

DOI: 10.61369/NPS.2025040002

# 基于改进贝叶斯优化的 TCN-GRU 风光功率 预测

楚子易, 武雅慧, 张亚刚

(新能源电力系统全国重点实验室(华北电力大学), 北京 102206)

## Wind and Solar Power Forecasting based on Improved Bayesian Optimization of TCN-GRU

CHU Ziyi, WU Yahui, ZHANG Yagang

(National Key Laboratory of New Energy Power System(North China Electric Power University), Beijing 102206)

**摘要:**【目的】风能和太阳能因其清洁、可再生的特性,在能源转型中发挥着关键作用,但其出力受自然条件制约,兼具强随机性与波动性,导致功率预测难度显著提升。因此,提高二者的预测精度与效率成为亟待解决的问题。【方法】本文提出了一种基于改进自适应经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)和改进贝叶斯优化(surrogate safety-aware bayesian optimization, SSABO)的时域卷积网络-门控循环单元(temporal convolutional network-gated recurrent unit, TCN-GRU)风光功率综合预测模型,并结合自适应带宽核密度估计(adaptive bandwidth kernel density estimation, ABKDE)实现区间预测,以量化出力波动的不确定性。其中,ICEEMDAN算法通过自适应信号分解,有效抑制模态混叠问题,降低噪声干扰,充分提取数据特征。TCN-GRU模型简化了模型结构并提高了计算效率;引入SSABO优化关键参数,模型的收敛速度更快、寻优精度更高,显著提升了训练效率和预测精度。【结果】研究表明:ICEEMDAN算法有效解决了伪模态问题,数据分解效果优于传统CEEMDAN;SSABO优化后的TCN-GRU模型在风电和光伏数据集上的预测误差较未优化模型均有较大幅度的降低;ABKDE区间预测在不同置信水平下的覆盖率均优于理论值,验证了模型输出不确定性的可靠性。【结论】该模型适用于不同能源类型的预测,且具备较高的精度和效率,为风光功率预测提供了一种有效的解决方案。

**关键词:**风光互补发电系统;功率预测;CNN-GRU模型;贝叶斯优化;区间预测;预测误差;稳定性

**ABSTRACT:**[Objective] Wind and solar energy play a key role in energy transformation due to their clean and renewable characteristics. However, their output is restricted by natural conditions and has strong randomness and volatility, resulting in a significant increase in the difficulty of power prediction. Therefore, improving the prediction accuracy and efficiency of the two has become an urgent problem to be solved.[Methods] This paper proposes a temporal convolutional network-gated recurrent unit (TCN-GRU) wind and solar power prediction model based on improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) and surrogate safety-aware bayesian optimization (SSABO). Combined with adaptive bandwidth kernel density estimation (ABKDE), interval prediction is realized to quantify the uncertainty of output fluctuation. Among them, the ICEEMDAN algorithm effectively suppresses the modal aliasing problem, reduces noise interference, and fully extracts data features through adaptive signal decomposition. The TCN-GRU model simplifies the model structure and improves the computational efficiency. By introducing SSABO to optimize the key parameters, the convergence speed of the model is faster and the optimization accuracy is higher, which significantly improves the training efficiency and prediction accuracy.[Results] The research shows that the ICEEMDAN algorithm effectively solves the pseudo-modal problem, and the data decomposition effect is better than the traditional CEEMDAN. The prediction error of the TCN-GRU model optimized by SSABO on the wind power and photovoltaic data sets is greatly reduced compared with the unoptimized model. The coverage of ABKDE interval prediction at different confidence levels is better than the theoretical value, which verifies the reliability of the model output uncertainty.[Conclusion] The model is

基金项目: 国家自然科学基金项目 (U22B6006)。

Project Supported by National Natural Science Foundation of China (U22B6006).

suitable for the prediction of different energy types, and has high accuracy and efficiency, which provides an effective solution for wind and solar power prediction.

**KEY WORDS:**wind-solar complementary power generation system; power prediction; CNN-GRU model; bayesian optimization; interval prediction; prediction error; stability

## 0 引言

全球化石能源储量日渐枯竭, 能源转型进程显著加速, 可再生能源的开发与应用成为各领域的研究热点<sup>[1]</sup>。其中, 风能与太阳能凭借其清洁环保的特性已经成为可再生能源领域的重要组成部分。然而, 风电和光伏发电易受自然环境的影响, 具有很强的随机性和波动性<sup>[2]</sup>。在此背景下, 风电-光伏互补发电系统被认为是一种有效的解决方案<sup>[3]</sup>。因此, 深入研究风电-光伏发电预测技术, 研发更高效精准的预测模型, 对充分挖掘风光能源利用潜力、推动可再生能源规模化应用与电网技术升级发展具有重要的现实意义。

随着人工智能技术的发展, 国内外学者关于风电和光伏发电预测进行了大量的研究<sup>[4]</sup>。研究的方法一般可以分为3类, 分别是物理模型、统计模型和机器学习<sup>[5]</sup>。物理模型在中长期预测场景有显著优势, 但是该方法对气象数据的精度要求较高, 因此应用场景受到限制<sup>[6]</sup>。统计模型是通过挖掘历史数据的规律建立预测模型, 如差分自回归滑动平均法 (autoregressive integrated moving average, ARIMA)<sup>[7]</sup>和季节性自回归集成平均法 (seasonal autoregressive integrated moving average, SARIMA)<sup>[8]</sup>等。该方法可以有效捕捉时间序列的趋势性等特征, 但是难以提取数据的深层特征, 缺乏鲁棒性<sup>[9]</sup>。

