

DOI:10.3880/j.issn.1004-6933.2023.03.023

LSTM 变体模型在径流预测中的性能及其可解释性

田 烨^{1,2}, 谭伟丽^{1,2}, 王国庆³, 袁 星^{1,2}

(1. 南京信息工程大学水文水资源工程学院, 江苏 南京 210044; 2. 水利部水文气象灾害机理与预警重点实验室, 江苏 南京 210044; 3. 南京水利科学研究院水文水资源研究所, 江苏 南京 210029)

摘要: 基于湘江流域 1999—2013 年实测水文气象数据, 采用 LSTM 模型和其变体模型研究多个预见期下不同输入变量和不同模型结构对径流预测结果的影响, 评估 LSTM 模型及其变体模型在短期径流预测中的性能, 基于排列重要性法和积分梯度法探究了 LSTM 模型对流域径流预测的可解释性。结果表明: 在历史径流输入数据的基础上增加有效的水文气象变量输入, 可以明显改善模型的预测效果, 输入变量的改变比模型结构的差异对预测结果的影响更大; 随着预见期的增大, 降水数据的加入对预测效果表现出不同程度的提升, 预见期为 1 d 时, 预测结果的纳什效率系数(NSE)提升 2.0%, 预见期为 2~4 d 时, NSE 提升可达 13.6%; 降水和历史径流在预测中起着重要的作用, 而前期湿润条件与降水事件的共同作用是湘江流域洪水的主要诱发因素; LSTM 模型可反映两种不同的输入输出关系, 这两种关系对应于近期降雨和历史降雨两种洪水诱发机制。

关键词: 径流预测; LSTM 模型; 可解释性; 深度学习模型; 湘江流域

中图分类号: P338 **文献标志码:** A **文章编号:** 1004-6933(2023)03-0188-07

Performance of variant LSTM models in runoff prediction and their interpretability // TIAN Ye^{1,2}, TAN Weili^{1,2}, WANG Guoqing³, YUAN Xing^{1,2} (1. School of Hydrology and Water Resources Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. Key Laboratory of Hydrometeorological Disaster Mechanism and Early Warning of Ministry of Water Resources, Nanjing 210044, China; 3. Hydrology and Water Resources Department, Nanjing Hydraulic Research Institute, Nanjing 210029, China)

Abstract: Based on observed hydrometeorology data in the Xiangjiang River Basin from 1999 to 2013, the long short-term memory (LSTM) model and its variant models were used to study the influences of different input variables and different model structures with different foresight periods on runoff prediction results, and performance of the LSTM model and its variant models in short-term runoff prediction was evaluated. Then, the interpretability of the LSTM model for runoff prediction of the Xiangjiang River Basin was explored using the permutation importance and integrated gradient methods. The results demonstrate that incorporating hydrometeorological variable data with historical runoff data as the model input can significantly improve the prediction performance of the model, and changes in input variables have a greater impact on prediction results than differences in model structure; with the increase of the foresight period, the addition of precipitation data leads to different degrees of improvement in the model prediction performance, and the Nash-Sutcliffe efficiency coefficient (NSE) of prediction results increased by 2.0% with a foresight period of one day, while the increase in NSE was up to 13.6% with a foresight period of two to four days. Precipitation and historical runoff were found to play critical roles in runoff prediction, while the joint effect of early humid conditions and precipitation events was identified to be the primary factor inducing floods in the Xiangjiang River Basin. The LSTM model can reveal two distinct input-output relationships, corresponding to two flood-triggering mechanisms of recent rainfall and historical rainfall.

Key words: runoff prediction; LSTM model; interpretability; deep learning model; Xiangjiang River Basin

基金项目: 国家自然科学基金面上项目(52121006); 国家自然科学基金青年科学基金(51709148)

