

李世林, 王李东, 刘晓阳, 等. 径流式水电站出力预测的学习模型研究[J]. 水利水电技术(中英文), 2025, 56(1): 193-202. DOI: 10.13928/j.cnki.wrahe.2025.01.016

LI Shilin, WANG Lidong, LIU Xiaoyang, et al. Study on power prediction of runoff hydropower station based on learning model [J]. Water Resources and Hydropower Engineering, 2025, 56(1): 193-202. DOI: 10.13928/j.cnki.wrahe.2025.01.016

径流式水电站出力预测的学习模型研究

李世林¹, 王李东², 刘晓阳², 马光文¹, 黄炜斌¹, 朱燕梅¹

(1. 四川大学 水利水电学院, 四川 成都 610065; 2. 中国长江电力股份有限公司, 湖北 宜昌 443000)

摘要:【目的】准确的径流式水电站出力预测对于拟定发电调度计划、电力保供策略至关重要。针对径流式水电站发电出力随机性强, 直接预测精度低等特点, 提出一种基于自适应变分模态分解和时间卷积网络(TCN)的组合预测模型。【方法】首先利用鲸鱼群算法(WOA)对变分模态分解(VMD)的参数进行优选, 实现原始出力序列的最优自适应分解, 然后对分解后的每个分量分别建立TCN模型进行趋势预测, 最后将所得结果重构得到最终预测结果。【结果】结果显示: 与其他模型相比, 所提模型在相同条件下预测效果更优。在非汛期, 所提模型决定系数 R^2 为97.08%、平均相对误差MRE为3.68%、均方根误差RMSE为10.05 MW; 在汛期, 所提模型决定系数 R^2 为93.71%、平均相对误差MRE为8.09%、均方根误差RMSE为32.96 MW。【结论】结果表明: (1)WOA-VMD方法能够有效地提取径流式水电站出力序列的特征, 降低自身数据的不稳定性对预测结果造成的影响; (2)相比于VMD-TCN、TCN、LSTM、RNN、BP五种模型, 所提出的WOA-VMD-TCN预测模型能有效提升水电站出力预测精度, 为径流式水电站短期出力预测提供了一种新的、有效的建模思路。

关键词: 径流式水电站; 功率预测; 鲸鱼群算法; 变分模态分解; 时间卷积网络; 影响因素

DOI: 10.13928/j.cnki.wrahe.2025.01.016

开放科学(资源服务)标志码(OSID):

中图分类号: TV747

文献标志码: A

文章编号: 1000-0860(2025)01-0193-10



Study on power prediction of runoff hydropower station based on learning model

LI Shilin¹, WANG Lidong², LIU Xiaoyang², MA Guangwen¹, HUANG Weibin¹, ZHU Yanmei¹

(1. College of Water Resources and Hydropower, Sichuan University, Chengdu 610065, Sichuan, China;

2. China Yangtze Power Co., Ltd., Yichang 443000, Hubei, China)

Abstract: [Objective] Accurate power prediction of a runoff hydropower station is crucial for formulating generation scheduling plans and ensuring a reliable power supply strategy. Considering the strong randomness in the generation output of runoff hydropower stations and the low accuracy of direct prediction, a combined prediction model based on Adaptive Variational Mode Decomposition (VMD) and Temporal Convolutional Network (TCN) was proposed. [Methods] Initially, the Whale Optimization Algorithm (WOA) is employed to optimize the parameters of Variational Mode Decomposition (VMD), achieving optimal

收稿日期: 2023-12-18; 修回日期: 2024-04-01; 录用日期: 2024-04-08; 网络出版日期: 2025-01-20

基金项目: 中国长江电力股份有限公司项目“关联水电站发电能力及蓄能变化趋势研究”(2423020031); 国家重点研发计划(2018YFB0905204)

作者简介: 李世林(1999—), 男, 硕士研究生, 主要从事梯级水库智能运行管理研究。E-mail: 1849737579@qq.com

通信作者: 马光文(1960—), 男, 教授, 博士研究生导师, 博士, 主要从事水电运行管理及电力市场研究。E-mail: magw8158@163.com

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

adaptive decomposition of the original output sequence. Subsequently, TCN model is individually established for trend prediction of each decomposed component. Finally, the obtained result are reconstructed to obtain the final prediction. [Results]The result shows that, compares to other models, the model established has varying degrees of improvement in prediction performance under the same conditions. [Conclusion]The result indicates: (1) The WOA-VMD method can effectively extract the characteristics of the output sequence of a runoff-type hydropower station and reduce the influence of the instability of its own data on the prediction result. (2) Compared to the five models of VMD-TCN, TCN, LSTM, RNN and BP, the proposed WOA-VMD-TCN prediction model can effectively improve the prediction accuracy of hydropower station power, providing a new and effective modeling approach for power prediction of runoff hydropower stations.

Keywords: runoff hydropower station; power prediction; whale swarm algorithm; Variational Mode Decomposition (VMD); Temporal Convolutional Network (TCN); influencing factors

0 引言

水电作为一种清洁、可再生能源, 在实现“双碳”目标的过程中具有极其重要的作用^[1-2]。径流式水电站分布广泛, 在电力工业中占据不可替代的地位^[3]。随着我国大力开发水电能源, 径流式水电装机规模逐年上升, 但由于水电机组出力受天然径流影响较大, 导致径流式水电站弃水和缺电问题频发^[4]。准确的径流式水电站出力预测对于拟定发电调度计划、保障电网稳定运行至关重要。

