

基于 CEEMDAN-FESC-OVMD-Transformer 耦合模型的 长江上游月径流预测

徐嘉远^{1,2}, 邹磊¹, 张利平³, 王飞宇⁴, 夏军^{1,3}

(1. 中国科学院地理科学与资源研究所陆地水循环及地表过程重点实验室, 北京 100101;
2. 中国科学院大学资源与环境学院, 北京 100049; 3. 武汉大学水资源与水电工程科学国家重点实验室, 湖北 武汉 430072;
4. 华北电力大学水利与水电工程学院, 北京 102206)

摘要:为提升水文要素非一致性变异背景下的长江上游月径流预测精度,基于宜昌与寸滩水文站 1961—2022 年逐月径流数据,构建了基于自适应噪声完备集合经验模态分解(CEEMDAN)、模糊熵(FE)、谱聚类(SC)、最优变分模态分解(OVMD)与 Transformer 深度学习模型耦合的 CEEMDAN-FESC-OVMD-Transformer 混合预测模型对长江上游月径流进行模拟预测。结果表明:CEEMDAN-FESC-OVMD-Transformer 混合预测模型在宜昌与寸滩水文站具有较好的月径流预测效果,训练期纳什效率系数高于 0.9,测试期纳什效率系数分别达到 0.84 与 0.89;CEEMDAN-FESC-OVMD 分解框架可提升汛期峰值流量预测精度;OVMD 二次分解结构可有效降低月径流高频率序列复杂度,提升径流的预测稳定性。

关键词:月径流预测;CEEMDAN;VMD;Transformer;耦合模型;长江上游

中图分类号:P338 **文献标志码:**A **文章编号:**1004-6933(2025)04-0197-13

Prediction of monthly runoff in upper reaches of the Yangtze River based on coupled model of CEEMDAN-FESC-OVMD-Transformer//XU Jiayuan^{1,2}, ZOU Lei¹, ZHANG Liping³, WANG Feiyu⁴, XIA Jun^{1,3} (1. Key Laboratory of Water Cycle and Related Land Surface Processes, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China; 2. College of Resources and Environment, University of Chinese Academy of Sciences, Beijing 100049, China; 3. State Key Laboratory of Water Resources and Hydropower Engineering Science, Wuhan University, Wuhan 430072, China; 4. School of Water Resources and Hydropower Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: To improve the prediction accuracy of monthly runoff in the upper reaches of the Yangtze River under the background of inconsistent hydrological elements, based on the monthly runoff data from 1961 to 2022 at Yichang and Cuntan hydrological stations, a hybrid prediction model combining complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN), fuzzy entropy (FE), spectral clustering (SC), optimal variational mode decomposition (OVMD), and Transformer deep learning model (CEEMDAN-FESC-OVMD-Transformer) was constructed to simulate and predict the monthly runoff in the upper reaches of the Yangtze River. The results showed that the hybrid model performed well in predicting the monthly runoff at Yichang and Cuntan hydrological stations, with NSE up to 0.9 in the training period, and NSE of 0.84 and 0.89 in the testing period, respectively; the CEEMDAN-FESC-OVMD decomposition framework can improve the accuracy of peak flow prediction during the flood season; the two-stage decomposition structure of the OVMD can effectively reduce the complexity of the high-frequency sequence of monthly runoff, and improve the stability of runoff prediction.

Key words: prediction of monthly runoff; CEEMDAN; VMD; Transformer; coupled model; upper reaches of the Yangtze River

准确的月径流序列预测是水资源规划、洪旱灾害防控与水库优化调度的重要依据^[1-2]。当前,由于高强度的人类活动,温室气体排放增加、全球气温升高、大气湿度与水汽输送的增加与加强、极端降雨与

基金项目:国家重点研发计划项目(2023YFC3006705);长江电力股份有限公司资助项目(Z242302022)

作者简介:徐嘉远(1999—),男,硕士研究生,主要从事流域水循环模拟研究。E-mail:xujiayuan22@mails.ucas.ac.cn

通信作者:邹磊(1990—),男,副研究员,博士,主要从事流域水循环模拟研究。E-mail:zoulel@igsrr.ac.cn

洪水事件频率与强度的增加,破坏了径流序列的平稳性,亟须提升径流预测模型在水文要素非一致性变化背景下的适用性^[3-5]。因此,降低径流预测随机性,从而提升非平稳月径流预测可靠性对于水资源科学管理具有重要意义。

径流预测方法根据模型原理主要包括:①过程驱动模型,具备水文过程物理机制,但模型复杂性与不确定性较高^[1,6];②数据驱动模型,仅利用水文气象数据结合统计方法进行预测,在时间序列分析预测中具有优势^[5,7]。数据驱动模型中,传统水文统计学模型通常基于独立同分布、平稳性与线性等假设限制,难以识别非线性与非平稳变化下的径流序列特征^[1,2,8],而机器学习模型可捕捉径流的非线性特征,但对径流的周期性与非平稳变化考虑不足^[2,5,9-10]。

机器学习模型中,Transformer 深度学习模型可通过多头注意力机制捕捉数据全局信息,在时间序列预测中优于传统递归神经网络^[10-11]。为降低径流序列非平稳性对径流预测的影响,从而提升预测精度,基于信号分解方法与机器学习模型的分解集成预测框架得到广泛应用^[2,7,12]。时间序列的非平稳性是指序列统计特征随时间显著变化的性质^[13]。信号分解方法可通过限制分解的子序列满足相对平稳的条件,将径流序列分解为多个不同频率的子序列从而挖掘其中的关键特征^[14-15],其中,自适应噪声完备集合经验模态分解 (complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN) 与最优变分模态分解 (optimal variational mode decomposition, OVMD) 可减少信号模态混叠现象,且具备优异的抗噪声性能与分解完整性^[13,16]。结合 CEEMDAN、OVMD 与 Transformer 深度学习模型的径流预测框架可同时降低径流非平稳性对径流预测的干扰,并增强径流多频率特征的识别能力,从而提高非平稳径流序列的预测精度。

目前,在基于分解集成框架的径流预测研究中,相关学者通过对最高频子序列进行二次或多次分解并预测,以进一步降低预测的非线性与复杂性^[17-18]。如吴小涛等^[18]利用集合经验模态分解法分解湖北寸滩水文站日径流,采用变分模态分解对频率最高的子序列进行二次分解,并对获取的 20 个子序列分别建立机器学习模型进行预测,结果表明,构建的模型预测精度高于单一模型。然而高频信号分布于多个子序列中,因此部分学者以固定阈值将子序列重构为不同复杂度或频率的序列,并对高频序列进行二次分解与预测。如 Dong 等^[19]对 CEEMDAN 分解的岷江日径流子序列采用模糊熵计算复杂度,并以模糊熵值 0.4 为阈值将各子序列分

