



基于GR4J与LSTM耦合的清江流域径流模拟对比分析

向怡衡 彭涛 郭晓薇 周悦 曾鹏 殷志远 祁海霞 刘柯

Comparative analysis of runoff simulation in the Qingjiang River basin based on the coupling of GR4J and LSTM

XIANG Yiheng, PENG Tao, GUO Xiaowei, ZHOU Yue, ZENG Peng, YIN Zhiyuan, QI Haixia, LIU Ke

在线阅读 View online: <https://doi.org/10.12406/byzh.2026-006>

您可能感兴趣的其他文章 Articles you may be interested in

WRF-Hydro模式结合不同降水产品模拟清江流域径流的效果分析

Effect analysis of WRF-Hydro model combined with different precipitation products to simulate runoff in the Qingjiang River Basin

暴雨灾害. 2023, 42(4): 395–405 <https://doi.org/10.12406/byzh.2022-205>

基于小时分辨率的降水过程辨识方法研究

Research on precipitation process identification method based on hourly resolution

暴雨灾害. 2021, 40(1): 12–18 <https://doi.org/10.3969/j.issn.1004-9045.2021.01.002>

基于深度学习模型ViT-Bi-LSTM的监控相机在夜间强降雨监测的应用初探

Preliminary exploration of nighttime heavy rainfall detection using surveillance cameras based on deep learning model ViT-Bi-LSTM

暴雨灾害. 2025, 44(5): 592–601 <https://doi.org/10.12406/byzh.2025-089>

CMIP6 HighResMIP高分辨率气候模式对青藏高原降水模拟的评估

Evaluation of CMIP6 HighResMIP models in Simulating Precipitation over Tibetan Plateau

暴雨灾害. 2022, 41(2): 215–223 <https://doi.org/10.3969/j.issn.1004-9045.2022.02.012>

区域海气耦合模式对黄渤海周边近地层温湿预报的性能研究

Study on the performance of the regional air-sea coupled model on forecast accuracy of near-surface temperature and humidity in the surrounding areas of the Yellow Sea and Bohai Sea

暴雨灾害. 2024, 43(1): 63–72 <https://doi.org/10.12406/byzh.2023-051>

未来RCPs情景下淮河流域夏玉米卡脖子旱风险预估

Simulative projection of future choking drought disaster risk of summer maize in the Huaihe River basin under RCPs scenarios

暴雨灾害. 2021, 40(2): 201–207 <https://doi.org/10.3969/j.issn.1004-9045.2021.02.012>



关注微信公众号，获得更多资讯信息

向怡衡,彭涛,郭晓薇,等.2026.基于 GR4J 与 LSTM 耦合的清江流域径流模拟对比分析[J].暴雨灾害,45(4):598–608. XIANG Yiheng, PENG Tao, GUO Xiaowei, et al. 2026. Comparative analysis of runoff simulation in the Qingjiang River basin based on the coupling of GR4J and LSTM [J]. *Torrential Rain and Disasters*, 45(4):598–608 (in Chinese). doi:10.12406/byzh.2026-006

基于 GR4J 与 LSTM 耦合的清江流域径流模拟对比分析

向怡衡¹, 彭涛^{1, 2}, 郭晓薇³, 周悦¹, 曾鹏³,
殷志远¹, 祁海霞¹, 刘柯¹

(1. 中国气象局武汉暴雨研究所 全国暴雨研究中心/中国气象局流域强降水重点开放实验室/暴雨监测预警湖北省重点实验室, 武汉 430205; 2. 三峡国家气候观象台, 宜昌 443099; 3. 广西壮族自治区气象灾害防御技术中心, 南宁 530022)

摘要: 为评估传统水文模型与数据驱动模型在山区流域中的径流模拟性能, 本文以清江流域为研究区域, 基于 2014—2023 年逐日降水与径流资料, 对传统水文模型 (GR4J) 与长短时记忆网络模型 (LSTM) 的性能进行比较; 在此基础上构建两类融合物理机制与数据驱动的混合模型 (松耦合模型 Hybrid1 将 GR4J 模拟径流作为 LSTM 输入特征, 属于单向信息融合; 紧耦合模型 Hybrid2 在 LSTM 输出径流的同时, 进一步生成 GR4J 模型参数, 并将其反馈至 GR4J 模型, 形成“LSTM-参数-GR4J”的闭环交互结构), 并分析混合建模策略对山区径流模拟性能的提升效果。结果表明: 在观测资料受限条件下, 采用单一年份资料进行模型率定与训练, LSTM 模型整体表现优于 GR4J; 采用丰枯年组合资料 (2017 年丰水年与 2019 年枯水年) 进行模型率定与训练, GR4J 与 LSTM 在验证期内的纳什效率系数 (NSE) 分别为 0.742 和 0.790, Kling-Gupta 效率系数 (KGE) 分别为 0.543 和 0.771, 显著优于采用单一年份资料的结果, 且模拟性能接近于使用较长时间序列资料 (2014—2019 年) 的水平。混合建模策略进一步提升了径流模拟精度, 其中 Hybrid2 整体优于 Hybrid1。Hybrid2 在验证期 (2020—2023 年) 的 NSE 和 KGE 分别为 0.795 和 0.771, 较 GR4J 模型分别提高 10.7% 和 52.7%, 较 LSTM 模型分别提高 3.7% 和 14.7%。此外, 各模型径流模拟性能呈现明显的季节性差异, 在夏季及汛期表现较好, 其中 Hybrid2 在汛期的 NSE 和 KGE 均超过 0.8, 具有良好的洪水期径流模拟能力。因此, 采用单一年份、丰枯年组合水文资料训练模型具有可行性, Hybrid2 能有效提升山区径流模拟精度, 可为山区流域径流模拟预报提供参考。

关键词: GR4J; LSTM; 物理机制与数据驱动耦合; 山区径流模拟; 评估

中图法分类号: P49

文献标志码: A

DOI: 10.12406/byzh.2026-006

Comparative analysis of runoff simulation in the Qingjiang River basin based on the coupling of GR4J and LSTM

XIANG Yiheng¹, PENG Tao^{1, 2}, GUO Xiaowei³, ZHOU Yue¹, ZENG Peng³,
YIN Zhiyuan¹, QI Haixia¹, LIU Ke¹

(1. *National Rainstorm Research Center/CMA Basin Heavy Rainfall Key Laboratory/ Hubei Key Laboratory for Heavy Rain Monitoring and Warning Research, Institute of Heavy Rain, CMA, Wuhan 430205*; 2. *Three Gorges National Climatological Observatory, Yichang 443099*; 3. *Guangxi Zhuang Autonomous Region Meteorological Disaster Prevention and Mitigation Technology Center, Nanning 530022*)

