

基于误差校正融合模型的自适应带宽洪水区间预报

康 艳^{1,2}, 艾慧茹^{1,2}, 彭仁娟^{1,2}, 胡维贺^{1,2}, 吴巍然^{1,2}, 张梓尚^{1,2}, 由宇军³

(1. 西北农林科技大学旱区农业水土工程教育部重点实验室, 陕西 杨凌 712100; 2. 西北农林科技大学水利与建筑工程学院, 陕西 杨凌 712100; 3. 陕西省水文水资源勘测中心, 陕西 西安 710068)

摘要:针对小流域洪水产汇流过程复杂、洪水突发性强、物理机制模型预报精度不高等问题,采用以物理机制模型为主的误差校正型和以深度学习模型为主的机理引导型两种融合方式构建了 HYMOD、GR4J 与 LSTM 模型的融合模型,探讨了不同融合模型的模拟性能,采用自适应带宽核密度估计 (ABKDE) 开展了不同预见期洪水区间预报。以陕西黑河小流域洪水预报为例评估了各模型预报性能,结果表明:HYMOD、GR4J、LSTM 等单一模型能够提供可靠的预报结果,且深度学习模型 LSTM 优于物理机制模型 HYMOD 和 GR4J,而 HYMOD 模型比 GR4J 模型模拟性能更加稳定;融合模型既保留了物理模型的可解释性,又提高了洪水预报的精度,预报性能较单一模型有显著提高,纳什效率系数提升了 3.66%~70.51%;误差校正融合模型的预报性能优于机理引导融合模型,其中误差校正融合模型 HYMOD-LSTM 预报效果最优;HYMOD-LSTM 模型在 90%置信水平下的预测区间覆盖率超过 92%,表现出良好的性能,能够有效反映预报洪水过程的不确定性,且基于 ABKDE 的洪水区间预报结果合理可靠,体现了 ABKDE 良好的自适应调节能力。

关键词:洪水预报;误差校正融合模型;机理引导融合模型;自适应带宽核密度估计;黑河流域
中图分类号:P338 **文献标志码:**A **文章编号:**1004-6933(2025)05-0106-09

Adaptive bandwidth flood interval forecasting based on error-corrected hybrid model//KANG Yan^{1,2}, AI Huiru^{1,2}, PENG Renjuan^{1,2}, HU Weihe^{1,2}, WU Weiran^{1,2}, ZHANG Zishang^{1,2}, YOU Yujun³ (1. Key Laboratory of Agricultural Soil and Water Engineering in Arid and Semiarid Areas, Ministry of Education, Northwest A&F University, Yangling 712100, China; 2. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling 712100, China; 3. Hydrology and Water Resources Survey Center of Shaanxi Province, Xi'an 710068, China)

Abstract: To address the issues of complex flood generation and concentration processes, sudden flood occurrence, and low prediction accuracy of physical mechanism models in small watersheds, two kinds of hybrid methods, namely the error-corrected hybrid models mainly based on physical mechanism models and the mechanism-guided hybrid model mainly based on deep learning models were constructed by using the HYMOD, GR4J, and LSTM models. The simulation performance of different hybrid methods was explored, and the adaptive bandwidth kernel density estimation (ABKDE) was also proposed for flood interval forecasting with different lead times. With the typical small watershed of the Heihe River in Shaanxi Province as an example, the flood forecasting performance of each model was evaluated. The results show that the single models, including the HYMOD, GR4J, and LSTM models can provide reliable forecast results, and the deep learning model LSTM is superior to the physical mechanism models HYMOD and GR4J, while the simulation performance of the HYMOD model is more stable than that of the GR4J model. The hybrid models not only retain the interpretability of the physical model, but also improve the accuracy of flood forecasting, with the Nash efficiency coefficient increasing by 3.66% to 70.51%, demonstrating a significant improvement in forecasting performance compared to the single models. The error-corrected hybrid models have better forecasting performance than the mechanism-guided hybrid models, among which the error-corrected hybrid model HYMOD-LSTM has the best forecasting effect. The prediction interval coverage probability of the HYMOD-LSTM model at the 90% confidence level exceeds 92%, demonstrating excellent performance of the model. The HYMOD-LSTM model can effectively reflect the uncertainty of the forecasted flood process, and the results of flood interval forecasting based on ABKDE are reasonable and reliable, reflecting the good adaptive adjustment ability of ABKDE.

Key words: flood forecasting; error-corrected hybrid model; mechanism-guided hybrid model; adaptive bandwidth kernel density estimation; the Heihe River Basin