为高频与低频序列,对高频序列采用变分模态分解进行二次分解,最终利用机器学习模型分别预测高频与低频序列并重构。结果表明,该方法洪水预报精度较高,提升了预测精度,但阈值设定具有主观性。此外,还有学者利用单一机器学习模型预测分解获得的子序列,或分别构建模型预测各个子序列^[20-21],但前者难以准确预测序列变化的拐点,后者则增加了模型训练的复杂度^[22]。基于此,本文采用抗噪能力较强的模糊熵 (fuzzy entropy, FE) 法计算一次信号分解的径流子序列复杂度^[23-24],利用具有较高数据分布适应性的谱聚类 (spectral clustering, SC) 法将子序列自动聚类重构为高、中、低频序列,并对高频序列进行二次分解^[25],以高频子序列矩阵作为深度学习模型输入识别其多频变化模式,并分别构建模型学习中频与低频时间序列变化,对未来 1 月径流进行滚动预测,以避免人为设定阈值对子序列重构的影响并提升模型精度。

长江上游为宜昌水文站以上控制流域,其径流变化对长江中下游水资源规划与三峡梯级水库调度具有重要意义。因此,本文以长江上游宜昌与寸滩水文站月径流过程为研究对象,基于 CEEMDAN 获取径流子序列,利用模糊熵与谱聚类法重构多频序列,引入 OVMD 对高频序列进行二次分解,结合高频单模型与中低频多模型的混合框架,构建 CEEMDAN-FESC-OVMD-Transformer 混合预测模型,旨在提升长江上游径流预测精度,为非平稳月径流预测提供适用性方案。

1 研究区概况与数据来源

长江流域干流流经高原、山区、盆地以及平原地带^[26],上游流域以宜昌水文站 (30.69°N、111.28°E) 为控制站,包括金沙江、雅砻江、岷江、嘉陵江、乌江等水系。流域地处亚热带季风区,为湿润与半湿润气候,年平均气温为 10~15℃,多年平均降水量为 800~1200 mm。流域径流主要由降雨产流形成,在夏季径流量较大^[27]。图 1 为长江上游流域水文站分布。

采用宜昌与寸滩水文站 1961—2022 年逐月径流数据进行模拟预测研究,其月均流量数据来源于水文年鉴及长江水利委员会水文局。选取每个水文站 1961—2004 年径流数据作为训练集,2005—2022 年径流数据作为测试集用于径流预测,即以 7:3 为比例划分模型训练期与测试期^[28]。

2 模型构建

2.1 CEEMDAN

CEEMDAN 是在经验模态分解 (empirical mode




图1 长江上游流域水文站分布

Fig.1 Distribution of hydrological stations in the upper reaches of Yangtze River Basin

decomposition, EMD) 框架上改进的信号处理方法^[29],其核心是将原始时间序列分解为不同频率的子序列,即本征模态分量(intrinsic mode function, IMF)。其中,EMD 可利用数据序列的自身时间尺度特征进行模态分解,适用于非平稳与非线性时间序列的分解^[30];而 CEEMDAN 则在 EMD 的基础上,通过引入适应性白噪声解决了模态混叠问题,提升了模态分解与重构的精度^[17,31]。

CEEMDAN 首先对原始输入信号添加不同的自适应高斯白噪音,再利用 EMD 法分解每组信号,求得第一阶 IMF 平均值与其残差,之后计算阶数 $k \geq 2$ 时的 IMF 与其残差,当余量序列为常数、单调函数或不穿过 0 时分解结束。本文采用的 CEEMDAN 参数噪声添加次数与噪声权重根据试错法设定为 100 与 0.005。

2.2 模糊熵与谱聚类

模糊熵法是一种用于评估时间序列复杂度的方法^[32]。该方法在近似熵 (ApEn) 和样本熵 (SampEn) 的基础上引入了模糊隶属度函数来处理信号的不确定性;还采用了均值去除操作和基于指数函数的相似度计算策略,从而显著提升了算法的抗噪声性能和稳定性,更适合于信号分解后的序列分类^[23,32]。模糊熵的计算过程如下:对时间序列进行 m 维相空间重构,计算任意 2 个重构向量之间的绝对最大距离,并引入模糊隶属度函数来量化向量间的相似性,最终通过定义关系维度函数实现模糊熵的计算。本文利用模糊熵评价经 CEEMDAN 分解获得 IMF 复杂度,序列的模糊熵越大,序列越复杂。模糊熵的参数设置基于试错法确定:嵌入维数设为 2,相似容限阈值取 0.2,相似容限边界梯度设为 2。

谱聚类法是一种基于图论的聚类分析方法^[33],相较于 K 均值聚类,谱聚类法可对非凸数据集与任意形状数据空间实现最优聚类与划分,具有更强的适应性^[25]。该算法将数据看作空间点,并将点用边

连接,其中距离较远的点间权重低而距离近的点间权重高,图用点的集合与边的集合共同描述。谱聚类过程即将图划分为不同子图(切图)后保证子图内边权重高而间边权重低。本文采用谱聚类法对模糊熵评价的 IMF 进行复杂度聚类,并将对应复杂度的 IMF 重构为不同频率的子序列,作为后续二次分解或预测模型的输入变量。其中,谱聚类的高斯核函数参数根据试错法设定为 0.1。

2.3 OVMD

OVMD 是在变分模态分解 (variational mode decomposition, VMD) 的基础上改进而来的信号分解方法^[34]。VMD 法具有非递归、自适应和准正交等特点,其关键参数——分解层数可通过多种优化方法确定^[20-21]。OVMD 通过中心频率法确定 VMD 的分解层数,在捕捉时间序列的非线性特征方面具有优势。

OVMD 分解过程为:①将原始序列分解为 K 个中心频率为 ω_k 的模态函数,并对模态函数进行 Hilbert 变换;②建立约束性变分问题,并通过 Lagrange 乘子法将其转换为非约束性问题求解 IMF 分量,分解层数根据最小误差指数计算更新步长来确定;③利用 OVMD 对经谱聚类重构的高频序列进行二次分解,将分解获得的 IMF 作为后续模型预测的输入,以降低分解序列的非线性与复杂性,从而提高后续模型的预测精度^[17]。除分解层数外,根据试错法将 OVMD 的惩罚因子参数设定为 2000。

2.4 Transformer 深度学习模型

Transformer 是一种基于多头注意力机制与编码器-解码器架构的深度学习网络^[35]。相较于长短期记忆网络和门控循环单元等常用于时间序列预测的深度学习模型,Transformer 深度学习模型能够识别全序列不同位置的信息,从而充分挖掘长序列中数据的依赖关系。在具体实现上,Transformer 深度学习模型通过多组查询、键与值矩阵计算注意力值,再将其拼接变换,形成多头注意力机制。

