

基于 RF-Informer 模型的月径流遥相关预报

李继清¹, 谢宇韬¹, 徐学军², 吴 亮¹

(1. 华北电力大学水利与水电工程学院, 北京 102206; 2. 长江设计集团有限公司, 湖北 武汉 430010)

摘要:为延长中长期径流预报的预见期,提高预报精度,从物理成因上考虑径流的影响因素,在前期降水径流的基础上增加遥相关因子,通过随机森林(RF)模型进行因子选择,引入长时间序列预报中表现良好的 Informer 模型,构建了月径流预报的 RF-Informer 模型,并利用该模型对雅砻江流域两河口、锦西、二滩 3 个水库的入库月径流进行了预报。结果表明:将遥相关因子引入流域月径流预报可以延长预见期,提高预报精度;相较于线性相关法,基于 RF 模型选择预报因子可以挖掘因子间非线性关系,提升预报效果;与 RF-LSTM、RF-SVM、RF-BP 神经网络模型相比,RF-Informer 模型的误差最小,预报精度最高。

关键词:月径流预报;遥相关因子;随机森林模型;Informer 模型;雅砻江流域

中图分类号:TV124 **文献标志码:**A **文章编号:**1004-6933(2025)03-0039-07

Monthly runoff teleconnection forecasting based on RF-Informer model//LI Jiqing¹, XIE Yutao¹, XU Xuejun², WU Liang¹(1. School of Water Resources and Hydropower Engineering, North China Electric Power University, Beijing 102206, China; 2. Changjiang Institute of Survey, Planning, Design and Research Co., Ltd., Wuhan 430010, China)

Abstract: To extend the lead time and improve the accuracy of medium-to-long-term runoff forecast, teleconnection factors were incorporated as physical determinants of runoff formation alongside antecedent precipitation-runoff relationships. An RF-Informer model for monthly runoff forecast was developed by integrating the random forest (RF) model for predictor selection with the Informer model, which has demonstrated superior performance in long-sequence time-series forecasting. The proposed model was applied to forecast monthly inflow runoff of the Lianghekou, Jinxi, and Ertan reservoirs in the Yalong River Basin. Results indicate that the integration of teleconnection factors effectively extends the lead time while enhancing the accuracy for forecasting basin-scale monthly runoff. By resolving nonlinear couplings between predictors that linear methods overlook, the RF-driven feature selection advances the physical interpretability and predictive skill of runoff forecast; compared with the RF-LSTM, RF-SVM, and RF-BP neural network models, the RF-Informer model achieves the minimum forecast error and highest precision in monthly runoff forecast.

Key words: monthly runoff forecast; teleconnection factor; random forest model; Informer model; the Yalong River Basin

中长期径流预报是流域水资源开发规划、水利工程调度运行、水旱灾害防御的重要依据,对合理开发优化流域水资源、推动区域社会经济发展具有重要意义。与短期径流预报相比,中长期径流预报由于预见期较长、降水预报数据存在局限性、影响因子复杂等因素^[1],具有更高的预报不确定性,其精度主要由预报因子选择和预报模型构建两方面决定。

目前,常用的径流预报方法包括水文模型、机器学习方法和两者耦合预报的方法 3 类。由于现阶段缺乏中长预见期的可靠天气预报资料,以长短时记忆网络(long short term memory, LSTM)^[2-3]、支持向

量机^[4](support vector machine, SVM)、反向传播(back propagation, BP)神经网络^[5]为代表的基于机器学习的驱动模型在学习和拟合目标变量与解释因子之间的非线性关系方面具有一定的优势^[6],得到了广泛的关注和应用^[7-8]。针对传统循环神经网络(recurrent neural network, RNN)模型存在无法并行和梯度爆炸等问题, Vaswani 等^[9]提出了 Transformer 模型,完全基于注意力机制,避免了复杂的递归或卷积操作,具有更高的并行性。在此基础上, Zhou 等^[10]提出了基于 Transformer 的 Informer 模型,通过稀疏自注意力机制、蒸馏机制和生成式的解