受风电、光伏发电功率的波动性与不稳定性影响, 单一预测模型难以对其实现高精度的功率预测<sup>[10]</sup>。目前, 机器学习算法与信号分解算法相融合的混合预测模型, 成为风光预测领域的主流方向<sup>[11]</sup>。文献[12]用集合经验模态分解 (ensemble empirical mode decomposition, EEMD) 分解风功率, 又利用长短期记忆网络 (long short-term memory, LSTM) 提取数据特征, 以及利用麻雀搜索算法 (sparrow search algorithm, SSA) 优化超参数, 构建预测模型。文献[13]利用自适应噪声完备集合经验模态分解 (complete ensemble

empirical mode decomposition with adaptive noise, CEEMDAN) 分解序列, 又结合卷积神经网络 (convolutional neural network, CNN) 与 LSTM 挖掘序列的局部特征和长期趋势; 另外, 提出基于气象特征的多头注意力机制 (weather feature-based contextual multi-head attention, WCMA) 进一步提高模型的预测精度。文献[14]利用注意力机制提取风-光联动特征, 通过全连接网络预测发电量, 最后利用 LSTM 建立了依据历史负荷和功率预测的负荷预测模型。文献[15]将网格化的风速数据作为输入信息, 同时利用薄样条插值理论 (thin plate spline, TPS) 形成目标数据集, 同时利用生成对抗网络 (generative adversarial network, GAN) 实现风速的精准预测。组合模型的不断开发与应用大幅度提升了风光预测精度<sup>[16]</sup>。为了进一步提升预测效果, 研究引入多种优化算法对神经网络模型的参数进行寻优<sup>[17]</sup>。文献[18]通过灰狼优化算法 (grey wolf optimizer, GWO) 确定双向长短期记忆网络 (bidirectional long short-term memory network, BiLSTM) 模型的最优超参数组合, 有效地提升了光伏预测精度。研究使用 Harris 鹰算法 (harris hawks optimization, HHO) 优化控制器 (Transformer) 关键参数, 提升模型预测准确性与鲁棒性<sup>[19]</sup>。尽管预测领域的研究已取得显著成果, 但目前多数文献仍聚焦于单一的能源预测任务, 风电-光伏联合预测的研究较少。在模型选择上, 深度神经网络因其高精度的拟合特征而备受学者青睐<sup>[20]</sup>, 但是计算复杂度较高, 受参数设置影响较大。在处理大规模时间序列时, 较长的训练时间较长, 难以满足电网调度对高效预测的要求。

基于以上问题, 本文提出了一种基于改进型自适应经验模态分解 (improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN) 和改进贝叶斯优化算法 (surrogate safety-aware bayesian optimization, SSABO) 优化时域卷积网络-门控循环 (temporal convolutional network-gated recurrent unit, TCN-GRU) 的风光功率综合预测模型。首先, 通过 ICEEMDAN 算法自适应分解信号, 能够有效减少模态混叠现象和噪声残留, 更好地提取序列中的信息, 为后续功率的准确预测建立良好基础。其次, 在预测模型方面, 本文采用时域卷积网络 (temporal convolutional network, TCN) 和门控循环 (gated recurrent unit,

GRU)的组合模型(TCN-GRU),并利用SSABO对模型的超参数进行优化。TCN模块通过扩张感受野强化对局部波动的感知,而GRU模块则通过高效的门控循环单元实现对序列长期趋势特征的捕捉。相较于LSTM模型,GRU在保障预测结果准确性的基础上显著提升了训练速率。结合SSABO算法的全局寻优能力,提升了计算效率。此外,本文利用自适应带宽核密度估计(adaptive bandwidth kernel density estimation, ABKDE)<sup>[21]</sup>进行区间预测,量化风光功率的波动范围,点预测结果获取涵盖概率分布的全局信息。

综上所述,本文提出的ICEEMDAN自适应分解算法结合SSABO优化的TCN-GRU模型,不仅能对复杂信号实现高效分解,还要精准处理时间序列数据,需有效提升模型的泛化能力与鲁棒性,为风电、光伏功率预测问题提供了一个新的解决方案。

### 1 ICEEMDAN分解算法

ICEEMDAN是用于分解复杂信号的方法。基于早期的经验模态分解(empirical mode decomposition, EMD)容易出现模态混合、过度分解的问题<sup>[22]</sup>,ICEEMDAN相较于早期的改进版本集合经验模态分解(ensemble empirical mode decomposition, EEMD)、互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD),进一步提升了分解精度,能够有效地提取复杂信号中的不同特征。

$E_k(\cdot)$ 表示输入信号被EMD分解后产生的第 $k$ 阶IMF分量; $F(\cdot)$ 表示求信号的局部均值,具体的算法步骤如下:

步骤1:向待分解信号 $x$ 中加入 $N$ 组白噪声 $\omega^{(n)}$ ,生成一组构造序列组 $x^{(n)} = x + \beta_0 E_1(\omega^{(n)})$ ,其中 $n=1,2,\dots,N$ , $\beta$ 为噪声权重;

步骤2:对 $x^{(n)}$ 进行EMD分解,得到一组残差序列 $r_1 = F(x^{(n)})$ ,其中 $F(x^{(n)}) = x - E_1(x)$ 。计算得到第一阶分量 $I_{IMF1} = x - F(x^{(n)})$ ;

步骤3:继续向 $r_1$ 中添加第2阶的白噪声分量,利用局部均值算子 $F(\cdot)$ 计算得到第2组残差序列 $r_2 = F(r_1 + \beta_1 E_2(\omega^{(n)}))$ 和第2阶分量 $I_{IMF2} = r_1 - r_2$ ;

步骤4:重复像第 $k-1$ 阶残差序列中加入第 $k$ 阶的白噪声分量,得到第 $k$ 组残差序列 $r_k = F(r_{k-1} + \beta_{k-1} E_k(\omega^{(n)}))$ 和第 $k$ 阶分量 $I_{IMFk} = r_{k-1} - r_k$ ;

步骤5:重复进行步骤4,直到分解结束,最后得到一组本征模态分量 $I_{IMF1}, I_{IMF2}, \dots, I_{IMFk}$ 。

## 2 预测模型

### 2.1 SSABO优化算法

SSABO优化算法由3部分构成,分别是先验概率模型、观测模型和采集函数<sup>[23]</sup>。其中,先验概率模型用于表示目标函数的初始估计,通常选择高斯过程作为先验模型。观测模型用于描述观测数据生成机制即观测集的似然函数。采集函数是根据后验概率分布构成,通常有3种,分别是比例-积分控制器(proportional-integral controller, PI)、期望改进(expected improvement, EI)和上置信界(upper confidence bound, UCB)函数,有效的采集函数可以使得总损失最小。相较于传统的网格搜索和随机搜索方法,SSABO优化算法具有显著优势。利用自适应的搜索策略使得贝叶斯优化算法(bayesian optimization, BO)具有较高的效率达到全局最优解。通过不必要的迭代和优化滤镜,显著提高优化效率以获得深度学习模型的最佳参数组合。