近年来随着全球气候变化、极端天气事件频繁发生,洪水灾害呈现趋多态势。2000 年以来全球发生了 7300 余起重大自然灾害,其中特大洪水事件占比约 44%^[1],而我国是全球自然灾害较为严重的国家,尤以洪涝为甚^[2]。2023 年 8 月 11 日 14—18 时秦岭北麓嵩沟小流域出现强降雨过程,该次短历时暴雨洪水的洪量约为 5.47 万 m³,诱发山洪泥石流灾害,造成多人伤亡的惨痛事件^[3-4]。山丘区中小流域因暴雨时空变化大、地形条件复杂、产汇流速度快,导致山洪预报难度大、预报精度不高^[5]。高精度、高时效的洪水预报可为洪水预警、洪水风险分析和水库防洪调度提供科学依据,对洪水灾害防御具有重要意义^[6]。流域洪水预报模型可分为经验模型^[7]、概念模型^[8]、分布式模型^[9]和水动力模型^[10],能够概化复杂多变的水文现象和过程。水文模型基于物理成因机制,通过降雨、蒸发、入渗等信息计算产汇流过程,具有明确的物理含义和较好的可解释性^[11]。其中,HYMOD 模型和 GR4J 模型原理和结构较为简单,需要的资料较少,广泛应用于洪水预报,已在全球 400 多个不同气候条件的区域得到验证^[12-13]。水动力模型能够模拟水流在河道及河漫滩的演进过程以及由暴雨引发的洪涝现象,但由于求解复杂,通常耗时较长且产生高计算成本^[10]。此外,气候变化及人类活动对流域水循环的扰动加剧^[14],也导致物理机制模型模拟精度不高。基于数据驱动的深度学习的模型进行预报时,能够以较少的参数表示复杂的函数,其对样本数据进行分析并寻求规律的过程与水文预报通过分析历史水文数据获取规律类似,极大地提高了预报的准确性,在水文领域获得广泛关注^[15],如熊怡等^[16]将自适应变分模态分解和长短时记忆网络(long short-term memory, LSTM)相结合捕捉径流动态过程,进一步提升了径流预报精度。虽然深度学习模型不受现有物理知识的局限,其预测能力相对于物理机制模型具有显著的优势,但其参数大多缺少物理机制支撑,对物理过程的可解释性较低^[17-18]。因此,如何借助 HYMOD、GR4J 等物理机制模型的产汇流可解释性及 LSTM 等深度学习模型对非线性过程强捕获能力的优势,将二者有效融合以提高洪水预报精度有待进一步探讨。

物理机制模型与深度学习模型融合方法目前有在物理机制模型中融入深度学习模型^[19]和利用物理机制模型指导深度学习模型^[20]两大类。例如:Kumanlioglu 等^[21]利用人工神经网络替换了 GR4J 模型的汇流部分,与遗传算法相结合对混合模型参

数的概念进行校准,对日降雨径流模型进行了改进;Boucher 等^[22]利用多层感知器计算 GR4J 模型的状态变量,以此改善其预报效果;段雅楠等^[13]采用新安江模型和 Tank、SAC (Sacramento model)、SMAR (soil moisture accounting and routing)、HYMOD、GR4J 等水文模型分别预报流域洪水,并将其结果作为 AdaBoost (adaptive boosting)、CatBoost (categorical boosting)、RF (random forest)、SVM (support vector machine) 和 XGB (extreme gradient boosting) 等学习器的输入,得到 5 种不同的集成预报结果,研究表明,各模型集成后的预报精度整体上均优于单模型的结果;Cho 等^[23]通过嵌入 LSTM 校正 WRF-Hydro (weather research and forecasting hydrological modeling system),预测模拟值与观测值之间的误差,提高了模型的预测精度;Xie 等^[24]将降雨径流预报过程中涉及的 3 种物理条件编码写入深度学习模型的损失函数,约束模型得到符合物理规律的输出,起到模型正则化作用,不仅增强了峰值预报能力,还减少了不合理负值出现的情况;Tajiki 等^[25]应用递归贝叶斯方法识别 HYMOD 模型误差的主要来源,将噪声添加到模型状态中,使用集成卡尔曼滤波器实时更新水文参数和状态,并考虑 HYMOD 模型参数的不确定性,进一步提高了预测效果。融合模型可以有效提升洪水预报精度^[6],但现有研究多集中于单一方式的模型融合,不同融合方式对融合模型预报性能的影响还有待研究。

洪水受到复杂的自然因素和人为因素综合影响,洪水过程蕴含着确定性的物理规律和不确定性的统计规律,因此预报结果不可避免地会产生误差^[26-27],仅考虑确定性预报的融合模型只能为防洪决策提供有限的不确定性(或风险)信息^[28]。核密度估计(kernel density estimation, KDE)作为一种非参数估计方法,无需预设数据分布的具体形式,有效避免了参数估计中因分布假设不当而导致的模型偏差问题。在给定样本数据的情况下, KDE 的精度受限于带宽和核函数^[29],从而影响了平滑程度和估计的准确性,自适应带宽核密度估计 (adaptive bandwidth kernel density estimation, ABKDE) 能够根据历史洪水数据中的高低水特征捕捉到洪水涨落过程中的细微变化,动态调整带宽参数,从而更准确地估计预测结果的概率密度分布^[30]。相较于传统 KDE, ABKDE 可以提供更准确的局部特性和密度变化^[31],基于 ABKDE,利用融合模型模拟洪水过程,开展洪水区间预报,可为水库防洪调度等决策提供更多的风险信息^[32-33]。

针对小流域洪水产汇流过程复杂、洪水突发性强、物理机制模型预报精度不高等问题,本文采用以物理机制模型为主的误差校正型和以深度学习模型为主的机理引导型两种融合方式构建 HYMOD、GR4J 与 LSTM 模型的融合模型,探讨不同融合方式对预报精度的影响,并采用 ABKDE 进行区间预报,以为流域防洪减灾和水库洪水管理提供科学依据。

1 研究方法

1.1 HYMOD 和 GR4J 模型

HYMOD 模型是由英国学者 Moore 提出的基于蓄满产流机制的非线性概念性水文模型,其优势在于参数少、结构简单,被广泛应用^[34]。GR4J 模型为集总式概念性水文模型,仅包含 4 个参数,采用产流水库和汇流水库两个非线性水库进行产汇流计算^[35-36]。本文以纳什效率系数(NSE)最大化为目标函数,采用 SCE-UA (shuffled complex evolution-University of Arizona)算法率定 HYMOD 和 GR4J 模型参数。

