



DOI:10.12404/j.issn.1671-1815.2402025

引用格式:魏振宇,姜雪松,杨立发.基于误差补偿及 IDBO-BiLSTM 的风电功率短期预测[J].科学技术与工程,2025,25(6):2397-2405.

Wei Zhenyu, Jiang Xuesong, Yang Lifa. Short term prediction of wind power based on error compensation and IDBO-BiLSTM[J]. Science Technology and Engineering, 2025, 25(6): 2397-2405.

基于误差补偿及 IDBO-BiLSTM 的风电功率短期预测

魏振宇¹, 姜雪松^{1*}, 杨立发²

(1. 东北林业大学机电工程学院, 哈尔滨 150040; 2. 中国船舶集团有限公司第七〇三研究所, 哈尔滨 150783)

摘 要 针对风电出力稳定性差、随机性强而导致的模型精度差的问题。提出了一种基于二次分解误差补偿的风电功率短期预测模型。首先建立双向长短期记忆(bidirectional long short-term memory, BiLSTM)预测模型对风电功率进行预测并输出预测误差。其次,采用了一种利用混沌映射初始化种群、引入黄金正弦策略更新滚球蛱蝶位置,并添加动态自适应权重系数来更新偷窃蛱蝶的位置的改进蛱蝶优化算法(improved dung beetle optimizer, IDBO)对预测模型参数寻优,防止网络陷入局部最优解,自适应搜寻最优参数组合。然后,采用分解-重构-分解的策略,利用自适应噪声的完全集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)进行首次分解,并且引入样本熵(sample entropy, SE)与K均值(K-means)将序列按频率进行重构并通过变分模态分解(variational mode decomposition, VMD)将高频误差序列分解成不同频段的误差序列,提高后续模型的预测效率及预测精度。最后,将各分量输入误差补偿模型进行预测并引入 Attention 机制学习不同时间步的特征关系,并给与不同权重值,加强对关键信息的注意力。通过新疆达坂城风电场实测数据验证了所提模型预测精度高,具有显著优势。

关键词 风电功率短期预测;双向长短期记忆网络;改进蛱蝶优化算法;完全集合经验模态分解;变分模态分解

中图分类号 TP183 TM614; **文献标志码** A

Short Term Prediction of Wind Power Based on Error Compensation and IDBO-BiLSTM

WEI Zhen-yu¹, JIANG Xue-song^{1*}, YANG Li-fa²

(1. College of Mechanical and Electrical Engineering, Northeast Forestry University, Harbin 150040, China;

2. 703 Research Institute, China State Shipbuilding Corporation, Harbin 150783, China)

[Abstract] Aiming at the problem of poor model accuracy caused by poor stability and strong randomness of wind power output. A short-term prediction model of wind power based on quadratic decomposition error compensation was proposed. Firstly, BiLSTM (bidirectional long short-term memory) prediction model is established to predict wind power and output prediction errors. Secondly, an IDBO (improved dung beetle optimizer) algorithm was used to initialize the population by using chaotic mapping, update the position of rolling dung beetles by introducing golden sine strategy, and update the position of thieving dung beetles by adding dynamic adaptive weight coefficient to optimize the parameters of the prediction model. Prevent the network from falling into the local optimal solution, and adaptively search the optimal parameter combination. Then, using the decomposition-reconstruction-decomposition strategy, CEEMDAN (complete ensemble empirical mode decomposition with adaptive noise) was used for the first decomposition. In addition, SE (sample entropy) and K-means are introduced to reconstruct the sequence according to frequency, and the high-frequency error sequence was decomposed into error sequences of different frequency bands by VMD (variational mode decomposition). Improve the prediction efficiency and accuracy of subsequent models. Finally, the input error compensation model of each component was used to predict and the Attention mechanism was introduced to learn the feature relationship of different time steps and give different weight values to enhance the attention to key information. Through the measured data of a wind farm in Xinjiang, the prediction accuracy of the proposed model is proved to be high and has significant advantages.

