DOI:10.13869/j.cnki.rswc.2026.06.025 CSTR:32311.14.rswc.2026.06.025
黄莉, 肖桂荣. 基于Ia-LSTM模型的汀江中上游降雨径流模拟与预测[J]. 水土保持研究,2026,33(6):189-200.
Huang Li, Xiao Guirong. Rainfall-runoff simulation and prediction in middle and upper reaches of Tingjiang River Basin based on Ia-LSTM model [J]. Research of Soil and Water Conservation,2026,33(6):189-200.

基于Ia-LSTM模型的汀江中上游降雨径流模拟与预测

黄 莉[1], 肖桂荣[1,2]
(1.福州大学 数字中国研究院(福建), 福州 350108;
2.福州大学 空间数据挖掘与信息共享教育部重点实验室, 福州 350108)

摘 要:[目的]融合物理机制与数据驱动优势构建径流预报模型,以提升洪水预报的物理可解释性与模拟稳健性,为流域洪水预警和防灾减灾提供技术参考。[方法]以汀江流域中上游为研究区,采用HEC-HMS水文模型对场次暴雨过程进行精细化模拟,系统分析了初始损失参数(Ia)的空间异质性及其对产流机制的调控作用;并将其作为物理特征参数嵌入LSTM输入层,构建了Ia-LSTM耦合预报模型。[结果](1)基于HEC-HMS优化的Ia值可有效表征流域降雨径流物理机制,不同场次下各子流域Ia呈现显著空间差异,其值受多因素协同调控;(2)HEC-HMS物理水文模型在洪峰捕捉和峰现时间同步上表现较为可靠,而LSTM数据驱动模型在整体径流过程趋势拟合上更具优势,表现出物理模型与数据模型在不同维度上的互补性;(3)Ia-LSTM模型显著提升了中短期降雨径流预报稳健性,随着预见期延长其性能衰减幅度远小于LSTM模型与BOLSTM模型,12 h预见期NSE仍达0.71,总体NSE精度为0.849。[结论]将产汇流物理参数Ia嵌入LSTM有效增强了数据驱动模型对降雨径流物理机制的表征能力,Ia-LSTM模型在提升中短期预报稳健性的同时,显著延缓了预见期延长导致的性能衰减。

关键词:径流; 初始损失; Ia-LSTM
中图分类号:P338 **文献标识码:**A **文章编号:**1005-3409(2026)06-0189-12

Rainfall-runoff simulation and prediction in middle and upper reaches of Tingjiang River Basin based on Ia-LSTM model

Huang Li[1], Xiao Guirong[1,2]
(1.*The Academy of Digital China (Fujian), Fuzhou University, Fuzhou* 350108, *China*; 2.*Key Laboratory of Spatial Data Mining and Information Sharing of Ministry of Education, Fuzhou University, Fuzhou* 350108, *China*)

Abstract: [**Objective**] This study aims to construct a runoff prediction model integrating physical mechanisms and data-driven advantages to enhance the physical interpretability and simulation robustness of flood prediction, thereby providing technical references for watershed flood early warning and disaster prevention and mitigation. [**Methods**] Taking the middle and upper reaches of the Tingjiang River Basin as the study area, the HEC-HMS hydrological model was employed to conduct refined simulations of individual heavy rainfall events. The spatial heterogeneity of the initial loss parameter (Ia) and its regulatory role in runoff generation mechanisms were systematically analyzed. Ia was then incorporated as a key physical parameter into the input layer of LSTM, establishing an Ia-LSTM coupled prediction model. [**Results**] (1) HEC-HMS-optimized Ia values effectively characterized the physical mechanisms of rainfall-runoff in the river basin. Significant spatial differences in Ia were observed across sub-basins during different individual events, and its values were jointly controlled by multiple synergistic factors. (2) The HEC-HMS physical hydrological model demonstrated reliable performance in peak

收稿日期:2025-11-10 **修回日期:**2025-12-20 **接受日期:**2026-01-08
资助项目:国家重点研发计划项目(2024YFD160130104);中国科学院战略性先导科技专项(A类)项目(XDA23100504)
第一作者:黄莉(2001—),女,江西宜春人,硕士研究生,研究方向为水文预报及模型研究。E-mail:wyqhaha@163.com
通信作者:肖桂荣(1972—),男,福建龙岩人,博士,研究员,主要从事地理信息系统、空间信息网络服务、政务数据可视化研究。E-mail:xiaogr@fzu.cn

capture and peak timing synchronization, while the LSTM data-driven model exhibited superior trend fitting capabilities for the overall runoff process, reflecting complementary strengths between physical and data models across different dimensions. (3) The Ia-LSTM model significantly enhanced the robustness of short- to medium-term rainfall-runoff prediction. Its performance degradation with extended lead times was substantially smaller than that of the LSTM and BOLSTM models. The NSE for a 12-hour lead time remained at 0.71, with an overall NSE of 0.849. [**Conclusion**] Embedding the physical parameter Ia of runoff generation and concentration into LSTM effectively enhances the capability of data-driven models to represent rainfall-runoff physical mechanisms. The Ia-LSTM model improves short- to medium-term prediction robustness while significantly mitigating performance degradation associated with lead time extension.

Keywords: runoff; initial loss; Ia-LSTM

全球气候变化导致极端强降水事件频发,山洪灾害正成为全球各类自然灾害的主要灾种[1]。中国近60%山洪灾害分布于东南低山丘陵平原及西南中低山高原盆地大区,其中致灾密度峰值区位于东南低山丘陵与平原过渡地带[2]。山丘区中小流域暴雨时空变化大、地形条件复杂且降雨-径流的非线性特征显著[3];外加区域社会经济发展限制,水雨情监测系统、洪灾预警机制均不完善等,导致山丘区中小流域山洪预报难度大、预报精度不高,洪涝灾害的暴露性和易损性强[4]。因此,高精度、高时效的洪水预报对洪水灾害防御具有重要意义。

依据水文运动物理机制的科学内涵与复杂程度,水文模型主要分为三大类别:集总式概念性模型、分布式水文模型以及数据驱动模型[5]。作为概念性模型的典型代表,新安江模型与GR4J模型借助相对简化的物理概念和经验公式,或采用具备物理意义的结构单元,对流域水文过程进行近似刻画[6]。而降雨径流转化机制极为复杂,概念性水文模型难以实现精准的多时段连续预报[7]。分布式物理模型具备严密的物理理论基础,充分考虑了各类变量与参数的空间异质性,水量及能量传输均可直接依据连续性控制方程求解,从而能够更为精确地刻画水文过程[8],如HEC-HMS模型、SWAT模型等。但分布式水文模型所需资料较为详细,计算过程过于复杂,且许多参数需通过复杂的率定过程确定[9]。上述两类模型主要聚焦于自然径流过程的模拟,其输入输出均为同一时刻的实测数据;对未来径流进行预报时,必须引入降雨预测、蒸发量、气温等外部数据,模型本身并不具备预见能力[10]。伴随人工智能技术的迅猛发展,基于数据驱动的水文预报模型应运而生,该类模型可有效应对非线性、非稳态时间序列问题。其中,长短期记忆神经网络(Long Short-Term Memory, LSTM)最具代表性,其成功克服了循环神经网络(Recurrent Neural Network, RNN)中常见的梯度爆炸或梯度消失等难题,凭借独特的时间序列捕捉能力与长期记忆功能,在多时段洪水预报领域中表现优异[11]。单输出的LSTM神经网络能够较好地模拟洪水过程及处理一定程度的噪声[12],但由于深度学习模型缺少物理机制支撑,未能考虑降雨径流转化机制,并常受输入变量可获得性的限制[13],预测结果的可解释性不足,且无法对预报不确定性进行量化评估[14]。