水能到电能的转化涉及一个复杂的非线性过程, 建立准确可靠的预测模型是研究的重要问题。何勇等^[5]针对小水电历史数据做样本分类并提取特征, 然后选取相关程度较大的特征建立了 BP 网络模型预测小水电装机日利用小时数; 刘晨曦等^[6]通过对大小水电的发电能力进行相关性分析, 构建基于大水电发电能力的小水电发电能力预测模型; 张海峰等^[7]通过建立水电拓扑结构, 捕捉水电站的上下游关联特征, 然后基于迁移学习构建目标水电站的发电预测模型。以上研究方法主要是水电站之间以及单站自身数据的关联分析, 而没有捕捉时间序列前后数据的关联性, 未能充分挖掘时间序列中的潜在信息。

KONSTANTINA 等^[8]尝试考虑历史数据和当前数据的数据关系, 根据前一日或者前几日的历史数据, 建立不同的机器学习模型来预测小水电站的发电量, 取得了较好的预测效果。胡尧等^[9]首先构建 CNN 卷积神经网络进行历史出力特征提取, 再引入双向门控循环单元(BiGRU)获取出力序列在时间尺度上前后的关联性, 预测效果较好。梁曦文等^[10]首先通过 ESMD 对原始出力数据进行模态分解, 以消除非平稳性因素对于预测结果的影响, 然后根据偏自相关函数(PACF)分析时间序列前后相关性, 选择关联程度更

大的因子作为输入特征量, 最后基于机器学习模型 LSSVM, 建立了基于 ESMD-LSSVM 的组合预测模型, 模拟性能较好。综上, 深入分析时间序列、挖掘并提取其自身特征, 并通过机器学习模型进行预测, 成为提高预测精度的关键。

径流式水电站的实际出力序列受到来水变化、机组效率及水力损失等因素的影响, 存在负荷不规律性变化、急增急减等不平稳现象, 如果直接采用机器学习预测模型进行训练, 会使得预测误差偏大。极点对称模态分解 ESMD^[11-12]和变分模态分解 VMD^[13-14]等信号分解方法, 已经广泛应用于时序数据平稳性处理。虽然 ESMD 方法能够有效解决模态混叠的问题和发掘序列数据的内在特性, 但是 ESMD 分解出的高频分量波动较大, 数值差异明显, 受到预测模型预测机制和适用性边界的限制, 高频分量的预测准确率还有待提升^[10-15]。相较于 EMSD 分解而言, VMD 的性能更好, 它能够将高频信号进一步细化得到多个简单的子序列, 且分解效果好、分解序列较少^[15]。变分模态分解 VMD 在对原始数据进行分解的过程中, 分解个数 k 和惩罚因子 a 这两个参数需要人为确定, 往往很难取到最优解, 会影响实际预测过程中的准确性和时效性, 因此, 需优化算法进行参数的优选^[16]。

近年来, 随着深度学习的不断发展, 多种深度学习模型已经被广泛应用于时间序列预测领域, 其中包括递归神经网络(RNN)、长短期记忆网络(LSTM)及时间卷积网络(TCN)。RNN 模型在训练过程中容易出现梯度消失或爆炸的问题, 同时也难以处理长期依赖^[17]。为了解决这个问题, 有学者提出了 LSTM 模型, 它通过引入门控机制来捕捉和保留长期依赖关系^[18]。然而由于 LSTM 具有较多的参数, 可能导致计算速度缓慢。相较于 RNN 和 LSTM 两种模型, TCN 模型能够避免梯度消失的问题, 具有更大的感

受野且能够并行计算^[19], 在处理时间序列数据上表现出色。目前 TCN 在光伏功率预测^[20-21]及电力负荷预测^[22]等领域已取得良好效果。

为了探索 VMD 模态分解方法和 TCN 模型在水电站出力预测问题上的潜力, 本文利用电站实际运行数据进行数据预处理和相关性分析, 然后采用可有效分解复杂时间序列的 VMD 方法, 并结合鲸鱼群算法 WOA 进行参数优选, 再进一步地结合时间卷积网络模型 TCN, 建立了基于 WOA-VMD-TCN 的预测模型, 最后将其与其他模型预测结果进行对比分析, 旨在为水电站出力预测提供新的科学思路。

1 研究方法

1.1 Spearman 相关性分析

Spearman 相关性分析是一种非参数方法, 不依赖于数据的具体分布形式^[23]。在存在极端值的情况下, Spearman 相关性系数相对较为鲁棒, 不容易受到极端值的影响。故本文选择 Spearman 相关性系数进行相关性分析, 公式如下

$$\rho = \frac{\sum_i (R_i - \bar{R})(S_i - \bar{S})}{\sqrt{\sum_i (R_i - \bar{R})^2 \sum_i (S_i - \bar{S})^2}} \quad (1)$$

式中, R_i 、 R 为两个已排序变量的观测值秩次; \bar{R} 、 \bar{S} 为两个变量的平均秩次; N 为每种变量的总数量。

1.2 变分模态分解

变分模态分解于 2014 年, 由 DRAGOMIRETSKIY 等^[24]提出。该算法具有优越的非参数性、适应性和可解释性, 能有效提取信号中不同频率成分, 广泛应用于信号处理和振动分析, 其约束变分模型为

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

式中, K 为解结果中模态分量的总数; ∂_t 为梯度; δ_t 为狄拉克分布; j 为虚数单位; $*$ 为卷积算子; $u_k(t)$ 为调幅调频函数; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 为各模态分量对应的中心频率; $\{u_k\} = \{u_1, u_2, \dots, u_k\}$ 为解结果, 即模态分量; $f(t)$ 为原始信号; t 为时间变量。

对于有约束的问题, 求解过程比较困难。为方便求解, 在公式(2)中加入拉格朗日算子 λ , 并设置惩罚, 而惩罚的程度由惩罚因子 a 的大小决定^[25], 从而将有约束问题成功转化为无约束问题。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = a \sum_{k=1}^K \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + [\lambda(t), f(t) - \sum_{k=1}^K u_k(t)] \quad (3)$$