### 2.2 TCN模型

TCN作为一种改进的深度学习架构,在处理时间序列的长期依赖关系和大规模并行计算方面具有显著优势。TCN通过结合因果卷积、膨胀卷积和残余连接,能够有效地提取输入序列的时序特征并将其映射到输出空间<sup>[24]</sup>。因果卷积与膨胀卷积是TCN的核心部分,通过调整膨胀因子 $d$ ,模型能够在不增加参数数量的情况下以指数级扩大感受野。与传统卷积核对输入数据的处理不同,因果卷积确保了模型在时刻 $t$ 的预测仅依赖于 $t$ 时刻之前的观测数据,严格遵循时间序列的因果律,有效避免了信息泄漏。

残差链接用于降低多层卷积堆叠导致的梯度消失风险。通过跳跃连接来保留模型浅层的重要特征信息,并将卷积层提取的深度特征矩阵进行整合。这种结构显著提升了深度网络的训练稳定性,提升预测结果的准确性。

此外,相比于循环神经网络(recurrent neural network, RNN),TCN具有参数共享机制和卷积并行化的特性,这降低了模型的复杂度,大幅提升了计算效率,能够有效应用于风光预测任务。

### 2.3 超参数优化的TCN-GRU模型

为进一步提升风光功率的预测精度,本文构建

了基于 TCN-GRU 的组合预测模型。GRU 模型是一种循环神经网络模型，用于处理序列数据和时序数据的机器学习方法<sup>[25-28]</sup>。作为 RNN 的优化变体，GRU 通过精简的门控机制有效解决了传统递归网络在处理长序列时的梯度消失问题。相比于 LSTM 模型，GRU 模型结构较为简单，包括两个重要的门控单元，分别是重置门和更新门。

重置门用于衡量前一时刻隐藏状态对当前时刻隐藏状态的影响程度。重置门计算公式为：

$$C_t = \sigma(W_c \cdot [h_{t-1}, x_t] + l_c) \quad (1)$$

式中， $C_t$  表示重置门状态， $w_c$  表示重置门的权重， $l_c$  表示重置门的偏置参数， $h_{t-1}$  表示上一时刻状态， $\sigma$  表示 sigmoid 激活函数。

更新门用于衡量当前时刻的输入信息对当前的隐藏状态的影响程度。更新门计算公式为：

$$G_t = \sigma(W_g \cdot [h_{t-1}, x_t] + l_g) \quad (2)$$

式中， $G_t$  表示更新门状态， $w_g$  表示更新门的权重， $l_g$  表示重置门的偏置参数。

这类门控机制让 GRU 可以选择性地遗忘冗余信息、保留关键信息，同时赋予模型较强的记忆特性。基于重置门和更新门的状态，GRU 模型的隐藏状态更新公式为：

$$\tilde{h} = \tanh(W_h \cdot [C_t * h_{t-1}, x_t] + l_h) \quad (3)$$

$$h_t = (I - G_t) * h_{t-1} + G_t * \tilde{h} \quad (4)$$

$$y_t = W_y \cdot h_t + l_y \quad (5)$$

式中，式 (3) 表示候选集，式 (4) 表示当前时刻隐藏状态，式 (5) 表示输出向量。式中， $\tilde{h}$  表示当前候选集状态， $h_t$  表示当前时刻状态， $w_h$  和  $w_y$  分别表示隐藏层和输出层的权重， $l_h$  和  $l_y$  分别表示候选集和输出层的偏置参数， $I$  表示单位矩阵。

SSABO-TCN-GRU 预测模型具体步骤如下：

(1) 参数的初始化。确定待优化的超参数集合，主要包括 TCN 层的卷积核尺寸、扩张因子序列、GRU 层的隐藏单元数以及学习率等。设定 BO 的迭代阈值与搜索值域，并完成 TCN-GRU 基础架构的初始定义；

(2) 目标函数的设定。构建以均方误差

(mean squared error, MSE) 为核心的目标函数，用于量化模型在训练阶段的预测偏差；

(3) SSABO 的寻优过程。首先由 SSA 在全域范围内识别潜在最优空间；之后通过 BO 的采集函数指导，在缩小后的搜索范围内对 TCN-GRU 的超参数进行搜索；

(4) 优化模型的训练。将步骤 (3) 优化得到的超参数代入 TCN-GRU 模型，使用训练集数据进行训练，得到预测模型；

(5) 模型的评估与预测。在测试集上评估模型性能，并利用训练好的模型测试集上进行预测，输出预测结果。

### 3 混合预测模型构建流程

本文融合 ICEEMDAN 分解算法、SSABO 优化算法与 TCN-GRU 预测模型，构建了一套风光功率的预测模型体系。ICEEMDAN-SSABO-TCN-GRU 混合预测模型的整体流程如图 1 所示，具体的模型构建步骤如下：

步骤 1：对原始风光功率序列进行归一化处理，随后将预处理后的原始数据序列划分为训练集与测试集，用于模型的训练与性能验证；

步骤 2：采用 ICEEMDAN 分解算法对原始风光功率序列进行数据分解，充分挖掘数据特征，降低原始序列的复杂程度，提高后续模型预测的准确性；

步骤 3：将分解得到的 IMFs 分别作为 ICE-EMDAN-SSABO-TCN-GRU 模型的输入数据，先经由 TCN 层提取数据的局部特征信息，再将其输入至 GRU 层以捕捉序列中的长期依赖关系。与此同时，引入 SSABO 优化算法对 TCN-GRU 模块的超参数进行寻优配置，提升模型的训练效率与预测精度，最终通过全连接层输出对应 IMF 分量的预测结果；

步骤 4：对所有 IMF 分量的预测结果进行叠加，得到风光功率各自最终的点预测值；

步骤 5：运用误差评价指标对所提模型的预测性能进行量化评估，结合对比实验进一步分析本文模型的优越性；

步骤 6：利用 ABKDE 进行区间预测，衡量数据变化的波动程度。

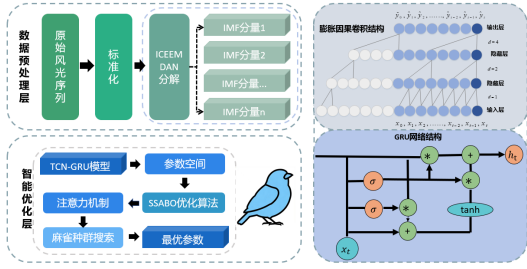


图1 风电-光伏综合预测系统流程图

Fig.1 Flow chart of wind power-PV integrated forecasting system

## 4 实验结果及误差分析

### 4.1 数据分析

为全面地验证本文所提模型的性能表现，选取了比利时某电场的风电与光伏功率数据作为实验数据集<sup>[29]</sup>，数据采样间隔时间为15分钟，其中训练集包含778个样本点，测试集包含182个样本点。

