



DOI:10.12404/j.issn.1671-1815.2407479

引用格式:朱婷,颜七笙.基于模态分解和RIME-CNN-BiLSTM-AM的风速预测方法[J].科学技术与工程,2025,25(20):8514-8525.

Zhu Ting, Yan Qisheng. Wind speed prediction based on modal decomposition and RIME-CNN-BiLSTM-AM[J]. Science Technology and Engineering, 2025, 25(20): 8514-8525.

电工技术

# 基于模态分解和 RIME-CNN-BiLSTM-AM 的风速预测方法

朱婷<sup>1</sup>, 颜七笙<sup>2\*</sup>

(1. 东华理工大学经济与管理学院, 南昌 330000; 2. 东华理工大学理学院, 南昌 330013)

**摘要** 作为一种清洁的可再生能源,风能在缓解日益严重的能源危机方面充当着重要作用。然而,风速的波动性和随机性给电力系统的稳定运行带来了严峻的挑战。针对该问题,提出一种基于自适应噪声完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)与霜冰优化算法(rime optimization algorithm, RIME)-卷积神经网络(convolutional neural network, CNN)-双向长短期记忆网络(bidirectional long short-term memory network, BiLSTM)-注意力机制(attention mechanism, AM)的短期风速预测组合模型 CEEMDAN-RIME-CNN-BiLSTM-AM。首先,对初始风速序列采用 CEEMDAN 算法,得到一系列较平稳的子模态,以降低风速序列的波动性;然后,采用 RIME 霜冰优化算法优化 CNN 超参数,建立 CNN-RIME 模型,对风速数据进行自适应提取和挖掘;接着,采用 BiLSTM-AM 模型对处理后的数据进行预测;最后,将各子序列的预测结果叠加,得到最终预测结果。以某地实际风速数据集进行对比试验,该模型在单步与多步预测中均展现出良好的预测性能,可以为制定调度计划提供参考,以最大程度地提高能源利用率和供电。

**关键词** 风速预测;自适应噪声完备集合经验模态分解(CEEMDAN);霜冰优化算法(RIME);卷积神经网络(CNN);双向长短期记忆网络(BiLSTM);注意力机制(AM)

中图分类号 TM614 TP183; 文献标志码 A

## Wind Speed Prediction Based on Modal Decomposition and RIME-CNN-BiLSTM-AM

ZHU Ting<sup>1</sup>, YAN Qi-sheng<sup>2\*</sup>

(1. College of Economic and Management, East China University of Technology, Nanchang 330000, China;

2. College of Science, East China University of Technology, Nanchang 330013, China)

**[Abstract]** Serving as a clean and renewable energy source, wind energy plays a significant role in mitigating the increasingly severe energy crisis. However, the fluctuation and randomness of wind speed pose severe challenges to the stable operation of power systems. To address this issue, a combined short-term wind speed forecasting model named CEEMDAN-RIME-CNN-BiLSTM-AM was proposed, which was based on complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN), rime optimization algorithm (RIME), convolutional neural network (CNN), bidirectional long short-term memory network (BiLSTM), and attention mechanism (AM). Initially, the CEEMDAN algorithm was applied to the original wind speed series to obtain a series of relatively stable sub-modes, thereby reducing the volatility of the wind speed series. Subsequently, the CNN hyperparameters were optimized using the RIME algorithm to establish the CNN-RIME model for adaptive extraction and mining of wind speed data. Then, the BiLSTM-AM model was employed to forecast the processed data. Finally, the forecasting results of each sub-series were superimposed to obtain the final forecasting result. A comparative experiment was conducted using an actual wind speed dataset from a certain location. The proposed model demonstrates good forecasting performance in both single-step and multi-step forecasting, providing a reference for scheduling plans to maximize energy utilization and power supply.

**[Keywords]** wind speed prediction; complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN); rime optimization algorithm (RIME); convolutional neural network (CNN); bidirectional long short-term memory network (BiLSTM); attention mechanism (AM)

收稿日期:2024-10-10; 修订日期:2025-04-28

基金项目:国家自然科学基金(71961001)

第一作者:朱婷(2001—),女,汉族,安徽阜阳人,硕士研究生。研究方向:智能计算及应用。E-mail:1668986880@qq.com。

\*通信作者:颜七笙(1976—),男,汉族,江西临川人,博士,教授。研究方向:智能计算及应用。E-mail:yanqs93@126.com。

投稿网址:www.stae.com.cn

近年来,能源短缺、环境恶化等一系列问题让绿色可再生能源成为人们关注的焦点。其中,风能以其高效、纯净、资源丰富等优势得到了快速发展。随着风电在电网中所占比例的不断增加,风电输出的不稳定性给电网的稳定运行带来了挑战,其中风速的随机性和不稳定性是其中的主要因素<sup>[1]</sup>。因此,准确、稳定的风速预测对高效的电网规划和确保可再生能源的充分接纳起着十分重要的作用<sup>[2-3]</sup>。

中外学者在风速预测领域开展了广泛研究。目前,风速预测的主要方法可归纳为三大类别:统计学模型、人工智能模型以及组合预测模型。

统计学模型包括 ARMA(auto regressive moving average)<sup>[4]</sup>、ARIMA(auto regressive integrated moving average)<sup>[5]</sup>、Logistic 模型<sup>[6]</sup>等。尽管统计学方法具备结构简洁、建模便利的特点,然而,输入数据的分布特征对模型输出结果产生影响显著。

人工智能模型包括支持向量机(support vector machine, SVM)<sup>[7]</sup>、随机森林(random forest, RF)<sup>[8]</sup>等。其中, SVM 算法既适用于线性问题也适用于非线性问题,其泛化误差率低,能有效应对传统算法面临的高维数据处理难题,但在面对大规模时间序列数据时,存在收敛速度慢和预测精度下降的问题。随机森林算法通过同时训练多个决策树来提高预测性能,但随机森林算法对噪声数据比较敏感。近年来,深度学习备受瞩目,并被应用于风速预测领域,如长短期记忆网络(long short-term memory, LSTM)<sup>[9]</sup>、卷积神经网络(convolutional neural network, CNN)<sup>[10]</sup>和门控循环单元(gated recurrent unit, GRU)<sup>[11]</sup>等。文献[12]通过将 CNN 融入预测模型,实现了对数据内部变化规律的空间特征的有效提取。文献[13]选用双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)作为预测框架,该网络凭借其双向信息流结构,能够更全面地捕捉各分量的动态变化,进而提升了预测模型的精确度。文献[14]在预测模型中引入注意力机制(attention mechanism, AM),为双向门控循环单元(bidirectional recurrent neural network, BiGRU)的输出状态分配了不同权重,从而增强了关键特征的输出,实验结果显示,其预测精度相较于 BiGRU 模型有明显提升。

组合预测模型即将数据分解算法或优化算法与预测模型进行组合,将数据分解为若干个简单分量或对模型重涉及的多个超参数进行优化。文献[15]采用变分模态分解(variational mode decomposition, VMD)对风速序列进行分解并与 GRU 组成组合预测模型对负荷进行预测, VMD 展现出较好的

