

基于集合经验模态分解和 TCN-BiLSTM 的 波浪发电功率预测

钟卓玲¹, 杨俊华¹, 林炳骏², 吕世强¹, 邓存杰¹, 于欢欢¹

(1. 广东工业大学 自动化学院, 广州 510006; 2. 南方电网广西北海供电局, 广西 北海 536000)

摘要: 针对波浪发电功率随机性强、难以精准预测问题,提出基于集合经验模态分解、时间卷积网络(temporal convolutional network, TCN)和双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络的波浪发电功率组合预测方法。应用集合经验模态分解方法,将原始序列分解为不同时间尺度的本征模态函数;将最小绝对收缩和选择算法提取的环境主要特征序列与根据样本熵值,对本征模态函数分组,重构为高频、中频和低频的分量结合,输入到 TCN-BiLSTM 预测模型,求和重构各分量得到波高预测结果;并将结果输入至所搭建直驱式波浪发电系统模型中,获得波浪输出功率预测值。仿真结果表明,相较于其他传统模型,所提方案模型预测精度上准确性更高,且具备更强泛化能力,在不同时间跨度预测任务中性能优异。

关键词: 波浪发电系统;集合经验模态分解;时间卷积网络;双向长短期记忆网络;功率预测

DOI: 10.19753/j.issn1001-1390.2026.10.010

中图分类号: TM619

文献标识码: A

文章编号: 1001-1390(2026)10-0104-12

Wave power generation prediction based on ensemble empirical mode decomposition and TCN-BiLSTM

Zhong Zhuoling¹, Yang Junhua¹, Lin Bingjun², Lv Shiqiang¹, Deng Cunjie¹, Yu Huanhuan¹

(1. School of Automation, Guangdong University of Technology, Guangzhou 510006, China.

2. Guangxi Beihai Power Supply Bureau, China Southern Power Grid, Beihai 536000, Guangxi, China)

Abstract: To address the challenges posed by the strong randomness and difficulty in accurately predicting wave power generation, this paper proposes a hybrid prediction method based on ensemble empirical mode decomposition (EEMD), temporal convolutional network (TCN), and bidirectional long short-term memory network (BiLSTM). The EEMD method is applied to decompose the original wave power time series into intrinsic mode functions (IMFs) across different time scales. Then, the primary environmental features are extracted using the least absolute shrinkage and selection operator algorithm. The IMFs are grouped and reconstructed into high-frequency, mid-frequency, and low-frequency components based on their sample entropy values. These reconstructed components, along with the extracted features, are input into the TCN-BiLSTM prediction model. The predictions of each component are summed to obtain the wave height forecasting results, which are subsequently fed into a direct-drive wave power generation system model to predict wave power output. Simulation results demonstrate that the proposed method achieves higher prediction accuracy and exhibits superior generalization capabilities compared to traditional models. It also performs exceptionally well in forecasting tasks across different time horizons.

Keywords: wave power generation system, ensemble empirical mode decomposition, temporal convolutional network, bidirectional long short-term memory, power prediction

0 引言

在全球能源转型和“双碳”目标背景下,清洁可再生能源已成为各国能源结构转型重点。波浪能

能量密度高于太阳能和风能数倍^[1],属于清洁无污染的绿色能源,发展潜力巨大。预计到 2050 年,海洋能源预计可为全球能源贡献约 7% 的份额^[2],潜在输出可达 337 GW^[3]。与风能一样,波浪能同样存在显著的随机性、间歇性和不规则性,并网后发

基金项目: 国家自然科学基金资助项目(62173148); 广东省自然科学基金资助项目(2022A1515010150,2023A1515010184)

电功率的波动性可能会影响电力系统稳定。可靠的波浪能预测技术,是其成为可持续电力来源的关键^[4]。

波浪能基本预测方法大致分为物理建模方法^[5]、统计方法^[6]和机器学习方法^[7]。物理建模基于物理定律建立数学模型,适用于大规模波能预测,但计算复杂且耗时^[8]。统计方法依赖历史数据,通过分析数据间的关联性进行预测,但对数据质量高度敏感^[9]。相比之下,机器学习通过自主学习输入输出关系,突破了传统方法的局限。文献[10]利用气温、海平面压力等环境特征结合多种人工神经网络模型,实现波高精确预测。

在机器学习领域,长短期记忆(long short-term memory, LSTM)网络通过引入门机制解决了作为时间序列预测的经典方法循环神经网络(recurrent neural network, RNN)梯度消失问题^[11]。文献[12]介绍了一种结合卷积神经网络(convolutional neural networks, CNN)与门控循环单元(gated recurrent unit, GRU)的复合模型,通过特征提取与序列建模实现高效预测,同时验证了多特征输入优势。双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络进一步扩展了 LSTM 网络,通过同时考虑时间序列的前后关系显著提升预测精度^[13]。文献[14]提出了一种基于 BiLSTM 的短期预测框架,针对智能电网数据质量问题,通过 BiLSTM 建模短期电力负荷与风电发电量预测,展现了 BiLSTM 在多领域预测任务中的优异性能和鲁棒性。

尽管 LSTM 及其变种在序列建模方面取得了较大突破,但随着数据复杂性增加,其计算效率逐渐成为瓶颈。时间卷积网络(temporal convolutional network, TCN)通过因果卷积和扩张卷积,有效提取时间序列特征,不仅能解决长时间依赖问题,还可大幅提升模型并行计算能力^[15]。文献[16]采用融合时间注意力机制的 TCN 模型预测光伏功率,展现出在复杂时间序列建模中的优越性能。

波浪数据受多种环境因素影响,时间序列通常包含如趋势、波动和噪声等非平稳特性。利用分解的方法对数据进行预处理,可有效分离出复杂时间序列特征,提高预测精度。经验模态分解(empirical mode decomposition, EMD)将时间序列分解为不同频率模态分量,显著增强模型对序列特征的提取能力,但仍存在模态混叠的问题^[17]。变分模态分解(variational mode decomposition, VMD)^[18]和完全集