作者简介: 田烨(1986—), 女, 讲师, 博士, 主要从事水文气象灾害预警研究。E-mail: tianye@nuist.edu.cn

通信作者: 王国庆(1971—), 男, 教授级高级工程师, 博士, 主要从事流域水文模拟、气候变化影响与适应、水资源综合管理研究。E-mail: gqwang@nhri.cn

gqwang@nhri.cn

降雨径流模拟和预测对水资源管理、防洪抗旱、水电能源开发等有着至关重要的作用^[1-3]。数据驱动的降雨径流模型主要通过挖掘历史数据中驱动因子与目标值之间的关系来预测径流^[4],在应用方面具有较高的灵活性,弥补了概念性和物理性水文模型对流域水文条件要求严格的不足^[5]。受到计算机计算能力的限制,早期常用的数据驱动模型,包括支持向量机和人工神经网络等^[6-7],在径流预测时,不能很好地表征水文、气象、地理数据的时间和空间特征^[8-9],近年来计算机和深度学习的发展提高了数据驱动模型的模拟预测能力。基于多门结构的长短期记忆(long short-term memory, LSTM)网络从结构上克服了普通循环神经网络的梯度消失问题,并广泛应用于径流预测领域^[10-11]。诸多研究表明 LSTM 模型不仅能描述复杂集水区在日尺度上的降雨-径流关系^[12],而且在挖掘时间序列数据长期相关性方面有着明显优势,特别是在洪水预测中表现出良好的预测性能^[13]。

除了在挖掘长期相关性方面的优势,由于 LSTM 模型结构灵活,在标准 LSTM 模型结构基础上融合其他模型结构的混合模型架构(变体模型)可以进一步提高预测准确性^[14-16]。目前常用的 LSTM 变体模型包括 CNN-LSTM、Bi-LSTM、Conv-LSTM 等。CNN-LSTM 模型结合了卷积神经网络和循环神经网络,运用在湖泊水位的预测研究中取得了良好的效果^[17];Bi-LSTM 模型使用了双向传递结构,综合考虑数据前后向联系,在风速预测方面取得了更可靠和更准确的结果^[18];Conv-LSTM 模型利用卷积神经网络有效考虑了降水的空间信息,并结合 LSTM 模型兼顾时序信息的特点,为降水临近的预测提出了新的解决思路^[19]。可见,通过改进 LSTM 模型产生的变体模型在水文相关领域预测中取得了一定的进展^[20-21],但目前缺乏对这些变体模型在流域径流预测中性能的综合评估,对相关输入变量在深度学习径流模拟中作用的量化和对改善径流预测效果的解释等问题仍有待进一步研究。

目前大部分关于 LSTM 模型的研究主要关注提高预测效果,如通过优化参数或者改善模型结构框架来提高预测精度^[22-23]。如何理解深度学习模型做出的预测是目前机器学习领域面临的挑战,国内外研究者已逐步开展深度学习模型可解释性问题的研究^[24-25],排列重要性法和积分梯度法等已初步运用在深度学习模型可解释性研究中。McGovern 等^[26]基于排列重要性法分析树模型预测冬季降水类型的结果,发现温度、风速、风差是较为重要的预测因子,证实了预测因子重要性在气象学中的重要

意义。Jiang 等^[27]采用梯度积分法揭示了 LSTM 径流模型得到的映射关系与诱发洪水机制之间的联系。因此,增强深度学习本身的可解释性,将极大提高 LSTM 模型在流域径流预测中的可靠性,使模型具有重要的科学理论意义和应用价值。

本文针对 LSTM 模型在流域短期径流预测中的不确定性和可解释性,采用 LSTM 模型和其变体模型研究多个预见期下不同输入变量和不同模型结构对预测结果的影响,评估 LSTM 模型及其变体模型在短期径流预测中的性能。利用排列重要性法和积分梯度法,根据 LSTM 模型不同输入变量与模型预测结果的关系,探究湘江流域不同预见期下水文气象变量对径流预测结果的重要性,量化 LSTM 模型的重要预测因子。基于洪峰发生前期日降水贡献,对 LSTM 模型的预测结果进行进一步分析,解构深度学习模型的径流预测机制和对应的物理机理。