抗噪声能力,然而其分解效果却高度依赖于核心参数的设定,而这些参数的确定往往带有较大的主观判断成分。文献[16]采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)算法,将风速序列分解为一系列具有不同特征的模态分量结合相关预测算法,展现出优异的预测效果。文献[17]采用麻雀搜索算法(sparrow search algorithm, SSA)对预测模型隐藏层神经元个数、学习率等参数进行优化,确定模型的最优参数组合。文献[18]采用灰狼优化算法(grey wolf optimizer, GWO)对组合模型的权重参数进行优化,经过实验表明,经过优化后的模型预测性能显著提高。

上述方法均采用信号分解、人工智能模型和优化算法去研究风速的变化特征。但在利用这些方法时均没有深入探究风速变化规律与预测模型之间的深层联系,算法参数设定后固定不变,使得风速预测的准确度存在一定局限性。现采用智能算法主动适应风速变化规律,采用信号分解和深度学习方法深入探究风速的变化规律。

针对风速序列的特点,根据“分解-预测-重构”的研究思路,提出 CEEMDAN 和霜冰优化算法(rime optimization algorithm, RIME)优化 CNN 的 BiLSTM-AM 的组合预测模型。将风速序列采用 CEEMDAN 算法分解为若干分量,以降低风速的波动性;把影响因素进行归一化处理,消除数据量纲差异。采用 RIME 算法对 CNN 的卷积层和的数量  $N$ 、卷积核的大小  $K$ 、批处理大小和学习率进行优化以构建 RIME-CNN 模型,极大优化 CNN 的特征处理能力。建立 BiLSTM-AM 模型,将经过特征处理后的数据输入至 BiLSTM-AM 模型中训练。BiLSTM 可以同时处理过去与未来的时序信息,AM 可以区分来自 BiLSTM 的时间序列信息的重要性,模型可以聚焦数据的关键部分,提取最深层的时间相关性。最后,将各子序列的预测结果进行叠加,得出最终的预测值。将所提模型分别进行不同分解算法的对比、不同化算法的对比、其他模型的对比、消融实验及多步预测实验。实验结果表明,所提模型具有较好的预测效果,可为风电并网稳定运行提供可靠信息。

## 1 模型原理

### 1.1 自适应噪声完备集合经验模态分解算法

CEEMDAN 是一种改进的数据分解算法<sup>[19]</sup>,通过自适应的添加高斯白噪声,使得在实验次数较少的情况下对信号进行分解重构,得到若干个 IMF 分

量,CEEMDAN 不仅在很大程度上消除了 EMD 和 EEMD 的模态混叠和噪声残差大等问题,而且对于处理非线性和非平稳信号分解效果很好。具体步骤如下。

**步骤 1** 在第  $M$  次实验中,运用式(5)对原始信号  $x_i$  进行分解,取平均后得到第一个 IMF 分量和第一个残差信号  $r_1(t)$ 。

$$\text{IMF}_1 = \frac{1}{M} \sum_{i=1}^M \text{IMF}_{1i} \quad (1)$$

式(1)中:  $\text{IMF}_1$  为  $M$  次实验取平均得到的第一个分量;  $M$  为实验次数;  $\text{IMF}_{1i}$  为  $i$  次实验得到的 IMF 分量。

$$r_1(t) = x(t) - \text{IMF}_1(t) \quad (2)$$

**步骤 2** 在残差信号中加入自适应噪声  $\varepsilon_1 E_1[\omega_i(t)]$ ,其中,  $\varepsilon_1$  为高斯白噪声  $\omega_i(t)$  的信噪比,  $E_1(\cdot)$  为分解后第  $i$  个 IMF 分量的算子,则下一个 IMF 分量可表示为

$$\text{IMF}_2 = \frac{1}{M} \sum_{i=1}^M E_1 \{ r_1(t) + \varepsilon_1 E_1[\omega_i(t)] \} \quad (3)$$

**步骤 3** 对剩下的残差信号重复以上步骤,则第  $n$  个 IMF 分量可表示为

$$\text{IMF}_n = \frac{1}{M} \sum_{i=1}^M E_n \{ r_n(t) + \varepsilon_n E_n[\omega_i(t)] \} \quad (4)$$

式(4)中:  $r_n(t)$  为第  $n$  个分量的残差;  $\varepsilon_n$  为第  $n$  个分量中的信噪比;  $E_n(\cdot)$  为分解后第  $n$  个 IMF 分量的算子。

**步骤 4** 重复上述步骤,直到残差信号不能再被分解为止。假设最后分解出  $N$  个 IMF 分量,则最终原始信号可表示为

$$x(t) = \sum_{i=1}^N \text{IMF}_i + \sum_{i=1}^M r_i(t) \quad (5)$$

## 1.2 霜冰优化算法

RIME 是 Su 等<sup>[20]</sup>于 2023 年提出的算法,该算法通过模拟软霜冰粒子的运动,提出一种用于算法搜索的霜冰搜索策略。RIME 算法基于物理的优化器,利用模拟霜冰中软冰针和硬冰针生长过程,来实现优化方法的探索和开发行为,并通过改进的正向贪婪选择机制进行全局寻优。Su 等<sup>[20]</sup>将该算法划分为初始化霜冰结晶点、引入软霜冰搜索策略和硬霜冰穿刺机制,并改进贪婪选择策略来建立数学模型。图 1 为 RIME 算法流程图。

RIME 霜冰粒子种群  $R$  位置可表示为

$$R = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1j} \\ x_{21} & x_{22} & \cdots & x_{2j} \\ \vdots & \vdots & & \vdots \\ x_{i1} & x_{i2} & \cdots & x_{ij} \end{bmatrix} \quad (6)$$

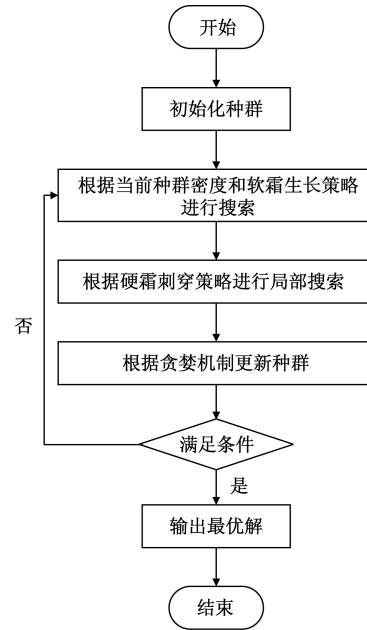


图 1 RIME 算法流程图

Fig. 1 Flow chart of RIME algorithm

式(6)中:  $x_{ij}$  为霜冰粒子种群,其中,  $i$  为霜冰晶体的序号,  $j$  为霜冰颗粒的序号。

所有霜冰粒子的适应度值  $F(S_i)$  可表示为

$$F(S_i) = \begin{bmatrix} f([x_{i1} & x_{i2} & \cdots & x_{ij}]) \\ f([x_{21} & x_{22} & \cdots & x_{2j}]) \\ \vdots \\ f([x_{i1} & x_{i2} & \cdots & x_{ij}]) \end{bmatrix} \quad (7)$$

