

DOI:10.3969/j.issn.2097-0706.2026.01.002

基于 CEEMDAN-DBO-VMD-TCN-BiGRU 的短期 风电功率预测

Short-term wind power prediction based on CEEMDAN-DBO-VMD-TCN-BiGRU

陈旭东, 卞礼杰, 马刚*, 陈浩, 詹孝升, 彭乐瑶

CHEN Xudong, BIAN Lijie, MA Gang*, CHEN Hao, ZHAN Xiaosheng, PENG Leyao

(南京师范大学 电气与自动化工程学院, 南京 210023)

(School of Electrical and Automation Engineering, Nanjing Normal University, Nanjing 210023, China)

摘要: 提升风电功率预测的准确性对于保障电网安全与稳定运行至关重要。然而, 风电具有高度的随机性和波动性, 传统预测方法在特征提取和建模能力方面存在不足。为此, 提出一种融合完全自适应噪声集合经验模态分解(CEEMDAN)、蜣螂优化(DBO)算法、变分模态分解(VMD)、时间卷积网络(TCN)与双向门控循环单元(BiGRU)的短期风电功率预测模型 CEEMDAN-DBO-VMD-TCN-BiGRU。利用 CEEMDAN 对原始风电功率数据进行分解, 提取内在模态函数(IMF)以捕捉时间序列的关键特征; 通过样本熵与 K-means 聚类将 IMF 划分为高频、中频和低频分量, 选取高频分量采用 DBO 优化的 VMD 进行二次分解, 以提高特征提取效果并降低计算复杂度; 所有分量经归一化处理后输入 TCN-BiGRU 组合模型进行预测, 各分量预测结果经叠加与反归一化处理获得最终预测值。试验结果显示, 相较于对比模型, 该模型的预测精度最优, 验证了所提模型的有效性、稳定性和应用潜力。

关键词: 风电功率预测; 完全自适应噪声集合经验模态分解; 蜣螂优化算法; 变分模态分解; 样本熵; K-means 聚类; 时间卷积网络; 双向门控循环单元

中图分类号: TK 81 文献标志码: A 文章编号: 2097-0706(2026)01-0013-10

Abstract: Improving the accuracy of wind power prediction is crucial for ensuring safe and stable operation of the power grid. However, wind power exhibits high randomness and volatility, and traditional prediction methods have limitations in feature extraction and modeling capabilities. Therefore, CEEMDAN-DBO-VMD-TCN-BiGRU, a short-term wind power prediction model integrating complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN), dung beetle optimizer (DBO) algorithm, variational mode decomposition (VMD), temporal convolutional network (TCN), and bidirectional gated recurrent unit (BiGRU) was proposed. CEEMDAN was used to decompose the original wind power data, extracting intrinsic mode functions (IMFs) to capture key features of the time series. The IMFs were divided into high-frequency, medium-frequency, and low-frequency components using sample entropy and K-means clustering. The high-frequency components were selected for secondary decomposition using DBO-optimized VMD to improve feature extraction effectiveness and reduce computational complexity. All components were normalized and then input into the TCN-BiGRU combined model for prediction. The prediction results of each component were superimposed and denormalized to obtain the final prediction value. Experimental results showed that compared with benchmark models, the proposed model had the best prediction accuracy, verifying its effectiveness, stability, and application potential.

Keywords: wind power prediction; complete ensemble empirical mode decomposition with adaptive noise; dung beetle optimizer algorithm; variational mode decomposition; sample entropy; K-means clustering; temporal convolutional network; bidirectional gated recurrent unit

0 引言

随着化石燃料的可用性不断下降, 开发新能源变得愈发重要。风能作为一种环保型新能源已成为电网的重要组成部分。2023 年全球风力发电容量实现了里程碑式的增长, 新增装机容量超过 100

基金项目: 江苏省碳达峰碳中和科技创新专项资金项目 (BE2022003)
Technological Innovation Special Fund Project for Carbon Peaking and Carbon Neutrality in Jiangsu Province (BE2022003)

GW,其中包括 105.6 GW 的陆上风力发电容量和 10.8 GW 的海上风力发电容量^[1]。然而,由于风力发电具有高度的随机性和不确定性,大规模将其接入电网会给电力系统的安全性和稳定性带来运行上的挑战^[2]。此外,风电功率预测是并网风电场的首要任务,不仅有助于减少弃风现象的发生,还为风电场的日常调度与发电计划提供依据^[3]。因此,高精度的风力发电预测对于电网的安全运行尤为重要。

目前,国内外的风力发电预测模型主要分为物理方法、统计模型^[4]、机器学习^[5]和深度学习^[6]方法这几类。其中,深度学习模型是当前研究的焦点。物理模型无需依赖历史数据,主要基于风电场的地形特征和气象条件构建,具有较强的理论基础。然而,该类方法建模过程复杂,计算成本高,实用性受限。统计模型则基于风电场的历史观测数据,如概率自回归和概率质量偏差模型,通过建立风电功率与相关解释变量之间的关系实现预测,但其在处理大规模非线性数据时存在局限。相比之下,机器学习模型依赖于特征工程,需要从原始数据中手动提取关键特征作为输入,以提升建模效果,主要包括支持向量机(Support Vector Machine, SVM)^[7]、多层感知器(Multilayer Perceptron, MLP)^[8]、K最近邻(K-Nearest Neighbors, KNN)^[9]等。深度学习擅长处理非线性和时序数据,但单一的深度学习模型在处理复杂风电数据时依然会面临一些挑战,影响预测精度。为了解决风电预测的不确定性和间歇性问题,采用时间序列分解和深度学习方法的混合预测模型进一步提高风电功率预测的准确性^[10]。

