

基于深度学习的改进 ERRIS 径流预报实时校正模型

刘莉¹, 梁霄¹, WANG Quanjun², 许月萍¹

(1. 浙江大学建筑工程学院, 浙江 杭州 310058; 2. 墨尔本大学工程与信息技术学院, 维多利亚 墨尔本 3052)

摘要: 为提高径流预报精度, 基于长短期记忆网络(LSTM)改进 ERRIS 模型, 构建了径流预报实时校正的 ERRIS-LSTM 模型, 以雅鲁藏布江流域和椒江流域为例进行对比分析。结果表明: 与 ERRIS 模型相比, ERRIS-LSTM 模型使雅鲁藏布江流域和椒江流域径流预报的纳什效率系数分别提升了 4.1% 和 1.1%, 均方根误差分别减小了 67.7% 和 5.7%, 使雅鲁藏布江流域中、低水流量的百分比偏差分别降低了 75.5% 和 79.1%, 椒江流域低水流量统计指标均改善超过 20%; ERRIS-LSTM 模型能够充分获取误差序列的序贯相关性, 生成的集合预报比 ERRIS 模型预报的整体精度更高, 连续排序概率评分降低了 75% 以上, 不确定性更小, 可靠性更强; 相比于 LSTM 模型的校正结果, ERRIS-LSTM 模型可以额外提供校正结果的不确定性信息, 在业务预报和防洪决策中具有重要的应用前景。

关键词: 径流预报; 实时校正; 深度学习; ERRIS 模型; LSTM 模型; 雅鲁藏布江流域; 椒江流域

中图分类号: P338 **文献标志码:** A **文章编号:** 1004-6933(2024)06-0155-10

Improved ERRIS model for real-time correction of streamflow forecast based on deep learning// LIU Li¹, LIANG Xiao¹, WANG Quanjun², XU Yueping¹ (1. College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, China; 2. Faculty of Engineering and Information Technology, University of Melbourne, Melbourne 3052, Australia)

Abstract: In order to improve the accuracy of streamflow forecast, the ERRIS model was improved based on LSTM, and the ERRIS-LSTM model was constructed for real-time correction of streamflow forecast. The Yarlung Zangbo River and Jiao River basins were taken as examples for comparative analysis. The results showed that, compared with the ERRIS model, the ERRIS-LSTM model increased the Nash-Sutcliffe efficiency coefficient by 4.1% and 1.1%, decreased the root mean squared error by 67.7% and 5.7% in streamflow forecast of the Yarlung Zangbo River and Jiao River basins, respectively. Especially for medium and low flows of the Yarlung Zangbo River Basin, the values of percent bias of streamflow forecast obtained by the ERRIS-LSTM model were reduced by 75.5% and 79.1%, respectively, and the statistical indexes of low flow in the Jiao River Basin obtained by the ERRIS-LSTM model were improved by more than 20%. The ERRIS-LSTM model could fully capture the continuity of the error series, and the ensemble forecasts generated by the ERRIS-LSTM model were more accurate, less uncertain, and more reliable than those of the ERRIS model, with the continuous ranked probability score reduced by more than 75%. In comparison with the deterministic corrected results of the LSTM model, the ERRIS-LSTM model can provide additional uncertainty information, which is promising in operational forecasting and decision-making in flood control.

Key words: streamflow forecast; real-time correction; deep learning; ERRIS model; LSTM model; Yarlung Zangbo River Basin; Jiao River Basin

准确的径流预报是流域水资源综合利用、防洪抗旱减灾及水库运行调度的重要科学依据, 具有显著的经济价值和社会效益^[1]。但在实际水文应用中, 受到自然复杂性和人类认知局限性等因素的影

响, 水文预报通常存在一定的误差, 导致预报结果与客观实际存在偏差, 需要进行误差修正^[2], 而实时校正是提升径流预报精度、保证预报模型实用性和有效性的重要方法^[3-4]。

基金项目: 浙江省重点研发计划项目(2021C03017); 浙江省自然科学基金项目(LQ22E090004); 国家自然科学基金项目(52309038); 浙江省自然科学基金重点基金项目(LZ20E090001); 中国博士后科学基金项目(2023M733117)

作者简介: 刘莉(1990—), 女, 助理研究员, 博士, 主要从事洪水预报与水文模拟研究。E-mail: li_liu@zju.edu.cn

通信作者: 许月萍(1975—), 女, 教授, 博士, 主要从事水文水资源研究。E-mail: yuepingxu@zju.edu.cn

径流预报的实时校正方法大致可分为两类:过程误差校正(process bias correction, PBC)方法和终端误差校正(terminal bias correction, TBC)方法^[2-3]。PBC方法包括卡尔曼滤波^[5]、动态响应曲线法^[6]等,通过对水文预报各个过程进行误差修正达到降低终端误差的目的。受限于实测数据信息获取的完整性,PBC方法在实时校正作业预报中的实用性不高^[2]。TBC方法不考虑预报过程的中间误差,直接对最终预报总误差进行校正,包括基于自回归(autoregressive, AR)模型的校正方法^[7]、基于协整理论的ARECM(autoregressive error correction model)^[8]、KNN(K-nearest neighbor)方法^[4]等。AR模型算法简单,资料需求少,应用最为广泛,但其依赖于预报误差的序贯相关性,当序列突变(如洪水起涨、洪峰附近)时这种序贯相关性发生变化,会导致修正结果不佳^[8]。针对上述问题,Li等^[9-10]提出了约束AR模型,以此为基础开发了ERRIS(error reduction and representation in stages)模型,可以显著降低AR模型对洪峰的过度校正,并提供误差的统计分布特征,生成径流概率预报。ERRIS模型被澳大利亚气象局应用在国家未来7d集合径流预报中^[11],但其校正主要依靠前一时刻的误差信息,对于误差变异性较大和误差长期相关性较高的流域,可能存在非最优校正的问题^[12]。因此,研究如何改善ERRIS模型对误差信息的处理方式,进而提高模型校正效率有着重要意义。

机器学习和深度学习技术为洪水实时校正带来了新的机遇,Nanda等^[13]利用小波神经网络建立实时误差校正模型,证实该技术能有效改善原始水文模型预报的误差低估问题;蒋志强等^[14]利用长短期记忆网络(long short-term memory, LSTM)模型建立了考虑预报误差和情景的径流预报校正方法;黄一昕等^[2]认为虽然目前大数据分析技术在洪水预报实时校正中尚未有实质性的进展,但利用大数据和机器学习寻找终端误差或过程误差与数据之间的关联规则,进而建立预报误差的修正模型,有望进一步提升校正效果;Nearing等^[15]也认为LSTM模型能够克服AR模型对新数据普适性差的问题。鉴于深度学习技术在径流预报及校正中的成功应用,本文尝试将深度学习技术与传统参数化误差校正模型相耦合,在ERRIS模型中引入LSTM提取误差数据序列的关联规则,构建径流预报误差实时修正的ERRIS-LSTM模型,提高流域径流预报的精度,为洪水预报预警和防洪调度提供更有力的科学支撑。