式(7)中:  $f$  为每个霜冰粒子的适应度。

每个霜冰粒子  $x_{ij}$  在凝结之前会按照一定规律运动,自由状态的粒子则会移动到软冰附近凝结,但当超过一定的范围则无法凝结,在软冰形成的过程中每个粒子的随机性会导致凝结面积增大,受环境影响最终达到一个稳定状态。

针对霜冰粒子的运动性质,霜冰粒子的位置可表示为

$$R_{ij}^{\text{new}} = R_{\text{best},j} + r_1 \cos(\theta) \beta [\psi(U_{bij} - L_{bij}) + L_{bij}] \quad (8)$$

$$r_2 < E \quad (9)$$

式中:  $R_{ij}^{\text{new}}$  为粒子更新后的位置;  $R_{\text{best},j}$  为霜冰种群  $R$  中最优晶体的第  $j$  个粒子;  $r_1$  为  $(-1, 1)$  的随机数,控制粒子的移动方向,并且会随着粒子移动方向  $\cos\theta$  迭代发生变化;  $\beta$  为环境因子,表示外部的影响因素;粒子附着力  $\psi$  为  $(0, 1)$  的随机数,用于控制粒子间的距离;  $U_{bij}$ 、 $L_{bij}$  分别为粒子运动空间的上界和下界;  $E$  为附着系数,会随迭代的次数增大,影响粒子的凝结概率;  $r_2$  为  $(0, 1)$  的随机数,它与  $E$  控制粒子是否凝结,即粒子位置是否更新。

为了确保收敛需设定可表示为

$$\theta = \pi \frac{h}{10H} \quad (10)$$

式(10)中: $h$ 为当前迭代次数; $H$ 为最大迭代次数。

$$\beta = 1 - \frac{\left(\frac{wh}{H}\right)}{w} \quad (11)$$

式(11)中: $\beta$ 为阶跃函数; $w$ 为用于控制步进函数的段数;

$E$ 的表达式为

$$E = \sqrt{\frac{h}{H}} \quad (12)$$

随软冰凝结面积增大,产生强随机性和覆盖范围广的特点,让算法能够快速覆盖全空间的搜索,从而在优化过程中兼顾了全局性和局部性。硬冰受外界因素影响会向着同一方向凝结,由于硬冰的增长方向一致,导致硬冰之间很容易交叉,实现普通粒子和最优粒子的维度交换,有利于提高解的精度。由于在迭代的过程中,粒子之间的交叉互换,避免了局部最优,提高了收敛性。随着硬冰的生长穿刺,粒子之间的交叉替换可表示为

$$R_{ij}^{\text{new}} = R_{\text{best},j}, r_3 < F^{\text{norm}}(S_i) \quad (13)$$

式(13)中: $F^{\text{norm}}(S_i)$ 为当前适应度值归一化的值,表示第*i*个粒子被选中的概率; $r_3$ 为(-1,1)的随机数。

### 1.3 卷积神经网络

作为深度学习领域最广泛的算法,CNN 因其卓越的特征提取性能而被广泛应用于能源系统<sup>[21]</sup>。具体来说,CNN 主要由卷积层和池化层组成,卷积层通过应用卷积核对风速数据中的非线性特征进行精确的局部提取,有效捕捉数据中的核信息。池化层对提取的特征进行压缩和过滤,以提炼出更重要的信息,这不仅提高了模型处理数据的效率,也显著增强了其泛化能力,为风电系统研究提供了强大的技术支持。CNN 的基本结构如图 2 所示。




图2 CNN 结构图

Fig. 2 CNN structure diagram

### 1.4 BiLSTM 网络

BiLSTM 通过集成前向 LSTM 层和后向 LSTM 层,对传统单向 LSTM 进行增强,前向 LSTM 层和后向 LSTM 层都有助于整体输出<sup>[22]</sup>。虽然单一单向 LSTM 利用了历史风速数据,但值得注意的是,它在预测中缺乏对未来信息的考虑<sup>[23]</sup>。BiLSTM 不仅考

虑了序列的前向输入,还考虑了后向输入,即同时利用了序列的过去和未来信息。这种双向的处理方式有助于模型更全面地利用数据信息,从而进一步提高预测精度。BiLSTM 结构如图 3 所示。

$$\vec{h}_t = \text{LSTM}(x_t, \vec{h}_{t-1}) \quad (14)$$

$$\tilde{h}_t = \text{LSTM}(x_t, \tilde{h}_{t-1}) \quad (15)$$

$$y_t = \sigma(\mathbf{W}_y[\vec{h}_t, \tilde{h}_t] + \mathbf{b}_y) \quad (16)$$

式中:LSTM 单元为传统 LSTM 网络的计算过程; $\sigma$ 为 Sigmoid 函数; $\vec{h}_t$ 为*t*时刻的正向 LSTM 隐藏层状态; $\tilde{h}_t$ 为*t*时刻的向后 LSTM 隐藏层状态; $\mathbf{W}_y$ 和 $\mathbf{b}_y$ 分别为权重矩阵和偏差项; $x_1, x_2, \dots, x_t$ 为 $t_1, t_2, \dots, t_i$ 各时刻对应的输入数据, $i \in \{1, 2, \dots, t\}$ ;  $y_1, y_2, \dots, y_t$ 为 $t_1, t_2, \dots, t_i$ 各时刻对应的输出数据, $i \in \{1, 2, \dots, t\}$ 。




图3 BiLSTM 结构图

Fig. 3 BiLSTM structure diagram

### 1.5 注意力机制

注意力机制源于对人脑注意力特性的模拟,最早用于图像处理领域<sup>[24]</sup>。在深度学习中,注意力机制将对预测起关键作用的信息分配较大的权重,不重要的信息赋予较小的权重,通过该机制来优化信息处理的效率。注意单元的结构如图 4 所示。注意状态转换过程<sup>[25]</sup>如式(17)~式(20)所示。在深度学习中,注意力机制能够自适应地调整不同信息的权重,从而增强模型在特征挖掘方面的能力。通过将注意力机制融入 BiLSTM 网络,能够更精准地聚焦于关键特征,同时降低或忽略次要特征的影响。这不仅提高了模型的预测效率和准确性,还增强了其应对信息过载的能力。

$$S_{ii} = \mathbf{V} \tanh(\mathbf{W} \mathbf{H}_i + \mathbf{U} h_i + \mathbf{b}), \quad i = 1, 2, \dots, t-1 \quad (17)$$

$$a_{ii} = \frac{\exp S_{ii}}{\sum_{i=1}^{t-1} \exp S_{ii}}, \quad i = 1, 2, \dots, t-1 \quad (18)$$

$$F = \sum_{i=1}^t a_{ii} h_i, \quad i = 1, 2, \dots, t-1 \quad (19)$$

$$h'_i = f(F, \mathbf{H}_i) \quad (20)$$

式中: $S_{ii}$ 为利用 tanh 双曲正切激活函数计算时间步

的隐藏层状态对当前时刻输出的重要性得分;  $y_1, y_2, \dots, y_i$  为输入序列;  $h_1, h_2, \dots, h_i$  为输入序列对应的 BiLSTM 隐藏层输出的状态值;  $H_t$  为  $t$  时刻 CNN-BiLSTM 输出权重矩阵;  $a_{it}$  为 BiLSTM 隐藏层输出的状态值对应的当前注意权重;  $F$  为模型输出结果;  $h'_i$  为最终的特征向量;  $f(\cdot)$  为  $h'_i$  的计算过程;  $V, W, U, b$  为模型的学习参数。