[Keywords] wind power short-term forecast; bidirectional long short-term memory network; improved dung beetle optimization algorithm; complete ensemble empirical mode decomposition; variational mode decomposition

收稿日期: 2024-03-24; 修订日期: 2024-12-10

基金项目: 黑龙江省自然科学基金(LH2019E001)

第一作者: 魏振宇(2000—),男,汉族,山东济宁人,硕士研究生。研究方向:短期风电功率预测。E-mail:1634945056@qq.com。

* 通信作者: 姜雪松(1979—),男,汉族,黑龙江佳木斯人,博士,副教授。研究方向:工业工程与管理、智能制造工艺与装备。E-mail:xuesongjiang@nefu.edu.cn。

投稿网址:www.stae.com.cn

风能是目前应用最广泛的可再生能源之一,其在能源系统中的比重不断提高。然而实际生活中风力发电过程却因为风力的随机性而带来很大的不确定性^[1],并且风电功率的大小也受风速外的气压、温度、湿度、风向等因素的影响,这加剧了风电功率预测的不稳定性。风力发电预测稳定性差、随机性强的特性对电网的调度和储能能力形成巨大考验^[2],因此,迫切地需要提升风电功率预测精度,以最大程度地减轻风电波动所带来的挑战。

早期的风电功率预测主要采用人工神经网络、支持向量机^[3-4]和极端梯度增强算法(extreme gradient boosting, xgboost)等,但这些模型无法感受与记忆输入时间有关的时序特征,导致预测精度有限。随着深度学习发展,长短期记忆神经网络(long short-term memory, LSTM),时序卷积网络(convolutional neural networks, CNN),自注意力模型(transformer)等深度神经网络被广泛用于风电功率的预测问题。然而深度学习模型经常面临无法有效地关注时间序列的关键信息的问题。文献[5]提出一种基于 Attention-GRU 的数值天气预报风速修正和 Stacking 多算法融合预测模型,考虑多种气象因素,并通过 Attention 机制分配关键因素权重,提高计算效率,有效地提高了预测精度。文献[6]通过设计多层语义结合的注意力机制加强对特征向量的编码能力,并使用分位数回归和核密度估计方法处理模型输出。文献[7-9]分别通过灰狼优化算法、遗传算法、改进粒子群优化算法对预测模型进行改进,优化了参数的选取,提高了预测精度。上述模型仅通过组合深度学习模型进行风电功率预测,挖掘特征信息,提高了预测精度,并且结合了优化算法寻找模型最优超参数,提高了运算效率。但上述模型却没有考虑到风电功率预测稳定性差、随机性强的问题。文献[10]为了降低时间序列的非稳定特征,将原始数据输入变分模态分解(variational mode decomposition, VMD)进行分解,然后使用权值共享门控循环单元(weight sharing gate recurrent unit, WSGRU)对所有子分量进行快速建模预测。同样的,文献[11]提出了算术优化算法(improved arithmetic optimization algorithm, IAOA)-变分模态分解 VMD-LSTM 预测模型。利用 IAOA 对 VMD 的关键分解参数进行优化,有效提高了预测效率和预测精度。文献[12]通过完全经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)排列熵(permutation entropy, PE)、小波包分解(wavelet packet decomposition, WPD)对信号进行处理,然后输入 LSTM 神经网络,并建立多目标优化损失函数,综合提升模型的预测性能。

利用深度学习的方法预测风电功率,不可避免地会造成预测误差^[13]。同时如果能从预测误差中建立起误差与风电功率的关联网络,挖掘其内在联系,便能更进一步地提高风电功率预测的精度。然而上述研究只关注了对深度学习模型的改进和对气象特征的提取,却忽视了预测误差所带来的潜在价值。

综上所述,现提出一种基于二次分解误差补偿的风电功率短期预测模型。首先利用 IDBO-BiLSTM 模型对风电功率进行初步预测,随后输出预测功率与实际功率之间的误差值作为误差补偿模型的训练数据。最后,叠加误差补偿数据和初步预测功率数据作为最终预测功率,以提升预测精度。考虑到风力发电具有稳定性差、随机性强的特征,简单地输入误差信息进行预测对精度的提升效果有限,因此在误差补偿之前加入自适应白噪声完备集成经验模态分解法和变分模态分解降低序列的不稳定性,并在误差补偿模型中引入注意力机制加强对关键信息的注意力。基于此,以新疆达坂城风电场功率实测数据为研究对象,构建一种基于二次分解误差补偿的风电功率短期预测模型,并进行仿真验证所提模型预测可行性与有效性。

1 模型原理及预测具体流程

1.1 误差补偿模型的原理

对于一个特定的深度学习网络,其内部的运算原理、随机数种子、各个模块结构、参数权重等皆是定值。使用同样的样本数据多次预测,其结果始终相同。同样的,通过相同模型进行预测,所造成的预测误差也必然遵守模型的运算规则。因此,将初步预测功率所得到的预测误差再次投入深度学习网络进行训练,使模型建立起误差与用于功率预测的气象特征、功率数据与误差之间的结构关系网络,实现对误差的精准预测,从而提升风功率的预测精度。