Abstract: To evaluate the runoff simulation performance of traditional hydrological and data-driven models in mountainous basins, this study takes the Qingjiang River basin as the research area and compares the performance of the conceptual hydrological model (GR4J) and the Long Short-Term Memory network (LSTM) based on the daily precipitation and runoff data from 2014 to 2023. On this basis, two hybrid models integrating physical mechanisms and data-driven approaches are developed: a loosely coupled model (Hybrid1) and a tightly coupled model (Hybrid2). In Hybrid1, the runoff simulated by GR4J is used as an input feature for LSTM, representing a one-way information fusion strategy. By contrast, Hybrid2 not only outputs runoff through LSTM but also generates GR4J model parameters,

收稿日期: 2026-01-08; 定稿日期: 2026-06-11

资助项目: 国家自然科学基金项目 (U2340201); 广西重点研发计划项目 (AB25069132); 全国暴雨研究开放基金项目 (BYKJ2025Q34, BYKJ2025M27, BYKJ2024Z11); 中国气象局创新发展专项 (CXFZ2026J133)

第一作者: 向怡衡, 主要从事水文气象应用研究。E-mail: yiheng20201022@163.com

通信作者: 彭涛, 主要从事水文气象应用研究。E-mail: pt_mail@sohu.com

© Editorial Office of *Torrential Rain and Disasters*. OA under CC BY-NC-ND 4.0

which are subsequently fed back into GR4J, thereby forming a closed-loop interaction structure of "LSTM-parameters-GR4J". The improvements in simulation performance achieved by hybrid modeling strategies are further assessed. Results show that, under limited data conditions, when models are calibrated using single-year data, LSTM generally outperforms GR4J. When a combination of wet and dry years (2017 and 2019) is used for calibration, GR4J and LSTM achieve Nash-Sutcliffe efficiency (NSE) values of 0.742 and 0.790, and Kling-Gupta efficiency (KGE) values of 0.543 and 0.771, respectively, during the validation period. These results are significantly better than those obtained using single-year data and are comparable to those achieved with longer time series data (2014-2019). The hybrid modeling strategy further improves runoff simulation accuracy, with Hybrid2 outperforming Hybrid1 overall. In particular, Hybrid2 attains NSE and KGE values of 0.795 and 0.771, respectively, during the validation period (2020-2023), representing improvements of 10.7% and 52.7% over GR4J, and 3.7% and 14.7% over LSTM. In addition, model performance exhibits clear seasonal variability, with all models achieving optimal accuracy in summer and the flood season. Hybrid2 achieves NSE and KGE values exceeding 0.8 in the flood season, demonstrating strong capability for flood-period runoff simulation. Overall, the results demonstrate the feasibility of training models using single-year and wet-dry year combination data, and confirm that Hybrid2 effectively enhances runoff simulation accuracy in mountainous basins, providing a valuable reference for runoff simulation and flood forecasting in similar regions.

Key words: GR4J; LSTM; coupling of physical mechanisms and data-driven approaches; runoff simulation in mountainous basins; evaluation

引言

在全球变暖与人类活动加剧的背景下,极端暴雨及其诱发的洪涝灾害频发,严重威胁人民生命财产安全与社会经济可持续发展,已成为我国最严重的自然灾害之一(包红军等, 2020; 张国涛等, 2025; 高顺年, 2026)。我国山区约占全国国土面积的 2/3,流域分布密集,山洪灾害致死人数占洪涝灾害总死亡人数的 61%~80%(涂勇等, 2020),已成为当前防灾减灾工作的重点与难点(郭良等, 2018)。在此背景下,提升降雨径流模拟能力不仅是水文学研究的核心问题,也对水资源优化管理与防洪减灾决策具有重要意义(Noori and Kalin, 2016; 甘衍军等, 2017)。然而,受复杂地形制约的观测困难、降雨时空高度变异性以及水文过程的强非线性等影响,山区流域径流模拟与预测的难度显著增加(Gao et al., 2020; 敖天其等, 2025)。因此,提升山区降雨径流模拟的精度与可靠性,对加强水资源科学管理、增强洪水预警能力具有重要的科学价值与现实意义(庞轶舒等, 2022; 夏军和石卫, 2016)。

目前,降雨径流模型主要可分为基于物理机制的水文模型与数据驱动模型两大类(Devia et al., 2015)。传统水文模型虽具有明确的物理基础,但在处理日益增长的多源水文大数据及模拟复杂系统时面临挑战(雍斌等, 2023)。数据驱动模型则基于海量观测数据,通过统计学习直接挖掘降雨-径流响应关系的内在规律(刘攀等, 2021)。由于其较低的计算复杂度和较高的模型精度,数据驱动模型在径流预测中得到了广泛应用(Yaseen et al., 2015),代表性模型包括人工神经网络(ANN)(Nourani, 2017)、支持向量机(SVM)(Lin et al., 2013)和模糊逻辑方法(Wang and Altunkaynak, 2012)。其中,长短时记忆神经网络(LSTM)作为

循环神经网络(RNN)的改进架构(Hochreiter and Schmidhuber, 1997),因其卓越的时间序列建模能力受到水文学界广泛关注,被证明是一种高效的降雨径流预测工具(Xiang et al., 2020; 黄天文等, 2024)。然而,此类模型通常采用“黑箱”建模方式,主要依赖变量间的统计关联,难以精确刻画具有强非线性和时变特性的物理水文过程。

值得注意的是,无论是传统水文模型还是数据驱动模型,其模拟性能在很大程度上均依赖于参数率定或模型训练所采用的观测数据条件。传统水文模型需通过率定优化参数(李德龙等, 2013),而数据驱动模型通常被认为对训练数据量要求较高(Gauch et al., 2021),因此现有研究多采用长期序列进行建模(胡乐怡等, 2024)。然而,在观测资料短缺的山区流域,长时序数据往往难以获取。已有研究表明,具有代表性的短期数据同样具备支撑模型良好表现的潜力(Sun et al., 2017)。例如,在水文模型方面, Sorooshian 等(1983)建议至少需要一个完整水文年数据进行率定; Perrin 等(2007)发现湿润流域中从包含干湿条件的长期数据中选取约 350 d 即可实现稳定参数估计。在数据驱动模型方面, Yu 等(2023)发现在干旱流域 LSTM 模型可基于代表性的一年数据实现成功校准; Lu 等(2021)在资料稀缺流域中证实,若预测期与训练期水文变异性相似,基于短期数据训练的 LSTM 仍可获得较高精度。尽管机器学习方法在水文领域的应用不断拓展,但针对不同观测数据条件下水文模型及数据驱动模型的适用性研究仍然不足。