该算法中有两个重要的因子, 即 k 和 a , 它们的取值会直接影响模态分解的效果。本文提出采用鲸鱼群算法进行调整, 以更准确地确定变分模态分解算法的参数。

1.3 包络熵

包络熵能够反映信号的随机性和复杂性, 经过 VMD 分解的 IMF 分量信号的局部包络熵越小, 分量信号越简单, 复杂程度越低, 规律性越强。包络熵的计算公式^[26]如下

$$\begin{cases} E_F = - \sum_{i=1}^m p_i \log_2 p_i \\ p_i = a(i) / \sum_{i=1}^m a(i) \end{cases} \quad (4)$$

式中, E_F 为 IMF 信号的包络熵; m 为 IMF 信号长度; p 为信号概率分布; $a(i)$ 为 IMF 信号经希尔伯特解调得到的包络信号序列。

1.4 鲸鱼群算法

WOA 即鲸鱼群算法, 是由 MIRJALILI 等^[27]于 2016 年首次提出的一种元启发式优化算法。该模型具有搜索速度快、收敛范围广以及参数简单等优点^[28]。该算法有三个重要的计算步骤。

(1) 围剿猎物。WOA 算法假设当前最佳候选解即为猎物位置, 其他鲸鱼则计算它们当前位置到最优解的距离, 并朝着当前最佳解的方向聚拢, 从而促使整个群体在搜索空间中协同寻找最优解。计算公式如下

$$X(m+1) = X^*(m) - A |CX^*(m) - X(m)| \quad (5)$$

$$A = 2a_0 r_1 - a \quad (6)$$

$$C = 2r_2 \quad (7)$$

$$a_0 = 2 - 2m/m_{\max} \quad (8)$$

式中, $X(m+1)$ 为下一次位置向量; $X(m)$ 为当前位置向量; $X^*(m)$ 为最优解的位置向量; m 为迭代次数; m_{\max} 为最大迭代次数; r_1 、 r_2 为 $[0, 1]$ 范围内的随机向量; A 、 C 为系数向量; a_0 为收敛因子。

(2) 螺旋气泡攻击。鲸鱼在准备捕获猎物时, 会同时出现两种行为, 即收缩包围圈和气泡捕食, 所以在进行数学公式表达时, 引入捕食概率 p (p 在 $[0, 1]$ 范围内), 来确定鲸鱼的行动方式^[29]。计算

公式如下

$$X(m+1) = \begin{cases} X^*(m) - AD, & p < 0.5 \\ De^{bl} \cos(2\pi l) + X^*(m), & p \geq 0.5 \end{cases} \quad (9)$$

式中, D 为鱼到最优解的距离; b 为个常数, 称为螺旋常数; l 为 $[-1, 1]$ 范围内的随机数。

(3) 寻觅猎物。| A | 的大小, 对于鲸鱼的行为具有决定性意义。为了能够实现全局搜索, 鲸鱼需要判断与同伴的位置关系再采取行动。如果 | A | 大于 1, 鲸鱼会进行随机搜索。计算公式如下

$$X(m+1) = X_{rand}(m) - A |CX_{rand}(m) - X(m)| \quad (10)$$

式中, $X_{rand}(m)$ 为前任意一条鲸鱼的位置。

1.5 时间卷积网络 TCN

TCN 由 BAI 等^[30] 于 2018 年提出, 在 TCN 的模型结构中, 采用了扩展因果卷积结合残差连接的方式。扩展因果卷积结构如图 1 所示。扩展卷积可避免普通卷积由于层数过多而带来的梯度消失、训练复杂等问题。