为了解数据集的分布特征，研究从变异系数、极差、偏度及峰度等4个统计维度展开分析（详见表1）。结合图2的可视化结果可知，光伏功率的波动区间相对更大；而表1的统计指标进一步显示，光伏功率的变异系数与峰度均高于风电功率，表明相较于风电功率序列，光伏功率出现极端值的概率更高，其数据分布的复杂程度也更为突出。

本研究先对风光数据集分别进行归一化处理，以消除量纲对模型的影响，提高模型的预测精度。

表1 不同数据集的统计特征

Tab.1 Statistical characteristics of different data sets

数据集	极差	变异系数	偏度	峰度
风电功率	3 996.43	0.750 0	0.24	1.81
光伏功率	6 910.06	1.281 6	0.99	2.59




图2 原始风电、光伏数据

Fig.2 Original wind power and PV data

### 4.2 基准模型分析

为筛选出适配本实验数据的预测模型，本研究首先选取反向传播神经网络（backpropagation neural network, BP）、极限学习机（extreme learning machine, ELM）、LSTM、GRU、TCN及TCN-GRU共6种典型神经网络模型，分别对归一化后的风光数据进行预测并记录误差结果；本研究采用平均绝对误差（mean absolute error, MAE）、均方根误差（root mean squared error, RMSE）与平均绝对百分比误差（mean absolute percentage error, MAPE）这3项常用误差指标，对比了6种模型对两类功率数据的预测精度，各模型的指标计算结果详见表2和图3。

误差指数计算公式如公式（6）、公式（7）和公式（8）：

$$e_{MAE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (6)$$

$$e_{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (7)$$

$$e_{MAPE} = \frac{1}{m} \sum_{i=1}^m \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (8)$$

其中， $y_i$ 为真实值， $\hat{y}_i$ 为预测值， $\bar{y}$ 是真实值的平均值， $m$ 为样本点的个数。

表2 基准模型误差指标统计表

Tab.2 Benchmark model error index statistics table

数据集	模型	$e_{MAE}$	$e_{RMSE}$	$e_{MAPE} / \%$
风电	BP	0.771 4	0.959 6	43.340 6
	ELM	0.436 4	0.516 3	19.662 4
	LSTM	0.337 9	0.388 6	13.344 3
	GRU	0.285 2	0.394 4	8.352 1
	TCN	0.295 5	0.377 7	8.935 9
	TCN-GRU	0.249 6	0.300 0	12.012 2
光伏	BP	0.656 1	0.922 4	35.492 2
	ELM	0.426 5	0.560 2	17.768 7
	LSTM	0.377 0	0.385 0	20.949 9
	GRU	0.295 1	0.396 6	13.321 7
	TCN	0.233 6	0.282 6	14.134 4
	TCN-GRU	0.202 1	0.240 3	12.587 6

在对比的模型中，单一神经网络模型的表现存

在明显差异：BP在风光数据集上的预测效果均为最差表现；LSTM呈现出显著的数据集依赖性，其在风电数据集上误差较小，但在光伏数据集上  $e_{RMSE}$  却显著偏高；GRU与TCN的性能相对均

衡，不仅在风电数据集上具备较好的预测效果，在波动更为剧烈的光伏数据集上，其预测误差也显著低于其他模型。如图3结果表面，所设计的混合模型TCN-GRU，凭借TCN与GRU的协同优势，在各类数据集上均展现出更好的预测效果，进一步证明了模型结合的有效性，故选取TCN-GRU作为预测主模型。

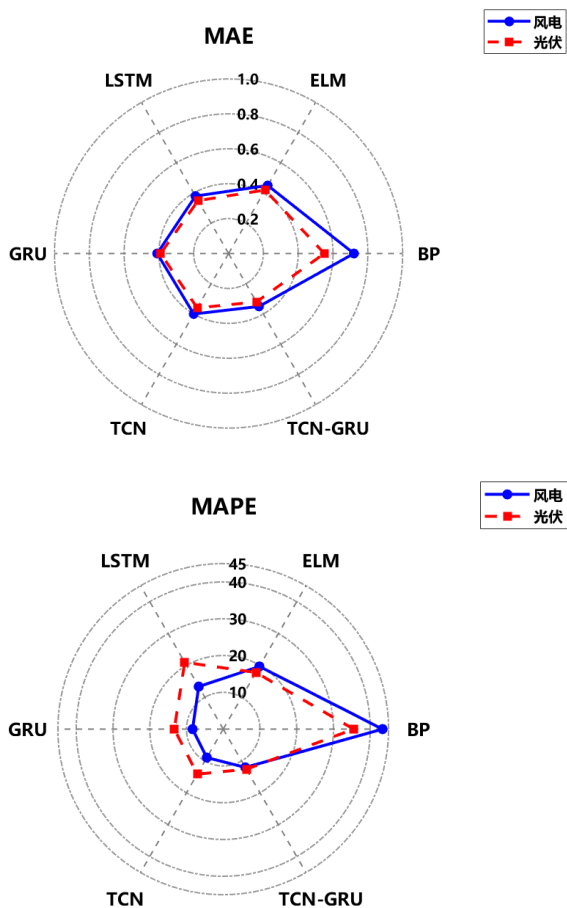


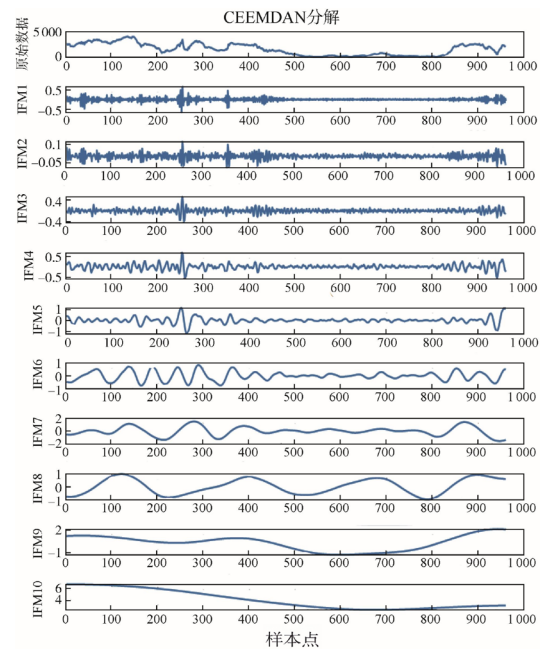
图3 基准模型误差雷达图

Fig.3 Radar plot of baseline model error

#### 4.3 数据分解结果分析

针对CEEMDAN算法在处理非平稳数据时易产生伪模态的缺陷，本研究采用ICEEMDAN算法对风电功率与光伏功率数据进行分解优化，并通过对比实验验证其改进效果。实验中，ICEEMDAN与CEEMDAN对同一组风光数据分别进行处理，分解结果的对比可视化如图4、图5所示。