文献[11]利用变分模态分解(Variational Mode Decomposition, VMD)将电力负荷数据中的高频模态分量分解为不同尺度的本征模态函数。文献[12]利用完全自适应噪声集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)引入自适应噪声,有效地解决了经验模态分解(Empirical Mode Decomposition, EMD)存在的局限性,克服了模式混合和端点效应等难题,同时降低了误差积累。文献[13]首先引入了样本熵(Sample Entropy, SE)并使用 CEEMDAN 来降低信息的复杂性,增强了原始数据的可预测性。文献[14]引入鲸鱼优化算法(Whale Optimization Algorithm, WOA)优化变分量模态分解,求得最优 VMD 分解模态数,提高了模型精度。这些分解方法能够有效降低风电功率数据非平稳性对预测造成的影响,然而单一分解模型存在明显局限性,如分解结果不稳定,对噪声敏感等。

尤其针对风电功率数据中的高频成分,若未得到充分分解会影响模型预测能力。文献[15]提出了具备出色的可扩展性与平移不变性的时间卷积网络(Temporal Convolutional Network, TCN),但其对输入序列长度存在一定敏感性。文献[16]中提出了门控循环单元(Gated Recurrent Unit, GRU),随后在 GRU 基础上改进出双向门控循环单元(Bidirectional Gated Recurrent Unit, BiGRU),该网络在缓解梯度消失问题上表现出色,但在处理特定序列模式时,可能会引发过拟合现象。

基于上述已有研究,为进一步提高风电功率预测精度,弥补单一模型预测缺陷,本文提出一种基于 CEEMDAN、蜣螂优化(Dung Beetle Optimizer, DBO)算法、VMD、TCN 和 BiGRU 的短期风电功率预测模型。首先采用 CEEMDAN 对风电功率数据进行一次分解得到若干本征模态函数(Intrinsic Mode Function, IMF)分量,计算各分量 SE 并依据熵值进行 K-means 聚类,划分为高频、中频和低频分量。然后采用 DBO 对 VMD 进行参数寻优,将聚类后的高频分量进行优化 VMD 二次分解。最后将所有分解出的分量导入 TCN-BiGRU 模型,利用 TCN 提取全局时序特征,采用双向门控循环单元 BiGRU 在 TCN 提取特征的基础上更深入挖掘时间序列的双向依赖关系,从而增强组合模型泛化能力,减小预测误差。

1 优化模态二次分解

1.1 基于 CEEMDAN 的一次分解

EMD 是一种信号分析方法,通过将时间序列分解为多个 IMF 和一个残余项来实现信号的分解^[17]。集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)是一种基于 EMD 的集合变体方法^[18]。首先在原始序列上添加高斯白噪声,然后进行多次分解并对分解结果取平均。与 EMD 相比, EEMD 提高了噪声抑制能力和分解稳定性。CEEMDAN 是通过在 EEMD 的基础上向原始信号加入自适应白噪声来解决模式混叠问题,多次迭代后获得比 EEMD 更稳定的分解结果。对于时间序列信号 $a(t)$ 而言, CEEMDA 算法的分解过程如下。

(1)对时间序列信号 $a(t)$ 加入 I 次高斯白噪声,生成一组新的信号集合。

$$a_i(t) = a(t) + \varepsilon_0 \omega_i(t), \quad (1)$$

式中: $a_i(t)$ 为加入白噪声后的信号; ε_0 为高斯白噪声的权值系数; $\omega_i(t)$ 为第 i 次处理时的高斯白噪声。

(2)对所有 $a_i(t)$ 进行 EMD 分解,得到第 1 个

IMF 分量 $c_1^i(t)$, 取其均值作为经 CEEMDAN 分解得到的第 1 个 IMF 分量 $b_1(t)$, 同时得到第 1 个残差序列 $c_1(t)$ 。

$$b_1(t) = \frac{1}{I} \sum_{i=1}^I c_1^i(t), \quad (2)$$

$$c_1(t) = a(t) - b_1(t). \quad (3)$$

(3) 将残差序列加入噪声构造为 I 个新的时间序列 $c_1(t) + \varepsilon_1 E_1(\omega_i(t))$ (E 为 EMD 操作符), 对其继续进行 EMD 分解后取均值得到 $b_2(t)$, 继续做差可得第 2 个残差序列 $c_2(t)$ 。以此类推, 可得第 n 阶段残差和 CEEMDAN 分解后第 $n+1$ 个 IMF 分量。

$$b_{n+1}(t) = \frac{1}{I} \sum_{i=1}^I E_1(c_n(t) + \varepsilon_n E_n(\omega_i(t))), \quad (4)$$

$$c_n(t) = c_{n-1}(t) - b_n(t). \quad (5)$$

(4) 对经过 N 个阶段得到的 IMF 分量求和后取平均得到最终的 IMF 分量; 将原始信号减去所有 IMF 分量的和, 得到最终残差信号 $R(t)$ 。

$$R(t) = a(t) - \sum_{n=1}^N b_n(t). \quad (6)$$

式(6)移项可得时间序列经过 CEEMDAN 分解后的表达式。

1.2 K-means

K-means 是一种广泛应用于数据聚类的无监督学习算法。通过将数据集划分成多个簇, 使得每个簇内的数据点尽可能相似, 同时让不同簇之间数据点的差异尽可能大, 从而实现聚类^[19]。本文借助 K-means 对高频、中频、低频等 3 个频段 IMF 分量的 SE 进行区分。高频分量反映信号的短期剧烈波动, 中频分量关联着中等时间尺度的周期性波动, 而低频分量则反映长期趋势。通过聚类可以对不同频段分量采取不同处理策略, 进而提高整体模型功率预测准确度。