1.2 LSTM 模型

LSTM 模型是一种时间循环神经网络,通过门控机制有效捕获序列中的长期依赖关系,防止梯度消失或爆发,能够有效处理具有非线性、非稳态时间序列的问题^[37-39]。本文采用 Adam(adaptive moment estimation)梯度优化算法训练模型,以 NSE 最大化为目标函数,采用遗传算法优选 LSTM 的超参数。模型隐含层单元数、迭代次数、批处理大小、神经元个数、初始学习率和学习率下降因子分别为 4、30、32、128、0.01 和 0.005。

1.3 融合模型

通过以物理机制模型为主的误差校正型和以深度学习模型为主的机理引导型融合方式构建 HYMOD、GR4J 与 LSTM 模型的融合模型,探讨不同融合方式的模拟性能,洪水预报融合模型框架如图 1 所示。

a. 误差校正融合模型。提出洪水模拟-误差校正-洪水重构的融合模型框架,以 HYMOD 和 GR4J 模型为预报主模型,借助 LSTM 模型识别物理机制模型模拟的误差特征,进行实时动态误差校正,重构洪水预报结果,从而构建误差校正融合模型(HYMOD-LSTM、GR4J-LSTM)。融合模型将第 T 个时间步长的预报误差添加到 HYMOD 或 GR4J 模型的模拟流量 Q_{sim} 中,得到校正的流量 Q_{corr} ,将 Q_{corr} 作为融合模型第 $T+1$ 个时间步长的 Q_{sim} ,持续循环,




图 1 洪水预报融合模型框架

Fig. 1 Framework of flood forecasting hybrid model

实现实时动态误差校正。

b. 机理引导融合模型。将具有物理可解释性的 HYMOD 和 GR4J 模型作为机理引导模型,将其模拟结果作为 LSTM 模型的补充输入变量,构建以 LSTM 模型为主预报模型的机理引导融合模型(LSTM-HYMOD、LSTM-GR4J)进行洪水预报。将 HYMOD 或 GR4J 模型第 T 个时间步长的模拟流量 Q_{sim} 作为补充变量添加到融合模型第 T 个时间步长的输入中,得到模型的模拟结果。

1.4 ABKDE

KDE 是一种基于样本数据估计随机变量概率密度函数的非参数估计方法,该方法无需预设数据总体分布,可直接根据样本数据特征重构密度函数^[40]。本文基于 ABKDE 开展不同预见期洪水区间预报,选取高斯核函数进行非参数核密度估计,通过自适应带宽参数使得数据集内的每一个点都有一个相对应的带宽,在样本点密集区域带宽较小,密度估计更加精细,而在样本点稀疏区域带宽较大,以平滑密度估计,从而实现在满足预测区间覆盖率要求的情况下尽可能减少预测区间平均宽度。

1.5 评价指标

本文采用纳什效率系数(NSE)、相关系数(CC)、洪峰相对误差(RE)和均方根误差(RMSE)对模型模拟性能进行评价。NSE 反映模拟值对实测值的整体拟合效果;CC 对模拟值与实测值之间的关联性进行评定;RE 量化模拟洪峰流量与实测洪峰流量的偏离程度;RMSE 侧重于评价系列总体的误差情况,RMSE 越小表示模型的性能越好^[41]。

采用预测区间覆盖率 (prediction interval coverage probability, PICP)、预测区间平均宽度 (prediction interval average width, PINAW) 和连续排位概率分数 (continuous ranked probability score, CRPS) 表征模型的区间预报性能^[42]。PICP 是评价区间预报可靠性的核心指标之一, PICP 值越大表示落在预报区间内的实测点比率越高; 在满足目标覆盖率的前提下, PINAW 值越小表示预报区间的精度越高; CRPS 是结合可靠性和集中度的综合指标, 是衡量区间预报总体效果的标准方法, 其值越小表示对区间预报的准确性越高。

2 实例分析

2.1 研究区概况

陕西省黑河是渭河南岸较大支流, 属黄河二级支流, 发源于秦岭太白山北麓的茫谷, 流域总面积 2 258 km², 干流总长度为 125. 8 km。该流域地处秦岭褶皱带, 地形以山地为主, 为典型的半干旱半湿润大陆性季风气候特征。多年平均降水量约为 800 mm, 降水多集中在夏、秋两季, 洪水具有汇流快、洪峰高、洪量大的特点。

黑河金盆水库枢纽工程位于黑河峪口以上约 1. 5 km 处, 距西安市 86 km, 是一项以城市供水为主, 兼有农灌、防洪、发电等综合利用的大(Ⅱ)型水利工程, 该工程的洪水预报对区域防洪安全具有重大影响。陈河水文站作为金盆水库的关键入库监测点, 控制面积约为 1 380 km², 为水库的运行与管理提供了重要支持。本文选取该站点以上集水区域为研究区, 陕西渭河南岸黑河流域概况如图 2 所示。

2.2 资料来源

收集黑河流域陈河水文站 2003—2019 年 6 h 时段洪水摘录资料; 选用陈河站上游 8 个雨量站(钓鱼台、厚畛子、麦场、沙梁子、板房子、老水磨、小王涧、金井)的降水量摘录资料, 采用泰森多边形法获得面平均降水量。将 2003—2014 年划分为训练期,