Transformer 深度学习模型由输入、编码器、解码器和输出组成。由于本文采用过去多月份径流量作为输入,未来 1 月径流量作为输出,即开展多输入单输出预测,因此需去除模型中的解码器部分。采用的 Transformer 深度学习模型结构包括 2 层编码器、1 层池化层与 1 层全连接层,其核心参数包括输入长度、多头注意力头数、全连接网络单元数、舍弃率、批次大小和迭代次数等。这些模型参数采用试错法从经验取值中筛选出预测效果最优的结果。利用 Transformer 深度学习模型对经 CEEMDAN 与 OVMD 分解并重构的月径流子序列进行预测,再叠加各子

序列的预测结果,最终得到径流的预测值。

2.5 CEEMDAN-FESC-OVMD-Transformer 混合预测模型

CEEMDAN-FESC-OVMD-Transformer 混合预测模型的建立主要包含以下 4 个步骤:①CEEMDAN 径流分解。利用 CEEMDAN 将宜昌与寸滩水文站 1961—2022 年逐月径流数据分别分解为多个频率不同的 IMF。②模糊熵复杂度评估与谱聚类径流重构。计算每个测站月径流分解获得的 IMF 模糊熵,并根据其大小采用谱聚类方法聚类为 3 类^[22],复杂度最高的一类定义为高频序列,最低的一类定义为低频序列,中等复杂度的一类定义为中频序列,并对 3 类序列的 IMF 分别叠加重构。③OVMD 高频径流二次分解。采用 OVMD 将重构的高频径流序列分解为多个 IMF。④Transformer 深度学习模型径流混合预测。以 1961—2004 年为 Transformer 深度学习模型训练期,2005—2022 年为测试期,对模型进行训练与测试。对于高频径流序列,以 OVMD 二次分解获得的多个 IMF 合并为 1 个矩阵作为输入,采用 Transformer 深度学习模型预测未来 1 月的高频径流序列;对于中频与低频径流序列,分别构建独立的 Transformer 深度学习模型预测未来 1 月的序列。将预测的高、中、低频径流序列叠加重构即为预测的未来 1 月径流序列。

CEEMDAN-FESC-OVMD-Transformer 混合预测模型框架见图 2(IMF 下标代表 IMF 序列编号,RES(residual sequence)为余量序列,Transformer_H、Transformer_M和 Transformer_L分别代表以高、中、低频序列为输入的 Transformer 深度学习模型)。

为了评估 CEEMDAN-FESC-OVMD-Transformer 混

合预测模型的预测效果,分别构建 CEEMDAN-FESC-Transformer 模型、CEEMDAN-FESC-EMD-Transformer 模型与 Transformer 深度学习模型预测月径流量,并对预测结果进行对比,分析 CEEMDAN-FESC 分解框架对 Transformer 深度学习模型预测精度的提升效果,评估 OVMD 二次分解结构在 CEEMDAN-FESC-Transformer 模型基础上的预测效果。

2.6 模型评价指标

采用纳什效率系数(NSE)、决定系数(R^2)、均方根误差(RMSE)、平均绝对误差(MAE)和误差标准差^[36-37]作为模型精度与稳定性评价指标以评估模型预测结果,其中 NSE 与 R^2 接近 1 表示模型预测效果较好,RMSE 与 MAE 接近于 0 表示模型预测误差较小,误差标准差较小表明预测稳定性较好。

3 径流预测效果分析

3.1 CEEMDAN 月径流序列分解

利用 CEEMDAN 对宜昌与寸滩水文站月径流序列分别进行信号分解,获得多个不同频率与振幅的 IMF,见图 3 和图 4。可见宜昌与寸滩水文站月径流均具有不平稳变化且振幅较大的特点,符合 CEEMDAN 分解要求。宜昌与寸滩水文站月径流序列均被分解为 7 个 IMF 与 1 个余量序列,月径流不同的 IMF 表现出不同的震荡与周期性特征。其中,两站 IMF₁ 频率最大,随着模态分解,序列的频率逐渐降低,总体序列振幅趋于平缓,余量序列不再穿过 0 值且单调递减。此外,宜昌与寸滩水文站的月径流余量序列呈现单调递减趋势,其量级与原始序列均值相近,表明两站月径流均为总体下降趋势^[38],




图 2 CEEMDAN-FESC-OVMD-Transformer 混合预测模型框架
Fig. 2 CEEMDAN-FESC-OVMD-Transformer model structure




图3 宜昌水文站月径流序列由 CEEMDAN 分解获得的 IMF

Fig. 3 IMF decomposed by CEEMDAN from monthly runoff sequences at Yichang hydrological station




图4 寸滩水文站月径流序列由 CEEMDAN 分解获得的 IMF

Fig. 4 IMF decomposed by CEEMDAN from monthly runoff sequences at Cuntan hydrological station

经 CEEMDAN 分解后月径流余量表现出更为平稳的特征,且分解过程有助于对月径流时间变化特征的理解,为实现高精度月径流预测提供了数据基础^[31]。

3.2 模糊熵与谱聚类序列重构

利用模糊熵法计算宜昌与寸滩水文站经 CEEMDAN 分解的月径流 IMF 复杂度,并采用谱聚类法将两站 IMF 聚类重构为高、中、低频序列。图 5 为宜昌与寸滩水文站重构的月径流序列,可见重构后的径流序列总体频率有所降低,稳定性增强,且低

频序列具有更多变化信息^[39]。其中,宜昌与寸滩水文站高频率序列均由 CEEMDAN 分解的 IMF_{YC1} 、 IMF_{CT1} (5.81、4.52,数据为模糊熵,下同)和 IMF_{YC2} 、 IMF_{CT2} (4.62、4.23)构成;宜昌站中频序列由 IMF_{YC3} (2.01)与 IMF_{YC4} (0.97)构成,低频序列由 IMF_{YC5} (0.69)、 IMF_{YC6} (0.52)、 IMF_{YC7} (0.16)与余量(0.01)构成;而寸滩水文站中频序列由 IMF_{CT3} (1.93)、 IMF_{CT4} (0.89)与 IMF_{CT5} (0.67)构成,低频序列由 IMF_{CT6} (0.48)、 IMF_{CT7} (0.18)与余量(0.01)构成。组成同一重构频率序列的 IMF 模糊熵较为




图 5 月径流 IMF 重构的高、中、低频序列

Fig. 5 High, medium, and low frequency sequences reconstructed from IMF of monthly runoff