成经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)^[19]等方法进一步优化了解析结果。基于 VMD 和向量自回归模型(vector autoregression, VAR),文献[20]提出波浪发电系统预测方案,将分解子序列重构并结合波高至功率转换模型实现高精度功率预测。文献[21]提出一种优化分解方法,利用排列熵的顺序剔除异常成分,有效预防模态混叠现象,同时运用自回归滑动平均模型,实现波高与波浪周期的短期精准预测。

针对波浪发电功率预测问题,文章提出一种基于集合经验模态分解和 TCN-BiLSTM 的混合预测模型。通过集合经验模态分解(ensemble empirical mode decomposition, EEMD)分解波高序列,提取不同时间尺度模态分量,有效缓解时间序列的非平稳性和噪声干扰;利用 TCN 捕捉全局依赖特征,结合 BiLSTM 建模时间序列的前后关联关系,提高预测精度;最后将预测结果输入波高至功率转换模型,计算波浪发电功率的预测值;在多特征输入条件下验证所提模型,研究 12、24、48、72 小时时间跨度的功率预测。结果表明,所提模型在不同海况下均展现出优异的鲁棒性与泛化性能,在短期预测中可精准捕捉动态波动,在中期预测中稳定性和趋势跟踪能力良好,为波浪发电高效利用提供支持。

1 EEMD-TCN-BiLSTM 预测模型

1.1 集合经验模态分解

EEMD 方法利用白噪声辅助分解,能够将非平稳、非线性波高信号自适应分解为不同时间尺度的本征模态函数(intrinsic mode functions, IMFs),有效解决 EMD 处理复杂信号时易出现的模态混叠问题,同时保留信号中的瞬时波动和长期趋势,分解后 IMFs 的局部特征得到均匀分布^[22-23],为后续针对性地采用 TCN 和 BiLSTM 提取各频段特征提供高质量输入,EEMD 的执行流程如下:

1) 在原始信号 $x(t)$ 中加入高斯白噪声 $n_m(t)$, 形成含噪信号 $x_m(t)$:

$$x_m(t) = x(t) + k \cdot n_m(t) \quad (1)$$

式中: k 为高斯白噪声的权值系数,控制加入的噪声强度大小。

2) EMD 分解

对含噪信号 $x_m(t)$ 进行 EMD 分解,逐层提取 IMFs。分解过程中,为衡量信号收敛性,计算相邻两次迭代信号 $x_j(t)$ 和 $x_{j-1}(t)$ 的差异,定义标准偏

差 (standard deviation, SD) 为:

$$E_{SD} = \sum_{t=1}^T \frac{|x_{j-1}(t) - x_j(t)|^2}{x_{j-1}^2(t)} \quad (2)$$

当 E_{SD} 小于设定阈值时, 当前信号即被认为满足 IMFs 提取条件。

3) 重复实验与 IMFs 平均

针对每组信号 $x(t)$, 重复实验 m 次, 每次使用不同的高斯白噪声 $n_m(t)$ 。通过平均处理所有实验中的 IMFs, 得到最终 IMF 为:

$$E_{IMF} = \frac{1}{M} \sum_{m=1}^M IMF_i^{(m)} \quad (3)$$

式中: IMF_i 为第 i 个 IMF 的平均值; $IMF_i^{(m)}$ 表示第 m 次实验中得到的第 i 个 IMF。

1.2 样本熵

样本熵是一种衡量时间序列复杂度和规律性的指标^[24-25]。假设输入时间序列为 $X = (x_1, x_2, \dots, x_M)$, M 为序列长度, 构造 m 维嵌入子序列:

$$X_i = (x_i, x_{i+1}, \dots, x_{i+m-1}), (1 \leq i \leq M-m) \quad (4)$$

对于所有可能的子序列 $(X_i, X_j) (i \neq j)$, 计算最大绝对差值:

$$d_{ij} = \max_{k=0, \dots, m-1} |x_{i+k} - x_{j+k}| \quad (5)$$

计算 m 维子序列中, 与 X_i 具有相似性的序列数量占比:

$$B_i^m(r) = \frac{1}{M-m-1} \sum_{M-m} H(r - d_{ij}) \quad (6)$$

式中: $H(x)$ 为 Heaviside 阶跃函数:

$$H(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (7)$$

若 $d_{ij} <$ 相似度阈值 r , 此时 X_i 与 X_j 相似, 有 $H(r - d_{ij}) = 1$, 否则 $H(r - d_{ij}) = 0$ 。对 m 维和 $m+1$ 维求平均概率为:

$$\begin{cases} B^m(r) = \frac{1}{M-m} \sum_{i=1}^{M-m} B_i^m(r) \\ A^m(r) = \frac{1}{M-m} \sum_{i=1}^{M-m} \frac{1}{M-m-1} \sum_{j=1, j \neq i}^{M-m} H(r - d_{ij}^{m+1}) \end{cases} \quad (8)$$

式中: $B^m(r)$ 为两个子序列在相似度阈值 r 下匹配 m 个点的概率; $A^m(r)$ 为两个子序列匹配 $m+1$ 个点的概率。

当 M 值有限时, 样本熵为:

$$\text{SampEn}(m, r, M) = -\ln \left(\frac{A^m(r)}{B^m(r)} \right) \quad (9)$$

样本熵值越高, 说明序列越复杂、随机性越强; 反之, 样本熵值越低, 表明序列结构较为简单, 呈现出更明显的规律性。

1.3 时间卷积网络

采用扩张因果卷积和残差连接结构的时间卷积网络 (temporal convolutional network, TCN), 能够有效地捕捉长时间依赖性^[26], 如图 1 所示。




