

引入质量守恒的 LSTM 模型在径流模拟中的应用及其可解释性分析

蒋 燕¹, 牛杰帆^{2,3,4}, 张 珂^{2,3,4,5,6,7}, 马御棠¹, 陈 凯¹

(1. 云南电网有限责任公司, 云南 昆明 650228; 2. 河海大学水灾害防御全国重点实验室, 江苏 南京 210098;
3. 河海大学水文水资源学院, 江苏 南京 210098; 4. 河海大学长江保护与绿色发展研究院, 江苏 南京 210098;
5. 中国气象局水文气象重点开放实验室, 江苏 南京 210098; 6. 水利部水利大数据重点实验室, 江苏 南京 210098;
7. 水利部水循环与水动力系统重点实验室, 江苏 南京 210098)

摘要:为评估引入质量守恒的长短期记忆网络(MC-LSTM)模型在径流模拟中的应用效果,以云南梨园流域和乌弄龙流域为例,采用 MC-LSTM 模型在不同预见期进行径流模拟,将其与标准长短期记忆网络(LSTM)模型和支持向量回归(SVR)模型进行对比,并基于 SHAP 方法探讨气象特征对 MC-LSTM 模型径流预测的贡献,分析模型的可解释性。结果表明:在无历史径流观测数据输入的情况下,MC-LSTM 模型与 LSTM 模型模拟精度优于 SVR 模型,MC-LSTM 模型在汛期性能略优于 LSTM 模型;纳入历史实测径流后,3 种模型在短预见期模拟中均表现出较高精度,随着预见期的延长,MC-LSTM 模型精度缓慢下降,但模型整体稳定,在中长预见期径流模拟过程中,MC-LSTM 模型相较 LSTM 模型和 SVR 模型表现良好;梨园流域和乌弄龙流域径流预测的主要影响因素分别为气温和降水,主导气象因子的差异反映了不同流域的产流过程特征差异,MC-LSTM 模型的可解释性分析有助于进一步明晰流域产流机制。

关键词:径流预测;LSTM 模型;深度学习模型;质量守恒;梨园流域;乌弄龙流域

中图分类号:TV124

文献标志码:A

文章编号:1004-6933(2025)06-0149-09

Runoff simulation based on mass-conserving LSTM model and its interpretability analysis//JIANG Yan¹, NIU Jiefan^{2,3,4}, ZHANG Ke^{2,3,4,5,6,7}, MA Yutang¹, CHEN Kai¹(1. Yunnan Power Grid Co., Ltd., Kunming 650228, China; 2. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China; 3. College of Hydrology and Water Resources, Hohai University, Nanjing 210098, China; 4. Yangtze Institute for Conservation and Development, Hohai University, Nanjing 210098, China; 5. China Meteorological Administration Hydro-Meteorology Key Laboratory, Nanjing 210098, China; 6. Key Laboratory of Water Big Data Technology of Ministry of Water Resources, Nanjing 210098, China; 7. Key Laboratory of Hydrologic-Cycle and Hydrodynamic-System of Ministry of Water Resources, Nanjing 210098, China)

Abstract: To evaluate the application effectiveness of the mass-conserving long short-term memory (MC-LSTM) model in runoff simulation, taking the Liyuan and Wunonglong basins in Yunnan Province as examples, the MC-LSTM model was employed to simulate runoff under different lead times, and it was compared with the standard long short-term memory (LSTM) and support vector regression (SVR) models. Furthermore, the SHAP (Shapley additive explanations) method was applied to explore the contribution of meteorological features to the runoff prediction of the MC-LSTM model and to analyze the interpretability of the model. The results show that, without the input of historical runoff observation data, the simulation accuracy of the MC-LSTM and LSTM models is superior to that of the SVR model, and the MC-LSTM model slightly outperforms the LSTM model during the flood season. When historical runoff observation data are included, the three models show high accuracy in short-term simulations. As the lead time increases, the accuracy of the MC-LSTM model declines gradually, but the model remains stable and performs better than the LSTM and SVR models in medium- to long-term runoff simulations. The main influencing factors of runoff prediction in the Liyuan and Wunonglong basins are temperature and precipitation, respectively. These differences in dominant factors reflect the distinct characteristics of

基金项目:中国南方电网云南电网有限责任公司科技项目(YNKJXM20222329);国家重点研发计划项目(2023YFC3006500);国家自然科学基金项目(52009028);中央高校基本科研业务费专项资金项目(B240203007)

作者简介:蒋燕(1981—),女,高级工程师,硕士,主要从事水电调度与发供电平衡研究。E-mail:jiangyan@dltd.yn.csg.cn

通信作者:牛杰帆(1997—),女,博士研究生,主要从事水文水资源研究。E-mail:jiefanniu@hhu.edu.cn

runoff generation processes in different basins, and the interpretability analysis of the MC-LSTM model helps clarify the mechanisms of runoff generation.