1 ERRIS-LSTM模型的构建

1.1 ERRIS模型

ERRIS模型^[9-10,12]主要通过4个步骤对预报结果进行校正:数据转换、偏差纠正、约束AR校正和误差分布改善。

步骤1 数据转换。径流数据通常呈现出异方差性,即高水流量的方差比低水流量的方差大很多^[16]。当AR模型应用于未经标准化的误差时可能由于放大的不确定性导致校正效果不佳,因此需要对误差序列进行标准化处理,使数据满足同方差性并服从高斯分布。由于Log-sinh数据转化方法对偏态分布的数据具有更高效的处理能力,本文采用该方法对原始径流进行数据转化^[16]:

$$Z_t = \{\lg[\sinh(a + bQ_t)]\} / b \quad (1)$$

式中: Z_t 为标准化后 t 时刻的实测径流; Q_t 为 t 时刻实测径流; a, b 为转换参数,根据流量确定。对模拟径流 \tilde{Q}_t 做同样的转换得到 $\tilde{Z}_{1,t}$,此阶段 Z_t 服从均值为 $\tilde{Z}_{1,t}$ 、标准偏差为 σ_1 的高斯分布,即 $Z_t \sim N(\tilde{Z}_{1,t}, \sigma_1^2)$ 。

步骤2 偏差纠正。对数据转换后的径流序列 $\tilde{Z}_{1,t}$ 进行条件偏差纠正:

$$\tilde{Z}_{2,t} = c + d\tilde{Z}_{1,t} \quad (2)$$

式中: c, d 分别为偏差纠正的截距和斜率参数。此阶段 Z_t 服从均值为 $\tilde{Z}_{2,t}$ 、标准偏差为 σ_2 的高斯分布,即 $Z_t \sim N(\tilde{Z}_{2,t}, \sigma_2^2)$ 。

步骤3 约束AR校正。基于前一时刻的误差信息进行实时校正:

$$\tilde{Z}_{3,t} = \begin{cases} \tilde{Z}_{2,t} + \Delta & |\tilde{Q}_{3,t}^* - \tilde{Q}_{2,t}| \leq |Q_{t-1} - \tilde{Q}_{2,t-1}| \\ f(\tilde{Q}_{2,t} + Q_{t-1} - \tilde{Q}_{2,t-1}) & \text{其他} \end{cases} \quad (3)$$

其中 $\Delta = \rho(Z_{t-1} - \tilde{Z}_{2,t-1})$

$$\tilde{Q}_{3,t}^* = f^{-1}(\tilde{Z}_{2,t} + \Delta) \quad \tilde{Q}_{2,t} = f^{-1}(\tilde{Z}_{2,t})$$

式中: ρ 为自相关参数; $f(\cdot)$ 表示Log-sinh数据转换; $f^{-1}(\cdot)$ 表示Log-sinh数据转换的逆运算。基于式(3)可以有效降低过度修正,此阶段 Z_t 服从均值为 $\tilde{Z}_{3,t}$ 、标准偏差为 σ_3 的高斯分布,即 $Z_t \sim N(\tilde{Z}_{3,t}, \sigma_3^2)$ 。

步骤4 误差分布改善。经约束AR校正后误差分布会变得突起并呈现尾部拖长的现象,因此,需要进一步利用高斯混合分布对误差分布进行改善,此阶段 Z_t 服从均值为 $\tilde{Z}_{4,t}$ ($\tilde{Z}_{4,t} = \tilde{Z}_{3,t}$)、标准偏差分别为 $\sigma_{4,1}, \sigma_{4,2}$ 的混合高斯分布,即 $Z_t \sim MN(\tilde{Z}_{4,t}, \sigma_{4,1}^2, \sigma_{4,2}^2, w)$,两种分布的权重分别为 w 和 $1-w$ 。为了区分高斯混合分布的两个组成分布函数,规定 $\sigma_{4,1} < \sigma_{4,2}$ 。

ERRIS 模型涉及的参数包括 c 、 ρ 、 w 以及每个阶段的标准偏差,都采用 SCE (shuffled complex evolution) 算法^[17]进行率定,率定的目标函数为最大化似然函数。ERRIS 模型输出结果为服从混合高斯分布的集合预报,能够表征校正结果的不确定性特征。本文在其分布函数上随机抽取 5 000 个数作为 5 000 个集合成员的预报结果。

1.2 LSTM 模型

LSTM 是一种特殊的循环神经网络^[18],通过独特的门控设计进行信息传递,信息传递机制更为精细,能够充分挖掘序列数据的长期依赖关系,有效避免传统循环神经网络在序列数据训练过程中出现梯度消失或梯度爆炸的问题^[19-20]。LSTM 模型的每层神经元设计为具有多个门的结构,其中输入门用于控制信息输入,遗忘门用于控制依赖信息的取舍,输出门用于控制信息输出。本文采用控制变量法进行 LSTM 模型的超参数率定,4 个超参数分别为舍弃率、训练批次、隐藏层单元数和迭代次数。损失函数设为均方误差 (mean squared error, MSE),评估指标为平均绝对误差 (mean absolute error, MAE),选择 Adam 为模型优化器。

1.3 ERRIS-LSTM 模型

ERRIS 模型约束 AR 校正的校正量 Δ 仅能线性利用前一时刻的误差信息,为充分利用参数化校正模型和人工智能模型的优势,本文提出利用 LSTM 模型预测 ERRIS 模型的校正量 Δ :

$$\Delta = L(\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}) \quad (4)$$

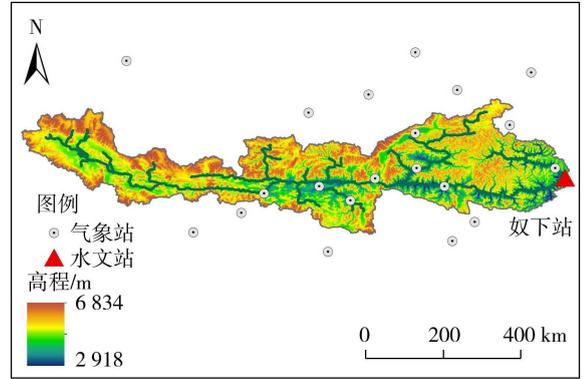
式中: $L(\cdot)$ 为 LSTM 模型函数; $\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}$ 分别为 $t-1, t-2, \dots, t-k$ 时刻的预报误差, $\varepsilon_{t-i} = Z_{t-i} - \tilde{Z}_{2,t-i}$ ($i = 1, 2, \dots, k$)。 k 值通过自相关函数 (autocorrelation function, ACF) 和偏自相关函数 (partial autocorrelation function, PACF) 分析确定。ACF 用以描述数据系列自身不同时期的相关关系,而 PACF 用以考虑滞后第 k 个时刻对目前结果的影响。

2 实例分析

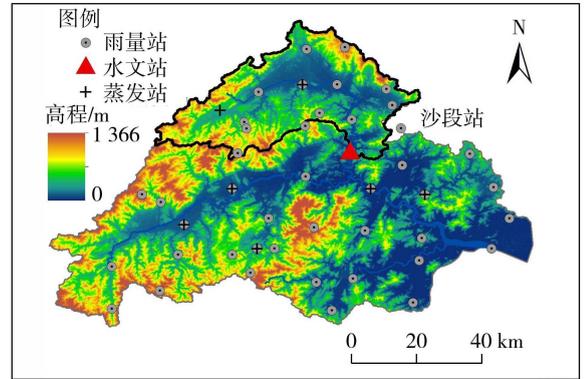
2.1 流域概况

选取雅鲁藏布江和椒江流域(图 1)进行实例分析。雅鲁藏布江发源于青藏高原西南部,处于 $28^{\circ}8'N \sim 31^{\circ}17'N, 82^{\circ}E \sim 94^{\circ}39'E$ 之间。流域全长 2 057 km,平均海拔在 4 600 m 以上,奴下水文站以上流域面积约为 21 万 km^2 ^[21]。受孟加拉湾暖湿气流、西风环流以及高原地理环境的影响,流域从东到西分别为寒冷干燥的温带草原气候、温带森林草原气

