

作者简介: 李子乾(1984—), 男, 本科, 高级工程师, 主要研究方向为企业信息化建设及运维, Email: lzq_ian@163.com

性与动态演化特征,显著提高预测精度并减少人为干扰^[6]。例如,文献[7]针对住宅小区的短期热负荷需求,构建卷积神经网络(convolutional neural network, CNN)预测模型,并引入缎蓝园丁鸟算法对网络参数进行优化,在实际数据集上验证了模型的有效性。文献[8]则提出将多相门控循环网络(multi-dimensional gated recurrent units, MD-GRU)与CNN融合,采用全局平均池化策略以应对高维空间-时间特征建模问题,提升了模型在复杂环境下的泛化能力。然而,当前大多数融合方法仅通过静态权重简单叠加各子模型结果,未能充分挖掘各模型在不同数据维度下的性能差异。

为提升预测模型的精度与适应性,本文提出一种结合变分模态分解^[9](variational mode decomposition, VMD)与改进鲸鱼优化算法^[10](improved whale optimization algorithm, IWOA)的WTCN-BiGRU-Attention短期负荷预测方法。该方法首先通过VMD对原始负荷序列进行分解,提取平稳性更高的模态分量以降低建模难度;随后分别构建CatBoost回归模型与WTCN-BiGRU-Attention深度网络以捕捉负荷的多尺度时序特征;并利用IWOA对各模型关键超参数进行自适应优化,克服传统手工调参带来的性能瓶颈;最后引入基于MAPE反比加权机制对各子模型输出进行动态融合,从而兼顾局部精度与整体稳定性。实验结果显示,所提出模型在多项评估指标上均优于现有主流方法,具备良好的实用性和推广前景。

1 智能预测模型设计

在负荷预测任务中,时间序列数据蕴含着影响负荷变化趋势的重要信息。然而,传统预测模型在特征提取方面存在一定局限性,难以充分挖掘数据规律。相较之下,机器学习适用于平稳序列的建模,而深度学习在处理非平稳数据方面表现更优^[11]。为提升预测精度,本文提出了一种基于多模型集成的智能预测方案。该方法通过集成多种神经网络的优势,能够更全面地提取数据中的特征信息。具体的模型架构如图1所示。

本研究提出了一种创新的负荷预测方法,其技术路线如下:首先采用VMD技术对原始负荷数据进行预处理,将其分解为多个具有物理意义的模态分量。在特征提取阶段,引入小波时域卷积网络(wavelet temporal convolutional network,




图1 多模型融合网络负荷智能预测模型

Fig.1 Multi-model fusion network load intelligent prediction model WTCN)来捕获负荷数据的多尺度特征。随后,通过双向门控循环单元(bidirectional gated recurrent unit, BiGRU)网络融合多维特征并进行时序建模,同时结合注意力机制(attention mechanism, AM)突出关键特征的影响权重。为提高模型性能,采用IWOA对网络超参数进行优化。最终预测阶段,将深度学习方法与CatBoost算法的预测结果通过基于MAPE倒数加权的融合策略进行集成,从而构建出更加鲁棒的智能预测系统。

1.1 基于VMD负荷数据处理

VMD是一种先进的信号处理技术,由Konstantin研究团队在2014年首次提出。该方法采用完全非递归的自适应变分框架,通过精确控制各模态的带宽参数,有效解决了传统经验模态分解(empirical mode decomposition, EMD)方法中存在的模态混叠问题。VMD技术能够将复杂信号分解为一系列具有明确中心频率的本征模态函数(intrinsic mode function, IMF),这些分量在频域上具有更好的分离特性,特别适合处理具有强非线性和高波动特性的电力负荷数据。该算法的

实现过程主要包括以下关键步骤:

构建带约束的变分优化问题:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(d(t) + \frac{j}{pt} \right) g u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^K u_k(t) = S \end{cases} \quad (1)$$