Key words: runoff prediction; LSTM model; deep learning model; mass conservation; the Liyuan Basin; the Wunonglong Basin

降雨径流模拟与预报在水资源管理、防洪减灾等领域发挥着关键作用^[1-2],准确预测流域径流对于洪水风险评估及防洪决策至关重要^[3-4]。水文模型作为揭示水文过程时空变化规律的重要工具,广泛应用于水文现象的机理研究,通常分为过程驱动模型和数据驱动模型^[5]。过程驱动模型通过明确和相对固定的物理关系描述水文现象,但在实际应用过程中需要大量数据进行参数率定,导致模型复杂度高且耗时长^[6-7]。数据驱动模型擅长从数据中挖掘模式,无需流域的先验知识,能够从多角度捕捉水文数据中的复杂非线性关系,具有强大的仿真能力^[8-11]。

自 20 世纪末以来,随着水文实测、遥感遥测和高分辨率地形等数据的不断积累,水文大数据资源日益丰富^[5,12],基于海量数据基础,机器学习与深度学习等人工智能技术在水文模拟中的应用取得了一系列突破性进展^[13-16]。Kratzert 等^[17]在 CAMELS (catchment attributes and meteorology for large-sample studies)数据集的 241 个流域中应用长短时记忆网络(long short-term memory, LSTM)模型进行径流模拟,模型表现优于萨克拉门托模型和 VIC (variable infiltration capacity)等传统基于物理机制的水文模型;徐源浩等^[18]采用 LSTM 构建了不同预见期的暴雨洪水模型,并在黄河中游洪水模拟中发现 6 h 预见期内预报精度较高;张珂等^[19]探究了不同洪水预报智能模型在我国半干旱半湿润区的应用效果,研究发现支持向量机(support vector machine, SVM)模型整体稳定,在小流域实时洪水预报中具有明显优势;田焘等^[20]比较了多种 LSTM 变体模型在径流预报中的应用效果,结果表明增加有效的水文气象变量输入可改善预测效果,输入变量比模型结构的差异对预测结果的影响更显著。

国内外研究表明,深度学习模型在水文大数据整合与建模灵活性方面具有显著优势^[21],但由于其“黑箱”特性及缺乏物理机制支持,在预测数据超出训练范围时,模型性能和可解释性往往显著下降^[22]。因此,物理机制与深度学习模型的融合已成为水文模拟领域的重要研究方向^[23-24]。Xie 等^[25]将降雨径流预报过程中涉及的 3 种物理条件编码引入 LSTM 模型的损失函数,结果表明该模型与标准 LSTM 模型相比,整体精度有所提升,其峰值预报能力也进一步增强;Wang 等^[26]将物理规律与专家经验融合,构建了物理机制驱动的神经网络 TgNN,其

预测性能明显优于传统深度学习模型;Lu 等^[27]提出了正则化与物理引导的 LSTM 模型,该模型在融雪影响和非融雪流域的应用中表现出良好的泛化能力,受水文变率的影响较小。

当前物理机制-深度学习融合方法主要依赖于引入损失函数的物理约束或耦合专家经验规则等“软约束”方式,但此类方法难以严格保障模型的物理一致性^[28]。本文选用引入质量守恒的长短时记忆网络(mass-conserving LSTM, MC-LSTM)模型进行径流模拟,通过单元状态更新,显式地嵌入质量守恒机制,在模型架构层面实现物理守恒。将 MC-LSTM 模型与 LSTM 模型和支持向量回归(support vector regression, SVR)模型进行对比,研究不同模型结构对预测结果的影响,评估 MC-LSTM 模型在不同预见期下的径流预测性能。针对 MC-LSTM 模型不同输入与预测结果的关系,采用 SHAP (Shapley additive explanations)方法分析输入气象特征对 MC-LSTM 模型预测的贡献程度,对 MC-LSTM 模型进行可解释性分析。