相似,且从高频至低频模糊熵有明显降低,表明重构结果较为合理。可见重构后的高频序列仍具有较高的复杂性,需利用二次分解法进一步降低序列的复杂度。

3.3 EMD 与 OVMD 月径流二次分解

利用 OVMD 与 EMD 对谱聚类重构的宜昌与寸滩水文站高序列进行二次分解,见图 6 和图 7。通过迭代寻优,宜昌与寸滩水文站 OVMD 的最优分解层数分别为 8 与 6 层,超过最优分解次数的模态分解将过度分解序列,导致模态混叠与噪声增加^[40],因此两站 OVMD 分别将高序列分解为 8 个和 6 个 IMF。此外,EMD 分别将两站月径流分解为 8 个与 7 个 IMF。OVMD 与 EMD 均将原始序列分解为不同频率与振幅的子序列,但分解获得的两站径流序列 IMF 数量不同,不同 IMF 下的频率与振幅特征也各不相同。

3.4 各模型月径流预测结果对比

利用 CEEMDAN-FESC-OVMD-Transformer 混合

预测模型对宜昌与寸滩水文站月径流进行预测,并分别构建 CEEMDAN-FESC-EMD-Transformer、CEEMDAN-FESC-Transformer 与 Transformer 模型作为基准进行对比。表 1 为各模型的总体预测精度。可见 CEEMDAN-FESC-OVMD-Transformer 模型在宜昌与寸滩水文站训练期与测试期 NSE 均高于其他模型,而寸滩水文站整体精度相对较高,这可能是由于其位于流域较上游,受到水库调蓄与人类活动的影响相对较小^[41]的原因。宜昌水文站训练期与测试期 NSE 分别为 0.94 与 0.84,相较于其他模型两阶段最高提升 0.1 与 0.21;寸滩水文站训练期与测试期 NSE 分别为 0.96 与 0.89,相较于其他模型两阶段最高提升 0.13 与 0.19。

在宜昌与寸滩水文站,CEEMDAN-FESC-OVMD-Transformer 混合预测模型相较其他模型提升的精度、在训练期和测试期之间的精度相对较为接近,表明该模型预测效果好,泛化能力强。两站径流预测




图 6 由 OVMD 分解获得的月径流高频子序列

Fig. 6 Monthly runoff high-frequency subsequences obtained by OVMD decomposition




图 7 由 EMD 分解获得的月径流高频的子序列

Fig. 7 Monthly runoff high-frequency subsequences obtained by EMD decomposition

表 1 模型训练期和测试期预测结果评价

Table 1 Evaluation of prediction results of models in training and testing periods

水文站	模型	训练期				测试期			
		NSE	R^2	RMSE	MAE	NSE	R^2	RMSE	MAE
宜昌	CEEMDAN-FESC-OVMD-Transformer	0.94	0.94	2 371.59	1 762.67	0.84	0.85	3 159.17	2 298.71
	CEEMDAN-FESC-EMD-Transformer	0.86	0.87	3 646.23	2 658.36	0.63	0.63	4 747.56	3 476.87
	CEEMDAN-FESC-Transformer	0.89	0.89	3 309.90	2 182.02	0.73	0.75	4 060.57	2 854.69
	Transformer	0.84	0.84	3 918.85	2 403.05	0.72	0.72	4 182.53	2 737.54
寸滩	CEEMDAN-FESC-OVMD-Transformer	0.96	0.96	1 705.44	1 293.90	0.89	0.92	2 368.57	1 825.10
	CEEMDAN-FESC-EMD-Transformer	0.85	0.85	3 282.76	2 381.57	0.70	0.71	3 974.15	2 801.79
	CEEMDAN-FESC-Transformer	0.83	0.84	3 392.28	2 339.64	0.78	0.79	3 406.54	2 356.60
	Transformer	0.86	0.87	3 087.48	1 901.53	0.78	0.78	3 383.01	1 977.91

精度最低的模型在不同站、不同时期各不相同。训练期除 CEEMDAN-FESC-OVMD-Transformer 以外的模型精度相对较为接近,训练与测试期 CEEMDAN-FESC-EMD-Transformer 模型总体预测精度最低,表明采用二次分解法进行高精度径流预测时需比对优选方法。对于高频率序列的二次分解,OVMD 在径流预测精度的提升方面效果较为显著,这可能是因为 VMD 对高频分量分解完全,分解的各分量振幅小且信息量大,而 EMD 分解的分量尤其是高频分量包含更多的噪音干扰,且高频分量中的 IMF₁ 与 IMF₂ 因振幅大、规律性弱而难以预测^[21,28,42]。相较于 Transformer 模型,CEEMDAN-FESC-Transformer 模型径流预测精度主要在测试期提升且幅度较小,表明 CEEMDAN-OVMD 的二次分解结构可提升径流预测精度。这可能是因为 CEEMDAN-OVMD 在径流序列分解中具有高效性且与耦合的模型存在协同作用,可降低单模型预测误差^[17]。

3.4.1 月径流预测与实测值对比

宜昌与寸滩水文站 4 种模型月径流预测结果与

实测对比见图 8 与图 9。

a. 宜昌水文站。① CEEMDAN-FESC-OVMD-Transformer 模型。训练期与测试期预测结果较为接近,预测流量均与实测值吻合较好,但对各年汛期流量峰值稍有低估,平均低估 3 450 m³/s;测试期枯水期预测流量相对于实测值也稍有低估,平均低估 1 780 m³/s。② CEEMDAN-FESC-EMD-Transformer 模型。训练期各年汛期流量预测值均低于实测值,平均低估 5 600 m³/s;枯水期存在部分年份高估实测流量(平均高估 1 610 m³/s)而部分年份低估实测流量(平均低估 1 010 m³/s)的情况。测试期对于汛期流量的低估程度(平均低估 8 380 m³/s)高于训练期;枯水期流量存在较大程度的高估,平均高估 3 520 m³/s,多数时期预测值与实测值的吻合效果相对较弱。③ CEEMDAN-FESC-Transformer 模型。训练期与测试期均存在汛期峰值流量预测值低于实测值的情况,训练期平均低估 6 080 m³/s,测试期平均低估 6 560 m³/s,且训练期与 CEEMDAN-FESC-EMD-Transformer 模型预测效果较为接近。④ Transformer 模型。在训练期与测试期均存在对汛




图 8 宜昌水文站月径流预测结果对比

Fig. 8 Comparison of monthly runoff prediction results at Yichang hydrological station




图 9 寸滩水文站月径流预测结果对比

Fig. 9 Comparison of monthly runoff prediction results at Cuntan hydrological station

期峰值流量低估的情况,平均低估 $8\,460\text{ m}^3/\text{s}$,且预测的峰值流量明显低于 CEEMDAN-FESC-OVMD-Transformer 模型。

b. 寸滩水文站。① CEEMDAN-FESC-OVMD-Transformer 模型。训练期与测试期预测效果较为相似,流量预测值与实测值较为吻合,但各年汛期对峰值流量稍有低估,平均低估 $3\,260\text{ m}^3/\text{s}$;部分年份枯水期对实测流量也稍有低估,平均低估 $1\,380\text{ m}^3/\text{s}$ 。② CEEMDAN-FESC-EMD-Transformer 模型。同样存在预测低估峰值流量(平均低估 $6\,550\text{ m}^3/\text{s}$)的现象且程度高于 CEEMDAN-FESC-OVMD-Transformer 模型,另外部分年份高估了枯水期流量,平均高估 $2\,240\text{ m}^3/\text{s}$ 。③ CEEMDAN-FESC-Transformer 模型。