式中: $\{u_k\}$, $\{\omega_k\}$ 分别为 VMD 模态集和中心频率; k 为 IMF 数量。

引入二次惩罚项 β 和拉格朗日乘子 λ :

$$\begin{aligned} L(u_k, \omega_k, \lambda) = & \beta \sum_{k=1}^K \left\| \partial_t \left[\left(d(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (2)$$

使用交替方向乘子法求解,过程如下:

$$\sum_{k=1}^K \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 < \gamma \quad (3)$$

式中: γ 为容许误差; n 为迭代次数。

$\hat{u}_k^{n+1}$, $f(t)$, $\lambda(t)$ 经傅里叶变换为 $\hat{u}_k^{n+1}(\omega)$, $\hat{f}(\omega)$, $\hat{\lambda}^n(\omega)$ 。

1.2 WTCN-BiGRU-Attention 模型

电力系统历史负荷数据蕴含着丰富的规律特征信息。这些时序数据不仅记录了电力负荷的变化轨迹,还隐含着用电行为模式、季节周期特性以及突发事件影响等多维度信息特征。通过深入挖掘这些历史数据的内在规律,可以显著提升预测模型的准确性和鲁棒性^[12]。在时序特征提取方面,采用具有长程记忆能力的时序卷积网络(temporal convolutional network, TCN),其独特的扩张因果卷积结构能够有效捕获负荷数据中的长期依赖关系。同时引入 BiGRU 网络,通过其前向和后向的信息传递机制,进一步提升了模型对时序动态特征的建模能力。为优化特征选择过程,采用 AM 自动学习各特征维度的重要性权重,使模型能够聚焦于关键特征。通过这种多网络协同的混合建模框架,实现了对负荷数据深层特征的充分挖掘,从而显著提升了预测精度。

TCN 作为卷积神经网络的重要改进架构,在时序特征提取方面展现出独特优势。该网络通过因果卷积确保时序特性,利用膨胀卷积扩展感受野,结合残差连接构建深层结构。本研究提出的 WTCN 模型在传统 TCN 框架中创新性地采用 Morlet 小波函数作为残差模块的激活函数,其数

学表达式为

$$y = \cos(1.75x) e^{-x^2/2} \quad (4)$$

式中: x 为残差块的输入。

在 WTCN 网络架构中,针对 VMD 分解得到的各模态分量,系统性地整合了负荷特征相关变量。该网络创新性地采用 Morlet 小波函数替代传统激活函数,构建了具有时频分析能力的残差模块。通过这种设计, WTCN 层实现了对负荷数据及其关联因素的高效特征提取。

GRU 网络作为 LSTM 网络的简化版本,相较于 LSTM 的 3 个门控单元, GRU 只含有重置门和更新门,其参数较少更易收敛^[12-13]。BiGRU 网络在 GRU 基础上改进为双向传播架构,通过前向和后向两个独立的信息流实现时序特征的双向提取。与单向 GRU 不同, BiGRU 的前后向隐藏层互不干扰。本研究采用双层 BiGRU 结构,对 WTCN 提取的特征进行深度时序建模,有效捕捉数据的时间相关性。

AM 采用权重分配策略强化关键特征,防止其在训练过程中被弱化。本研究以 BiGRU 网络的双层激活输出作为 AM 输入,依据特征重要性计算各向量的权重分布,并通过参数优化过程动态调整权重矩阵。

1.3 改进鲸鱼优化算法

鲸鱼优化算法食位置描述如下式所示:

$$\begin{cases} D = |C \cdot X^*(t) - X(t)| \\ X(t+1) = X^*(t) - A \cdot D \end{cases} \quad (5)$$