1 研究区概况及数据资料

1.1 研究区概况

湘江流域(图 1)位于 110°30'E ~ 114°00'E、24°31'N ~ 28°45'N,发源于广西壮族自治区兴安县,自西南向北流经湖南,汇入洞庭湖。湘江流域干流全长 856 km,流域面积 94 660 km²,降水量年际变化大,年内分布不均^[28],年平均降水量为 1 300 ~ 1 500 mm。湘潭站(112.92°E、27.86°N)是湘江流域的出口控制站,近年来受流域干流水利工程修建和非法挖沙等人类活动的影响,湘潭站的径流变化规律发生了很大改变,汛期最大日平均径流量可达 2.06 万 m³/s。提高径流预测精度,可为地方政府和防汛部门提供可靠的决策依据。




图 1 研究区概况

Fig. 1 Overview of study area

1.2 数据资料

采用湘潭站(图 1)1999—2013 年的实测日径流数据,并采用泰森多边形法计算流域平均日降水量,结合彭曼公式计算湘江流域日蒸散发量^[29-30]。

以 1999—2008 年的逐日数据作为模型的训练期样本,2009—2013 年的逐日数据作为验证期样本。图 2 为 1999—2013 年湘江流域降雨-径流时间序列,其中,训练期径流量范围为 195 ~ 19 300 m³/s,均值为 2 125 m³/s;验证期径流量范围为 248 ~ 18 400 m³/s,均值为 1 923 m³/s。




图 2 湘江流域降雨-径流时间序列

Fig.2 Rainfall-runoff time series in the Xiangjiang River Basin

2 研究方法

2.1 LSTM 及变体模型

LSTM 模型^[31]作为一种特殊的递归神经网络,由多个记忆单元结构组成,每个记忆单元的功能由 3 个“门”控制:遗忘门决定对上一个单元状态信息的舍弃量;输入门决定新获取的信息中储存在当前单元状态内的比例;输出门决定这一时刻最终的输出信息。本文采用控制变量法率定 LSTM 及变体模型的 8 个参数:时间步长、舍弃率、训练批次、隐藏层单元数、迭代次数、过滤通道数、卷积核和池化层数。通过对模型结构的改变,LSTM 模型衍生出不同的变体模型,包括 Bi-LSTM 模型、Stack-LSTM 模型、CNN-LSTM 模型等。Bi-LSTM 模型^[18]具备同时双向捕捉过去和未来数据信息的能力,理论上 Bi-LSTM 模型比传统的 LSTM 模型更能充分考虑到径流数据在时间上的联系。Stack-LSTM 模型^[31]通过将上层 LSTM 结构的输出作为下层 LSTM 结构的输入来增强模型的表达能力,以预测更加复杂的问题。CNN-LSTM 模型^[32]融合了 CNN 算法和 LSTM 算法,CNN 模型通过卷积和池化两个步骤挖掘数据特征,并对数据进行特征提取和整合;LSTM 模型对整合的数据特征进行筛选与记忆,通过全连接层输出预测结果。相对于 LSTM 模型,CNN-LSTM 模型增加

了 3 个参数,分别是过滤通道数、卷积核大小和池化层数。Conv-LSTM 模型^[19]内部结构与 LSTM 模型一致,主要区别在于“门”的计算方式,前者是卷积计算,后者是矩阵计算。Conv-LSTM 模型参数类型和 CNN-LSTM 模型一致,其采用二维数据输入,弥补 LSTM 模型采用一维数据输入,不适用于空间序列数据的缺陷。

综合考虑模型的预测效果和计算时长,本文将参数设置分为含有历史径流数据和不含历史径流数据两组。第一组参数设置如表 1 所示,第二组参数设置时间步长为 35,训练批次为 200,迭代次数为 80,其他参数与第一组设置相同。

2.2 输入变量组合方案

为了比较输入变量特征对模型预测结果的影响,设计了 5 种输入变量组合方案评估输入数据对模型日径流量预测结果的影响:DLT-1 方案模型输入数据为降水数据,DLT-2 方案模型输入数据为降水和蒸发数据,DLT-3 方案模型输入数据为历史径流数据,DLT-4 方案模型输入数据为历史径流和降水数据,DLT-5 方案模型输入数据为历史径流、降水和蒸发数据。选取纳什效率系数 (Nash-Sutcliffe efficiency coefficient, NSE)^[33]、相对偏差 (relative deviation, RD)、均方根误差 (root mean squared error, RMSE) 和相对均方根误差 (relative root mean squared error, RRMSE) 等指标评估模型预测日径流和洪峰流量的性能。