图 1 扩展因果卷积

Fig. 1 Expand causal convolution

对于时间序列输入 x_t , 扩展因果卷积计算公式^[31] 为

$$F(t) = \sum_{i=0}^{k-1} f(i)x_{t-di} \quad (11)$$

式中, d 为洞系数; k 为积核大小; $f(i)$ 为积核中第 i 个元素。

残差块通过引入残差学习机制提高深度网络对时间序列复杂模式的建模能力, 如图 2 所示。

2 预测模型

本研究建立 WOA-VMD-TCN 组合预测模型以提高径流式水电站出力预测的精度, 如图 3 所示。组合模型步骤如下。

(1) 对径流式水电站的实际运行数据(包括: 发

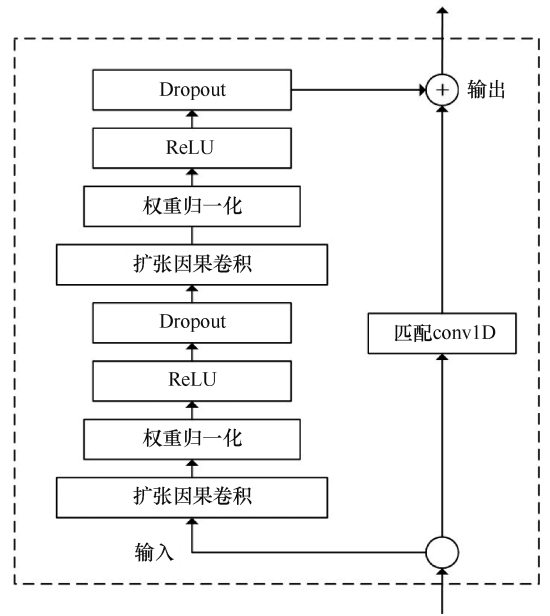


图 2 TCN 残差块

Fig. 2 TCN residual block

电出力、入库流量、出库流量、坝上水位及水头) 进行数据预处理, 得到电站日内 96 点运行序列。

(2) 对数据进行 Spearman 相关性分析, 筛选出与出力相关性较高的特征序列, 作为输入特征量。

(3) 采用 WOA, 以包络熵值作为适应度函数对 VMD 分解参数 k 和 a 进行优选。

(4) 通过参数优选后的 VMD 模型对出力序列进行信号分解, 得到多个 IMF 分量。

(5) 将步骤(2)筛选出的特征量作为输入, 并将分解后的出力数据分量作为输出, 最后分别构建 TCN 模型并进行预测。

(6) 重构各 IMF 分量的输出值, 得到最终的径流式水电站出力预测序列。

3 算例分析

为了验证 WOA-VMD-TCN 模型的实际运用效果, 本文选取四川某径流式水电站 2021 年 1 月 1 日—10 月 31 日的实际运行数据进行建模分析, 该数据包括发电出力、入库流量、出库流量、坝上水位及水头 5 组数据。

3.1 数据预处理和样本制作

3.1.1 数据预处理

水电站通过信息采集系统获取发电出力、水库水位和流量数据。由于仪器故障、数据传输错误或操作失误, 可能导致部分数据缺失或异常。对比完整时间序列和原始数据, 发现缺失数据仅占 1%。为了简

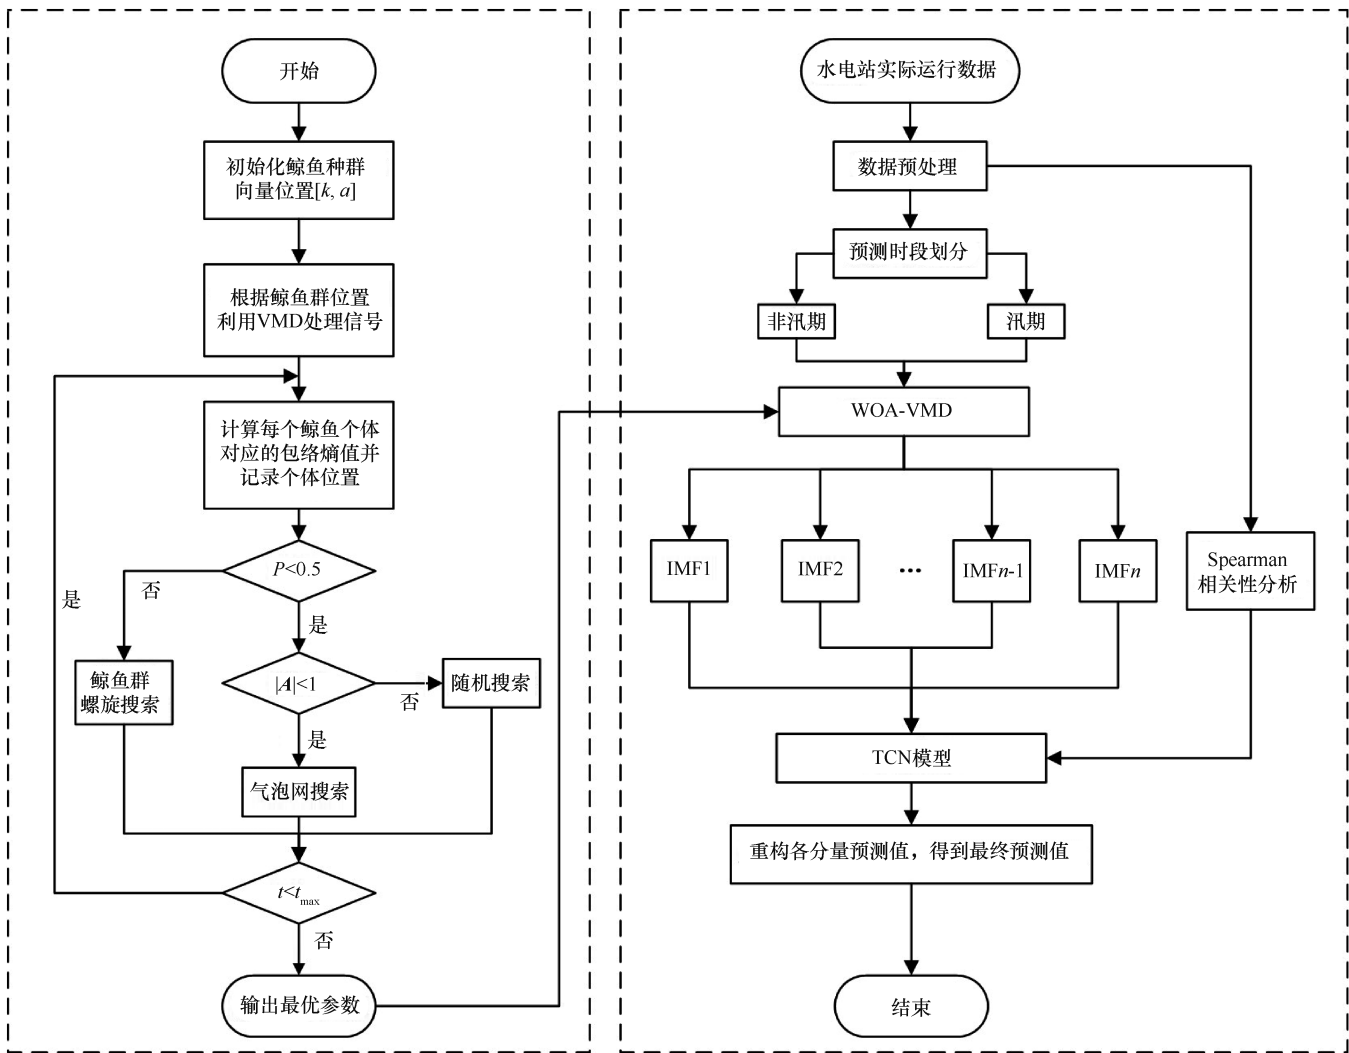


图3 预测模型流程

Fig. 3 Flowchart of forecast model

便操作,选择用线性内插代替含有空缺值的数据。异常值检测采用基于特征值的方法,如出入库流量不可能为负数,坝上水位不可能低于死水位,发电功率不可能高于额定装机等。异常值用前后值的均值替代。