基金项目:国家自然科学基金项目(52179014);国家重点研发计划项目(2022YFC3002702)
作者简介:李继清(1972—),女,教授,博士,主要从事水文水资源研究。E-mail:jqli6688@163.com
通信作者:谢宇韬(1997—),男,博士研究生,主要从事水文水资源研究。E-mail:xieyutao0117@163.com

码机制,在提高 Transformer 计算效率、优化内存和架构的同时,提供了更好的预测性能。由于 Informer 模型在结构上更适应长序列时间预测的特性,被广泛应用于光伏功率^[11]、风力发电量^[12]和负荷预测^[13-14]等领域,但在径流预报领域还未被应用。

预报因子是中长期径流数据驱动模型的输入,选取准确的预报因子是提高预报精度的关键。从物理成因来看,降水是径流的来源,降水的来源包括大气环流、海温等因素^[15]。近年来,遥相关因子被广泛应用于水文领域中,流域径流受到流域和全球尺度气候输入的影响^[16],相较于基于前期降水径流的预报方法,引入遥相关因子从物理成因上考虑其与径流的相关性,可以延长中长期径流预报的预见期^[17]。但是,引入大量遥相关因子的同时会显著增加预报因子集的维度,带来部分不相关和冗余的数据,降低预报的效率和准确度。如何从水文、气象、气候构成的高维预报因子集中挖掘与径流的相关性,为流域径流预报构建准确的预报因子集,是提高中长期径流预报质量的一个方向。赵铜铁钢等^[18]基于随机森林(random forest, RF)模型从 750 个水文-气象因子中筛选,构建了长江上游枯水期径流预报因子集;何小刚等^[19]通过 RF 模型筛选水文-气象遥相关因子,耦合 GBHM (geomorphology-based hydrological model),预报了丹江口水库的月入库径流;刘建华等^[20]在水文大气因子外增加海温偶极数据,延长了天一水库的预见期;熊怡等^[21]基于贝叶斯优化改进 RF 模型,并应用到与向家坝、石鼓、攀枝花 3 站径流相关的 396 个水文、气象和气候因子的筛选。

为了从物理成因上考虑径流和因子的相关性,本文构建了月径流预报的 RF-Informer 模型,该模型采用 RF 模型从雅砻江流域实测降水径流和国家气候中心记录的 130 项气象气候因子中筛选预报因子集,将筛选的预报因子集输入 Informer 模型进行月径流预报,以期水库调度运行、风险分析和决策提供参考。

1 研究方法

1.1 RF 模型

RF 模型^[22-23]是一种集成多棵决策树的监督学习算法,通过对多个随机抽样和随机特征选择生成的决策树结果进行投票或平均,提升预测准确性和抗过拟合能力,被广泛应用于挖掘目标因子与影响因子间的相关关系,以及评价影响因子的重要性。基于自主采样结果,将样本划分为训练样本和检验

样本,以预报误差的无偏估计作为检验样本的拟合误差,随机打乱某一因子的取值后再次进行预报,考察此时检验样本拟合误差的增加值,该增加量即为该因子的重要性评分。

1.2 Informer 模型

Informer 模型由若干编码器-解码器组成。序列经过卷积编码和嵌入后输入编码器,编码器通过多层概率稀疏自注意力和蒸馏操作,提取序列中的关键特征,输出编码特征向量;解码器通过掩码自注意力和交叉注意力机制,生成未来序列的预报,最后通过全连接层将解码器输出映射为具体的径流预报值。针对长序列时间预报存在的问题,Informer 模型主要有 3 点优势:①概率稀疏自注意力机制将时间复杂度从 L^2 减少到 $L\lg L$ (L 为输入的规模),有效降低了模型计算复杂度;②自注意力蒸馏机制可缩短每一层的输入序列长度,随着序列长度的缩短,计算量和存储量随之降低;③通过生成式的解码机制,可在序列预报时一步得到结果,避免了多步预测的误差累积。