图 1 TCN 结构图

Fig. 1 TCN structure diagram

TCN 通过引入扩张因子,在不增加计算复杂度情况下,扩大感受野,捕获长时间依赖信息。假设输入时间序列为 $X = (x_1, x_2, \dots, x_N)$, 其中 $x(t) \in R$, 是时间步 t 的输入数据, N 为序列长度。扩张卷积运算为:

$$y_t = \sum_{i=0}^{k-1} w_i \cdot x_{t-i \cdot d} \quad (10)$$

式中: $w(i)$ 为卷积核权重; k 为卷积核大小; d 为扩张因子(如 $d=1, 2, 4, \dots$)。

残差连接中给定输入 x 和卷积层输出 $F(x)$, 每层最终输出为:

$$y = x + F(x) \quad (11)$$

$F(x)$ 通过卷积层进行非线性变换, 激活函数为 ReLU。通过残差连接, TCN 在处理复杂时间序列时兼顾特征稳定性和训练效率。

1.4 双向长短期记忆网络

基于 LSTM 的扩展模型 BiLSTM, 核心是门控机制, 可动态控制信息的存储与遗忘^[27]。LSTM 的状态更新过程为:

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tan h(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t \odot \tan h(C_t) \end{cases} \quad (12)$$

式中: σ 为 Sigmoid 激活函数; $x(t)$ 为当前时刻输入; h_{t-1} 为前一时间步隐藏状态; $\tan h$ 为双曲正切激活函数; W 和 b 分别为权重矩阵和偏置向量。

$$\begin{cases} \sigma(x) = \frac{1}{1 + e^{-x}} \\ \tan h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \end{cases} \quad (13)$$

BiLSTM 在 LSTM 基础上引入了反向序列处理模块, 通过正、反向两个 LSTM 网络分别处理序列数据, 其输出结合每个时间步, 从而捕捉过去和未来的上下文信息。通过引入对波浪发电数据未来状态的决策, 增强时间序列数据建模能力。

假设输入序列为 $X = (x_1, x_2, \dots, x_T)$, T 为序列长度, BiLSTM 输出表示为:

$$h_t = [\vec{h}_t, \overleftarrow{h}_t] \quad (14)$$

式中: $\vec{h}_t$ 和 $\overleftarrow{h}_t$ 分别为时间步 t 的正、反向 LSTM 输出; h_t 为双向 LSTM 最终输出。

1.5 EEMD-TCN-BiLSTM 预测模型

基于 EEMD-TCN-BiLSTM 的组合预测模型流程如图 2 所示。




图 2 EEMD-TCN-BiLSTM 模型流程图

Fig. 2 Flow chart of EMD-TCN-BiLSTM model

预测步骤如下:

- 1) 收集波浪数据并对数据进行预处理;
- 2) 标准化波高序列, 通过 EEMD 方法提取多个表征不同时间尺度特征的 IMFs, 减少信号复杂性;
- 3) 对环境特征进行筛选利用最小绝对收缩和选择 (least absolute shrinkage and selection operator, LASSO) 算法, 提取主要特征序列; 根据样本熵值对 IMFs 分组并重构为高、中、低频分量, 将各分量预测结果结合主要特征序列输入预测模型。对于高频分量, 采用 BiLSTM 双向捕捉时序中快速且复杂的局部变化, 输出高频分量的预测序列, 即 $y_{\text{high}}(t)$; 对于中低频分量, 采用 TCN 模型对其进行长时序依赖和趋势提取得到中低频分量的预测序列, 即 $y_{\text{min/low}}(t)$;
- 4) 最终的波高预测结果由各频段预测值逐点相加得到:

$$y(t) = y_{\text{high}}(t) + y_{\text{min/low}}(t) \quad (15)$$

2 直驱式波浪发电系统

波浪发电系统的基本结构图如图 3 所示。




图 3 波浪发电系统模型图

Fig. 3 Wave power generation system model diagram

2.1 浮子运动模型

根据牛顿第二定律,浮子运动方程^[28]为:

$$M \ddot{x}(t) + F_r(t) + K_m x(t) = F_{\text{wave}}(t) + F_e(t) + F_s(t) \quad (16)$$

式中: M 为浮子总质量/kg; K_m 为弹性系数/(N/m); $x(t)$ 为浮子位移/m;当浮子处于平衡位置时,流体恢复力为:

$$F_s(t) = Kz(t) = \rho g \pi r^2 x(t) \quad (17)$$

辐射力为:

$$F_r(t) = m_\infty \ddot{x}(t) + B_m \dot{x}(t) \quad (18)$$

发电机反电磁力为:

$$F_e(t) = -B_g \dot{x}(t) - K_g x(t) \quad (19)$$

式中: B_m 为水动力阻尼系数; B_g 为发电机阻尼系数; K_g 为发电机等效弹性系数。

由波高产生波浪激励力 $F_{\text{wave}}(t)$ ^[29]为:

$$\begin{cases} F_{\text{wave}}(t) = -\rho g S_f K_s(\omega, h, d) \frac{H}{2} \\ K_s(\omega, h, d) = \frac{\cosh(k(\omega)(h-d))}{\cosh(k(\omega)h)} \\ K(\omega) = \frac{\omega^2}{g} \end{cases} \quad (20)$$

式中: ρ 为海水密度/(kg/m³); S_f 为浮子面积/m²; $K_s(\omega, h, d)$ 为压力系数; H 为波高/m; $K(\omega)$ 为波数/(1/m)。

2.2 波浪功率的计算

为实现最大波浪能捕获,谐振状态下的系统阻尼力与波浪激励力平衡,有:

$$B = B_g + B_m \quad (21)$$

假定忽略电机内损耗,运动方程可简化为:

$$F_{\text{wave}}(t) = B \dot{x}(t) \quad (22)$$

电机吸收的瞬时海浪功率为:

$$P_{\text{wave}}(t) = F_{\text{wave}}(t) \cdot \dot{x}(t) \quad (23)$$

平均波周期 T 内所捕获的总波浪能为:

$$E_{\text{wave}} = \int_0^T P_{\text{wave}}(t) dt = \int_0^T \frac{F_{\text{wave}}^2(t)}{4B_g} dt = T \frac{F_{\text{max}}^2}{8B_g} \quad (24)$$