候和亚热带温湿气候,流域内降水分布很不均匀,从流域下游至上游呈梯度减少趋势。作为亚洲水塔最重要的流域之一,雅鲁藏布江流域径流预报对下游水资源规划和洪水预警具有重要的作用。受限于复杂的水文、气候和地理条件,流域内气象站点稀疏,水文循环过程复杂,径流过程的季节性变化显著,径流模拟和预报存在较大误差,进行径流预报实时校正十分必要^[22]。



(a) 雅鲁藏布江流域



(b) 椒江流域

图 1 流域概况

Fig. 1 Overview of river basins

椒江流域位于浙东南沿海,处于 $28^{\circ}28'N \sim 29^{\circ}19'N, 120^{\circ}14'E \sim 121^{\circ}34'E$ 之间,面积约为 $6\,600\text{ km}^2$ 。流域为亚热带湿润气候,雨季集中在每年 4—10 月,年平均降水量约为 $1\,600\text{ mm}$ ^[23]。椒江上游分为永安溪和始丰溪两大支流,是典型的山溪性河流,分别设有柏枝岙和沙段水文站,水文站以上集水面积分别为 $2\,720\text{ km}^2$ 和 $1\,610\text{ km}^2$ 。流域下游为感潮河段,受潮水顶托极易在雨季形成洪水。作为浙江省第三大河流,椒江径流预报对于流域水资源优化配置和流域防汛减灾具有重要意义。流域内虽然有较为完善的水文气象站点,但由于流域面积小,坡陡流急,洪水暴涨暴落,径流序列的序贯相关性变化大,实时校正面临较大的挑战。

2.2 径流预报

根据流域特征,分别采用不同水文模型对雅鲁

藏布江流域和椒江流域进行径流预报。雅鲁藏布江流域为大尺度高寒山区流域,水文过程复杂,流域径流由降水、融雪和融冰等构成^[22],本文选取 VIC (variable infiltration capacity) 分布式水文模型进行水文预报。VIC 模型是基于网格的大尺度陆面模式,能够基于水量和能量平衡模拟陆面过程,并考虑网格内不同土地覆盖类型的影响,具有较高的模拟精度^[23-24]。本文在雅鲁藏布江流域建立空间分辨率为 $0.25^{\circ} \times 0.25^{\circ}$ 、时间步长为 6 h 的 VIC 模型,更多建模细节可参考文献^[12,22]。

椒江流域为湿润山区流域,本文选取三水源新安江模型^[25]开展径流预报,该模型被广泛应用在湿润、半湿润地区的径流模拟和预报。模型将全流域划分为若干单元子流域,对单元子流域分别进行产汇流计算,再经过河道演算得到流域出口的流量过程。模型输入降水和蒸发数据分别来自流域内 45 个基本雨量站和 7 个蒸发站 (E601 蒸发皿) (图 1(b))。参照陆曼皎等^[26-27]的经验,利用遗传算法对模型的 15 个参数进行优化。

选取径流序列的纳什效率系数 (Nash-Sutcliffe efficiency coefficient, NSE) 和百分比偏差 (percent bias, Pbias) 作为目标函数对两个流域的水文模型进行参数优化。

2.3 评估指标

通过比较 ERRIS 模型和 ERRIS-LSTM 模型在整个流量序列和 3 个不同流量等级的预报精度来评估其对日径流校正的准确性和实用性。除 NSE 和 Pbias 以外,本文还选取均方根误差 (root mean square error, RMSE)、MAE 两项确定性指标和连续排序概率评分 (continuous ranked probability score, CRPS)、 α 指数两项集合指标作为评估指标。CRPS 是集合预报的综合性指标,其值越小表示预报结果越好,当预报为确定性预报时,CRPS 相当于 MAE^[12]; α 指数表征预报结果的可靠性,预报结果可靠性越高, α 指数越大, $\alpha = 1$ 表示完美预报^[28]。根据流域的流量值特征,本文将流量分为 3 个等级:将日流量从大到小排序后,前 10% 的大流量定为高水流量,中间 50% 的流量定为中水流量,后 40% 的小流量定为低水流量^[29]。

为公平比较 ERRIS 和 ERRIS-LSTM 模型的性能,两个校正模型均采用相同的训练数据和测试数据。由于流域数据可获取时间不同,对于雅鲁藏布江流域奴下站,选取 2005—2010 年为实时校正模型的训练期,2011—2014 年为测试期;对于椒江流域沙段站,选取 2011—2016 年为实时校正模型的训练期,2017—2020 年作为测试期。本文以预见期为 1d

的径流预报进行实例分析。

2.4 结果与分析

图 2 为雅鲁藏布江流域奴下站和椒江流域沙段站日径流误差序列 ACF 和 PACF 与滞后时间的关系,可以看出奴下站 ACF 呈现典型拖尾现象,其 PACF 值在滞后时间大于 7 d 时基本落在 95% 的置信带内,可以认为奴下站日径流误差与滞后 7 d 内的误差信息相关性较大。因此,式 (4) 中 k 值取 7,即采用前 7 d 的误差数据作为 LSTM 模型的输入预测当前时刻的误差。特别地,奴下站 PACF 在 7 d 内存在正、负显著相关,这可能和流域径流存在某些季节性变化、趋势或周期性变化有关,也可能由于数据不充分导致。沙段站预报径流误差与奴下站有着显著的差别,其 ACF 并不呈现渐变拖尾现象。滞后时间从 0 d 变为 1 d 时,其 ACF 值由 1 骤减至 0.17,说明椒江流域径流误差序列的自相关性不高。通过分析沙段站的 ACF 和 PACF,可以确定其对应的 k 值为 5。此外,采用控制变量法确定的 LSTM 模型训练批次为 32,迭代次数为 200,舍弃率为 0.2,隐藏层单元数为 20。奴下站和沙段站 LSTM 模型训练过程中损失函数和评估指标随迭代次数的变化如图 3 所示 (图中数值为对数据标准化处理后的结果)。由图 3 可知,模型迭代次数在 10 次以内时, MSE 迅速下降,奴下站和沙段站 LSTM 模型的迭代次数分别约为 25 次和 35 次时, MSE 和 MAE 曲线均达到拐点,误差下降速度逐渐趋于平缓,模型逐渐收敛。

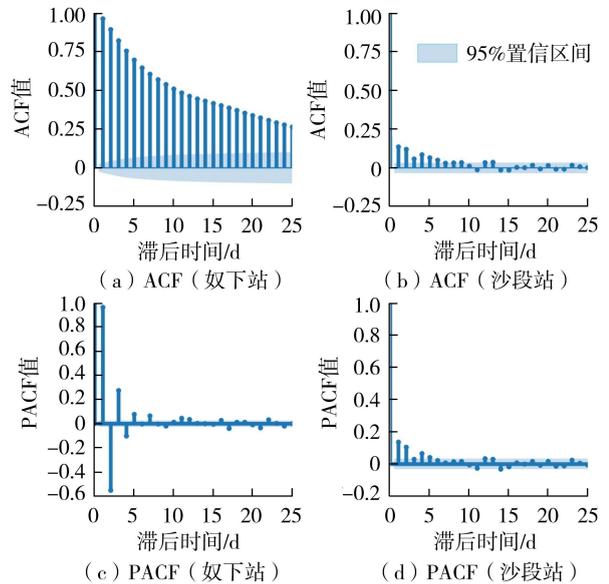


图 2 日径流误差序列 ACF 和 PACF 与滞后时间的关系
Fig. 2 Relationships of ACF and PACF of daily streamflow error series with lag time