2.3 解释性方法

采用排列重要性法和积分梯度法对模型的预测结果进行解释。排列重要性法最初由 Breiman^[34]为随机森林模型提出,可用于决策树、随机森林、LSTM 等模型的可解释性分析。排列重要性有两种方式,分别为单通道和多通道方式^[35],这两种方式都可确定当预测因子和目标变量之间的统计联系中断后,预测精度的下降程度。随机排列预测因子,如果改变某个预测因子顺序后模型性能显著下降,则表明该预测因子重要,如果模型性能没有明显变化则说明该预测因子不重要。本文采用排列重要性法比较历史径流、降水、蒸发 3 个预测因子的重要性。

表 1 模型参数设置信息

Table 1 Model parameter setting information

模型	时间步长	舍弃率	训练批次	隐藏层单元数	迭代次数	过滤通道数	卷积核	池化层数
LSTM	10	0.01	64	100	100			
Bi-LSTM	10	0.01	64	30 (两层)	100			
Stack-LSTM	10	0.01	64	50 (两层)	100			
CNN-LSTM	10	0.01	64	100	100	128	4	1
Conv-LSTM	10	0.01	64	100	100	128	1 × 2	2

积分梯度法^[36]是一种基于梯度的方法,通过追溯模型输出与其输入的梯度关系,计算输入的具体贡献。积分梯度法适用于各种神经网络模型架构的可解释性分析^[37]。本文采用积分梯度法对 LSTM 模型预测结果的洪峰流量进行分析,揭示洪峰发生前期日降水的贡献程度。

3 结果与分析

3.1 模型的径流预测性能

利用 NSE 指标评估 LSTM 模型和 LSTM 变体模型的日径流预测性能,结果如表 2 所示。DLT-1 方案下,Stack-LSTM 和 Bi-LSTM 模型日径流预测结果的 NSE 值大于 LSTM 模型,CNN-LSTM 模型与 LSTM 模型日径流预测结果的 NSE 值大致相同,而 Conv-LSTM 模型日径流预测结果的 NSE 值小于 LSTM 模型。DLT-2 方案下,CNN-LSTM 模型日径流预测结果的 NSE 值大于 LSTM 模型,而其他 LSTM 变体模型与 LSTM 模型预测性能大致相同。DLT-3、DLT-4 和 DLT-5 方案下,各模型预测结果的 NSE 值差异微小,不超过 0.01。

表 2 模型日径流预测结果的 NSE 值

Table 2 NSE values of model daily runoff prediction results

模型	NSE				
	DLT-1	DLT-2	DLT-3	DLT-4	DLT-5
LSTM	0.822	0.840	0.909	0.928	0.939
Stack-LSTM	0.840	0.844	0.904	0.925	0.932
Bi-LSTM	0.832	0.833	0.908	0.931	0.935
CNN-LSTM	0.821	0.860	0.902	0.933	0.934
Conv-LSTM	0.780	0.837	0.905	0.937	0.937

各模型洪峰流量预测结果的 RD 值如图 3 所示。DLT-1 和 DLT-2 方案下,各模型洪峰流量预测结果的 RD 值中位数为 -35%; DLT-3、DLT-4 和 DLT-5 方案下,各模型洪峰流量预测结果的 RD 值中位数为 -10%; 同一种方案下,各模型对各场次洪水的洪峰流量预测性能大致相同。在输入组合中未加入历史径流的情况下,预测结果总体 RD 值偏低,而加入历史径流可使低估偏差降低。