3.1.2 样本制作

由于径流式水电站发电受到来水变化的直接影响^[32],因此本文结合长江上游汛期和非汛期的划分时段分别进行模型的预测验证,1—4月作为非汛期的模拟时段,5—10月作为汛期的模拟时段。以汛期末最后3 d作为测试集,其余部分按9:1划分出训练集和验证集。训练集用于训练初始出力序列预测模型;验证集用于防止过拟合,在训练过程中进行模型验证;测试集用于评估所提预测方法的预测性能。

采用滑动窗口法制作输入-目标对,利用过去 M 个时间步的特征量值预测未来 N 个时间步的出力值。本文选择 $M=96 \times 2$, $N=4$,作为模型输入值和目标值

的长度,即利用过去 2 d 的输入特征量值预测未来 1 h 的出力值。

3.2 评价指标

运用决定系数 R^2 、平均相对误差 MRE 和均方根误差 $RMSE$ 三种指标对模型的预测性能进行评估,其计算公式分别为

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (12)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \frac{|X_i - Y_i|}{X_i} \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2} \quad (14)$$

式中, n 为总的预测次数; X_i 为实际值(MW); Y_i 为预测值(MW); \bar{X} 为实际值的平均值(MW); R^2 为因

变量能被自变量变化所解释的比例, R^2 越接近 1, 表明模拟精度越高。 $RMSE$ 和 MRE 值越小, 则预测误差越小。

3.3 参数设置

模型参数对训练和预测结果的影响显著, 精确的参数设定对模型的模拟效果起着至关重要的作用。经过多次试验验证, 最终确定各模型的相关参数设定, 如表 1 所列。

表 1 模型参数

Table 1 Parameters of models

模 型	可调参数	各时段参数值	
		非汛期	汛 期
WOA	初始种群数	20	20
	最大迭代次数	200	200
	变量个数	2	2
	k 搜索范围	[2, 15]	[2, 15]
	a 搜索范围	[100, 3 000]	[100, 3 000]
VMD	k	5	6
	a	900	1 500
TCN	卷积核数量	64	64
	卷积核大小	2	2
	残差块数量	1	1
	扩张率列表	(1, 2, 4, 8, 16, 32)	(1, 2, 4, 8, 16, 32)
	舍弃率	0.05	0.02
	batchsize	512	512
	epoch	10	15
	残差块激活函数	ReLU	ReLU
	优化算法	Adam	Adam
	学习率	0.002	0.003
损失函数	MSE	MSE	

3.4 相关性分析

Spearman 相关系数如表 2 所列。当相关系数达到 0.6 以上时, 就可认为强相关。由此, 本文筛选与历史发电功率相关性系数在 0.6 以上的特征值作为输入, 筛选后剩余的输入特征量为历史出力、入库流量、出库流量和水头。即本文提出的模型及相关对比模型的输入特征量均为历史出力、入库流量、出库流量和水头。

表 2 各特征量与发电出力的 Spearman 相关性系数

Table 2 Spearman correlation coefficient of each factor and power generation

时 段	入库流量	出库流量	坝上水位	水 头
非汛期	0.928	0.985	0.153	0.973
汛 期	0.756	0.784	0.126	0.859

由表 2 可知, 在非汛期, 各特征量与发电出力之间的相关性较高。这是由于来水量较为有限, 电站运行主要基于实际需求, 按来水流量来进行发电。相比

之下, 在汛期, 电站需要采取防洪措施, 对水位进行更大范围的调控, 同时存在弃水过程, 因而导致各特征量与发电出力之间的相关性降低。

3.5 数据分解

将原水电出力数据序列按照非汛期和汛期两个时段采用 WOA-VMD 方法分别进行分解, 并由低频至高频进行排列(见图 4)。从图 4 可以看出, 趋势项整体呈现一定规律性, 能够大致反映水电出力的变化规律。在非汛期, 由于来水较少, 且随机性较强, 所以在趋势项中出力呈现上升和下降交替进行的趋势; 在汛期, 水库来水比较充足, 所以整体来看水电出力值较为平稳, 维持在一个较高的水平。在周期项中, 曲线快速上下波动, 反映出日内水电出力的波动性和随机性较强。而其余子序列, 按照一定频率平稳的进行高频振动, 具有一定的规律性。因此, 水电出力原始序列经过分解以后, 数据信号被划分为更为简单、更有规律的分量, 能够消除非平稳性因素的影响且凸显出力序列的数据特征。