1.2 风电功率短期预测的具体流程

风功率由于其强随机性和非平稳性,导致其预测精度一直较低,为提升功率预测精度,本文研究提出一种基于二次分解误差补偿的风电功率短期预测模型。具体流程如下。

(1)首先将输入预测模型的数据进行预处理,利用 IDBO-LSTM 预测模型对风功率进行快速的初步预测,并对比实际功率,得到风功率的初步预测误差。

(2)利用 CEEMDAN 将初步预测误差分解为多组模态分量,并计算各分量的样本熵,通过 K-means 聚类算法将分量进行重构。

(3)选出重构后的高频分量,利用 VMD 将高频预测误差序列分解为一组子分量。

(4)将各分量、气象特征、风功率输入 BiLSTM-AT-

TENTION 预测模型。得到各分量风功率预测误差值

(5)将误差值与风功率初步预测功率值进行整合,作为最终风功率预测值。

(6)对预测结果进行评价,分析模型性能
风功率预测流程图如图 1 所示。





图 1 风电功率短期预测的具体流程

Fig. 1 Specific process of short-term prediction of wind power

2 预测模型结构

2.1 双向长短期记忆网络 (BiLSTM)

BiLSTM 神经网络结构是由 2 个相互独立的 LSTM 神经网络组成,它同时考虑了过去和未来的信息,可以通过向前向和向后向两个方向传播。这使得 BiLSTM 网络不仅能捕捉过去的信息,还能预知未来的信息,通过双向处理序列信息加强了捕捉长期依赖关系的能力,从而在处理时间序列问题上有更好的表现。LSTM 模型内部结构如图 2 所示。



$C(t)$ 和 $C(t-1)$ 分别为 t 时刻更新后的新细胞状态与上一时刻的细胞状态; $H(t)$ 和 $H(t-1)$ 分别为 t 时刻隐藏状态与上一时刻的隐藏状态

图 2 LSTM 模型内部结构

Fig. 2 Internal structure of LSTM model

LSTM 模型单元的完整传播公式为

$$f = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\dot{C}_t = \text{Relu}(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t C_{t-1} + i_t C_t \quad (4)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t \text{Relu}(C_t) \quad (6)$$

式中: f_t 为遗忘门; i_t 为输入门; o_t 为输出门; σ 和 ReLU 分别为 Sigmoid 函数和 ReLU 激活函数; W_f 、 W_i 、 W_c 、 W_o 分别为各式的权重矩阵; b_f 、 b_i 、 b_c 、 b_o 分别为各式的偏置向量; x_t 为当前模型输入信息; $\dot{C}_t$ 和 C_t 分别为隐藏层生成 t 时刻记忆单元的临时状态和新细胞状态; h_t 隐藏层最终输出值。

LSTM 网络相比传统神经网络,能够捕捉数据中的长期依赖性、通过门控机制解决可能会遇到的梯度消失与梯度爆炸问题,同时 LSTM 特殊的细胞状态能够选择性的动态处理信息。BiLSTM 网络增加了对前后信息处理的能力,能充分挖掘数据中的有用信息,在预测任务中具有出色的表现。

2.2 注意力机制

Attention 机制能够在计算能力有限的情况下将资源分配给优先级更高的任务,从而提升模型的精度。在本文研究中,将注意力机制引入 LSTM 模型的输出上,使用注意力层来计算输入序列中每个时间步的权重,然后将这些权重应用于 LSTM 输出序列中的每个时间步来产生一个加权的表示。Attention 机制的引入使得模型在信息处理过程中优先关注权重占比较大的信息,提高了信息处理效率,同时提升了结果的准确性。Attention 机制结构如图 3 所示。

Attention 机制计算公式为

$$S_i = F(Q, K_i) \quad (7)$$

$$a_i = \text{softmax}(S_i) = \frac{e^{S_i}}{\sum_{j=1}^N e^{S_j}} \quad (8)$$

$$\text{Attention}[(K, V)Q] = \sum_{i=1}^n a_i h_i \quad (9)$$




图 3 Attention 机制结构图

Fig. 3 Attention mechanism structure diagram

式中: Q 为查询; K 为键; V 为值; N 为数据长度; S_i 为每个隐藏层的得分; a_i 为权重系数; h_i 为 BiLSTM 隐藏层输入值; Attention 为最终所求的注意力值。