1 研究区概况与数据来源

1.1 研究区概况

选取梨园流域和乌弄龙流域作为研究区(图 1)。梨园流域位于金沙江水系石鼓断面上游(26°N~36°N, 90°E~102°E),地处云贵高原西北部和四川盆地西部,河流发源于青海省西南部沱沱河,沿途流经青藏高原、四川省,最后流入云南省。梨园流域总面积约为 21.4 万 km²,海拔为 1674~6293 m,地势自西北向东南逐渐降低,流域气候复杂




图 1 研究区概况

Fig. 1 Overview of study area

多变,属于半干旱气候区,受高原季风和副热带季风的显著影响,多年平均降水量为 462 mm;径流深年际变化较大,年内分布不均,径流主要由降雨、融雪及冰川融水补给。乌弄龙流域位于澜沧江上游(27°N~34°N,93°E~101°E),源自青藏高原唐古拉山脉,总面积约为 7.6 万 km²,自北向南呈狭长带状分布,海拔为 1 889~6 372 m,地形特点为西北高、东南低。受高原山地气候影响显著,乌弄龙流域雨季集中在 5—10 月,气候特点为低温少雨,下游降水相对较多,年均降水量为 541 mm。

1.2 数据来源

输入的气候变量包括流域日平均降雨数据、气温数据、雪深数据,输出变量为流域日平均径流量。研究区降水和气温数据来源于中国气象信息中心提供的气象数据,空间分辨率为 5 km;雪深的时空分布数据来源于中国雪深长序列数据集(<https://data.tpdc.ac.cn/>),空间分辨率为 25 km,采用双线性插值法将雪深数据降尺度至 5 km 网格;流域出口断面的实测流量数据来自梨园水文站和乌弄龙水文站的入库实测数据。计算流域各气候变量的面平均值时,将时间序列按照 7:3 的比例划分为模型训练集和验证集。梨园流域采用 2010—2020 年日数据作为训练样本,2021—2023 年日数据作为验证样本。乌弄龙流域则采用 2019—2021 年日数据作为训练样本,2022—2023 年日数据作为验证样本。图 2 为研究区训练期和验证期降雨-径流时间序列。




图 2 研究区降雨-径流时间序列

Fig. 2 Time series of rainfall-runoff in study area

2 研究方法

2.1 径流模拟模型

LSTM 是一种经过特殊设计的递归神经网络,

其核心优势在于通过记忆单元和门控机制有效解决长序列数据处理中梯度消失和梯度爆炸问题^[29]。通过引入质量守恒约束的 LSTM 新架构^[30],将 MC-LSTM 模型运用于径流预测中可以确保降雨-径流模拟中水量的守恒^[31]。MC-LSTM 模型结合了 LSTM 模型的强大序列建模能力和水文过程中的水量平衡要求,使用归一化激活函数,并从存储质量中减去输出质量,从而在 LSTM 架构中强制执行守恒定律。

SVM^[32-33]是基于 VC 维理论和结构风险最小的监督学习算法。标准 SVM 通过构建最大间隔超平面实现分类任务优化,对于非线性可分问题,引入核函数将原始空间映射到高维特征空间以线性化决策边界。在回归领域,其扩展形式 SVR 模型采用不敏感损失函数,通过控制预测误差容忍度实现回归曲面拟合,其优势在于通过核函数高效处理水文时间序列的非线性特征,并避免过拟合风险。

2.2 数据预处理和模型构建

LSTM 模型的所有输入变量通过归一化方法进行缩放。基于流域积雪消融周期的特点,积雪形成消融周期约为 7 月;经过多次调整序列长度试验,LSTM 模型序列长度设定为 210 d;超参数通过贝叶斯优化方法进行选择,损失函数为实测径流与预测径流的均方根误差(RMSE);模型采用 Adam 优化器训练,对学习率进行自适应调整,并结合早停和 Dropout 策略以防止过拟合。在 MC-LSTM 模型中,气温与雪深等辅助输入变量同样经过归一化处理,而降水量作为质量输入保留其原始值;由于 MC-LSTM 模型需要满足水量守恒,Dropout 策略可能影响水量计算,故仅采用早停策略。为确保模型的可比性,MC-LSTM 模型的超参数设置与 LSTM 模型保持一致。SVR 模型所有输入变量通过归一化方法进行缩放,超参数使用贝叶斯优化方法进行优选,核函数选用径向基函数。

2.3 精度评价指标

本文主要采用预测值与观测值的偏差(Bias)、皮尔逊相关系数(r)、纳什效率系数(NSE)、Kling-Gupta 效率系数(KGE)和极端流量偏差等指标评价验证期内模型的预测性能。Bias 衡量预测值与观测值的平均偏差; r 反映二者之间的线性相关性;NSE 用于比较残差与观测数据方差的相对大小;KGE 融合了预测与观测值相关性、相对变异性(预测与观测值标准差之比)和偏差,综合评估水文模型性能。此外,还使用最高 2% 流量范围的偏差百分比(FHV)和最低 30% 流量范围的偏差百分比(FLV)分别评价模型在洪峰流量和基流范围内的表现。