平均输出功率需考虑系统最大功率点匹配的实际吸收效率,将式(20)带入式(24)可得:

$$p = \eta \frac{F_{\text{max}}^2}{8B_g} \quad (25)$$

式中: η 为波浪能装置转换效率,受海况、控制策略及几何优化影响,典型效率范围为0.2~0.6^[30],文中设定为0.5。

3 算例分析与预测实验

3.1 数据获取与预处理

为验证所提出的 EEMD-TCN-BiLSTM 模型在不同环境下的预测能力,首先选取国家数据浮标中心 46076 浮标站点作为重点分析对象,该站点位于深海区域,海况复杂,具有典型的高能海况特征,适合作为极端工况下的波高预测实验场景。数据集涵盖该站点 2020—2021 年共 16 992 组波浪观测数据,时间分辨率为 1 h。如图 4 所示,该站点观测数据中不仅包含大量常态海况数据,同时也记录了多个风速超过 17.5 m/s、波高超过 4 m 的极端风浪事件,呈现出显著的强非平稳性与高波动特征。将数据集按时间顺序划分,前 80% 的数据作为训练集,中间 10% 作为验证集,最后 10% 作为测试集。随后检验模型在不同环境条件下的性能。




图 4 站点极端环境分析

Fig. 4 Site extreme environment analysis

数据预处理阶段,通过插值法对波浪数据缺失值进行填补;采用四分位距法(IQR)处理异常值,通

过计算数据的第一四分位数 (Q_1) 和第三四分位数 (Q_3), 确定异常值的上下界 ($Q_1 - 1.5IQR$ 和 $Q_3 + 1.5IQR$), 删除超出界限的波高数据, 从而实现极端值的剔除并保证数据的质量。

3.2 特征提取与评估指标

LASSO 特征提取算法通过对模型参数施加稀疏性约束, 自动筛选并保留对目标变量影响显著的特征, 其机制在于将部分回归系数收缩至零, 以减少冗余变量干扰并降低过拟合风险。此外, LASSO 还削弱异常值和噪声对估计结果的影响, 提高模型的稳健性。因此, 在波高预测中, 采用 LASSO 对风向、浮标平均速度、阵风速度、平均波周期、海平面压力、空气温度、海面温度等环境变量进行筛选, 提取与波高相关性最高的关键特征, 从而优化建模效果并提升预测精度。

LASSO 目标函数^[31]由残差平方和(residual sum of squares, RSS)与 L_1 正则项两部分组成, 旨在通过优化回归系数 β , 寻找使两部分总和最小的参数组合:

$$Loss(\beta) = \frac{1}{2n} \sum_{i=1}^n (y_i - \sum_{j=1}^p x_{ij}\beta_j)^2 + \alpha \sum_{j=1}^p |\beta_j| \quad (26)$$

式中: α 为正则化强度参数, 控制模型复杂度同时引入稀疏性。较大的 α 值迫使更多的特征系数缩减为零, 从而实现特征选择, 防止模型过拟合。

通过 10 折交叉验证确定最优 α 值为 0.063 1。经 LASSO 算法提取出回归系数 β 绝对值非 0 的四个环境变量作为预测模型的输入变量: 阵风速度 (0.507 2)、平均波周期 (0.469 9)、海平面压力 (-0.138 5)、海面温度 (-0.118 7)。

为验证所提方法优越性能, 采用评估模型预测效果的评价指标有: 平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、均方根误差 (root mean squared error, RMSE) 和拟合优度 (R^2)^[32]。其中 MAE、MAPE、RMSE 值越小表示误差越小, R^2 值越接近 1 表示拟合程度越高。

3.3 分解重构与参数选择

采用 EEMD 对原始波高信号进行多尺度分解, 分离噪声分量与有效特征, 并基于样本熵对 IMFs 进行重组, 进一步削弱噪声对模型建模过程的干扰。经 EEMD 处理后, 原始信号被分解为 13 个按频率降序排列的 IMFs, 如图 5 所示, 在此过程中, 最佳分解次数设定为 200, 白噪声幅值比例为 0.1。




图 5 分解结果

Fig. 5 Decomposition result

为降低输入至 TCN-BiLSTM 预测模型的数据规模并提升模型运行效率, 结合样本熵值对 IMFs 分组并重构。在重构过程中, 根据样本熵的高低, 将 IMFs 分量分类为: 样本熵值大于 0.05 的子序列被重构为高频分量 (噪声和高频波动), 样本熵值低于 0.01 的子序列被重构为低频分量 (长期趋势), 其余子序列被重构为中频分量 (短期波动), 结果如表 1 所示。

表 1 重构分量与原始分量对应关系

Tab. 1 Reconstructed component corresponds to the original component

重构分量	原始分量
高频 RIMF1	IMF4 + IMF5 + IMF6
中频 RIMF2	IMF1 + IMF2 + IMF3 + IMF7 + IMF8
低频 RIMF3	IMF9 + IMF10 + IMF11 + IMF12 + IMF13

通过样本熵进一步筛选和重构 IMF_s 分量,将噪声主导的高频分量单独预测,进一步减少噪声对中低频主特征的干扰,避免噪声在整体预测中的累积效应。经过重构,子序列由原来的 13 个减少为 3 个,显著降低了 TCN-BiLSTM 预测模型的输入维度。如图 6 所示,所得重构误差为 0.059。