奴下站和沙段站测试期径流校正效果对比如图 4 所示,径流的 95% 置信区间为 2.5%~97.5%分

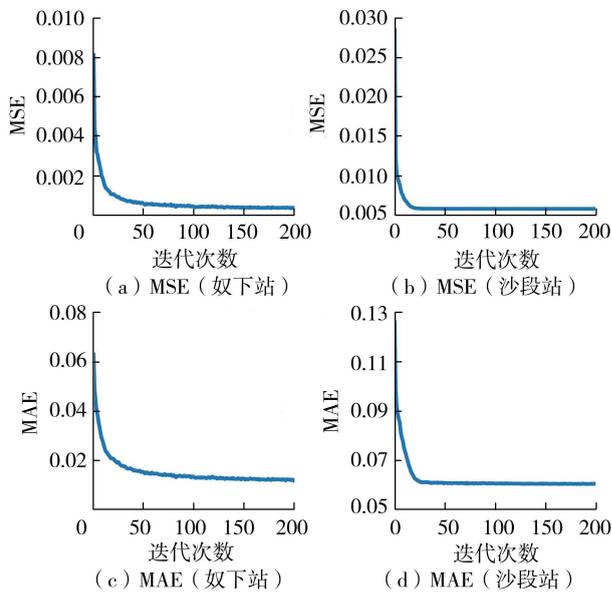


图3 损失函数和评估指标随迭代次数变化

Fig. 3 Variations of loss function and evaluation index with iteration time

位点范围内的流量,不同模型整个流量序列和不同流量等级的统计指标如表1和表2所示。

由图4(a)可知,ERRIS、ERRIS-LSTM模型均能有效修正雅鲁藏布江流域奴下站原始预报的误差。原始预报存在对枯水期径流的显著低估和对丰水期

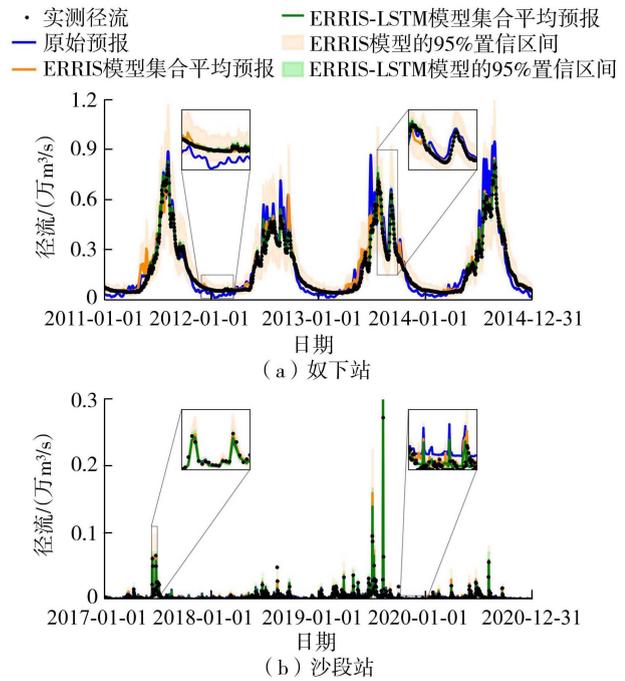


图4 测试期径流校正效果对比

Fig. 4 Comparison of streamflow correction effect in testing period

径流的显著高估,并对每年初夏第一个洪峰存在明显高估,导致其Pbias为6.7%的正偏差,RMSE达到634 m³/s。经ERRIS模型修正后,整体径流得到了

表1 整个流量序列的统计指标

Table 1 Statistical indexes for entire streamflow series

站点	校正模型	NSE	RMSE/(m ³ /s)	MAE/(m ³ /s)	Pbias/%	CRPS	α 指数
奴下站	原始预报	0.870	634	434	6.7		
	ERRIS	0.956*	371*	202*	7.2*	198.96	0.64
	ERRIS-LSTM	0.995*	120*	69*	1.4*	48.78	0.68
	LSTM	0.993	123	77	-1.6		
沙段站	原始预报	0.920	37	16	17.3		
	ERRIS	0.880*	35*	14*	1.7*	10.12	0.82
	ERRIS-LSTM	0.890*	33*	13*	-0.8*	11.19	0.84
	LSTM	0.920	32	13	5.6		

注:“*”表示确定性指标为5000个集合成员的集合平均径流(等权重算术平均)计算结果。下同。

表2 不同流量等级的统计指标

Table 2 Statistical indexes for different streamflow levels

流量等级	校正模型	奴下站统计指标					沙段站统计指标				
		NSE	RMSE/(m ³ /s)	MAE/(m ³ /s)	Pbias/%	CRPS	NSE	RMSE/(m ³ /s)	MAE/(m ³ /s)	Pbias/%	CRPS
高水	原始预报	-0.22	1059.2	829.6	10.6	0.92	70.5	42.6	-9.4		
	ERRIS	0.61*	600.5*	401.7*	-1.5*	504.7	0.84*	101.0*	53.8*	-6.5*	41.1
	ERRIS-LSTM	0.93*	255.2*	195.0*	1.8*	138.4	0.85*	97.9*	52.2*	-10.8*	49.9
	LSTM	0.93	262.7	198.9	-1.6		0.91	72.1	43.5	-9.1	
中水	原始预报	0.61	710.4	490.6	8.3	-0.02	18.4	12.8	19.9		
	ERRIS	0.86*	417.8*	246.7*	10.6*	235.2	0.19*	16.4*	11.0*	-1.8*	8.3
	ERRIS-LSTM	0.99*	122.8*	82.3*	2.6*	58.1	0.18*	17.0*	12.5*	-1.7*	7.7
	LSTM	0.98	128.9	88.0	-2.4		0.16	16.7	11.3	5.9	
低水	原始预报	-16.6	292.2	260.1	-12.5	-15.7	15.1	13.1	271.0		
	ERRIS	-5.9*	183.1*	93.0*	14.8*	74.4	-4.6*	8.8*	6.0*	115.0*	4.6
	ERRIS-LSTM	0.86*	26.0*	20.5*	3.1*	13.9	-2.4*	6.8*	4.6*	48.0*	3.1
	LSTM	0.68	39.2	34.9	-5.8		-6.9	10.4	7.7	155.0	