2.4 可解释性分析方法

SHAP 方法是基于博弈论的模型解释方法,能够量化各输入特征对模型预测的贡献^[34]。其核心为基于 SHAP 值评估每个特征在多特征环境中的边际贡献,确保解释具有公平性、一致性和模型无关性。SHAP 值适合用于分析和解释神经网络模型中的复杂关系^[35],SHAP 值越大,说明该特征值对模型预测结果越重要。

3 结果与分析

3.1 无历史径流输入情况下模型模拟精度评价与比较

为探讨 LSTM、MC-LSTM、SVR 模型在梨园流域和乌弄龙流域径流模拟的适用性,采用贝叶斯优化方法对 LSTM 模型超参数进行优选。为了便于模型对比,MC-LSTM 模型的参数设置中除了 Dropout 率,其他参数与 LSTM 模型相同,表 1 为 LSTM 模型超参数设置。SVR 模型使用贝叶斯优化方法进行参数优选,最终选取梨园流域误差项惩罚函数和 γ 值分别为 10.93 和 0.29,乌弄龙流域分别为 9.16 和 0.65。为探讨模型气候驱动-径流响应的映射能力,排除径流自回归特征的干扰,不采用径流量的历史观测信息作为模型输入,而采用流域日平均降雨数

表 1 LSTM 模型超参数设置

Table 1 Hyperparameter setting for LSTM model						
流域	批次数	初始学习率	训练批次 时段长度/d	隐含层 单元数	Dropout 率	训练 代数
梨园	32	0.01	210	32	0.1	80
乌弄龙	16	0.01	210	32	0.1	50

表 2 验证期模型模拟精度对比

Table 2 Comparison of model simulation accuracy during validation period							
模型	流域	Bias/(m ³ /s)	NSE	FHV/%	FLV/%	r	KGE
LSTM	梨园	-95.77	0.81	-33.74	-0.27	0.94	0.72
	乌弄龙	-30.22	0.87	-11.99	-0.12	0.93	0.93
MC-LSTM	梨园	-106.16	0.80	-30.92	-19.50	0.95	0.70
	乌弄龙	47.32	0.84	-9.27	-11.87	0.92	0.91
SVR	梨园	37.67	0.58	-46.37	52.27	0.76	0.69
	乌弄龙	-27.96	0.51	26.50	-52.63	0.71	0.62




图 3 验证期模拟径流过程对比

Fig.3 Comparison of simulated runoff processes during validation period

据、气温数据、雪深数据作为模型输入,输出变量为流域日平均径流量。

采用梨园流域和乌弄龙流域数据分别对 LSTM、MC-LSTM、SVR 模型进行训练,使用训练好的模型进行验证期径流模拟,表 2 为 3 种模型验证期模拟精度对比,总体来看,LSTM 和 MC-LSTM 模型的表现优于 SVR 模型(图 3)。LSTM 和 MC-LSTM 模型在两个流域中的表现均较为理想,且在乌弄龙流域的模拟精度略优于梨园流域,两模型在验证期的 NSE 均大于 0.8,r 超过 0.92,表明其在捕捉融雪径流过程方面具有较高的准确性。SVR 模型模拟结果相对较差,NSE 约为 0.55,KGE 约为 0.65,径流过程呈现较大的波动性,梨园流域的模拟结果优于乌弄龙流域。引入质量守恒约束后,MC-LSTM 模型在汛期的表现略优于 LSTM 模型,梨园流域和乌弄龙流域的 FHV 分别为-30.92%和-9.27%;然而在枯水期,LSTM 模型的表现优于 MC-LSTM 模型,FLV 分别为-0.27%和-0.12%。这表明 MC-LSTM 模型通过质量守恒约束损失了部分灵活性以增强物理一致性。这种约束可能导致模型对训练数据中随机噪声的适应性降低,但提升了物理过程的一致性和模型结果的可靠性。

3.2 历史径流输入情况下不同预见期模型模拟精度对比

为进一步探究不同预见期模型的性能,分别选取 1、3、5、7、15、30d 预见期,在不同历史径流数据作为输入的条件下,对 3 种模型进行训练与验证,表 3 统计了不同预见期 3 种模型模拟精度,不同预见期模型模拟径流过程如图 4 和图 5 所示。在加入历史