2.3 改进蜣螂算法

蜣螂优化算法是一种新型的仿生智能优化算法^[14],通过模仿蜣螂滚球、跳舞、觅食、繁殖和偷窃等行为,可有效解决复杂的优化搜索问题。蜣螂优化算法相较于其他仿生算法,具有更强的全局搜索能力。但同时,DBO 算法也会与其他寻优算法一样容易陷入局部最优解,而无法做到全局搜索。为了减少搜索的复杂性、加快算法收敛速度,同时提升全局搜索能力和跳出局部最优的能力,提出一种 IDBO 算法。首先引入 Chebyshev 映射,帮助改善种群的分布。同时,使用黄金正弦策略对滚球蜣螂进行位置更新。最后,增加动态权重系数调整窃取蜣螂位置。IDBO 算法加快了收敛速度、增强了算法跳出局部最优能力,并且平衡全局搜索能力和局部开发的能力。

2.3.1 Chebyshev 映射

在基础 DBO 优化算法中采用的是随机种群初始化,会造成种群多样性不足、种群分布不均的情况,针对这种情况,本文模型采用 Chebyshev 混沌映射的种群初始化的方法。通过 Chebyshev 混沌映射使得初始种群分布得更加均衡,从而提高算法全局搜索效果。Chebyshev 混沌映射的公式为

$$x_{n+1} = \cos(k \arccos x_n), \quad x \in [-1, 1] \quad (10)$$

式(10)中: k 为阶次。

2.3.2 黄金正弦策略

黄金正弦算法(Golden-SA)是一种新型的元启发式算法^[15]。该算法利用正弦函数与单位圆的关系,能够遍历正弦函数上的所有点,应用在蜣螂滚球行为中,能够有效提高 DBO 算法的全局搜索能力。同时,在蜣螂滚球更新位置过程中引入黄金分割系数,充分搜索产生优质解的局部区域,从而有助于 DBO 算法跳出局部最优,快速收敛。位置更新公式为

$$\begin{cases} x_1 = -\pi + (1 - \tau)2\pi \\ x_2 = -\pi + \tau 2\pi \\ X_i(t+1) = X_i(t) | \sin R_1 | + \\ R_2 \sin R_1 | x_1 X_i^b - x_2 X_i | \end{cases} \quad (11)$$

式(11)中: τ 为黄金分割系数; X_i 为第 i 只滚球蜣螂的位置信息; t 为迭代次数; X^b 为最优位置; R_1 为一个介于 $0 \sim 2\pi$ 的随机数; R_2 为一个介于 $0 \sim \pi$ 的随机数。

2.3.3 偷窃蜣螂位置更新动态权重

DBO 算法中部分蜣螂会偷窃其他蜣螂的粪球,在这个过程中偷窃蜣螂会向其他蜣螂传递自身所获得的信息,方便其他蜣螂更快地收敛到更优解附近。通过引入自适应动态权重系数改进其位置,从

而使得算法更有可能发现全局最优解,并且蜣螂之间的信息传递与共享也使得整个群体更快地搜索全局,提高算法的全局搜索能力。本文模型窃取蜣螂位置更新公式为

$$\begin{cases} X_i(t+1) = \\ \frac{w_1 X^b + w_2 \mathbf{g} [|x_i(t) - X^*| + |x_i(t) - X^b|]}{2} \\ w_1 = 2e^{-(2t/T)} \\ w_2 = 2e^{-[2(T-t)/T]} \end{cases} \quad (12)$$

式(12)中: $X(t)$ 为第 i 只偷窃蜣螂在第 t 次迭代时的位置信息; $\mathbf{g}$ 表示服从正态分布的大小为 $1 \times D$ 的随机向量; T 为最大迭代次数。

固定的位置更新权重系数并不利于找寻全局最优解。在搜索初期, w_1 较大,蜣螂会在最优蜣螂附近进行搜索。随着迭代的不断进行,这时 w_2 的影响力逐渐大于 w_1 ,蜣螂这时会跳出局部最优,一定程度上解决了算法局部开发与全局探索不平衡的问题。

2.4 基于 IDBO 的参数优化

神经网络预测模型的精度主要受学习率、隐藏层的神经元数量、迭代次数等参数的影响。为进一步提升预测模型的精度,克服神经网络参数难以调整的问题,选用 IDBO 为预测模型进行参数寻优。BiLSTM 激活函数为 Relu, Dropout 层选取 0.2,迭代次数为 70 次。并且采用 LearningRateScheduler 调度器动态调整学习率。优化目标包括隐藏层的神经元数量、样本批量以及预测模型学习率。

IDBO 优化 BiLSTM-ATTENTION 模型的具体优化过程流程如下:①通过混沌映射初始化蜣螂种群;②初始 BiLSTM 参数并设置参数寻优区间;③计算当前所有蜣螂的适应度值;④更新所有蜣螂的位置;⑤每次迭代后重新计算蜣螂的适应度,引入动态学习因子,随着迭代的进行,自适应调整蜣螂位置;⑥判断是否满足最大迭代,若满足,则输出神经网络超参数,否则返回 3 继续迭代。