较大改善, NSE 提升了 9.8%, RMSE 降低了 41.5%, 特别是枯水期, 低水流量的 MAE 降低了约 64.2%。尽管 ERRIS 模型在预防过度校正上做了相当大的努力, 但还是存在对峰后流量改善较为有限的现象, 从图 4(a) 可以明显看出几乎所有洪峰后的退水流量都存在校正失效的现象, 校正后的流量精度甚至低于原始预报结果, 同时 ERRIS 模型还有加剧原始预报对初夏第一个洪峰高估误差的趋势。相应地, 表 2 中中水流量的 Pbias 指标从原始 8.3% 增加至 10.6%, 低水流量的 Pbias 从原本的低估偏差 -12.5% 过度校正为正偏差 14.8%, 高水流量的 Pbias 经校正后虽然很小 (-1.5%), 但主要是由于峰后流量骤降引起的, 并不是有效校正。这些问题经过 ERRIS-LSTM 模型校正后得到了有效解决, 整个流量序列的 NSE 达到了 0.995, RMSE 降低至 $120 \text{ m}^3/\text{s}$, 分别比 ERRIS 模型进一步提升了 4.1% 和降低了 67.7%, 说明通过 LSTM 模型获取 AR 模型的校正量能够有效地解决洪峰前后序列的序贯相关性突变导致的校正失效问题。对比 ERRIS 和 ERRIS-LSTM 模型不难看出, ERRIS-LSTM 模型能够比 ERRIS 模型更高效地校正预报误差, 具体表现为高水流量的 NSE 进一步提升了 52.5%, 中水和低水流量的 Pbias 分别降低为 2.6% 和 3.1%, 分别比 ERRIS 进一步降低了 75.5% 和 79.1%, 低水流量的 NSE 大幅度改善为 0.86。从集合指标来看, ERRIS-LSTM 模型集合预报的 CRPS 仅为 ERRIS 模型的 24.5%, 意味着 ERRIS-LSTM 显著降低 CRPS 达 75% 以上, 整体预报精度更高。具体到不同流量等级, ERRIS-LSTM 模型高、中、低水流量集合预报的 CRPS 分别降低了 72.6%、75.3% 和 81.3%。此外, 从图中 95% 置信区间的宽度可以看出, ERRIS 模型的不确定性较大, 而 ERRIS-LSTM 模型在覆盖实测径流的同时, 大幅度减小了置信区间宽度, 不确定性更小, 可靠性更高, 更适用于业务预报。

椒江流域沙段站日径流序列变异性大、相关性不显著 (图 2(c)), 由图 4(b) 可知, ERRIS 和 ERRIS-LSTM 模型的修正效果不及奴下站明显, 但校正模型对整个径流序列的高估误差均有显著改善。原始预报整体径流的 NSE 为 0.92、RMSE 为 $37 \text{ m}^3/\text{s}$ 、Pbias 为 17.3%, 经 ERRIS 模型校正后, NSE 略微下降了 4.3%、RMSE 降低了 5.4%、Pbias 降低了 90.2%。ERRIS 模型对沙段站径流的校正效果主要集中在中水和低水流量, 其中低水流量统计指标的改善程度均超过了 40%, 特别是 NSE、Pbias 分别提升和降低了 70.7% 和 57.6%, 而高水流量的统计指标经 ERRIS 模型校正后显示出一定

的退步。ERRIS-LSTM 模型的校正效果比 ERRIS 模型有所提高, 大多数统计指标均呈现不同程度的改善, 其中整个流量序列的 RMSE 和 MAE 分别比 ERRIS 模型的预报降低了 5.7% 和 7.1%, NSE 和 α 指数则分别提升了 1.1% 和 2.4%。在不同流量等级上, ERRIS-LSTM 模型对高水和中水流量的校正效果与 ERRIS 模型相当, 但对于低水流量, ERRIS-LSTM 模型能够提供更进一步的改善, 改善程度超过 20%, 特别是指标 Pbias 和 CRPS 比 ERRIS 模型分别降低了 58.3% 和 32.6%。ERRIS 和 ERRIS-LSTM 模型均表现出对高水流量改善不足的问题, 这可能是该流域高水流量样本不充分导致的, 同时椒江流域高水流量的异常高误差也使得校正效果降低。

为了进一步验证 ERRIS-LSTM 模型的优越性, 表 1 和表 2 中还同时给出了 LSTM 模型对径流校正的统计结果。对于奴下站, LSTM 模型的表现介于 ERRIS 和 ERRIS-LSTM 模型之间, 其所有统计指标均比 ERRIS-LSTM 模型稍逊一筹。特别是对低水流量的校正, 相比于 LSTM 模型, ERRIS-LSTM 模型的各项统计指标改善超过了 25%, 其 CRPS 比 LSTM 模型的 MAE 低近 60%, 此外, ERRIS-LSTM 模型还可以提供额外的不确定信息。在椒江流域, 3 个模型的表现则各有千秋, LSTM 模型最大的优势体现在指标 NSE 上, 但其对低水流量的偏差纠正不及 ERRIS 和 ERRIS-LSTM 模型。

图 5 和图 6 分别为 ERRIS 和 ERRIS-LSTM 模型随机生成的集成员整个流量序列和不同流量等级统计指标的小提琴图, 图中虚线从下到上分别是 25%、50% 和 75% 分位点, 所示结果为 5000 个集成员的统计指标分布, 计算结果的不确定性越小, 表现为图中小提琴分布越集中。

从图 5 可以看出, 对于雅鲁藏布江流域奴下站 (图 5(a) ~ (d)), ERRIS-LSTM 模型在所有确定性指标上比 ERRIS 模型拥有绝对的优势, 并且其指标的分布更集中, 意味着 ERRIS-LSTM 模型在提高预报精度的同时, 能够有效降低预报的不确定性, 更有利于业务化径流预报。ERRIS 模型集合预报的 MAE、RMSE、NSE 和 Pbias 基本集中在 $570 \text{ m}^3/\text{s}$ 、 $910 \text{ m}^3/\text{s}$ 、0.77 和 6.8% 附近, 分布较为集中; ERRIS-LSTM 模型的 MAE、RMSE、NSE 和 Pbias 则集中在 $90 \text{ m}^3/\text{s}$ 、 $120 \text{ m}^3/\text{s}$ 、0.99 和 2% 附近, 分布更为集中。可见在数据相关性较好的流域, ERRIS-LSTM 模型能够从更长序列的相关性中获取更准确的校正量, 从而实现精度更高、不确定性更小、可靠度更高的预报。与之不同, 椒江流域沙段站的指标分布则呈现

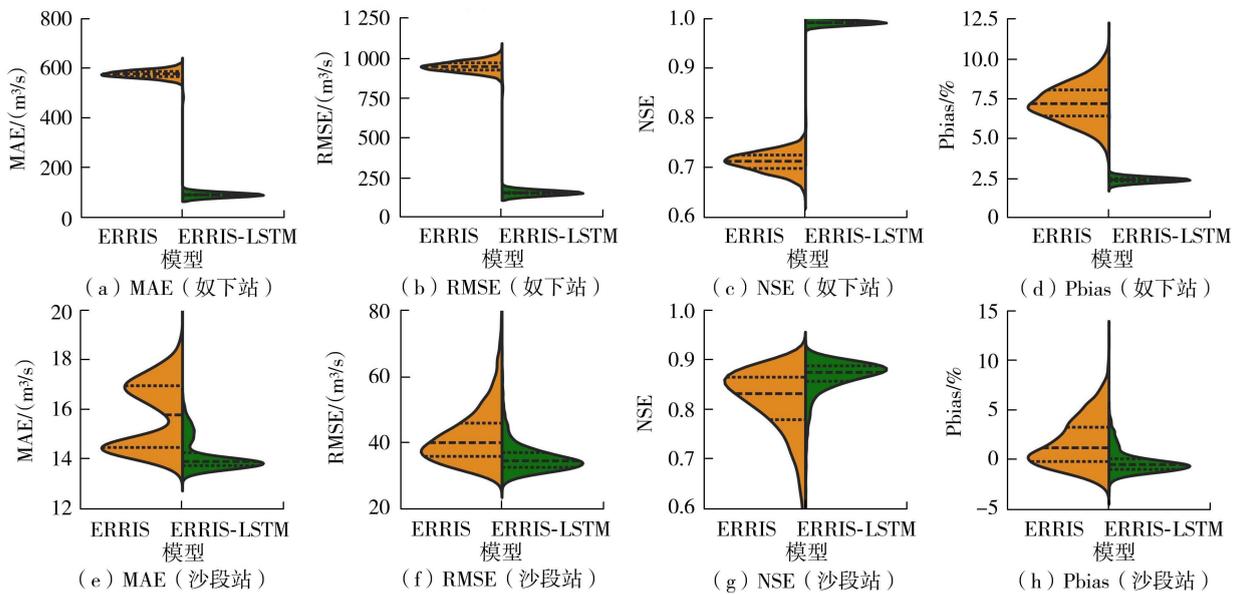


图5 随机生成的集成员整个流量序列统计指标的小提琴图

Fig. 5 Violin plots of statistical indexes of entire streamflow series for randomly generated ensemble members