1.3 月径流预报的 RF-Informer 模型

本文结合 RF 模型和 Informer 模型构建了月径流预报的 RF-Informer 模型,以降水径流数据和气候指数作为输入特征,通过优化的 RF 模型选择预报因子,确定最优预报因子集输入 Informer 模型中,得到月径流预报结果。具体步骤(图 1)如下:

a. 数据收集。从水文、气象、大气环流等成因中选择与径流相关性较强的因子,主要包括降水径流数据和气候指数。降水数据为站点降水量经泰森多边形加权计算得到的流域面平均降水量,径流数据为前期径流量。气候指数包括大气环流指数、海温指数和其他指数,大气环流指数包括北半球副高面积指数、东亚槽强度指数等 88 项,海温指数包括 NINO 指数、ENSO 指数等 26 项,其他指数包括南方涛动指数、太阳黑子指数等 16 项。由于预报因子对径流的影响存在滞后效应,考虑月径流的水文周期为 12 月,取前推 1~12 月的预报因子,构成备选预报因子集。

b. 基于 RF 模型的预报因子筛选。将备选预报因子集划分为训练集、验证集和测试集,有放回地进行 m 次随机取样,得到 m 个采样集,对于每个采样集构建决策树,生成 m 棵决策树,形成 RF 模型。在 m 个决策树中对每个预报因子的重要性进行评估,将每个预报因子在所有决策树中的重要性进行平均,结果集成后得到所有预报因子的重要性评分并进行排序,筛选出对月径流影响靠前的预报因子。

c. 基于 Informer 模型的月径流预报。将筛选

出的预报因子按重要性评分从高到低进行排序,由排序从前到后依次增加预报因子个数,组成不同的预报因子集,经过卷积编码和嵌入后作为 Informer 模型的输入序列(图 1 中绿色格子)。编码器接收输入序列后,通过多层概率稀疏自注意力和蒸馏操作,提取序列中的关键特征,通过主次堆栈的协同,实现多层次特征提取与压缩后输出编码特征向量,解码器接收编码器的输出和占位符序列(图 1 中标注为 0 的格子),通过掩码多层概率稀疏自注意力机制和交叉注意力机制生成全连接层,输出未来时间步长的径流预报值(图 1 中黄色格子表示重点关注时段)。计算各预报因子集的预报结果,并根据预报结果确定最优预报因子集。

为 148 亿 m^3 ,具有多年调节能力,对流域整体的水资源利用及防洪安全具有十分重要的影响。

本文采用的研究数据包括:两河口、锦西和二滩的入库月径流 Q 、130 项气候指数(包括 88 项大气环流指数 $A_1 \sim A_{88}$ 、26 项海温指数 $S_1 \sim S_{26}$ 和 16 项其他指数 $R_1 \sim R_{16}$)、雅砻江流域清水、石渠、甘孜、色达、道孚、新龙、理塘、康定、木里、九龙、越西、昭觉等 12 个气象站的月降水量 P (采用泰森多边形法将站点降水量转换为面平均降水量)。其中,降水数据来自中国气象数据网的中国地面气候资料月值数据集,气候指数来自国家气候中心的 130 项气候指数数据集。数据序列的时段为 1963—2017 年,按 7:1:2 划分训练集、验证集和测试集。采用 Mann-Kendall 检验对月径流序列进行分析,结果表明,月径流序列不存在显著的趋势变化(不拒绝零假设), p 值为 0.1408,因此月径流序列在 1963—2017 年保持一致性。