图 6 重构结果

Fig. 6 Reconstruction result

对比 EEMD-TCN-BiLSTM 模型与单一模型及组合模型的预测误差评估指标,验证模型性能。基于单一变量原则,对比模型相关参数设置为一致。其中 LSTM 由 2 层 128 个隐藏神经元组成,BiLSTM 有 2 层前向 LSTM 和 2 层反向 LSTM;TCN 由 3 层构成,通道数分别为 32、64 和 128,卷积核大小为 3,扩张因子为 1、2、4,丢弃率为 0.3。全连接层输出为 1 个神经元。使用 AdamW 优化器,初始学习率为 0.000 5,结合 ReduceLROnPlateau 调度器动态调整学习率,并引入早停机制,防止过拟合。

3.4 预测结果

为选择最优的时间步长,从而确保在波高预测中 EEMD-TCN-BiLSTM 模型的最佳性能。在其他参数一致情况下,将时间步长值设为 6~24,共进行 4 组测试。其中,时间步长含义是通过过去数据长度预测下一小时数据(如图 7 所示)。图 8 为不同时间步长的误差评估结果对比。

由图 8 可知,当时间步长值为 18 h,EEMD-TCN-BiLSTM 模型在预测未来 1 h 波高的效果最为理想,MAE、MAPE 和 RMSE 最低。为验证模型的优越性,在时间步长统一为 18 h 情况下,对比不同模型波高预测误差。




图 7 时间步长的定义

Fig. 7 Time step definition





图 8 不同时间步长的误差评估结果对比

Fig. 8 Comparison of error evaluation results for different time steps

由表 2 可知,从简单 LSTM 模型到复杂 EEMD-TCN-BiLSTM 模型,性能指标逐步得到优化。相较 LSTM 模型,BiLSTM 通过双向信息流增强了时间依赖关系捕获,MAPE 和 RMSE 分别下降了 2.5% 和 6%,但单纯依赖循环结构更新隐藏状态,仍存在信息衰减的问题,MAE 均大于 0.3。而 TCN 通过扩展卷积层和感受野,有效弥补该缺陷,TCN-BiLSTM 相比于 BiLSTM 模型 R^2 提升了 0.082 2。

表 2 46076 站点不同模型 1 h 的波高预测
Tab. 2 Wave height predictions of different models
for 1-hour at station 46076

模型	MAE	MAPE	RMSE	R^2
LSTM	0.254 3	0.144 5	0.362 6	0.816 8
BiLSTM	0.216 1	0.119 5	0.302 6	0.872 5
TCN-LSTM	0.213 2	0.117 0	0.292 8	0.880 5
TCN-BiLSTM	0.122 1	0.069 4	0.177 6	0.954 7
EEMD-TCN-LSTM	0.183 7	0.101 1	0.243 4	0.917 5
EEMD-TCN-BiLSTM	0.049 5	0.026 7	0.085 9	0.993 4

引入 EEMD 分解后,模型通过多尺度分解与降噪改善了非平稳信号的输入质量。相较于 TCN-LSTM 和 TCN-BiLSTM 这两个预测模型,EEMD-TCN-BiLSTM 的 MAE 分别下降了 0.163 7 和 0.072 6, R^2 分别提升了 0.112 9 和 0.038 7。

尽管如此,EEMD-TCN-LSTM 仍逊色于 TCN-BiLSTM,主要原因为 LSTM 无法像双向 LSTM 一样捕捉序列中的双向依赖,特别是在极端天气下,波高序列突变性强,缺乏未来信息的辅助,导致 EEMD-TCN-LSTM 对剧烈波动的预测能力不足。而 TCN-BiLSTM 通过双向感知机制,结合 TCN 的长依赖特征提取能力,对极端波动的拟合效果更佳,因而在各项指标上表现优于 EEMD-TCN-LSTM。

取 46076 站点 2021 年 12 月 31 日 00:50—23:50 时刻,绘制不同模型预测结果的对比图,如图 9 所示。




图 9 46076 站点不同模型预测 1 小时波高
Fig. 9 1-hour wave height prediction for site
46076 using different models

由图 9 可知,传统时序预测模型在极端工况下往往误差较大,而 EEMD-TCN-BiLSTM 模型能够通过多尺度特征提取提升对极端波浪的适应性,波高的预测值拟合程度要高于其他模型。

3.5 泛化实验

为进一步验证 EEMD-TCN-BiLSTM 模型在不同海洋环境下的泛化能力,选取了以普通工况为主的 41008 浮标站点作为泛化实验对象,选取该站点 2020 年—2021 年期间共 17 142 组波浪观测数据(时间分辨率同为 1 小时)开展对比实验,以进一步验证模型在不同工况下的适应性和鲁棒性。表 3 为 46076 与 41008 两个站点的基本情况对比。

表 3 两个站点环境及工况分析对比
Tab. 3 Analysis and comparison of the environment
and working conditions of two stations

指标	46076 站点
地理位置	(59.508 N,148.005 W)
海水深度	200 m(深水区)
风浪环境	高风浪、长周期波浪,台风/风暴季节性强
工况类型	高能海况、极端浪高频繁
应用场景	适合远洋风暴、高能波浪能研究

指标	41008 站点
地理位置	(31.400 N,80.866 W)
海水深度	16 m(近岸浅海区)
风浪环境	低风浪、短周期波浪,极端工况仅 0.02%
工况类型	常规海况为主、波浪相对稳定
应用场景	适合近岸波浪分析

41008 站点经 LASSO 特征提取后选用风向、阵风速度、平均波周期作为预测模型的输入特征变量。表 4 为各模型训练集误差。

表 4 41008 站点不同模型的预测 1 h 波高
Tab. 4 Wave height predictions of different models
for 1-hour at station 41008

模型	MAE	MAPE	RMSE	R^2
LSTM	0.165 2	0.275 5	0.209 1	0.699 2
BiLSTM	0.146 6	0.243 7	0.202 0	0.720 0
TCN-LSTM	0.135 5	0.224 6	0.185 1	0.765 3
TCN-BiLSTM	0.043 0	0.056 8	0.072 9	0.963 8
EEMD-TCN-LSTM	0.043 7	0.061 2	0.065 0	0.971 1
EEMD-TCN-BiLSTM	0.027 8	0.035 8	0.038 1	0.990 1