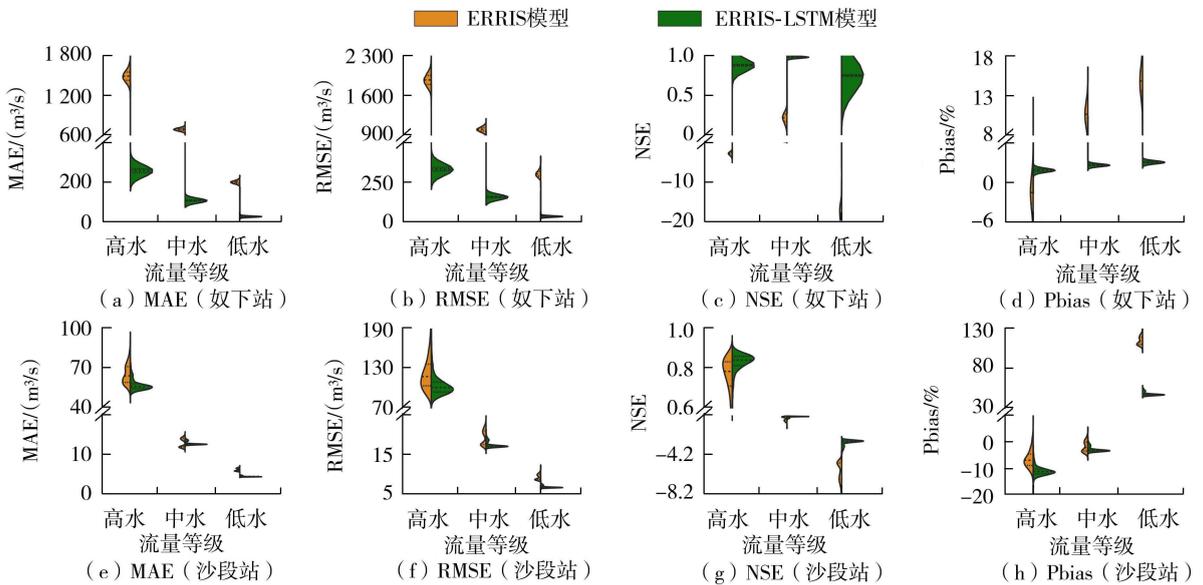


图6 随机生成的集成员在不同流量等级统计指标的小提琴图

Fig. 6 Violin plots of statistical indexes of different streamflow levels for randomly generated ensemble members

出较高的不确定性,这是因为沙段站径流序列的序贯相关性较差,校正模型只能通过拓宽预报分布以提高捕捉到实际预报的可能性(图5(e)~(h))。图5(e)中MAE呈现出较为明显的双峰特征,ERRIS模型约25%集成员预报结果的MAE和Pbias大于ERRIS-LSTM模型所有集成员预报结果的相应指标。在其余统计指标上,ERRIS-LSTM模型约75%集成员可以得到与ERRIS模型前25%集成员相当的预报结果。

不同流量等级的统计指标分布(图6)与整个流量序列的结果类似,总体来说,ERRIS-LSTM模型的统计指标在各流量等级中均更为集中,不确定性更

小。对于雅鲁藏布江流域奴下站,ERRIS-LSTM模型比ERRIS模型具有绝对的优势,前者各流量等级的统计指标均远远领先于后者。对于椒江流域沙段站,ERRIS和ERRIS-LSTM模型的中水和低水流量统计指标均有较为明显的双峰分布。对于高水流量,ERRIS-LSTM模型超过50%集成员可以得到与ERRIS模型前25%集成员相当的校正效果,而对于低水流量,ERRIS-LSTM模型几乎所有的集成员均可以提供比ERRIS模型更好的校正结果,这与集合平均的结果较为一致。

根据模型最优参数(表3)可以进一步分析模型性能。在模型参数中标准差是尺度参数,其值决定

表 3 模型最优参数

Table 3 Optimal parameters for models

站点	模型	σ_1	c	d	σ_2	ρ	σ_3	w	$\sigma_{4,1}$	$\sigma_{4,2}$
奴下站	ERRIS	1.4	-0.76	0.77	1.14	0.99	1.10	0.96	1.10	1.10
	ERRIS-LSTM	1.4	-0.76	0.77	1.14		0.17	0.98	0.13	1.00
沙段站	ERRIS	2.7	1.29	1.10	2.70	0.47	1.23	0.51	0.85	1.51
	ERRIS-LSTM	2.7	1.29	1.10	2.70		0.47	0.79	0.35	1.06

了概率分布的扩散程度。从表 3 可以看出,校正模型不同阶段标准差逐渐减小,意味着校正模型预报不确定性逐步降低。奴下站 ERRIS 模型混合高斯分布的标准差取值几乎一致(相差在 0.001 左右),相当于单一高斯分布,因此图 5(a)~(d)中整个流量序列的集合径流统计指标呈现较为典型的钟形分布;而 ERRIS-LSTM 模型混合高斯分布的标准差相差较大($\sigma_{4,1}=0.13$ 和 $\sigma_{4,2}=1$),标准差为 $\sigma_{4,1}$ 的高斯分布权重较大($w=0.98$),因此图中没有出现明显的第二个钟形分布,但有明显的拖长尾部。由于 ERRIS 模型的 $\sigma_{4,1}$ 比 ERRIS-LSTM 模型的 $\sigma_{4,1}$ 大很多,因此在图 4(a)中其 95%的置信区间分布更广。沙段站 ERRIS 模型中水和低水流量统计指标呈现双峰分布特征是由 $\sigma_{4,1}$ 和 $\sigma_{4,2}$ 相差较大造成的,并且 ERRIS 模型的 $w=0.51$,说明两个尺度参数相差较大的高斯分布权重相当,导致图 6(e)~(h)中 ERRIS 模型评估指标的两个钟形分布独立且显著,而虽然 ERRIS-LSTM 模型两个高斯分布的标准差相差较大,但标准差为 $\sigma_{4,1}$ 的高斯分布权重较大($w=0.79$),导致标准差为 $\sigma_{4,2}$ 的钟形分布不明显。此外,分析参数 ρ 可以发现,雅鲁藏布江流域前 1 天的预报误差信息对实时校正有着重要影响($\rho=0.99$),而椒江流域该参数取值则小很多($\rho=0.47$),说明其径流变异性较大,前期预报误差和实时校正结果相关性不高。