预测效果接近于 CEEMDAN-FESC-EMD-Transformer 模型,且其预测的汛期峰值流量和非汛期径流过程与实测值的吻合程度弱于 CEEMDAN-FESC-OVMD-Transformer 模型。④ Transformer 模型。预测结果存在对峰值流量的低估情况,平均低估 $8\,360\text{ m}^3/\text{s}$,且其峰值流量预测值相较 CEEMDAN-FESC-OVMD-Transformer 模型偏差较多。

宜昌与寸滩水文站预测径流效果的对比表明:① CEEMDAN-FESC-OVMD-Transformer 模型均能相对较好地预测汛期峰值流量与非汛期径流过程。此外,寸滩水文站的预测效果优于宜昌水文站,其他模型在两站的预测效果相对较为接近。除寸滩水文站受水库影响更小这一因素外,可能还与 CEEMDAN-

FESC-OVMD-Transformer 模型在波动幅度相对较小的径流过程中预测更有优势,同时对于具有不同波动幅度和信号频率组成的径流过程预测也具备良好的适应性有关。此外,CEEMDAN-FESC-OVMD-Transformer 模型在各年汛期对峰值流量存在轻微低估,且测试期枯水期对流量实测值也稍有低估,可能是因为峰值与谷底属于波动较大的高频信息,CEEMDAN 分解过程中引入的白噪声在预测重构还原时产生误差累积从而低估了流量;同时高频信息在分解后仍然存在复杂性,加之 Transformer 模型对于高频信息的预测精度有限(图 8(d)),因此预测结果存在一定程度的低估^[39,43-44]。此外,CEEMDAN-FESC-OVMD-Transformer 模型在测试期枯水期的表现也可能与模型预测中未考虑测试期降水等气候因子变化有关;且信号分解后,预测模型对极值与突变点的识别能力有限,因此测试期部分枯水期的预测流量低值与训练期接近,从而低于实测值^[45-47]。②CEEMDAN-FESC-EMD-Transformer 模型的预测效果与其他模型相差较大,说明该模型中 EMD 的二次分解对于不同站不具有稳定的分解效果与有效的精度提升。③CEEMDAN-FESC-Transformer 模型对于非汛期的径流预测效果相对较弱,表明基于 OVMD 的二次分解结构对于非汛期径流预测精度有一定的提升作用。④Transformer 模型低估汛期峰值流量的现象较为严重,表明 CEEMDAN 与 OVMD 的分解组合可有效提升汛期峰值流量预测精度,这与王文川等^[17]的研究结论一致。

3.4.2 预测误差

图 10 与图 11 为宜昌与寸滩水文站月径流预测结果线性拟合对比,表 2 为两站预测流量误差在不同流量级的标准差。根据黄健雄等^[48-50]的研究,将宜昌与寸滩水文站流量级分为小于 1 万 m^3/s 、1 万~3 万 m^3/s 和大于 3 万 m^3/s 的枯水、中水与洪水流量区间。宜昌站 CEEMDAN-FESC-OVMD-Transformer 模型的拟合线与 $y=x$ 的黑色虚线较为接近,各流量级的点据较均匀紧密分布在 $y=x$ 线两侧,误差标准差在各流量级较小且较为接近。其他 3 种模型拟合线与点据分布相较 CEEMDAN-FESC-OVMD-Transformer 模型均明显偏离 $y=x$ 线,且随着流量值增加分散程度增加,误差标准差显著增大且差异较大。CEEMDAN-FESC-EMD-Transformer 模型的预测流量随流量级的增加先偏大后偏小,其中流量大于 2 万 m^3/s 的点据整体预测流量偏小,各流量级误差标准差较大。CEEMDAN-FESC-Transformer 模型的点据整体分散程度与各流量级分布特征接近于 CEEMDAN-FESC-EMD-Transformer 模型,但各流量级误差标准差相对较小。Transformer 模型流量点据在小于 1 万 m^3/s 时相较各模型更集中于 $y=x$ 线,误差标准差最小;但大于 1 万 m^3/s 时的分布特征和误差标准差与 CEEMDAN-FESC-EMD-Transformer 模型和 CEEMDAN-FESC-Transformer 模型接近。寸滩水文站 CEEMDAN-FESC-OVMD-Transformer 模型的拟合线相较于其他模型在各流量级更接近于 $y=x$ 线,误差标准差在各流量级接近且较小。其他 3 种




图 10 宜昌水文站月径流预测结果线性拟合对比

Fig. 10 Comparison of linear fitting of monthly runoff prediction results at Yichang hydrological station




图 11 寸滩水文站月径流预测结果线性拟合对比

Fig. 11 Comparison of linear fitting of monthly runoff prediction results at Cuntan hydrological station

表 2 模型预测误差标准差

Table 2 Standard deviation of the error between the observed and predicted runoff of the models

水文站	模型	不同流量级下误差标准差/(m^3/s)			
		0~1 万 m^3/s	1 万~3 万 m^3/s	3 万~6 万 m^3/s	0~6 万 m^3/s
宜昌	CEEMDAN-FESC-OVMD-Transformer	2 013.90	2 787.93	3 221.81	2 626.45
	CEEMDAN-FESC-EMD-Transformer	2 607.42	4 065.82	5 023.39	3 995.02
	EEMDAN-FESC-Transformer	1 791.09	3 773.51	4 377.56	3 547.87
	Transformer	1 748.89	3 853.59	4 534.01	3 975.41
寸滩	CEEMDAN-FESC-OVMD-Transformer	2 097.38	2 896.20	3 159.39	2 677.13
	CEEMDAN-FESC-EMD-Transformer	2 637.28	4 074.39	5 269.75	4 014.06
	EEMDAN-FESC-Transformer	1 897.24	3 842.45	4 490.09	3 574.45
	Transformer	1 812.17	3 915.82	4 632.01	3 984.23

模型点据分布的偏小与偏大规律与宜昌水文站相应模型模拟结果相似,且均存在随流量级增大先偏大后偏小的现象,误差标准差在不同流量级差异较大。

宜昌与寸滩水文站线性拟合结果对比表明,CEEMDAN-FESC-OVMD-Transformer 模型相较于其他模型在各流量级模拟预测效果均较好,而CEEMDAN-FESC-EMD-Transformer 模型流量点据在整体上分散程度最严重,误差标准差在大多数流量级较大,体现了模型之间总体精度的差异。此外,寸滩水文站各模型点据在各流量级相较宜昌水文站更集中于 $y=x$ 线,但宜昌站 CEEMDAN-FESC-OVMD-Transformer 模型仍具有较好的预测效果,两站在不同流量级误差标准差均较小且接近,进一步说明CEEMDAN-FESC-OVMD-Transformer 模型对环境变化的抗干扰能力强,预测结果在各流量级具有稳定性,表明该模型框架可有效消除径流序列噪声并获取原始序列的有效信息^[5,17]。CEEMDAN-FESC-