近年来,随着监测技术发展和计算能力提升,耦合物理机制与机器学习的混合建模方法逐渐成为研究热点(李国英, 2022; 许钦等, 2025)。Karpatne 等

(2017) 提出将物理约束嵌入机器学习模型,通过构建可解释的物理模块以提升模型的泛化能力。目前,主流耦合方式多采用将水文模型输出的径流、土壤湿度等状态变量作为特征输入机器学习模型 (Okkan et al., 2021; 邓超等, 2025), 但该类方法通常表现为物理模型向机器学习模型的单向信息传递, 缺乏有效的反馈机制 (Cho and Kim, 2022)。Kraft 等 (2022) 提出了一种水文模型与 LSTM 深度交互的混合建模框架, 其中水文模型向 LSTM 提供气象强迫、静态属性及状态变量信息, 而 LSTM 则对水文模型的关键参数进行动态修正。然而, 针对山区流域不同耦合模型模拟精度比较的研究仍相对匮乏。

综上所述, 本文拟以清江流域为研究区域, 基于 2014—2023 年逐日降水与径流资料, 分别构建 GR4J 水文模型、机器学习模型以及两种融合物理机制与机器学习的混合模型 (依据交互机制差异, 将其区分为松耦合模型 Hybrid1 与紧耦合模型 Hybrid2。在此基础上, 开展以下研究: (1) 比较不同观测数据条件下 GR4J 水文模型与机器学习模型在山区流域中的径流模拟性能; (2) 采用长期观测数据率定模型时, 评估松耦合 Hybrid1 与紧耦合 Hybrid2 混合模型对径流模拟性能的提升效果; (3) 分析不同时间尺度与季节条件下各类模型的模拟特征。研究成果可为山区流域尤其是资料短缺地区的水文模拟提供方法参考。

1 研究区域和数据

清江流域 (108.58°—111.58°E, 29.55°—30.83°N) 位于鄂西武陵山区, 清江发源于利川市, 其地势由西向东逐渐降低, 并于宜都市汇入长江 (图 1)。流域气候属亚热带季风气候, 年平均气温约 14.1 °C, 多年平均降水量约 1 400 mm。流域面积约 1.67×10⁴ km², 其中山区面积占比超过 80%, 属典型山溪性河流特征区, 洪水过程以涨落迅速、峰值集中的特点为主。作为鄂西暴雨高发区域, 清江流域年内最大洪峰多出现在 6—7 月。

本文选取受人类活动干扰较小的水布垭控制断面以上流域作为研究区域。采用资料包括研究区内 175 个气象站 (其中包含 5 个国家气象站和 170 个区域气象站) 2014—2023 年逐日降水、气温及潜在蒸散发观测数据, 由中国气象局提供, 采用泰森多边形方法计算面雨量; 水布垭水文站同期逐日径流观测数据, 由长江水利委员会水文局提供。其中, 2014—2019 年数据用于模型率定, 2020—2023 年数据用于模型验证与评估。




图 1 清江流域高程及水文气象站点分布

Fig. 1 Distribution of elevation and hydro-meteorological stations in the Qingjiang River basin

2 模型简介与研究方法

2.1 GR4J 水文模型

GR4J 是一种结构简洁、参数较少的概念性水文模型, 采用两个线性水库分别模拟产流和汇流过程 (Perrin et al., 2003)。模型输入为逐日降水量与潜在蒸散发, 通过土壤蓄水层进行产流计算, 并进一步将总径流划分为快速流 (约 90%) 与慢速流 (约 10%), 分别通过单位线 UH1 和 UH2 进行汇流演算。GR4J 仅包含 4 个需率定的参数 (表 1) 所示, 各参数物理意义明确, 分别控制产流、土壤蓄水、地下水交换及汇流过程。

表 1 GR4J 模型参数

Table 1 Parameters of the GR4J model

参数	含义	取值范围
X1	最大土壤水储蓄水容量/mm	1~350
X2	地下水交换系数	-10~10
X3	前一日最大产流容量/mm	1~400
X4	单位线时间基数/d	1~10

2.2 长短时记忆模型 (LSTM)

长短时记忆网络 (Long Short-Term Memory, LSTM) 是一种适用于序列建模的循环神经网络 (RNN) 结构 (Hochreiter and Schmidhuber, 1997)。与传统 RNN 相比, LSTM 通过引入门控机制, 有效克服了长期依赖学习中的梯度消失或爆炸问题。其基本单元由遗忘门、输入门和输出门组成, 可通过以下公式 (Hochreiter and Schmidhuber, 1997) 描述前向传播过程

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t^\circ \tanh(C_t) \quad (6)$$

式中, x_t 表示 t 时刻的输入向量; f_t 、 i_t 、 o_t 分别代表遗忘门、输入门与输出门的激活向量; h_t 为隐状态向量, 即当前时刻的输出; $\tilde{C}_t$ 为候选细胞状态, C_t 为更新后的细胞状态; W 和 b 分别为权重矩阵与偏置项, 通过反向传播算法在训练中迭代优化。

本文中 LSTM 的训练依托其 MATLAB 2018b Deep Learning Toolbox 完成。网络采用单隐藏层结构, 含 20 个神经元, 使用 Adam 优化器进行训练, 以均方误差 (MSE) 作为损失函数, 批量大小为 10。输入序列长度被设定为 60, 初始学习率设定为 0.001。所有输入特征均进行 0~1 范围标准化, 且在模型前向计算前将负值置零。

2.3 混合模型的构建

基于 GR4J 水文模型和 LSTM 机器学习模型, 本文构建了两种融合物理机制与数据驱动方法的混合模型, 其核心区别在于模型间的交互方式。两种混合模型的具体建模策略如下:

(1) 将气象要素 (降水、气温、潜在蒸散发等) 及 GR4J 模型输出的径流作为输入特征, 输入 LSTM 模型, 由 LSTM 直接模拟最终径流过程, 称为松耦合模型 Hybrid1。

(2) LSTM 的输入与 Hybrid1 相同, 但其输出同时包括径流模拟值和 GR4J 模型参数。预测得到的参数集随后反馈至 GR4J 模型, 形成“LSTM-参数-GR4J”的闭环交互结构, 称为紧耦合模型 Hybrid2。

2.4 模型训练与参数率定策略

GR4J 模型采用蒙特卡洛方法 (Xiang et al., 2019) 进行参数率定, 随机采样 10 000 组参数, 依据训练期纳什效率系数 (NSE) 筛选最优的 100 组构成参数集合。蒙特卡洛随机采样广泛应用于水文模型的不确定性分析, 通过探索参数空间, 能够有效处理参数间的相互作用与模拟目标的多维性, 避免优化过程陷入局部最优, 从而获得代表性更强的参数集合, 为后续构建混合模型提供稳定可靠的物理模块输出。