图 2 黑河流域概况

Fig. 2 Overview of the Heihe River Basin

选取 15 场洪水数据用于模型参数率定; 将 2015—2019 年划分为验证期, 选取 7 场洪水数据用于模型验证。考虑到原始数据时间分辨率、洪水径流过程连续变化特性以及模型稳定性要求, 将时间间隔设置为 $\Delta t=6\text{ h}$, 使用插值法以 Δt 为基本计算步长, 通过滑动窗口法递推生成预测序列^[43]。图 3 为 22 场次暴雨洪水过程线, 图中每个时段为 6 h。

2.3 单一模型模拟结果

利用训练期 15 场洪水数据, 采用 SCE-UA 算法对 HYMOD 和 GR4J 模型参数进行率定, 结果见表 1 和表 2。不同模型在不同预见期对黑河流域洪水预报的评价指标见表 3。从表 3 可以看出, 与 HYMOD 和 GR4J 模型相比, 当预见期为 6 h 时, 深度学习 LSTM 模型具有较高的预报精度, 其 NSE 与 HYMOD 和 GR4J 模型相比提升了 10. 13%~17. 72%。

表 1 HYMOD 模型参数率定结果

Table 1 HYMOD model parameter calibration results					
预见期/h	$C_{\max}/\text{mm}$	$b_{\exp}$	α	R_s/d	R_q/d
6	14. 80	0. 61	0. 51	0. 08	0. 48
12	24. 74	1. 72	0. 99	0. 06	0. 38
18	22. 40	1. 64	0. 99	0. 06	0. 33
参数范围	1~1 200	0. 1~2. 0	0. 30~0. 99	0. 05~0. 10	0. 20~0. 99

注: $C_{\max}$ 为流域内最大蓄水能力; $b_{\exp}$ 为流域蓄水能力空间变化指数; α 为快速流和慢速流分配因子; R_s 为慢速流水箱的出流衰减因子; R_q 为快速流水箱的出流衰减因子。




图 3 训练期和验证期场次暴雨洪水过程线

Fig. 3 Rainstorm flood hydrographs during training and validation periods

表 2 GR4J 模型参数率定结果

Table 2 GR4J model parameter calibration results				
预见期/h	X_1 /mm	X_2 /mm	X_3 /mm	X_4 /d
6	100	0.23	45.07	2.90
12	100	0.73	88.48	2.90
18	100	1.17	136.53	2.90
参数范围	100~1 200	-5~3	20~300	1.1~2.9

注： X_1 为产流水库容量； X_2 为地下水交换系数； X_3 为汇流水库容量； X_4 为单位线汇流时间。

HYMOD 和 GR4J 模型具有稳定的物理机制，且 HYMOD 模型的稳定性优于 GR4J 模型。

图 4 和图 5 分别为单一模型验证期实测流量和模拟流量的散点图和对应的泰勒图。从图 4 可以看出，验证期内低流量拟合状况较好，且拟合线分布在 1：1 线附近，然而在洪峰附近，部分高流量点位于 1：1 线以下，这可能因为缺少大流量样本，导致各

模型对验证期洪峰流量的系统性低估。从图 5 可以看出，预见期为 6 h 时，LSTM 模型模拟流量与观测流量相关系数最高，标准偏差和均方根误差最低，但 12 h 和 18 h 预见期的预报性能降低，效果较差。HYMOD 和 GR4J 模型在不同预见期的结果相对 LSTM 模型较为稳定。可以得出结论，各模型不同预见期的模拟结果存在差异，且随着预见期的延长，预报精度随之下降，这与诸多研究结果相似^[28,43-44]。当预见期较短时，LSTM 模型的模拟性能相对最优，HYMOD 和 GR4J 模型相对较差。

2.4 融合模型模拟结果

由表 3 可见，与单一模型相比，融合模型的 NSE 提升了 3.66%~70.51%，得到了满意的预报效果，模型性能有不同程度的提升。误差校正融合模型预报性能优于机理引导融合模型，其 NSE 提高了

表 3 不同模型洪水预报结果的评价指标

Table 3 Evaluation indexes of flood forecast results of different models during training and validation periods										
类型	模型	预见期/h	训练期				验证期			
			NSE	CC	RE/%	RMSE/(m ³ /s)	NSE	CC	RE/%	RMSE/(m ³ /s)
单一模型	HYMOD	6	0.71	0.85	18.83	93.84	0.65	0.81	18.94	72.86
		12	0.65	0.81	28.34	103.28	0.60	0.78	30.01	76.32
		18	0.60	0.78	35.14	110.76	0.58	0.77	34.24	78.94
	GR4J	6	0.78	0.88	14.06	81.59	0.71	0.84	17.08	65.50
		12	0.50	0.70	29.32	124.39	0.57	0.79	28.38	79.18
		18	0.24	0.50	62.33	151.73	0.33	0.66	50.22	99.04
	LSTM	6	0.80	0.90	13.35	78.59	0.79	0.91	16.74	55.92
		12	0.58	0.77	21.71	113.50	0.53	0.73	23.48	83.50
		18	0.36	0.66	64.56	138.93	0.23	0.65	56.30	106.17
误差校正融合模型	HYMOD-LSTM	6	0.86	0.93	16.26	64.85	0.82	0.91	17.98	29.07
		12	0.82	0.93	20.05	72.95	0.79	0.90	22.30	33.83
		18	0.80	0.90	33.29	77.69	0.78	0.89	24.27	33.17
	GR4J-LSTM	6	0.80	0.91	18.37	78.59	0.70	0.85	18.35	31.35
		12	0.87	0.94	15.24	63.88	0.86	0.93	19.42	23.94
		18	0.94	0.97	15.06	42.88	0.88	0.97	20.38	35.28
机理引导融合模型	LSTM-HYMOD	6	0.79	0.89	16.54	79.39	0.58	0.79	19.40	78.15
		12	0.70	0.84	19.67	96.15	0.61	0.79	26.72	75.78
		18	0.71	0.85	29.73	93.33	0.61	0.79	30.91	75.55
	LSTM-GR4J	6	0.79	0.89	18.50	80.70	0.69	0.84	18.98	67.55
		12	0.78	0.88	19.28	81.95	0.67	0.83	20.14	69.42
		18	0.75	0.88	27.46	87.61	0.65	0.87	29.94	71.41