综上,LSTM 变体模型与 LSTM 模型具有相似的径流预测性能,洪峰流量对于前期洪水序列具有较强的依赖性。

3.2 输入变量对模型预测结果的影响

从表 2 可以看出,输入变量对模型日径流预测结果的影响大于 LSTM 模型结构。同一模型在不同输入变量组合方案下,如 LSTM 模型在 5 种方案下日径流预测结果 NSE 值的最大变化幅度约为 0.12; 而同一输入变量组合方案下,如 DLT-3 方案下,5 个模型日径流预测结果 NSE 值的最大变化幅度约为 0.01。从改变输入变量组合方案的角度,DLT-3 方案下,各模型日径流预测结果的 NSE 值约为 0.905, DLT-1 和 DLT-2 方案下,各模型日径流预测结果的 NSE 值为 0.78~0.86,对比发现,历史径流数据作为模型输入时,各模型日径流预测结果优于降水和蒸发数据作为模型输入。对比 DLT-3 与 DLT-4 方案的结果可发现,在历史径流输入数据基础上加入降水数据后,各模型日径流预测结果的 NSE 值由约 0.905 提升至约 0.930;对比 DLT-4 与 DLT-5 方案的结果可发现,加入蒸发数据后,NSE 值提升甚小。说明对于短期径流预测,降水的影响大于蒸发,大量




图 3 模型洪峰流量预测结果的 RD 值

Fig. 3 RD values of model peak flow prediction results

研究也表明,径流对降水敏感,降水量的改变会引起径流极大的变化。

3.3 不同预见期下降水对 LSTM 模型预测结果的影响

表 3 为不同预见期 LSTM 模型 5 种方案下日径流预测的评价结果。对比 DLT-3 与 DLT-4 方案的结果可见,随着预见期的增大,降水对预测效果的影响表现出不同程度的提升。预见期为 1 d、2 d、3 d、4 d 时,降水数据的加入使模型日径流预测结果的 NSE 值分别增大了 2.0%、11.7%、13.6%、7.6%。对比 DLT-1 与 DLT-3 方案的结果可见,预见期为 1 d 时,DLT-3 方案下模型的预测结果优于 DLT-1 方案,但预见期为 2~4 d 时,DLT-1 方案下模型的预测结果优于 DLT-3 方案。降水的影响在预见期为 2~4 d 时最为显著,这可能与湘江流域的面积和汇流时间有关,流域面积越大,汇流时间越长,降水量对流域出口处径流量的影响时滞越长。

表 3 不同预见期 LSTM 模型日径流预测的评价结果
Table 3 Evaluations results of daily runoff prediction of LSTM model with different foresight periods

方案	预见期/d	NSE		RMSE/(m ³ ·s ⁻¹)		RRMSE	
		训练期	验证期	训练期	验证期	训练期	验证期
DLT-1	1	0.855	0.822	809	820	0.416	0.421
	2	0.825	0.774	886	940	0.455	0.483
	3	0.717	0.647	1130	1173	0.581	0.603
	4	0.562	0.519	1404	1438	0.721	0.739
DLT-2	1	0.881	0.840	731	792	0.376	0.407
	2	0.851	0.784	820	922	0.421	0.474
	3	0.738	0.655	1086	1160	0.558	0.596
	4	0.584	0.524	1368	1458	0.703	0.749
DLT-3	1	0.938	0.909	525	623	0.272	0.323
	2	0.756	0.704	1046	1070	0.542	0.555
	3	0.562	0.557	1402	1450	0.727	0.751
	4	0.427	0.494	1605	1501	0.575	0.570
DLT-4	1	0.958	0.928	432	556	0.222	0.286
	2	0.875	0.821	747	875	0.384	0.450
	3	0.742	0.693	1075	1142	0.552	0.587
	4	0.575	0.570	1381	1353	0.709	0.695
DLT-5	1	0.965	0.939	440	550	0.226	0.283
	2	0.882	0.829	730	869	0.375	0.446
	3	0.750	0.698	1060	1130	0.545	0.581
	4	0.580	0.575	1370	1345	0.704	0.691

3.4 LSTM 模型的可解释性分析

随着深度学习模型在水文领域中的广泛应用,深度学习模型的可解释性受到越来越多的关注,分析可解释性的意义在于增强模型的可靠性,并通过解释发现深度学习模型预测的潜在规律及机制,因此,了解预测因子在模拟中的意义显得尤为重要。表 4 比较了降水、蒸发和历史径流这 3 个预测因子的重要性随预见期的变化。由表 4 可见,随着预见

期的增大,历史径流因子的重要性逐渐降低,降水因子的重要性有所增加,蒸发因子的重要性没有明显变化。总体而言,预见期为 1 d 时,历史径流是最重要的径流预测因子,随着预见期的增大,降水也成为重要的径流预测因子。作为气象要素,降水对径流预测的影响大于蒸发,降水被认为是降雨-径流模型中重要的变量,由 LSTM 模型训练得出的权重也体现了这一点。预见期从 1 d 变化到 4 d 时,降水因子的重要性呈先增大后减小的规律。