对于 LSTM 及混合模型, 以前述 GR4J 最优参数集合对应的模拟结果为输入, 各执行 100 次随机初始化训练, 并保留训练期 $NSE > 0.5$ 的模型组成集合, 用于后续评估。

2.5 评估指标

为评价径流模拟效果, 本文采用 NSE (记作 E_{NS})、Kling-Gupta 效率系数 KGE (记作 E_{KG}) 作为主要评估指标 (Moriasi et al., 2007), 同时通过分析 KGE 的分解项 (相关系数 r , 变幅比 α 与均值比 β),

进一步评估模型在动态一致性、径流波动幅度及水量平衡方面的表现。各指标的计算公式 (Moriasi et al., 2007) 如下

$$E_{NS} = 1 - \frac{\sum_{i=1}^n (Q_{obs,i} - Q_{sim,i})}{\sum_{i=1}^n (Q_{obs,i} - \bar{Q}_{obs})} \quad (7)$$

$$E_{KG} = 1 - \sqrt{(r-1)^2 + (\alpha-1)^2 + (\beta-1)^2} \quad (8)$$

$$r = \frac{\sum_{i=1}^n (Q_{sim,i} - \bar{Q}_{sim})(Q_{obs,i} - \bar{Q}_{obs})}{\sqrt{\sum_{i=1}^n (Q_{sim,i} - \bar{Q}_{sim})^2 \sum_{i=1}^n (Q_{obs,i} - \bar{Q}_{obs})^2}} \quad (9)$$

$$\alpha = \frac{\sigma_{sim}}{\sigma_{obs}} \quad (10)$$

$$\beta = \frac{\mu_{sim}}{\mu_{obs}} \quad (11)$$

其中, $Q_{obs,i}$ 和 $Q_{sim,i}$ 分别表示第 i 日的观测与模拟径流, $\bar{Q}_{obs}$ 为观测序列均值, r 、 α 与 β 分别为相关系数、标准差、均值比。NSE 的取值范围为 $(-\infty, 1]$, 1 为最优值; KGE 的取值范围为 $(-\infty, 1]$, r 的取值范围为 $[-1, 1]$, α 与 β 的取值范围为 $[0, \infty)$, 最优值均为 1。

此外, 本文引入流量历时曲线 (Flow Duration Curve, FDC) 作为对统计评价指标的补充, 用以分析模型在不同流量区间的模拟特征。给定一段长度为 N 的径流时间序列 $\{Q_i\}$, FDC 的构建步骤如下

(1) 将径流数据按流量大小从大到小排序, 得到序列 $Q_{(1)} \geq Q_{(2)} \geq \dots \geq Q_{(N)}$

(2) 对排序后第 i 个径流值, 计算其超越概率 P_i

$$P_i = \frac{i}{N+1} \times 100\% \quad (12)$$

(3) 以超越概率 P_i 为横轴、对应流量 $Q_{(i)}$ 为纵轴, 绘制流量历时曲线。

为更清晰地刻画不同流量区间的分布特征, 本文在绘制流量历时曲线 (FDC) 时采用分轴对数表示方式: 一类 FDC 以超越概率为对数坐标、径流量为线性坐标, 另一类 FDC 以径流量为对数坐标、超越概率为线性坐标。

3 结果与分析

3.1 不同观测数据条件下 GR4J 与 LSTM 模型的性能评估

为探究不同观测数据条件下 GR4J 与 LSTM 模型的径流模拟效果, 首先采用长序列观测数据

(2014—2019 年) 对两种模型进行率定与训练, 并在 2020—2023 年期间对 GR4J 和 LSTM 模型进行验证。表 2 给出两种模型在率定期与验证期内评价指标, 包括 NSE、KGE 及其分解项 r 、 α 与 β , 这些指标基于集合径流中位数计算得到。从中看到, 在长序列数据条件下, LSTM 模型整体表现优于 GR4J 模型, 其 KGE 值显著更高。进一步分析 KGE 的分解项可知, 两种模型的相关系数 r 与变幅比 α 较为接

表 2 清江流域率定期 (2014—2019 年) 和验证期 (2020—2023 年) GR4J 与 LSTM 模型评估指标

Table 2 Evaluation metrics of GR4J and LSTM models for the Qingjiang River basin during the calibration period (2014—2019) and validation period (2020—2023)

不同时期	模型	评估指标				
		NSE	KGE	r	α -KGE	β -KGE
率定期	GR4J	0.764	0.500	0.918	0.803	0.548
	LSTM	0.791	0.669	0.914	0.722	0.842
验证期	GR4J	0.745	0.564	0.890	0.848	0.606
	LSTM	0.795	0.751	0.899	0.800	0.892

近, 而 LSTM 的均值比 β 更接近于 1, 表明其对径流均值水平的刻画更为准确。

在此基础上, 本文进一步探究在观测资料受限条件下, 采用单一年份资料进行模型率定与训练, 两种模型的模拟表现差异。具体而言, 分别选取 2014—2019 年间各单一年份数据对 GR4J 与 LSTM 模型进行率定与训练, 验证期统一设定为 2020—2023 年 (同时评估整体验证期和逐年表现)。每组实验重复 100 次, 形成 100 组模拟径流集合, 并以集合中位数作为最终模拟结果进行性能评估 (图 2)。从图中可见, 在不同训练年份条件下, 两种模型在整体验证期内的模拟性能均存在明显差异。其中, GR4J 的 NSE 范围为 0.594—0.751, 均值为 0.667; LSTM 的 NSE 范围为 0.673—0.783, 均值为 0.737。在 KGE 指标方面, LSTM (范围 0.590—0.816, 均值 0.690) 同样优于 GR4J (范围 0.396—0.527, 均值 0.461), 表明在仅使用一年观测数据的情况下, LSTM 整体上表现出更强的适应性与稳定性。

需要指出的是, 模型模拟性能对训练年份的选




图 2 清江流域 GR4J (a、b) 与 LSTM (c、d) 模型在验证期-率定期匹配年份下的 NSE (a、c) 和 KGE (b、d) 评估指标热力图

Fig. 2 Heatmap of (a, c) NSE and (b, d) KGE evaluation metrics for (a, b) GR4J and (c, d) LSTM models in the Qingjiang River basin under matched calibration-validation years

择较为敏感。对于GR4J模型,使用2014年数据进行率定,在验证期内可获得相对较高的NSE与KGE;而对LSTM模型而言,2017年作为训练年份时整体表现最佳。当进一步将评估窗口聚焦至单一年份时,LSTM的优势并非始终占优,如2021年,GR4J在采用2014、2016年和2017年作为训练年份时,其NSE高于对应条件下的LSTM。这表明在仅具备单一年份观测资料的条件下,不同模型对特定水文情势的适应能力存在差异。