式中: t 为迭代次数; A , C 为控制参数向量; $X^*(t)$ 为当前最优解的位置向量; $X(t)$ 为个体当前的位置向量。

为模拟鲸鱼捕猎时螺旋游动与收缩包围的同步行为,在建立数学模型时设定两种行为的发生概率各为 50%。该机制可表示为

$$X(t-1) = \begin{cases} X^*(t) - A \cdot D & p < 0.5 \\ D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t) & p \geq 0.5 \end{cases} \quad (6)$$

其中

$$D' = |X^*(t) - X(t)|$$

式中: D' 为当前鲸鱼搜索个体与最优个体之间的距离; p 为捕食机制概率,其值域为 $[0, 1]$ 之间的随机数。

然而传统鲸鱼优化算法在全局搜索与局部挖掘的协调上存在一定的局限性^[14]。图 2 显示,鲸鱼优化算法采用边界收缩策略来减小搜索范围,其收敛性能取决于收敛因子的调节作用。




图2 WOA收缩包围机制

Fig.2 WOA shrink-wrap mechanism

由于线性递减难以准确描述优化过程特征,因此采用非线性收敛因子进行改进:

$$a = 2 - 2\sin(u \frac{t}{\max_iter} \pi + \varphi) \quad (7)$$

式中: $u = 2$; $\varphi = 0$; $\max_iter$ 为最大迭代次数。

优化初期采用较大收敛因子值,通过渐进递减方式扩大参数搜索空间;随着迭代进行,收敛因子加速衰减,从而提升算法收敛效率。

线性因子虽能改善算法性能,但因未充分利用鲸鱼位置向量,会降低种群灵活性并影响优化效果。为此,本文添加自适应权重来进一步增强算法的全局搜索能力,其计算公式如下:

$$Q = 0.2\cos[\frac{\pi}{2}(1 - \frac{t}{\max_iter})] \quad (8)$$

采用 $f(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$ 作为基准测试函数,为验证改进鲸鱼优化算法(IWOA)的性能表现,实验设置500次迭代,测试函数维度为30,并取10次实验均值作为最终结果。图3对比结果显示,相较于WOA和仅改进收敛因子的NWOA,同时具备自适应权重和非线性收敛因子的IWOA在收敛速度和精度方面均有显著提升,其算法流程如图4所示。

1.4 WTCN-BiGRU-Attention-CatBoost 短期负荷预测模型

在VMD层中,电力负荷数据作为输入,其模态数和惩罚因子由中心频率确定。合理选择 k 值既可防止模态混叠,又能减少IWOA组合预测模型的参数量。WTCN层接收VMD分解的负荷数据分量和天气特征作为WTCN-BiGRU-Attention模型的输入。采用卷积核尺寸3,权重归一化处理,Dropout率0.2抑制过拟合并加速收敛,扩张系




图3 标准测试函数验证WOA算法的收敛特性

Fig.3 Convergence properties of the WOA algorithm verified by standard test functions




图4 IWOA优化算法流程图

Fig.4 Flowchart of IWOA optimization algorithm

数配置为(1,2,4,8,16,32),同时设置128个过滤器。

在WTCN-BiGRU-Attention模型训练中,采用Adam优化器更新网络参数。该一阶优化方法通过自适应调整学习率,比传统梯度下降更高效地最小化损失函数。模型使用均方误差(MSE)作为损失评价指标,其数学表达式为

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (9)$$

式中: N 为样本数量; y_i , $\hat{y}_i$ 分别为负荷真实值和预测值。

CatBoost是基于梯度提升决策树(gradient boosting decision trees,GBDT)的优化算法。相较于传统GBDT,该算法通过减少参数数量、消除梯度偏差和预测偏移,显著降低了过拟合概率,增强了泛化性能。特别适用于负荷预测等数据挖

据任务,其并行计算特性大幅提升了运算效率。算法表达式如下:

$$\hat{x}_k^i = \frac{\sum_{j=1}^{q-1} [x_{\sigma_j,k} = x_{\sigma_i,k}] \cdot Y_{\sigma_j} + a \cdot q}{\sum_{j=1}^{q-1} [x_{\sigma_j,k} = x_{\sigma_i,k}] + a} \quad (10)$$