改进蜣螂算法寻优区间如表 1 所示。

表 1 参数优化区间
Table 1 Parameter optimization interval

超参数	寻优区间
第一层神经元数量	[32, 128]
第二层神经元数量	[32, 128]
学习率	[0.001, 0.01]
样本批量	[20, 60]

3 基于二次分解的误差补偿预测

3.1 CEEMDAN 分解

CEEMDAN 是 EEMD 的改进模型,通过向经验

模态分解 EMD(empirical mode decomposition), 分解后产生的 IMF 本征模态函数(intrinsic mode function, IMF)分量中加入自适应噪声使分解结果更加准确, 有效地减少了重构误差, 提高了分解效率。CEEMDAN 算法的操作步骤如下。

$$y_m(t) = x(t) + \alpha \delta_m(t) \quad (13)$$

$$\text{IMF}_1(t) = \frac{1}{M} \sum_{m=1}^M \text{IMF}_1^m(t) \quad (14)$$

$$r_1(t) = y(t) - \text{IMF}_1(t) \quad (15)$$

$$\text{IMF}_n(t) = \frac{1}{K} \sum_{k=1}^K E_{n-1} \{ r_{n-1}(t) + \alpha_{n-1} E_{n-1} [\delta_k(t)] \} \quad (16)$$

$$r_n(t) = r_{n-1}(t) - \text{IMF}_n(t) \quad (17)$$

$$x(t) = \sum_{n=1}^N \text{IMF}_n + r_N(t) \quad (18)$$

式中: $\delta_m(t)$ 斯白噪声序列; $y_m(t)$ 为 m 次得分解子序列; $x(t)$ 为原始信号; α 为白噪声权重系数。

将 m 次高斯白噪声序列添加到初步预测误差序列中, 得到待分解的 m 次子序列, 使用 EMD 分解得分解子序列, 对得到 m 个第一分量求平均值得到第一个模态分量 IMF_1 及第一阶残差分量 $r_1(t)$ 。随后, 通过上述公式持续分解, 依次计算。直到余量误差无法继续分解停止。

3.2 初步预测误差模态分量重构

为降低初步预测误差的非平稳行, 将初步预测的功率误差进行信号分解, 同时为了得到更精细的模态分量, 将初步预测误差进行 CEEMDAN-VMD 二次分解, 这虽能一定程度上提升预测精度, 但这将导致模态分量过多, 极大地影响预测效率。为了提升风电功率预测精度的同时有效地减少预测时间, 提高计算效率, 本文研究提出一种先重构在分解的方法。通过计算 CEEMDAN 分解的初步误差序列各模态分量的样本熵, 利用样本熵评估各分量复杂度, 然后按照各自分量的复杂度通过 K -means 聚类算法将各分量重构为高、中、低三种频率的模态分量。然后在对高频初步预测误差分量进行 VMD 分解, 通过重构分量可以得到更加稳定且精细的子序列, 同时也大大缩小了误差补偿预测模型的运算时间, 极大地增加了预测效率和预测精度。

3.2.1 K -means 聚类算法

K -means 算法由于它具有操作简单、收敛速度快的优点被广泛用于聚类运算^[16], K -means 算法的基本过程如下: ①随机选取 K 个点作为初始聚类的簇心; ②分别计算各聚点到簇心的欧式距离, 将离该点距离最近的点划分为同类; ③更新簇心再次迭代; ④簇心不再发生明显的变化时停止。

3.2.2 VMD 变分模态分解

VMD 是一种自适应、非递归的信号分解方法, 能够将原始信号分解为一系列具有稀疏性质的平稳模态分量。它可以自适应性的匹配各分量的最佳中心频率和有限带宽, 求得变分问题最优解。VMD 分解过程如下。

变分模型约束表达式为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial(t) \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k = f(t) \end{cases} \quad (19)$$

式(19)中: u_k 为各模态分量, $k=1, 2, \dots, K$; ω_k 为各模态分量对应的中心频率; $\delta(t)$ 为狄拉克函数。

为求解上述约束表达式, 引入二次惩罚函数和增广拉格朗日函数, 公式为

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial(t) \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k \right\|_2^2 + \\ & \langle \lambda(t), f(t) - \sum_{k=1}^K u_k \rangle \end{aligned} \quad (20)$$

式(20)中: α 为二次惩罚参数; λ 为拉格朗日乘法算子。

使用交替方向乘子法计算各模态分量 u_k 以及各模态分量对应的中心频率 ω_k , 更新公式为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (21)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (22)$$