为进一步评估采用丰水年与枯水年组合数据进行模型率定的效果,从率定期中选取丰水年2017年(年均径流量 $329.5\text{ m}^3\cdot\text{s}^{-1}$,较10 a均值偏高31.8%)与枯水年2019年(年均径流量 $129.0\text{ m}^3\cdot\text{s}^{-1}$,较10 a均值偏低48.4%)构成两年组合率定期。由表3可知,采用丰枯年组合资料率定GR4J模型,2020—2023年验证期内的NSE和KGE分别为0.742和0.543,均高于各单一年份资料率定结果的平均水平(NSE均值为0.667,KGE均值为0.461);采用丰枯年组合资料率定LSTM模型,NSE和KGE分别达到0.790和0.771,同样显著优于单一年份资料率定结果的平均水平(NSE均值为0.737,KGE均值为0.690)。结果表明,丰枯年组合资料能够有效提升模型的模拟性能。

表3 采用清江流域丰水年(2017年)、枯水年(2019年)组合资料率定的GR4J与LSTM模型在验证期的评估指标

Table 3 Evaluation metrics of GR4J and LSTM models calibrated using combined data from wet (2017) and dry (2019) years in the Qingjiang River basin during the validation period

验证期年份	GR4J		LSTM	
	NSE	KGE	NSE	KGE
2020	0.797	0.541	0.865	0.724
2021	0.585	0.420	0.505	0.441
2022	0.482	0.497	0.510	0.558
2023	0.716	0.772	0.614	0.804
2020—2023	0.742	0.543	0.790	0.771

将丰枯年组合资料率定结果与长序列资料(2014—2019年)率定结果进行对比发现,两者在2020—2023年验证期内的NSE与KGE差异较小(长序列资料条件下,GR4J的NSE和KGE分别为0.745和0.564,LSTM的NSE和KGE分别为0.795和0.751,见表2),且对于部分验证年份,采用丰枯年组合资料进行率定时表现更优,例如,采用丰枯年组合资料率定时,2022年验证期的NSE与KGE均高于采用长序列资料率定的结果。这表明,在观测资

料相对匮乏的山区流域,选取具有水文代表性的丰枯年组合资料进行模型率定,不仅能够维持整体模拟精度,还能提升模型对某些特定年份径流过程的刻画能力。

3.2 采用长期观测数据率定的耦合模型模拟性能提升分析

在前述分析基础上,本文基于GR4J与LSTM模型构建了两种混合模型,即松耦合模型Hybrid1和紧耦合模型Hybrid2。在完成四类模型的训练后,仅保留训练期NSE大于0.5的模型运行结果,用于构建集合模拟结果。其中,LSTM模型及两种混合模型的100次训练运行均满足该筛选标准。表4给出两种混合模型在率定期与验证期内的评价指标,包括NSE、KGE及其分解项 r 、 α 与 β 。综合各项评价指标可知,Hybrid2的整体模拟性能优于Hybrid1。在验证期内,与GR4J模型(表2)相比,Hybrid1与Hybrid2的NSE分别提升了6.8%与10.7%,KGE分别提升了45.1%与52.7%;与LSTM模型(表2)相比,两混合模型的NSE分别提升0.1%与3.7%,KGE分别提升9.0%与14.7%。结果表明,混合建模策略对GR4J模型的性能改善尤为显著。进一步分析KGE的分解项发现,Hybrid1与Hybrid2的均值比 β 值分别较GR4J提升80.4%与58.4%,说明混合模型主要通过改善对径流均值的模拟,从而有效降低了系统偏差。相比之下,各模型的相关系数 r 和变幅比 α 的差异相对较小,表明混合模型性能提升的主要来源于对径流量级而非波动幅度的优化。

表4 清江流域率定期(2014—2019年)和验证期(2020—2023年)两种混合模型评估指标

Table 4 Evaluation metrics of two hybrid models for the Qingjiang River basin during the calibration period (2014—2019) and validation period (2020—2023)

不同时期	模型	评估指标				
		NSE	KGE	r	α -KGE	β -KGE
率定期	GR4J	0.832	0.839	0.913	0.882	1.065
	LSTM	0.878	0.833	0.940	0.890	0.890
验证期	GR4J	0.796	0.819	0.893	0.888	1.094
	LSTM	0.824	0.861	0.908	0.904	0.960

图3为四种模型在率定期与验证期内模拟径流与观测径流的散点分布。从中看出,Hybrid2的决定系数 R^2 最高(0.854),且数据点更密集分布于1:1线附近,整体拟合效果明显优于GR4J与LSTM。需要指出的是,所有模型的回归斜率均小于1,表明在高流量条件下仍存在一定程度的系统性低估,但混合




图3 清江流域四种模型 GR4J (a)、LSTM (b)、Hybrid1 (c)、Hybrid2 (d) 在率定期与验证期的观测和模拟流量相关性散点图

Fig. 3 Scatter plots of observed versus simulated streamflow for (a) GR4J, (b) LSTM, (c) Hybrid1 and (d) Hybrid2 in the Qingjiang River basin during the calibration and validation periods

模型的低估幅度相对较小。

图4给出四种模型在率定期与验证期内模拟与观测流量的流量历时曲线(FDC),其中图4a以对数尺度表示超越概率,图4b以对数尺度表示径流量。由图4a可见,各模型在高流量区间($>3\,000\text{ m}^3 \cdot \text{s}^{-1}$)均存在一定低估,其中LSTM的低估最为明显,而Hybrid2在高流量区间的偏差相对最小。图4b表明,GR4J模型在低流量区间存在一定低估,但其绝对误差一般小于 $50\text{ m}^3 \cdot \text{s}^{-1}$,在实际应用中仍具有可接受性;Hybrid1在低流量区间则表现出轻微高估。总体而言,Hybrid2在整个流量范围内与观测径流的吻合程度最高,这与其在表4中表现出的最优NSE与KGE结果保持一致。

3.3 不同时间尺度与季节条件下模型模拟特征分析

表5给出采用长期观测数据率定的四种模型在验证期内各季节及汛期和非汛期的评估指标,包括

春季(3—5月)、夏季(6—8月)、秋季(9—11月)、冬季(12月—次年2月)、汛期(4—10月)和非汛期(11月—次年3月)。从中可见,各模型的模拟性能随季节与水文时期变化显著,所有模型在夏季的模拟效果最佳,秋季次之,冬季相对较弱;同时,汛期的模拟性能普遍优于非汛期。两种混合模型在所有季节与水文时期内的表现均优于GR4J和LSTM模型,其中Hybrid2在夏季和汛期的NSE与KGE均超过0.8,具有良好的洪水期径流模拟性能。

