

DOI: 10. 3969/j. issn. 2097-0706. 2025. 09. 004

基于模态二次分解和 OOA-CNN-BiLSTM-Attention 的光伏发电功率组合预测

Hybrid prediction of photovoltaic power generation based on modal secondary decomposition and OOA-CNN-BiLSTM-Attention

李祯, 杨国华*, 张元曦, 马鑫, 杨娜, 刘浩睿, 马龙腾
LI Zhen, YANG Guohua*, ZHANG Yuanxi, MA Xin, YANG Na,
LIU Haorui, MA Longteng
(宁夏大学 电子与电气工程学院, 银川 750021)

(School of Electronic and Electrical Engineering, Ningxia University, Yinchuan 750021, China)

摘要: 由于太阳辐射的间歇性和不稳定性, 光伏发电功率具有较高的随机性和波动性, 给电网的稳定运行带来了挑战。为提高预测精度, 采用带自适应噪声的完全集合经验模态分解对光伏发电功率数据进行分解, 得到不同频率的本征模态分量; 基于样本熵对这些分量进行 K -means 聚类, 划分为高频、中频和低频分量, 然后进一步对高频分量采用变分模态分解进行细化分解; 结合卷积神经网络 (CNN)、双向长短期记忆网络 (BiLSTM) 和注意力 (Attention) 机制构建了复合深度学习预测模型, 并利用鱼鹰优化 (OOA) 算法对超参数进行优化。试验结果显示, 所提基于模态二次分解和 OOA-CNN-BiLSTM-Attention 的组合预测模型的均方根误差为 4.11 kW, 平均绝对误差为 2.88 kW, 平均绝对百分比误差为 3.08%, 决定系数为 98.89%, 优于其他模型, 表明该方法能够有效捕捉光伏发电功率的多尺度特征, 具有较强的泛化能力和应用潜力。

关键词: 光伏功率预测; 模态分解; 卷积神经网络; BiLSTM 神经网络; 注意力机制

中图分类号: TK 519 文献标志码: A 文章编号: 2097-0706(2025)09-0028-10

Abstract: Due to the intermittency and instability of solar radiation, photovoltaic (PV) power generation shows high randomness and fluctuation, posing challenges to the stable operation of power grids. To improve prediction accuracy, the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) was applied to decompose PV power data into intrinsic mode functions (IMFs) with different frequencies. These IMFs were clustered using K -means based on sample entropy, categorizing into high-, medium-, and low-frequency components. The high-frequency components were further decomposed using variational mode decomposition (VMD) for refined analysis. A hybrid deep learning prediction model was established by integrating convolutional neural network (CNN), bidirectional long short-term memory (BiLSTM) network, and attention mechanism. The osprey optimization algorithm (OOA) was employed to optimize the model's hyperparameters. The experimental results showed that the proposed hybrid prediction model based on modal secondary decomposition and OOA-CNN-BiLSTM-Attention achieved a root mean square error of 4.11 kW, a mean absolute error of 2.88 kW, a mean absolute percentage error of 3.08%, and a coefficient of determination of 98.89%, outperforming other models. It is demonstrated that the proposed method effectively captures the multi-scale features of PV power generation with strong generalization ability and application potential.

Keywords: photovoltaic power prediction; modal decomposition; convolutional neural network; BiLSTM neural network; attention mechanism

0 引言

随着气候变化和全球能源需求的增长, 减少碳排放、提升可再生能源利用率成为全球面临的共同挑战。光伏发电作为一种清洁、可再生的绿色能源备受瞩目^[1-2], 但其输出功率受太阳辐射波动影响较

基金项目: 宁夏回族自治区自然科学基金项目 (2023AAC03853); 宁夏大学研究生创新项目 (CXXM2025087)
Ningxia Hui Autonomous Region Natural Science Foundation Project (2023AAC03853); Ningxia University Graduate Innovation Project (CXXM2025087)

大,具有显著的随机性,这种不确定性为电网的安全和稳定运行带来很大的挑战^[3-4]。因此,提高光伏发电功率预测精度对优化电力系统调度、减少功率波动影响以及提高新能源利用率具有重要意义^[5]。

目前,光伏发电功率的预测方法主要分为物理模型方法和数据驱动模型方法^[6]。物理模型方法基于光伏系统的结构、组件特性及气象条件进行预测,能够较好地描述光伏系统的物理特性,但往往需要大量的现场测量数据,并且建模过程复杂^[7]。相比之下,数据驱动模型通过分析历史数据中的复杂关系,在较少先验知识的条件下也能实现对光伏发电功率的高精度预测^[8]。因此,近年来基于机器学习和深度学习的预测方法逐渐成为研究热点,例如人工神经网络、循环神经网络、门控循环单元、卷积神经网络(Convolutional Neural Network, CNN)、长短期记忆(Long Short-Term Memory, LSTM)网络^[9-10]、支持向量机、极限学习机^[11]等方法,均在光伏功率预测中展现了较好的应用前景。尽管深度学习在处理非线性和时序数据方面表现出强大的能力,但光伏发电数据的多尺度特性及噪声问题,给单一深度学习模型带来了很大的挑战^[12]。为了应对这一问题,模态分解结合组合预测模型方法逐渐被引入光伏发电功率预测中,先将复杂的非平稳信号分解为多个本征模态分量(Intrinsic Mode Function, IMF),然后再进行建模与预测,以进一步提高预测精度^[13-14]。