从对比结果可以看出，ICEEMDAN分解得到的各分量结构简洁规整，相较于原始功率数据，



波动平稳性与周期规律性均明显提升。同时，分解后的数据区间均稳定在 $[-2, 2]$ ，避免了极端值对模型的影响；以及相较于CEEMDAN的分解情况来看，ICEEMDAN显著减少了模态分量的个数，解决了CEEMDAN伪模态问题，提升了数据分解的有效性与可靠性。




图4 CEEMDAN和ICEEMDAN对风电功率分解  
Fig.4 CEEMDAN and ICEEMDAN decomposition of wind power

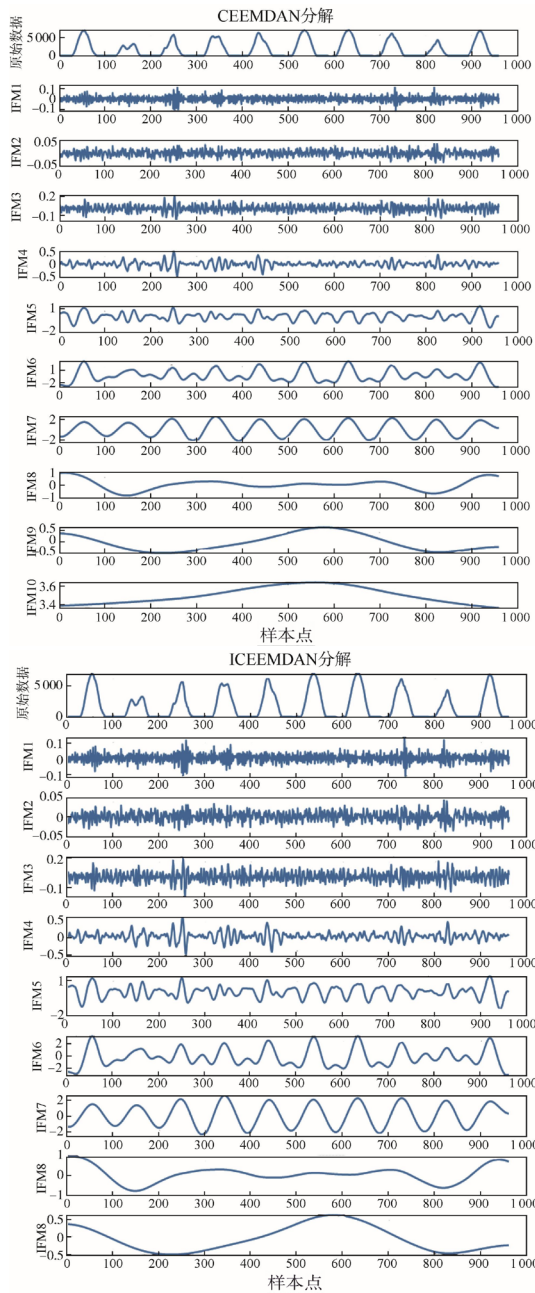


图5 CEEMDAN和ICEEMDAN光伏功率分解  
Fig.5 CEEMDAN and ICEEMDAN of decomposition PV

#### 4.4 确定性预测结果分析

为了更加清晰直观地对比各个组合模型的预测效果，我们将BO-TCN-GRU模型、CEEMDAN-SSABO-TCN-GRU模型和本文所提出来的ICEEMDAN-SSABO-TCN-GRU模型的预测结果与测试集的真实值进行直观比较，各模型的预测图如图6所示，预测误差结果如图7和图8所示。可以明显看出本文提出的模型有更好的预测效果，尤其针对数据突变时刻与失效时间场景，依旧能够保持较高的预测精度。