1.3 SE

SE 是一种通过评估在时间序列中产生新模式的可能性来量化时间序列复杂性的度量^[20]。与传统的近似熵相比, SE 排除了自匹配, 在处理边界效应和数据长度变化方面表现出更高的稳健性。SE 的计算公式为

$$\text{Sampen}(n, x, N) = \lim_{N \rightarrow \infty} \left\{ - \ln \left(\frac{B^{n+1}(x)}{B^n(x)} \right) \right\}, \quad (7)$$

式中: N 为序列长度; $B^n(x)$ 和 $B^{n+1}(x)$ 分别为序列在阈值 x 处匹配 n 个点和 $n+1$ 个点的概率; 通常情况下 n 为 2; x 为阈值, 通常是序列标准差的 10%~25%。

本文通过计算 SE 来衡量不同 IMF 分量的复杂度, SE 越大复杂度越高, 信号不规则程度也越高。

1.4 DBO

VMD 分解过程中模态数和惩罚因子对分解效果影响显著。模态数 K 决定分解后 IMF 的数量, 惩罚因子用于控制信号的带宽。传统 VMD 分解中的 K 值一般根据需求固定, 很难得到全局最优结果。本文采用 DBO 算法对 VMD 的模态数 K 和惩罚因子 α 进行寻优。DBO 算法是一种新兴的群体智能优化算法, 模拟蜣螂在自然界中的滚球、舞蹈、繁殖、偷窃和觅食等 5 种行为机制, 实现全局探索与局部开发的动态平衡, 具备较强的全局寻优能力与鲁棒性, 能够有效提升 VMD 分解的适应性与分量质量, 可为后续预测模型提供更具判别性的特征输入^[21]。

1.5 VMD

VMD 是一种自适应的信号处理方法, 通过非递归的方式将原始信号分解为 K 个具有不同中心带宽的子序列^[22]。该分解的目的是使子序列的带宽总和最小化, 确保每个模式在频域中尽可能集中于其中心频率附近。具体表达式为

$$\left\{ \begin{array}{l} \min_{\{\lambda_k, \omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) * \lambda_k(t)] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_{k=1}^K \lambda_k(t) = f(t) \end{array} \right\}, \quad (8)$$

式中: K 为模态分解数; λ_k 为各模态函数; ω_k 为各模态中心频率; $*$ 表示卷积运算; ∂_t 为时间 t 处的梯度; $f(t)$ 为原始信号。

VMD 的核心在于构建一个优化问题, 该问题通过引入惩罚因子 α 和拉格朗日乘子 μ 将约束条件转换为无约束。

$$L(\{\lambda_k\}, \{\omega_k\}, \mu) = \alpha \sum_{k=1}^K \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) * \lambda_k(t)] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K \lambda_k(t) \right\|_2^2 + \left\langle \mu(t), f(t) - \sum_{k=1}^K \lambda_k(t) \right\rangle. \quad (9)$$

通过交替更新模态函数、中心频率和拉格朗日乘子, 最终逐步逼近最优解。鉴于 VMD 对高频信号有良好的分解表现, 本文首先对原始信号进行一次 VMD 分解, 随后通过 DBO 算法优化 VMD 参数, 对高频分量进行二次分解, 以充分提取高频分量的时序特征, 提高短期风电功率预测精度。

2 预测模型原理

2.1 TCN

TCN 是一种基于卷积神经网络 (Convolutional Neural Network, CNN) 架构的时间序列数据处理模

型,广泛应用于多个领域。TCN具有3个核心特征:因果卷积、扩张卷积和残差连接^[23],其框架如图1所示(图中, d 为扩张率)。




图1 TCN架构

Fig. 1 TCN architecture

因果卷积遵循严格的时间约束,仅使用当前时刻及之前的信息,不考虑未来数据。与传统卷积不同,扩张卷积在卷积过程中以间隔方式对输入进行采样,能够以较少的层实现更大的感受野。扩张卷积 $F(s)$ 计算公式为

$$F(s) = (x * df)(s) = \sum_{h=0}^{k-1} f(h) \cdot X_{s-d \cdot h}, \quad (10)$$

式中: s 为序列中的当前位置; d 为扩张率, $d \in [1, 2^1, \dots, 2^{N-1}]$; N 为每个TCN中卷积层的个数; $X_{s-d \cdot h}$ 为输入到滑动窗口中前一时刻的值; k 为卷积核大小, $k=3$; $f(h)$ 为对应层的第 h 个卷积核。

残差连接环节是经过一系列自身的运算后,将上一层的误差输出到下一层。残差模块结构如图2所示,其计算公式为

$$X_i = \beta(G(X_{i-1}) + X_{i-1}), \quad (11)$$

式中: β 为激活函数; X_{i-1} 为上一层的误差; G 为通过膨胀因果卷积的4个部分对 X_{i-1} 进行的转换。




图2 残差模块结构

Fig. 2 Residual module structure

2.2 BiGRU

BiGRU是一种基于GRU的循环神经网络(Recurrent Neural Network, RNN)变体,它能够同时利用序列数据的过去和未来信息进行建模^[24]。BiGRU结合了两个GRU层:一个用于处理正向序列,通过正向传播将时间序列输入网络中训练,挖掘数据的正向相关性;另一个用于处理逆向序列,在逆向传播中训练时间序列,挖掘数据的逆向相关性^[25]。相比于单层GRU, BiGRU可以更好地捕捉序