3.6 结果讨论

为验证 WOA-VMD-TCN 模型的预测效果, 本研究将 WOA-VMD-TCN 模型与 VMD-TCN、TCN、LSTM、RNN 及 BP 五种模型的模拟效果进行对比, 如图 5 和图 6 所示, 图 5 展示了 2021 年 4 月 28 日—30 日的预测效果, 图 6 展示了 2021 年 10 月 29 日—31 日的预测效果。由图 5 可知, 在非汛期 WOA-VMD-TCN 模型的预测曲线和实际发电出力曲线最为接近。对比传统的机器学习 BP 模型和时序模型, 能够看出在长序列样本预测上, 时序模型更加具有优势; 对比 TCN、LSTM 和 RNN 模型, 能够看出 TCN 模型的泛化能力更好, 对于出力数据能够更好地预测; 对比 VMD-TCN 模型和 TCN 模型, 前者对于突变数据的预测效果更好, 说明 VMD 模态分解能够有效地降低数据的不平稳性, 增加模型预测的准确率; 对比 WOA-VMD-TCN 模型和 VMD-TCN 模型能够看出, VMD 经过参数优选后确实能够提高 TCN 模型的预测精度。由图 6 可知, 整体来看, 6 种模型的预测效果较优, 且依然能够得出结论: 在现有数据条件下, 本文所提模型更加具有优势。但综合图 5 和图 6 的结果显示, 6 种模型在预测突变值、低值点和高值点时存在一定的误差。这可能源于两个主要原因: 第一, 所选取的数据样本序列较为短暂, 数据量有限, 导致模型无法充分捕捉数据的变化规律; 第二, 本文提出的模型主要集中在模型本身的优化和改进上, 并未对原始数据进行充分地处理和分析。因此, 未来的研究可





图 4 水电出力 VMD 分解

Fig. 4 VMD decomposition diagram of hydropower power

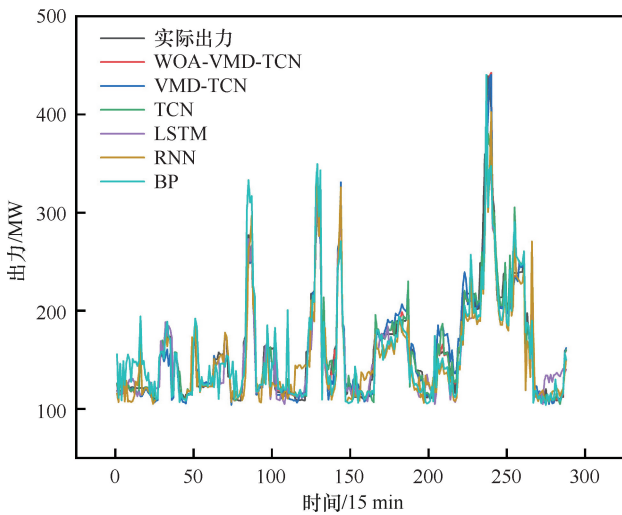


图 5 非汛期预测结果

Fig. 5 Prediction results of non-flood season




图 6 汛期预测结果

Fig. 6 Forecast results for flood season

以探索如何从数据源头入手, 提升数据的质量, 并进行更深入地分析和处理, 以进一步提升预测精度。

利用 3 种评价指标 R^2 、 MRE 、 $RMSE$ 对两个不同时段 6 种预测模型的模型性能进行评价, 预测误差计

算结果, 如表 3 所列。

表 3 评价指标计算结果

Table 3 The results of the evaluation metric calculations.

时段	模型	误差指标		
		$R^2/\%$	$MRE/\%$	$RMSE/MW$
非汛期	WOA-VMD-TCN	97.08	3.68	10.05
	VMD-TCN	95.54	5.16	12.28
	TCN	93.48	5.22	14.89
	LSTM	86.33	8.76	22.56
	RNN	85.49	9.47	22.94
	BP	81.05	10.22	25.56
汛期	WOA-VMD-TCN	93.71	8.09	32.96
	VMD-TCN	92.76	9.47	35.72
	TCN	91.77	10.92	37.81
	LSTM	87.97	13.86	45.63
	RNN	86.48	17.07	48.38
	BP	83.50	20.13	55.93

由表 3 可知, 本文所提模型 WOA-VMD-TCN 的预测误差显著低于其他模型。在非汛期, 本文模型相比于 VMD-TCN、TCN、LSTM、RNN、BP 这 5 种对比模型, R^2 分别增加了 1.54%、3.60%、10.74%、11.59%、16.02%; MRE 分别减少了 1.47%、1.53%、5.08%、5.78%、6.54%; $RMSE$ 分别减少了 2.23 MW、4.84 MW、12.51 MW、12.89 MW、15.51 MW, 体现出 WOA-VMD-TCN 模型的模拟性能更优, 预测误差更小。在汛期, 通过比较各模型的指标计算结果依然能够得出结论, 即在相同条件下, 本文提出模型对比其他模型更加具有优势, 预测精度更高。

另外, 通过对比 TCN、LSTM、RNN 与 BP 模型, 能够得出时序模型在处理长系列数据预测方面上具有显著优势; 对比 TCN、LSTM 与 RNN 模型, 验证了基础模型 TCN 的优势, 泛化能力更好; 对比 VMD-TCN 与 TCN 模型, 能够看出原始出力序列经过模态分解后, 能够消除数据本身的不平稳性, 提高预测精度; 对比 WOA-VMD-TCN 与 VMD-TCN 模型, 能够看出经过参数优选后再进行原始数据信号模态分解, 在预测效果上更加具有优势。

其次, 通过对比非汛期和汛期两个时间段的预测效果, 能够得出结论: 非汛期的预测效果优于汛期的预测效果, 这从侧面验证了在非汛期发电出力与其余特征的相关性更高, 而汛期由于受到防洪要求、库容等限制, 导致发电出力与其余特征的相关性较弱, 这也体现了在数据处理阶段针对非汛期和汛期进行分别预测的必要性。

4 结论

本文针对径流式水电站出力波动性大、随机性强等特点, 提出了一种基于自适应变分模态分解和时间卷积网络(TCN)的组合预测模型, 即 WOA-VMD-TCN 预测模型。得出如下结论:

(1) Spearman 相关性分析可用于分析径流式水电站出力序列与其他特征值的相关性, 从而确定序列中的特征量。

(2) 采用 WOA 算法针对 VMD 模型进行参数优选, 能够提升分解效果并降低非平稳性因素的影响, 进而提高 TCN 模型的预测性能。

(3) WOA-VMD-TCN 模型在四川某径流式水电站出力预测中取得了良好效果, 为水电站出力预测提供了一种新的思路。

参考文献(References):