基于此,将水文模型物理约束强及结果可解释等优点,与深度学习模型强大的非线性映射能力结合,已成为国际水文研究的前沿方向之一[15]。Cui等[16]通过融合新安江(XAJ)模型、长短期记忆(LSTM)神经网络和混合密度网络(Mixture Density Network, MDN),在保持XAJ-LSTM-EDE模型预报精度的同时,量化预报洪水过程的不确定性,并获得合理可靠的置信区间和优良的概率预报性能。康艳等[17]基于HYMOD和GR4J等物理水文模型,引入LSTM对残差序列进行动态修正,以此构建出误差校正型融合预报架构;结果表明:相较于HYMOD,GR4J及LSTM等单一建模方案,融合模型在预报性能上展现出显著优势,纳什效率系数(Nash-Sutcliffe Efficiency Coefficient, NSE)增幅达3.66%~70.51%。Young等[18]将HEC-HMS水文模型的模拟输出作为反向传播神经网络(Back Propagation Neural Network, BPNN)与支持向量回归(Support Vector Regression, SVR)的辅助输入变量,构建两种物理-数据驱动耦合架构;结果表明该方法均能有效改善HEC-HMS模型的径流模拟精度。大量的研究和应用实践表明[19-20],融合物理机制的机器学习模型综合利用了数据驱动与物理驱动两种建模思路的优势,既保留了模型的可解释性,又充分利用机器学习等大数据方法提高了模型的精度和适用性。然而,现有相关研究大多以降雨、径流数据作为输入和输出进行机器学习模型训练,忽略了产汇流过程固有的涨退水特性[21]。而产流初损与径流起涨密切相关,起涨流量越大则初损越小[22]。此外,不同

场次洪水的成灾条件差异显著，前期降雨、土壤湿度等因素存在显著差异，将固定产流参数用于不同场次洪水模拟对精度有一定影响。

因此，本研究以汀江流域中上游地区为研究对象，基于 HEC-HMS 模型精细化模拟场次降雨径流过程，系统分析表征流域下垫面物理特性的初始损失参数的空间异质性及其对产流与汇流机制的影响。并将优化后的初始损失值（Ia）作为关键物理特征嵌入 LSTM 神经网络输入层，构建物理机制与数据驱动深度耦合的 Ia-LSTM 洪水预报模型，系统评估其在不同预见期下的径流预测性能。并与 LSTM、基于贝叶斯优化算法的 BOLSTM 模型进行对比，旨在深入探究物理引导的深度学习模型对洪水预报稳健性与泛化能力的有效性与应用潜力，为洪水预警、风险分析及水库防洪调度等提供相关科学依据。

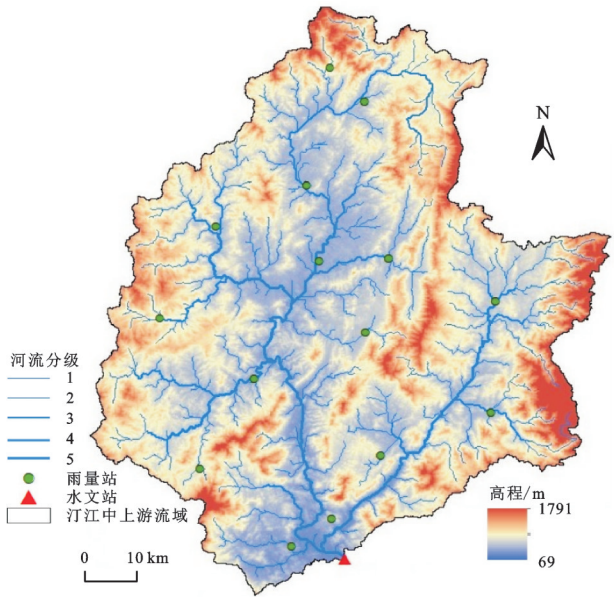
1　研究区域与数据

1.1　研究区概况

汀江为福建省第三大河流，位于东经 115°59′—117°10′，北纬 24°28′—26°02′，主干流流经长汀、武平、上杭、永定 4 县后流入广东省。汀江流域属中亚热带季风气候区且受副热带高压控制，年降雨量高峰在每年的 5—8 月，夏季多暴雨洪水且携带大量泥沙。流域中上游地区主要包括长汀县与上杭县，长汀县年均降水量 1 500 mm 以上，雨量充沛，且降水强度高，曾是我国南方典型的强水土流失区[23]。上杭县山峦重叠，河湖水系纵横交错，径流量变幅显著，流域面积 50 km²以上的河流有 26 条，多属于山区性河流。上杭水文站作为汀江流域主要控制站，汇集了上游曜田河、桃溪河、旧县河等多条支流来水，控制汀江流域集水面积达 5 888 km²（含本区外面积）。因此，本研究以汀江流域中上游地区为研究对象，选取上杭水文站作为流域典型监测断面，分析其以上集水区降雨径流情况（图 1）。

1.2　数据来源与预处理

研究选取上杭水文站及以上集水区内 15 个雨量站点 2017 年 6 月 1 日—2024 年 6 月 1 日逐时径流与降雨量数据用于训练及验证模型，数据来源于福建省水利厅，其中实测数据序列的前 80% 场次事件用于模型率定，后 20% 作为模型的检验数据。数字高程模型（Digital Elevation Model，DEM）源自地理空间数据云，分辨率为 30 m，使用 ArcGIS 裁剪得到研究区 DEM 高程数据；土壤数据来自世界土壤数据库（Harmonized World Soil Database，HWSD），其 1 km 分辨率的网格数据经重采样为 30 m 分辨率；土地利用数据采用武汉大学遥感信息处理研究所杨杰教授和黄昕教授团队发布的中国 30 m 分辨率土地覆盖数据。



注：基于标准地图服务系统下载的审图号 GS（2024）0650 号的标准地图制作，底图未做修改

图 1　研究区示意图

Fig. 1　Schematic diagram of study area

研究基于流域内多源、多尺度水文气象观测资料，开展暴雨洪水事件的系统性识别与质量控制。利用灰色关联度分析法量化各雨量站与出口水文站径流序列的动态响应关系，遴选关联度＞0.8 的 15 个代表性雨量站；统一时间步长为 1 h，并对原始降雨、径流数据进行异常值处理与数据去噪，确保序列连续性与物理一致性。基于泰森多边形法计算流域面平均雨量，并依据中国气象局对暴雨的定义，筛选 24 h 累积面雨量≥50 mm 或 12 h 累积面雨量≥30 mm 的场次暴雨事件作为模型输入降雨场次。经上述质量控制，最终筛选出 28 场独立暴雨事件，其流域面雨量为 51.02～311.66 mm，洪峰流量为 223.7～3 597 m³/s，样本兼具代表性、典型性与极端性，可支撑后续暴雨-洪水响应机制及模拟研究。

2　研究方法

2.1　HEC-HMS 模型

HEC-HMS 水文模型是常用于中小山区流域的分布式降雨径流模型，主要由 HEC-GeoHMS，HEC-DSSVue 和 HEC-HMS 三部分组成，采用松散耦合模式整合[24]，能有效利用模型的水文模拟功能和 GIS 软件的空间分析功能。依托物理机制的 HEC-HMS 可有效统筹考量降水特征、土壤属性及土地覆被等水文地质要素的空间异质性，借助数字高程信息沿水流方向将研究区划分为若干子汇水单

元;子流域数量越多越有助于提高模型模拟的准确性,但过度离散化将加剧参数率定难度、扩大不确定性范围,并显著增加运算成本[25]。各子单元水文特性经独立演算后,其产汇流成果沿模型识别的河道逐级传递,经河道洪水演进计算最终汇聚至流域出口断面,形成完整的径流时序过程[26]。HEC-HMS模型将流域水文响应分为产流、直接径流、基流及河道汇流4个部分,研究依据流域下垫面特征与数据需求,针对性地选择SCS-CN法、SCS单位线法、退水曲线法以及马斯京根法分别进行计算。

2.2 初始损失Ia

降雨初始损失量(Ia)指降雨初期尚未产生地表径流阶段,因下垫面土壤下渗、地表填洼及植被截留等作用而被消耗的部分降水,该部分损失量不直接参与后续汇流过程形成径流[27]。Ia的大小与土壤前期含水量、流域累积前期降雨量和土地利用类型等密切相关,并随降雨场次的不同呈现出明显的时空变异特征,即不同场次降雨的初损值存在较大差异。本研究中的初始损失值可由HEC-HMS模型中产流模块采用的SCS-CN法进行初步计算,该方法基于水量平衡方程和比例相等假设,依据累积降雨量、土地利用、土壤类型及前期土壤含水量等条件模拟计算产流量。计算公式如下:

$$\mathrm{Pe}=\frac{(P-\mathrm{Ia})^2}{P-\mathrm{Ia}+S}\quad(P\geqslant\mathrm{Ia}) \tag{1}$$