列中的双向依赖关系,从而更全面理解时序特征数据。BiGRU原理如图3所示。




图3 BiGRU原理

Fig. 3 BiGRU principle

3 基于CEEMDAN-DBO-VMD-TCN-BiGRU的短期风电功率预测模型

为确保各个子模块的引入具备明确的功能定位与协同逻辑,本文提出的CEEMDAN-SE-K-means-DBO-VMD-TCN-BiGRU短期风电功率预测组合模型遵循“粗分解—复杂度识别—高频细分—深度建模”的逐层策略。其中:CEEMDAN用于对原始非平稳风电功率序列进行初步分解,获得多个尺度的IMF,降低直接建模的难度;SE量化各IMF的复杂性,结合K-means聚类识别具有高扰动性的高频分量;高频分量在时域中往往具有较高的瞬态变化性与SE,对深度模型而言更易引起过拟合或梯度不稳定问题,因此,本文仅对高频部分采用DBO优化的VMD进行细化解构,进一步消解扰动、提升特征可分性,中频与低频分量直接参与预测建模,以避免对原始结构的过度干预;最终使用TCN-BiGRU模型完成预测,其中TCN用于捕捉局部时序模式, BiGRU用于增强双向时序依赖,整体形成兼顾全局趋势与局部扰动的联合建模结构。组合模型预测流程如图4所示。

其具体实现过程如下。

(1)首先对原始风电功率数据集进行预处理,去除缺失值和异常值,提升数据质量与可靠性,然后运用Min-Max归一化对各特征变量进行标准化处理,确保不同量纲下特征的可比性。在完成预处理的基础上,进一步从数据中提取与风电功率高度相关的关键特征变量。归一化公式为

$$Z' = \frac{Z - Z_{\min}}{Z_{\max} - Z_{\min}}, \quad (12)$$

式中: Z' 为归一化后的数据; Z 为原始数据; Z_{\min} 为特征中的最小值; Z_{\max} 为特征中的最大值。

(2)使用CEEMDAN对处理后的数据进行一次分解,分解为多个IMF分量。

(3)计算各IMF分量的SE值,对分量进行重构,

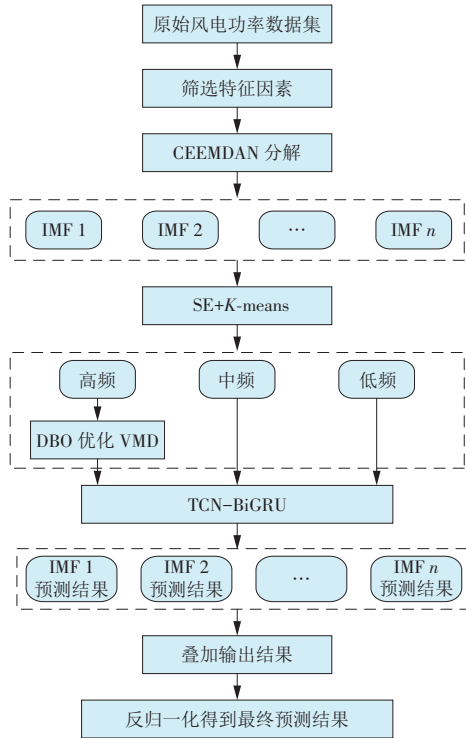


图 4 组合模型预测流程

Fig. 4 Combined model prediction process

并借助 K-means 将分量分为高频、中频、低频,得到新的序列。

(4)使用 DBO 算法对 VMD 参数寻优,再用优化参数对高频分量进行二次分解,进一步提取信号中的高频成分。

(5)将分解后的各个序列输入 TCN-BiGRU 模型进行功率预测,将若干个模态的预测结果进行叠加重构,得到最终输出结果。

(6)将最终输出结果进行反归一化处理,得到预测结果。

4 算例分析

4.1 试验数据来源

本文采用新疆某风电场 2019-06-01—08-31 的实测风电数据进行研究。数据集主要包含测风塔 10, 30, 50, 70 m 处的风速和风向, 轮毂高度风速和风向, 温度, 气压, 湿度和实际发电功率等 14 个特征。该风电场实测数据采样间隔为 15 min, 即每天采样 96 个样本, 共计 8 832 个样本数据。为提高模型泛化能力和试验的合理性, 选取样本数据前 80% 作为训练集, 剩余 20% 作为测试集。模型运行平台为 Intel i7-14650HX, 内存为 16 GB, 在 Matlab2024a 中完成功率预测。

4.2 数据处理

由于风电场实测风电功率数据存在缺失值与异常值, 直接用于建模预测将影响模型性能与结果

的可靠性, 因此需要先对数据进行预处理。本文通过 3σ 准则识别异常值, 将其视作缺失值, 采用插值法对缺失数据进行填补。此外, 原始数据集中包含 14 个特征因素, 并非所有变量对风电功率具有显著影响, 若全部纳入模型输入将增加计算量并延长预测时间。为提升建模效率, 本文采用皮尔逊相关系数分析法筛选出与风电功率高度相关的特征变量作为最终模型输入, 相关性分析结果如图 5 所示。




图 5 风电功率与各特征因素相关性

Fig. 5 Correlation between wind power and various features

由图 5 可知, 测风塔各高度风速及轮毂高度风速与实际风电功率存在显著相关性。为降低特征之间的多重共线性对模型预测精度的影响, 本文优先选取轮毂高度风速与测风塔 70 m 处风速作为主要输入特征, 同时保留轮毂高度风向、测风塔 70 m 处风向及实际风电功率用于后续分析。考虑到所选特征变量的量纲不一致, 为消除维度影响, 采用 Min-Max 标准化方法对数据进行归一化处理, 将各特征值映射至 $[0, 1]$ 。

4.3 模型评价指标

本文选用均方根误差 (Root Mean Squared Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 和决定系数 (R^2) 作为模型评价指标。其中 R^2 越接近 1, 表明模型拟合能力越强, 预测效果越优; 而 RMSE, MAE, MAPE 值越小, 说明模型在风电功率预测任务中表现出更高的精度与稳定性。

$$\delta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2}, \quad (13)$$

$$\delta_{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i|, \quad (14)$$

$$\delta_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100\%, \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2}, \quad (16)$$