2.2 预报因子筛选

考虑月径流受预报因子的影响,在时空尺度上存在一定的滞后,对于月径流预报,完整的水文周期为 12 月,故取 12 作为滞后的阶数,即对入库月径流、月降水量、遥相关因子共 132 个影响因素前推 12 月得到 1584 个备选预报因子。基于 RF 模型计算 1584 个备选预报因子的重要性评分,以两河口水库月径流预报为例,与两河口入库径流相关性较高的为前期入库月径流、月降水量和大气环流指数,海温指数存在一定的相关性,其他指数未表现出明显的相关性。统计备选预报因子中重要性评分在前 30 的预报因子,大气环流指数为 23 个,占 77%;海温指数和其他指数均为 0;前期月降水量为 2 个,占 7%;前期入库月径流为 5 个,占 17%。在所有备选预报因子中,重要性评分最高(0.47)的为 7 月前降水量 P_{t-7} ;重要性评分排序第 2 的为 12 月前北非副高脊线位置指数(the North African subtropical high ridge position, NASHRP) $A_{24,112}$,结合 Tong 等^[24]的研究结论,NASHRP 是影响我国降水的主要环流指数之一,NASHRP 异常北移会引起我国降水增加,NASHRP 异常南移会导致我国降水减少。海温指数中重要性评分最高(排序第 38)的为 10 月前印度洋暖池面积指数 $S_{13,110}$,结合 Wang 等^[25]的研究,印度洋暖池的改变会对中国西南地区降水产生一定的影响,尤其在夏季和秋季。总的来说,雅砻江流域两河口水库入库月径流影响因子成因复杂,主要包括前期降水量、月径流、大气环流指数和海温指数,且在所有影响因子中,前期大气环流指数的占比最大,影响更显著。




图 1 RF-Informer 模型的月径流预报流程
Fig. 1 Monthly runoff forecasting process of RF-Informer model

1.4 评价指标

选取纳什效率系数(NSE)、决定系数(R^2)、均方根误差(RMSE)、平均绝对误差(MAE)和平均绝对百分比误差(MAPE)等 5 项指标作为评价指标。当 NSE、 R^2 越大, RMSE、MAE 和 MAPE 越小时,模型的模拟精度越高。

2 实例应用

2.1 研究区概况与数据来源

雅砻江是金沙江最大的支流,流域径流由夏季降雨、季节性积雪融水和冬季地下水 3 部分组成。流域枯水期为 1—3 月和 12 月,过渡期为 4—5 月和 10—11 月,汛期 6—9 月。两河口、锦西、二滩为雅砻江流域 3 个控制性水库工程,3 库总调节库容

分别采用线性相关法和 RF 模型从备选预报因子中选取与两河口入库月径流相关系数较大的前 30 个预报因子进行排序,依次增加预报因子输入 Informer 模型进行月径流预报,计算 MAE 值,如图 2 所示。两种预报因子筛选方法挑选出了一些相同的排序靠前的因子,如 $A_{24,112}$ 。然而就各因子排序而言,通过两种方法得到的排序结果大多不一致,如线性相关法中 $A_{24,112}$ 排在第 7,其重要性评分排在第 2,这是由于各因子间存在一定的非线性关系,可以在 RF 模型中体现。




图 2 两河口水库两种方法排序前 30 的预报因子重要性及预报误差

Fig. 2 Importance assessment and forecast errors of top 30 predictors using two methods at the Lianghekou Reservoir

由图 2(a)可知,预报因子与径流的相关系数最大值为 0.86,采用线性相关法筛选无法体现各因子间的非线性关系。各预报因子与径流的相关性是独立评估的,各预报因子相应的相关系数下降缓慢,排序接近的因子其相应的相关系数也较为接近。预报结果的 MAE 值随着预报因子的增加先减小后趋于稳定,仅采用相关系数最大的预报因子进行预报时,预报结果的 MAE 值最大,为 $242.39 \text{ m}^3/\text{s}$,预报效果最差;采用前 21 个预报因子进行预报时,预报结果的 MAE 值最小,为 $192.05 \text{ m}^3/\text{s}$,预报效果最好。从图 2(b)可以看出,采用 RF 模型筛选预报因子时,预报因子重要性评分最高为 0.48,随着排序的增加快速下降,相较于线性相关法下降的速率更快。从预报效果来看,仅采用排序第一的预报因子进行预报,其结果的 MAE 值与线性相关法基本相同,采用前 13 个预报因子进行预报时,预报结果的

MAE 值达到最小,为 $181.35 \text{ m}^3/\text{s}$,相较于线性相关法更快地达到了最佳预报效果,且预报精度更高。究其原因这是由于增加了大量遥相关因子,因子间存在一定的冗余和非线性关系,会对预报模型产生噪声干扰,而 RF 模型相较于线性相关法能更好地体现因子间非线性关系,去除噪声的干扰,选择更准确的径流预报因子集,从而改善预报质量。