文献[15]采用变分模态分解(Variational Mode Decomposition, VMD)方法分解光伏功率数据的不同频率成分,以提取多尺度特征并减弱数据的不平稳性。文献[16]采用了完全集合经验模态分解,将分解得到的模态分量输入预测模型,从而捕捉多尺度特性。文献[17]则通过带自适应噪声的改进完全集合经验模态分解减少了噪声干扰和模态混叠,使分解后的模态分量更为纯净。这些研究在数据的多频率分解和多尺度特征提取方面取得了一定成效,一定程度上能够提高光伏功率预测的准确性。然而,现有分解方法对高频成分的精细化处理仍存在模态混叠或噪声残留问题,单一的分解方法通常对高频成分缺乏进一步细化,使得高频模态中的细微特征未得到充分挖掘,尤其在复杂天气条件下,无法充分提取高频波动中的有效信息,导致模型对短期变化的捕捉能力不足。文献[18]使用LSTM网络挖掘时序特征,虽在长时间依赖建模方面有优势,但对短期波动捕捉不佳。文献[19]采用反向传播(Back Propagation, BP)神经网络进行预测,尽管优化了模型性能,但其对非平稳性和时序依赖敏感

性较低,易陷入局部最优,影响预测的准确性。文献[20]采用支持向量回归捕捉光伏功率的非线性关系,但对时间依赖性处理不足,难以应对复杂波动。

综上所述,单纯依赖模态分解难以捕捉非线性时序特征,用单个预测算法难以做到精准建模,无法实现高精度预测。为此,本文首先利用带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)对光伏功率数据进行多尺度分解并提取本征模态分量;其次,基于样本熵将IMF聚类划分为高频、中频和低频分量,对高频分量进一步采用VMD细化分解以提取精细频率特征,然后利用CNN提取局部特征,采用双向长短期记忆网络(Bidirectional Long Short-Term Memory, BiLSTM)捕捉时序依赖,引入注意力(Attention)机制增强关键特征识别进行预测,最后利用鱼鹰优化算法(Osprey Optimizer Algorithm, OOA)优化模型超参数,以进一步提升模型性能和泛化能力。

1 模态二次分解

1.1 CEEMDAN分解

经验模态分解(Empirical Mode Decomposition, EMD)是一种自适应信号分解方法,将复杂信号分解为多个固有模态函数,每个分量代表信号在特定时间尺度上的振荡特性^[21]。集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)通过向信号添加白噪声进行多次分解,然后对结果取平均,从而减少模态混叠和噪声影响,提升分解的稳定性^[22]。CEEMDAN则是在EEMD基础上引入自适应噪声,经过多次迭代改进,进一步解决了噪声残留和模态混叠问题,使分解结果更加准确,尤其适用于复杂的非平稳信号分析^[23-24]。CEEMDAN通过向原始信号加入噪声来减少模态混叠问题,给定信号 $x(t)$,加入噪声后,CEEMDAN的分解过程为

$$x(t) + \varepsilon_n \omega_n = \mu_1 + r_1, \quad (1)$$

式中: ε_n 为白噪声幅值; ω_n 为噪声信号; μ_1 为第1个本征模态函数; r_1 为剩余部分的残差信号。

然后继续分解残差信号 r_1

$$r_1 + \varepsilon_n \omega_n = \mu_2 + r_2. \quad (2)$$

这个过程会持续迭代,直至残差信号的能量小于原始信号总能量的1%或已分解出的分量数量达到预设阈值(超过12个则停止分解)。通过这种分解,可以将复杂的非平稳信号转化为多个相对简单的成分,降低后续建模的难度。

1.2 K-means 聚类算法

K-means 聚类是一种无监督机器学习算法,用于将数据集划分为若干个相互独立的簇^[25]。本文利用 K-means 聚类对计算出的 IMF 分量的样本熵进行分类,将 IMF 分量划分为高频、中频和低频 3 类。高频分量主要反映信号中的短期剧烈变化和噪声,而中频和低频分量则分别代表较长时间尺度的周期性变化和趋势变化。通过对不同类型的分量进行分类,可以在后续的建模中采取不同的处理策略,从而提高模型的预测精度。

1.3 样本熵

样本熵是一种用来度量时间序列复杂度的指标,能够量化信号的无序程度,公式为

$$\text{SampEn}(m, r) = -\ln\left(\frac{A}{B}\right), \quad (3)$$

式中: m 为嵌入维度; r 为相似度容限(通常为信号标准差的 0.10~0.25 倍); A 为满足距离条件 $\|x_i - x_j\| < r$ 的 $m+1$ 维向量对的数量; B 为满足距离条件的 m 维向量对的数量。

样本熵越大,说明信号的复杂度和不规则程度越高。本文利用样本熵来分析各个 IMF 分量的复杂程度,以便对其进行合理的分类和处理。通过样本熵的计算,可以有效地将 IMF 分量划分为高频、中频和低频等不同类型的,从而在后续建模过程中采用针对性策略。

1.4 VMD

VMD 是一种基于变分理论的自适应信号分解方法,它通过最小化每个模态的带宽来实现分解,可以指定分解得到的 IMF 个数^[26-27]。给定信号 $x(t)$, VMD 通过最小化以下目标函数进行模态分解

$$\min_{\{\mu_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + j \frac{1}{\pi t} \right) * \mu_k(t) e^{-j\omega_k t} \right] \right\|_2^2 \right\}, \quad (4)$$