式中： x_i 为实际功率； \hat{x}_i 为预测功率； \bar{x}_i 为实际功率的平均值； n 为样本总数。

4.4 优化 VMD 二次分解结果分析

对收集的原始风电数据进行第 1 次 CEEMDAN 分解,分解过程中添加 350 组白噪声,标准差为 0.2 MW。分解结果如图 6 所示。通过 CEEMDAN 分解得到 14 个 IMF 分量,其频率依次降低,说明原始数据的复杂度得到有效降解。




图 6 CEEMDAN 一次分解

Fig. 6 CEEMDAN primary decomposition

对各 IMF 分量进行 SE 计算,设置嵌入维度为 2,相似容限阈值 r 为信号标准差的 20%,其具体数值如图 7 所示。从 SE 分布图可看出,不同 IMF 分量的 SE 差异显著,高频分量的 SE 最高,可达 1.403 4,而低频分量的 SE 最低,仅为 0.001 6,反映出各分量在时序复杂性与信息量方面存在明显差异。

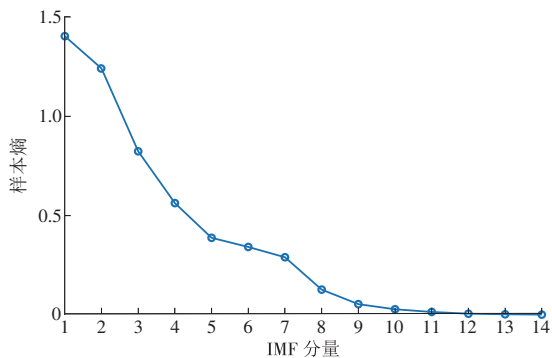


图 7 各 IMF 分量 SE 值

Fig. 7 SE values of all IMF components

在图 7 的基础上对一次分解后的子序列进行重构。IMF1—IMF4 的 SE 远超其他分量,且从 1.403 4 降至 0.563 1,数值变化最剧烈,相比之下 IMF5—

IMF7 的 SE 变化速率适中,IMF8—IMF14 的 SE 变化速率趋于平缓,结合图 6 可看出 2 组分量的复杂度和波动性较 IMF1—IMF4 均显著降低,因此本文将 IMF1—IMF4 划分为高频分量,IMF5—IMF7 划分为中频分量,IMF8—IMF14 划分为低频分量。借助 K-means 聚类得到高频、中频、低频分量 SE 分别为 0.971 6,0.399 4,0.047 0。图 8 中用 Co-IMF1, Co-IMF2, Co-IMF3 分别表示高频、中频和低频分量。




图 8 聚类后各频段分量

Fig. 8 Components of each frequency band after clustering

将 Co-IMF1, Co-IMF2, Co-IMF3 分别输入本文所提预测模型 TCN-BiGRU 中,预测结果如图 9—11 所示。图 9 中,将高频分量作为预测输入得到的预测值与真实值相比存在显著滞后和过冲,误差远高于中频(图 10)和低频(图 11)的预测结果。




图 9 高频分量预测结果

Fig. 9 High-frequency component prediction results

各分量预测试验评价指标见表 1。从预测结果看,模型对低频和中频分量的拟合效果显著优于高频分量。低频分量具有最低的 RMSE 和 MAE,分别为 8.47,5.98 MW,且 R^2 高达 97.73%,说明低频分量作为输入时模型整体预测效果最好;中频分量预测表现也较为稳定, R^2 为 96.56%;相比之下,高频分量由于波动剧烈、噪声干扰大,其 RMSE 为 12.55




图 10 中频分量预测结果

Fig. 10 Medium-frequency component prediction results




图 11 低频分量预测结果

Fig. 11 Low-frequency component prediction results

MW, R^2 仅 77.80%, 预测误差较大。这一差异凸显了分频建模的优势,尤其是高频分量的单独建模和优化处理对于提升整体预测精度具有关键作用。根据图 7 的 SE 值,中频与低频分量的 SE 较低,结构相对平稳,过度分解反而可能带来信息冗余,且直接作为输入预测效果较好,因此本文仅选择对高频分量进行优化二次分解。

表 1 各分量预测试验评价指标

Table 1 Evaluation indicators of component prediction experiment

分量	RMSE/MW	MAE/MW	MAPE/%	R^2 /%
高频	12.55	8.99	10.28	77.80
中频	11.87	7.78	9.58	96.56
低频	8.47	5.98	8.46	97.73

经过 DBO 对 VMD 参数寻优得到最优 IMF 分解数为 6, 惩罚因子为 1 305.16, 高频 IMF 在二次分解后 SE 降为 0.285 8, 0.272 5, 0.319 4, 0.351 0, 0.377 9, 0.397 4, 与原 SE(0.971 6) 相比, 数值显著减小, 子序列更加平滑, 表明二次分解有效降低了高频分量的复杂度, 二次分解得到的子序列可以更加灵活反映 Co-IMF1 的风电特征。优化二次分解后的各分量处理结果如图 12 所示。




图 12 优化二次分解后各频段分量

Fig. 12 Components of each frequency band after optimized secondary decomposition

4.5 预测结果及分析

为验证本文所提模型的有效性和预测精度, 采用 6 种模型进行对比试验, 模型 1 为 TCN-BiGRU, 模型 2 为 VMD-TCN-BiGRU, 模型 3 为 CEEMDAN-TCN-BiGRU, 模型 4 为 DBO-VMD-TCN-BiGRU, 模型 5 为 CEEMDAN-VMD-TCN-BiGRU, 模型 6 为本文所提模型, 预测结果如图 13 所示。