图4 注意力机制结构图

Fig. 4 Structure of the attention mechanism

## 2 CEEMDAN-RIME-CNN-BiLSTM-AM 模型的建立

该模型由 CEEMDAN、RIME-CNN 和 BiLSTM-AM 模型组成。首先,采用 CEEMDAN 分解算法对原始风速数据进行分解;其次,为了提高 CNN 模型的性能,使用 RIME 寻找 CNN 模型的最优超参数,超参数包括卷积核数量  $N$ 、卷积核大小  $K$ 、批量大小和学习率;然后,使用 BiLSTM-AM 模型训练从 CNN 提取的特征, BiLSTM 的隐藏层可以学习并捕捉从 CNN 提取的局部特征的内部变化规律,并通过迭代过程从局部特征中提取出更复杂、更完整的全局特征,以提高信息的有效利用率。AM 可以区分来自 BiLSTM 隐藏层的时间序列信息的重要性,模型可以聚焦数据的关键部分,提取最深层的时间相关性。最后,全连接层提供最终预测结果。CEEMDAN-RIME-CNN-BiLSTM-AM 模型的框架如图 5 所示。具体步骤如下。

**步骤 1** 将海平面气压、温度、相对湿度、平均风等气象因素进行归一化处理。

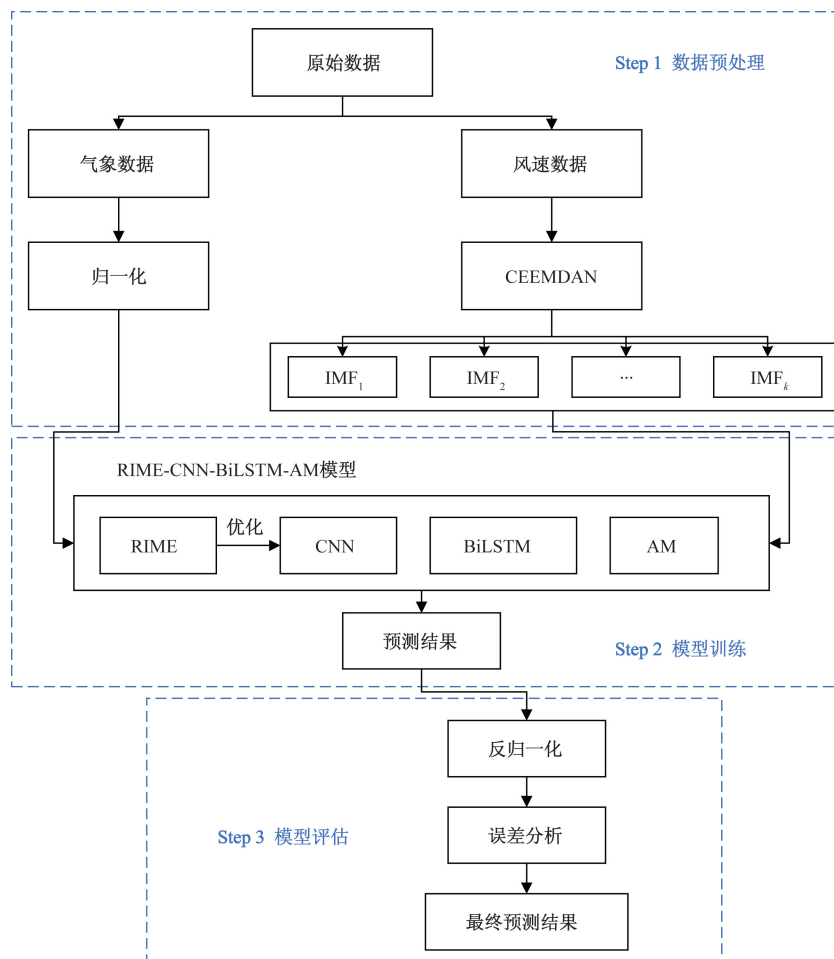


图5 模型预测框架

Fig. 5 Model prediction framework

**步骤 2** 采用 CEEMDAN 分解方法对风速数据进行分解,得到若干个分量,在保留风速原始特征的同时,最大限度地降低预测精度。

**步骤 3** 采用 RIME 优化算法对 CNN 的超参数进行优化,有效提取风速数据中的局部特征;构建 BiLSTM-AM 模型对处理后的数据进行预测。

**步骤 4** 将各子序列的预测结果进行叠加,得到最终的预测结果,并将此模型与其他模型进行对比分析,采用误差评估指标来衡量模型的预测精确度。

### 3 数据来源与数据处理

#### 3.1 数据来源

为验证模型的有效性和科学性,风速数据集来源于国家可再生能源实验室(National Renewable Energy Laboratory, NREL),采用美国科罗拉多州戈尔登地区 2023 年 10 月 1 日—12 月 31 日的风速数据集,采样间隔为 1h,数据包括温度(单位:℃)、相对湿度(单位:%)、海平面气压(单位:Pa)、平均风向[单位:(°)]、平均风速(单位:m/s)5 维数据,共 2 161 个数据。取 80% 的数据作为训练集,20% 的数据作为测试集,预测方法为单步滚动预测。

从图 6 和表 1 可以看出,风速变化无明显规律,最大风速为 27.385 m/s,最小风速仅为 0.189 m/s,风速变化范围较大,其无规律的变化使得对风速的预测变得较为困难。

由表 1 中原始风速序列的统计指标值可知,平均风速为 4.274 m/s,从风速数据的方差与标准差分析来看,其离散程度较高,表明风速具有较强的波动性和不稳定性特点。




图 6 原始风速数据图

Fig. 6 Plot of raw wind speed data

表 1 原始风速序列统计值

Table 1 Raw wind speed series statistics

统计指标	原始风速				
	最大值/ (m·s <sup>-1</sup> )	最小值/ (m·s <sup>-1</sup> )	均值/ (m·s <sup>-1</sup> )	方差	标准差
数值	27.385	0.189	4.274	10.896	3.301

#### 3.2 数据预处理

首先需要对原始风速数据进行 CEEMDAN 分解,将非平稳、非线性的风速数据分解成多个较为平稳的分量,提高风速预测精度。CEEMDAN 分解图如图 7 所示。

从图 7 可以看出,原始风速序列被分解为 8 个 IMF 模态分量和 1 个残差分量,将模态分量作为输入变量输入到预测模型中,可以有效地提取风速信号的重要信息,减小风速序列的随机波动性。然后,需要对气象因素进行归一化处理,归一化公式为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (21)$$

式(21)中: $x^*$ 为归一化后的数据; $x$ 为原始数据; $x_{\max}$ 为原始数据中的最大值; $x_{\min}$ 为原始数据中的最小值。




图 7 CEEMDAN 分解图

Fig. 7 CEEMDAN decomposition chart

### 3.3 实验环境及参数设置

本实验基于 Pytorch 框架实现,并且在 Python3.9、CPU 为 Intel(R) Core(TM) i5 13500H,显卡为 Intel Iris Xe Graphics,内存为 16 G 5200 MHz 的环境中进行训练和预测。