表6进一步给出四种模型在验证期逐年尺度上的NSE与KGE结果。可以看出,所有模型在典型丰水年2020年(该年流域降水量达 $1\,863.5\text{ mm}$,较10 a均值偏高30%;年均径流量为 $402.3\text{ m}^3 \cdot \text{s}^{-1}$,较10 a均值偏高61%)均取得了最佳模拟效果,各模型的NSE均高于0.84,KGE均大于0.55,说明不同模型对丰水年径流过程均具备较为可靠的模拟能




图 4 清江流域四种模型在率定期 (a) 与验证期 (b) 的流量历时曲线 (其中, 图 a 以对数坐标表示超过概率, 图 b 以对数坐标表示日流量)

Fig. 4 Flow duration curves (FDCs) of observed and simulated streamflow for the four models in the Qingjiang River basin during the (a) calibration and (b) validation periods (especially, exceedance probability presented in a log scale in Fig. a, streamflow presented in a log scale in Fig. b)

表 5 采用清江流域长期观测数据率定的四种模型在验证期内各季节及汛期和非汛期的评估指标

Table 5 Evaluation metrics of four models calibrated using long-term observational data in the Qingjiang River basin during the validation period for each season, flood season, and non-flood season

时段	GR4J		LSTM		Hybrid1		Hybrid2	
	NSE	KGE	NSE	KGE	NSE	KGE	NSE	KGE
春季	0.087	0.288	0.404	0.539	0.56	0.785	0.555	0.726
夏季	0.792	0.663	0.807	0.715	0.805	0.77	0.841	0.819
秋季	0.534	0.636	0.748	0.748	0.634	0.599	0.68	0.711
冬季	-0.358	-0.066	-0.151	0.185	0.13	0.521	0.124	0.575
汛期	0.736	0.614	0.788	0.744	0.782	0.805	0.815	0.852
非汛期	0.028	0.062	0.210	0.431	0.467	0.697	0.477	0.733

表 6 清江流域四种模型在验证期 (2020–2023 年) 逐年的 NSE 和 KGE

Table 6 Annual NSE and KGE values for the four models in the Qingjiang River basin during the validation period (2020–2023)

模型	NSE				KGE			
	2020	2021	2022	2023	2020	2021	2022	2023
GR4J	0.841	0.613	0.401	0.498	0.558	0.425	0.459	0.611
LSTM	0.868	0.625	0.711	0.694	0.697	0.544	0.827	0.829
Hybrid1	0.879	0.687	0.582	0.536	0.799	0.745	0.705	0.549
Hybrid2	0.909	0.699	0.639	0.598	0.840	0.680	0.804	0.657

力。相比之下,在模拟表现相对较弱的年份中,GR4J 在 2022 年表现最差,LSTM 在 2021 年表现最弱,而两种混合模型均在 2023 年的模拟精度相对较低,反映不同模型对年际水文情势的敏感性存在差异。

图 5 给出四种模型在验证期内逐年尺度的实测与模拟径流过程线,从中反映出不同水文情景下模型的动态响应特征。具体而言:在 2020 年丰水年情景下,相较于 GR4J 和 LSTM 模型,两种混合模型对全年径流变化过程的整体拟合能力更强。其中,

LSTM 与 Hybrid1 对 7 月洪峰存在明显低估,而 GR4J 与 Hybrid2 对该洪峰的模拟相对较为准确。在 2021 年汛期,各模型能够较好地捕捉径流变化趋势,但均未能精确再现 7 月洪峰过程。在 2022 年枯水年条件下,GR4J 对 5 月以前的径流过程存在明显低估,而其余模型在该时段表现相对较好;但两种混合模型在 5—6 月高流量阶段出现了一定程度的高估。在 2023 年,各模型总体上能够较好地再现汛期径流变化,但对 9 月洪峰均存在一致性的明显高估。




图 5 清江流域四种模型 GR4J (a₁—a₄)、LSTM (b₁—b₄)、Hybrid1 (c₁—c₄)、Hybrid2 (d₁—d₄) 在验证期 2020 (a₁—d₁)、2021 (a₂—d₂)、2022 (a₃—d₃)、2023 (a₄—d₄) 的实测与模拟流量

Fig. 5 Observed and simulated hydrographs for GR4J (a₁—a₄), LSTM (b₁—b₄), Hybrid1 (c₁—c₄) and Hybrid2 (d₁—d₄) in the Qingjiang River basin during 2020 (a₁—d₁), 2021 (a₂—d₂), 2022 (a₃—d₃) and 2023 (a₄—d₄)

4 结论与讨论

本文以清江流域为研究区域, 基于 2014—2023 年逐日降水与径流资料, 评估了不同观测数据条件下 GR4J 与 LSTM 模型在山区流域中的径流模拟性能, 并在此基础上构建了松耦合 Hybrid1 和紧耦合 Hybrid2 两类混合模型, 分析了混合建模策略对山区径流模拟性能的提升效果。同时, 对比了不同时间尺度和季节条件下各模型的模拟特征。得出主要结论如下:

(1) 采用单一年份、丰枯年组合水文资料进行模型率定与训练具有一定可行性, 其中采用丰枯年组合资料能够有效提升径流模拟性能。采用单一年份资料进行率定时, LSTM 整体表现优于 GR4J; 采用丰

水年 (2017 年) 与枯水年 (2019 年) 组合数据进行率定时, GR4J 与 LSTM 在验证期内的 NSE 和 KGE 均明显高于单一年份资料率定结果的平均水平, 且模拟效果接近于使用长时间序列资料 (2014—2019 年) 率定的结果。

(2) 混合建模策略能够显著提升山区径流模拟精度, 其中 Hybrid2 的整体表现优于 Hybrid1。与 GR4J 模型相比, Hybrid2 在验证期 NSE 与 KGE 分别提升 10.7% 与 52.7%; 与 LSTM 模型相比, NSE 与 KGE 分别提升 3.7% 与 14.7%。

(3) 模型模拟性能在清江流域呈现明显的季节性和年际差异。总体而言, 各模型在夏季及汛期的模拟效果优于冬季和非汛期, 在丰水年 (2020 年) 中整

体精度较高。其中,Hybrid2在夏季和汛期的NSE与KGE均超过0.8,具有良好的洪水期径流模拟性能。此外,各模型在不同水文情势下的表现差异反映了其对水文过程刻画能力的差别,而混合模型在多数情况下能够增强对不同水文情势的适应性,从而克服了单一模型的结构局限性。