图 13 试验 1 的预测结果对比

Fig. 13 Comparison of prediction results in experiment 1

本文模型在进行 CEEMDAN-DBO-VMD 分解后, 对每个 IMF 分量分别构建 TCN-BiGRU 网络。预测模型具体参数设置为: TCN 层数为 4, 包含 2 个膨胀卷积残差模块, 每层使用 64 个大小为 5 的卷积核, 膨胀因子依次为 1 和 2, 并引入 50% Dropout 防止过拟合; BiGRU 设置前向与反向 GRU 神经元各 35 个; 训练阶段采用 Adam 优化器, 最大训练轮次为 100, 初始学习率为 0.01, 每 100 轮衰减为原来的 1/10 000, 并加入 L2 正则项以提升泛化能力。

在图 13 中, 模型 6 在不同区段均表现出较高的拟合精度, 对风电功率的突增、突降响应更为迅速准确, 这得益于 CEEMDAN 处理非平稳信号、VMD 抑制模式混叠以及 DBO 精调参数增强泛化能力。

总体而言,模型6的综合预测性能最优,充分运用了多源模态分解、参数优化和深度学习网络,在风电功率预测的精度和稳定性方面有很大提升。

为验证模型的有效性,采用 RMSE, MAE, MAPE, R^2 作为模型评价指标进行分析,见表2。

表2 试验1评价指标

Table 2 Evaluation indicators of experiment 1

模型	RMSE/MW	MAE/MW	MAPE/%	R^2 /%
1	8.94	5.52	8.64	97.36
2	7.75	5.50	7.17	98.02
3	7.45	5.24	6.82	98.18
4	7.01	4.95	6.73	98.38
5	6.86	4.93	6.53	98.45
6	6.47	4.30	6.28	98.62

模型1将原始风电数据直接输入TCN-BiGRU模型进行功率预测, RMSE为8.94 MW, MAE为5.52 MW, MAPE为8.64%, R^2 为97.36%。与其余5种模型相比,模型1的RMSE, MAE, MAPE均表现出最高误差, R^2 亦为最低,反映其整体预测精度较弱。尽管TCN在提取风电时间序列中的复杂特征方面具备一定优势, BiGRU也能有效捕捉风电变化的动态特征,但由于缺乏时序分解过程,模型1在处理复杂非平稳序列方面的能力明显不足。

相较于未经分解的模型1,模型2,3的各项评价指标均更优,表明时序分解显著增强了模型对复杂风电序列特征的提取能力与预测精度。与模型2相比,模型3的RMSE, MAE, MAPE分别降低了3.87%, 4.73%, 4.88%, R^2 提高了0.16%,说明CEEMDAN在分解精度和时序特征保留上优于VMD,为预测模型提供了更优质的特征输入。

模型4在模型2的基础上加入了DBO优化, RMSE和MAE较模型4减少接近10%,表明在分解中加入优化算法寻找最优参数能显著改善网络对复杂数据的适应能力。模型5在模型1的基础上加入了CEEMDAN和VMD双分解模型,整体预测效果仅次于模型6。模型6融合了前5个模型的优点,采用DBO优化VMD的二次分解模型对时序数据进行深度分解,将分解结果导入TCN-BiGRU模型进行功率预测,整体预测效果最优。

为进一步验证所提模型和优化算法在进行风电功率预测方面的优越性,另外选取4种模型与本文所提模型进行对比试验,各模型预测结果如图14所示。模型7将模型6中的DBO算法替换为PSO算法;模型8将模型6中的DBO算法替换为WOA算法;模型9在模型6的基础上对TCN-BiGRU模型加入注意力机制;模型10将TCN-BiGRU模型替换成

CNN-BiLSTM模型。模型7,8用来验证模型6所用优化算法的优越性;模型10用来对比检验TCN-BiGRU模型与CNN-BiLSTM模型的预测性能。试验2的预测结果如图14所示,评价指标见表3。




图14 试验2的预测结果对比

Fig. 14 Comparison of prediction results in experiment 2

表3 试验2评价指标

Table 3 Evaluation indicators of experiment 2

模型	RMSE/MW	MAE/MW	MAPE/%	R^2 /%
6	6.47	4.31	6.28	98.62
7	8.14	5.91	7.46	97.81
8	6.69	4.79	6.31	98.53
9	8.73	5.83	8.67	97.49
10	7.49	5.48	7.15	98.14

(1)与模型6采用的DBO算法相比,模型7与模型8的RMSE, MAE, MAPE指标均有不同程度的上升,而 R^2 分别下降了0.82%和0.09%。这一结果表明,在VMD分解与模型性能提升方面,PSO算法和WOA算法的优化效果不及DBO算法, DBO在该场景下展现出更优的全局搜索能力与预测适应性。

(2)在模型6的基础上引入注意力机制构建模型9后,其RMSE, MAE, MAPE分别上升了34.87%, 35.26%, 38.18%, R^2 下降了1.15%。结果显示,注意力机制在该模型结构中未能发挥正向作用,反而抑制了其性能。这表明提升预测精度并非依赖于模型结构的简单堆叠,过度复杂化可能扰乱序列特征的表达,进而削弱模型的整体性能。

(3)与模型6相比,模型10的RMSE, MAE, MAPE分别上升了15.77%, 27.15%, 13.85%, R^2 下降了0.49%。结果表明,相较于模型10, TCN-BiGRU结构在短期风电功率预测任务中表现更为优越,具有更强的时序建模能力与泛化性能。

通过上述两组对比试验可知,本文所提模型在结构设计及优化算法方面实现了良好的平衡,预测精度最高,各项评价指标均最优。该模型通过融合优化后的VMD二次模态分解与深度学习方法,在风电功率预测任务中表现出较强的适用性,验证了其