表 4 预测因子的重要性随预见期的变化
Table 4 Importance of predictive factors varying with foresight period

预见期/d	预测因子重要性值		
	历史径流	降水	蒸发
1	1.213	0.111	0.005
2	0.657	0.274	0.016
3	0.439	0.329	0.009
4	0.390	0.254	0.013

积分梯度法揭示出 LSTM 模型在湘江流域反映了两种不同的输入输出关系,利用 DLT-1 方案分析这两种关系对应的两种洪水诱发机制:近期降雨和历史降雨。近期降雨指洪水发生前 3 d 内高强度的降水事件,历史降雨指洪水发生前超过 3 d 或者几周内的降水事件,近期降雨和历史降雨诱发的洪水分别占样本数据集的 23.8% 和 76.2%。采用小波变换法从验证期数据集中识别出 21 个显著洪峰,在模型预测完成后,利用积分梯度法计算每个时间步长降水对于识别出的洪峰值的贡献。图 4 给出了两类降水事件在每个时间步长对洪峰值贡献。由图 4 可见,近期降雨只有在目标洪峰值附近发生时才表现出显著的贡献,表明洪峰值可能是由近期持续时间短、强度高的降水事件引起的,虽然降水事件之前流域的土壤湿度可能在一定程度上增加了洪水的规模,但近期降雨对洪水有着较大的贡献。相比之下,历史降水事件在洪峰值出现前的一段时间就有贡献,可能对洪峰有显著影响,表明洪水可归因于降水事件之前的湿润条件,这种湿润条件源自几天前或




图 4 每个时间步长上降水对洪峰值的贡献度
Fig. 4 Contribution of precipitation to flood peak at each time step

几周内的降水事件,使流域土壤含水量逐渐饱和。虽然洪水需要降水事件来触发,但流域的前期土壤含水量可能起着不可忽视的作用。

4 结 论

a. 以 NSE 值为评价指标,LSTM 模型与 LSTM 变体模型对日径流预测具有相似的性能,在输入变量包含历史径流数据的方案下,LSTM、Stack-LSTM、BI-LSTM、CNN-LSTM 和 Conv-LSTM 模型预测结果的 NSE 值之间差异不超过 0.01。输入变量的改变比模型结构的差异对预测结果影响更为明显。

b. 以历史径流数据、降水数据和蒸发数据作为模型的输入时,预测效果最好;单独以历史径流数据作为模型的输入时,预测效果优于以降水和蒸发组合作为输入。以历史径流输入为基础,增加有效的水文气象变量,对于短期径流的预测效果更好。

c. 排列重要性法对 LSTM 模型重要预测因子的量化结果显示,预见期为 1 d 时,历史径流是最重要的径流预测因子,随着预见期的增大,降水的影响更加显著。在历史径流输入数据基础上加入降水数据后,当预见期为 2~4 d 时,LSTM 模型预测结果的 NSE 值提升可达 13.6%,远大于预见期为 1 d 时 NSE 值的提升(2.0%)。LSTM 模型训练得到的各因子重要性反映出降水对径流预测的重要性大于蒸发。

d. 积分梯度法揭示了 LSTM 模型两种不同的输入输出关系,对应于近期降雨和历史降雨两种洪水诱发机制,这两种诱发机制分别占样本数据集的 23.8% 和 76.2%。

参考文献:

[1] DEY P, MISHRA A. Separating the impacts of climate change and human activities on streamflow: a review of methodologies and critical assumptions [J]. Journal of Hydrology, 2017, 548: 278-290.

[2] ZHANG Shaobo, CHEN Jie, GU Lei. Overall uncertainty of climate change impacts on watershed hydrology in China [J]. International Journal of Climatology, 2022, 42(1): 507-520.

