

# 基于 SSA 优化的 Transformer-BiGRU 短期 风电功率预测<sup>\*</sup>

包广斌 杨龙龙 范超林 李 煥

(兰州理工大学计算机与通信学院 兰州 730050)

**摘 要:** 为提高风电功率预测精度,提出了一种基于 SSA 优化的 Transformer-BiGRU 组合模型。首先,采用 CEEMDAN 将原始序列分解为多个模态分量和残差分量,降低数据复杂性和不稳定性。然后,结合 Transformer 的自注意力机制与 BiGRU 的双向时序建模能力,构建了一个高效的组合模型。针对 Transformer-BiGRU 模型超参数优化困难的问题,引入 SSA 麻雀搜索算法对超参数进行优化,进一步提升预测精度。最后,以龙源电力风电预测数据集为例,通过对比实验和消融实验验证了该模型优于其他传统模型和模型中各组件的有效性,实验结果表明该方法的  $R^2$  达到了 0.981 0。

**关键词:** 风电预测;麻雀搜索算法;自适应噪声完备经验模态分解;双向门控循环单元;自注意力机制

**中图分类号:** TM614;TN-9 **文献标识码:** A **国家标准学科分类代码:** 470.4047

## Short-term wind power prediction based on SSA-optimized Transformer-BiGRU

Bao Guangbin Yang Longlong Fan Chaolin Li Huan

(School of Computer and Communication Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

**Abstract:** To improve wind power prediction accuracy, a combination model based on SSA-optimized Transformer-BiGRU is proposed. First, CEEMDAN decomposes the original sequence into multiple modal components and a residual component, reducing data complexity and instability. Then, a high-efficiency combined model is constructed by integrating the self-attention mechanism of the Transformer with the bidirectional time-series modeling capability of BiGRU. To address the challenge of hyperparameter optimization for the Transformer-BiGRU model, the SSA algorithm is introduced to optimize the hyperparameters, further enhancing prediction accuracy. Finally, using the Longyuan Electric Power wind power prediction dataset, comparative and ablation experiments are conducted to show that the proposed model outperforms other traditional models and demonstrates the effectiveness of each component. The experimental results indicate that the method achieves an  $R^2$  of 0.981 0.

**Keywords:** wind power prediction; sparrow search algorithm; complete ensemble empirical mode decomposition with adaptive noise; bidirectional gated recurrent unit; self-attention mechanism

## 0 引 言

随着新能源技术的突破性进展以及各国政府的政策支持,新能源产业特别是风能领域实现了快速发展<sup>[1]</sup>。然而,风能的波动性和不确定性使得风力发电功率预测充满挑战,但准确的预测能提高风电机组的运行效率,优化电力调度与资源配置,从而确保电网的稳定性。针对风电功率预测的挑战,近年来学者们提出了多种方法,主要集中在数据预处理和模型优化两方面。

具体而言,王瑞等<sup>[2]</sup>利用改进的麻雀算法优化了双向门控循环单元(BiGRU)网络的参数,有效解决了神经网络参数调整困难的问题。Liu 等<sup>[3]</sup>提出了一种结合 EMD、LSTM 和 ARIMA 的风速预测模型,通过 EMD 分解风速序列,并将熵值较大的子序列使用 LSTM 预测,熵值较小的子序列用 ARIMA 预测,最后合并各子序列的结果。王瑞等<sup>[4]</sup>提出了一种基于 VMD 和 LSSVM 的风电功率预测模型,采用改进蝙蝠算法优化 LSSVM 超参数,提高了预测精度和稳定性。杨国清等<sup>[5]</sup>提出了一种基于注意力机制和

GRU 的风速修正模型,通过 Attention-GRU 修正风速预报,并结合 Stacking 框架融合 XGBoost、LSTM、SVR、LASSO 等算法,提升了预测精度。王愈轩等<sup>[6]</sup>提出了一种结合 CNN、LSTM 和 lightGBM 的超短期风电功率预测方法,通过模型组合克服了单一模型的精度不足,提高了风电功率预测的准确性。Parri 等<sup>[7]</sup>提出的 SVM-D-TF-QS 模型结合了 SVM 和 Transformer 的自注意力机制,有效提升了风速预测的精度。然而,尽管现有的研究方法取得了一定成果,但预测的精度仍有提升的空间。

本文提出了一种基于 SSA 优化的 CEEMDAN-Transformer-BiGRU 模型,用于短期风电功率预测。该方法首先通过 CEEMDAN 对风电数据进行模态分解,提取多尺度特征,再结合 Transformer 的自注意力机制和 BiGRU 的时序建模能力,提升了预测精度。同时,利用 SSA 优化 Transformer-BiGRU 模型的超参数,进一步增强了模型的性能。为电网调度和风电场资源优化提供了有效的决策支持。

## 1 基本理论

### 1.1 CEEMDAN 模态分解

CEEMDAN 作为一种自适应的时频分析法,基于 EEMD 进行优化,可以有效克服 EMD 的模态混叠问题,同时避免了 EEMD 中残余噪声引入的不足,展现出卓越的数据特征挖掘能力。CEEMDAN 的主要步骤如下<sup>[8]</sup>:

1) 对原始信号  $x(t)$  添加标准正态分布的高斯白噪声  $w^i(t)$ , 得到  $x^i(t) + w^i(t)$ 。将  $x^i(t)$  信号 EMD 分解为固有模式函数和一个残余项  $r_1(t)$ , 并选择保留信号的首个 IMF 分量  $I_{IMF1}$  为:

$$I_{IMF1} = \frac{1}{m} \sum_{i=1}^m I_{IMF1}^i(t) \quad (1)$$

$$r_1(t) = x(t) - I_{IMF1} \quad (2)$$

式中:  $I_{IMF1}^i(t)$  为第一个分解模式函数;  $m$  为信号数量。

2) 在残余分量  $r_1(t)$  中添加新的高斯白噪声  $w^i(t)$ , 得到一个新分量  $r_1^i(t) = r(t) + w^i(t)$ 。将  $r_1^i(t)$  进行 EMD 分解, 分解方法为:

$$I_{IMF2} = \frac{1}{m} \sum_{i=1}^m EMD(r(t) + w^i(t)) \quad (3)$$

$$r_2(t) = r_1(t) - I_{IMF2}(t) \quad (4)$$

3) 重复上述过程,直到残余信号的极值点数不超过 2 个。最后,原始信号可以表示为所有分量和残余量的叠加,可表示为:

$$x(t) = \sum_{j=1}^z I_{IMFj} + r_z(t) \quad (5)$$

### 1.2 SSA 优化算法

麻雀搜索算法是一种新颖的群体智能优化方法,灵感源自麻雀在觅食和避敌过程中的集体行为和自组织机制<sup>[9]</sup>。算法的关键步骤如下:

1) 生产者更新位置

$$X_{ij}^{t+1} = \begin{cases} x_{ij}^t \exp(-\frac{i}{\alpha r_{\max}}), AL < ST \\ x_{ij}^t + QL, AL \geq ST \end{cases} \quad (6)$$

式中:  $x_{ij}^t$  为第  $t$  次迭代中第  $i$  只麻雀的第  $j$  维参数;  $r_{\max}$  为最大迭代次数;  $\alpha$  为  $(0, 1]$  中的均匀随机数;  $ST$  为安全阈值,取  $[0, 1]$  中的均匀随机数;  $AL$  为报警值,取  $[0.5, 1]$ ;  $Q$  为标准正态分布随机数;  $L$  为  $1 \times d$  的单位矩阵。  $AL < ST$  为周围没有危险;  $AL \geq ST$  为部分麻雀种群发现危险。随后立即更新跟随者位置。

2) 更新警戒者位置

$$X_{ij}^{t+1} = \begin{cases} X_{best}^t + \beta |x_{ij}^t - X_{best}^t|, f_i > f_g \\ x_{ij}^t + K \left( \frac{|x_{ij}^t - X_{worst}^t|}{f_i - f_w + \xi} \right), f_i = f_g \end{cases} \quad (7)$$

式中:  $X_{best}^t$  为种群的中心位置;  $\beta$  为服从标准正态分布的控制参数;  $K$  为  $[-1, 1]$  之间的随机数;  $\xi$  为无穷小量;  $f_i$  为目前麻雀的适应度;  $f_g$ 、 $f_w$  为麻雀的最佳适应度和最差适应度。  $f_i > f_g$  为代表麻雀极易受到攻击;  $f_i = f_g$  为表示麻雀意识到危险,开始移动。

### 1.3 Transformer 网络

Transformer 模型的核心内容主要包括自注意力机制和多头注意力机制<sup>[10]</sup>。完整的 Transformer 的内部架构如图 1 所示。

1) 自注意力机制

自注意力机制通过评估注意力得分,为输入序列中的每个位置分配不同的权重。其计算过程如下:

$$Attention(Q, K, V) = \text{soft max} \left( \frac{QK^T}{\sqrt{d_k}} \right) V \quad (8)$$

式中:  $Attention()$  为自注意力计算函数;  $Q$  为查询向量矩阵;  $K$  为键向量矩阵;  $V$  为值向量矩阵;  $T$  为矩阵转置操作;  $d_k$  为键向量维度;  $\text{soft max}()$  为归一化函数。

2) 多头自注意力机制

多头注意力机制将各个注意力头的输出合并,并通过线性变换生成最终的结果。其计算过程如下:

$$\begin{cases} MultiHead(Q, K, V) = \text{Concat}(head_1, \dots, head_h) W_o \\ head_i = Attention(QW_Q, KW_K, VW_V), i = 1, 2, \dots, h \end{cases} \quad (9)$$

式中:  $MultiHead()$  为多头自注意力计算函数;  $head_i$  为第  $i$  个注意力头的输出;  $h$  为注意力总头数;  $\text{Concat}()$  为向量拼接操作;  $QW_Q, KW_K, VW_V$  为映射矩阵;  $W_o$  为映射矩阵。

### 1.4 BiGRU 网络

BiGRU 是一种增强型 RNN 架构,通过两个分别处理正向和反向序列的 GRU 层实现双向信息流。这一结构使得 BiGRU 能够有效捕捉序列中的长期依赖,从而提升模型的预测能力。模型结构如图 2 所示。