式中: $\mu_k(t)$ 为第 k 个模态分量; ω_k 为对应的中心频率; ∂_t 为时间导数; $*$ 表示卷积操作。

VMD 的一个重要特点是其分解过程是在频率域内进行优化的,这样可以更好地控制每个模态的频率分布,从而有效捕捉信号中的细微频率变化。VMD 在高频信号的细化分解中表现优异,因此在对光伏发电功率的高频波动分析中具有重要作用。

采用模态分解方法可以有效地将光伏功率数据分解为不同频率的子序列,然而仅依赖模态分解难以充分提取高频分量的时序特征,影响短期预测精度。因此,为进一步提升高频分量的表征能力,本文构建复合深度学习模型,将模态分解与组合预测方法相结合,充分挖掘各频率成分的时序信息。

2 预测模型原理

2.1 OOA

超参数的选择对深度学习模型性能至关重要,但手动调节超参数不仅耗时,而且难以找到全局最优解。本文采用 OOA 自动优化模型的学习率、卷积核大小、LSTM 神经元数量等超参数。OOA 是一种模拟鱼鹰捕猎行为的全局优化算法,具有较强的全局搜索能力和较快的收敛速度。

2.2 CNN

CNN 最初用于图像识别任务,近年来在处理时间序列数据方面也取得了显著的成功^[28]。本文采用 CNN 从经过模态分解后的输入特征中提取局部信息。具体来说,卷积层通过滑动卷积核提取不同尺度的特征,池化层则用于减少特征的维度,避免过拟合。通过多层卷积和池化操作, CNN 能够有效提取输入数据中的局部特征,进而为后续的 LSTM 部分提供高质量的特征信息。

2.3 BiLSTM 网络

LSTM 网络是一种专门用于处理序列数据的循环神经网络,能够有效缓解梯度消失和梯度爆炸问题。BiLSTM 网络通过同时利用正向和反向两个 LSTM 层,能够更好地捕捉序列数据中的前后依赖信息^[29]。LSTM 结构如图 1 所示,分为遗忘门、输入门、输出门。




图 1 LSTM 网络结构

Fig. 1 Structure of LSTM network

遗忘门公式为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f), \quad (5)$$

式中: f_t 为遗忘门保留结果; σ 为激活函数; W_f 为权重矩阵; h_{t-1} 为上一时刻的输出; x_t 为当前时刻的输入; $[h_{t-1}, x_t]$ 为 x_t 顺序连接在 h_{t-1} 后形成的新向量; b_f 为偏置向量。

输入门公式为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i), \quad (6)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c), \quad (7)$$

式中: i_t 为当前时刻状态的添加结果; $\tilde{C}_t$ 为当前时刻的中间状态; W_i 和 W_c 为各自的权重矩阵; b_i 和 b_c 为

各自的偏置向量。

更新单元状态公式为

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t, \quad (8)$$

式中: C_t 为当前时刻的状态; C_{t-1} 为上一时刻的状态; $\otimes$ 表示向量点乘。

输出门公式为

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o), \quad (9)$$

$$h_t = o_t \otimes \tanh(C_t), \quad (10)$$

式中: o_t 为输出程度值; W_o 为权重矩阵; b_o 为偏置向量; h_t 为当前时刻的输出。

BiLSTM 通过同时运行前向 LSTM 和后向 LSTM 来处理时间序列的前后信息, 结构如图 2 所示。BiLSTM 的输出由前向 LSTM 隐状态 $\vec{h}_t$ 和后向 LSTM 隐状态 $\tilde{h}_t$ 组合而成

$$h_t = [\vec{h}_t; \tilde{h}_t]. \quad (11)$$




图 2 BiLSTM 网络结构

Fig. 2 Structure of BiLSTM network

在光伏发电功率预测中, 未来功率值的变化不仅与过去的信息相关, 还可能与后续的信息存在联系, 因此 BiLSTM 比单向 LSTM 更适用于该任务。

2.4 Attention 机制

Attention 机制通过为输入序列中的每个时间步分配一个重要性权重, 使得模型可以更加关注那些对预测结果影响更大的时间步, 其公式为

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (12)$$

式中: Q 为查询向量; K 为键向量; V 为值向量; d_k 为键向量的维度。

在光伏发电功率预测中, 不同时间步的数据对最终预测结果影响不同, Attention 机制可帮助模型自适应地选择更有价值的信息, 从而提升整体预测性能。Attention 机制通过计算输入序列的加权和, 使模型能够聚焦于对预测任务具有判别性的关键特征, 从而提高对复杂非线性关系的建模能力。

3 短期光伏功率组合预测模型

3.1 预测模型整体结构

输入层: 将经过数据处理和分解后的特征矩阵

输入模型。输入特征包含多尺度的模态分量, 能够反映光伏发电功率的不同频率特征。

卷积层与池化层: 输入特征首先通过若干卷积层和池化层, 以提取局部特征。这些特征被用作后续 LSTM 层的输入。

BiLSTM 层: 卷积层输出的特征被传递到 BiLSTM 层, 以捕捉时间序列中的前后依赖信息。双向结构确保模型能够同时利用过去和未来的信息, 从而提高预测效果。

注意力层: BiLSTM 的输出经过注意力层, 以便模型更加关注重要的时间步。通过 Attention 机制, 模型能够动态调整对不同时间步的关注程度, 从而提升预测性能。