在模型训练过程中,各网络的参数对模型训练结果有很大影响结果。通过多次训练对比,BiLSTM 网络参数设置如下:隐藏层数目为 1,隐藏层神经元数目为 64,学习率为 0.003,最大迭代次数为 50。经过 RIME 优化之后的 CNN 结构为:卷积核的数量  $N$  为 3、卷积核的大小  $K$  为 10,批处理大小为 142,学习率为 0.05。具体 RIME-CNN 的超参数设置信息如表 2 所示。

表 2 RIME-CNN 超参数网络设置

Table 2 RIME-CNN hyperparameters network setup

超参数	取值
卷积和数量	3
卷积核大小	10
批处理大小	142
学习率	0.05

### 3.4 评价指标

为了有效比较和分析的预测模型,选取均方误差(mean squared error, MSE)、均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)、决定系数  $R^2$  作为模型的评价标准,评估本文模型及其他对比模型的预测性能。其中, MSE、RMSE、MAE 的结果越小,表示模型的预测误差越小,  $R^2$  越大,表示模型的精确度越高。这 4 项指标的计算公式分别为

$$MSE = \frac{1}{n} \sum_{i=1}^n |Y_i - Y'_i|^2 \quad (22)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |Y_i - Y'_i|^2} \quad (23)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - Y'_i| \quad (24)$$

$$R^2 = \frac{\left[ \sum_{i=1}^n (Y_i - \bar{Y}_i)(Y'_i - \bar{Y}') \right]^2}{\left[ \sum_{i=1}^n (Y_i - \bar{Y}_i)^2 \right] \left[ \sum_{i=1}^n (Y'_i - \bar{Y}')^2 \right]} \quad (25)$$

式中:  $n$  为样本数;  $Y_i$  为实际值;  $Y'_i$  为预测值,  $\bar{Y}_i$  为实际平均值;  $\bar{Y}'$  为预测平均值。

## 4 仿真实验

### 4.1 不同分解算法的对比

为了验证 CEEMDAN 在数据分解任务中的效

能,构建 CEEMDAN-RIME-CNN-BiLSTM-AM 模型,并将其预测性能与 EMD-RIME-CNN-BiLSTM-AM 及 EEMD-RIME-CNN-BiLSTM-AM 这两种不同的分解算法进行对比分析。图 8 展示了这 3 种分解模型所得预测结果的对比情况。

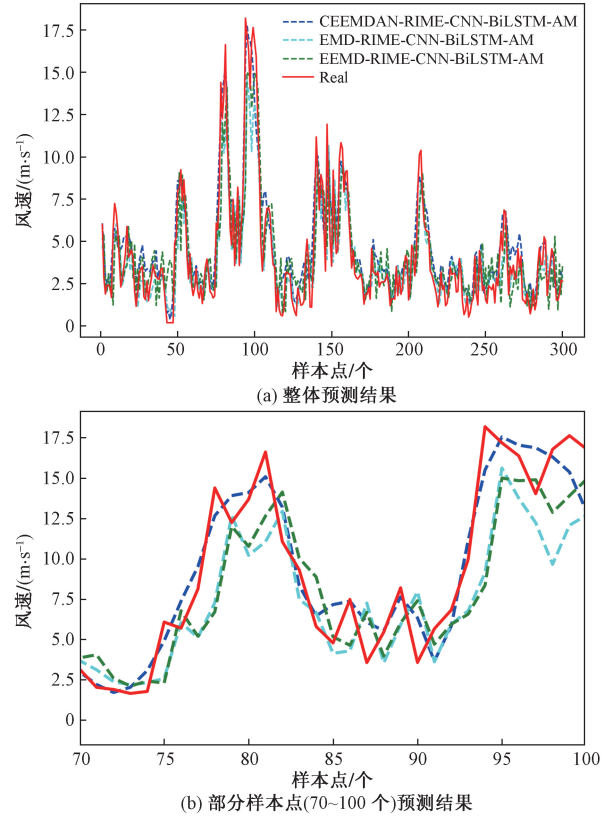


图 8 不同分解算法预测结果对比

Fig. 8 Comparison of the prediction results of different decomposition algorithms

从图 8 可以看出,与 EMD-RIME-CNN-BiLSTM-AM 和 EEMD-RIME-CNN-BiLSTM-AM 模型相比,本文模型预测性能最好,预测误差最小,说明 CEEMDAN 分解算法通过解决 EMD 和 EEMD 中存在的模态混叠现象以及它们残留的噪声问题,有效提升了预测的准确性。

### 4.2 不同优化算法的对比

为了评估 RIME 冰霜优化算法优异性,分别运用 GWO 和 WOA 对 CNN 的 4 个关键超参数进行了优化。随后,将这两种优化算法与所提出的 RIME 冰霜优化算法的预测性能进行了对比分析。图 9 展示了这 3 种不同优化算法所得模型的预测结果。

从图 9 可以看出,经过 GWO、WOA、RIME 算法优化后的预测模型都能够很好地拟合出风速的大致趋向,但相较于 GWO 和 WOA 算法,RIME 算法展现出更加优秀的预测效果。

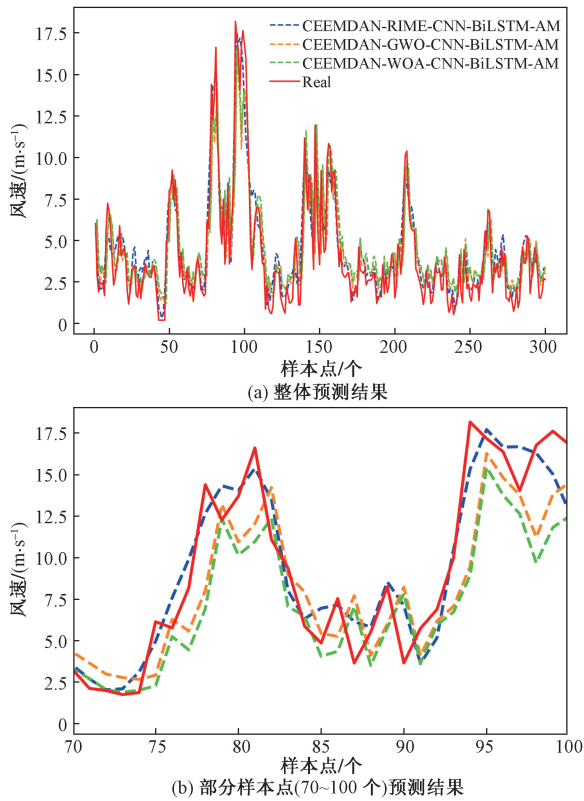


图9 不同优化算法预测结果对比

Fig. 9 Comparison of prediction results of different optimization algorithms

### 4.3 与其他模型的对比

为进一步验证所提模型 CEEMDAN-CNN-BiLSTM-AM 模型对风速预测的准确性, 将 BiLSTM、LSTM、BPNN 和 ELM 模型与其进行对比, 具体预测结果如图 10 所示。