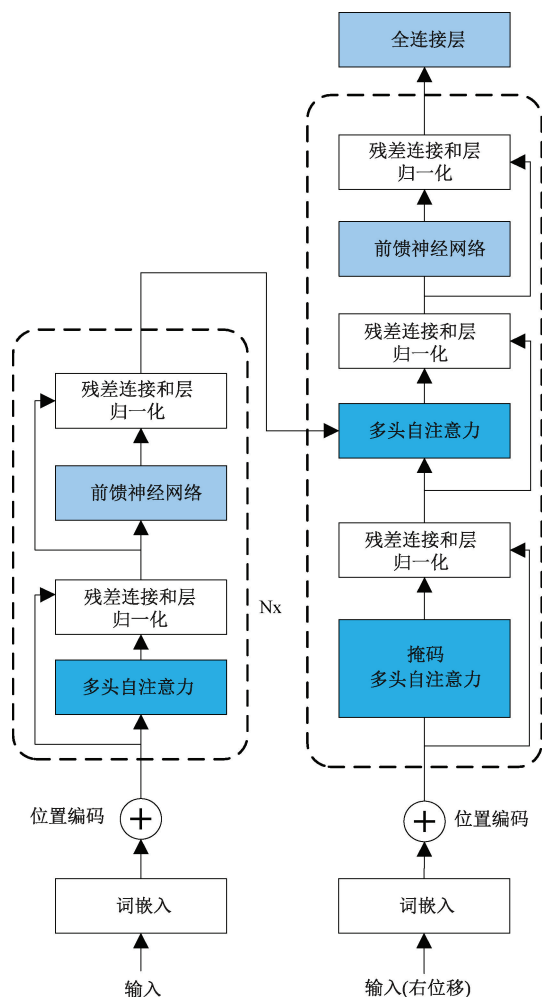


图1 Transformer模型结构

Fig.1 Transformer model structure




图2 BiGRU模型结构

Fig.2 BiGRU model structure

## 2 建立短期风电功率预测模型

### 2.1 建立Transformer-BiGRU预测模型

Transformer通过自注意力机制捕捉全局依赖,特别适合处理长序列数据,而BiGRU通过双向信息流处理序列数据,能够同时捕捉前向和后向特征。在构建Transformer-BiGRU预测模型时,可以将Transformer的编码器部分用于对风速等时间序列特征进行编码,提取具

有全局依赖性的高层特征表示。而解码器部分则用BiGRU网络代替,以充分利用双向信息流的优势,对序列进行更细粒度的动态建模,从而增强模型在预测阶段对输入特征的敏感性和适应能力。模型的整体架构如图3所示。

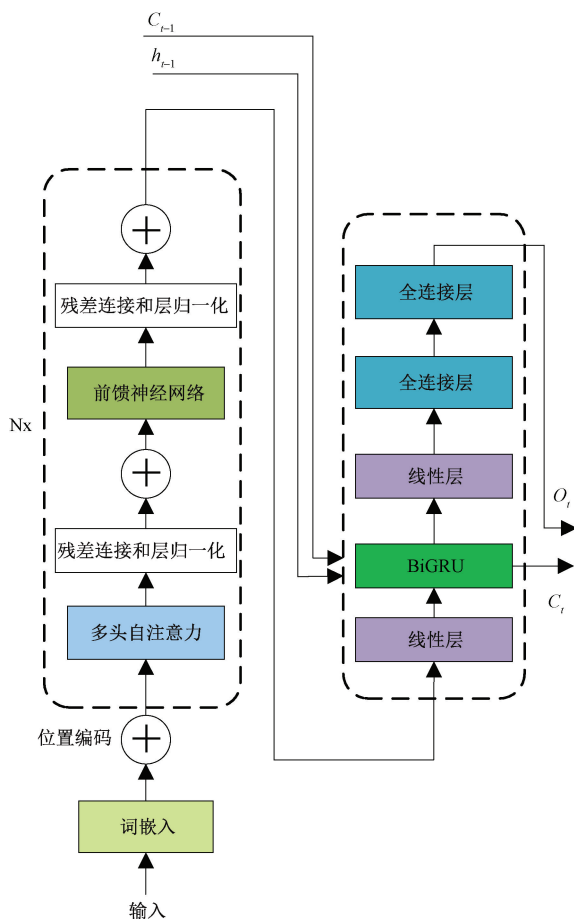


图3 Transformer-BiGRU模型

Fig.3 Transformer-BiGRU model structure

### 2.2 SSA优化Transformer-BiGRU模型

在Transformer模型中,嵌入维度、隐藏层神经元个数、注意力头数、编码器解码器数、失活率以及BiGRU模型中的层数、每层神经元的个数,此外还有学习率、批量大小等超参数的选择会对模型的拟合度和预测的精度产生重要影响。考虑到风电输出功率预测模型中的输入是多维数据,手动调整Transformer模型和BiGRU模型的参数不仅效率低,而且预测精度差。因此,采用全局搜索能力强、优化参数收敛速度快的麻雀搜索算法来优化Transformer-BiGRU模型,确保模型能够快速稳定收敛。麻雀算法优化模型的流程如图4所示。

### 2.3 短期风电功率预测模型

为了实现更精确的风电功率预测,提出了一种基于CEEMDAN-SSA-Transformer-BiGRU的预测模型。模型结构如图5所示。步骤如下:

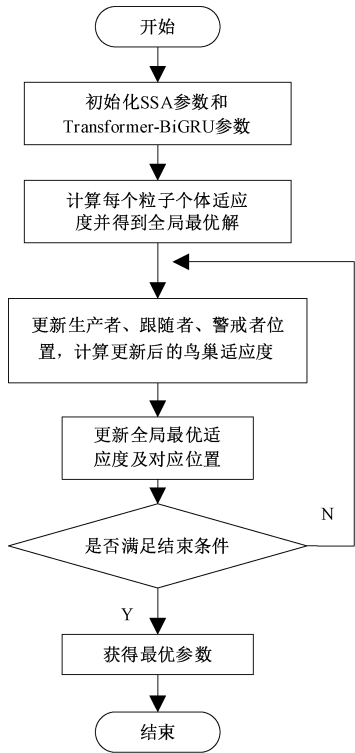


图 4 SSA 优化模型流程

Fig. 4 Flowchart of the SSA optimization model

- 1)数据预处理:采用均值填充法处理缺失值,并进行归一化操作。
- 2)序列分解:通过 CEEMDAN 算法对功率序列进行自适应模态分解,提取多组 IMF 分量及残差项,以应对非平稳信号特性。
- 3)参数优化:运用 SSA 算法对 Transformer-BiGRU 混合模型的超参数进行自适应调优,提升模型泛化能力。
- 4)特征建模:将分解后的各分量输入优化模型,通过 Transformer 的多头注意力机制捕捉长程依赖,结合 BiGRU 的双向门控网络提取局部时序特征,最终经全连接层融合输出预测结果。