- [1] 张建云, 周天涛, 金君良. 实现中国“双碳”目标 水利行业可以做什么[J]. 水利水运工程学报, 2022(1): 1-8.
ZHANG J Y, ZHOU T T, JIN J L. What can the water conservancy industry do to achieve China's "dual carbon" goals? [J]. Journal of Water Resources and Water Engineering, 2022(1): 1-8.
- [2] 白雪. 水电在实现“双碳”目标构建新型电力系统中发挥关键作用[N]. 中国经济导报, 2023-08-05(3).
BAI X. Hydropower plays a key role in realizing the "dual carbon" goal and building a new power system[N]. China Economic Herald, 2023-08-05(3).
- [3] 徐玮, 罗欣, 刘梅, 等. 用于小水电地区负荷预测的两阶段还原法[J]. 电网技术, 2009, 33(8): 87-92.
XU W, LUO X, LIU M, et al. Two-stage restoration method for load forecasting in small hydropower areas[J]. Power System Technology, 2009, 33(8): 87-92.
- [4] 曾洁. 小水电发电负荷预测的研究[D]. 武汉: 华中科技大学, 2019.
ZENG J. Research on Load Forecasting of Small Hydropower Generation [D]. Wuhan: Huazhong University of Science and Technology, 2019.
- [5] 何勇, 李刚, 孙永军, 等. 基于模糊聚类和 BP 神经网络的小水电短期发电能力预测方法[J]. 水电能源科学, 2014, 32(11): 188-192.
HE Y, LI G, SUN Y J, et al. Short-term generation capacity prediction method for small hydropower based on fuzzy clustering and BP neural network[J]. Water Resources and Power, 2014, 32(11): 188-192.
- [6] 刘晨曦, 李刚, 程春田, 等. 大小水电相关分析的地区小水电发电能力预测方法[J]. 水电能源科学, 2016, 34(8): 63-66.
LIU C X, LI G, CHENG C T, et al. Regional small hydropower

- generation capacity prediction method based on correlation analysis of large and small hydropower[J]. *Water Resources and Power*, 2016, 34(8): 63-66.
- [7] 张海锋, 杨晶莹, 冷俊, 等. 基于图迁移学习的梯级水电发电超短期预测[J]. *电网与清洁能源*, 2023, 39(10): 104-112.
ZHANG H F, YANG J Y, LENG J, et al. Cascaded hydropower generation ultra-short-term forecasting based on graph transfer learning [J]. *Power Grid and Clean Energy*, 2023, 39(10): 104-112.
- [8] KONSTANTINA D K, KONSTANTINA S G, LOANNIS T, et al. Day-ahead energy production in small hydropower plants: Uncertainty-aware forecasts through effective coupling of knowledge and data[J]. *Advances in Geosciences*, 2022, 56: 155-162.
- [9] 张建云, 金君良. 国家水网建设几个方面问题的讨论[J]. *水利发展研究*, 2023, 23(11): 1-7.
ZHANG Jianyun, JIN Junliang. Discussion on several issues concerning the construction of national water network [J]. *Water Resources Development Research*, 2023, 23(11): 1-7.
- [10] 梁曦文, 肖峰, 闵昊凌, 等. 基于 ESMD-LSSVM 模型的径流式水电站出力预测研究[J]. *中国农村水利水电*, 2023(9): 224-229.
LIANG X W, XIAO F, MIN H L, et al. Research on run-of-river hydropower station output prediction based on ESMD-LSSVM model [J]. *China Rural Water Conservancy and Hydropower*, 2023(9): 224-229.
- [11] 王国娟, 冷建伟. 基于 ESMD-PE 和 ADBN 的短期电力负荷预测[J]. *电测与仪表*, 2023, 60(1): 29-35.
WANG G J, LENG J W. Short-term power load forecasting based on ESMD-PE and ADBN [J]. *Electrical Measurement and Instrumentation*, 2023, 60(1): 29-35.
- [12] 刘尚东, 孙东永, 许晶晶, 等. 基于 ESMD-NNBR 耦合的月径流预测模型[J]. *水文*, 2023, 43(1): 52-56.
LIU S D, SUN D Y, XU J J, et al. Monthly runoff prediction model based on ESMD-NNBR coupling[J]. *Hydrology*, 2023, 43(1): 52-56.
- [13] 杨健, 孙涛, 陈小龙, 等. 基于 VMD-EWT-IASSP-EBILSTM 的短期电力负荷预测[J]. *科学技术与工程*, 2023, 23(27): 11646-11654.
YANG J, SUN T, CHEN X L, et al. Short-term power load forecasting based on VMD-EWT-IASSP-EBILSTM [J]. *Science Technology and Engineering*, 2023, 23(27): 11646-11654.
- [14] 李飞宏, 肖迎群. 基于 VMD-GRU-EC 的短期电力负荷预测方法[J]. *中国测试*, 2023, 49(10): 120-127.
LI F H, XIAO Y Q. Short-term electricity load forecasting method based on VMD-GRU-EC[J]. *China Measurement & Testing*, 2023, 49(10): 120-127.
- [15] 李昂, 张坤, 桑宇婷, 等. 基于 ESMD-VMD-ESN 二次分解组合模型的水位预测[J]. *人民珠江*, 2022, 43(11): 116-121.
LI A, ZHANG K, SANG Y T, et al. Water level prediction based on ESMD-VMD-ESN quadratic decomposition combined model [J]. *People's Pearl River*, 2022, 43(11): 116-121.
- [16] 李宏扬, 高丙朋. 基于改进 VMD 和 SNS-Attention-GRU 的短期光伏发电功率预测[J]. *太阳能学报*, 2023, 44(8): 292-300.
LI H Y, GAO B P. Short-term PV power prediction based on improved VMD and SNS-Attention-GRU[J]. *Journal of Solar Energy*, 2023, 44(8): 292-300.
- [17] 宋绍剑, 李博涵. 基于 LSTM 网络的光伏发电功率短期预测方法的研究[J]. *可再生能源*, 2021, 39(5): 594-602.
SONG S J, LI B H. Research on short-term forecasting method of photovoltaic power generation based on LSTM network [J]. *Renewable Energy*, 2021, 39(5): 594-602.
- [18] 闫孟婷, 黄炜斌, 张天遥, 等. 基于 JMI-CNN-LSTM 耦合模型的梯级水电站间流量动态滞时关系[J]. *水利水电技术(中英文)*, 2023, 54(3): 154-164.
YAN M T, HUANG W B, ZHANG T Y, et al. Dynamic lag relationship between inflows of cascade hydropower stations based on JMI-CNN-LSTM coupling model [J]. *Water Resources and Hydropower Engineering*, 2023, 54(3): 154-164.
- [19] LI D, JIANG F, CHEN M, et al. Multi-step-ahead wind speed forecasting based on a hybrid decomposition method and temporal convolutional networks[J]. *Energy*, 2022, 238: 121981.
- [20] 宋绍剑, 姜屹远, 刘斌. 一种 TCN 的改进模型及其在短期光伏功率区间预测的应用[J]. *计算机应用研究*, 2023, 40(10): 3064-3069.
SONG S J, JIANG Y Y, LIU B. An improved TCN model and its application in short-term PV power interval prediction [J]. *Applied Research of Computers*, 2023, 40(10): 3064-3069.
- [21] 吴珺玥, 赵二刚, 郭增良, 等. 基于 Spearman 系数和 TCN 的光伏出力超短期多步预测[J]. *太阳能学报*, 2023, 44(9): 180-186.
WU J Y, ZHAO E G, GUO Z L, et al. Multi-step ultra-short-term forecasting of photovoltaic output based on Spearman coefficient and TCN[J]. *Acta Energetica Solaris Sinica*, 2023, 44(9): 180-186.
- [22] 马越, 温蜜. 基于多尺度 LDTW 和 TCN 的空间负荷预测方法[J]. *计算机工程*, 2024, 50(3): 106-113.
MA Y, WEN M. Spatial load forecasting based on Multi-scale LDTW and TCN networks [J]. *Computer Engineering*, 2024, 50(3): 106-113.
- [23] 吴军英, 路欣, 刘宏, 等. 基于 Spearman-GCN-GRU 模型的超短期多区域电力负荷预测[J]. *中国电力*, 2024, 57(6): 131-140.
WU J Y, LU X, LIU H, et al. Super-short-term multi-regional electricity load forecasting based on Spearman-GCN-GRU model [J]. *China Electric Power*, 2024, 57(6): 131-140.
- [24] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2013, 62(3): 531-544.
- [25] 陈杨. 基于 VMD-SSA-BP 方法的光伏发电短期功率预测[J]. *自动化应用*, 2023, 64(15): 67-70.