表 3 不同预见期模型模拟精度对比

Table 3 Comparison of model simulation accuracy for different lead times

模型	预见期/d	梨园流域						乌弄龙流域					
		Bias/(m ³ /s)	NSE	FHV/%	FLV/%	r	KGE	Bias/(m ³ /s)	NSE	FHV/%	FLV/%	r	KGE
LSTM	1	30.91	0.97	-3.40	0.74	1.00	0.98	24.36	0.97	-4.11	11.31	0.99	0.96
	3	-31.07	0.96	-11.95	2.27	0.98	0.94	11.03	0.94	-11.52	10.45	0.97	0.97
	5	-107.68	0.90	-19.71	3.71	0.96	0.84	29.85	0.88	-11.47	8.12	0.94	0.93
	7	-72.72	0.92	-18.87	9.02	0.97	0.85	-22.19	0.93	-13.87	5.38	0.96	0.94
	15	-221.95	0.80	-41.20	6.02	0.94	0.68	-26.13	0.86	-24.07	2.80	0.93	0.86
	30	-372.15	0.69	-45.18	3.30	0.95	0.56	-28.06	0.83	-14.84	5.44	0.95	0.86
MC-LSTM	1	48.25	0.92	-2.63	2.11	0.98	0.92	20.11	0.96	-4.06	9.95	0.98	0.91
	3	-43.79	0.84	-13.69	4.76	0.95	0.89	28.06	0.90	-8.80	5.36	0.95	0.95
	5	-76.52	0.85	-14.50	5.46	0.96	0.87	16.33	0.87	-14.42	8.00	0.94	0.89
	7	-67.77	0.82	-20.86	8.95	0.94	0.85	21.71	0.88	-12.13	8.71	0.94	0.91
	15	-102.83	0.80	-28.61	4.17	0.93	0.82	19.25	0.87	-18.78	6.71	0.93	0.89
	30	-131.46	0.76	-34.51	6.07	0.95	0.81	24.25	0.84	-16.11	7.64	0.94	0.88
SVR	1	66.71	0.96	-2.60	23.21	0.99	0.94	-46.78	0.95	-17.69	13.23	0.98	0.85
	3	37.06	0.94	-13.87	24.56	0.97	0.91	-59.93	0.87	-33.45	4.36	0.94	0.82
	5	49.26	0.89	-23.51	27.50	0.95	0.86	-49.48	0.81	-43.13	13.86	0.91	0.79
	7	65.42	0.85	-24.93	26.80	0.93	0.85	-58.73	0.76	-46.47	13.23	0.88	0.75
	15	-33.07	0.80	-34.84	28.18	0.90	0.80	-54.22	0.62	-49.91	9.56	0.80	0.70
	30	87.57	0.72	-43.47	26.03	0.85	0.80	-26.87	0.56	-51.15	21.82	0.75	0.67




图 4 梨园流域不同预见期模拟径流过程

Fig. 4 Simulated runoff processes of the Liyuan Basin for different lead times

径流数据后,3 种模型的模拟精度提升,并且在 30 d 预见期内,均能够较好地捕捉年内和年际的径流特征。随着预见期的延长,尽管模型仍能较好地捕捉年内和年际径流的总体规律,但在长预见期的条件下,模型的洪水模拟能力均有所下降。

从图 6 和图 7 可以看出,随着预见期的延长,模拟结果的离散度逐渐延长,模型精度下降。如表 3 所示,对于梨园流域,随着预见期的延长,3 种模型验证期 NSE 和 KGE 减小,Bias 增大。LSTM 和 SVR 模型在预见期为 1 d 和 3 d 时 NSE 均不小于 0.94,在预见期为 5 d 和 7 d 时 NSE 均不小于 0.85。在预见期为 1~7 d 时,MC-LSTM 模型模拟精度略低于

LSTM 和 SVR 模型,但 NSE 依然不小于 0.82。随着预见期的延长,LSTM 和 SVR 模型精度下降较为明显,NSE 下降速率较 1~7 d 预见期稍快;而 MC-LSTM 模型的 NSE 下降相对平稳,与短预见期(1~3 d)下降速率相当。在 15 d 预见期时,3 种模型的 NSE 均为 0.80,而 MC-LSTM 模型的 KGE 略大于 LSTM 和 SVR 模型,且 MC-LSTM 模型的 FHV 和 FLV 保持在较稳定的水平,分别为 -28.61% 和 4.17%。在 30 d 预见期时,MC-LSTM 模型表现更为优越,NSE 依然保持在 0.76;相同预见期 LSTM 和 SVR 模型的 NSE 分别为 0.69 和 0.72,LSTM 和 SVR 模型的 FHV 与 MC-LSTM 偏差较大。