同样基于 RF 模型筛选锦西和二滩水库入库月径流预报因子,得到重要性评分排序前 30 的预报因子,逐渐增加预报因子数,对应的结果如图 3 所示。锦西和二滩水库结果总体趋势和两河口水库相同,随着排序增加,预报因子的重要性评分快速下降,预报结果的 MAE 值亦随着预报因子数的增加而快速下降至最小值,然后趋于平稳。锦西水库的预报效果在采用前 11 个预报因子时达到最佳,预报结果的 MAE 值为 $173 \text{ m}^3/\text{s}$;二滩水库的预报精度在采用前 11 个预报因子时最高,MAE 值为 $158.65 \text{ m}^3/\text{s}$ 。




图 3 锦西、二滩水库排序前 30 的预报因子重要性及预报误差

Fig. 3 Importance assessment and forecast errors of top 30 predictors at the Jinxi and Ertan reservoirs

两河口、锦西、二滩水库分别为雅砻江流域上中下游的控制性水库工程,通过 RF 模型分别选择 13、11、11 个预报因子得到了最优预报效果,分析 3 库的最优预报因子集(表 1)可知,3 库共有 23 个预报因子,通过这 23 个预报因子即可较为准确地实现雅砻江流域的月径流预报。3 库最优预报因子集中共同包含的因子有 3 个,分别为 7 月前东亚槽强度指数 $A_{64,17}$ 、1 月前东亚槽强度指数 $A_{64,11}$ 和 1 月前降水量 P_{11} ,其中东亚槽强度指数表示东亚地区大气

环流的特征,容易影响雅砻江的天气变化。仅两河口和锦西水库共同包含的最优预报因子有 2 个,分别为 2 月前和 1 月前径流 Q_{t2} 、 Q_{t1} ;仅两河口和二滩水库共同包含的最优预报因子有 3 个,分别为 $A_{24,t12}$ 、1 月前亚洲区极涡强度指数 $A_{51,t1}$ 和 7 月前降水量 P_{t7} ;仅锦西和二滩水库共同包含的最优预报因子只有 1 个,为 8 月前北半球极涡强度指数 $A_{55,t8}$ 。

表 1 3 库入库月径流最优预报因子

Table 1 Optimal predictors for monthly runoff of three reservoirs				
最优因子	物理意义	两河口 水库	锦西 水库	二滩 水库
$A_{64,t7}$	7 月前东亚槽强度指数	✓	✓	✓
$A_{64,t1}$	1 月前东亚槽强度指数	✓	✓	✓
P_{t1}	1 月前降水量	✓	✓	✓
Q_{t2}	2 月前径流量	✓	✓	
Q_{t1}	1 月前径流量	✓	✓	
$A_{24,t12}$	12 月前 NASHRP 指数	✓		✓
$A_{51,t1}$	1 月前亚洲区极涡强度指数	✓		✓
P_{t7}	7 月前降水量	✓		✓
$A_{55,t8}$	8 月前北半球极涡强度指数		✓	✓
$A_{24,t6}$	6 月前 NASHRP 指数	✓		
$A_{33,t12}$	12 月前 NASHRP 指数			✓
$A_{35,t6}$	6 月前北非副高北界位置指数	✓		
$A_{35,t1}$	1 月前北非副高北界位置指数		✓	
$A_{35,t7}$	7 月前北非副高北界位置指数			✓
$A_{51,t8}$	8 月前亚洲区极涡强度指数		✓	
$A_{51,t7}$	7 月前亚洲区极涡强度指数	✓		
$A_{51,t2}$	2 月前亚洲区极涡强度指数		✓	
$A_{55,t1}$	1 月前北半球极涡强度指数	✓		
$A_{58,t1}$	1 月前北半球极涡中心强度指数	✓		
$A_{66,t1}$	1 月前青藏高原-2 指数		✓	
$A_{70,t1}$	1 月前北大西洋涛动指数			✓
Q_{t12}	12 月前径流量			✓
Q_{t3}	3 月前径流量		✓	