[3] 刘佳,邱庆泰,李传哲,等.降水临近预报及其在水文预报中的应用研究进展[J].水科学进展,2020,31(1): 129-142. (LIU Jia, QIU Qingtai, LI Chuanzhe, et al. Advances of precipitation nowcasting and its application in hydrological forecasting [J]. Advances in Water Science, 2020, 31(1): 129-142. (in Chinese))

[4] LEE H, MCINTYRE N, WHEATER H, et al. Selection of conceptual models for regionalisation of the rainfall-runoff relationship [J]. Journal of Hydrology, 2005, 312(1/2/3/

4): 125-147.

[5] DUAN Qingyun, SOROOSHIAN S, GUPTA V. Effective and efficient global optimization for conceptual rainfall-runoff models [J]. Water Resources Research, 1992, 28(4): 1015-1031.

[6] BRAY M, HAN Dawei. Identification of support vector machines for runoff modelling [J]. Journal of Hydroinformatics, 2004, 6(4): 265-280.

[7] 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.

[8] 岳兆新,艾萍,熊传圣,等.基于信息熵与改进极限学习机的中长期径流预测[J].水利水电科技进展,2021, 41(4): 7-14. (YUE Zhaoxin, AI Ping, XIONG Chuansheng, et al. Medium-long term runoff forecasting based on information entropy and improved extreme learning machine [J]. Advances in Science and Technology of Water Resources, 2021, 41(4): 7-14. (in Chinese))

[9] 胡庆芳,曹士圯,杨辉斌,等.汉江流域安康站日径流预测的 LSTM 模型初步研究[J].地理科学进展,2020, 39(4): 636-642. (HU Qingfang, CAO Shiyi, YANG Huibin, et al. Daily runoff predication using LSTM at the Ankang Station, Hanjing River [J]. Progress in Geography, 2020, 39(4): 636-642. (in Chinese))

[10] LIU Junjiang, YUAN Xing, ZENG Junhan, et al. Ensemble streamflow forecasting over a cascade reservoir catchment with integrated hydrometeorological modeling and machine learning [J]. Hydrology and Earth System Sciences, 2022, 26(2): 265-278.

[11] LIU Ping, WANG Jin, SANGAIAH A K, et al. Analysis and prediction of water quality using LSTM deep neural networks in IoT environment [J]. Sustainability, 2019, 11(7): 2058.

[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] LE X H, HO H V, LEE G, et al. Application of long short-term memory (LSTM) neural network for flood forecasting [J]. Water, 2019, 11(7): 1387.

[14] KIM T Y, CHO S B. Predicting residential energy consumption using CNN-LSTM neural networks [J]. Energy, 2019, 182: 72-81.

[15] HUANG C J, KUO Pinghuan. A deep CNN-LSTM model for particulate matter (PM_{2.5}) forecasting in smart cities [J]. Sensors, 2018, 18(7): 2220.

[16] BARZEGAR R, AALAMI M T, ADAMOWSKI J. Short-term water quality variable prediction using a hybrid CNN-LSTM deep learning model [J]. Stochastic