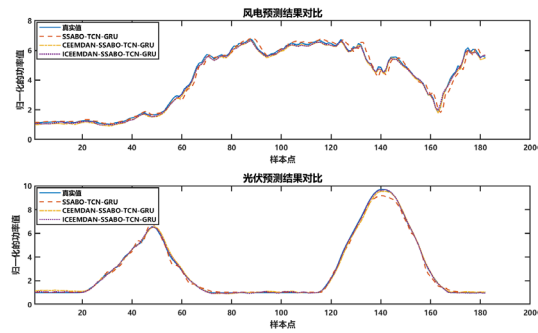


图6 点预测结果对比  
Fig.6 Comparison of prediction results

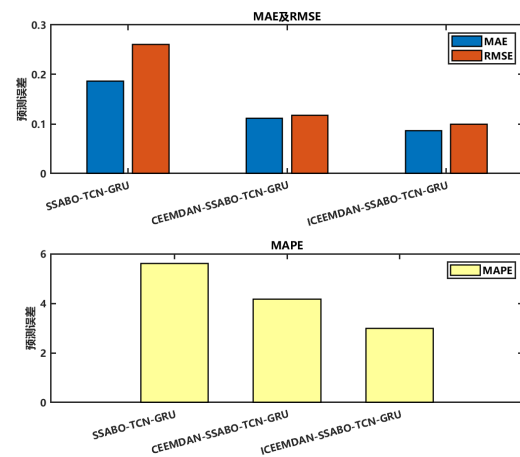


图7 风电点预测误差条形图  
Fig.7 Bar chart of wind power point forecast

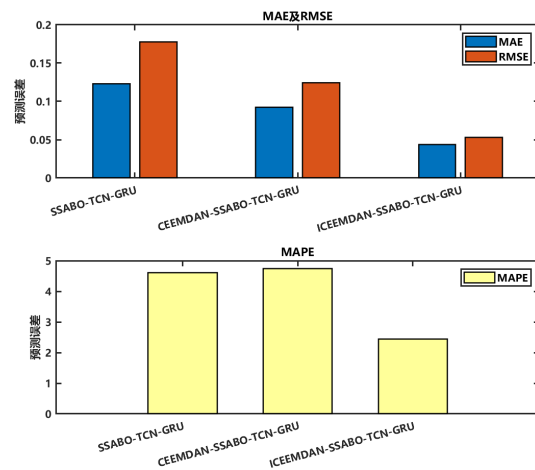


图8 光伏点预测条形图  
Fig.8 Bar chart of PV point forecasts

(1) 本文模型ICEEMDAN-SSABO-TCN-GRU在风电数据集上的 $e_{MAE}$ 、 $e_{RMSE}$ 、 $e_{MAPE}$ 分别为0.0861、0.0997和2.9995%。与SSABO-TCN-GRU进行对比，3个误差指标在不同数据集上有大幅减小，风电数据集上分别降低了53.83%、61.73%和46.53%；同时，相比于CEEMDAN模型，本文的

模型分别在风光数据集上均有大幅降低,进一步说明了ICEEMDAN解决了伪模态问题,证明了本文模型改进算法的有效性。

(2)在光伏数据集中,本文模型的 $e_{MAE}$ 、 $e_{RMSE}$ 、 $e_{MAPE}$ 值分别为0.043 4、0.052 7和2.437 8%。而未加入优化算法的TCN-GRU的各误差值分别为0.202 1、0.240 3和12.76%。通过数据对比可知,引入SSABO算法后,模型在3项误差指标上分别实现了78.53%、78.07%以及80.90%的大幅度优化。这有力地证明了SSABO算法通过全局搜索机制,有效避免了模型陷入局部最优,显著增强了模型对功率预测的精度。

4.5 不确定性预测结果分析

为进一步量化预测结果的稳定性,本文在获取点预测值的基础上,引入ABKDE构建区间预测模型。旨在通过概率区间刻画功率波动的不确定性,并选取90%与95%置信水平( $\alpha=0.1$ )对区间覆盖率及宽度进行测试。实验得到的风光预测不确定性区间分布如图9和图10所示。




图9 风电区间预测结果

Fig. 9 Wind power interval prediction results

表3 风、光功率数据的点预测结果的误差评估指数

Tab.3 Error assessment indices for point prediction results for wind and PV power data

数据集	模型	$e_{MAE}$	$e_{RMSE}$	$e_{MAPE} / \%$
风电	SSABO-TCN-GRU	0.186 5	0.260 5	5.609 5
	CEEMDAN-SSABO-TCN-GRU	0.111 5	0.117 8	4.178 7
	ICEEMDAN-SSABO-TCN-GRU	0.086 1	0.099 7	2.999 5
光伏	SSABO-TCN-GRU	0.123 1	0.178 0	4.614 4
	CEEMDAN-SSABO-TCN-GRU	0.092 6	0.124 6	4.736 6
	ICEEMDAN-SSABO-TCN-GRU	0.043 4	0.052 7	2.437 8




图10 光伏区间预测结果

Fig.10 Photovoltaic interval prediction results

表4数据显示,当置信水平设定为90%时,风电与光伏序列的实际覆盖率分别达到90.11%和92.32%,均优于预设的理论值;而在95%置信水平下,覆盖率进一步提升至95.51%和96.75%,表现出极高的可靠性。结合图9和图10可知该模型在不同置信度下均能有效包络绝大部分观测值。与此同时,预测区间的宽度表现出显著的自适应特征,这充分验证了ABKDE算法通过动态调整带宽参数,能够精准表征预测值的概率分布,实现了覆盖率与预测精度的双重优化。

5 结论

本文针对风电和光伏发电预测精度低的问题,提出了一种基于改进型自适应经验模态分解(ICEEMDAN)和改进的贝叶斯优化(SSABO)的TCN-GRU风光功率综合预测模型。该模型通过数据分解、超参数优化和智能预测模型的协同作用,在光伏和风电数据集上的预测效果都具有良好的表现,显著提高了风光功率预测的精度和效率,为可再生能源的高效利用和电网的稳定运行提供了有力支持。主要结论如下:

表4 风光功率的区间预测评估指数

Tab.4 Evaluation index for interval prediction of wind power

覆盖率 /%	风电	光伏
90	0.901 1	0.923 2
95	0.955 1	0.967 5

(1)通过ICEEMDAN算法对原始风光数据进行自适应分解,有效减少了模态混叠和噪声残留,显著提升了数据特征的提取能力。

(2) 结合 TCN 与 GRU, TCN 有效扩大了感受野, 能够捕捉功率数据中的长期趋势; 而 GRU 模块则通过门控机制提取了短期波动的时序依赖性, 二者构建了高效的 TCN-GRU 混合预测模型。

(3) 利用改进的贝叶斯优化对模型超参数进行优化, 模型能够在更少的迭代次数内找到最优解, 进一步提升了训练效率和预测精度。

(4) 本文在点预测的基础上利用 ABKDE 进行了区间预测, 能够自适应地衡量数据变化的不确定性。

综上所述, 本文构建的预测框架能够为实际能源调度提供决策参考, 从而有效驱动可再生能源的高效利用。后续的研究将致力于结合多源气象因子进一步挖掘功率变化的深度特征。此外, 针对模型在极端气象条件下的迁移能力与稳健性, 是未来算法优化的关键方向, 可为全球能源体系的智能化转型提供技术支撑。