OVMD-Transformer 模型结合二次分解结构与Transformer 模型挖掘长序列数据依赖的能力,将非一致性变化的径流过程分解为不同波动幅度和信号频率的径流序列,并重点分解复杂高频组分从而提升了模拟精度,对不同时期、不同流量级下的径流过程均表现出较好的模拟效果,可提升径流预测模型在水文要素非一致性变化背景下的适用性。

4 结 论

a. CEEMDAN-FESC-OVMD-Transformer 模型在长江上游宜昌与寸滩水文站月径流的预测中效果较好,训练期 NSE 分别为 0.94 与 0.96,测试期 NSE 分别为 0.84 与 0.89,相较于 CEEMDAN-FESC-EMD-Transformer 模型、CEEMDAN-FESC-Transformer 模型和 Transformer 模型在训练期最大提升了 0.1 与 0.21,在测试期提升了 0.13 与 0.19,相较其他模型有较大提升且精度稳定。

b. 结合模糊熵与谱聚类的 CEEMDAN-OVMD 分解组合,将原始序列分解为不同频率与振幅的 IMF 并重构为低频、中频与多模态的高频信号,分别构建 Transformer 深度学习模型进行预测,可有效提升汛期峰值流量的预测精度。

c. 基于 OVMD 二次分解结构识别分离了高频信号的不同变化特征,降低了月径流序列高频组分的复杂度,提升了 CEEMDAN-FESC-Transformer 模型对环境影响的适应性与在各流量级的预测稳定性。

参考文献:

[1] 熊怡,周建中,孙娜,等. 基于自适应变分模态分解和长短期记忆网络的月径流预报[J]. 水利学报,2023,54(2):172-183. (XIONG Yi,ZHOU Jianzhong,SUN Na,et al. Monthly runoff prediction based on self-adaptive variational mode decomposition and long short-term memory network[J]. Journal of Hydraulic Engineering, 2023,54(2):172-183. (in Chinese))

[2] 张力,王红瑞,郭珪楠,等. 基于时序分解与机器学习的非平稳径流序列集成模型与应用[J]. 水科学进展,2023,34(1):42-52. (ZHANG Li,WANG Hongrui,GUO Beinan,et al. Integrated model and application of non-stationary runoff based on time series decomposition and machine learning[J]. Advances in Water Science,2023,34(1):42-52. (in Chinese))

[3] YAN Lei, XIONG Lihua, RUAN Gusong, et al. Design flood estimation with varying record lengths in Norway under stationarity and nonstationarity scenarios [J]. Hydrology Research,2021,52(6):1596-1614.

[4] MILLY P C,BETANCOURT J,FALKENMARK M,et al. Stationarity is dead: whither water management? [J]. Science,2008,5863(319):573-574.

[5] 康艳,程潇,陈沛如,等. 基于集成学习模型的非平稳月径流预报[J]. 水资源保护,2023,39(2):125-135. (KANG Yan,CHENG Xiao,CHEN Peiru,et al. Non-stationary monthly runoff forecast based on ensemble learning model[J]. Water Resources Protection,2023,39(2):125-135. (in Chinese))

[6] 张珂,牛杰帆,李曦,等. 洪水预报智能模型在中国半干旱半湿润区的应用对比[J]. 水资源保护,2021,37(1):28-35. (ZHANG Ke,NIU Jiefan,LI Xi,et al. Comparison of artificial intelligence flood forecasting models in China's semi-arid and semi-humid regions [J]. Water Resources Protection,2021,37(1):28-35. (in Chinese))

[7] 梁浩,黄生志,孟二浩,等. 基于多种混合模型的径流预测研究[J]. 水利学报,2020,51(1):112-125. (LIANG Hao,HUANG Shengzhi,MENG Erhao,et al. Runoff prediction based on multiple hybrid models[J]. Journal of Hydraulic Engineering, 2020, 51 (1): 112-125. (in

Chinese))

[8] ADAMOWSKI J, CHAN F H, PRASHER S O, et al. Comparison of multiple linear and nonlinear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada [J]. Water Resources Research,2012,48(1):273-279.

[9] 李菊,崔东文. 基于 WPT-IDBO-RELM 和 WPT-IDMO-RELM 模型的日径流预测[J]. 水利水电科技进展,2024,44(6):48-55. (LI Ju, CUI Dongwen. Daily runoff prediction based on WPT-IDBO-RELM and WPT-IDMO-RELM models[J]. Advances in Science and Technology of Water Resources,2024,44(6):48-55. (in Chinese))

[10] 熊一橙,徐炜,张锐,等. 基于 LSTM 网络的长江上游流域径流模拟研究[J]. 水电能源科学,2021,39(9):22-24. (XIONG Yicheng, XU Wei, ZHANG Rui, et al. Research on runoff simulation in the upper Yangtze River based on the LSTM network [J]. Water Resources and Power,2021,39(9):22-24. (in Chinese))

[11] 许月萍,陆豪楠,于欣廷,等. 基于深度学习集合预报的水库闸门防洪优化调度[J]. 水科学进展,2024,35(6):900-913. (XU Yueping, LU Haonan, YU Xinting, et al. Optimization of gate operation for reservoir flood control based on deep learning ensemble forecasting [J]. Advances in Water Science,2024,35(6):900-913. (in Chinese))

[12] 郭田丽,宋松柏,张特,等. 基于两阶段粒子群优化算法的新型逐步分解集成径流预测模型[J]. 水利学报,2022,53(12):1456-1466. (GUO Tianli, SONG Songbai, ZHANG Te, et al. A new stepwise decomposition ensemble model based on two-stage particle swarm optimization algorithm for the runoff prediction [J]. Journal of Hydraulic Engineering, 2022, 53 (12): 1456-1466. (in Chinese))

[13] 梁宏涛,刘硕,杜军威,等. 深度学习应用于时序预测研究综述[J]. 计算机科学与探索,2023,17(6):1285-1300. (LIANG Hongtao, LIU Shuo, DU Junwei, et al. Review of deep learning applied to time series prediction [J]. Journal of Frontiers of Computer Science and Technology,2023,17(6):1285-1300. (in Chinese))

[14] FANG Jinjie, YANG Linshan, WEN Xiaohu, et al. Ensemble learning using multivariate variational mode decomposition based on the Transformer for multi-step-ahead streamflow forecasting [J]. Journal of Hydrology, 2024,636:131275.