式中: σ 为先验项权重系数; q 为先验项,对于回归任务,CatBoost算法默认采用数据集的平均值作为先验项取值。

CatBoost适用于平稳序列预测,其预测结果与WTCN-BiGRU-Attention网络输出采用MAPE-RW算法融合。通过其加权优化初始权重配置,全局自适应搜索最优权重组合,建立最优融合模型。最终预测值表达式如下:

$$\begin{cases} Q_i = \frac{M_j}{M_i + M_j} \\ f_{\text{final}} = Q_{\text{VTWBA}} f_{\text{Catboost}} + Q_{\text{Catboost}} f_{\text{VTWBA}} \end{cases} \quad (11)$$

式中: Q_i (Q_{VTWBA} , Q_{Catboost}) 为对应模型权重,即MAPE-RW自适应权重搜索; f_{final} 为多模型融合最终预测输出; f_{Catboost} , f_{VTWBA} 为预测输出。

2 预测模型算例

2.1 数据处理

为优化神经网络训练过程,本研究使用min-max归一化技术将输入数据转换至(0,1)区间。为实现预测负荷与实际值的可比性,对模型输出执行逆向归一化处理。计算公式如下:

$$\begin{cases} x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \\ x = x_n (x_{\max} - x_{\min}) + x_{\min} \end{cases} \quad (12)$$

式中: x 为原始负荷数据; $x_{\max}$, $x_{\min}$ 分别为样本数据的极值; x_n 为归一化处理后的数据值。

2.2 数据选取与参数整定

本研究通过RMSE, MAPE, MAE和R-square 4项指标评估模型性能。其中RMSE和MAPE指标值均为测试集数据的计算结果,以此客观反映模型预测的准确性和可靠性。

数据来源于2006年—2010年澳大利亚某区域的电力负荷及气象数据。除去荷数据还涉及5个特征向量,分别是湿球温度、干球湿度、相对湿度、露点温度和电价。采用30 min采样间隔(每日48个样本点),以固定时间窗为输入特征,下一时刻负荷为输出标签,实施单步滚动预测。数据

集按照3:1:1划分,即前3年用于模型训练,第4年作为验证集优化超参数,第5年作为独立测试集评估模型性能。特征参数如表1所示。

表1 特征参数

Tab.1 The parameterization

特征信息	特征描述	特征类型
日期	采样间隔 30 min	时间
天气	绝对饱和温度	湿球温度
	真实热力学温度	干球湿度
	大气干燥程度	湿度
	水蒸气与水达平衡状态温度	露点湿度
经济	价格	kW·h
负荷	电量	MW

模型验证结果表明(图5),当变分模态分解参数惩罚因子为1 850,收敛容差 $tol=1e-7$,模态数为5时,中心频率稳定性最佳且分解层数最少,5个分解模态(IMF1, IMF2, IMF3, IMF4, IMF5)结果如图6所示。




图5 不同k值的中心频率

Fig.5 Different k values correspond to the center frequency




图6 VMD分解结构

Fig.6 Structure of VMD Decomposition

为确保IWOA算法在合理范围内优化网络超参数,表2给出了各参数的取值范围。经IWOA优化后的WTCN-BiGRU-Attention网络最终参数配置如表3所示。

通过随机搜索算法对CatBoost层网络的超参数进行优化,最终确定的最优超参数组合如表4所示。

表2 IWOA具体参数设置
Tab.2 Parameter settings for IWOA

参数	参数值	
参数设置	5	鲸鱼数量
	5	最大迭代次数
	2	常数 b
寻优上下界	[0.001,0.01]	学习率
	[10,100]	网络迭代次数
	[16,128]	批量大小
	[1,20]	BiGRU网络节点数
	[1,100]	全连接层节点数