- CHEN Y. Short-term power prediction of photovoltaic power generation based on VMD-SSA-BP method [J]. Automation Applications, 2023, 64(15): 67-70.
- [26] 姜飞, 林政阳, 王文焯, 等. 考虑最小平均包络熵负荷分解的最优 Bagging 集成超短期多元负荷预测[J]. 中国电机工程学报, 2024, 44(5): 1777-1789.
- JIANG F, LIN Z Y, WANG W Y, et al. Optimal Bagging ensemble multi-region short-term load forecasting considering minimum mean envelope entropy load decomposition [J]. Proceedings of the Chinese Society for Electrical Engineering, 2024, 44(5): 1777-1789.
- [27] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.
- [28] 沙金霞. 改进鲸鱼算法在多目标水资源优化配置中的应用[J]. 水利水电技术, 2018, 49(4): 18-26.
- SHA J X. Application of improved whale algorithm in multi-objective water resource optimization allocation [J]. Water Resources and Hydropower Engineering, 2018, 49(4): 18-26.
- [29] 祁宇轩, 范俊岩, 吴定会, 等. 基于相似日与 BiLSTM 组合的短期电力负荷预测[J]. 控制理论与应用, 2024, 41(12): 2304-2314.
- QI Y X, FAN J Y, WU D H, et al. Short-term electricity load forecasting based on combined similar days and BiLSTM [J]. Control Theory and Applications, 2024, 41(12): 2304-2314.
- [30] BAI S J, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [EB/OL]. <https://doi.org/10.48550/arXiv.1803.01271>.
- [31] 李发崇, 李鹏, 高莲, 等. 基于多尺度模型融合和 VMD-TCN-RF 混合网络的短期电力负荷预测方法[J]. 电子器件, 2023, 46(4): 1035-1042.
- LI F C, LI P, GAO L, et al. Short-term electricity load forecasting method based on multiscale model fusion and VMD-TCN-RF hybrid network [J]. Electronic Devices, 2023, 46(4): 1035-1042.
- [32] 周业荣, 李相锐, 绳博宇, 等. 水风光蓄互补发电系统中风光容量配置研究[J]. 水利水电技术(中英文), 2023, 54(11): 1-14.
- ZHOU Y R, LI X R, SHENG B Y, et al. Study on capacity configuration of wind and solar power in complementary generation system for water and hydroelectricity [J]. Water Resources and Hydropower Engineering, 2023, 54(11): 1-14.

(责任编辑 王璐)