3 结论

a. 以雅鲁藏布江和椒江流域预见期为 1 d 的日径流预报为例,定量评估了 ERRIS-LSTM 模型对整个流量序列及不同流量等级的校正水平。经 ERRIS-LSTM 校正后,雅鲁藏布江径流预报的 NSE 提升 14.5%,达到了 0.995, RMSE 相比于 ERRIS 的校正结果进一步降低了 67.7%,高水流量的 NSE 指标进一步提升了 52.5%。ERRIS-LSTM 模型对椒江流域沙段站整个流量序列和低水流量的校正比 ERRIS 模型呈现出更高的校正水平,低水流量的统计指标改善程度超过 20%, Pbias 和 CRPS 相比 ERRIS 分别降低了 58.3%和 32.6%。

b. ERRIS-LSTM 模型实时校正方法简单,运算

效率高,综合了 LSTM 模型对数据的深度挖掘能力和 ERRIS 模型对不确定性的定量表达,能够为解决传统实时校正技术无法考虑预报的不确定性和 AR 模型对高水流量的过度校正问题提供新的研究思路,更有利于业务预报预警和防洪决策。由于 LSTM 模型是纯数据驱动模型,对样本数量要求较高,因此,ERRIS-LSTM 模型在数据充分的流域表现更好。

参考文献:

- [1] 田焯,谭伟丽,王国庆,等. LSTM 变体模型在径流预测中的性能及其可解释性[J]. 水资源保护, 2023, 39(3):188-194. (TIAN Ye, TAN Weili, WANG Guoqing, et al. Performance of variant LSTM models in runoff prediction and their interpretability[J]. Water Resources Protection, 2023, 39(3):188-194. (in Chinese))
- [2] 黄一昕,王钦钊,梁忠民,等. 洪水预报实时校正技术研究进展[J]. 南水北调与水利科技(中英文), 2021, 19(1):12-35. (HUANG Yixin, WANG Qinzhaoh, LIANG Zhongmin, et al. Research advances on real-time correction methods for flood forecasting[J]. South-to-North Water Transfers and Water Science & Technology, 2021, 19(1):12-35. (in Chinese))
- [3] 陈鑫,刘艳丽,张建云,等. 数据挖掘技术在洪水预报实时校正中的应用[J]. 水力发电学报, 2022, 41(8):54-62. (CHEN Xin, LIU Yanli, ZHANG Jianyun, et al. Application of data mining techniques in real-time correction of flood forecasts[J]. Journal of Hydroelectric Engineering, 2022, 41(8):54-62. (in Chinese))
- [4] 孙文字,姚成,刘志雨,等. 秦淮河水文水动力模型及实时校正[J]. 河海大学学报(自然科学版), 2022, 50(4):26-33. (SUN Wenyu, YAO Cheng, LIU Zhiyu, et al. Hydrological and hydrodynamic model of Qinhuai River and real-time correction[J]. Journal of Hohai University (Natural Sciences), 2022, 50(4):26-33. (in Chinese))
- [5] 孙逸群,包为民,江鹏,等. 基于无迹卡尔曼滤波的新安江模型实时校正方法[J]. 湖泊科学, 2018, 30(2):488-496. (SUN Yiqun, BAO Weimin, JIANG Peng, et al. Real-time updating of XAJ model by using unscented Kalman filter[J]. Journal of Lake Sciences, 2018, 30(2):488-496. (in Chinese))
- [6] 司伟,包为民,瞿思敏. 洪水预报产流误差的动态系统

- 响应曲线修正方法[J]. 水科学进展,2013,24(4):497-503. (SI Wei, BAO Weimin, QU Simin. Runoff error correction in real-time flood forecasting based on dynamic system response curve[J]. Advances in Water Science, 2013,24(4):497-503. (in Chinese))
- [7] 焦伟杰,龙海峰. 基于自回归模型的分布式水文模型预报校正[J]. 水资源与水工程学报,2015,26(2):103-108. (JIAO Weijie, LONG Haifeng. Forecast and correction of distributed hydrological model based on autoregression model[J]. Journal of Water Resources and Water Engineering,2015,26(2):103-108. (in Chinese))
- [8] 张旭旻,瞿思敏,李倩,等. 基于协整理论的淮河流域上游洪水预报实时校正方法[J]. 水资源保护,2022,38(6):88-95. (ZHANG Xumin, QU Simin, LI Qian, et al. Real-time correction method of flood forecasting for the upper Huaihe River Basin based on cointegration theory[J]. Water Resources Protection,2022,38(6):88-95. (in Chinese))
- [9] LI M, WANG Q J, BENNETT J C, et al. A strategy to overcome adverse effects of autoregressive updating of streamflow forecasts [J]. Hydrology and Earth System Sciences,2015,19(1):1-15.
- [10] LI M, WANG Q J, BENNETT J C, et al. Error reduction and representation in stages (ERRIS) in hydrological modelling for ensemble streamflow forecasting [J]. Hydrology and Earth System Sciences,2016,20(9):3561-3579.
- [11] BENNETT J C, ROBERTSON D E, WANG Q J, et al. Propagating reliable estimates of hydrological forecast uncertainty to many lead times[J]. Journal of Hydrology, 2021,603:126798.
- [12] LIU L, WANG Q J, XU Y P. Temporally varied error modelling for improving simulations and quantifying uncertainty[J]. Journal of Hydrology,2020,586:124914.
- [13] NANDA T, SAHOO B, CHATTERJEE C. Enhancing real-time streamflow forecasts with wavelet-neural network based error-updating schemes and ECMWF meteorological predictions in variable infiltration capacity model [J]. Journal of Hydrology,2019,575:890-910.
- [14] 蒋志强,王随玲,汤正阳,等. 基于多情景划分的三峡水库入库径流预报校正[J]. 水力发电学报,2022,41(4):47-61. (JIANG Zhiqiang, WANG Suiling, TANG Zhengyang, et al. Correction to predicted inflow of Three Gorges Reservoir based on division of different scenarios [J]. Journal of Hydroelectric Engineering, 2022,41(4):47-61. (in Chinese))
- [15] NEARING G S, KLOTZ D, FRAME J M, et al. Technical note: data assimilation and autoregression for using near-real-time streamflow observations in long short-term memory networks [J]. Hydrology and Earth System Sciences,2022,26(21):5493-5513.
- [16] ZHAO T T G, WANG Q J, BENNETT J C, et al. Quantifying predictive uncertainty of streamflow forecasts based on a Bayesian joint probability model[J]. Journal of Hydrology,2015,528:329-340.
- [17] DUAN Q Y, SOROOSHIAN S, GUPTA V K. Optimal use of the SCE-UA global optimization method for calibrating watershed models[J]. Journal of Hydrology,1994,158(3/4):265-284.
- [18] 石卓,史东华,姚成,等. 基于径流模数的 LSTM 模型在无资料嵌套流域的应用[J]. 河海大学学报(自然科学版),2024,52(3):51-57. (SHI Zhuo, SHI Donghua, YAO Cheng, et al. Application of runoff modulus-based LSTM in ungauged nested watersheds [J]. Journal of Hohai University (Natural Sciences), 2024,52(3):51-57. (in Chinese))
- [19] 苑希民,黄玉啟,田福昌,等. 基于 LSTM-GM 神经网络模型的风暴潮增水预报方法[J]. 水资源保护,2023,39(6):8-15. (YUAN Ximin, HUANG Yuqi, TIAN Fuchang, et al. Research on forecasting method of storm surge based on LSTM-GM neural network model[J]. Water Resources Protection,2023,39(6):8-15. (in Chinese))
- [20] 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))
- [21] 左德鹏,韩煜娜,徐宗学,等. 气候变化对雅鲁藏布江流域植被动态的影响机制[J]. 水资源保护,2022,38(6):1-8. (ZUO Depeng, HAN Yuna, XU Zongxue, et al. Impact mechanism of climate change on vegetation dynamics in the Yarlung Zangbo River Basin [J]. Water Resources Protection,2022,38(6):1-8. (in Chinese))
- [22] LIU Li, XU Yueping, PAN Suli, et al. Potential application of hydrological ensemble prediction in forecasting floods and its components over the Yarlung Zangbo River Basin, China [J]. Hydrology and Earth System Sciences,2019,23(8):3335-3352.
- [23] 韦林,段凯,刘效东,等. 基于多源数据与多模型集成的流域人为蒸散发变异评估[J]. 水利学报,2022,53(4):433-444. (WEI Lin, DUAN Kai, LIU Xiaodong, et al. Assessing human-induced evapotranspiration change based on multi-source data and Bayesian model averaging at the basin scale [J]. Journal of Hydraulic Engineering, 2022,53(4):433-444. (in Chinese))
- [24] 吴志勇,白博宇,何海,等. 珠江流域 1981—2020 年水文干旱时空特征分析[J]. 河海大学学报(自然科学版),2023,51(1):1-9. (WU Zhiyong, BAI Boyu, HE Hai, et al. Temporal and spatial characteristics of hydrological drought in the Pearl River Basin from 1981 to 2020 [J]. Journal of Hohai University (Natural