图 4 单一模型验证期实测流量和模拟流量散点图

Fig. 4 Scatter plots of observed versus simulated streamflow for single models during validation period




图 5 单一模型验证期的泰勒图

Fig. 5 Taylor diagram of single models during validation period

15.19%~29.27%。HYMOD 和 GR4J 模型基于稳定的物理机制得到洪水预报结果,LSTM 模型从其误差序列中捕获规律并进行实时校正,有效提高了不同预见期的洪水预报精度。预见期为 6 h 时,机理引导融合模型模拟性能与 HYMOD 和 GR4J 模型相比反而有所下降,可能原因在于 HYMOD 和 GR4J 模型在模拟过程中会产生误差,其结果作为输入经过 LSTM 模型融合后会造成误差的再次传递,导致最后的结果可能会劣于误差校正融合模型。如图 6 和图 7 所示,误差校正融合模型的散点分布相对紧凑,更接近 1:1 线,且从图 8 可以看出, HYMOD-LSTM 模型模拟流量与观测流量间的误差在不同预见期相对稳定。可以得出结论,经实时动态误差校正方式融合的 HYMOD-LSTM 模型预报性能相对最优。

图 6 和图 7 所示,误差校正融合模型的散点分布相对紧凑,更接近 1:1 线,且从图 8 可以看出, HYMOD-LSTM 模型模拟流量与观测流量间的误差在不同预见期相对稳定。可以得出结论,经实时动态误差校正方式融合的 HYMOD-LSTM 模型预报性能相对最优。

2.5 区间预报结果

为进一步分析融合模型的预报性能,在验证期内选取洪峰流量最大的洪水过程(20190912 场次洪水)进行分析。选用 HYMOD-LSTM 模型的洪水重构结果,采用 ABKDE 对其洪水过程的预报误差进行拟合,获得 90% 置信度下的误差分布和预报区间,表 4 为 HYMOD-LSTM 模型区间预报的评价指标。从表 4 可以看出, HYMOD-LSTM 模型的 PICP 值不低于 92%,90% 置信区间覆盖了绝大多数的实测点,表明置信区间合理可靠。随着预见期的延长,PICP 值逐渐减小,PINAW 值和 CRPS 值逐渐增

表 4 HYMOD-LSTM 模型区间预报评价指标

Table 4 Interval prediction evaluation indexes of HYMOD-LSTM model

预见期/h	PICP/%	PINAW	CRPS/(m^3/s)
6	93	0.15	0.27
12	93	0.15	0.27
18	92	0.21	0.29




图 6 误差校正融合模型验证期实测流量和模拟流量散点图

Fig. 6 Scatter plots of observed versus simulated streamflow for error-corrected hybrid model during validation period




图 7 机理引导融合模型验证期实测流量和模拟流量散点图

Fig. 7 Scatter plots of observed versus simulated streamflow for mechanism-guided hybrid model during validation period




图 8 融合模型验证期的泰勒图

Fig. 8 Taylor diagrams of hybrid models during validation period

加,表明预报不确定性逐渐增大,区间预报性能有所降低。

图 9 为 20190912 场次洪水预报误差的 KDE 曲线,在样本点密集区域 ABKDE 带宽较小,使得密度估计更加精细;在样本点稀疏区域带宽较大,以平滑密度估计。可以发现,经自适应带宽优化后的 ABKDE 曲线能更准确地捕捉局部特性和密度变化。如图 10 所示(图中每个时段为 6 h),HYMOD-LSTM 模型在 6 h 预见期具有较好的预报效果,置信区间覆盖绝大多数实测流量点,且区间宽度较窄,表明置

信区间可以较好地反映预报洪水过程的不确定性。随着预见期的延长,退水过程的预报洪水过程线拟合效果有所下降,但可以较为准确地预报峰现时间;置信区间逐渐变宽,表明不确定性逐渐增大,但覆盖率仍接近 90%。由此可见,HYMOD-LSTM 模型能够提供可靠的区间预报。

3 结 论

a. HYMOD、GR4J 和 LSTM 等单一模型在洪水预报中具有较好的适用性。短预见期时,LSTM 模




图 9 20190912 场次洪水预报误差的 KDE 曲线

Fig. 9 KDE curves of forecast errors for flood event of 20190912




图 10 HYMOD-LSTM 模型对 20190912 场次洪水的预报结果和置信区间

Fig. 10 Forecast results of HYMOD-LSTM model and confidence intervals for flood event of 20190912