## 参考文献


- [1] 周金涛,何山,王维庆,等.基于黑翅鸢算法和VMD的短期风电功率预测[J].太阳能学报,2025,46(12):762-773. ZHOU Jintao,HE Shan,WANG Weiqing,et al.Short-Term Wind Power Prediction based on Black-winged Kite Algorithm and Vmd[J].Acta Energiæ Solaris Sinica,2025,46(12):762-773.
- [2] 白婕,秦晓辉,安鹏,等.计及高影响天气事件的风光长期时间序列预测研究现状与关键技术展望[J].电网技术,2026,50(2):829-848. BAI Jie,QIN Xiaohui,AN Peng,et al.Research Status and Key Technology Prospects of Long-term Time Series Forecasting of Wind and Solar Power Considering the High-impact Weather Events[J].Power System Technology,2026,50(2):829-848.
- [3] 黄晟,潘丽君,屈尹鹏,等.基于改进深度Q网络的无预测风电场日前拓扑优化[J].电力系统自动化,2025,49(2):122-132. HUANG Sheng,PAN Lijun,QU Yinpeng,et al.Day-ahead Topology Optimization for Wind Farm without Forecasting based on Improved Deep Q Network[J].Automation of Electric Power Systems,2025,49(2):122-132.
- [4] 杨超颖,赵军,李慧蓬,等.基于时序特征交互与功率气象特征融合的风电超短期预测方法[J/OL].华北电力大学学报(自然科学版),2025:1-10.(2025-12-17). <https://link.cnki.net/urlid/10.1999.tm.20251217.0910.002>. YANG Chaoying,ZHAO Jun,LI Huipeng,et al.Ultra-Short-Term Wind Power Forecasting Based on Temporal Feature Interaction and Power-Meteorological Feature Fusion[J/OL].Journal of North China Electric Power University (Natural Science Edition),2025:1-10.(2025-12-17). <https://link.cnki.net/urlid/10.1999.tm.20251217.0910.002>.
- [5] 高帆,包道日娜,赵明智,等.多场景规划下混合储能对风光耦合出力波动的平抑特性[J].电工技术学报,2025,40(9):2827-2839. GAO Fan,BAO Daorina,ZHAO Mingzhi,et al.Smoothing Characteristic of Wind-Solar Coupled Output Fluctuations by Hybrid Energy Storage under Multi-Scenario Planning[J].Transactions of China Electrotechnical Society,2025,40(9):2827-2839.
- [6] 肖剑,别克扎提·巴合提,张辉,等.多尺度自适应时频交互协同风电集群功率预测[J/OL].电力系统及其自动化学报,2025:1-11.(2025-12-09). <https://doi.org/10.19635/j.cnki.csu-epsa.001759>. XIAO Jian;BIEKEZATI Baheti;ZHANG Hui;ZHANG Keren. Multi-Scale Adaptive Time-Frequency Cooperative Method for Wind Power Cluster Forecasting [J/OL].Proceedings of the CSU-EPSA,2025:1-11. (2025-12-09). <https://doi.org/10.19635/j.cnki.csu-epsa.001759>.
- [7] 崔杨,朱晗,王议坚,等.基于CNN-SAEDN-Res的短期电力负荷预测方法[J].电力自动化设备,2024,44(4):164-170. CUI Yang,ZHU Han,WANG Yijian,et al.Short-term Power Load Forecasting Method based on CNN-SAEDN-Res[J].Electric Power Automation Equipment,2024,44(4):164-170.
- [8] 陈臣鹏,赵鑫,毕贵红,等.基于多模式分解和麻雀优化残差网络的短期风速预测模型[J].电网技术,2022,46(8):2975-2985. CHEN Chenpeng,ZHAO Xin,BI Guihong,et al.SSA-Res-GRU Short-Term Wind Speed Prediction Model based on Multi-Model Decomposition[J].Power System Technology,2022,46(8):2975-2985.
- [9] 滕婧,姜亚君,师瑞峰,等.基于频率增强融合时空信息的超短期风电功率预测[J].太阳能学报,2025,46(9):198-207. TENG Jing,JIANG Yajun,SHI Ruifeng,et al.Ultra-short-term Wind Power Prediction based on Frequency Enhancement and Spatio-temporal Information Fusion[J].Acta Energiæ Solaris Sinica,2025,46(9):198-207.
- [10] 陈磊,黄凯阳,张怡,等.基于信息重组和TCN-LSTM-MHSA的超短期风电功率预测[J/OL].南方电网技术,2024:1-10.(2024-06-27). <https://kns.cnki.net/kcms/detail/44.1643.TK.20240626.1553.009.html>. CHEN Lei,HUANG Kaiyang,ZHANG Yi,et al.Ultra-short-term Wind Power Forecasting based on Information Reorganization and TCN-LSTM-MHSA[J/OL].Southern Power System Technology,2024:1-10.(2024-06-27). <https://kns.cnki.net/kcms/detail/44.1643.TK.20240626.1553.009.html>.