2.3 径流预报结果

为比较 Informer 模型相较于不同预报模型的预报效果,以两河口水库为例,分别采用线性相关法和 RF 模型选择预报因子,并选取了 LSTM、SVM、BP 神经网络模型进行月径流预报作为对比,4 种模型的预报效果见表 2。由表 2 可知,对于单一预报模型,利用 RF 模型筛选预报因子,预报精度优于线性相关法;在两种因子筛选方法中,Informer 模型预报月径流的各项指标均优于其他 3 个模型;在所有因子筛选方法和预报模型的组合中,RF 模型和 Informer 模型组合的预报精度最佳。

基于 RF 模型对预报因子筛选,建立 RF-Informer 模型,并采用不同模型对两河口入库径流进行预报,测试期(2009 年 1 月至 2017 年 12 月)结果如图 4 所示。由图 4 可知,4 个预报模型都具有较好的预报性能,各模型预报的径流序列和实测径流序列整体上拟合效果较好。从典型丰水年

表 2 两河口水库月径流预报精度评价

Table 2 Accuracy evaluation of monthly runoff forecast for the Lianghekou Reservoir

预报因子 筛选方法	预报模型	NSE	R^2	RMSE/ (m^3/s)	MAE/ (m^3/s)	MAPE
线性相关法	Informer	0.82	0.93	221	192	0.20
	LSTM	0.70	0.80	331	218	0.21
	SVM	0.68	0.79	340	221	0.25
	BP 神经网络	0.72	0.80	327	231	0.29
RF 模型	Informer	0.78	0.94	207	181	0.18
	LSTM	0.62	0.84	316	209	0.20
	SVM	0.57	0.82	337	208	0.19
	BP 神经网络	0.64	0.76	361	243	0.23




图 4 测试期不同预报模型的月径流预报结果

Fig. 4 Forecast results of monthly runoff with different forecast models during testing period

(2012 年)、平水年(2009 年)、枯水年(2010 年)的结果看,平水年和枯水年相较丰水年的预报值与实测值更为接近,主要在峰值的预报存在差异。对于低流量径流的预报,4 个模型的预报值与实测值结果相近,其中,RF-Informer 模型的预报值与实测值的拟合度最高;对于高流量径流的预报,4 个模型对峰值的预报值都小于实测的峰值,年内径流出现双峰结构时预报效果最差。从成因上看,月降水量、前期径流和遥相关因子对流域径流有一定的影响,枯水期的径流组成较简单平稳,汛期高流量甚至是大洪水的组成复杂,可学习的样本较少,且年内来水有时出现双峰结构,因而预报的精度较差。

为进一步分析遥相关因子在月径流预报中的作用,建立考虑遥相关因子与降水径流(遥相关因子、月降水量、入库月径流)和仅考虑降水径流(月降水量、入库月径流)的两类预报因子集,基于两类预报因子集,分别建立预见期为 12 月的 RF-Informer 模型,预报结果如图 5 所示。由图 5 可知,总体上两个预报因子集得到的预报结果都接近实测径流过程,但考虑遥相关因子与降水径流的预报结果更贴合实测径流过程。随着预见期的增加,对于预见期大于或等于 5 月的预报结果,尤其是预见期为 6~10 月的情况下,考虑遥相关因子与降水径流的预报径流相较仅考虑降水径流的预报结果明显更准确,表明

在前期降水径流的基础上增加遥相关因子作为预报模型输入可以有效延长月径流预报的预见期。




图5 两个预报因子集径流预报结果

Fig. 5 Runoff forecast results of two sets of predictors

为进一步分析 RF-Informer 模型的月径流预报性能,分别从不同月份开始进行不同预见期(1~12月)的预报试验,预报精度评价结果如图6所示。由图6可知,从不同月份开始,随着预见期的延长,预报误差随之增大。在预见期为1~3月时(图6中黄框所示),以1—4月、11—12月作为预报起点的