3 实验结果及分析

3.1 输入数据预处理

本文使用基于龙源电力集团有限公司实际风电场数据构建的空间动态风电预测 (SDWPF) 数据集进行实验。SDWPF 包含 134 个 wpap 输出功率、风速、环境温度等特征信息,每隔 10 min 采样一次,数据覆盖 245 天。从中选取 1 个 wpap 数据的功率、风速和环境温度作为特征信息,用于单机一步超前风电功率预测。本文将 35 280 条原始数据按照 7:2:1 的比例划分为训练集、验证集和测试集。测试集数据如图 6 所示。

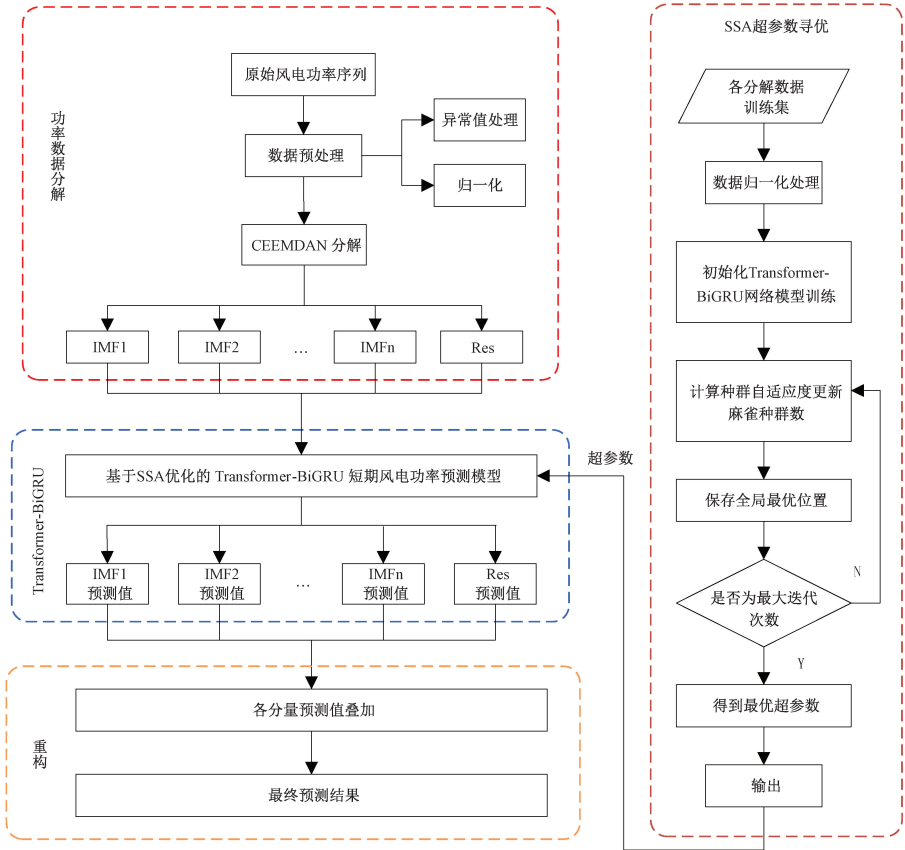


图 5 CEEMDAN-SSA-Transformer-BiGRU 模型结构

Fig. 5 CEEMDAN-SSA-Transformer-BiGRU model architecture






图6 风功率时间序列

Fig. 6 Wind power time series

3.2 评价指标

为了全面分析模型的预测效果和评价模型的性能,本文采用均方误差(MSE)、平均绝对误差(MAE)、均方根误差(RMSE)、决定系数( $R^2$ )对模型的预测精度进行评价。指标对应的计算公式如下:

$$MSE = \frac{1}{N} \sqrt{\sum_{i=1}^N (X_i - Y_i)^2}$$
 (10)

$$MAE = \frac{1}{N} \sum_{i=1}^N |X_i - Y_i|$$
 (11)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - Y_i)^2}$$
 (12)

$$R^2 = 1 - \frac{\sum_{i=1}^N (X_i - Y_i)^2}{\sum_{i=1}^N (Y_i - \hat{Y})^2}$$
 (13)

式中:  $N$  为采样样本总个数;  $X_i$  为第  $i$  个数据点的预测值;  $Y_i$  第  $i$  个数据点的真实值;  $\hat{Y}$  为样本的平均值。

3.3 实验结果分析

1)CEEMDAN 分解数据

通过 CEEMDAN 算法对风电功率序列进行模态分解,得到 12 个本征模态函数(IMF)和 1 个残差函数(Res)。分解结果如图 7 所示(展示部分分量 IMF1-IMF9)。

2)实验环境及参数设置

本文实验是在 windows10 平台上进行,计算机的配置:处理器为 Intel (R) Core (TM) i5-9300HF CPU @ 2.40 GHz,显卡为 NVIDIA GeForce GTX 1650,内存为 16 G。采用 SSA 算法对 Transformer-BiGRU 神经网络模型进行寻优,主要对 Transformer 网络的嵌入维度、隐藏层神经元个数、注意力头数、编码器层数、失活率以及 BiGRU 网络的层数和隐藏层神经元个数和训练过程中使用的学习率、批量大小等参数进行优化,优化之后的结果如表 1 所示。