全连接层与输出层: 经过 Attention 层的输出通过全连接层进行处理, 全连接层的输出被映射到最终的功率预测值。输出层用于提供单步预测结果, 即光伏发电功率的预测值。

超参数优化: 通过 OOA 对模型中的关键超参数进行优化, 以获得最佳的预测性能。

3.2 预测流程及步骤

整体预测流程如图 3 所示, 主要预测步骤如下。




图 3 整体预测流程

Fig. 3 Overall prediction process

(1) 对光伏发电数据进行预处理, 并通过特征筛选提取与功率预测相关的特征因素。

(2) 使用 CEEMDAN 将原始信号分解为多个本征模态函数。

(3) 对 IMF 分量计算样本熵, 并使用 K-means 将

分量划分为高频、中频、低频 3 类。

(4)对高频分量进行 VMD 分解,进一步细化信号的高频成分。

(5)结合 CNN 提取局部特征、BiLSTM 捕捉时序依赖, Attention 机制增强对关键特征的关注,使用 OOA 优化超参数。

(6)对各分量的预测结果进行相加重构,最后进行模型效果评估。

4 算例分析

4.1 数据来源及预处理

本文使用宁夏某光伏电站 2019-03-01—05-31 T 08:00—20:00 的测量数据进行预测研究。该光伏电站数据采样时间间隔为 15 min,包含温度、云层不透明度、露点温度、太阳散射辐射、太阳直接辐射、太阳总水平辐射、跟踪倾角辐射、大气可降水量、相对湿度、地面气压、风向、风速 12 个特征因素。

首先对光伏数据集进行预处理,主要是缺失值和异常值处理。缺失值以前后 3 天同一时间节点的数据均值来填补。采用 3σ 原则筛选异常值,即将误差超出 $[\mu - 3\sigma, \mu + 3\sigma]$ (其中 μ 为均值; σ 为标准差)的数值视为异常值,将识别出的异常值当成缺失值处理。

为了保证试验的科学性和预测模型的泛化能力,数据集被分为训练集和测试集,其中 80% 数据用于模型的训练,20% 数据用于测试。模型采用 Matlab 2023b 进行编程实现,所有试验在 Intel i7-8750 CPU 和 16 GB 内存的环境下完成。

4.2 特征因素筛选

为了提高光伏发电功率预测的准确性,首先需要从众多的环境和运行参数中筛选出与发电功率密切相关的特征因素。采用皮尔逊相关系数来衡量各个特征与光伏发电功率之间的线性关系,见表 1。

由表 1 可以看出,太阳辐射类的特征有 4 类,这些特征之间的高度相关性会导致预测模型受到多重共线性的影响,进而影响预测精度,为避免此问题,选择与光伏功率相关性最高的太阳总水平辐射这一因素作为代表特征,另外选择相关系数绝对值较大的温度、云层不透明度、相对湿度作为输入用于后续的建模和分析,以减少冗余特征对模型性能的负面影响。

4.3 模态二次分解

采用 CEEMDAN 对原始光伏发电功率数据进行分解,得到若干个 IMF 分量,如图 4 所示。这些分量

表 1 特征因素的皮尔逊相关系数

特征	皮尔逊相关系数
温度	0.36
云层不透明度	0.62
露点温度	0.11
太阳散射辐射	0.44
太阳直接辐射	0.77
太阳总水平辐射	0.99
跟踪倾角辐射	0.91
大气可降水量	0.10
相对湿度	0.38
地面气压	0.02
风向	0.04
风速	0.04

从高频到低频排列,反映信号中的短期波动与长期趋势。通过对不同频率分量的分析,可以更加精准地提取信号特征并进行后续处理。




图 4 CEEMDAN 处理结果

Fig. 4 CEEMDAN processing results

计算每个 IMF 分量的样本熵,如图 5 所示。由图 5 可见,各 IMF 分量的样本熵差异较大,从高频分量的 1.388 3 到低频分量的 0.000 2 不等,表明高频成分通常具有更复杂的动态结构,而低频成分则较为平稳。

在此基础上,参考样本熵,以样本熵 ≥ 0.6 为高频,样本熵 ≤ 0.2 为低频,其余为中频作为 K-means 聚类的依据进行划分,得到高频 IMF1—IMF4,中频 IMF5—IMF6,低频 IMF7—IMF13 这 3 种不同层级的




图 5 CEEMDAN 分解后各分量的样本熵
Fig. 5 Sample entropy of different components decomposed by CEEMDAN

频分量,如图 6 所示。聚类后的各类样本熵值为:高频分量 1.068 3,中频分量 0.401 9,低频分量 0.065 0。这一分类过程能够在后续处理时对不同频率分量采用不同策略,有助于提升模型的预测性能。




图 6 K-means 聚类后的 IMF 组合
Fig. 6 IMF groups after K-means clustering

为了进一步提取高频分量中的关键特征信息,对高频分量使用 VMD 进行细化分解并计算其各分量的样本熵值,分解个数 K 定为 3,如图 7 所示。




图 7 VMD 分解后的高频分量及中低频分量
Fig. 7 High-frequency and medium/low-frequency components decomposed by VMD