图5 乌弄龙流域不同预见期模拟径流过程

Fig. 5 Simulated runoff processes of the Wunonglong Basin for different lead times




图6 梨园流域验证期径流量散点图

Fig. 6 Scatter plots of runoff during validation period for the Liyuan Basin

对于乌弄龙流域,3种模型在预见期为1d和3d时模拟精度较高,LSTM模型的NSE不小于0.94,SVR模型的NSE不小于0.87,MC-LSTM模型NSE在两者之间。在预见期为5d和7d时,MC-LSTM和LSTM模型精度缓慢下降,NSE仍不小于0.87,FHV和FLV数值相当;而SVR模型的精度下降速度较快,Bias较大,在预见期为7d时NSE为0.76,FHV和FLV分别为-46.47%和13.23%。随着预见期进一步延长,SVR模型的NSE下降速度显

著加快,而MC-LSTM和LSTM模型的精度下降较为平稳。在预见期为30d时,MC-LSTM模型的NSE为0.84,KGE为0.88,其精度优于LSTM模型,相同预见期SVR模拟精度较低,NSE仅为0.56。

综上所述,在加入历史径流作为输入后,3种模型在短预见期(1~3d)模拟中皆具有优秀的表现(NSE不小于0.87)。随着预见期延长,MC-LSTM模型的精度下降较为缓慢,FHV和FLV保持在较稳定的水平,在较长预见期(15~30d)模拟中具有较




图 7 乌弄龙流域验证期径流量散点图

Fig. 7 Scatter plots of runoff during validation period for the Wunonglong Basin

大优势,相较 LSTM 和 SVR 模型表现良好。

3.3 MC-LSTM 模型可解释性分析

为进一步探讨 MC-LSTM 模型径流预测与相关气象特征的相互作用机制,采用 SHAP 方法进行 MC-LSTM 模拟可解释性分析。图 8 为验证期内各气象因子样本的 SHAP 值,SHAP 值为正时表示该因素对径流有正向影响,SHAP 值为负时则表示负向影响,样本点颜色表示各样本对应特征值的大小。对于梨园流域,影响程度最大的气象因子为气温,其次为降水和雪深;对于乌弄龙流域,降水是主要影响因素,气温和雪深的重要性相对较低。整体来看,梨园流域降水样本的 SHAP 值集中在 0 附近,对径流预测有正向和负向贡献,但影响程度相对较小,表明




图 8 验证期气象特征对模型输出贡献

Fig. 8 Contribution of meteorological features to model output during validation period

降水对梨园流域径流预测的影响比较平稳;乌弄龙流域降水样本的 SHAP 值分布范围大,有较大的正向和负向贡献,说明降水对乌弄龙流域径流预测的影响显著。气温对梨园流域径流预测的影响显著,有较大的正向和负向贡献,大部分样本的 SHAP 值为正,表明气温升高可能直接导致径流量显著增加;气温对乌弄龙流域径流预测也具有一定影响,高温对径流有明显的正向效应,而低温对径流的影响不显著。雪深对梨园流域径流预测的影响主要集中在负向,特别是较小的雪深可能使积雪融化得较快,导致在较早时期径流量较大,但随着时间推移,后期没有足够的积雪继续补给径流,因此在降水和雪水资源不足的时期,径流量减少;雪深对乌弄龙流域径流预测的影响主要集中在正向,表明随着雪深增加,径流量随之增大,但其影响力仍不及降水和气温。综合来看,水文过程是多种气象因子共同作用的结果,不同流域的主导气象因子存在显著差异。梨园流域地势跨度较大,海拔范围广,径流形成受到多个过程的共同作用,气温作为主导气象因子,与融雪和冰川消融过程密切相关,气温的变化直接影响径流量的大小和时序分布。乌弄龙流域面积相对较小,表现出更强的降水主导特征,降水集中在下游地区,直接控制径流量的短期变化,而气温和雪深的作用相对次要。将 SHAP 方法应用于 MC-LSTM 模型能够有效捕捉水文过程的差异性,进而识别出各流域的主导气象因子,明晰流域产流机制。