表3 WTCN-BiGRU-Attention最优超参数
Tab.3 WTCN-BiGRU-Attention network optimal hyperparameters

模型标签	IMF1	IMF2	IMF3	IMF4	IMF5
全连接层节点	49	4	46	14	97
WTCN节点	16	11	7	17	19
BiGRU节点	8	18	8	17	2
网络迭代次数	38	26	61	70	89
批量大小	72	19	72	37	22
学习率	0.004 7	0.002 7	0.006 4	0.005 4	0.002 4

表4 CatBoost层网络最优超参数
Tab.4 Optimal hyperparameters for CatBoost layer networks

Verbose	学习率	最大迭代次数	树深
50	0.03	900	12

3 结果分析

为直观比较预测精度,对2010年12月22日—28日共一周每日负荷数据进行预测,将本文模型与传统单一模型及混合模型进行对比分析。表5展示了不同分支模型与本文所提融合模型负荷预测评价指标对比。图7展示了2010年12月28日单日的负荷预测结果曲线,可见本文模型预测结果更准确稳定,与真实负荷吻合度最高。

表5 模型测试集总预测评价指标

预测模型	RMSE	MAPE	MAE	R -square
	/MW	%	/MW	
WTCN-BiGRU-A	108.532	0.862	75.137	0.964
IWOA-WTCN-BiGRU-A	113.386	0.929	84.479	0.975
CatBoost	87.826	0.719	66.28	0.984
本文组合模型	72.654	0.625 5	55.70	0.995

表6和表7呈现了各模型的中期(2010年每个月)负荷预测误差指标,MAPE和MAE值越小表明模型性能越优。数据显示,本文提出的融合模型相比IWOA-WTCN-BiGRU-A和CatBoost单独预测时精度更高:RMSE分别下降40.732 MW和15.172 MW,MAPE降低0.305 5%和0.093 5%,

MAE减少28.779 MW和10.58 MW。可能是由于IWOA-WTCN-BiGRU-A在负荷平稳时预测误差较大,因其VMD分解过程存在数据损失;而CatBoost虽擅长预测稳态分量,但对波动数据适应性较差。通过MAPE-RW算法整合二者的优势,显著提升了预测精度。




图7 单日负荷预测结果

Fig.7 Load forecasting results of one day

表6 MAPE模型预测评价指标

Tab.6 MAPE model predictive evaluation indicators

月	WTCN-BiGRU-A	IWOA-WTCN-BiGRU-A	CatBoost	本文
1	0.945	0.783	0.733	0.636
2	0.854	0.815	0.666	0.553
3	0.739	0.765	0.649	0.545
4	0.959	0.856	0.924	0.716
5	0.865	1.058	0.753	0.636
6	0.776	1.123	0.613	0.653
7	0.830	1.037	0.653	0.645
8	0.852	1.259	0.673	0.718
9	0.830	1.079	0.634	0.674
10	0.877	0.849	0.843	0.617
11	0.895	0.766	0.753	0.568
12	0.921	0.766	0.735	0.545

表7 MAE模型预测评价指标

Tab.7 MAE model predictive evaluation indicators

月	WTCN-BiGRU-A	IWOA-WTCN-BiGRU-A	CatBoost	本文
1	83.71	72.51	68.97	60.53
2	78.32	76.75	59.45	52.95
3	63.27	66.75	64.75	42.52
4	78.41	73.43	74.75	60.26
5	72.51	94.64	67.85	60.01
6	74.35	105.42	65.85	61.47
7	75.65	103.63	67.85	56.74
8	81.43	123.53	63.85	70.12
9	73.53	99.78	64.85	64.46
10	74.53	69.25	65.87	50.74
11	73.53	64.52	65.57	43.52
12	72.41	63.54	65.75	45.02