式中:Pe为净雨量(mm);P为累积降雨量(mm);Ia为初始损失(mm),包括植物截留、下渗和填洼等;S为流域可能的最大滞留量(mm)。

初始损失Ia与最大滞留量S之间存在经验关系,通常表示为:

$$\mathrm{Ia}=0.2S \tag{2}$$

参数S通过CN值确定,二者关系为:

$$S=\frac{5400}{\mathrm{CN}}-254 \tag{3}$$

CN值是SCS曲线法的关键参数,常用取值范围为40~98,值越大表明产流能力越强,具体CN值可通过相应查算表获取。依据流域特征将研究区划分为各个子流域,结合前期土壤含水量、土壤类型、土地利用及地形等数据在ArcGIS软件中进行叠加分析及像元加权平均计算,得到各子流域平均CN值。

2.3 LSTM模型

相较于传统循环神经网络,LSTM在隐含层结构中引入记忆细胞机制,有效克服时序建模与预测任务中的长期依赖难题,进而对具备周期性特征的时间序列实现精准的模式识别与信息抽取[14]。LSTM通过控制特征信息的流入流出和数据梯度流动,有效学习径流与径流影响因子间非线性非平稳关系。针对LSTM模型相关权重的更新幅度及模型过拟合等[28],需要选择合适的学习率、设置正则项等一系列超参数,研究选用贝叶斯优化算法(Bayesian Optimization, BO)实现LSTM模型超参数的自动优化。该方法通过构建概率模型对关键超参数进行全局最优搜索,并以验证集上的损失函数作为优化目标,从所有超参数候选解中选取函数值最大的超参数作为最优取值[29]。研究选取批次大小(batch size)、神经元数量(unit)、模型迭代次数(epoch)、学习率(learning rate)及丢弃率(dropout rate)作为优化参数,各优化参数的可选范围通过经验确定,采用均方误差(Mean Squared Error, MSE)作为算法损失函数,纳什效率系数评价模拟性能。最终确定BOLSTM模型最优超参数组合为epochs=182, batch_size=51, lstm_units=238, learning_rate=0.001, dropout_rate=0.27。降雨经产汇流过程流经流域出口断面,即上游降雨为出口断面径流量的主要来源,为研究神经网络模型对暴雨径流过程的模拟与预测效果,将模型输入确定为流域内15个雨量站实测降雨数据和上杭站前期径流量数据,输出为上杭站径流量数据。

2.4 Ia-LSTM模型

传统LSTM模型在降雨径流模拟中通常直接输入原始降水序列与流量序列,因缺乏明确的水文物理支撑,导致输入变量与输出结果之间的映射关系较为松散等问题。本研究提出一种物理机制与数据驱动相融合的Ia-LSTM混合架构,将水文循环中的关键物理概念——降雨初始损失量(Ia)以显式约束形式嵌入深度学习框架,通过以有效降雨量替代原始总雨量作为模型输入,强化输入特征与径流响应间的物理因果联系,进而同步提升模型的预测精度与机理可解释性。具体模型框架如图2所示,P为降雨量,Q为径流量。

3 结果与分析

3.1 Ia值计算与特征分析

为精确估算流域的初始损失(Ia),本研究基于流域DEM数据,结合河网分级分段方法,将研究区划分为10个子流域(W_{430}, W_{500}, W_{550}, W_{580}, W_{590}, W_{640}, W_{660}, W_{710}, W_{730}, W_{740})。在HEC-geoHMS模块中实现对流域网格划分、多边形处理、线性河网提取及子流域属性计算等过程,形成具有明确汇流关系的子流域概化模型作为HEC-HMS模型的基础输入数据(图3)。利用SCS-CN单位线法对Ia值进行初步估算,其关键参数包括子流域CN值、前期土壤含水量(AMC)

及流域坡度等。各子流域CN值通过融合土壤类型与土地利用数据,并参照TR-55手册中的曲线数查算表确定。前期土壤含水量依据场次降雨时间前5 d的降雨量划分干旱(AMCⅠ)、一般(AMCⅡ)和湿润(AMCⅢ)3种类型;初损值Ia则通过公式(2)和公式(3)初步计算得出;相关参数见表1。