4 结 论

- a. 在未使用历史径流观测信息作为模型输入的情况下,LSTM 和 MC-LSTM 模型均显著优于 SVR 模型。MC-LSTM 模型在汛期的径流预测能力较 LSTM 模型更强,能够更准确地刻画洪水过程,但在枯水期表现略逊于 LSTM 模型。
- b. 在纳入历史径流数据后,3 种模型在预见期较短时均表现出良好的模拟精度。随着预见期的延长,尽管 MC-LSTM 模型的模拟精度有所下降,但其稳定性和整体精度仍优于 LSTM 和 SVR 模型,尤其在 15~30 d 预见期范围内,MC-LSTM 模型表现出更好的适应性和泛化能力。
- c. 基于 SHAP 方法的 MC-LSTM 模型可解释性分析为理解不同流域的水文过程差异性提供了有效支持,有助于进一步明晰流域产流机制。

参考文献:

[1] WANG Sheng, ZHANG Ke, CHAO Lijun, et al. A new approach for gridded risk assessment of rainfall-triggered flood and landslide hazards over a large region based on coupled flood-landslide modelling and ensemble simulation [J]. Environmental Modelling & Software, 2024, 172: 105917.

[2] CHEN Xinyu, ZHANG Ke, LUO Yuning, et al. A distributed hydrological model for semi-humid watersheds with a thick unsaturated zone under strong anthropogenic impacts:a case study in Haihe River Basin[J]. Journal of Hydrology, 2023, 623: 129765.

[3] 姚成,李致家,张珂,等. 基于栅格型新安江模型的中小河流精细化洪水预报[J]. 河海大学学报(自然科学版), 2021, 49 (1): 19-25. (YAO Cheng, LI Zhijia, ZHANG Ke, et al. Fine-scale flood forecasting for small and medium-sized rivers based on Grid-Xin’ anjiang model [J]. Journal of Hohai University (Natural Sciences), 2021, 49(1) : 19-25. (in Chinese))

[4] 张珂,张企诺,陈新宇,等. 栅格新安江-地表地下双人工调蓄分布式水文模型[J]. 水资源保护, 2021, 37 (5): 94-101. (ZHANG Ke, ZHANG QINUO, CHEN XINYU, et al. Gridded Xin’ anjiang-dual anthropogenic above ground and underground regulation distributed hydrological model[J]. Water Resources Protection, 2021, 37(5): 94-101. (in Chinese))

[5] 刘昌军. 基于人工智能和大数据驱动的新一代水文模型及其在洪水预报预警中的应用[J]. 中国防汛抗旱, 2019, 29 (5): 11. (LIU Changjun. A new generation of hydrological model theory based on artificial intelligence and big data and its application in flood forecasting[J]. China Flood & Drought Management, 2019, 29 (5): 11.

(in Chinese))

[6] 张然,柴志勇,张婷,等. 基于机器学习模型的洪水预报研究进展[J]. 水利水电技术(中英文), 2023, 54 (11): 89-101. (ZHANG Ran, CHAI Zhiyong, ZHANG Ting, et al. Research progress of flood forecasting based on machine learning models [J]. Water Resources and Hydropower Engineering, 2023, 54 (11): 89-101. (in Chinese))

[7] WANG Zhaoli, LAI Chengguang, CHEN Xiaohong, et al. Flood hazard risk assessment model based on random forest[J]. Journal of Hydrology, 2015, 527: 1130-1141.

[8] 雷庆文,闫磊,巫晨煜,等. 基于 MK-SVM 和时序特征分析的月径流预报模型[J]. 水资源保护, 2024, 40 (6): 148-154. (LEI Qingwen, YAN Lei, WU Chenyu, et al. Monthly runoff prediction model based on MK-SVM and time series feature analysis [J]. Water Resources Protection, 2024, 40 (6): 148-154. (in Chinese))

[9] 欧阳文字,叶磊,王梦云,等. 深度学习水文预报研究进展综述 I : 常用模型与建模方法[J]. 南水北调与水利科技(中英文), 2022, 20 (4): 650-659. (OUYANG Wenyu, YE Lei, WANG Mengyun, et al. Review of deep learning on hydrological forecasting I : common models and applying methods[J]. South-to-North Water Transfers and Water Science & Technology, 2022, 20(4): 650-659. (in Chinese))

[10] 师鹏飞,赵酉键,徐辉荣,等. 融合相空间重构和深度学习的径流模拟预测[J]. 水科学进展, 2023, 34 (3): 388-397. (SHI Pengfei, ZHAO Youjian, XU Huirong, et al. Simulation and prediction of streamflow based on phase space reconstruction and deep learning algorithm [J]. Advances in Water Science, 2023, 34 (3): 388-397. (in Chinese))

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

[12] 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.