从图 10 可以看出, 仅采用单一模型进行预测会受到数据观测视角局限性的影响。相比之下, CEEMDAN-RIME-CNN-BiLSTM-AM 组合模型在追踪风速变化趋势上表现更佳, 且细节上更接近实际值。通过对比部分样本点 (70 ~ 100) 的预测结果, 可以观察到样本点 70 ~ 75 属于风速平稳阶段, 在该阶段模型的预测性能普遍要优于风速剧烈变化阶段。与单一模型相比, CEEMDAN-RIME-CNN-BiLSTM-AM 组合模型在风速波动条件下仍保持了良好的预测效果, 这表明组合模型相较于单一模型更能适应复杂多变的气象条件, 不仅提升了预测精度, 还增强了模型的普遍适用性。

### 4.4 消融实验

为验证所提出组合模型的有效性, 将所提出模型 CEEMDAN-RIME-CNN-BiLSTM-AM 与 RIME-CNN-BiLSTM-AM、CNN-BiLSTM-AM、BiLSTM-AM 和 BiLSTM 模型进行对比, 预测结果如图 11 所示。

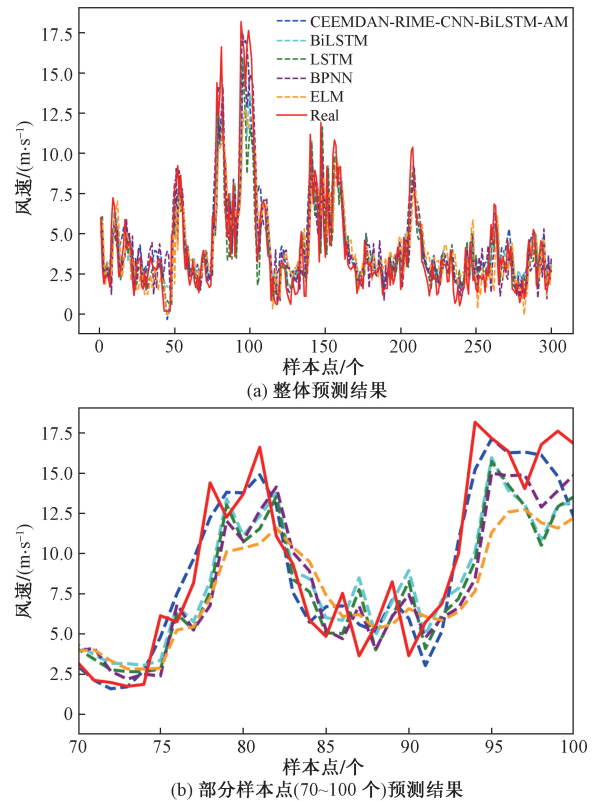


图10 与其他模型预测结果对比

Fig. 10 Comparison with other model predictions

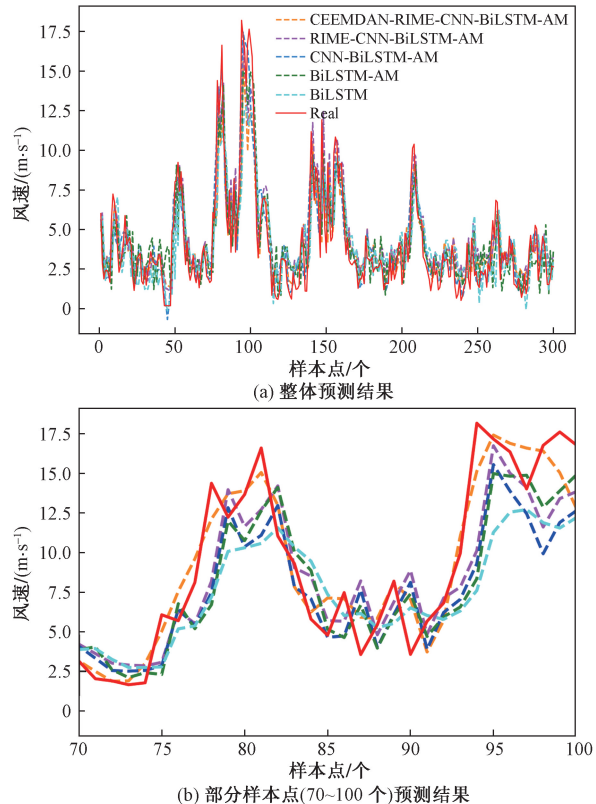


图11 消融实验预测结果对比

Fig. 11 Comparison of predicted results from ablation experiments

图 11 为 CEEMDAN-RIME-CNN-BiLSTM-AM、RIME-CNN-BiLSTM-AM、CNN-BiLSTM-AM、BiLSTM-AM 和 BiLSTM 模型的预测图,可以看出,5 种模型都能够大致拟合出风速的大致趋向,但 RIME-CNN-BiLSTM-AM、CNN-BiLSTM-AM、BiLSTM-AM 和 BiLSTM 模型在波峰与波谷区域的预测效果不是很理想,CEEMDAN-RIME-CNN-BiLSTM-AM 模型无论在波峰还是波谷区域都能很好地捕捉到风速的变化规律,能更好地拟合出真实值,预测误差更小。

#### 4.5 各模型预测误差分析

为了更准确地展示各模型的预测性能,采用 MSE、RMSE、MAE 和  $R^2$  评价指标来表示各模型误差值,各模型预测误差评价指标值如表 3 和图 12 所示。

表 3 各模型评价指标值

模型	MSE	RMSE	MAE	$R^2$
Model1:ELM	4.726	2.174	2.428	0.774
Model2:BPNN	4.425	2.104	2.357	0.795
Model3:LSTM	3.956	1.989	2.185	0.816
Model4:BiLSTM	3.639	1.907	2.037	0.859
Model5:BiLSTM-AM	3.472	1.863	1.839	0.905
Model6:CNN-BiLSTM-AM	3.425	1.851	1.769	0.913
Model7:RIME-CNN-BiLSTM-AM	2.957	1.719	1.539	0.929
Model8:EMD-RIME-CNN-BiLSTM-AM	2.472	1.572	1.409	0.936
Model9:EEMD-RIME-CNN-BiLSTM-AM	2.057	1.434	1.339	0.948
Model10:CEEMDAN-WOA-CNN-BiLSTM-AM	1.992	1.412	1.013	0.962
Model11:CEEMDAN-GWO-CNN-BiLSTM-AM	1.726	1.314	0.968	0.969
Model12:CEEMDAN-RIME-CNN-BiLSTM-AM	1.384	1.176	0.888	0.981