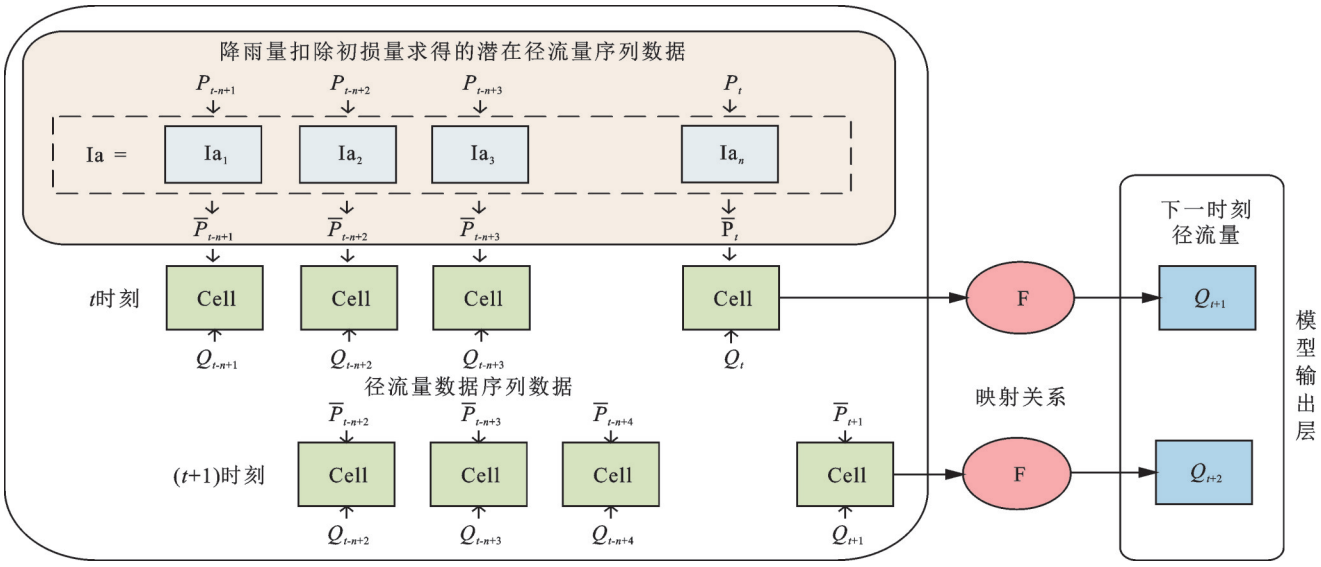


图2　Ia-LSTM模型结构示意图

Fig. 2　Schematic diagram of Ia-LSTM model structure

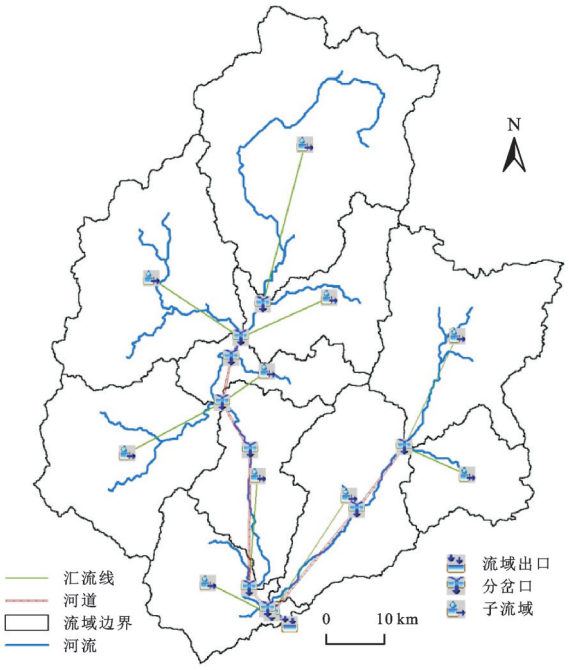


图3　研究区HEC-HMS模型概化图

Fig. 3　Schematic diagram of HEC-HMS model in study area

传统基于经验公式的Ia取值往往忽略降雨特性、土壤空间异质性及下垫面类型的局地差异,难以适应多场次洪水模拟的精度需求。为此,本研究进一步对各子流域Ia值进行场次暴雨事件的率定优化。具体而言,基于不同暴雨事件实测径流过程,以峰值加权均方根误差(Peak Weighted Root Mean Square Error, PWRMSE)作为目标函数,通过Nelder-Mead算法对Ia进行全局搜索与迭代优化,寻找使目标函数最小化的最优Ia值。该方法能够有效适应不同子流域在特定降雨条件下的空间变异特征,提高模型对实际降雨径流响应的模拟能力。优化后的Ia值因场次与子流域而异(表2),充分体现地形、土地利用、土壤类型、前期含水量及降雨特征等综合因素的影响。

表2为部分场次暴雨事件各子流域经优化后的最优初始损失值,其数值范围与空间分布具有显著的异质性。例如:F_1(暴雨时间20170625)场次中,子流域Ia值范围从6.4 mm到19.1 mm,变异系数较高,表明流域内下垫面条件的空间异质性显著;且数值相比于场次F_7(暴雨时间20210429,Ia值范围为13.2～24.6 mm)明显降低,即当前期土壤含水量较少时,降雨初始损失值较高。其次,在降雨量较大的场次F_2(总降雨量约179.1 mm)中,子流域W_{430}的Ia值为7.8 mm;而在降雨量较小的F_3(总降雨量约104.17 mm)中,Ia值为9.2 mm;呈现W_{430}的Ia值并未简单地随降雨量减小而单调递减的趋势,表明Ia的取值并非仅由降雨量单一因素决定。

实际上,Ia数值大小本质上是前期土壤湿度、土地利用、土壤类型、地形坡度及前期降水时空分布等多因素协同作用的结果,各因子通过改变流域下垫面的蓄水能力和水分再分配过程影响Ia的累积与消退。如土壤湿度决定下垫面对新增降水的接纳能力:若前期土壤已接近饱和(高湿度),新增降水更易

转化为地表径流，Ia对当前产流的启动阈值则更低。本研究区属红壤区，土壤田间持水量25%～30%，当Ia计算值接近该阈值时，模型对后续降雨的产流响应显著增强。其次，植被覆盖度高（如研究区森林覆盖率约78%）的林地，冠层截留和下渗能力强，前期降雨的水分损耗更大，Ia的累积速率相对较慢；而耕地或裸地占比高的区域，下渗能力弱、蒸散发损耗小，Ia更易累积至较高值。土壤类型（如研究区红壤黏粒含量较高，稳定渗透系数较低）决定下渗速率，进而影响Ia的消退速度。通过选用研究区土壤类型、土地利用类型、地形坡度和前期降雨量等多类物理参数对Ia值的协同影响，表明Ia不是一个静态参数，而是一个由多因子协同调控的动态变化的综合性物理特征。因此，合理量化并动态确定初始损失值Ia的空间异质性对准确刻画流域产流过程至关重要。通过分析不同场次、不同子流域的最优Ia值，有助于揭示多重因素耦合作用下的产流机制，进而提升径流模拟的精度与预报能力。

表1 各子流域物理属性

Table 1 Physical attributes of sub-basins

子流域	面积/km²	面积占比/%	AMCⅡ下的初始CN值	平均坡度/%
W_{430}	1126.44	19.13	67.41	12.84
W_{500}	433.10	7.36	71.9	13.28
W_{550}	857.10	14.56	70.23	13.36
W_{580}	244.33	4.15	73.49	16.45
W_{590}	773.33	13.13	71.83	14.38
W_{640}	447.92	7.61	74.33	15.06
W_{660}	687.57	11.68	70.71	14.24
W_{710}	309.93	5.26	76.9	16.97
W_{730}	607.39	10.32	71.7	14.81
W_{740}	400.89	6.81	68.57	12.28

表2 各场次暴雨事件中各子流域最优Ia值

Table 2 Optimal Ia values for each sub-basin during individual heavy rainfall events

场次	降雨量/mm	W_{430}	W_{500}	W_{550}	W_{580}	W_{590}	W_{640}	W_{660}	W_{710}	W_{730}	W_{740}
F_1	199.16	6.4	7.8	9.2	10.6	12.1	13.4	14.8	16.2	17.6	19.1
F_2	179.10	7.8	10.6	13.4	16.2	19.2	21.8	24.6	7.4	10.2	13.4
F_3	104.17	9.2	13.4	17.6	21.8	6.4	10.2	14.4	18.6	22.8	7.6
F_4	58.89	10.6	16.2	21.8	7.4	13.1	18.6	24.2	9.8	15.4	21.1
F_5	164.31	12.1	19.2	6.7	13.5	20.3	7.1	14.2	21.1	8.1	15.1
F_6	105.63	13.4	21.8	10.2	18.6	7.1	15.4	23.8	12.2	20.6	9.3
F_7	198.30	14.8	24.6	14.4	24.2	14.6	23.8	13.6	23.4	13.2	23.1
F_8	196.27	16.2	7.4	18.6	9.8	21.4	12.2	23.4	14.6	5.8	17.1
F_9	164.62	17.6	10.2	22.8	15.4	8.7	20.6	13.2	5.8	18.4	11.2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
F_{26}	88.18	21.4	17.8	14.2	10.6	7.9	23.4	19.8	16.2	12.6	9.7
F_{27}	138.86	22.8	20.6	18.4	16.2	14.1	11.8	9.6	7.4	5.2	23.1
F_{28}	71.19	24.2	23.4	22.6	21.8	21.1	20.2	19.4	18.6	17.8	17.2

3.2 单一模型模拟结果与分析

本研究以F_1—F_{22}共22场暴雨洪水场次进行模型率定，F_{23}—F_{28}共6场用于模型验证。依据《水文情报预报规范》要求，模拟场次判定为合格需同时满足洪峰流量与径流深相对误差小于20%，且峰现时间差在3 h以内。表3为HEC-HMS模型与LSTM模型对F_{23}—F_{28}暴雨事件的降雨径流过程模拟效果评价指标表，从纳什效率系数（NSE）、洪峰相对误差、峰现时差及径流深相对误差4个方面对模型模拟性能进行综合对比。

在整体合格率方面，HEC-HMS与LSTM模型合格率均为83.3%，其中，HEC-HMS在模拟F_{25}场次中因洪峰误差达－24.90% 而被判定为不合格；LSTM模型在F_{23}（NSE＝0.49，径流深误差25.58%）中模拟效果不合格。从关键指标来看，HEC-HMS在多数场次中NSE高于0.75，洪峰误差基本控制在±10%以内（除F_{25}外），峰现时间偏差不超过3 h，表明其在洪峰捕捉与过程同步性方面具有较好精度。LSTM模型虽在F_{24}，F_{25}与F_{28}中NSE较高（分别为0.88，0.85，0.92），但洪峰系统性偏高现象较明显，峰现时间亦存在多处滞后（F_{23}—F_{26}均为负偏差），表明其在极端响应与时间相位上仍存在优化空间。

图4为HEC-HMS与LSTM模型对验证集中场次F_{24}，F_{26}和F_{28}的模拟径流过程对比。HEC-HMS模型在模拟洪峰值及峰现时间上，效果相对更为理想；以场次F_{24}为例，其模拟洪峰数值、时间与实测峰值更贴近。相比之下，LSTM模型在模拟整个径流过程