综上所述,本文验证了采用单一年份、丰枯年组合水文资料进行模型训练的可行性,并表明提出的紧耦合混合建模框架在提升山区流域径流模拟精度方面具有明显优势,可为缺乏资料的山区流域径流模拟与洪水预报提供参考。然而,本文仍存在一定局限性。首先,研究仅以清江流域为案例,未来有必要在不同气候区、下垫面条件及人类活动影响程度差异显著的流域开展多案例对比研究,以进一步检验模型的泛化能力。其次,本文主要关注日尺度径流模拟,尚未扩展至预报应用情景,而在实际防洪调度中,具有预见期的径流预测更具现实意义。在后续研究中将在此基础上引入数值天气预报或集合预报产品,构建基于混合模型的径流预报体系,并重点评估其在极端洪水事件中的径流预报性能。

参考文献 (References):

- 敖天其,刘臻,吴玲玲,等.2025.分布式水文模型在高原山地流域的研究与应用进展[J].*高原山地气象研究*,45(3):14–23. Ao T Q, Liu Z, Wu L L, et al. 2025. Research and application progress of distributed hydrological models in plateau mountainous basins [J]. *Plateau and Mountain Meteorology Research*,45(3):14–23 (in Chinese). doi:10.3969/j.issn.1674-2184.2025.03.002
- 包红军,林建,曹爽,等.2020.基于流域地貌的中小河流致洪动态临界面雨量阈值研究[J].*气象*,46(11):1495–1507. Bao H J, Lin J, Cao S, et al. 2020. Topography-based dynamic critical arearainfall threshold for small to middle-sized river flood warning [J]. *Meteorological Monthly*,46(11):1495–1507 (in Chinese). doi:10.7519/j.issn.1000-0526.2020.11.010
- 邓超,孙培源,尹鑫,等.2015.基于概念性水文模型与长短时记忆模型耦合的汉江上游流域径流模拟[J].*湖泊科学*,37(1):279–292. Deng C, Sun P Y, Yin X, et al. 2015. Runoff simulation in the upper Han River Basin using physics-informed machine learning model [J]. *Journal of Lake Sciences*,37(1):279–292 (in Chinese). doi:10.18307/2025.0143
- 甘衍军,徐晶,赵平,等.2017.暴雨致洪预报系统及其评估[J].*应用气象学报*,28(4):385–398. Gan Y J, Xu J, Zhao P, et al. 2017. Introduction and evaluation of a rainstorm-caused flood forecasting system [J]. *Journal of Applied Meteorological Science*,28(4):385–398 (in Chinese). doi:10.11898/1001-7313.20170401
- 高顺年,高铭,王振海.2026.青海大通“8·18”山洪灾害的天气特点及其气象应急服务对策[J].*暴雨灾害*,45(1):142–148. Gao S N, Gao M, Wang Z H. 2026. Synoptic characteristics and corresponding meteorological emergency service strategies based on a mountain flood disaster event in Datong of Qinghai Province on August 18, 2022 [J]. *Torrential Rain and Disasters*,45(1):142–148 (in Chinese). doi:10.12406/byzh.2024-140
- 郭良,丁留谦,孙东亚,等.2018.中国山洪灾害防御关键技术[J].*水利学报*,49(9):1123–1136. Guo L, Ding L Q, Sun D Y, et al. 2018. Key techniques of flash flood disaster prevention in China [J]. *Journal of Hydraulic Engineering*,49(9):1123–1136 (in Chinese). doi:10.13243/j.cnki.slxb.20180728
- 胡乐怡,蒋晓蕾,周嘉慧,等.2014.考虑记忆时间的LSTM模型在赣江流域径流预报中的应用[J].*湖泊科学*,36(4):1241–1251. Hu L Y, Jiang X L, Zhou J H, et al. 2014. Application of LSTM considering time steps in runoff prediction of Ganjiang River Basin [J]. *Journal of Lake Sciences*,36(4):1241–1251 (in Chinese). doi:10.18307/2024.0454
- 黄天文,焦飞,伍志方.2024.一种基于迁移学习和长短期记忆神经网络的降水预报方法[J].*暴雨灾害*,43(1):45–53. Huang T W, Jiao F, Wu Z F. 2024. A precipitation forecast method based on transfer learning and Long Short Term Memory [J]. *Torrential Rain and Disasters*,43(1):45–53 (in Chinese). doi:10.12406/byzh.2023-118
- 李德龙,程先云,杨浩,等.2013.人工智群算法在水文模型参数优化率定中的应用研究[J].*水利学报*,44(z1):95–101. Li D L, Cheng X Y, Yang H, et al. 2013. Study on artificial intelligence optimization algorithms for auto-calibration of hydrological models [J]. *Journal of Hydraulic Engineering*,44(z1):95–101 (in Chinese). doi:10.3969/j.issn.0559-9350.2013.z1.014
- 李国英.2022.加快建设数字孪生流域提升国家水安全保障能力[J].*中国水利*, (20):1. Li G Y. 2022. Accelerate to build the digital twin river basins and enhance China's capacity to ensure water security [J]. *China Water Resources*, (20):1 (in Chinese). doi:10.16616/j.cnki.11-4446/TV.2022.09.01
- 刘攀,郑雅莲,谢康,等.2021.水文水资源领域深度学习研究进展综述[J].*人民长江*,52(10):76–83. Liu P, Zheng Y L, Xie K, et al. 2021. Review of research progress in deep learning for hydrology and water resources [J]. *Yangtze River*,52(10):76–83 (in Chinese). doi:10.16232/j.cnki.1001-4179.2021.10.012
- 庞铁舒,张俊,秦宁生,等.2022.长江上游夏季径流量年际增量预测模型及检验[J].*应用气象学报*,33(1):115–128. Pang Y S, Zhang J, Qin N S, et al. 2022. Forecast model of interannual increment for summer runoff and its verification in the upper reaches of the Yangtze River [J]. *Journal of Applied Meteorological Science*,33(1):115–128 (in Chinese). doi:10.11898/1001-7313.20220110
- 涂勇,吴泽斌,何秉顺.2020.2011—2019年全国山洪灾害事件特征分析[J].*中国防汛抗旱*,30(Z1):22–25. Tu Y, Wu Z B, He B S. 2020. Analysis on the characteristics of flash flood disasters in China from 2011 to 2019 [J]. *China Flood & Drought Management*, 30(S1):22–25 (in Chinese). doi:10.16867/j.issn.1673-9264.2020239
- 夏军,石卫.2016.变化环境下中国水安全问题研究与展望[J].*水利学报*,47(3):292–301. Xia J, Shi W. 2016. Perspective on water security issue of changing environment in China [J]. *Journal of Hydraulic Engineering*,47(3):292–301 (in Chinese). doi:10.13243/j.cnki.slxb.20150937
- 许钦,金晨,张坤,等.2025.耦合深度学习与水文模型的喀斯特地区径流模拟方法[J].*水科学进展*,36(4):634–645. Xu Q, Jin C, Zhang K, et al. 2025. Runoff simulation in Karst regions by integrating deep