表 4 数据显示,在 41008 站点预测模型 EEMD-TCN-BiLSTM 相较于 LSTM、BiLSTM、TCN-LSTM、

TCN-BiLSTM、EEMD-TCN-LSTM 等模型, MAPE 分别下降 23.97%、20.79%、18.88%、2.1% 和 2.54%; 而 R^2 分别提升了 0.290 9、0.270 1、0.224 8、0.026 3 和 0.190 0, 验证了模型在平稳环境下依然具备显著优势。

结合表 2~表 4 可得, 41008 站点数据结构相对简单、波浪平稳, 极端天气概率低, 易使部分模型在训练时对局部噪声或小幅波动产生过拟合。相较而言, 46076 站点波高数据波动大、非平稳性强, 模型更关注全局特征, 过拟合风险较低。尤其在 41008 站点, 除预测模型 EEMD-TCN-BiLSTM 外, 其他模型在测试集上误差仍偏高, 说明传统模型在平稳环境下对全局趋势建模能力不足, 抗过拟合能力差。

EEMD 分解抑制输入噪声, 样本熵组合重构不同频分量, TCN 捕捉长周期依赖, BiLSTM 建模双向时序特征, 形成了良好的“分解-重构-分支-重构”的多阶段协同机制, 有效缓解了因局部波动与信号噪声引发的过拟合风险。在复杂(46076 站点)与简单(41008 站点)海况下均展现出优异的鲁棒性与泛化性能, 充分验证了其跨工况、跨场景的广泛适应能力。

取 41008 站点 2021 年 12 月 31 日 00:50—23:50 时刻, 画出预测结果对比折线图, 如图 10 所示。




图 10 41008 站点不同模型预测 1 小时波高
Fig. 10 1-hour wave height prediction for site 41008 using different models

由图 9 与图 10 对比可知, 41008 站点因波高振幅低, 模型对微小波动或局部异常点的敏感性增强, 进而放大了整体相对误差, 导致误差表现相对

明显; 而模型在 46076 站点能够更好捕捉到宏观趋势和大尺度变化, 微小误差在大波高背景下对相对误差的影响被稀释, 因而图 9 中表现出更好的拟合效果和误差相对较小的趋势。

4 波浪发电功率预测

4.1 1 小时波浪发电功率预测

波高预测值与平均波周期共同作为波能转换模型的输入参数, 计算波浪发电系统预测功率值; 原始数据则用于计算实际输出功率。46076 站点在 2021 年 12 月 31 日 00:50—23:50 时刻的实际功率与基于 EEMD-TCN-BiLSTM 模型预测功率对比如图 11 所示, 图中拟合曲线斜率接近 1, 且 R^2 高达 0.998 7, MAE 值为 0.48, 表明模型预测功率与实际功率高度吻合。同时, 95% 置信带较窄, 预测点大多落入置信区间内, 进一步验证了模型在海洋能功率预测任务中的可靠性与精度。




图 11 1 小时的真实功率与预测功率

Fig. 11 1-hour actual power and predicted power

4.2 不同时间跨度的预测

1 小时短时间跨度波浪发电功率预测, 有助于电网短期调度和实时负载平衡, 而更长时间跨度可体现趋势性变化和周期性波动。通过不同时间跨度预测, 可更好捕捉系统不同时间尺度上的变化特性。于是, 使用 EEMD-TCN-BiLSTM 模型对 46076 站点进行 12、24、48、72 h 跨度的预测。

由表 5 可得, 随着时间跨度增加, 模型 EEMD-TCN-BiLSTM 预测误差 MAE、MAPE、RMSE 呈现出逐渐增大趋势, 而 R^2 则逐渐下降, 但模型整体依然保持较高水平, 平均 MSE 为 0.090 0, MAPE 为 0.048 8, RMSE 为 0.121 5, R^2 达到 0.976 4。

表 5 不同时间跨度的预测波高误差

Tab.5 Prediction errors of wave heights
across different time spans

时间跨度	MAE	MAPE	RMSE	R^2
12 h	0.064 5	0.034 9	0.088 5	0.988 6
24 h	0.075 1	0.040 4	0.100 8	0.985 6
48 h	0.088 7	0.047 9	0.120 8	0.978 2
72 h	0.131 7	0.071 9	0.175 9	0.953 1
平均值	0.090 0	0.048 8	0.121 5	0.976 4

不同时间跨度的波高预测对比如图 12 所示。




图 12 不同时间跨度波高预测对比

Fig. 12 Comparison of significant wave height
predictions across different time spans

从图 13 可知,不同时间跨度功率曲线整体呈现相似趋势,即功率在某一阶段迅速上升后,在较高功率区域内出现波动。在短时间跨度内,模型 EEMD-TCN-BiLSTM 能够精准捕捉系统动态变化,预测精度较高。尽管在较长时间跨度预测中,不确定性逐渐加大,模型依然能够反映功率变化的整体趋势,体现了模型稳定性。




图 13 不同时间跨度真实功率与预测功率对比

Fig. 13 Comparison of actual and predicted power
across different time spans

5 结论

文章提出了一种基于 EEMD-TCN-BiLSTM 的波浪发电功率预测方法,以提升波浪能功率预测的精度与鲁棒性。首先,采用 EEMD 对波高时间序列进行多尺度分解,并基于样本熵对 IMF_s 分组重构为高频、中频、低频分量,随后 TCN 负责提取中低频分量的依赖特征,BiLSTM 则用于捕捉高频分量中的复杂时序关系,实现对波高的精准预测。最后,将波高预测值与平均波周期输入至波能转换模型中,计算得到波浪发电系统的功率值。