趋势上更具优势,能够较好地拟合径流的涨落情况;但在场次F_{26}中的洪峰值表现上存在一定偏差,尤其在快速涨水阶段的响应略显滞后。总体而言,两种模型的模拟结果均能体现实际径流量的总体变化趋势,说明其在汀江流域中上游地区具有一定的适用性。HEC-HMS在结构上更注重水文过程的物理机制,适用于洪水峰值等关键的情景;而LSTM则体现出数据驱动模型在整体过程拟合上的稳定性。

表 3　HEC-HMS,LSTM 模拟效果评价指标系数

Table 3　Evaluation indicator coefficients of HEC-HMS and LSTM simulation performance

场次	HEC-HMS				LSTM			
	NSE	洪峰差/%	峰现时间差/h	径流差/%	NSE	洪峰差/%	峰现时间差/h	径流差/%
F_{23}	0.82	6.70	0	−2.08	0.49	10.85	−3	25.58
F_{24}	0.78	−9.74	+1	15.54	0.88	8.08	−3	−3.48
F_{25}	0.65	−24.90	+3	−9.48	0.85	9.94	−2	6.15
F_{26}	0.85	−4.19	−1	12.82	0.75	17.94	−1	9.58
F_{27}	0.80	9.40	−2	−10.70	0.70	12.46	+3	9.99
F_{28}	0.91	3.88	+1	−1.37	0.92	2.63	0	8.77

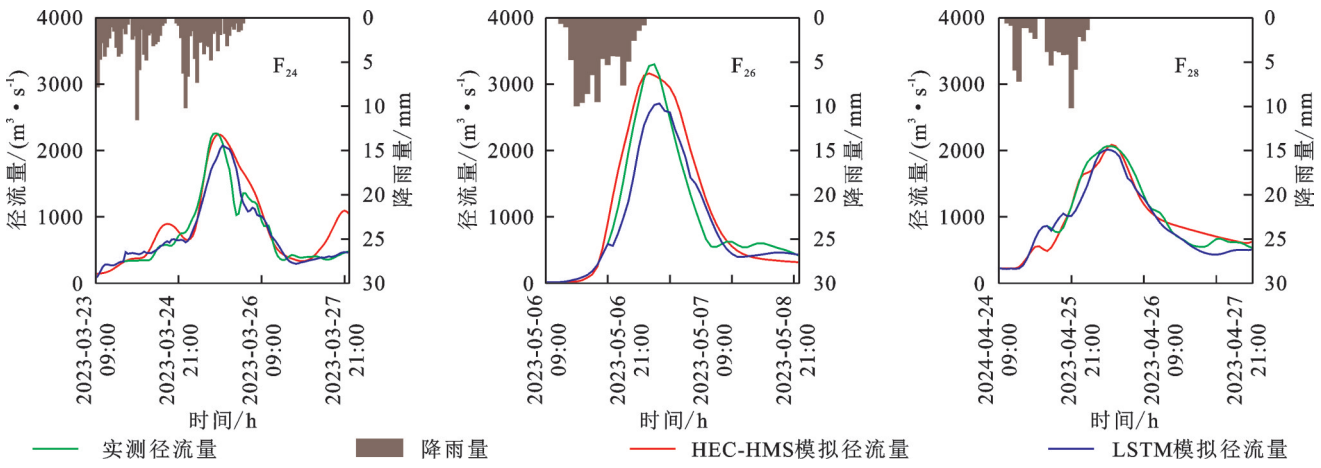


图 4　HEC-HMS,LSTM 对 F_{24},F_{26}及 F_{28}场次暴雨模拟效果对比

Fig. 4　Comparison of HEC-HMS and LSTM simulation performance for F_{24}, F_{26}, and F_{28} individual heavy rainfall events

3.3　Ia-LSTM 模型验证与总体性能分析

3.3.1　各模型模拟性能对比　为评估LSTM,BOLSTM及Ia-LSTM模型在不同预见期下对降雨径流预测中的总体性能,研究选用NSE,RMSE(均方根误差)和MAE(平均绝对误差)3类指标进行综合对比。由表4可知,随着预见期的延长,所有模型的总体预测精度均呈下降趋势,表现为RMSE与MAE逐渐增大,NSE系数逐渐降低。其中,LSTM模型在12 h预见期下的NSE降至0.64,RMSE增至321.37,表明其在较长预见期下模拟性能衰减明显。BOLSTM模型通过贝叶斯优化在一定程度上提升了中短预见期的稳定性,但在9 h后仍出现NSE低于0.7的情况。相比之下,Ia-LSTM模型在各预见期下均表现出更优且更稳定的预测能力。尤其在较长预见期(6~12 h)条件下,其NSE始终高于其他两类模型,12 h时仍保持在0.7以上;同时,其MAE与RMSE增长幅度更为平缓,在12 h时MAE为196.97 m^3/s,显著低于LSTM的248.99 m^3/s,证实Ia-LSTM模型对降雨径流预测具有更好的捕捉能力与泛化性能。

进一步结合不同预见期下各模型的预测散点图分析可得(图5),随着预见期延长,LSTM与BOLSTM的点据离散程度显著增大,尤其在9 h与12 h预见期下偏离1∶1参考线较远(9 h预见期下LSTM,BOLSTM和Ia-LSTM的决定系数分别为0.765,0.803,0.826;12 h下分别为0.743,0.776,0.812)。Ia-LSTM的点据在不同预见期下均能更紧密分布于对角线两侧,表明其模拟过程更为集中、偏差更小,说明引入初始损失参数有效增强模型对流域下垫面影响的刻画能力,进而提升模型在中长期径流预测中的准确性与可靠性。

3.3.2　典型降雨场次下Ia-LSTM模型预测分析　以典型降雨场次F_{24}在不同预见期下的预测效果为例,引入初始损失(Ia)物理参数的Ia-LSTM模型预测效果显著优于LSTM及BOLSTM模型(表5)。当预见期从1 h延长至12 h时,各模型NSE均呈下降趋势(Ia-LSTM,BOLSTM和LSTM分别下降0.343,0.4,0.434);但Ia-LSTM在各预见期下始终保持着相对最高NSE值,且Ia-LSTM模型衰减幅度明显更小。在预

见期9 h到12 h中，Ia-LSTM模型NSE下降仅9.38%，而BOLSTM和LSTM分别下降16.19%和21.44%；相比之下，基于贝叶斯优化算法的BOLSTM模型预测精度虽略优于基础LSTM，但仍不及Ia-LSTM。

表4 各模型在不同预见期下的预测评价指标

Table 4 Prediction evaluation indicator for each model under different lead times

模型	指标	系数					
		1 h	2 h	3 h	6 h	9 h	12 h
LSTM	RMSE	146.14	170.45	185.8	264.47	280.96	321.37
	MAE	107.7	127.65	139.63	188.23	209.19	248.99
	NSE	0.92	0.87	0.85	0.7	0.68	0.64
BOLSTM	RMSE	57.61	138.86	167.05	233.77	262.49	294.55
	MAE	40.41	107.83	125.27	172.93	196.84	233.23
	NSE	0.99	0.93	0.89	0.78	0.72	0.68
Ia—LSTM	RMSE	56.98	141.1	152.58	221.83	249.06	269.89
	MAE	40.47	101.58	111.89	160.82	191.44	196.97
	NSE	0.99	0.92	0.9	0.79	0.75	0.71