3)实验分析

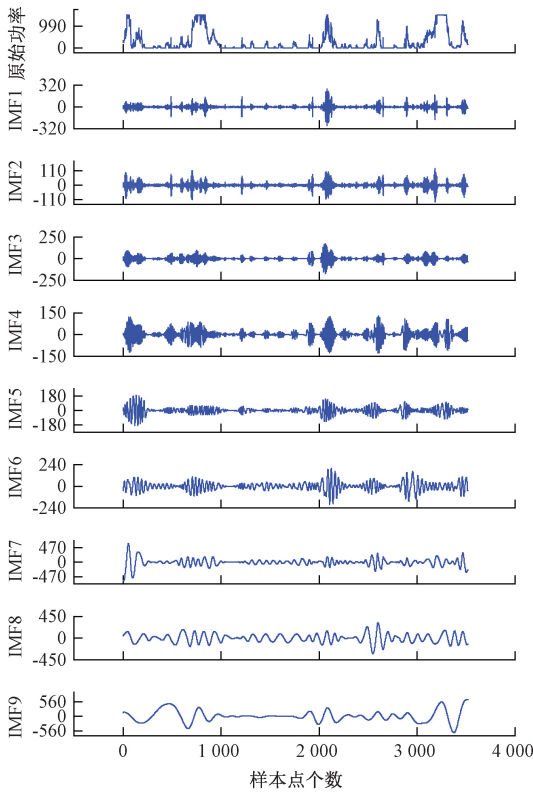


图7 CEEMDAN 功率分量图

Fig. 7 CEEMDAN power component diagram

(1)对比实验

为消除单次训练结果的偶然性对评估结果的影响,本文对每个模型进行了 7 次独立训练,并在此基础上去除了每个评估指标中的最大值和最小值。最终,计算剩余 5 次训练的平均值,作为更为稳健的评估指标。本文还将 LSTM<sup>[11]</sup>、CNN-GRU<sup>[12]</sup>、Informer<sup>[13]</sup>、Transformer<sup>[14]</sup>、Autoformer<sup>[15]</sup>、Transfomer-CNN<sup>[16]</sup>和 BiGRU<sup>[17]</sup>等经典模型引入进行对比实验。功率预测对比图如图 8 所示(选取第 226 天 144 个点的数据进行展示)。实验结果指标如表 2 所示。模型各指标对比如图 9 所示。

表 1 超参数寻优结果

Table 1 Hyperparameter optimization results

寻优参数	Transformer-BiGRU
Transformer 嵌入维度	32
Transformer 隐藏层神经元个数	161
Transformer 注意力头数	4
Transformer 编码器层数	2
Transformer 失活率	0.000 24
BiGRU 层数	2
BiGRU 隐藏层神经元个数	[16,32]
学习率	0.000 1
批量大小	256

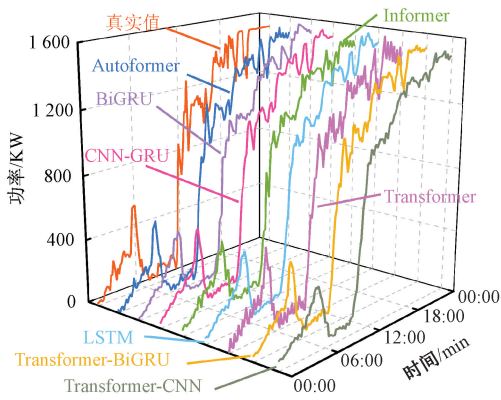


图 8 功率预测对比图

Fig. 8 Power prediction comparison diagram

表 2 模型对比

Table 2 Model comparison

预测模型	MSE/kW	MAE/kW	RMSE/kW	R <sup>2</sup>
LSTM	3 957.93	41.78	62.91	0.978 5
CNN-GRU	4 071.77	43.91	63.76	0.977 9
Informer	7 838.76	64.26	88.32	0.957 4
Transformer	6 513.31	60.65	80.62	0.964 6
Autoformer	6 255.10	60.04	78.84	0.966 0
Transformer-CNN	5 911.30	54.65	76.78	0.967 9
BiGRU	4 825.20	43.55	69.40	0.973 8
本模型	<b>3 490.00</b>	<b>38.42</b>	<b>59.04</b>	<b>0.981 0</b>

通过表格中的数据分析,可以看出,在单一模型中,LSTM模型表现最为优越,具有明显的优势。具体而言,LSTM的 $R^2$ 为0.978 5,远高于Informer( $R^2=0.957 4$ ),并且优于Transformer( $R^2=0.964 6$ )和Autoformer( $R^2=0.966 0$ )。此外,LSTM的MSE为3 957.93,MAE为41.78, RMSE为62.91, $R^2$ 为0.978 5。与Informer模型相比,LSTM的MSE降低了3 880.83,MAE降低了22.48, RMSE降低了25.41, $R^2$ 增加了0.021 1;与Autoformer模型相比,LSTM的MSE、MAE、RMSE分别降低了2 297.17、18.26、15.93, $R^2$ 则提升了0.012 5;与Transformer模型相比,LSTM的MSE、MAE、RMSE同样分别降低了2 555.38、18.87、17.71, $R^2$ 提升了0.013 9。与BiGRU模型相比,LSTM的预测效果同样更好,MSE降低了867.27,MAE降低了1.77, RMSE降低了6.49, $R^2$ 提升了0.004 7。

对于组合模型,本研究提出的组合模型表现出更优异的预测性能。该模型的MSE为349 0,MAE为38.42, RMSE为59.04, $R^2$ 为0.981 0,相较于单独的LSTM模型,本研究提出的组合模型的MSE降低了467.93,MAE降低了3.36, RMSE降低了3.87, $R^2$ 增加了0.002 5。与CNN-GRU模型相比,该组合模型的MSE、MAE、RMSE分别降低