[13] XIANG Zhongrun, YAN Jun, DEMIR I. A rainfall-runoff model with LSTM-based sequence-to-sequence learning [J]. Water Resources Research, 2020, 56 (1): e2019WR025326.

[14] SEO B C, KRAJEWSKI W F, QUINTERO F. Multi-scale hydrologic evaluation of the national water model streamflow data assimilation[J]. Journal of the American Water Resources Association, 2021, 57 (6): 875-884.

[15] 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))
- [16] FENG Dapeng, FANG Kuai, SHEN Chaopeng. Enhancing streamflow forecast and extracting insights using long-short term memory networks with data integration at continental scales[J]. Water Resources Research, 2020, 56(9): e2019WR026793.
- [17] KRATZERT F, KLOTZ D, BRENNER C, et al. Rainfall-runoff modelling using long short-term memory (LSTM) networks[J]. Hydrology and Earth System Sciences, 2018, 22(11): 6005-6022.
- [18] 徐源浩, 邬强, 李常青, 等. 基于长短时记忆(LSTM)神经网络的黄河中游洪水过程模拟及预报[J]. 北京师范大学学报(自然科学版), 2020, 56(3): 387-393. (XU Yuanhao, WU Qiang, LI Changqing, et al. Simulation of the flood process in the middle reaches of the Yellow River by a long-short term memory (LSTM) neuro network[J]. Journal of Beijing Normal University (Natural Science), 2020, 56(3): 387-393. (in Chinese))
- [19] 张珂, 牛杰帆, 李曦, 等. 洪水预报智能模型在中国半干旱半湿润区的应用对比[J]. 水资源保护, 2021, 37(1): 28-35. (ZHANG Ke, NIU Jiefan, LI Xi, et al. Comparison of artificial intelligence flood forecasting models in China's semi-arid and semi-humid regions[J]. Water Resources Protection, 2021, 37(1): 28-35. (in Chinese))
- [20] 田烨, 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))
- [21] 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))
- [22] 金桂中, 陈国灿, 赵兰兰, 等. 基于多源预报残差的卡尔曼滤波校正技术[J]. 河海大学学报(自然科学版), 2024, 52(4): 1-4. (JIN Guizhong, CHEN Guocan, ZHAO Lanlan, et al. Kalman filter correction technique based on multi-source forecast residuals[J]. Journal of Hohai University (Natural Sciences), 2024, 52(4): 1-4. (in Chinese)).
- [23] RAZAVI S, HANNAH D M, ELSHORBAGY A, et al. Coevolution of machine learning and process-based modelling to revolutionize earth and environmental sciences: a perspective[J]. Hydrological Processes, 2022, 36(6): e14596.
- [24] DE BÉZENAC E, PAJOT A, GALLINARI P. Deep learning for physical processes: incorporating prior scientific knowledge[J]. Journal of Statistical Mechanics: Theory and Experiment, 2019, 2019(12): 124009.
- [25] 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.
- [26] WANG Nanzhe, ZHANG Dongxiao, CHANG Haibin, et al. Deep learning of subsurface flow via theory-guided neural network[J]. Journal of Hydrology, 2020, 584: 124700.
- [27] LU Dan, KONAPALA G, PAINTER S L, et al. Streamflow simulation in data-scarce basins using Bayesian and physics-informed machine learning models[J]. Journal of Hydrometeorology, 2021, 22(6): 1421-1438.
- [28] FANG Kuai, KIFER D, LAWSON K, et al. The data synergy effects of time-series deep learning models in hydrology[J]. Water Resources Research, 2022, 58(4): e2021WR029583.
- [29] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [30] YANG Haifeng, HU Juanjuan, CAI Jianghui, et al. A new MC-LSTM network structure designed for regression prediction of time series[J]. Neural Processing Letters, 2023, 55(7): 8957-8979.
- [31] 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))
- [32] RAGHAVENDRA N S, DEKA P C. Support vector machine applications in the field of hydrology: a review[J]. Applied Soft Computing, 2014, 19: 372-386.
- [33] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [34] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017: 4768-4777.
- [35] DÍAZ-RODRÍGUEZ N, LAMAS A, SANCHEZ J, et al. Explainable neural-symbolic learning (X-NeSyL) methodology to fuse deep learning representations with expert knowledge graphs: the MonuMAI cultural heritage use case[J]. Information Fusion, 2022, 79: 58-83.