在 VMD 分解后,细化的高频分量样本熵值从原来的 1.068 3 降至 0.374 3,0.439 7,0.488 2。这一显著降低表明,通过 VMD 分解,高频分量的复杂动态特征被进一步分离,转化为更简单且较平稳的频率分量。这种样本熵值的下降反映了高频分量中噪声和多尺度特征的有效分解,使每个分量中的频率特征更加清晰和纯粹,有助于增强后续深度学习模型的特征识别能力。

4.4 预测结果分析

在模型训练阶段,采用 OOA 对模型超参数进行优化,以确保模型的最佳性能,优化后模型关键参数见表 2。

表 2 OOA 优化后的 LSTM 网络超参数	
Table 2 Hyperparameters of LSTM network optimized by OOA	
参数	数值
学习率	0.004 138 4
LSTM 层神经元数	39
L2 正则化系数	0.000 401 5
最大训练轮数	10

为进一步说明模型训练过程中超参数优化的过程与效果,本文以高频分量 IMF 2 为例,展示其在 OOA 优化下的进化曲线,如图 8 所示。由图 8 可以看出,优化过程中模型均方误差 (Mean-Square Error, MSE) 逐步下降并趋于稳定,表明优化过程具有良好的收敛性与稳定性,从侧面验证了本文所构建模型结构和优化机制的合理性与有效性。




图 8 OOA 优化下的进化曲线 (IMF 2)
Fig. 8 Evolution curve under OOA optimization (IMF 2)

为评估并验证所用方法的优越性,本文将所提组合预测模型与其他几种预测模型进行对比试验。

模型 1:直接将数据输入 CNN-BiLSTM 模型进行预测。

模型 2:数据经过 CEEMDAN 和 VMD 分解后,输入 CNN-BiLSTM 模型进行预测。

模型 3:在模型 2 的基础上增加 Attention 部分。

模型 4:数据只用 CEEMDAN 分解后,输入到 CNN-BiLSTM-Attention 模型进行预测。

模型 5:数据只用 VMD 分解后,输入到 CNN-BiLSTM-Attention 模型进行预测。

模型 6:在模型 3 的基础上增加 OOA 优化算法进行优化,即本文所提模型。

由图 9 可以看到,模型 6 的预测曲线与实际光伏发电功率的变化趋势基本一致,能够较好地捕捉到发电功率的高频波动和低频趋势。这得益于模态分解方法有效地将复杂信号分解为多尺度特征,使得模型能够分别对不同尺度的特征进行建模;同时,CNN-BiLSTM-Attention 模型对局部特征和时间序列依赖性的准确捕捉,进一步提高了对功率波动的预测精度,Attention 机制的引入,使模型能够更好地聚焦于关键时刻的特征变化,从而使预测结果更加接近实际观测值。总体而言,模型在处理非平稳信号和多频率成分方面的优势明显,从而提升了光伏发电功率预测的精度和稳定性。




图 9 测试集预测值与真实值对比

Fig. 9 Comparison between predicted and actual values on test set

为了验证模型的有效性,本文将预测结果与实际测量的光伏发电功率进行对比,并计算多种评估指标,包括决定系数(R^2)、均方根误差(Root Mean Squared Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)以及平均绝对百分比误差(Mean Absolute Percentage Error, MAPE),误差分析结果见表 3。

模型 1 直接将原始数据输入 CNN-BiLSTM 模型进行预测,未进行信号分解,结果显示其 RMSE 为 6.45kW, MAE 为 5.21 kW, MAPE 为 15.74%, R^2 为 96.33%,表明在未进行分解的情况下,模型难以有效处理复杂的时序数据。相比之下,模型 2 通过 CEEMDAN 和 VMD 分解数据后,预测精度显著提升, RMSE 降至 4.66 kW, R^2 提升至 98.40%,说明信

表 3 不同模型的误差指标对比

Table 3 Comparison of error indicators among different models

模型	MAE/kW	MAPE/%	R^2 /%	RMSE/kW
1	5.21	15.74	96.33	6.45
2	3.21	12.07	98.40	4.66
3	3.12	10.59	98.50	4.43
4	3.49	11.92	98.32	4.43
5	3.22	11.74	98.46	4.45
6	2.88	3.08	98.89	4.11

号分解可以有效提取多尺度特征,增强模型的表现。模型 3 在模型 2 的基础上加入 Attention 机制后, RMSE 进一步降低至 4.43 kW,表明 Attention 机制通过聚焦关键特征提高了预测精度。

模型 4 和模型 5 分别使用 CEEMDAN 和 VMD 单一分解,也取得了较好的效果,但在部分误差指标上逊色于双分解模型。

模型 6 采用了 OOA 对超参数进行调整,表现最佳, RMSE 为 4.11 kW, MAE 为 2.88 kW, MAPE 仅为 3.08%, R^2 达到了 98.89%,优于其他模型。

总体来看,CEEMDAN 和 VMD 的结合使得模型能够更好地提取不同频率的特征,而 Attention 机制的引入则提升了模型对关键时间步的关注度,OOA 优化算法进一步减少了误差,使得本文提出的双分解模型在光伏发电功率预测中表现出较好的预测精度和稳定性。

为了验证所提预测模型及优化算法相对于其他模型及优化算法的优越性,另做几组对比试验进行分析。

模型 7:与模型 6 的区别在于使用哈里斯鹰优化(Harris Hawks Optimization, HHO)算法进行参数优化。

模型 8:与模型 6 的区别在于采用白鲸优化(Beluga Whale Optimization, BWO)算法进行参数优化。

模型 9:将模型 6 中的 BiLSTM 部分替换为双向门控循环单元(Bidirectional Gated Recurrent UnitBiGRU)模型进行预测。