- learning with physically-based hydrological models [J]. *Advances in Water Science*, 36(4):634–645 (in Chinese). doi:10.14042/j.cnki.32.1309.2025.04.008
- 雍斌, 张建云, 王国庆. 2023. 黄河源区水文预报的关键科学问题[J]. 水科学进展, 34(2):159–171. Yong B, Zhang J Y, Wang G Q. 2023. Key scientific issues of hydrological forecast in the headwater area of Yellow River [J]. *Advances in Water Science*, 34(2):159–171 (in Chinese). doi:10.14042/j.cnki.32.1309.2023.02.001
- 张国涛, 崔鹏, 张晨笛. 2025. 中国山洪灾害防控理论与技术: 进展、挑战与对策[J]. 地理科学进展, 44(7):1315–1333. Zhang G T, Cui P, Zhang C D. 2025. Theory and technology of flash flood disaster prevention and control in China: Progress, challenges, and counter measures [J]. *Progress in Geography*, 44(7):1315–1333 (in Chinese). doi:10.18306/dlkxjz.2025.07.001
- Cho K, Kim Y. 2022. Improving streamflow prediction in the WRF-Hydro model with LSTM networks [J]. *Journal of Hydrology*, 605: 127297. doi:10.1016/j.jhydrol.2021.127297
- Devia G K, Ganasri B P, Dwarakish G S. 2015. A review on hydrological models [J]. *Aquatic Procedia*, 4:1001–1007. doi:10.1016/j.aqpro.2015.02.126
- Gao S, Huang Y, Zhang S, et al. 2020. Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation [J]. *Journal of Hydrology*, 589:125188. doi:10.1016/j.jhydrol.2020.125188
- Gauch M, Mai J, Lin J. 2021. The proper care and feeding of CAMELS: How limited training data affects streamflow prediction [J]. *Environmental Modelling & Software*, 135:104926. doi:10.1016/j.envsoft.2020.104926
- Hochreiter S, Schmidhuber J. 1997. Long short-term memory [J]. *Neural Computation*, 9(8):1735–1780. doi:10.1162/neco.1997.9.8.1735
- Karpatne A, Atluri G, Faghmous J H, et al. 2017. Theory-guided data science: A new paradigm for scientific discovery from data [J]. *IEEE Transactions on Knowledge and Data Engineering*, 29(10): 2318–2331. doi:10.1109/TKDE.2017.2720168
- Kraft B, Jung M, Körner M, et al. 2022. Towards hybrid modeling of the global hydrological cycle [J]. *Hydrology and Earth System Sciences*, 26(6):1579–1614. doi:10.5194/hess-26-1579-2022
- Lin G F, Chou Y C, Wu M C. 2013. Typhoon flood forecasting using integrated two-stage Support Vector Machine approach [J]. *Journal of Hydrology*, 486:334–342. doi:10.1016/j.jhydrol.2013.02.012
- Lu D, Konapala G, Painter S L, et al. 2021. Streamflow simulation in data-scarce basins using bayesian and physics-informed machine learning models [J]. *Journal of Hydrometeorology*, 22(6):1421–1438. doi:10.1175/JHM-D-20-0082.1
- Moriasi D, Arnold J, Van Liew M, et al. 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations [J]. *Transactions of the ASABE*, 50. doi:10.13031/2013.23153
- Noori N, Kalin L. 2016. Coupling SWAT and ANN models for enhanced daily streamflow prediction [J]. *Journal of Hydrology*, 533:141–151. doi:10.1016/j.jhydrol.2015.11.050
- Nourani V. 2017. An Emotional ANN (EANN) approach to modeling rainfall-runoff process [J]. *Journal of Hydrology*, 544:267–277. doi:10.1016/j.jhydrol.2016.11.033
- Okkan U, Ersoy Z B, Ali Kumanlioglu A, et al. 2021. Embedding machine learning techniques into a conceptual model to improve monthly runoff simulation: A nested hybrid rainfall-runoff modeling [J]. *Journal of Hydrology*, 598:126433. doi:10.1016/j.jhydrol.2021.126433
- Perrin C, Michel C, Andréassian V. 2003. Improvement of a parsimonious model for streamflow simulation [J]. *Journal of Hydrology*, 279(1):275–289. doi:10.1016/S0022-1694(03)00225-7
- Perrin C, Oudin L, Andreassian V, et al. 2007. Impact of limited streamflow data on the efficiency and the parameters of rainfall—runoff models [J]. *Hydrological Sciences Journal*, 52(1):131–151. doi:10.1623/hysj.52.1.131
- Sorooshian S, Gupta V K, Fulton J L. 1983. Evaluation of Maximum Likelihood Parameter estimation techniques for conceptual rainfall-runoff models: Influence of calibration data variability and length on model credibility [J]. *Water Resources Research*, 19(1):251–259. doi:10.1029/WR019i001p00251
- Sun W, Wang Y, Wang G, et al. 2017. Physically based distributed hydrological model calibration based on a short period of streamflow data: case studies in four Chinese basins [J]. *Hydrology and Earth System Sciences*, 21(1):251–265. doi:10.5194/hess-21-251-2017
- Wang K H, Altunkaynak A. 2012. Comparative case study of rainfall-runoff modeling between SWMM and fuzzy logic approach [J]. *Journal of Hydrologic Engineering*, 17(2):283–291. doi:10.1061/(ASCE)HE.1943-5584.0000419
- Xiang Y, Li L, Chen J, et al. 2019. Parameter uncertainty of a snowmelt runoff model and its impact on future projections of snowmelt runoff in a data-scarce deglaciating river basin [J]. *Water*, 11(11):2417. doi:10.3390/w11112417
- Xiang Z, Yan J, Demir I. 2020. A rainfall-runoff model with LSTM-based sequence-to-sequence Learning [J]. *Water Resources Research*, 56(1):e2019WR025326. doi:10.1029/2019WR025326
- Yaseen Z M, El-shafie A, Jaafar O, et al. 2015. Artificial intelligence based models for stream-flow forecasting: 2000–2015 [J]. *Journal of Hydrology*, 530:829–844. doi:10.1016/j.jhydrol.2015.10.038
- Yu Q, Jiang L, Wang Y, et al. 2023. Enhancing streamflow simulation using hybridized machine learning models in a semi-arid basin of the Chinese loess Plateau [J]. *Journal of Hydrology*, 617:129115. doi:10.1016/j.jhydrol.2023.129115

(责任编辑 闵爱荣)