- kns.cnki.net/kcms/detail/44.1643.TK.20240626.1553.009.html.
- [11] 盛四清,袁伟智.基于二次分解和 BiLSTM-XGBoost-ARIMA 组合模型的短期风速预测[J/OL].华北电力大学学报(自然科学版),2024:1-13.(2024-07-29). <https://kns.cnki.net/kcms/detail/13.1212.tm.20240726.1332.004.html>. SHENG Siqing, YUAN Weizhi. Short-term Wind Speed Prediction based on Quadratic Decomposition and BiLSTM-XGBoost-ARIMA Combination Model[J/OL]. Journal of North China Electric Power University (Natural Science Edition), 2024:1-13. (2024-07-29). <https://kns.cnki.net/kcms/detail/13.1212.tm.20240726.1332.004.html>.
- [12] 依沙克·司马义,陈昊,张正强,等.基于NWP信息的SSA优化EEMD-LSTM风电超短期功率预测[J].太阳能学报,2025,46(8):176-183. YISHAKE · Simayi, CHEN Hao, ZHANG Zhengqiang, et al. Ultra-Short-Term Wind Power Prediction Based on Nwp Information Using SSA Optimized EEMD- LSTM[J]. Acta Energetiae Solaris Sinica, 2025, 46(8): 176-183.
- [13] WANG H, YAN J, ZHANG J W, et al. Short-Term Integrated Forecasting Method for Wind Power, Solar Power, and System Load based on Variable Attention Mechanism and Multi-task Learning[J]. Energy, 2024, 304: 132188.
- [14] 冯双磊,王铮,王伟胜,等.基于CycleGAN的区域风速网格化预测方法[J/OL].中国电机工程学报,2025:1-14.(2025-08-19). <https://link.cnki.net/urlid/11.2107.TM.20250819.1601.004>. FENG Shuanglei, WANG Zheng, WANG Weisheng, et al. Gridded Forecasting of Local Wind Speeds Based on CycleGAN[J/OL]. Proceedings of the CSEE, 2025:1-14. (2025-08-19). <https://link.cnki.net/urlid/11.2107.TM.20250819.1601.004>.
- [15] 赖纪东,谢天月,苏建徽,等.基于粒子群优化算法的孤岛微电网电压不平衡补偿协调控制[J].电力系统自动化,2020,44(16):121-129. LAI Jidong, XIE Tianyue, SU Jianhui, et al. Coordinated Control of Voltage Unbalance Compensation in Islanded Microgrid Based on Particle Swarm Optimization Algorithm[J]. Automation of Electric Power Systems, 2020, 44(16): 121-129.
- [16] 赵如意,王晓辉,郑碧煌,等.基于特征优化和混合改进灰狼算法优化 BiLSTM 网络的短期光伏功率预测[J].电网技术,2025,49(1):209-222. ZHAO Ruyi, WANG Xiaohui, ZHENG Bihuang, et al. Short-Term Photovoltaic Power Prediction based on Feature Optimization and Hybrid Improved Grey Wolf Algorithm-Optimized BiLSTM Network[J]. Power System Technology, 2025, 49(1): 209-222.
- [17] 殷豪,丁伟锋,陈顺,等.基于长短时记忆网络-纵横交叉算法的含高比例新能源电力市场日前电价预测[J].电网技术,2022,46(2):472-480. YIN Hao, DING Weifeng, CHEN Shun, et al. Day-Ahead Electricity Price Forecasting of Electricity Market with High Proportion of New Energy Based on LSTM-CSO Model[J]. Power System Technology, 2022, 46(2): 472-480.
- [18] 孙艳,陈雁,莫东,等.基于风险分摊的多风电场机会约束机组组合求解方法[J].电网技术,2022,46(8):2996-3006. SUN Yan, CHEN Yan, MO Dong, et al. Joint Chance Constrained Unit Commitment with Wind Farms based on Risk Sharing[J]. Power System Technology, 2022, 46(8): 2996-3006.
- [19] 黄震,侯凯元,夏德明,等.基于HHO-Transformer架构的7天时间尺度新能源发电功率预测[J/OL].上海交通大学学报,2025:1-15.(2025-12-25). <https://doi.org/10.16183/j.cnki.jsjtu.2025.336>. HUANG Zhen, HOU Kaiyuan, XIA Deming, et al. Forecasting of Renewable Energy Power Generation based on HHO-Transformer Architecture for 7-Day Time Scales[J/OL]. Journal of Shanghai Jiao Tong University, 2025:1-15. (2025-12-25). <https://doi.org/10.16183/j.cnki.jsjtu.2025.336>.
- [20] 郑哲明,孔玲玲,何印.基于CPO-ICEEMDAN-DBO-TCN-GRU模型短期风电功率预测[J].现代电子技术,2025,48(24):88-94. ZHENG Zheming, KONG Lingling, HE Yin. Short-Term Wind Power Prediction based on CPO-ICEEMDAN-DBO-TCN-GRU Model[J]. Modern Electronic Technique, 2025, 48(24): 88-94.
- [21] 叶林,裴铭,路朋,等.基于天气分型的短期光伏功率组合预测方法[J].电力系统自动化,2021,45(1):44-54. YE Lin, PEI Ming, LU Peng, et al. Combination Forecasting Method of Short-term Photovoltaic Power based on Weather Classification[J]. Automation of Electric Power Systems, 2021, 45(1): 44-54.
- [22] 范竞敏,贺广林,王新刚,等.基于VMD-TCN-GRU-AM的超短期风电预测[J].太阳能学报,2025,46(6):538-547. FAN Jingmin, HE Guanglin, WANG Xingang, et al. Ultra Short Term Wind Power Prediction based on VMD-Ten-Gru-Am[J]. Acta Energetiae Solaris Sinica, 2025, 46(6): 538-547.
- [23] 李笑竹,王维庆.基于贝叶斯理论的分布鲁棒优化在储能配置上的应用[J].电网技术,2022,46(10):4001-4011. LI Xiaozhu, WANG Weiqing. Application of Distributed Robust Optimization based on Bayesian Theory in Allocation of Energy Storage[J]. Power System Technology, 2022, 46(10): 4001-4011.
- [24] ZHANG Y G, PAN Z Y, WANG H, et al. Achieving Wind Power and Photovoltaic Power Prediction: an Intelligent Prediction System based on a Deep Learning Approach[J]. Energy, 2023, 283: 129005.
- [25] 成晓明,王磊,张鹏超,等.区域级电力负荷数据特性研究与短期预测[J].电网技术,2022,46(3):1092-1099. CHENG Xiaoming, WANG Lei, ZHANG Pengchao, et al. Data Characteristics and Short-Term Forecasting of Regional Power Load[J]. Power System Technology, 2022, 46(3): 1092-

- 1099.
- [26] 杨康,李蓝青,李艺丰,等.一种新型分布式光伏出力区间预测方法[J].发电技术,2024,45(4):684-695.  
YANG Kang,LI Lanqing,LI Yifeng,et al.A Novel Distributed Photovoltaic Output Interval Prediction Method[J].Power Generation Technology,2024,45(4): 684-695
- [27] 闫朝阳,李蓝青,徐浩嘉,等.基于白鲨算法与改进长短期记忆网络的光伏出力预测[J].发电技术,2025,46(4): 778-787.  
YAN Chaoyang,LI Lanqing,XU Haojia,et al.Photo- voltaic Output Prediction Based on Improved Long Short-Term Memory Network Using White Shark Optimization Algorithm[J].Power Generation Technol- ogy,2025,46(4):778-787.
- [28] 付小标,侯嘉琪,李宝聚,等.一种二模态天气分型方法及其在光伏功率概率预测的应用[J].发电技术,2024,45(2):299-311.  
FU Xiaobiao,HOU Jiaqi,LI Baoju,et al.A Two-Modal Weather Classification Method and Its Application in Photovoltaic Power Probability Prediction[J]. Power Generation Technology,2024,45(2):299-311.
- [29] Elia Group.Open Data Elia:Belgian grid data (2024) [EB/OL]. (2024-05-22)[2025-10-08].<https://www.elia.be/en/grid-data/open-data>.

收稿日期: 2025-10-10

作者简介:



楚子易

楚子易, (2004), 女, 本科生, 主要研究新能源电力系统分析与控制和电力市场等, E-mail: chuziyi@ncepu.edu.cn。



武雅慧

武雅慧, (2000), 女, 硕士研究生, 通讯作者, 主要研究新能源电力系统分析与控制和电力市场等, E-mail: wuyahui@ncepu.edu.cn。



张亚刚

张亚刚, (1978), 教授, 主要研究新型电力系统和碳排放等。