模型 10:将模型 6 中的 BiLSTM 部分替换为双向时间卷积神经网络(Bidirectional Temporal Convolutional Network, BiTCN)模型进行预测。

模型 11:将模型 6 中的 Attention 部分替换为自适应增强(Adaptive Boosting, Adaboost)模型进行预测。

模型 12:将模型 6 中的 BiLSTM-Attention 部分替换为时空 Transformer(Spatio-Temporal-Transformer, ST-Transformer)模型进行预测。

预测结果如图 10 所示,误差分析结果见表 4。通过对比发现:模型 6 在所有对比模型中表现最为优越;尽管模型 7 的 R^2 接近模型 6,但其 MAE 为 3.00 kW,MAPE 为 11.19%,RMSE 为 4.32 kW,整体精度明显低于模型 6;模型 8 的 MAPE 为 3.28%,RMSE 为 4.53 kW,MAE 为 3.15 kW,精度也不如模型 6;模型 9 的 MAE 略优于模型 6(2.81 kW),但 MAPE 高达 10.95%,且 RMSE 为 4.19 kW,整体精度依然不足;模型 10,11,12 同样未能超越模型 6,尤其是模型 11,其 MAPE 高达 12.67%,RMSE 为 4.33 kW,预测精度远低于模型 6。




图 10 不同模型的预测值与真实值对比

Fig. 10 Comparison between predicted and actual values using different models

表 4 不同模型的误差指标对比

Table 4 Comparison of error indicators among different models

模型	MAE/kW	MAPE/%	R^2 /%	RMSE/kW
7	3.00	11.19	98.58	4.32
8	3.15	3.28	98.45	4.53
9	2.81	10.95	98.71	4.19
10	3.03	11.28	98.57	4.32
11	3.01	12.67	98.56	4.33
12	2.97	5.96	98.77	4.28

各项试验结果表明:模型 6 凭借其最优的多尺度特征捕捉能力和较强的泛化能力,在所有对比模型中表现出最佳的预测精度,验证了本文提出的基于模态分解和深度学习模型的组合方法在光伏发电功率预测中的优越性;同时,该方法能够有效提升光伏发电功率的预测准确性,有较强的实际应用价值。

5 结论

本文提出了一种基于 CEEMDAN-VMD 分解与 OOA-CNN-BiLSTM-Attention 的光伏发电功率预测模型,以宁夏地区某光伏电站实际数据为例进行验证,得到如下结论。

(1)结合 CEEMDAN 和 VMD 分解方法,对光伏发电功率数据进行双重信号分解:CEEMDAN 用于将光伏功率数据分解为多尺度的本征模态分量,有效处理信号的不平稳性和噪声问题。针对高频分量的复杂性,进一步采用 VMD 进行细化分解,从而提取更精细的高频特征。这种二次分解方式弥补了现有单一分解方法对高频信息处理不足的问题,使模型在捕捉短期波动和剧烈变化方面表现更优,为后续模型提供了更加精细的特征输入。

(2)利用样本熵计算各模态分量的复杂度,并结合 K-means 聚类将模态分量划分为高频、中频和低频分量。这一策略能够对不同频率分量进行分类处理,有效避免了直接建模可能引入的干扰,并为高频分量的进一步分解奠定了基础。样本熵的引入,增强了对信号复杂度的量化分析,弥补了现有方法中对分量复杂度识别不足的缺陷。

(3)构建了 CNN-BiLSTM-Attention 的组合预测模型:CNN 用于提取局部特征;BiLSTM 通过双向结构捕捉时间序列的前后依赖关系,提高对动态特征的建模能力;Attention 机制增强了模型对关键时间步的关注,进一步提升了复杂数据的特征表达能力。这种多模块协同的组合设计,充分利用了各个组件的优势,尤其是在捕捉短期波动与长期趋势时表现尤为显著。

(4)从模态分解到深度学习建模,再到优化算法的引入,形成了一个系统的预测框架:模态二次分解提供高质量的特征输入;深度学习模型进行高效建模;优化算法进一步提升模型性能。在面对不同气象条件(本文数据集为整个春季的测量数据,包括晴天、阴天、云层快速变化等情况)所带来的非平稳性和波动性光伏功率数据时,模型能够稳定输出精准预测结果,说明在实际复杂环境下亦具备较强的适应能力。因此,该模型在实际工程中如电力系统调度优化、光伏电站输出平滑控制等方面具有良好的推广与应用前景,展现了不错的泛化能力。

总体来看,该模型通过多种方法的结合,有效提高了光伏发电功率的预测准确性与稳定性。未来可以进一步优化模型的实时性和扩展性,并结合更多外部数据提升其在复杂环境下的应用潜力。

参考文献:

[1]周孝信,陈树勇,鲁宗相,等.能源转型中我国新一代电力系统的技术特征[J].中国电机工程学报,2018,38(7):1893-1904,2205.
ZHOU Xiaoxin, CHEN Shuyong, LU Zongxiang, et al.