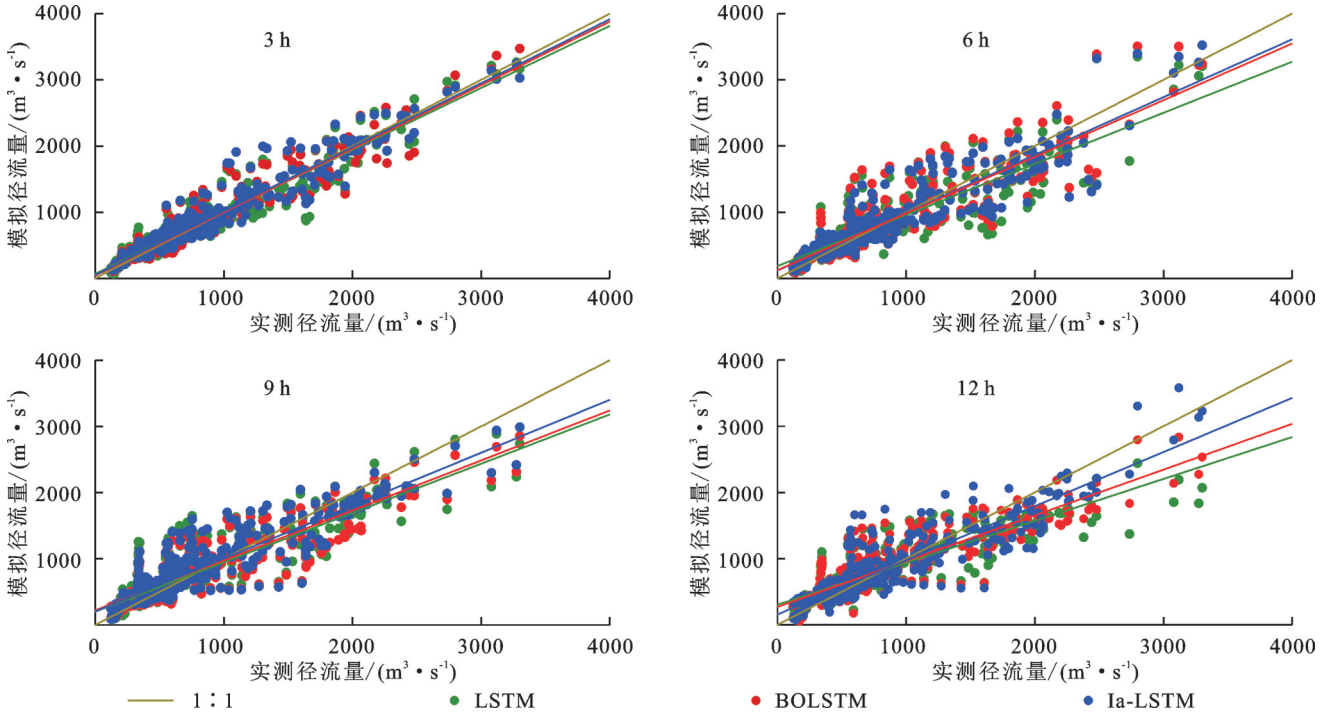


图5 各模型在不同预见期下的预测效果散点图

Fig. 5 Scatter plots of prediction performance under different lead times for each model

表5 Ia-LSTM，BOLSTM和LSTM对F_{24}场次暴雨在不同预见期下的NSE值

Table 5 NSE values of Ia-LSTM, BOLSTM, and LSTM for F_{24} heavy rainfall event under different lead times

预见期/h	LSTM	BOLSTM	Ia-LSTM
1	0.936	0.959	0.981
2	0.904	0.933	0.957
3	0.874	0.906	0.917
6	0.719	0.755	0.790
9	0.639	0.667	0.704
12	0.502	0.559	0.638

结合各模型在不同预见期下对F_{24}的预测过程对比分析可知（图6），在短预见期（1～3 h）下，各模型均能较好地捕捉径流变化过程。当预见期延长至6～12 h，LSTM与BOLSTM的预测过程线逐渐偏离实测轨迹，表现为洪峰系统性偏低，且涨水段拟合效果下降。而Ia-LSTM在融合表征下垫面影响的初始损失参数Ia后，其预测效果均更贴近实测径流曲线，在洪峰流量与过程形态的保持上表现良好。

3.3.3 Ia-LSTM总体预测精度分析 对各模型的总体预测精度进行综合评价，结果如图7和表6所示。图7NSE箱线图中Ia-LSTM模型的均值（0.849）与中位

数(0.893)均高于LSTM(0.777,0.796)和BOLSTM模型(0.828,0.867),且Ia-LSTM模型未出现NSE<0.6的异常指标;结合表6中NSE标准差结果,充分表明Ia-LSTM模型的预测精度更高且稳定性更好,受数据波动等因素影响较小,具有较强的鲁棒性。依据各模型预测评价指标系数误差可知(表6),Ia-LSTM模型在洪峰差与峰现时间差的均值及标准差方面均优于BOLSTM与LSTM模型,说明其在洪峰特征捕捉与时间对齐方面优势较为显著;而在总径流差方面,Ia-LSTM均值(1.404)高于BOLSTM(1.036)和LSTM(1.396)模型,标准差(1.159)高于BOLSTM(0.994),说明Ia-LSTM在整体径流总量预测方面略逊于BOLSTM模型,其原因可能与总径流受多因素综合影响有关,而BOLSTM通过参数调整在一定程度上优化了径流总量累计过程的拟合,而Ia-LSTM对长期径流总量平衡的精细化调控仍需进一步调优,但综合各方面表现,Ia-LSTM总体预测效果仍为最佳。

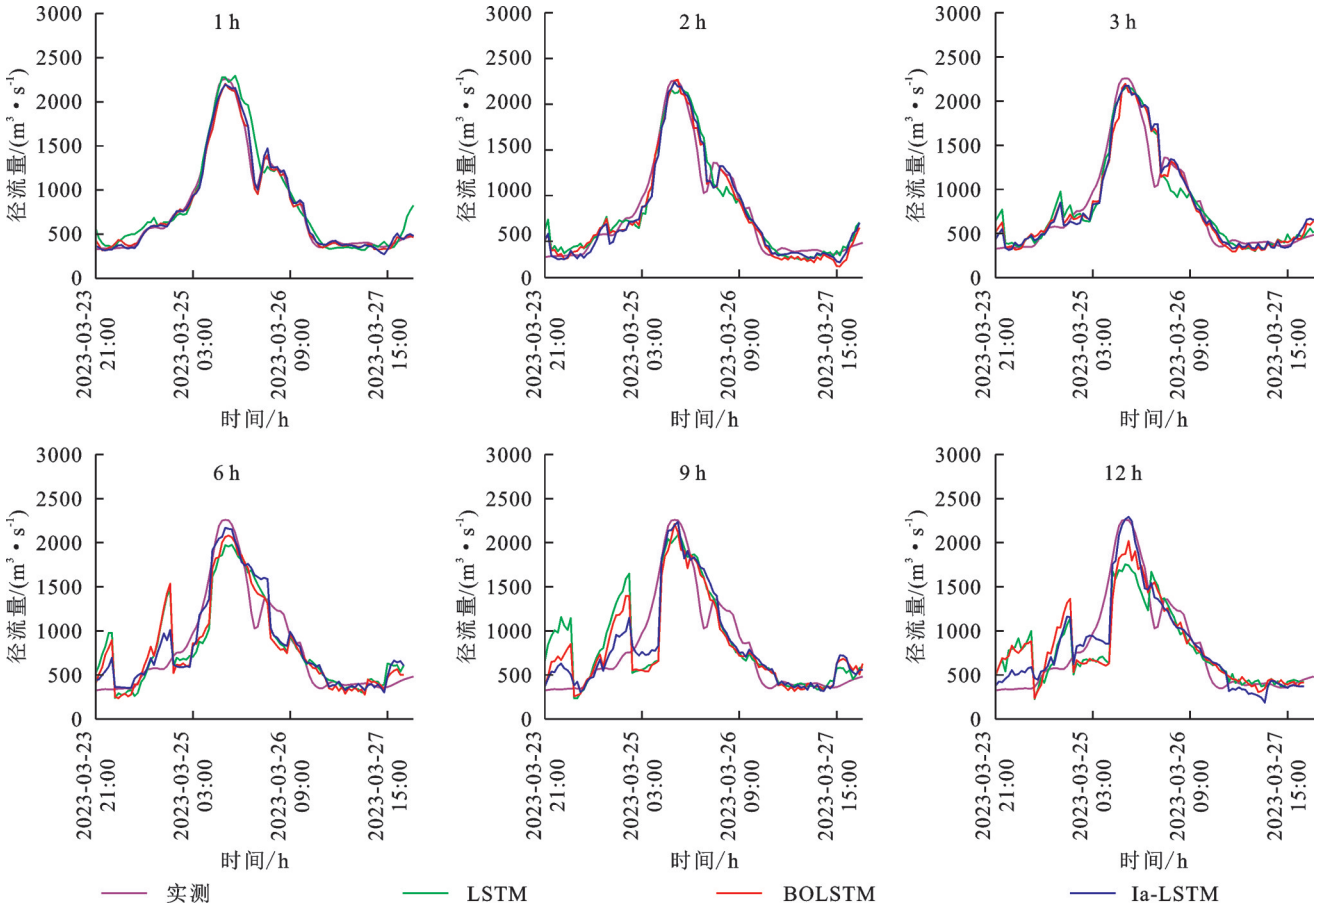


图6　各模型对F_{24}场次暴雨在不同预见期下的预测效果对比

Fig. 6　Comparison of prediction performance of each model for F_{24} heavy rainfall event under different lead times