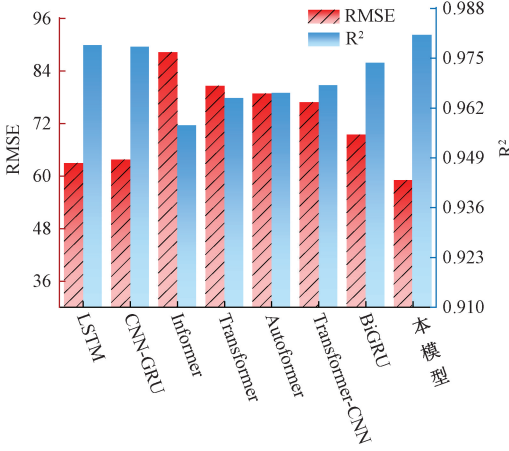
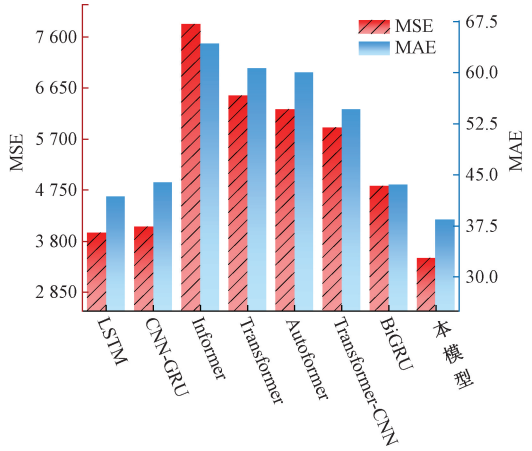


图 9 模型各指标对比图

Fig. 9 Model performance comparison diagram

了581.77、5.49、4.72, $R^2$ 提升了0.003 1;与Transformer-CNN模型相比,该组合模型的MSE、MAE、RMSE同样降低了2 421.3、16.23、17.74, $R^2$ 增加了0.013 1。

综合分析可以得出结论,在风电功率的时序预测任务中,本文提出的组合模型的性能明显优于其他对比模型,该模型性能最佳,其次是LSTM、CNN-GRU、BiGRU、Transformer-CNN、Autoformer和Transformer的表现相对较差,Informer模型的表现最为逊色。

(2)消融实验

为了全面验证CEEMDAN-Transformer-BiGRU模型中各模块的性能贡献,本文设计了一系列消融实验,具体步骤如下:首先,移除CEEMDAN模块,通过将CEEMDAN-Transformer-BiGRU与Transformer-BiGRU进行对比,以及CEEMDAN-Transformer与Transformer进行对比,评估CEEMDAN模块在数据分解与特性提取方面的作用。同时,将CEEMDAN-BiGRU与BiGRU进行比较,进一步体现数据分解对模型性能提升的优势。接着,将CEEMDAN-Transformer-BiGRU分别与单模块的Transformer和BiGRU进行对比,分析模块组合在增强预测性能方面的整体效果。实验结果如表3、4所示。实验结

果对比曲线图如图 10 所示(选取第 226 天 144 个点的数据进行展示)。

表 3 模型命名

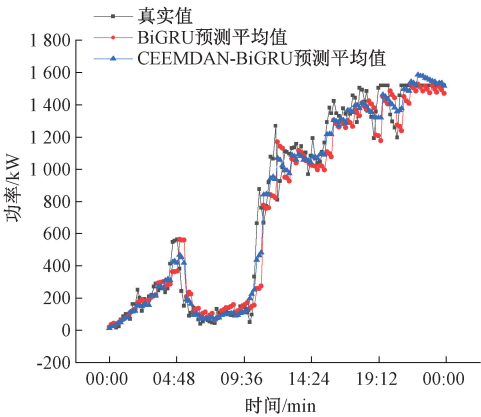
Table 3 Model naming

模型	序号
CEEMDAN-Transformer-BiGRU	模型一
Transformer-BiGRU	模型二
CEEMDAN-Transformer	模型三
Transformer	模型四
CEEMDAN-BiGRU	模型五
BiGRU	模型六

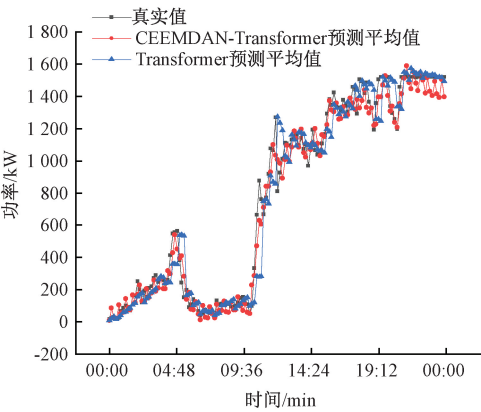
表 4 测试结果比较

Table 4 Comparison of test results

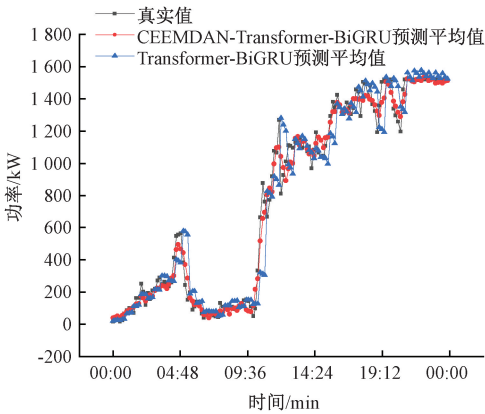
预测模型	MSE/KW	MAE/KW	RMSE/KW	R <sup>2</sup>
模型一	3 490.00	38.42	59.04	0.981 0
模型二	8 637.86	51.98	92.94	0.953 1
模型三	6 513.31	60.65	80.62	0.964 6
模型四	9 834.97	61.98	99.17	0.946 6
模型五	4 825.20	43.55	69.40	0.973 8
模型六	8 724.44	56.02	93.40	0.952 6