型的 NSE 与 HYMOD、GR4J 模型相比提升了 10.13%~17.72%,但随着预见期的延长,LSTM 模型的预报性能有所下降。而 HYMOD 模型产汇流机理更能适应黑河流域复杂水文条件,模拟性能较 GR4J 模型更加稳健。

b. HYMOD、GR4J 与 LSTM 模型的融合模型预报性能明显优于 HYMOD、GR4J 和 LSTM 等单一模型,NSE 提升了 3.66%~70.51%,表明融合模型有效地结合了物理机制模型的可解释性与深度学习模型的强捕获能力,能显著提高洪水预报精度。误差校正融合模型的 NSE 与机理引导融合模型相比提高了 15.19%~29.27%,其对非线性误差序列具有较强的捕捉能力,通过误差校正有效提高了预报精度,且校正效果随预见期增长衰减缓慢。HYMOD-LSTM 融合模型具有更好的预报性能。

c. HYMOD-LSTM 模型在 90%置信水平下,其预测区间覆盖率均超过 92%,表现出良好的性能,能够有效反映预报洪水过程的不确定性,区间预报结果合理可靠。ABKDE 避免了传统固定带宽 KDE 的局部适用性问题,能够通过捕捉洪水涨落过程中的细微变化动态调整带宽参数,表现出了良好的自适应调节能力。

参考文献:

[1] LI Guoyi,SHAO Weiwei,SU Xin,et al. Urban flood hazard assessment based on machine learning model[J]. Water Resources Management,2025,39(5):1953-1970.

[2] 程晓陶,刘昌军,李昌志,等. 变化环境下洪涝风险演变特征与城市韧性提升策略[J]. 水利学报,2022,53(7):757-768. (CHENG Xiaotao, LIU Changjun, LI Changzhi, et al. Evolution characteristics of flood risk under changing environment and strategy of urban resilience improvement [J]. Journal of Hydraulic Engineering,2022,53(7):757-768. (in Chinese))

[3] 刘传正,王建新. 降雨型山洪泥石流灾害成因及实证分析[J]. 中国防汛抗旱,2024,34(5):8-16. (LIU Chuanzheng,WANG Jianxin. Empirical analysis of causes of rainfall-triggered mountain torrential floods and debris flow disasters[J]. China Flood & Drought Management, 2024,34(5):8-16. (in Chinese))

[4] 姚秋玲,何秉顺,涂勇,等. 陕西西安长安区“2023. 8. 11”蒿沟泥石流灾害调查分析[J]. 中国防汛抗旱,2024,34(10):45-48. (YAO Qiuling, HE Bingshun, TU Yong, et al. Investigation and analysis of the “2023. 8. 11” Haogou mudflow disaster in Chang’ an District of Xi’ an City of Shaanxi Province [J]. China Flood & Drought Management,2024,34(10):45-48. (in Chinese))

[5] 刘媛媛,刘业森,刘洋,等. 基于机器学习降雨动态时空特征识别山丘区小流域洪水预报方法研究[J]. 水利学

报,2024,55(9):1009-1019. (LIU Yuanyuan, LIU Yesen, LIU Yang, et al. Research on flood forecasting method in mountainous small watersheds based on machine learning for identifying rainfall dynamic spatiotemporal features [J]. Journal of Hydraulic Engineering,2024,55(9):1009-1019. (in Chinese))

[6] XU Chengjing, ZHONG Ping’ an, ZHU Feilin, et al. A hybrid model coupling process-driven and data-driven models for improved real-time flood forecasting [J]. Journal of Hydrology,2024,638:131494.

[7] 申红彬,徐宗学,李其军,等. 基于 Nash 瞬时单位线法的渗透坡面汇流模拟[J]. 水利学报,2016,47(5):708-713. (SHEN Hongbin, XU Zongxue, LI Qijun, et al. Simulation of rainfall runoff on permeable slope based on Nash instantaneous unit hydrograph [J]. Journal of Hydraulic Engineering, 2016, 47 (5): 708-713. (in Chinese))

[8] SEZEN C, BEZAK N, BAI Yun, et al. Hydrological modelling of karst catchment using lumped conceptual and data mining models[J]. Journal of Hydrology,2019,576:98-110.

[9] 马强,王莹,魏琳,等. 基于分布式模型的流域洪水时空特征分析方法[J]. 水科学进展,2024,35(5):726-737. (MA Qiang, WANG Ying, WEI Lin, et al. A modelling-based assessment approach of basin flood spatiotemporal characteristics [J]. Advances in Water Science, 2024, 35 (5): 726-737. (in Chinese))

[10] 江春波,周琦,申言霞,等. 山区流域洪涝预报水文与水动力耦合模型研究进展[J]. 水利学报,2021,52(10):1137-1150. (JIANG Chunbo,ZHOU Qi, SHEN Yanxia, et al. Review on hydrological and hydrodynamic coupling models for flood forecasting in mountains watershed [J]. Journal of Hydraulic Engineering, 2021, 52 (10): 1137-1150. (in Chinese))

[11] 宋晓猛,张建云,王国庆,等. 变化环境下城市水文学的发展与挑战:II. 城市雨洪模拟与管理[J]. 水科学进展,2014,25(5):752-764. (SONG Xiaomeng, ZHANG Jianyun, WANG Guoqing, et al. Development and challenges of urban hydrology in a changing environment: II. urban stormwater modeling and management [J]. Advances in Water Science, 2014, 25 (5): 752-764. (in Chinese))

[12] 王宇晖,雷晓辉,蒋云钟,等. Hymod 模型参数敏感性分析和多目标优化[J]. 水电能源科学,2010,28(11):15-17. (WANG Yuhui, LEI Xiaohui, JIANG Yunzhong, et al. Parameter sensitivity analysis and multi-objective optimization on Hymod model [J]. Water Resources and Power,2010,28(11):15-17. (in Chinese))