图6 以不同月份作为预报起点时不同预见期的
预报效果评价

Fig. 6 Evaluation of forecast performance of different lead times with different starting months

预报误差较小,以5月和10月作为预报起点的预报误差次之,以6—9月作为预报起点的预报误差较大,这是由 RF-Informer 模型在高、低流量情况下预报性能决定的,符合雅砻江流域枯水期为1—3月和12月、过渡期为4—5月和10—11月、汛期6—9月的径流特性。

3 结 论

- a. 除前期降水径流外,遥相关因子对流域月径流也有一定的影响,增加遥相关因子作为预报模型的输入,可以提高月径流预报的精度,延长预见期。
- b. 在高维复杂预报因子集的处理上,RF 模型可以体现因子间的非线性关系,减小预报因子集的冗余,提升预报效果。
- c. 基于 RF 模型对预报因子的选择,构建了径流预报的 RF-Informer 模型,该模型预报效果优于 RF-LSTM、RF-SVM、RF-BP 神经网络模型,可以有效提高月径流预报精度。

参考文献:

[1] 孙周亮,刘艳丽,张建云,等. 中长期径流预报研究进展与展望[J]. 水资源保护,2023,39(2):136-144. (SUN Zhouliang, LIU Yanli, ZHANG Jianyun, et al. Research progress and prospect of mid-long term runoff prediction [J]. Water Resources Protection, 2023, 39(2): 136-144. (in Chinese))

[2] 刘莉,梁霄,WANG Quanjun,等. 基于深度学习的改进 ERRIS 径流预报实时校正模型[J]. 水资源保护,2024,40(6):155-164. (LIU Li, LIANG Xiao, WANG Quanjun, et al. Improved ERRIS model for real-time correction of streamflow forecast based on deep learning [J]. Water Resources Protection, 2024, 40(6): 155-164. (in Chinese))

[3] 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))

[4] 周鹏,许月萍,周欣磊,等. 基于多模型融合的椒江流域季节性径流集合预报[J]. 水利水电科技进展,2025,45(3):62-69. (ZHOU Peng, XU Yueping, ZHOU Xinlei, et al. Ensemble forecasting of seasonal streamflow in the Jiaojiang River Basin based on multi-model fusion [J]. Advances in Science and Technology of Water Resources, 2025, 45(3): 62-69. (in Chinese))

[5] 申智鹏,孙颖娜,姚浩,等. 基于 BP 神经网络模型的月径流预报[J]. 陕西水利,2022(5):42-44. (SHEN Zhipeng, SUN Yingna, YAO Hao, et al. Monthly runoff forecast based