式中: n 为迭代次数; $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{f}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别为 $u_k^{n+1}(t)$ 、 $\hat{f}(t)$ 、 $\hat{u}_i(t)$ 、 $\hat{\lambda}(t)$ 的傅里叶变换。

4 算例分析

为验证本文模型的有效性, 以新疆达坂城风电场实际监测数据集进行仿真验证, 该数据集包括 2019 年 1 月 1 日—2 月 7 日的风力发电功率数据。数据中的特征包括风电场风向、风速、实时气温、气压、湿度、时间, 共 6 种特征。以 15 min 采样 1 次, 每天采样 96 条, 38 d 共 3 648 条数据。为避免过程产生过拟合现象, 本文研究采取 7:3 的比例选取前 25 d 的 2 400 条数据作为训练数据, 验证集取 10 d 共计 960 条数据, 最后 3 d 共计 288 条数据作为预测集。实验结果将取 10 次实验结果的算术平均结

果作为最终结果。

4.1 误差评价指标

采用均方根误差 (root mean square error, RMSE)、决定系数 (R^2)、以及基于绝对平均误差 MAPE 改进的指标 (mean of actual values mean Absolute percentage error, MMAPE)^[17], 3 个指标作为评价指标。其公式分别为

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (23)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (\bar{y}_i - y_i)^2} \quad (24)$$

$$\begin{cases} E_{\text{MMAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_{\text{ave}}} \right| \times 100\% \\ y_{\text{ave}} = \frac{1}{n} \sum_{i=1}^n y_i \times 100\% \end{cases} \quad (25)$$

式中: y_i 为实测值; $\hat{y}_i$ 为预测值; E_{RMSE} 、 E_{MMAPE} 分别为预测结果的均方根误差和改进绝对平均误差; y_{ave} 为实测值的均值。

4.2 风电预测误差二次分解结果

通过 CEEMDAN 分解将初步预测误差序列分解, 并计算分解后的 IMF 样本熵展示各分量的复杂度, 最后将复杂度较高的分量通过 VMD 再次分解, 误差序列二次分解结果如图 4 所示。

如图 4 所示, CEEMDAN 将初步预测误差序列分解成多个 IMF, 然后将其重构并将高频分量再使




图4 序列二次分解结果

Fig. 4 CEEMDAN and VMD decomposition results

用 VMD 分解,形成最终的预测序列。为进一步验证本文所提二次分解方法的优越性,将单次 CEEMDAN 分解、单次 VMD 分解与本文模型所构建的误差分量进行精度预测比较,验证模型性能。预测结果如表 2 所示。

表 2 模型预测结果精度对比			
Table 2 Precision comparison of model prediction results			
模型	RMSE	MMAPE/ %	R^2 /%
CEEMDAN-VMD-IDBO-BiLSTM-ATTENTION	5.173	5.44	99.21
CEEMDAN-IDBO-BiLSTM-ATTENTION	7.921	8.13	98.20
VMD-IDBO-BiLSTM-ATTENTION	10.351	8.78	96.41

从表 2 得出,将本文模型与使用 VMD-IDBO-BiLSTM-ATTENTION 和 CEEMDAN-IDBO-BiLSTM-ATTENTION 组合模型预测结果比较, RMSE 分别降低了 5.178、2.748, MMAPE 分别降低了 3.34%、2.69%, R^2 分别提高了 2.80%、1.01%。表 2 给出了 3 种模型预测精度结果,从表 2 可以看出,经过 CEEMDAN-VMD 二次分解过后的误差序列的预测精度更高,风电功率短期预测曲线更加贴和真实曲线。

4.3 IDBO 的优化性能分析

为验证 IDBO 优化算法的性能,将 IDBO 与灰狼优化算法 GWO、麻雀优化算法 SSA、鲸鱼优化算法 WOA、苍鹰优化算法 NGO、以及蜣螂优化算法 DBO 进行比较。设置 GWO 的参数 $a = 2 - 2/M$,其中 M 为最大迭代次数; NGO 的攻击半径 $R = 0.02(1 - t)/M$,其中 t 为迭代次数; WOA 常数 $b = 1$; SSA 预警值 $ST = 0.8$ 发现者比例 $PD = 0.2$,警戒者比例 $SD = 0.2$, DBO 滚球蜣螂、产卵蜣螂、小蜣螂、偷窃蜣螂的比例分别为 0.2、0.4、0.2、0.2; 且 6 种优化算法的种群数量均为 30,最大迭代次数为 200,6 种模型寻优收敛曲线如图 5 所示。