[13] 段雅楠,梁忠民,赵建飞,等. 基于 Stacking 集成框架的水文模型组合预报研究[J]. 水电能源科学,2022,40(9):27-30. (DUAN Ya’ nan, LIANG Zhongmin, ZHAO Jianfei, et al. Combined forecasting of hydrological model

- based on Stacking integrated framework [J]. Water Resources and Power, 2022, 40(9): 27-30. (in Chinese))
- [14] 宋晓猛, 张建云, 占车生, 等. 气候变化和人类活动对水文循环影响研究进展[J]. 水利学报, 2013, 44(7): 779-790. (SONG Xiaomeng, ZHANG Jianyun, ZHAN Chesheng, et al. Review for impacts of climate change and human activities on water cycle[J]. Journal of Hydraulic Engineering, 2013, 44(7): 779-790. (in Chinese))
- [15] NEARING G S, KRATZERT F, SAMPSON A K, et al. What role does hydrological science play in the age of machine learning? [J]. Water Resources Research, 2021, 57(3): e2020WR028091.
- [16] 熊怡, 周建中, 孙娜, 等. 基于自适应变分模态分解和长短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))
- [17] GAO Weizhi, LIAO Yaoxing, CHEN Yuhong, et al. Enhancing transparency in data-driven urban pluvial flood prediction using an explainable CNN model[J]. Journal of Hydrology, 2024, 645: 132228.
- [18] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven earth system science[J]. Nature, 2019, 566(7743): 195-204.
- [19] YANG Shuyu, YANG Dawen, CHEN Jinsong, et al. A physical process and machine learning combined hydrological model for daily streamflow simulations of large watersheds with limited observation data [J]. Journal of Hydrology, 2020, 590: 125206.
- [20] 欧阳文宇, 叶磊, 顾学志, 等. 深度学习水文预报研究进展综述 II: 研究进展及展望[J]. 南水北调与水利科技 (中英文), 2022, 20(5): 862-875. (OUYANG Wenyu, YE Lei, GU Xuezhi, et al. Review of deep learning for hydrological forecasting II: research progress and prospect [J]. South-to-North Water Transfers and Water Science & Technology, 2022, 20(5): 862-875. (in Chinese))
- [21] KUMANLIOGLU A, FISTIKOGLU O. Closure to “performance enhancement of a conceptual hydrological model by integrating artificial intelligence” by Ahmet Ali Kumanlioglu and Okan Fistikoglu [J]. Journal of Hydrologic Engineering, 2020, 25(9): 07020019.
- [22] BOUCHER M A, QUILTY J, ADAMOWSKI J. Data assimilation for streamflow forecasting using extreme learning machines and multilayer perceptrons [J]. Water Resources Research, 2020, 56(6): e2019WR026226.
- [23] CHO K, KIM Y. Improving streamflow prediction in the WRF-Hydro model with LSTM networks [J]. Journal of Hydrology, 2022, 605: 127297.
- [24] XIE Kang, LIU Pan, ZHANG Jianyun, et al. Physics-guided deep learning for rainfall-runoff modeling by considering extreme events and monotonic relationships [J]. Journal of Hydrology, 2021, 603: 127043.
- [25] TAJIKI M, SCHOUPS G, FRANSSEN H J H, et al. Recursive Bayesian estimation of conceptual rainfall-runoff model errors in real-time prediction of streamflow [J]. Water Resources Research, 2020, 56(2): e2019WR025237.
- [26] WANG Jiao, ZHAO Lu, HAN Dawei, et al. Hydrological model adaptability to rainfall inputs of varied quality [J]. Water Resources Research, 2023, 59(2): e2022WR032484.
- [27] 葛守西, 程海云, 李玉荣. 水动力学模型卡尔曼滤波实时校正技术[J]. 水利学报, 2005, 36(6): 687-693. (GE Shouxi, CHENG Haiyun, LI Yurong. Real time updating of hydrodynamic model by using Kalman filter [J]. Journal of Hydraulic Engineering, 2005, 36(6): 687-693. (in Chinese))
- [28] 崔震, 郭生练, 王俊, 等. 基于混合深度学习模型的洪水过程概率预报研究[J]. 水利学报, 2023, 54(8): 889-897. (CUI Zhen, GUO Shenglian, WANG Jun, et al. Probabilistic forecasting of flood processes based on hybrid deep learning models [J]. Journal of Hydraulic Engineering, 2023, 54(8): 889-897. (in Chinese))
- [29] 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))
- [30] 许桉晨, 崔双喜, 邓顺黎. 基于时间序列分析与预测的电气互联综合能源系统运行风险评估[J]. 智慧电力, 2024, 52(11): 40-47. (XU Anchen, CUI Shuangxi, DENG Shunli. Operational risk assessment of electricity-gas interconnected integrated energy system based on time series analysis and prediction [J]. Smart Power, 2024, 52(11): 40-47. (in Chinese))
- [31] 金方承, 姜建国. 基于改进核密度估计的光伏发电功率区间预测[J]. 电子设计工程, 2024, 32(24): 36-41. (JIN Fangcheng, JIANG Jianguo. Photovoltaic power generation power interval prediction based on improved kernel density estimation [J]. Electronic Design Engineering, 2024, 32(24): 36-41. (in Chinese))
- [32] ZHOU Yanlai, CUI Zhen, LIN Kangling, et al. Short-term flood probability density forecasting using a conceptual hydrological model with machine learning techniques [J]. Journal of Hydrology, 2022, 604: 127255.
- [33] CUI Zhen, ZHOU Yanlai, GUO Shenglian, et al. Effective improvement of multi-step-ahead flood forecasting accuracy through encoder-decoder with an exogenous input structure [J]. Journal of Hydrology, 2022, 609: 127764.