- Technology features of the new generation power system in China[J]. Proceedings of the CSEE, 2018, 38(7): 1893–1904, 2205.
- [2]王蓓蓓, 亢丽君, 苗曦云, 等. 考虑可信度的新能源及需求响应参与英美容量市场分析及思考[J]. 电网技术, 2022, 46(4): 1233–1247.
- WANG Beibei, KANG Lijun, MIAO Xiyun, et al. Analysis and enlightenment of renewable energy and demand response participating in UK and US capacity markets considering capacity credibility [J]. Power System Technology, 2022, 46(4): 1233–1247.
- [3]张赞宁, 魏广军. 考虑特征选择的短期光伏功率组合预测模型[J]. 电力系统及其自动化学报, 2024, 36(8): 122–132.
- ZHANG Yunning, WEI Guangjun. Combined prediction model for short-term photovoltaic power considering feature selection [J]. Proceedings of the CSU-EPSA, 2024, 36(8): 122–132.
- [4]SI Z Y, YANG M, YU Y X, et al. Photovoltaic power forecast based on satellite images considering effects of solar position[J]. Applied Energy, 2021, 302: 117514.
- [5]张永宁, 任晓颖, 张飞, 等. 基于深度学习的光伏功率预测技术[J/OL]. 综合智慧能源: 1–8 (2024–04–01) [2025–03–01]. <http://kns.cnki.net/kcms/detail/41.1461.TK.20240328.2244.002.html>.
- ZHANG Yongning, REN Xiaoying, ZHANG Fei, et al. Photovoltaic power forecasting technology based on deep learning [J/OL]. Integrated Smart Energy: 1–8 (2024–04–01) [2025–03–01]. <http://kns.cnki.net/kcms/detail/41.1461.TK.20240328.2244.002.html>.
- [6]朱琼锋, 李家腾, 乔骥, 等. 人工智能技术在新能源功率预测的应用及展望[J]. 中国电机工程学报, 2023, 43(8): 3027–3048.
- ZHU Qiongfeng, LI Jiateng, QIAO Ji, et al. Application and prospect of artificial intelligence technology in renewable energy forecasting[J]. Proceedings of the CSEE, 2023, 43(8): 3027–3048.
- [7]汪鸿, 朱正甲, 陈建华, 等. 基于人工智能技术与物理方法结合的新能源功率预测研究[J]. 高电压技术, 2023, 49(S1): 111–117.
- WANG Hong, ZHU Zhengjia, CHEN Jianhua, et al. Research on new energy power prediction based on artificial intelligence technology and physical method [J]. High Voltage Engineering, 2023, 49(S1): 111–117.
- [8]陈凡, 李智, 丁津津, 等. 考虑光伏机理与数据驱动结合的短期功率预测[J]. 科学技术与工程, 2023, 23(20): 8686–8692.
- CHEN Fan, LI Zhi, DING Jinjin, et al. Consider short-term power prediction combining photovoltaic mechanism and data-driven [J]. Science Technology and Engineering, 2023, 23(20): 8686–8692.
- [9]王东风, 刘婧, 黄宇, 等. 结合太阳辐射量计算与 CNN-LSTM 组合的光伏功率预测方法研究[J]. 太阳能学报, 2024, 45(2): 443–450.
- WANG Dongfeng, LIU Jing, HUANG Yu, et al. Photovoltaic power prediction method combining solar radiation calculation and CNN-LSTM [J]. Acta Energiæ Solaris Sinica, 2024, 45(2): 443–450.
- [10]ALI A, AHMED A, MOUSSA L, et al. CNN-LSTM: An efficient hybrid deep learning architecture for predicting short-term photovoltaic power production [J]. Electric Power Systems Research, 2022, 208: 107908.
- [11]黄牧涛, 邢芳菲, 陈兴邦, 等. 基于 K-means 聚类和极限学习机组合算法的短期光伏功率预测[J]. 水电能源科学, 2024, 42(2): 217–220.
- HUANG Mutao, XING Fangfei, CHEN Xingbang, et al. Short-term PV power prediction based on K-means clustering and extreme learning machine combination algorithm[J]. Water Resources and Power, 2024, 42(2): 217–220.
- [12]马乐乐, 孔小兵, 郭磊, 等. 基于最大重叠离散小波变换和深度学习的光伏功率预测[J]. 太阳能学报, 2024, 45(5): 576–583.
- MA Lele, KONG Xiaobing, GUO Lei, et al. Photovoltaic power forecasting based on maximum overlap discrete wavelet transform and deep learning [J]. Acta Energiæ Solaris Sinica, 2024, 45(5): 576–583.
- [13]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 Energiæ Solaris Sinica, 2024, 45(4): 489–499.
- [14]程先龙, 张杰, 李思莹, 等. 基于 VMD-BP-BiLSTM 的短期风电功率预测[J/OL]. 综合智慧能源: 1–10 (2024–12–12) [2025–03–01]. <http://kns.cnki.net/kcms/detail/41.1461.TK.20241211.1634.002.html>.
- CHENG Xianlong, ZHANG Jie, LI Siying, et al. Short-term wind power prediction based on VMD-BP-BiLSTM [J/OL]. Integrated Intelligent Energy: 1–10 (2024–12–12) [2025–03–01]. <http://kns.cnki.net/kcms/detail/41.1461.TK.20241211.1634.002.html>.
- [15]张海涛, 李文娟, 李雪峰, 等. 基于变分模态分解和时间注意力机制 TCN 网络的光伏发电功率预测[J]. 电测与仪表, 2024, 61(12): 156–163.
- ZHANG Haitao, LI Wenjuan, LI Xuefeng, et al. Photovoltaic power forecasting based on TPA-TCN model and variational modal decomposition [J]. Electrical