在复杂非线性时序建模中的有效与可靠。

5 结论

本文提出的基于CEEMDAN-DBO-VMD-TCN-BiGRU的短期风力发电预测模型在保持结构协同的基础上,实现了分量识别与趋势建模的有机融合。为验证该混合模型在风电功率预测方面的有效性和优越性,采用10个不同模型分别进行了两组对比试验,选取新疆某风电场的风电功率数据进行短期预测,得出以下结论。

(1)与单一分解方法相比,将CEEMDAN的自适应噪声注入与VMD的带宽优化相结合的双分解方法显著提高了精确值计算的效率;使用DBO算法对VMD参数寻优,提升了模型的稳定性和泛化能力。

(2)通过计算SE值并结合K-means聚类方法将各个模态分量划分为高频、中频、低频3种频段,增强了从原始序列分量中提取特征的能力。

(3)为验证DBO算法的优越性,将CEEMDAN-DBO-VMD-TCN-BiGRU模型中的DBO分别替换成PSO和WOA算法进行预测试验,结果表明,CEEMDAN-DBO-VMD-TCN-BiGRU模型具有较高的稳定性和鲁棒性。

(4)相较于CNN-BiLSTM模型,TCN-BiGRU模型的MAPE, RMSE, MAE指标全面优化,且 R^2 上升了0.49%。因此,针对风电功率预测这类复杂、非平稳、多尺度依赖的时间序列问题,TCN-BiGRU相比CNN-BiLSTM更具优势。

(5)为进一步验证叠加模型数量对预测精度影响,对CEEMDAN-DBO-VMD-TCN-BiGRU模型加入了注意力机制,结果显示:RMSE, MAE, MAPE分别提高了34.87%, 35.26%, 38.18%, R^2 下降了1.15%,在所用对比模型中预测精度最差。因此,提高模型预测性能并不是依靠单纯堆叠模型数量,选择合适组合模型才能充分发挥每个子模型的优势。

参考文献:

[1] 国家能源局. 新型电力系统发展蓝皮书[EB/OL]. (2023-10-10)[2025-06-28]. http://www.nea.gov.cn/2023-06/02/c_1310724249.htm.

[2] 薛禹胜, 雷兴, 薛峰, 等. 关于风电不确定性对电力系统影响的评述[J]. 中国电机工程学报, 2014, 34(29): 5029-5040.

XUE Yusheng, LEI Xing, XUE Feng, et al. A review on impacts of wind power uncertainties on power systems [J]. Proceedings of the CSEE, 2014, 34(29): 5029-5040.

[3] 郁琛, 薛禹胜, 文福拴, 等. 风电功率预测误差的风险评

估[J]. 电力系统自动化, 2015, 39(7): 52-58.

YU Chen, XUE Yusheng, WEN Fushuan, et al. Risk assessment of wind power prediction errors [J]. Automation of Electric Power Systems, 2015, 39(7): 52-58.

[4] ZHANG R X, ZHU Z Y, YUAN M, et al. Regional residential short-term load-interval forecasting based on SSA-LSTM and load consumption consistency analysis [J]. Energies, 2023, 16(24): 8062.

[5] 唐新姿, 顾能伟, 黄轩晴, 等. 风电功率短期预测技术研究进展[J]. 机械工程学报, 2022, 58(12): 213-236.

TANG Xinzi, GU Nengwei, HUANG Xuanqing, et al. Progress on short term wind power forecasting technology [J]. Journal of Mechanical Engineering, 2022, 58(12): 213-236.

[6] 张冬冬, 单琳珂, 刘天皓. 人工智能技术在风力与光伏发电数据挖掘及功率预测中的应用综述[J]. 综合智慧能源, 2025, 47(3): 32-46.

ZHANG Dongdong, SHAN Linke, LIU Tianhao. Review on the application of artificial intelligence in data mining and wind and photovoltaic power forecasting [J]. Integrated Intelligent Energy, 2025, 47(3): 32-46.

[7] HUANG J T, QIN J, SONG S Z. A novel wind power outlier detection method with support vector machine optimized by improved Harris hawk [J]. Energies, 2023, 16(24): 7998.

[8] JIN T Y, XIA Y, JIANG H L. A physics-informed neural network approach for surrogating a numerical simulation of fractured horizontal well production prediction [J]. Energies, 2023, 16(24): 7948.

[9] HUANG A Z, XU R, CHEN Y, et al. Research on multi-label user classification of social media based on ML-KNN algorithm [J]. Technological Forecasting and Social Change, 2023, 188: 122271.

[10] 郭威, 孙胜博, 陶鹏, 等. 基于多元变分模态分解和混合深度神经网络的短期光伏功率预测[J]. 太阳能学报, 2024, 45(4): 489-499.

GUO Wei, SUN Shengbo, TAO Peng, et al. Short-term photovoltaic power forecasting based on multivariate variational mode decomposition and hybrid deep neural network [J]. Acta Energetica Sinica, 2024, 45(4): 489-499.

[11] SUN W, HUANG C C. A carbon price prediction model based on secondary decomposition algorithm and optimized back propagation neural network [J]. Journal of Cleaner Production, 2020, 243: 118671.

[12] SAHU P K, RAI R N, PATEL N. Deep learning-based fault classification of rolling bearings under noisy conditions using CEEMD-VMD-IMF with magnitude scalogram images [J]. Journal of Mechanical Science and Technology, 2024, 38(10): 5281-5295.