(下转第 131 页)

spring wheat in Western Loess Plateau based on DSSAT-CERES-Wheat Model [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53 (6) : 338-348. (in Chinese))

[33] 孟雨,田文仲,温鹏飞,等. 基于不同发育阶段协同的小麦品种抗旱性综合评判[J]. 作物学报,2023,49(2): 570-582. (MENG Yu, TIAN Wenzhong, WEN Pengfei, et al. Comprehensive evaluation of drought resistance of wheat varieties based on synergy of different developmental stages[J]. Acta Agronomica Sinica, 2023, 49 (2) : 570-582. (in Chinese))

[34] 李兴华,汪吴凯,杨特武,等. 节水抗旱稻发展现状、优势及需解决的主要问题[J]. 华中农业大学学报,2022, 41(1): 84-91. (LI Xinghua, WANG Wukai, YANG Tewu, et al. Development status, advantages and main problems to be resolved of water-saving and drought-resistant rice [J]. Journal of Huazhong Agricultural University, 2022, 41

(1):84-91. (in Chinese))

[35] 亢江飞,李林,方社法,等. 豫西地区大豆油菜间作抗旱保收的种植模式[J]. 大豆科技, 2021 (2) : 26-28. (KANG Jiangfei, LI Lin, FANG Shefa, et al. Planting pattern of soybean and oil sunflower intercropping in western Henan Province [J]. Soybean Science & Technology, 2021(2):26-28. (in Chinese))

[36] VICENTE-SERRANO S M, BEGUERÍA S, LÓPEZ-MORENO J I. A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index[J]. Journal of Climate, 2010, 23 (7) : 1696-1718

[37] ZHOU Zhaoqiang, SHI Haiyun, FU Qiang, et al. Assessing spatiotemporal characteristics of drought and its effects on climate-induced yield of maize in Northeast China [J]. Journal of Hydrology, 2020, 588: 125097. (收稿日期: 2025 - 03 - 07 编辑: 施业)

(上接第 114 页)

[34] MOORE R J. The probability-distributed principle and runoff production at point and basin scales [J]. Hydrological Sciences Journal, 1985, 30(2):273-297.

[35] PERRIN C, MICHEL C, ANDRÉASSIAN V. Improvement of a parsimonious model for streamflow simulation [J]. Journal of Hydrology, 2003, 279(1/2/3/4) : 275-289.

[36] 邓鹏鑫,王银堂,胡庆芳,等. GR4J 模型在赣江流域日径流模拟中的应用 [J]. 水文, 2014, 34 (2) : 60-65. (DENG Pengxin, WANG Yintang, HU Qingfang, et al. Application of GR4J in daily runoff simulation for Ganjiang River Basin [J]. Journal of China Hydrology, 2014, 34(2):60-65. (in Chinese))

[37] 白云鹏,郑爱民,王文川,等. 基于深度学习的山丘区中小河流洪水预报误差校正方法 [J]. 水文, 2025, 45 (1) : 37-44. (BAI Yunpeng, ZHENG Aimin, WANG Wenchuan, et al. Error correction method for flood forecasting of medium and small catchments in hilly areas based on deep learning [J]. Journal of China Hydrology, 2025, 45(1):37-44. (in Chinese))

[38] 张力,王红瑞,郭菲楠,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))

[39] 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))

[40] 徐冬梅,王亚琴,王文川. 基于 VMD-GRU 与非参数核密度估计的月径流区间预测方法及应用 [J]. 水电能源科学, 2022, 40 (6) : 1-5. (XU Dongmei, WANG Yaqin, WANG Wenchuan. Monthly runoff interval prediction method and application based on VMD-GRU and nonparametric kernel density estimation [J]. Water Resources and Power, 2022, 40(6):1-5. (in Chinese))

[41] KANG Yan, XIANG Yue, ZHANG Zishang, et al. A novel physical process-ensemble learning model framework with residual error decomposition to upskill daily runoff prediction [J]. Journal of Hydrology, 2025, 651:132565.

[42] 巴欢欢,郭生练,钟逸轩,等. 考虑降水预报的三峡入库洪水集合概率预报方法比较 [J]. 水科学进展, 2019, 30 (2) : 186-197. (BA Huanhuan, GUO Shenglian, ZHONG Yixuan, et al. Comparative study on probabilistic ensemble flood forecasting considering precipitation forecasts for the Three Gorges Reservoir [J]. Advances in Water Science, 2019, 30(2):186-197. (in Chinese))

[43] 刘成帅,解添宁,李文忠,等. 考虑径流过程量化的机器学习洪水预报模型 [J]. 水科学进展, 2024, 35 (3) : 420-429. (LIU Chengshuai, XIE Tianning, LI Wenzhong, et al. Machine learning-based flood forecasting models considering runoff process vectorization [J]. Advances in Water Science, 2024, 35(3):420-429. (in Chinese))

[44] 李步,田富强,李钰坤,等. 融合气象要素时空特征的深度学习水文模型 [J]. 水科学进展, 2022, 33 (6) : 904-913. (LI Bu, TIAN Fuqiang, LI Yukun, et al. Development of a spatiotemporal deep-learning-based hydrological model [J]. Advances in Water Science, 2022, 33(6):904-913. (in Chinese)) (收稿日期: 2025 - 02 - 28 编辑: 施业)