图 5 多种优化算法性能对比

Fig. 5 Performance comparison of various optimization algorithms

从图 5 可看出, GWO 收敛速度最慢, 寻优效果最差, WOA 和 NGO 算法收敛速度与适应度值量级相差不大, NGO 略优于 WOA, 但收敛速度较慢; DBO 与 SSA 收敛速度优于除 IDBO 外的其他算法, 适应度指也相对优秀。 DBO、SSA、IDBO 适应度值在一个量级上, 但在 6 种优化算法中 IDBO 收敛速度最快, 且适应度值最优。因此, 在这几种搜索优化算法中, IDBO 寻优能力最佳。

4.4 预测结果分析

为验证本文模型的有效性, 建立 SVM、CNN-BiLSTM、IDBO-BiLSTM、TCN-LSTM 4 种组合预测模型模型, 并与将本文模型比较, 评估模型性能。结果如表 3 所示。

表 3 得出, 将新衍生特征集输入到预测模型后, 相较于将新数据集输入 SVM、TCN-LSTM、CNN-BiLSTM、IDBO-BiLSTM 组合模型, RMSE 分别降低了 30.281、6.956、4.979、6.144, MMAPE 分别降低了 15.18%、2.73%、3.45%、3.60%, R^2 分别提高了 10.51%、2.65%、1.62%、2.57% 各模型对验证数据的预测结果如图 6 所示。

通过图 6 对比 LSTM 模型与 SVM 模型在谷峰位置的预测值与实际值有很大误差, 没有很好的拟合效果。而加入了卷积神经网络后的预测模型精度有了很大提升, 且 CNN-BiLSTM 对比 TCN-BiLSTM

表 3 部分模型预测结果精度对比
Table 3 Comparison of accuracy of prediction results of some models

模型	RMSE	MMAPE/%	R^2 /%
SVM	35.454	20.62	88.7
TCN-BiLSTM	12.129	8.17	96.56
CNN-BiLSTM	10.152	8.89	97.59
IDBO-BiLSTM	11.317	9.04	96.64
本文模型	5.173	5.44	99.21




图 6 部分模型预测效果对比

Fig. 6 Comparison of prediction effects of some models

组合模型预测精度上仍有较大提升,虽然 TCN 模型能够捕捉长期依赖关系,可能比 CNN 更适合处理长时序预测问题,而在风电功率预测问题中,风速与功率的相关性较强,局部风速的增加或减少会极大地影响功率的大小,而 CNN 模型可以很好地捕捉局部特征,这也导致了 CNN 模型所训练的模型精度更加准确。而进行误差补偿后的功率在平缓区和突变区的预测功率精度明显高于其他模型,同时 IDBO-BiLSTM 组合模型由于 IDBO 具有更强的全局搜索能力,在局部突变位置的补偿效果也优于 DBO-BiLSTM 模型,对比以 DBO 寻优的误差补偿模型 MMAPE 降低了 3.60%。因此, IDBO-BiLSTM 相较于其他的组合模型,在运行平稳区段和局部突变区段拟合效果更加突出,预测准确度明显提升。

5 结论

针对风电功率预测精度低的问题。提出了一种二次分解的误差补偿修正模型提高风功率预测精度,通过使用算例仿真和与传统预测模型和其他深度学习预测模型相比得出如下结论。

(1) 利用 CEEMDAN 和 VMD 对预测误差与风功率特征进行分解,可以有效地降低功率的非平稳性,增强模型的性能。

(2) 针对深度预测模型参数多难选取的问题,采用收敛速度快全局搜索能力强的改进蜣螂算法对模型参数进行寻优,避免因人工寻优选取参数速度慢、参数选择效果差的问题,大大提高了效率和精度。

(3) 通过对误差序列进行分解-重构-分解的策略,在对高频误差进行二次分解降低非平稳性的同时加快的风功率预测效率,提高了预测精度。

(4) 通过与传统预测模型以及其他组合深度学习模型进行对比,本文模型具有较高的预测精度和泛化能力。

通过新疆达坂城风电场的实测数据仿真实验表明,本文模型具有可行性,且具有更优的预测能力。同时也为提高时序预测问题的精度提供了一定的思路。

参考文献

[1] 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 Xupeng, Tang Yun, Zhang Kai, et al. Ultra-short term wind power prediction based on CEEMDAN-IDOA-BiLSTM[J]. Power Grids and Clean Energy, 2023, 39(11): 142-150.

[2] Hu S, Xiang Y, Shen X D, et al. Wind power prediction model considering meteorological factor and spatial correlation of wind

speed[J]. Automation of Electric Power Systems, 2021, 45(7): 28-36.