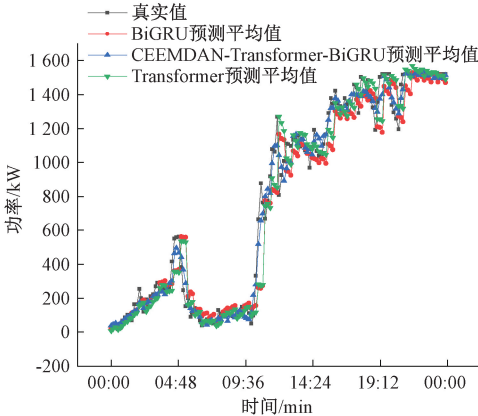
(a) BiGRU模块消融  
(a) Ablation of the BiGRU module



(b) Transformer模块消融  
(b) Ablation of the Transformer module



(c) Transformer-BiGRU模块消融  
(c) Ablation of the Transformer-BiGRU module



(d) 组合模块消融  
(d) Ablation of the combined module

图 10 实验结果对比曲线图

Fig. 10 Comparison curve of experimental results

根据表格数据,采用 CEEMDAN 分解算法的 BiGRU 模型、Transformer 模型以及 Transformer-BiGRU 组合模型在预测效果上均明显优于未使用 CEEMDAN 分解算法的模型。具体来说,在 CEEMDAN-BiGRU 模型中,相较于未使用 CEEMDAN 的 BiGRU 模型,MSE、MAE 和 RMSE 分别降低了 3 899.24、12.47 和 24,R<sup>2</sup> 增加了 0.021 2;在 CEEMDAN-Transformer 模型中,MSE、MAE 和 RMSE 分别降低了 3 321.66、1.33 和 18.55,R<sup>2</sup> 提升了 0.018;而在 CEEMDAN-Transformer-BiGRU 组合模型中,MSE、MAE 和 RMSE 的减少幅度与前两个模型一致,分别为 5 147.86、13.56 和 33.9,R<sup>2</sup> 的提升也保持一致,增加了 0.027 9。这表明,CEEMDAN 分解算法有效地降低了模型的预测误差,通过分解原始数据序列,有效解决了模态混淆问题。

进一步比较不同模型的表现,单独使用 Transformer 模型和 BiGRU 模型的效果均不及 CEEMDAN-Transformer-BiGRU 组合模型。在 CEEMDAN-Transformer-BiGRU 组合模型与单独 Transformer 模型相比,MSE、MAE 和 RMSE 分别降低了 6 344.97、23.56 和

40.13,  $R^2$  升高了 0.034 4;与单独 BiGRU 模型相比, MSE、MAE 和 RMSE 也分别降低了 5 234.44、17.6 和 34.36,  $R^2$  升高了 0.028 4。由此可见,组合模型通过融合各模型的优势,能够更全面地捕捉时间序列中的复杂特征,显著提高预测能力,相较于单独使用 Transformer 或 BiGRU 模型,表现更加优异。

## 4 结 论

本文针对风力发电功率存在较大的随机性和不确定性提出了一种基于 SSA 优化算法的 CEEMDAN-Transformer-BiGRU 的组合预测模型,通过算例分析得出以下主要结论:

通过 CEEMDAN 算法对风电功率进行分解,能够有效识别功率数据的局部非线性特征,克服了 EMD 和 EEMD 算法中常见的模态混叠和噪声干扰问题,提升了数据的稳定性和可预测性。选择拥有多头自注意力机制的 Transformer 模型和双向信息流结构的 BiGRU 模型相结合,能够更好地捕捉风电功率时间序列中的长短期依赖关系,显著提升了预测精度。引入麻雀搜索算法(SSA)对 Transformer-BiGRU 模型的超参数进行优化,不仅简化了超参数选择过程,还提高了模型的预测能力,增强了其适应性。实验结果表明,CEEMDAN-Transformer-BiGRU 组合模型在 MSE、MAE、RMSE 和  $R^2$  等指标上均优于传统的单一预测算法和其他混合预测模型,验证了其在预测任务中的优越性。

然而,当前的研究主要集中在短期风电功率预测,而中长期风电功率预测尚未得到充分探索,这一领域面临着更加复杂的挑战。中长期风电功率预测需要考虑更广泛的时间尺度,包括季节性波动、气候变化、外部环境因素等,这使得预测任务的复杂度大大增加。因此,未来的研究需要着重探讨如何融合不同的模型和优化算法,结合短期与中长期预测的优势,提升模型在长期预测中的适应能力和准确性。