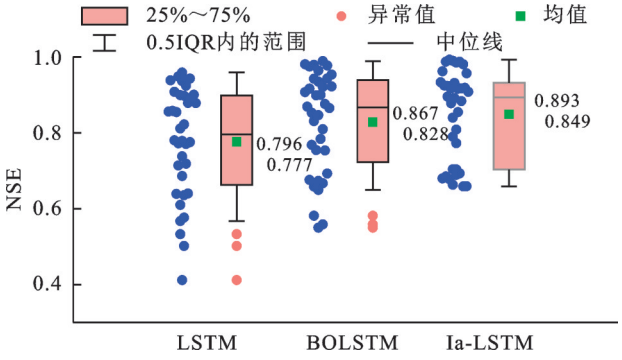


图7　各模型总体NSE箱线图

Fig. 7　Box plot of overall NSE for different models

结合箱线图与表格综合分析可知,Ia-LSTM在整体精度、稳定性和洪峰特征模拟方面表现最优,BOLSTM模型其次,LSTM相对较弱。表明在洪水预测模型中,单纯依赖神经网络结构的优化,其性能提升存在局限;而融合水文物理机制(如下垫面蓄留特性的初始损失Ia)能更有效地增强模型的泛化能力与预报稳健性。Ia的引入使模型能够更好地理解并模拟降雨径流过程中的物理约束,特别在预见期延长、水文非线性增强的情况下,基于物理逻辑的优化比单纯增加模型复杂度更能改善预测效果。

表6 各模型总体评价指标系统计值

Table 6 Statistical values of overall evaluation indicators for each model

模型	NSE		洪峰差/($m^3 \cdot s^{-1}$)		峰现时间差/h		总径流量差/mm	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差
LSTM	0.777	0.145	191.916	204.253	1.833	1.159	1.396	1.262
BOLSTM	0.828	0.134	169.110	156.016	1.472	1.576	1.036	0.994
Ia—LSTM	0.849	0.126	136.838	126.033	1.25	1.1301	1.404	1.182

4 讨论与结论

4.1 讨论与展望

本研究构建的Ia-LSTM耦合模型对汀江中上游地区1～12 h预见期下表现出较好的适用性，尤其在长预见期下仍能维持较高的精度和稳健性，验证了将初始损失值Ia嵌入数据驱动模型的有效性。然而，对于降雨径流模拟研究方面，该模型在物理机理融合深度、气候非平稳性适应及跨区域移植性方面仍存在局限，具体如下：

（1）本研究将Ia作为核心物理特征嵌入模型，是基于其在SCS-CN方法中对流域前期条件和产流临界状态的关键表征作用。通过对前期土壤湿度、下垫面特征等影响因子的综合考量，Ia在一定程度上反映了产汇流过程的物理机制。基于单一核心物理参数的融合方式虽取得了预期效果，但未来仍需系统评估不同物理特征组合及交互融合策略（如特征嵌入、分层耦合）对模型性能的影响，以期建立更优的、紧密耦合水文物理机制与数据驱动优势的混合预报模型。

（2）当前研究成果依赖于历史气候条件下的观测数据，其有效性建立在“气候平稳”假设之上。在当前气候变化背景下，若未来气候状态（如温度、降水格局等）超出历史变率范围，可能将导致参数的非平稳性，从而影响模型性能。后续研究可结合多情景未来气候数据，评估模型在非平稳条件下的鲁棒性，并探索动态参数率定方法及物理约束机制，以增强模型对气候变化的自适应调整能力，为气候变化背景下的洪水预警提供更可靠的决策支持。

（3）模型目前基于汀江流域中上游地区（亚热带季风气候、低山丘陵地形、红壤/黄壤主导下垫面）数据构建，若直接应用于其他流域，受限于下垫面异质性，其性能需进一步结合流域特征进行具体分析。理论上，在具有相似气候、地貌及下垫面条件的流域（如闽西南、粤东北同类山区），该模型框架及参数化方案具备一定参考价值及移植潜力。受限于多流域数据可获取性，本研究暂未开展系统性跨流域验证，后续将重点收集相似及异质流域的水文气象数据，通过参数区域化调整与模型结构优化，系统评估其迁移性能，推动模型在南方山区小流域洪水预报中的广泛应用。

4.2 结 论

（1）基于HEC-HMS模型优化的初始损失值（Ia）可有效表征流域产汇流物理机制过程。研究表明，不同场次暴雨事件下各子流域的Ia值呈显著空间差异，其与总降雨量无明显线性相关；是由多因子协同调控，且呈动态变化的综合性物理特征参数。HEC-HMS模型通过嵌入水文物理机制，精准刻画下垫面因素对产流过程的约束，充分验证Ia作为关键水文物理参数对降雨径流过程的有效表达。

（2）HEC-HMS物理模型与单一LSTM神经网络模型在洪水模拟中呈现差异化优势与局限。HEC-HMS基于明确的水文物理机制，在多数场次中的洪峰误差控制在±10%以内，且NSE普遍高于0.75，体现其基于物理机制结构在关键洪水特征模拟上的可靠性；而LSTM模型在模拟整个径流过程趋势上更为平滑，能够较好地拟合径流涨落状态。两者均能较好地反映流量总体变化趋势，表明其在汀江中上游地区具有一定适用性，但HEC-HMS更适用于峰值敏感场景，LSTM则体现出数据驱动模型在整体过程拟合上的稳定性。

（3）引入Ia水文物理机制的Ia-LSTM模型显著提升了流域内中长期洪水预测精度与稳健性。对比LSTM，BOLSTM与Ia-LSTM在不同预见期下的预测效果可知，随着预见期延长（1～12 h），模型预测精度均有所下降，但Ia-LSTM下降幅度更为平缓且始终维持相对较高NSE值（12 h时0.71）；且Ia-LSTM在整体精度、稳定性和洪峰特征模拟方面表现最优，BOLSTM模型其次，LSTM相对较弱；说明引入Ia参数可有效增强模型对流域响应的物理理解与泛化能力，证实将物理机制嵌入神经网络结构在提升洪水预报稳健性方面的有效性。

综上所述，结合物理机理与数据驱动方法的融合建模是提升洪水模拟与预报精度的有效途径。后续研究可进一步探索多机制融合的建模路径，结合参数区域化与多源数据同化方法，发展跨尺度的智能混合预报模型，为实现“机理-数据”双驱动的流域洪水模拟与预报提供理论支撑与技术路径。

参考文献(References)：

[1] 王协康，杨坡，孙桐，等．山区小流域暴雨山洪灾害分区预警研究[J]．工程科学与技术，2021，53(1)：29-38.
Wang X K, Yang P, Sun T, et al. Study on division early warning of flash flood disaster caused by rainstorm in mountainous small watersheds[J]. Advanced Engineering Sciences, 2021, 53(1): 29-38.

[2] 刘檣漪，程维明，孙东亚，等．中国历史山洪灾害分布特征研究[J]．地球信息科学学报，2017，19(12)：1557-1566.
Liu Q Y, Cheng W M, Sun D Y, et al. Distribution characteristics of historical mountain flood in China[J]. Journal of Geo-Information Science, 2017, 19(12): 1557-1566.