图 12 模型预测误差图

Fig. 12 Model prediction error plot

由表 3、图 12 可知,相较于 BiLSTM 模型,BiLSTM-AM模型通过引入注意力机制,实现了对输入信息权重的差异化分配,使关键信息获得更大权重,减少了冗余信息的干扰,使得 MSE 下降了 4.589%,RMSE 降低了 2.307%,MAE 减少了 9.720%, $R^2$  提升了 5.355%,这表明引入注意力机制的有效性。与 BiLSTM-AM 模型相比,CNN-BiLSTM-AM 模型有效捕捉了风速数据中的局部特征,进一步降低了预测误差,MSE 下降了 1.354%,RMSE 减少了 0.644%,MAE 下降了 3.801%, $R^2$  增加了 0.884%。相较于 CNN-BiLSTM-AM 模型,采用 RIME 算法优化 CNN 超参数的 RIME-CNN-BiLSTM-AM 模型展现出了更好的预测性能,MSE 降低了 13.664%,RMSE 减少了 7.131%,MAE 下降了 13.001%, $R^2$  增加了 1.752%,这充分说明了 RIME 算法在提高预测精度方面的优势。

相较于 EMD-RIME-CNN-BiLSTM-AM 与 EEMD-RIME-CNN-BiLSTM-AM 模型,CEEMDAN-RIME-CNN-BiLSTM-AM 模型展现出更优的预测性能,这证明了 CEEMDAN 在数据分解方面中的显著优势。

CEEMDAM-RIME-CNN-BiLSTM-AM 模型的 MSE 为 1.384, RMSE 为 1.176, MAE 为 0.888,  $R^2$  为 0.981,相较于 BiLSTM、LSTM、BPNN、ELM 模型, MSE 降低了 61.968%、65.014%、68.724% 和 70.715%;RMSE 分别下降了 38.332%、40.873%、44.093% 和 45.906%;MAE 分别下降 56.406%、59.359%、62.325% 和 63.427%; $R^2$  分别增长 14.203%、20.221%、23.396% 和 26.744%。这说明所提模型相较于其他单一模型有更高的预测精度和模型通用性。

#### 4.6 多步预测实验

为了验证本文方法的稳健性和普遍适用性,在单步预测的基础上拓展了多步预测实验,多部预测实验能够更好地反映出模型对时序信息更深层次的挖掘能力。该实验重点实施了两步及三步预测,相关的评价指标结果如表 4 和图 13 所示。

由表 4、图 13 的对比结果可知,随着预测步数的增加,预测误差呈现逐步上升的趋势,原因在于随时间推进,风速分量与历史数据间的关联性减弱,导致有效的时序特征难以被有效捕捉,从而使多步预测相较于单步预测更具挑战性。在多步预测实验中,所提出的模型依然展现出卓越的性能,各项评估指标均优于其他模型,这表明 CEEMDAN-RIME-CNN-BiLSTM-AM 模型具备高度的稳健性。

表 4 多步预测评价指标值

Table 4 Multi-step prediction evaluation indicator values

步长	模型	MSE	RMSE	MAE	R <sup>2</sup>
2 步	Model1; ELM	5.839	2.416	3.426	0.725
	Model2; BPNN	5.025	2.242	3.272	0.756
	Model3; LSTM	4.792	2.189	2.845	0.774
	Model4; BiLSTM	4.425	2.104	2.579	0.784
	Model5; BiLSTM-AM	3.886	1.971	2.451	0.793
	Model6; CNN-BiLSTM-AM	3.834	1.958	2.280	0.802
	Model7; RIME-CNN-BiLSTM-AM	3.431	1.853	1.918	0.826
	Model8; EMD-RIME-CNN-BiLSTM-AM	3.410	1.847	1.703	0.841
	Model9; EEMD-RIME-CNN-BiLSTM-AM	3.267	1.808	1.566	0.873
	Model10; CEEMDAN-WOA-CNN-BiLSTM-AM	3.202	1.789	1.439	0.896
	Model11; CEEMDAN-GWO-CNN-BiLSTM-AM	3.024	1.739	1.380	0.917
	Model12; CEEMDAN-RIME-CNN-BiLSTM-AM	2.305	1.518	1.328	0.935
3 步	Model1; ELM	7.629	2.762	4.357	0.611
	Model2; BPNN	7.285	2.699	4.026	0.694
	Model3; LSTM	6.926	2.632	3.878	0.717
	Model4; BiLSTM	6.602	2.569	3.731	0.732
	Model5; BiLSTM-AM	6.343	2.519	3.638	0.756
	Model6; CNN-BiLSTM-AM	6.174	2.485	3.343	0.762
	Model7; RIME-CNN-BiLSTM-AM	5.782	2.405	2.781	0.799
	Model8; EMD-RIME-CNN-BiLSTM-AM	5.508	2.347	2.697	0.818
	Model9; EEMD-RIME-CNN-BiLSTM-AM	4.526	2.127	2.523	0.827
	Model10; CEEMDAN-WOA-CNN-BiLSTM-AM	3.472	1.863	2.462	0.845
	Model11; CEEMDAN-GWO-CNN-BiLSTM-AM	3.239	1.799	2.409	0.853
	Model12; CEEMDAN-RIME-CNN-BiLSTM-AM	3.116	1.765	2.301	0.874

综上所述, 无论是进行单步预测还是多步预测, 将信号分解技术与深度学习相结合的方法都能高效地模拟风速的波动特性, 从而弥补单一预测算法的局限性, 进而提升模型的预测精确度。

### 5 结论

提出一种基于 CEEMDAN-RIME-CNN-BiLSTM-AM 的短期风速预测方法。通过仿真实验分析, 得出以下结论。

(1) 针对波动性强且具有随机性风速数据预测的难题, 采用了 CEEMDAN 算法对原始风速数据进





图 13 模型多步预测误差图

Fig. 13 Model multi-step prediction error plot

行分解处理, 以获得更为平稳的分量, 这一方法能够高效地提取风速信号中的关键信息, 显著降低风速序列的随机波动性。相较于传统的 EMD 和 EEMD 算法, CEEMDAN 算法在解决模态混叠现象及减少噪声残差方面展现出了更优的性能。

(2) 通过霜冰优化算法 RIME 自动寻找 CNN 模型超参数的最佳组合, 减少手动调参的繁琐过程, 从而提高了模型的预测精度, 使模型的性能达到最优。

(3) 采用单步以及多步实验对不同模型展开多组实验, 实验结果表明, 所提出的组合模型均呈现出优异的预测性能。

### 参 考 文 献

[1] 刘向龙, 蔡文斌, 于源, 等. 基于系统调度成本和储能经济收益规划的“源-网-储”协同互动优化调度策略[J]. 科学技术与工程, 2024, 24(35): 15065-15073.  
Liu Xianglong, Cai Wenbin, Yu Yuan, et al. “Source-network-storage” collaborative and interactive optimal dispatch strategy based on system dispatch cost and energy storage economic benefit objectives[J]. Science Technology and Engineering, 2024, 24(35):