[15] DUAN Wenyang, HUANG Limin, HAN Yang, et al. A hybrid EMD-AR model for nonlinear and non-stationary wave forecasting [J]. Journal of Zhejiang University-Science A (Applied Physics & Engineering), 2016, 17 (2):115-129.

[16] 邱绪迪,王坤,陈飞,等. 基于最优变分模态分解的渭河流域多步径流预报[J]. 人民长江,2024,55(8):79-86.

- (QIU Xudi, WANG Kun, CHEN Fei, et al. Multi-step runoff forecast in Weihe River Basin based on optimal variational mode decomposition[J]. Yangtze River, 2024, 55(8):79-86. (in Chinese))
- [17] 王文川,杜玉瑾,和吉,等. 基于 CEEMDAN-VMD-BP 模型的月径流量预测研究[J]. 华北水利水电大学学报(自然科学版), 2023, 44(1): 32-40. (WANG Wenchuan, DU Yujin, HE Ji, et al. Research on monthly runoff prediction based on CEEMDAN-VMD-BP model[J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2023, 44(1):32-40. (in Chinese))
- [18] 吴小涛,袁晓辉,袁艳斌,等. 基于 EEMD-VMD-SSA-KELM 模型的汛期日径流预测[J]. 中国农村水利水电, 2023(7): 27-34. (WU Xiaotao, YUAN Xiaohui, YUAN Yanbin, et al. A prediction of the daily runoff in the flood season based on EEMD-VMD-SSA-KELM model[J]. China Rural Water and Hydropower, 2023(7): 27-34. (in Chinese))
- [19] DONG Jinghan, WANG Zhaoai, WU Junhao, et al. A novel runoff prediction model based on support vector machine and gate recurrent unit with secondary mode decomposition[J]. Water Resources Management, 2024, 38(5):1655-1674.
- [20] 徐冬梅,夏王萍,王文川. 基于黏菌算法优化 VMD-CNN-GRU 模型的年径流预测[J]. 南水北调与水利科技(中英文), 2022, 20(3): 429-439. (XU Dongmei, XIA Wangping, WANG Wenchuan. Annual runoff prediction based on VMD-CNN-GRU model optimized by slime mould algorithm[J]. South-to-North Water Transfers and Water Science & Technology, 2022, 20(3): 429-439. (in Chinese))
- [21] 程家波,姬厚灵,陈中举,等. 基于 GWO-PE-VMD-ResNet 组合模型的日径流预测[J]. 水电能源科学, 2024, 42(8): 43-47. (CHENG Jiabo, JI Houling, CHEN Zhongju, et al. Daily runoff prediction based on the GWO-PE-VMD-ResNet combined model[J]. Water Resources and Power, 2024, 42(8): 43-47. (in Chinese))
- [22] ZHOU Feite, HUANG Zhehao, ZHANG Chaohong. Carbon price forecasting based on CEEMDAN and LSTM[J]. Applied Energy, 2022, 311:118601.
- [23] 王涛,李薇,许野,等. 计及相似日的 VMD-FE-LSTM 光伏出力组合预测模型研究[J]. 太阳能学报, 2024, 45(5): 490-499. (WANG Tao, LI Wei, XU Ye, et al. Study on photovoltaic power prediction of VMD-FE-LSTM considering similar days[J]. Acta Energiae Solaris Sinica, 2024, 45(5): 490-499. (in Chinese))
- [24] 姜建国,杨效岩,毕洪波. 基于 VMD-FE-CNN-BiLSTM 的短期光伏发电功率预测[J]. 太阳能学报, 2024, 45(7): 462-473. (JIANG Jianguo, YANG Xiaoyan, BI Hongbo. Photovoltaic power forecasting method based on VMD-FE-CNN-BiLSTM[J]. Acta Energiae Solaris Sinica, 2024, 45(7): 462-473. (in Chinese))
- [25] 郝立丽,张盼,李洪敏,等. 基于谱聚类的中国绿色创新效率评价及影响机理研究[J]. 东北师大学报(自然科学版), 2024, 56(1): 46-54. (HAO Lili, ZHANG Pan, LI Hongmin, et al. Study on the evaluation of efficiency and influence mechanism of Chinese green innovation based on spectral clustering[J]. Journal of Northeast Normal University (Natural Science Edition), 2024, 56(1): 46-54. (in Chinese))
- [26] 宋蕾玥,张珂,晁丽君,等. 基于随机森林模型的长江流域分区多源融合降水模拟方法研究[J]. 水资源保护, 2024, 40(3): 125-132. (SONG Leiyue, ZHANG Ke, CHAO Lijun, et al. Research on zoning multi-source fusion precipitation simulation method of the Yangtze River Basin based on random forest model[J]. Water Resources Protection, 2024, 40(3): 125-132. (in Chinese))
- [27] 沈嘉聚,杨汉波,刘志武,等. 长江上游径流对气象要素变化的敏感性分析[J]. 水资源保护, 2023, 39(1): 119-126. (SHEN Jiaju, YANG Hanbo, LIU Zhiwu, et al. Sensitivity analysis of annual runoff to annual variation of meteorological elements in upper reaches of the Yangtze River[J]. Water Resources Protection, 2023, 39(1): 119-126. (in Chinese))
- [28] 徐荣华,崔东文. 基于 EWT-EVO/CDO-GPR 模型的三峡入库月径流预测[J]. 三峡大学学报(自然科学版), 2025, 47(2): 26-32. (XU Ronghua, CUI Dongwen. Monthly runoff prediction of Three Gorges Reservoir based on EWT-EVO/CDO-GPR model[J]. Journal of China Three Gorges University (Natural Sciences), 2025, 47(2): 26-32. (in Chinese))
- [29] 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). New York: IEEE, 2011: 4144-4147.
- [30] 刘扬,王立虎. 基于改进 EMD-LSTM 的洪水预测方法研究[J]. 水利水电技术(中英文), 2022, 53(1): 35-44. (LIU Yang, WANG Lihu. Flood forecasting method based on an improved EMD-LSTM[J]. Water Resources and Hydropower Engineering, 2022, 53(1): 35-44. (in Chinese))
- [31] 刘扬,赵丽. 基于 CEEMDAN-QPSO-BLS 模型的径流预测研究[J]. 中国农村水利水电, 2024(1): 101-108. (LIU Yang, ZHAO Li. Runoff prediction and analysis based on CEEMDAN-QPSO-BLS method[J]. China Rural Water and Hydropower, 2024(1): 101-108. (in Chinese))
- [32] CHEN Waiting, WANG Zhizhong, XIE Hongbo, et al. Characterization of surface emg signal based on fuzzy entropy[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15(2): 266-272.
- [33] VON LUXBURG U. A tutorial on spectral clustering[J]. Statistics and Computing, 2007, 17(4): 395-416.