- Sciences), 2023, 51(1): 1-9. (in Chinese))
- [25] ZHAO Renjun. The Xinanjiang model applied in China [J]. Journal of Hydrology, 1992, 135(1/2/3/4): 371-381.
- [26] 陆旻皎. 新安江模型研究的回顾和展望[J]. 水利学报, 2021, 52(4): 432-441. (LU Minjiao. Recent and future studies of the Xinanjiang model[J]. Journal of Hydraulic Engineering, 2021, 52(4): 432-441. (in Chinese))
- [27] 吴勇拓, 李致家, 戚振亚, 等. 基于水文模型的缺资料流域设计洪水计算[J]. 河海大学学报(自然科学版), 2023, 51(6): 1-8. (WU Yongtuo, LI Zhijia, QI Zhenya, et al. Design flood calculation of watershed with lack of data based on hydrological model [J]. Journal of Hohai University (Natural Sciences), 2023, 51(6): 1-8. (in Chinese))
- [28] ZHAO Pengcheng, WANG Qianjun, WU Wenyan, et al. Spatial-mode-based calibration (SMoC) of forecast precipitation fields with spatially correlated structures: an extended evaluation and comparison with gridcell-by-gridcell postprocessing [J]. Journal of Hydrometeorology, 2023, 24(9): 1509-1525.
- [29] 董磊华, 熊立华, 万民. 基于贝叶斯模型加权平均方法的水文模型不确定性分析[J]. 水利学报, 2011, 42(9): 1065-1074. (DONG Leihua, XIONG Lihua, WAN Min. Uncertainty analysis of hydrological modeling using the Bayesian model averaging method [J]. Journal of Hydraulic Engineering, 2011, 42(9): 1065-1074. (in Chinese))

(收稿日期: 2024-01-02 编辑: 施业)

(上接第 112 页)

- [23] ALMANZI K Y, SHARIFF A R M, KALANTAR B, et al. Performance evaluation of hospital site suitability using multilayer perceptron (MLP) and analytical hierarchy process (AHP) models in malacca, malaysia [J]. Sustainability, 2022, 14(7): 3731.
- [24] ZENG Z P, LAN J Y, HAMIDI A R, et al. Integrating Internet media into urban flooding susceptibility assessment: a case study in China [J]. Cities, 2020, 101: 102697.
- [25] NANEHKARAN Y A, ZHU L C, CHEN J D, et al. Application of artificial neural networks and geographic information system to provide hazard susceptibility maps for rockfall failures [J]. Environmental Earth Sciences, 2022, 81(19): 475.
- [26] HU Caihong, ZHANG Xueli, LI Changqing, et al. Real-time flood classification forecasting based on k-means++ clustering and neural network [J]. Water Resources Management, 2022, 36(1): 103-117.
- [27] RAZAVI-TERMEH S V, SADEGHI-NIARAKI A, SEO M, et al. Application of genetic algorithm in optimization parallel ensemble-based machine learning algorithms to flood susceptibility mapping using radar satellite imagery [J]. Science of the Total Environment, 2023, 873: 162285.
- [28] RAZAVI-TERMEH S V, SADEGHI-NIARAKI A, CHOI S M. A new approach based on biology-inspired metaheuristic algorithms in combination with random forest to enhance the flood susceptibility mapping [J]. Journal of Environmental Management, 2023, 345: 118790.
- [29] PARYANI S, BORDBAR M, JUN C, et al. Hybrid-based approaches for the flood susceptibility prediction of Kermanshah Province, Iran [J]. Natural Hazards, 2023, 116(1): 837-868.
- [30] 黄钦, 谭翠, 杨波. 基于 XGBoost 算法的亚热带地区生态旅游适宜性评价方法研究 [J]. 地球信息科学学报, 2024, 26(2): 303-317. (HUANG Qin, TAN Cui, YANG Bo. Research on the evaluation method of ecotourism suitability in subtropical regions based on XGBoost algorithm [J]. Journal of Geo-Information Science, 2024, 26(2): 303-317. (in Chinese))
- [31] LIU Jun, XIONG Junnan, CHEN Yangbo, et al. A new avenue to improve the performance of integrated modeling for flash flood susceptibility assessment: applying cluster algorithms [J]. Ecological Indicators, 2023, 146: 109785.
- [32] 徐奎, 潘昊, 宾零陵, 等. 基于强化学习的海南岛山洪灾害易发性评估 [J]. 水资源保护, 2023, 39(2): 95-100. (XU Kui, PAN Hao, BIN Lingling, et al. Evaluation of mountain torrent disaster vulnerability in Hainan Island based on reinforcement learning [J]. Water Resources Protection, 2023, 39(2): 95-100. (in Chinese))
- [33] TIEN BUI D, HOANG N D, MARTÍNEZ-ÁLVAREZ F, et al. A novel deep learning neural network approach for predicting flash flood susceptibility: a case study at a high frequency tropical storm area [J]. Science of the Total Environment, 2020, 701: 134413.
- [34] ÖZAY B, ORHAN O. Flood susceptibility mapping by best-worst and logistic regression methods in Mersin, Turkey [J]. Environmental Science and Pollution Research, 2023, 30(15): 45151-45170.
- [35] 赵二峰, 李章寅, 袁冬阳. 基于双阶段注意力机制的大坝变形深度学习预测模型 [J]. 河海大学学报(自然科学版), 2023, 51(6): 44-52. (ZHAO Erfeng, LI Zhangyin, YUAN Dongyang. Deep learning model for deformation prediction of dam based on dual-stage attention mechanism [J]. Journal of Hohai University (Natural Sciences), 2023, 51(6): 44-52. (in Chinese)).

(收稿日期: 2024-04-11 编辑: 王芳)