- 15065-15073.
- [2] 郑晓亮, 杨晓亮, 来文豪. 新能源发电预测方法分类及研究进展[J]. 科学技术与工程, 2024, 24(34): 14503-14521.  
Zheng Xiaoliang, Yang Xiaoliang, Lai Wenhao. Classification and research progress of new energy power generation forecasting methods[J]. Science Technology and Engineering, 2024, 24(34): 14503-14521.
- [3] Wang H, Han S, Liu Y, et al. Sequence transfer correction algorithm for numerical weather prediction wind speed and its application in a wind power forecasting system[J]. Applied Energy, 2019, 237: 1-10.
- [4] 张金良, 刘子毅. 基于混合模型的超短期风速区间预测[J]. 电力系统保护与控制, 2022, 50(22): 49-58.  
Zhang Jinliang, Liu Ziyi. Ultra short term wind speed interval prediction based on a hybrid model[J]. Power System Protection and Control, 2022, 50(22): 49-58.
- [5] 蒋金良, 林广明. 基于 ARIMA 模型的自动站风速预测[J]. 控制理论与应用, 2008(2): 374-376.  
Jiang Jinliang, Lin Guangming. Automatic station wind speed forecasting based on ARIMA model[J]. Control Theory & Applications, 2008(2): 374-376.
- [6] 余泳涛, 张扬. 基于改进 Logistic 模型法的配电网负荷预测[J]. 南昌大学学报(工科版), 2022, 44(2): 200-204.  
Yu Yongtao, Zhang Yang. Distribution network load forecasting based on PSO-Logistic model method[J]. Journal of Nanchang University(Engineering & Technology), 2022, 44(2): 200-204.
- [7] Wu C Y, Wang J Z, Chen X J, et al. A novel hybrid system based on multi-objective optimization for wind speed forecasting[J]. Renewable Energy, 2020, 146: 149-165.
- [8] Ibrahim I A, Hossain M J, Duck B C. An optimized offline random forests based model for ultra-short-term prediction of PV characteristics[J]. IEEE Transactions on Industrial Informatics, 2019, 16(1): 202-214.
- [9] 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 Yuxuan, Liu Erjia, Huang Yongzhang. An ultra-short-term wind power prediction method based on CNN-LSTM-lightGBM combination[J]. Science Technology and Engineering, 2022, 22(36): 16067-16074.
- [10] Dong Y X, Wang J, Xiao L, et al. Short-term wind speed time series forecasting based on a hybrid method with multiple objective optimization for non-convex target[J]. Energy, 2021, 215: 119180.
- [11] 向玲, 李京蓄, 王朋鹤, 等. 基于 VMD-FIG 和参数优化 GRU 的风速多步区间预测[J]. 太阳能学报, 2021, 42(10): 237-242.  
Xiang Ling, Li Jingxu, Wang Penghe, et al. Wind speed multi-step interval forecasting based on VMD-FIG and parameter optimized GRU[J]. Acta Energetica Solaris Sinica, 2021, 42(10): 237-242.
- [12] 朱彦民, 李忠虎, 杨立清, 等. 基于卷积双向长短时记忆模型的风电机组故障预测[J]. 科学技术与工程, 2024, 24(25): 10790-10797.  
Zhu Yanmin, Li Zhonghu, Yang Liqing, et al. Fault prediction of wind turbine based on convolutional bidirectional long short term memory model[J]. Science Technology and Engineering, 2024, 24(25): 10790-10797.
- [13] 毕贵红, 黄泽, 赵四洪, 等. 基于混合分解和 PCG-BiLSTM 的风速短期预测[J]. 太阳能学报, 2024, 45(1): 159-170.  
Bi Guihong, Huang Ze, Zhao Sihong, et al. Short-term prediction of wind speed based on hybrid decomposition and PCG-BiLSTM[J]. Acta Energetica Solaris Sinica, 2024, 45(1): 159-170.
- [14] 沈建良, 来骏, 张翼, 等. 基于 ACMD 和 BiGRU-Attention 的负荷预测模型研究[J]. 浙江电力, 2023, 42(6): 70-77.  
Shen Jianliang, Lai Jun, Zhang Yi, et al. Research on a load forecasting model based on ACMD and BiGRU-Attention[J]. Zhejiang Electric Power, 2023, 42(6): 70-77.
- [15] 段雪滢, 李小腾, 陈文洁. 基于改进粒子群优化算法的 VMD-GRU 短期电力负荷预测[J]. 电工电能新技术, 2022, 41(5): 8-17.  
Duan Xueying, Li Xiaoteng, Chen Wenjie. Improved particles swarm optimization algorithm-based VMD-GRU method for short-term load forecasting[J]. Advanced Technology of Electrical Engineering and Energy, 2022, 41(5): 8-17.
- [16] 王贺, 陈蔚峰, 熊敏, 等. 融合 CEEMDAN 和 ICS-LSTM 的短期风速预测建模[J]. 电子测量与仪器学报, 2022, 36(4): 17-23.  
Wang He, Chen Hongfeng, Xiong Min, et al. Short-term wind speed forecasting modeling integrating CEEMDAN and ICS-LSTM[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(4): 17-23.
- [17] 刘可真, 阮俊泉, 赵现平, 等. 基于麻雀搜索优化的 Attention-GRU 短期负荷预测方法[J]. 电力系统及其自动化学报, 2022, 34(4): 99-106.  
Liu Kezhen, Ruan Junxiao, Zhao Xianping, et al. Short-term load forecasting method based on sparrow search optimized Attention-GRU[J]. Proceedings of the CSU-EPSA, 2022, 34(4): 99-106.
- [18] 程杰, 陈鼎, 李春, 等. 基于 GWO-CNN-BiLSTM 的超短期风电预测[J]. 科学技术与工程, 2023, 23(35): 15091-15099.  
Cheng Jie, Chen Ding, Li Chun, et al. Ultra-short-term wind power prediction based on GWO-CNN-BiLSTM[J]. Science Technology and Engineering, 2023, 23(35): 15091-15099.
- [19] 韩宏志, 唐振浩. 基于 CEEMDAN 与回声状态网络的风速预测方法[J]. 电力系统保护与控制, 2020, 48(12): 90-96.  
Han Hongzhi, Tang Zhenhao. Wind speed prediction method based on CEEMDAN and echo state network[J]. Power System Protection and Control, 2020, 48(12): 90-96.
- [20] Su H, Zhao D, Heidari A A, et al. RIME: A physics-based optimization[J]. Neurocomputing, 2023, 532: 183-214.
- [21] Li K, Mu Y, Yang F, et al. A novel short-term multi-energy load forecasting method for integrated energy system based on feature separation-fusion technology and improved CNN[J]. Applied Energy, 2023, 351: 121823.
- [22] Zhang D, Chen B, Zhu H, et al. Short-term wind power prediction based on two-layer decomposition and BiTCN-BiLSTM-attention model[J]. Energy, 2023, 285: 128762.
- [23] 彭华, 王文超, 朱永利, 等. 基于 LSTM 神经网络的风电场集电线路单相接地智能测距[J]. 电力系统保护与控制, 2021, 49(16): 60-66.  
Peng Hua, Wang Wenchao, Zhu Yongli, et al. An intelligent single-phase grounding fault location for a wind farm collection line

- based on an LSTM neural network [J]. *Power System Protection and Control*, 2021, 49(16): 60-66.
- [24] Mnih V, Heess N, Graves A. Recurrent models of visual attention [J]. *Advances in Neural Information Processing Systems*, 2014, 27: DOI: 10.48550/arXiv.1406.6247.
- [25] 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 Guoqing, Liu Shilin, Wang Deyi et al. Short-term wind power forecasting based on Attention-GRU wind speed correction and Stacking[J]. *Acta Energetica Solaris Sinica*, 2022, 43(12): 273-281.