实验结果表明,所提模型在短期(1 小时)预测任务中具有较高的精度,能够精准捕捉波浪动态变化特征,并在不同工况场景的站点上进行测试,所提模型均保持较好的泛化性能,说明其能够适应不同的海域环境。此外,在不同时间跨度(12 h 至 72 h)的预测任务中,相较于 LSTM、BiLSTM 和 TCN 模型,EEMD-TCN-BiLSTM 模型均表现出稳定的预测性能,误差显著降低。虽然误差指标随时间跨度增加有所上升,但整体预测精度仍维持在较高水平, R^2 值在 0.95 以上,表现出较强的趋势跟踪能力和稳定性,表明模型在面对长时间依赖性问题时依然能够保持较高的预测可信度。

总体而言,EEMD-TCN-BiLSTM 模型能够充分挖掘波浪能时序数据特征,兼具高精度和强泛化性,能够为波浪能发电系统的优化调度提供理论支撑。然而,文章在 TCN 结构参数调优方面仍有优化空间,未来研究可进一步探索自适应参数优化策略,提升模型在不同环境下适应能力。

参考文献

- [1] Neshat M, Nezhad M M, Sergiienko N Y, et al. Wave power forecasting using an effective decomposition-based convolutional Bi-directional model with equilibrium Nelder-Mead optimiser[J]. Energy, 2022, 256: 124623.
- [2] Esteban M, Leary D. Current developments and future prospects of offshore wind and ocean energy[J]. Applied Energy, 2012, 90(1): 128-136.
- [3] Yang Y H, Han L, Qiu C Y, et al. A short-term wave energy forecasting model using two-layer decomposition and LSTM-attention[J]. Ocean Engineering, 2024, 299: 117279.
- [4] Shadmani A, Nikoo M R, Gandomi A H, et al. A review of machine learning and deep learning applications in wave energy forecasting and WEC optimization[J]. Energy Strategy Reviews, 2023, 49: 101180.
- [5] Hiles C E, Beatty S J, De A A. Wave energy converter

- annual energy production uncertainty using simulations [J]. *Journal of Marine Science and Engineering*, 2016, 4 (3): 53.
- [6] Han Q K, Meng F M, Hu T, et al. Non-parametric hybrid models for wind speed forecasting[J]. *Energy Conversion and Management*, 2017, 148: 554-568.
- [7] Neshat M, Nezhad M M, Abbasnejad E, et al. A deep learning-based evolutionary model for short-term wind speed forecasting: A case study of the Lillgrund offshore wind farm[J]. *Energy Conversion and Management*, 2021, 236: 114002.
- [8] Wang W, Tang R, Li C, et al. A BP neural network model optimized by mind evolutionary algorithm for predicting the ocean wave heights [J]. *Ocean Engineering*, 2018, 162: 98-107.
- [9] Giorgi M G D, Ficarella A, Tarantino M. Error analysis of short term wind power prediction models[J]. *Applied Energy*, 2011, 88(4): 1298-1311.
- [10] Elbisy M S, Elbisy A M S. Prediction of significant wave height by artificial neural networks and multiple additive regression trees[J]. *Ocean Engineering*, 2021, 230: 109077.
- [11] Huang R J, Wei C J, Wang B H, et al. Well performance prediction based on long short-term memory (LSTM) neural network[J]. *Journal of Petroleum Science and Engineering*, 2022, 208: 109686.
- [12] 吴凡瞳, 杨俊华, 杨梦丽, 等. 基于卷积门控循环单元的波浪发电系统输出功率预测[J]. *太阳能学报*, 2024, 45(8): 682-688.
- Wu Fantong, Yang Junhua, Yang Mengli, et al. Output power prediction of wave power generation system based on convolutional gated cyclic unit[J]. *Acta Energetica Sinica*, 2024, 45(8): 682-688.
- [13] 张淑清, 李君, 姜安琦, 等. 基于 FPA-VMD 和 BiLSTM 神经网络的新型两阶段短期电力负荷预测[J]. *电网技术*, 2022, 46(8): 3269-3279.
- Zhang Shuqing, Li Jun, Jiang Anqi, et al. A novel two-stage model based on FPA-VMD and BiLSTM neural network for short-term power load forecasting[J]. *Power System Technology*, 2022, 46(8): 3269-3279.
- [14] 李岩, 刘鑫月, 乔俊杰, 等. 基于数据预处理和 Bi-LSTM 的智能电网预测方法[J]. *电测与仪表*, 2025, 62(6): 120-125.
- Li Yan, Liu Xinyue, Qiao Junjie, et al. Smart grid forecasting method based on data preprocessing and Bi-LSTM [J]. *Electrical Measurement & Instrumentation*, 2025, 62(6): 120-125.
- [15] Yang S B, Deng Z G, Li X F, et al. A novel hybrid model based on STL decomposition and one-dimensional convolutional neural networks with positional encoding for significant wave height forecast[J]. *Renewable Energy*, 2021, 173: 531-543.
- [16] 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.
- [17] Zhou S Y, Bethel B J, Sun W J, et al. Improving significant wave height forecasts using a joint empirical mode decomposition-long short-term memory network [J]. *Journal of Marine Science and Engineering*, 2021, 9(7): 744.
- [18] Jamei M, Ali M, Karbasi M, et al. Designing a multi-stage expert system for daily ocean wave energy forecasting: A multivariate data decomposition-based approach [J]. *Applied Energy*, 2022, 326: 119925.
- [19] 尹元亚, 潘文虎, 赵文广, 等. 基于 CEEMDAN 和 BiLSTM-AM 的超短期风速预测方法[J]. *电测与仪表*, 2024, 61(9): 77-84.
- Yin Yuanya, Pan Wenhui, Zhao Wenguang, et al. Ultra-short-term wind speed prediction method based on CEEMDAN and BiLSTM-AM[J]. *Electrical Measurement & Instrumentation*, 2024, 61(9): 77-84.
- [20] 罗琦, 杨俊华, 黄逸, 等. 基于变分模式分解和向量自回归模型的波浪发电系统输出功率预测[J]. *太阳能学报*, 2023, 44(3): 291-297.
- Luo Qi, Yang Junhua, Huang Yi, et al. Output power prediction of wave power system based on variational model decomposition and vector autoregressive model [J]. *Acta Energetica Sinica*, 2023, 44(3): 291-297.
- [21] 吴峰, 王飞, 顾康慧, 等. 基于 MEEMD-ARIMA 模型的波浪能发电系统输出功率预测[J]. *电力系统自动化*, 2021, 45(1): 65-70.
- Wu Feng, Wang Fei, Gu Kanghui, et al. A combined method of improved grey BP neural network and MEEMD-ARIMA for day-ahead wave energy forecast[J]. *Automation of Electric Power Systems*, 2021, 45(1): 65-70.
- [22] 汪敏, 张孟健, 禹洪波, 等. 基于 EEMD 和特征降维的非侵入式负荷分解方法研究[J]. *电测与仪表*, 2024, 61(6): 80-86.
- Wang Min, Zhang Mengjian, Yu Hongbo, et al. Research on non-intrusive load decomposition method based on EEMD and feature dimensionality reduction[J]. *Electrical Measurement & Instrumentation*, 2024, 61(6): 80-86.