- Environmental Research and Risk Assessment, 2020, 34 (2):415-433.
- [17] BARZEGAR R, AALAMI M T, ADAMOWSKI J. Coupling a hybrid CNN-LSTM deep learning model with a boundary corrected maximal overlap discrete wavelet transform for multiscale lake water level forecasting [J]. Journal of Hydrology, 2021, 598:126196.
- [18] JASEENA K U, KOVOOR B C. Decomposition-based hybrid wind speed forecasting model using deep bidirectional LSTM networks [J]. Energy Conversion and Management, 2021, 234:113944.
- [19] SHI Xingjian, GAO Zhihan, LAUSEN L, et al. Deep learning for precipitation nowcasting: a benchmark and a new model [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach; Curran Associates Inc., 2017:5622-5632.
- [20] 荣艳淑, 胡玉恒, 冯瑞瑞, 等. 广义相加模型在乌江夏季径流预报中的应用[J]. 河海大学学报(自然科学版), 2021, 49(2):121-126. (RONG Yanshu, HU Yuheng, FENG Ruirui, et al. Application of generalized additive model in summer runoff forecasting of Wujiang Basin[J]. Journal of Hohai University (Natural Sciences), 2021, 49(2):121-126. (in Chinese))
- [21] 白岗岗, 侯精明, 韩浩, 等. 基于深度学习的道路积水智能监测方法[J]. 水资源保护, 2021, 37(5):75-80. (BAI Ganggang, HOU Jingming, HAN Hao, et al. Intelligent monitoring method for road inundation based on deep learning[J]. Water Resources Protection, 2021, 37(5):75-80. (in Chinese))
- [22] 刘墨阳, 李巧玲, 李致家, 等. 基于小波分析的NARX神经网络在水位预测中的应用[J]. 南水北调与水利科技, 2019, 17(5):56-63. (LIU Moyang, LI Qiaoling, LI Zhijia, et al. The application of NARX neural network model based on wavelet analysis for water level prediction [J]. South-to-North Water Transfers and Water Science & Technology, 2019, 17(5):56-63. (in Chinese))
- [23] 刘章君, 郭生练, 许新发, 等. 贝叶斯概率水文预报研究进展与展望[J]. 水利学报, 2019, 50(12):1467-1478. (LIU Zhangjun, GUO Shenglian, XU Xinfu, et al. Bayesian probabilistic hydrological forecasting: progress and prospects [J]. Journal of Hydraulic Engineering, 2019, 50(12):1467-1478. (in Chinese))
- [24] CHENG Shujie, CHENG Lei, QIN Shujing, et al. Improved understanding of how catchment properties control hydrological partitioning through machine learning [J]. Water Resources Research, 2022, 58(4):e2021WR031412.
- [25] MONTAVON G, SAMEK W, MÜLLER K R. Methods for interpreting and understanding deep neural networks[J]. Digital Signal Processing, 2018, 73:1-15.
- [26] MCGOVERN A, LAGERQUIST R, GAGNE II D J, et al. Making the black box more transparent: understanding the physical implications of machine learning[J]. Bulletin of the American Meteorological Society, 2019, 100(11):2175-2199.
- [27] JIANG Shijie, ZHENG Yi, WANG Chao, et al. Uncovering flooding mechanisms across the contiguous United States through interpretive deep learning on representative catchments [J]. Water Resources Research, 2022, 58(1):e2021WR030185.
- [28] GAO Xichao, ZHU Qian, YANG Zhiyong, et al. Evaluation and hydrological application of CMADS against TRMM 3B42V7, PERSIANN-CDR, NCEP-CFSR, and gauge-based datasets in Xiang River Basin of China[J]. Water, 2018, 10(9):1225.
- [29] 胡庆芳, 杨大文, 王银堂, 等. Hargreaves 公式的全局校正及适用性评价[J]. 水科学进展, 2011, 22(2):160-167. (HU Qingfang, YANG Dawen, WANG Yintang, et al. Global calibration of Hargreaves equation and its applicability in China[J]. Advances in Water Science, 2011, 22(2):160-167. (in Chinese))
- [30] ZHANG Ke, KIMBALL J S, NEMANI R R, et al. A continuous satellite-derived global record of land surface evapotranspiration from 1983 to 2006 [J]. Water Resources Research, 2010, 46(9):W09522.
- [31] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8):1735-1780.
- [32] WU Hongcai, YANG Qinli, LIU Jiaming, et al. A spatiotemporal deep fusion model for merging satellite and gauge precipitation in China[J]. Journal of Hydrology, 2020, 584:124664.
- [33] NASH J E, SUTCLIFFE J V. River flow forecasting through conceptual models, part I: a discussion of principles [J]. Journal of Hydrology, 1970, 10(3):282-290.
- [34] BREIMAN L. Random forests [J]. Machine Learning, 2001, 45(1):5-32.
- [35] LAKSHMANAN V, KARSTENS C, KRAUSE J, et al. Which polarimetric variables are important for weather/no-weather discrimination? [J]. Journal of Atmospheric and Oceanic Technology, 2015, 32(6):1209-1223.
- [36] 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.
- [37] ARRIETA A B, DÍAZ-RODRÍGUEZ N, DEL SER J, et al. Explainable artificial intelligence (XAI): concepts, taxonomies, opportunities and challenges toward responsible AI[J]. Information Fusion, 2020, 58:82-115.

(收稿日期:2022-04-20 编辑:施业)