## 参考文献

- [1] 邹才能,何东博,贾成业,等.世界能源转型内涵、路径及其对碳中和的意义[J].石油学报,2021,42(2):233-247.  
ZOU C N, HE D B, JIA C H Y, et al. Connotation, pathways, and implications of global energy transition for carbon neutrality[J]. Acta Petrolei Sinica, 2021, 42(2): 233-247.
- [2] 王瑞,徐新超,逯静.基于特征选择及 ISSA-CNN-BiGRU 的短期风功率预测[J].工程科学与技术,2024,56(3):228-239.  
WANG R, XU X C H, LU J. Short-term wind power prediction based on feature selection and ISSA-CNN-BiGRU[J]. Engineering Science and Technology, 2024, 56(3): 228-239.
- [3] LIU M D, DING L, BAI Y L. Application of hybrid model based on empirical mode decomposition, novel recurrent neural networks and the ARIMA to wind speed prediction [J]. Energy Conversion and Management, 2021, 233: 113917.
- [4] 王瑞,陈泽坤,逯静.基于 VMD 和 IBA-LSSVM 的短期风电功率预测[J].河海大学学报(自然科学版),2021,49(6):575-582.  
WANG R, CHEN Z K, LU J. Short-term wind power prediction based on VMD and IBA-LSSVM[J]. Journal of Hohai University (Natural Sciences), 2021, 49(6): 575-582.
- [5] 杨国清,刘世林,王德意,等.基于 Attention-GRU 风速修正和 Stacking 的短期风电功率预测[J].太阳能学报,2022,43(12):273-281.  
YANG G Q, LIU S H L, WANG D Y, et al. Short-term wind power prediction based on attention-GRU wind speed correction and stacking[J]. Acta Energetica Sinica, 2022, 43(12): 273-281.
- [6] 王愈轩,刘尔佳,黄永章.基于 CNN-LSTM-lightGBM 组合的超短期风电功率预测方法[J].科学技术与工程,2022,22(36):16067-16074.  
WANG Y X, LIU E R J, HUANG Y Z H. Ultra-short-term wind power prediction method based on CNN-LSTM-lightGBM combination [J]. Science Technology and Engineering, 2022, 22 (36): 16067-16074.
- [7] PARRI S, TEEPARTHI K. SVMD-TF-QS: An efficient and novel hybrid methodology for the wind speed prediction [J]. Expert Systems with Applications, 2024, 249:123516.
- [8] 欧旭鹏,唐云,张凯,等.基于 CEEMDAN-IDOA-BiLSTM 的超短期风电功率预测[J].电网与清洁能源,2023,39(11):142-150.  
OU X P, TANG Y, ZHANG K, et al. Ultra-short-term wind power prediction based on CEEMDAN-IDOA-BiLSTM[J]. Power Grid and Clean Energy, 2023, 39(11):142-150.
- [9] YU D, QIAO X, WANG X. Light intensity optimization of optical fiber stress sensor based on SSA-LSTM model[J]. Frontiers in Energy Research, 2022, 10: 972437.
- [10] NASCIMENTO E G S, DE MELO T A C, MOREIRA D M. A transformer-based deep neural network with wavelet transform for forecasting wind speed and wind energy [J]. Energy, 2023, 278: 127678.

- [11] 曾进辉,苏旨音,肖锋,等. 基于生成对抗网络和 EMD-ISSA-LSTM 的短期电力负荷预测[J]. 电子测量技术, 2024, 47(20): 92-100.  
ZENG J H, SU ZH Y, XIAO F, et al. Short-term power load forecasting based on generative adversarial network and EMD-ISSA-LSTM [J]. Electronic Measurement Technology, 2024, 47(20): 92-100.
- [12] 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 M, ZHAI J X, MA J, et al. Short-term power load forecasting method based on transfer learning and CNN-GRU[J]. Engineering Journal of Wuhan University, 2024, 57(6): 812-820.
- [13] 王颀,刘兴杰,梁英,等. 一种基于 MGWO-Informer 的超短期风电功率预测方法[J]. 太阳能学报, 2024, 45(11): 477-485.  
WANG X, LIU X J, LIANG Y, et al. Ultra-short-term wind power prediction method based on MGWO-Informer[J]. Acta Energaie Solaris Sinica, 2024, 45(11): 477-485.
- [14] 黄莉,甘恒玉,刘兴举,等. 基于 Transformer 编码器的超短期光伏发电功率预测[J]. 智慧电力, 2024, 52(5): 16-22, 59.  
HUANG L, GAN H Y, LIU X J, et al. Ultra-short-term photovoltaic power prediction based on transformer encoder[J]. Smart Power, 2024, 52(5): 16-22, 59.
- [15] 唐利涛,张智勇,陈俊,等. 基于 Autoformer 的电力负荷预测与分析研究[J]. 华东师范大学学报(自然科学版), 2023(5): 135-146.  
TANG L T, ZHANG ZH Y, CHEN J, et al. Power load prediction and analysis based on Autoformer[J]. Journal of East China Normal University (Natural Science Edition), 2023(5): 135-146.
- [16] 朱彦民,李忠虎,王金明,等. 基于 Transformer 的风电机组故障预测[J]. 电子测量技术, 2024, 47(13): 45-52.  
ZHU Y M, LI ZH H, WANG J M, et al. Transformer-based fault prediction for wind turbine units[J]. Electronic Measurement Technology, 2024, 47(13): 45-52.
- [17] 白隆,俞斌,高峰,等. 基于 ICEEMDAN 和 TCN-AM-BiGRU 的短期光伏功率预测[J]. 电子测量技术, 2024, 47(9): 61-69.  
BAI L, YU B, GAO F, et al. Short-term photovoltaic power prediction based on ICEEMDAN and TCN-AM-BiGRU [J]. Electronic Measurement Technology, 2024, 47(9): 61-69.

#### 作者简介

**包广斌**, 博士, 副教授, 研究生导师, 主要研究方向为计算机网络体系结构、人工智能、计算机视觉和图像处理等。

E-mail: bao.gb@qq.com

**杨龙龙**(通信作者), 硕士研究生。主要研究方向为人工智能、负荷预测、风电功率预测等。

E-mail: 3150263545@qq.com