[13] 岳有军, 刘英翰, 赵辉, 等. 基于CEEMDAN-SE和DBN的短期电力负荷预测[J]. 电测与仪表, 2020, 57(17):

- 59–65.
YUE Youjun, LIU Yinghan, ZHAO Hui, et al. Short-term load forecasting based on CEEMDAN-SE and DBN [J]. *Electrical Measurement & Instrumentation*, 2020, 57(17): 59–65.
- [14] 胡锐, 乔加飞, 李永华, 等. 基于 WOA-VMD-SSA-LSTM 的中长期风电预测[J]. *太阳能学报*, 2024, 45(9): 549–556.
HU Rui, QIAO Jiafei, LI Yonghua, et al. Medium and long term wind power forecast based on WOA-VMD-SSA-LSTM [J]. *Acta Energetica Solaris Sinica*, 2024, 45(9): 549–556.
- [15] PEI Y, HUANG C J, SHEN Y, et al. A novel model for spot price forecast of natural gas based on temporal convolutional network [J]. *Energies*, 2023, 16(5): 2321.
- [16] 黄冬梅, 杨旭, 胡安铎, 等. 基于 CNN-BiGRU-XGBoost 的新型电力系统虚假数据注入攻击检测[J]. *电网技术*, 2025, 49(5): 2119–2127.
HUANG Dongmei, YANG Xu, HU Anduo, et al. Detection of false data injection attack in new power system based on CNN-BiGRU-XGBoost [J]. *Power System Technology*, 2025, 49(5): 2119–2127.
- [17] JIANG Z Y, CHE J X, WANG L N. Ultra-short-term wind speed forecasting based on EMD-VAR model and spatial correlation [J]. *Energy Conversion and Management*, 2021, 250: 114919.
- [18] 韩焯宸, 贺兴, 艾芊. 基于 GRU-EEMD 算法的非侵入式配电网功率欠定盲源分离[J]. *电力系统自动化*, 2023, 47(14): 64–71.
HAN Yechen, HE Xing, AI Qian. Non-intrusive underdetermined blind power source separation for distribution network based on gate recurrent unit and ensemble empirical mode decomposition algorithm [J]. *Automation of Electric Power Systems*, 2023, 47(14): 64–71.
- [19] ZHANG G, ZHANG C C, ZHANG H Y. Improved K-means algorithm based on density Canopy [J]. *Knowledge-based Systems*, 2018, 145: 289–297.
- [20] 钟燕, 王军, 宋戈, 等. 基于二次重构分解去噪及双向长短时记忆网络的极端天气下超短期电力负荷预测[J/OL]. *电网技术*, 2024: 1–15 (2024–09–11) [2025–06–28]. <https://link.cnki.net/doi/10.13335/j.1000-3673.pst.2024.0935>.
ZHONG Yan, WANG Jun, SONG Ge, et al. Ultra-short-term power load prediction under extreme weather based on secondary reconstruction denoising and BiLSTM [J/OL]. *Power System Technology*, 2024: 1–15 (2024–09–11) [2025–06–28]. <https://link.cnki.net/doi/10.13335/j.1000-3673.pst.2024.0935>.
- [21] 方朝雄, 郑洁云, 张章煌, 等. 基于相似日与 VMD-DBO-KELM 的分布式光伏发电功率预测方法[J]. *高电压技术*, 2025, 51(7): 3477–3487.
FANG Chaoxiong, ZHENG Jieyun, ZHANG Zhanghuang, et al. Distributed photovoltaic power prediction based on similar day and VMD-DBO-KELM [J]. *High Voltage Engineering*, 2025, 51(7): 3477–3487.
- [22] 范兴明, 许洪华, 李涛, 等. 基于 SMA-VMD 和能量熵的高压断路器故障诊断[J]. *高电压技术*, 2024, 50(12): 5248–5258.
FAN Xingming, XU Honghua, LI Tao, et al. Fault diagnosis of high-voltage circuit breakers based on SMA-VMD and energy entropy [J]. *High Voltage Engineering*, 2024, 50(12): 5248–5258.
- [23] 盛瑞祥, 张啸宇. 基于概率 TCN-Transformer 的短期光伏功率预测模型[J]. *综合智慧能源*, 2024, 46(11): 10–18.
SHENG Ruixiang, ZHANG Xiaoyu. Photovoltaic power forecasting model based on probabilistic TCN-Transformer [J]. *Integrated Intelligent Energy*, 2024, 46(11): 10–18.
- [24] DUAN Y C, LI P, XIA J. Prediction and scheduling of multi-energy microgrid based on BiGRU self-attention mechanism and LQPSO [J]. *Global Energy Interconnection*, 2024, 7(3): 347–361.
- [25] 宋江涛, 崔双喜, 樊小朝, 等. 基于 SGMD-SE 与优化 TCN-BiLSTM/BiGRU 的超短期风功率预测[J]. *太阳能学报*, 2024, 45(10): 588–596.
SONG Jiangtao, CUI Shuangxi, FAN Xiaochao, et al. Ultra-short-term wind power prediction based on SGMD-SE and optimized TCN-BiLSTM/BiGRU [J]. *Acta Energetica Solaris Sinica*, 2024, 45(10): 588–596.

(本文责编:刘芳)

收稿日期: 2025-07-03; 修回日期: 2025-09-05
 上网日期: 2026-01-07; 附录网址: www.ienergy.cn

作者简介:

陈旭东(2000), 男, 硕士生, 从事功率预测方面的研究, 2741928845@qq.com;

卞礼杰(2002), 男, 硕士生, 从事功率预测方面的研究, 2239749260@qq.com;

马刚(1984), 男, 教授, 博士, 从事新能源发电及入网技术等方面的研究, nnumg2@nynu.edu.cn;

陈浩(2000), 男, 硕士生, 从事综合能源系统优化调度方面的研究, 3312266385@qq.com;

詹孝升(2002), 男, 硕士生, 从事功率预测方面的研究, 1478604982@qq.com;

彭乐瑶(2001), 女, 硕士生, 从事功率预测方面的研究, 1519393180@qq.com。

*为通信作者。