- [23] 朱坤, 付青. 基于 EEMD-Kmeans-ALO-LSTM 的短期光伏功率预测[J]. 电源技术, 2023, 47(1): 103-107.
Zhu Kun, Fu Qing. A photovoltaic power forecasting method based on EEMD-Kmeans-ALO-LSTM[J]. Chinese Journal of Power Sources, 2023, 47(1): 103-107.
- [24] 刘禹彤, 赵琳, 王鑫太. 基于 SE-improved SGMD 的混合储能容量优化配置方法研究[J]. 高压电器, 2024, 60(10): 78-85, 103.
Liu Yutong, Zhao Lin, Wang Xintai. Research on optimal configuration method of hybrid energy storage capacity based on SE-improved SGMD[J]. High Voltage Apparatus, 2024, 60(10): 78-85, 103.
- [25] 杨康, 李蓝青, 李艺丰, 等. 一种新型分布式光伏出力区间预测方法[J]. 发电技术, 2024, 45(4): 684-695.
Yang Kang, Li Lanqing, Li Yifeng, et al. A novel distributed photovoltaic output interval prediction method[J]. Power Generation Technology, 2024, 45(4): 684-695.
- [26] 段宏, 郭成, 孙海东, 等. 基于 DDTW 聚类 and SK TCN-GC BiGRU 的分布式光伏短期功率预测[J]. 智慧电力, 2025, 53(4): 71-80.
Duan Hong, Guo Cheng, Sun Haidong, et al. Short-term power prediction for distributed photovoltaic systems based on DDTW clustering and SK TCN-GC BiGRU network[J]. Smart Power, 2025, 53(4): 71-80.
- [27] 薛展豪, 陈力, 林志颖, 等. 基于双向长短期记忆生成对抗网络的电力系统次同步振荡数据生成方法[J]. 智慧电力, 2024, 52(5): 60-66.
Xue Zhanhao, Chen Li, Lin Zhiying, et al. Subsynchronous oscillation data generation method of power system based on bidirectional long shortterm memory generative adversarial network[J]. Smart Power, 2024, 52(5): 60-66.
- [28] 康庆, 肖曦, 聂赞相, 等. 直驱型海浪发电系统输出功率优化控制策略[J]. 电力系统自动化, 2013, 37(3): 24-29.
Kang Qing, Xiao Xi, Nie Zanzhang, et al. An optimal control strategy for output power of the directly driven wave power generation system[J]. Automation of Electric Power Systems, 2013, 37(3): 24-29.
- [29] Prado M G D, Gardner F, Damen M, et al. Modelling and test results of the Archimedes wave swing[J]. Proceedings of the Institution of Mechanical Engineers Part a-Journal of Power and Energy, 2006, 220(A8): 855-868.
- [30] Aderinto T, Li H. Review on power performance and efficiency of wave energy converters[J]. Energies, 2019, 12(22): 4329.
- [31] 崔鸿雁, 徐帅, 张利锋, 等. 机器学习中的特征选择方法研究及展望[J]. 北京邮电大学学报, 2018, 41(1): 1-12.
Cui Hongyan, Xu Shuai, Zhang Lifeng, et al. The key techniques and future vision of feature selection in machine learning[J]. Journal of Beijing University of Posts and Telecommunications, 2018, 41(1): 1-12.
- [32] 张震, 肖莺, 任永建, 等. 基于气象因子的 EEMD-BP 方法在电网用电量预测中的应用[J]. 南方能源建设, 2024, 11(1): 122-132.
Zhang Zhen, Xiao Ying, Ren Yongjian, et al. Application of EEMD-BP method based on meteorological factors in grid electricity consumption forecast[J]. Southern Energy Construction, 2024, 11(1): 122-132.

收稿日期: 2025-01-27; 修回日期: 2025-07-06

作者简介:

钟卓玲(2000—),女,通信作者,硕士研究生,研究方向为波浪发电功率预测。E-mail:2419933416@qq.com

杨俊华(1965—),男,博士,教授,研究方向为电机电器及其控制、风力发电机组的设计与控制。
E-mail:yly93@gdut.edu.cn

林炳骏(1997—),男,硕士研究生,研究方向为波浪发电系统功率优化。E-mail:583722149@qq.com

吕世强(1999—),男,硕士研究生,研究方向为波浪发电系统模糊控制与功率优化。E-mail:674930699@qq.com

邓存杰(1999—),男,硕士研究生,研究方向为直驱式波浪发电系统自适应参数估计与功率控制。
E-mail:dengcunjie@163.com

于欢欢(1999—),男,硕士研究生,研究方向为直驱式波浪发电系统功率优化。E-mail:2080001843@qq.com

(编辑 王克祥)