[3] 刘悦，张建云，鲍振鑫，等．东部季风区不同地貌类型试验流域洪水研究[J]．水力发电学报，2022，41(3)：22-31.
Liu Y, Zhang J Y, Bao Z X, et al. Study of floods in experimental watersheds of different geomorphic types in eastern monsoon region of China[J]. Journal of Hydroelectric Engineering, 2022, 41(3): 22-31.

[4] 岳甲寅，刘招，毛钦男，等．结合cnn-lstm模型融合星地降水的洪水模拟研究[J]．中国农村水利水电，2025，67(7)：52-59.
Yue J Y, Liu Z, Mao Q N, et al. Research on flood simulation by integrating satellite and ground precipitation with CNN-LSTM model[J]. China Rural Water and Hydropower, 2025, 67(7): 52-59.

[5] 周琦，朱跃龙，陆佳民，等．组合式水文模型建模方法综述[J]．国外电子测量技术，2020，39(2)：11-18.
Zhou Q, Zhu Y L, Lu J M, et al. Overview of combined hydrological modeling methods[J]. Foreign Electronic Measurement Technology, 2020, 39(2): 11-18.

[6] 张洪刚，郭生练，王才君，等．概念性流域水文模型参数优选技术研究[J]．武汉大学学报：工学版，2004，48(3)：18-22，26.
Zhang H G, Guo S L, Wang C J, et al. Review and research of calibration techniques for conceptual hydrological model[J]. Engineering Journal of Wuhan University, 2004, 48(3): 18-22, 26.

[7] 张洪刚，郭生练，李超群．三峡水库区间定量降水预报不确定性初探[J]．人民长江，2006，52(4)：39-41.
Zhang H G, Guo S L, Li C Q. Preliminary study on uncertainty of quantitative precipitation forecast in Three Gorges Reservoir area[J]. Yangtze River, 2006, 52(4): 39-41.

[8] 翟晓燕，郭良，刘荣华，等．中国山洪水文模型研制与应用：以安徽省中小流域为例[J]．应用基础与工程科学学报，2020，28(5)：1018-1036.
Zhai X Y, Guo L, Liu R H, et al. Development and application of China flash flood hydrological model: case study in small and medium-sized catchments of Anhui Province[J]. Journal of Basic Science and Engineering, 2020, 28(5): 1018-1036.

[9] 沈泽宇，丁永生，孔乔．降雨径流与洪水淹没模型耦合的应用研究[J]．地球信息科学学报，2021，23(8)：1473-1483.
Shen Z Y, Ding Y S, Kong Q. Application study of coupling rainfall-runoff modeling and floodplain inundation mapping[J]. Journal of Geo-Information Science, 2021, 23(8): 1473-1483.

[10] 刘登嵩，葛路，许月萍，等．基于多水文模型预报能力分析的洪水预报[J]．浙江大学学报：工学版，2021，55(5)：1010-1018.
Liu D S, Ge L, Xu Y P, et al. Flood prediction by multi-hydrological models with forecasting ability analysis[J]. Journal of Zhejiang University: Engineering Science, 2021, 55(5): 1010-1018.

[11] 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 Y H, Wu Q, Li C Q, 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.

[12] 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.

[13] 崔震，郭生练，王俊，等．基于GR_4J-LSTM混合模型的洪水预报研究[J]．人民长江，2022，53(7)：1-7.
Cui Z, Guo S L, Wang J, et al. Research on flood forecasting based on GR_4J-LSTM hybrid model[J]. Yangtze River, 2022, 53(7): 1-7.

[14] 李涛，夏润亮，李冰，等．洪水预报研究与展望[J]．中国农村水利水电，2022，64(12)：107-114.
Li T, Xia R L, Li B, et al. Research on flood forecasting and its prospect[J]. China Rural Water and Hydropower, 2022, 64(12): 107-114.

[15] 祁海霞，彭涛，智协飞，等．深度学习技术在洪水预报中的应用进展及思考[J]．气象，2025，51(4)：446-459.
Qi H X, Peng T, Zhi X F, et al. Progress and reflection on application of deep learning techniques in flood forecasting[J]. Meteorological Monthly, 2025, 51(4): 446-459.

[16] Cui Z, Zhou Y L, Guo S L, 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.

[17] 康艳，艾慧茹，彭仁娟，等．基于误差校正hymod-lstm融合模型的自适应带宽洪水区间预报[J]．水资源保护，2025，41(5)：106-114，131.
Kang Y, Ai H R, Peng R J, et al. Adaptive bandwidth

flood interval forecasting based on error-corrected hybrid model[J]. Water Resources Protection, 2025,41(5):106-114,131.

[18] Young C C, Liu W C, Wu M C. A physically based and machine learning hybrid approach for accurate rainfall-runoff modeling during extreme typhoon events[J]. Applied Soft Computing, 2017,53:205-216.

[19] Ali Kumanlioglu A, Fistikoglu O. Performance enhancement of a conceptual hydrological model by integrating artificial intelligence[J]. Journal of Hydrologic Engineering, 2019,24(11):04019047.

[20] Tajiki M, Schoups G, Hendricks Franssen H J, 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.

[21] 刘成帅,解添宁,李文忠,等.考虑径流过程矢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 C S, Xie T N, Li W Z, et al. Machine learning-based flood forecasting models considering runoff process vectorization [J]. Advances in Water Science, 2024,35(3):420-429.

[22] 宋世凯,王海龙,郎子龙,等.基于hec-hms模型的太行山小流域山洪模拟研究:以邢台路罗川流域为例[J].灾害学,2023,38(1):117-124.
Song S K, Wang H L, Lang Z L, et al. Mountain flood simulation of small basin in Taihang Mountains using HEC-HMS model: a case study of Luluochuan River Basin[J]. Journal of Catastrophology, 2023, 38(1): 117-124.

[23] 赖日文,赖敏华,苏艳琴.长汀县水土流失敏感性时空分异研究[J].生态科学,2021,40(6):116-124.
Lai R W, Lai M H, Su Y Q. Temporal and spatial differentiation of soil and water loss sensitivity in Changting County[J]. Ecological Science, 2021,40(6):116-124.

[24] 田景环,樊素琦,王文川,等.FFMS模型与HEC-HMS模型在暴雨洪水预报中的应用比较[J].长江科学院院报,2021,38(3):59-65.
Tian J H, Fan S Q, Wang W C, et al. Comparison between FFMS model and HEC-HMS model applied in rainstorm and flood simulation[J]. Journal of Yangtze River Scientific Research Institute, 2021,38(3):59-65.

[25] 田竞,夏军,张艳军,等.Hec-hms模型在官山河流域的应用研究[J].武汉大学学报(工学版),2021,54(1):8-14.
Tian J, Xia J, Zhang Y J, et al. Application of HEC-HMS model in the Guanshan River Basin[J]. Engineering Journal of Wuhan University, 2021,54(1):8-14.

[26] 袁立婷.基于HEC-HMS水文模型的细河流域山洪预报预警研究[D].辽宁大连:辽宁师范大学,2019.
Yuan L T. Prediction and early warning of mountain flood disasters in Xihe River Basin based on HEC-HMS hydrological model [D]. Dalian, Liaoning: Liaoning Normal University, 2019.

[27] 夏弘.深度学习和水动力学模型结合的中小河流洪水预报研究[D].济南:山东大学,2023.
Xia H. Study on flood forecasting of small and medium-sized rivers based on deep learning and hydrodynamic model[D]. Jinan: Shandong University, 2023.

[28] 徐冬梅,王逸阳,王文川.基于贝叶斯优化算法的长短期记忆神经网络模型年径流预测[J].水电能源科学,2022,40(12):42-46.
Xu D M, Wang Y Y, Wang W C. Prediction of annual runoff using long short-term memory neural network model based on Bayesian optimization algorithm [J]. Water Resources and Power, 2022,40(12):42-46.

[29] 黄一凡,张翔,邓梁堃,等.基于机器学习的汉江流域径流模拟与时滞变化分析[J].水资源保护,2024,40(6):173-180.
Huang Y F, Zhang X, Deng L K, et al. Runoff simulation and time-lag change analysis in the Han River Basin based on machine learning[J]. Water Resources Protection, 2024,40(6):173-180.