- on BP neural network model inclined core [J]. Shaanxi Water Resources, 2022(5):42-44. (in Chinese))
- [6] 黄一凡,张翔,邓梁堃,等. 基于机器学习的汉江流域径流模拟与时滞变化分析[J]. 水资源保护, 2024, 40(6): 173-180. (HUANG Yifan, ZHANG Xiang, DENG Liangkun, et al. Runoff simulation and time-lag change analysis in the Han River Basin based on machine learning [J]. Water Resources Protection, 2024, 40(6): 173-180. (in Chinese))
- [7] 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))
- [8] 刘源,纪昌明,马皓宇,等. 基于集合 Kalman 滤波的中长期径流预报[J]. 水资源保护, 2024, 40(1): 93-99. (LIU Yuan, JI Changming, MA Haoyu, et al. Medium and long-term runoff forecast based on ensemble Kalman filter [J]. Water Resources Protection, 2024, 40(1): 93-99. (in Chinese))
- [9] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Incorporated, 2017: 6000-6010.
- [10] ZHOU Haoyi, ZHANG Shanghang, PENG Jieqi, et al. Informer: beyond efficient transformer for long sequence time-series forecasting [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2021: 11106-11115.
- [11] 滕陈源,丁逸超,张有兵,等. 基于 VMD-Informer-BiLSTM 模型的超短期光伏功率预测[J]. 高电压技术, 2023, 49(7): 2961-2971. (TENG Chenyuan, DING Yichao, ZHANG Youbing, et al. Ultra-short-term photovoltaic power prediction based on VMD-Informer-BiLSTM model [J]. High Voltage Engineering, 2023, 49(7): 2961-2971. (in Chinese))
- [12] WEI Hui, WANG Wensheng, KAO Xiaoxuan. A novel approach to ultra-short-term wind power prediction based on feature engineering and informer [J]. Energy Reports, 2023, 9: 1236-1250.
- [13] XU Hongbin, PENG Qiang, WANG Yuhao, et al. Power-load forecasting model based on Informer and its application [J]. Energies, 2023, 16(7): 3086.
- [14] GONG Mingju, ZHAO Yin, SUN Jiawang, et al. Load forecasting of district heating system based on Informer [J]. Energy, 2022, 253: 124179.
- [15] BURDANOWITZ J, BUEHLER S A, BAKAN S, et al. The sensitivity of oceanic precipitation to sea surface temperature [J]. Atmospheric Chemistry and Physics, 2019, 19(14): 9241-9252.
- [16] MAITY R, KASHID S S. Importance analysis of local and global climate inputs for basin-scale streamflow prediction [J]. Water Resources Research, 2011, 47(11): W11504.
- [17] WANG Jia, WANG Xu, LEI Xiaohui, et al. Teleconnection analysis of monthly streamflow using ensemble empirical mode decomposition [J]. Journal of Hydrology, 2020, 582: 124411.
- [18] 赵钢铁,杨大文,蔡喜明,等. 基于随机森林模型的长江上游枯水期径流预报研究[J]. 水力发电学报, 2012, 31(3): 18-24. (ZHAO Tongtiegang, YANG Dawen, CAI Ximing, et al. Predict seasonal low flows in the upper Yangtze River using random forests model [J]. Journal of Hydroelectric Engineering, 2012, 31(3): 18-24. (in Chinese))
- [19] 何小刚,赵钢铁,杨大文. 分布式水文模型与气象遥相关分析相结合的丹江口水库月入库径流预测[J]. 水力发电学报, 2013, 32(3): 4-9. (HE Xiaogang, ZHAO Tongtiegang, YANG Dawen, et al. Prediction of monthly inflow to the Danjiangkou Reservoir by distributed hydrological model and hydro-climatic teleconnections [J]. Journal of Hydroelectric Engineering, 2013, 32(3): 4-9. (in Chinese))
- [20] 刘建华,徐文馨,石昕颜,等. 融合海温偶极因子的长期月径流预报研究[J]. 中国农村水利水电, 2023(9): 46-53. (LIU Jianhua, XU Wenxin, SHI Xinyan, et al. Long-term streamflow prediction with sea surface temperature dipoles incorporated [J]. China Rural Water and Hydropower, 2023(9): 46-53. (in Chinese))
- [21] 熊怡,周建中,贾本军,等. 基于随机森林遥相关因子选择的月径流预报[J]. 水力发电学报, 2022, 41(3): 32-45. (XIONG Yi, ZHOU Jianzhong, JIA Benjun, et al. Monthly runoff prediction based on teleconnection factors selection using random forest model [J]. Journal of Hydroelectric Engineering, 2022, 41(3): 32-45. (in Chinese))
- [22] BREIMAN L. Bagging predictors [J]. Machine Learning, 1996, 24(2): 123-140.
- [23] BREIMAN L. Random forests [J]. Machine Learning, 2001, 45(1): 5-32.
- [24] TONG Xuan, YAN Zhongwei, XIA Jiangjiang, et al. Decisive atmospheric circulation indices for July-August precipitation in north China based on tree models [J]. Journal of Hydrometeorology, 2019, 20(8): 1707-1720.
- [25] WANG Lin, HUANG Gang, CHEN Wen, et al. Wet-to-dry shift over southwest China in 1994 tied to the warming of tropical warm pool [J]. Climate Dynamics, 2018, 51(7/8): 3111-3123.

(收稿日期: 2024-07-24 编辑: 施业)