- [34] ZHANG Chu, ZHOU Jianzhong, LI Chaoshun, et al. A compound structure of ELM based on feature selection and parameter optimization using hybrid backtracking search algorithm for wind speed forecasting [J]. Energy Conversion and Management, 2017, 143: 360-376.
- [35] YIN Hanlin, GUO Zilong, ZHANG Xiuwei, et al. RR-Former: rainfall-runoff modeling based on Transformer [J]. Journal of Hydrology, 2022, 609: 127781.
- [36] 徐嘉远, 邹磊, 夏军, 等. TVGM-LSTM 耦合模型及其径流模拟效果分析[J]. 水资源保护, 2023, 39(6): 104-110. (XU Jiayuan, ZOU Lei, XIA Jun, et al. TVGM-LSTM coupling model and its runoff simulation effect analysis [J]. Water Resources Protection, 2023, 39(6): 104-110. (in Chinese))
- [37] YAN Xin, SUN Jineng, HUANG Yanan, et al. Detecting and attributing the changes in baseflow in China's Loess Plateau [J]. Journal of Hydrology, 2023, 617: 128957.
- [38] 丁红, 王伟泽, 杨泽凡, 等. 基于深度学习和信号分解的北方寒区河流开河日期预报[J]. 水利学报, 2024, 55(5): 577-585. (DING Hong, WANG Weize, YANG Zefan, et al. Forecasting break-up date of river ice in northern China based on deep learning and signal decomposition technology [J]. Journal of Hydraulic Engineering, 2024, 55(5): 577-585. (in Chinese))
- [39] 丁占涛, 安杰, 吴国洋, 等. 基于 EEMD-SE-LSTM 组合模型的开都河日径流模拟研究[J]. 石河子大学学报(自然科学版), 2024, 42(3): 335-341. (DING Zhantao, AN Jie, WU Guoyang, et al. Study on daily runoff simulation of Kaidu River based on EEMD-SE-LSTM combined model [J]. Journal of Shihezi University (Natural Science), 2024, 42(3): 335-341. (in Chinese))
- [40] 韩莹, 王乐豪, 王淑梅, 等. 宽度-深度融合时频分析的径流智能预测方法[J]. 系统仿真学报, 2024, 36(2): 363-372. (HAN Ying, WANG Lehao, WANG Shumei, et al. Runoff intelligent prediction method based on broad-deep fusion time-frequency analysis [J]. Journal of System Simulation, 2024, 36(2): 363-372. (in Chinese))
- [41] 张素琼, 张艳军, 宋星原, 等. 基于神经网络的中长期径流预报时间尺度研究[J]. 中国农村水利水电, 2014(8): 110-114. (ZHANG Suqiong, ZHANG Yanjun, SONG Xingyuan, et al. Research on the time-scale of mid-to-long-term runoff forecast based on neural networks [J]. China Rural Water and Hydropower, 2014(8): 110-114. (in Chinese))
- [42] 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 Shangdong, SUN Dongyong, XU Jingjing, et al. Monthly runoff forecasting based on ESMD-NNBR hybrid model [J]. Journal of China Hydrology, 2023, 43(1): 52-56. (in Chinese))
- [43] 李鑫, 王双银, 黄毓林, 等. 基于两阶段分解策略的月径流模拟模型研究[J]. 水电能源科学, 2023, 41(9): 6-10. (LI Xin, WANG Shuangyin, HUANG Yulin, et al. Study of monthly runoff simulation model based on two-stage decomposition strategy [J]. Water Resources and Power, 2023, 41(9): 6-10. (in Chinese))
- [44] 钱玉霞, 陈伏龙, 何朝飞, 等. “分解-校正-集成”模式下基于深度信念网络模型的径流预测[J]. 长江科学院院报, 2024, 41(5): 35-44. (QIAN Yuxia, CHEN Fulong, HE Chaofei, et al. Runoff prediction based on deep belief network in decomposition-correction-integration mode [J]. Journal of Changjiang River Scientific Research Institute, 2024, 41(5): 35-44. (in Chinese))
- [45] 郑鑫, 陈俊旭, 胡智文, 等. 基于 EEMD-PSO-GRNN 模型的元江中上游径流预测[J]. 水文, 2023, 43(4): 96-103. (ZHENG Xin, CHEN Junxu, HU Zhiwen, et al. Runoff prediction in the middle and upper reaches of Yuanjiang River based on EEMD-PSO-GRNN model [J]. Journal of China Hydrology, 2023, 43(4): 96-103. (in Chinese))
- [46] 毛钦男, 刘招, 李杰, 等. 联合 ICEEMDAN 与多种智能优化算法的径流预测及对比研究[J]. 水电能源科学, 2023, 41(10): 23-26. (MAO Qinnan, LIU Zhao, LI Jie, et al. Runoff prediction and comparative study by combining ICEEMDAN and multiple intelligent optimization algorithms [J]. Water Resources and Power, 2023, 41(10): 23-26. (in Chinese))
- [47] 李原园, 刘为锋, 郭旭宁, 等. 1956—2016 年中国降水量时空分布规律及变化特征[J]. 水科学进展, 2025, 36(1): 1-17. (LI Yuanyuan, LIU Weifeng, GUO Xuning, et al. Spatial-temporal distribution and variation characteristics of precipitation in China from 1956 to 2016 [J]. Advances in Water Science, 2025, 36(1): 1-17. (in Chinese))
- [48] 黄建雄, 冶运涛, 曹引, 等. 黄河北干流水沙时空变化特征及协调性分析[J]. 河海大学学报(自然科学版), 2024, 52(3): 25-33. (HUANG Jianxiong, YE Yuntao, CAO Yin, et al. Analysis of spatial and temporal variation characteristics and coordination of water-sediment in the north main reach of Yellow River [J]. Journal of Hohai University (Natural Sciences), 2024, 52(3): 25-33. (in Chinese))
- [49] 姜利玲, 董炳江, 汤成友, 等. 长江上游三峡水库入库泥沙沙峰传播时间研究[J]. 人民长江, 2021, 52(7): 9-16. (JIANG Liling, DONG Bingjiang, TANG Chengyou, et al. Study on sand peak propagation time of input sediment of Three Gorges Reservoir in upper Changjiang River [J]. Yangtze River, 2021, 52(7): 9-16. (in Chinese))
- [50] 尹祖迎, 柴元方. 长江中游宜昌—螺山段同流量下中水位变化特征及机制研究[J]. 水电能源科学, 2022, 40(10): 31-34. (YIN Zuying, CHAI Yuanfang. Characteristics and mechanisms of medium water level of Yichang-Luoshan section in middle reaches of Yangtze River [J]. Water Resources and Power, 2022, 40(10): 31-34. (in Chinese))

(收稿日期: 2024-11-20 编辑: 胡新宇)