- Measurement & Instrumentation, 2024, 61 (12): 156-163.
- [16]梁亚峰,马立红,邱剑洪,等.基于CEEMD-LSTM光伏短期功率预测[J].科学技术与工程,2024,24(13): 5396-5405.
- LIANG Yafeng, MA Lihong, QIU Jianhong, et al. Short-term photovoltaic power forecasting based on CEEMD-LSTM[J]. Science Technology and Engineering, 2024, 24 (13): 5396-5405.
- [17]王瑞,闫豪,逯静.基于ICEEMDAN-MBWO-WKELM短期光伏功率预测[J].电力电子技术,2024,58(2): 59-63.
- WANG Rui, YAN Hao, LU Jing. Short-term photovoltaic power prediction based on ICEEMDAN-MBWO-WKELM [J]. Power Electronics, 2024, 58(2): 59-63.
- [18]袁俊球,王迪,谢小锋,等.基于广义天气分类的ICEEMDAN-LSTM网络光伏发电功率短期预测[J].综合智慧能源,2024,46(9): 53-60.
- YUAN Junqiu, WANG Di, XIE Xiaofeng, et al. Study of short-term PV power prediction based on ICEEMDAN-LSTM networks under generalized weather classifications [J]. Integrated Intelligent Energy, 2024, 46(9): 53-60.
- [19]夏晓荣,胡鹏飞,王飞,等.基于小波变换与优化BP神经网络的超短期光伏发电功率预测[J].电网与清洁能源,2024,40(10): 159-166.
- XIA Xiaorong, HU Pengfei, WANG Fei, et al. Ultra-short-term photovoltaic power prediction based on wavelet transform and optimal BP neural networks [J]. Power System and Clean Energy, 2024, 40(10): 159-166.
- [20]周鑫,李燕,曾永辉,等.基于SARIMAX-SVR的光伏发电功率预测[J].电力系统及其自动化学报,2024,36(5): 1-8.
- ZHOU Xin, LI Yan, ZENG Yonghui, et al. Forecasting of photovoltaic power generation based on SARIMAX-SVR [J]. Proceedings of the CSU-EPSA, 2024, 36(5): 1-8.
- [21]HUANG N, SHEN Z, LONG S, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society A: Mathematical Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [22]WU Z H, HUANG N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method [J]. Advances in Data Science and Adaptive Analysis, 2009, 1 (1): 1-41.
- [23]TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C]// 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Prague: IEEE, 2011: 22-27.
- [24]李芬,孙凌,王亚维,等.基于CEEMDAN-GSA-LSTM和SVR的光伏功率短期区间预测[J].上海交通大学学报,2024,58(6): 806-818.
- LI Fen, SUN Ling, WANG Yawei, et al. Short-term interval forecasting of photovoltaic power based on CEEMDAN-GSA-LSTM and SVR [J]. Journal of Shanghai Jiao Tong University, 2024, 58(6): 806-818.
- [25]李争,张杰,徐若思,等.基于相似日聚类 and PCC-VMD-SSA-KELM模型的短期光伏功率预测[J].太阳能学报,2024,45(2): 460-468.
- LI Zheng, ZHANG Jie, XU Ruosi, et al. Short term photovoltaic power prediction based on similar day clustering and PCC-VMD-SSA-KELM model [J]. Acta Energiae Solaris Sinica, 2024, 45(2): 460-468.
- [26]DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [27]王瑞,张璐婷,逯静.基于新型相似日选取和VMD-NGO-BiGRU的短期光伏功率预测[J].湖南大学学报(自然科学版),2024,51(2): 68-80.
- WANG Rui, ZHANG Luting, LU Jing. Short term photovoltaic power prediction based on new similar day selection and VMD-NGO-BiGRU [J]. Journal of Hunan University (Natural Sciences), 2024, 51(2): 68-80.
- [28]殷林飞,张依玲.结合变分模态分解与三重卷积神经网络的光伏出力预测[J/OL].综合智慧能源:1-9(2024-09-11)[2025-03-01].<http://kns.cnki.net/kcms/detail/41.1461.TK.20240910.1606.004.html>.
- YIN Linfei, ZHANG Yiling. Photovoltaic power output prediction based on variational mode decomposition and triple convolutional neural networks [J/OL]. Integrated Intelligent Energy: 1-9 (2024-09-11) [2025-03-01]. <http://kns.cnki.net/kcms/detail/41.1461.TK.20240910.1606.004.html>.
- [29]周育才,肖添,谢七月,等.基于聚类的HPO-BiLSTM光伏功率短期预测[J].太阳能学报,2024,45(4): 512-518.
- ZHOU Yucai, XIAO Tian, XIE Qiyue, et al. Clustering-based HPO-BiLSTM short-term prediction of PV power [J]. Acta Energiae Solaris Sinica, 2024, 45 (4): 512-518.

(本文责编:刘芳)

收稿日期:2025-03-03;修回日期:2025-04-15
 上网日期:2025-06-03;附录网址:www.ienergy.cn

作者简介:

李祯(2001),男,硕士生,从事人工智能算法在光伏发电功率预测方面的研究,1835832503@qq.com;

杨国华*(1972),男,教授,硕士生导师,硕士,从事电力系统自动化与智能配电网方面的研究,ygh@nxu.edu.cn。

*为通信作者。