4 结论

本研究采用VMD方法将负荷数据分解为平稳和非平稳分量,作为IWOA优化的WTCN-BiGRU-Attention模型输入,同时以原始数据构建CatBoost模型。通过MAPE-RW算法融合两种模型的预测结果,有效提升了负荷预测精度,为电力系统优化调度和微电网建设提供可靠依据。本文提出的模型规模总可训练参数量约0.83 M,计算复杂度较低,具有良好的实时性。本研究为未来多元化电力结构的科学调控奠定了基础,对保障电力系统稳定运行具有重要意义。

参考文献

- [1] 赵发金,舒征宇,王灿,等. 基于LASSO和LSTM-GRU的综合能源系统负荷预测[J]. 电气传动,2025,55(8):51-57.
Zhao Fajin, Shu Zhengyu, Wang Can, et al. Integrated energy system load forecasting based on LASSO and LSTM-GRU[J]. Electric Drive, 2025, 55(8): 51-57.
- [2] 卢武,郑人杰,赵文彬,等. 基于EMD-GRU的短期电力负荷预测方法[J]. 电气传动,2022,52(21):74-80.
Lu Wu, Zheng Renjie, Zhao Wenbin, et al. Short-term power load forecasting method based on EMD-GRU[J]. Electric Drive, 2022, 52(21): 74-80.
- [3] Shan X, Lu X, Zhai M, et al. Analysis of key technologies for artificial intelligence applied to power grid dispatch and control [J]. Automation of Electric Power Systems, 2019, 43(1): 49-57.
- [4] Fan S, Li L, Wang S, et al. Application analysis and exploration of artificial intelligence technology in power grid dispatch and control[J]. Power System Technology, 2020, 44(2): 401-411.
- [5] 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.
- [6] 姚浩然,李成鑫,郑秀娟,等. 集成自适应喇叭模式分解和BiLSTM的短期负荷组合预测模型[J]. 电力系统保护与控制,2022,50(19):58-66.
Yao H R, Li C X, Zheng X J, et al. Short-term load combination forecasting model integrating ACMD and BiLSTM[J]. Power System Protection and Control, 2022, 50(19): 58-66.
- [7] Zhao A, Mi L, Xue X, et al. Heating load prediction of residential district using hybrid model based on CNN[J]. Energy and Buildings, 2022, 266: 112122.
- [8] Abid F, Alam M, Alamri F S, et al. Multi-directional gated recurrent unit and convolutional neural network for load and energy forecasting: a novel hybridization[J]. AIMS Mathematics, 2023, 8(9): 19993-20017.
- [9] Mahmoud M S, Rahman M S U, Al-Sunni F M. Networked control of microgrid system of systems[J]. International Journal of Systems Science, 2016, 47(11): 2607-2619.
- [10] Wu X, Xu Y, Wu X, et al. A two-layer distributed cooperative control method for islanded networked microgrid systems[J]. IEEE Transactions on Smart Grid, 2019, 11(2): 942-957.
- [11] 张羽姗,周亚同. 基于VMD-SSA-RF算法的短期电力负荷预测模型优化[J]. 电工电能新技术,2024,43(12):30-39.
Zhang Yushan, Zhou Yatong. Optimization of short-term power load forecasting model based on VMD-SSA-RF algorithm[J]. New Technologies in Electrical Engineering and Power, 2024, 43(12): 30-39.
- [12] Shi S, Xu Z, Xiao Y. Load identification method of household smart meter based on decision tree algorithm[J]. International Journal of Global Energy Issues, 2022, 44(5/6): 440-453.
- [13] Dehghan-Dehnavi S, Fotuhi-Firuzabad M, Moeini-Aghaie M, et al. Decision-making tree analysis for industrial load classification in demand response programs[J]. IEEE Transactions on Industry Applications, 2020, 57(1): 26-35.
- [14] Dudek G. A comprehensive study of random forest for short-term load forecasting[J]. Energies, 2022, 15(20): 7547.

收稿日期:2025-06-19

修改稿日期:2025-08-27