[3] 王泽华,徐兴国,叶子臣. 基于改进麻雀搜索算法优化 SVM 的风电功率预测研究[J]. 技术与市场, 2023, 30(8): 70-74, 79.

Wang Zehua, Xu Xingguo, Ye Zichen. Wind power prediction based on improved sparrow search algorithm and SVM optimization[J]. Technology & Field, 2023, 30(8): 70-74, 79.

[4] 谢波,高建宇,张惠娟,等. 短期风电功率预测中的 IOFA-SVM 算法实现[J]. 电子测量技术, 2021, 44(12): 63-69.

Xie Bo, Gao Jianyu, Zhang Huijuan, et al. Implementation of IOFA-SVM algorithm for short-term wind power prediction[J]. Electronic Measurement Technology, 2021, 44(12): 63-69.

[5] Yang G Q, Liu S I, Wang D Y, et al. Short-term wind power forecasting based on attention-gru wind speed correction and stacking[J]. Acta Energetica Sinica, 2022, 43(12): 273-281.

[6] Qi F Z, Zhuo K X, Cao J. Short-term wind power probability density prediction method based on multi-level semantic attention mechanism[J]. Acta Energetica Sinica, 2022, 43(11): 140-147.

[7] 程杰,严婷,窦春霞,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, Yan Ting, Dou Chunxia, et al. Ultra-short term wind power prediction based on GWO-CNN-BiLSTM[J]. Science Technology and Engineering, 2019, 23(35): 15091-15099.

[8] 丁同,傅晓锦,刘明旺. 基于 GA-VMD-BiLSTM 算法的风电功率预测[J]. 扬州大学学报(自然科学版), 2022, 25(4): 44-49.

Ding Tong, Fu Xiaojin, Liu Mingwang. Wind power prediction based on GA-VMD-BiLSTM algorithm[J]. Journal of Yangzhou University (Natural Science Edition), 2022, 25(4): 44-49.

[9] 高鹭,孔繁苗,张飞,等. 基于 IPSO-BiLSTM-AM 模型的超短期风电功率预测方法[J]. 智慧力, 2022, 50(4): 27-34.

Gao Lu, Kong Fanmiao, Zhang Fei, et al. Ultrashort term wind power prediction method based on IPSO-BiLSTM-AM model[J]. Smart Power, 2012, 50(4): 27-34.

[10] Xiao L X, Zhang Y, Zhou H, et al. Ultra short term wind power prediction based on IAOA-VMD-LSTM[J]. Acta Energetica Sinica, 2023, 44(11): 239-246.

[11] Sheng S Q, Jin H Y, Liu C R. Short-term and mid-short-term wind power forecasting based on VMD-WSGRU[J]. Power System Technology, 2022, 46(3): 897-904.

[12] Chang Y F, Yang Z X, Pan F, et al. Ultra-short-term wind power prediction based on CEEMDAN-PE-WPD and multi-objective optimization[J]. Power System Technology, 2023, 47(12): 5015-5026.

[13] 伍俊杰,张倩,李国丽,等. 计及误差修正的变分模态分解-长短期记忆神经网络短期负荷预测[J]. 科学技术与工程, 2022, 22(12): 4828-4834.

Wu Junjie, Zhang Qian, Li Guoli, et al. Variational mode decomposition with error correction for short-term load forecasting by long short-term memory neural networks[J]. Science Technology and Engineering, 2002, 22(12): 4828-4834.

[14] Xue J, Shen B. Dung beetle optimizer: a new meta heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.

[15] Tanyildizi E, Demir G. Golden sine algorithm: a novel math in-

- spired algorithm[J]. Advances in Electrical and Computer Engineering, 2017, 17(2): 71-79.
- [16] 宋江涛,崔双喜,刘洪广. 基于二次分解 NGO-VMD 残差项与长短时记忆神经网络的超短期风功率预测[J]. 科学技术与工程, 2023, 23(6): 2428-2437.
- Song Jiangtao, Cui Shuangxi, Liu Hongguang. Ultra-short term wind power prediction based on quadratic decomposition NGO-VMD residual term and short term memory neural network [J]. Science Technology and Engineering, 2019, 23(6): 2428-2437.
- [17] 周洪煜,曾济贫,王照阳,等. 基于混沌 DNA 遗传算法与 PSO 组合优化的 RNN 短期风电功率预测[J]. 电力系统保护与控制, 2013, 41(2): 144-149.
- Zhou Hongyu, Zeng Jipin, Wang Zhaoyang, et al. RNN short-term wind power prediction based on chaotic DNA Genetic algorithm and PSO combination optimization[J]. Power System Protection and Control, 2013, 41(2): 144-149.