

郑凯丰, 马兴华, 崔国韬, 等. 基于 SAO 优化的 LSTM 模型在北流河的径流预报研究 [J]. 水利水电技术(中英文), 2026, 57(2): 83-94. DOI: 10.13928/j.cnki.wrahe.2026.02.006

ZHENG Kaifeng, MA Xinghua, CUI Guotao, et al. Runoff forecasting in Beiliu River based on SAO-optimized LSTM model [J]. Water Resources and Hydropower Engineering, 2026, 57(2): 83-94. DOI: 10.13928/j.cnki.wrahe.2026.02.006

# 基于 SAO 优化的 LSTM 模型在北流河的径流预报研究

郑凯丰<sup>1,2</sup>, 马兴华<sup>3,4</sup>, 崔国韬<sup>1,2</sup>, 陶昌弟<sup>5</sup>

- (1. 中山大学 地理科学与规划学院, 广东 广州 510275; 2. 中山大学 地理科学与规划学院粤北岩溶区 碳水耦合野外科学观测研究站, 广东 广州 510275; 3. 珠江水利委员会珠江水利科学研究院, 广东 广州 510611; 4. 水利部粤港澳大湾区水安全保障重点实验室, 广东 广州 510611; 5. 广西壮族自治区水利电力勘测设计研究院有限责任公司, 广西 南宁 530023)

**摘要:** 【目的】受气候变化与人类活动影响, 极端径流事件所引发的灾害频发, 基于深度学习模型长短时记忆神经网络(Long Short-Term Memory, LSTM)的径流预报广泛应用, 但其仍需提升准确性与可解释性。【方法】开发了基于雪消融优化算法(Snow Ablation Optimizer, SAO)与 LSTM 的组合模型进行径流预报。选取流域水文气象特征(径流量、降雨量、气温)和基于皮尔逊相关系数(Pearson Correlation Coefficient, PCC)筛选的六项大尺度气候因子指数作为模型输入, 并与反向传播神经网络(Back Propagation, BP)比较, 最后使用 Shapley 值法分析输入特征重要性与贡献度。【结果】结果显示: SAO-LSTM 模型平均绝对百分比误差(MAPE)为 0.26, 决定系数( $R^2$ )为 0.80, Nash-Sutcliffe 效率系数(NSE)为 0.80, 显著优于 LSTM 模型和 BP 模型, 且表现出良好的泛化能力; Shapley 解译结果显示降雨是关键驱动因子, 大尺度气候因子对小流域影响不显著, 未能提高模型预报能力。【结论】SAO-LSTM 模型预报能力显著提高, 具有优秀的泛化能力和鲁棒性; 对于小流域的径流预报, 降雨是关键驱动因素, 重要性显著优于其他特征变量, 而大尺度气候因子贡献较弱。研究提出的 SAO-LSTM 模型具有更高的预报精度, 为理解影响径流的关键因素提供思路, 在泛化能力方面表现出色, 具有很好的应用场景, 可为防洪和干旱决策提供一定的模型支撑。

**关键词:** LSTM; SAO; BP; 深度学习; 径流预报; 北流河; 大尺度气候因子; 影响因素

DOI: 10.13928/j.cnki.wrahe.2026.02.006

开放科学(资源服务)标志码(OSID):

中图分类号: P338.1; TV124

文献标志码: A

文章编号: 1000-0860(2026)02-0083-12



听语音  
聊科研

收稿日期: 2025-04-11; 修回日期: 2025-04-30; 录用日期: 2025-05-13; 网络出版日期: 2025-06-12

基金项目: 国家自然科学基金项目(42301012); 广州市基础与应用基础研究项目(2024A04J3814); 国家重点研发计划项目(2024YFD1700801-04); 中山大学高校基本科研业务(24qnp020)

作者简介: 郑凯丰(2002—), 男, 硕士研究生, 主要从事水文模型研究。E-mail: zhengkf@mail2.sysu.edu.cn

通信作者: 马兴华(1983—), 男, 正高级工程师, 博士, 主要从事水文水资源研究。E-mail: maxinghua2012@163.com

崔国韬(1989—), 男, 副教授, 博士, 主要从事水文水资源研究。E-mail: cuigt@mail.sysu.edu.cn

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

## Runoff forecasting in Beiliu River based on SAO-optimized LSTM model

ZHENG Kaifeng<sup>1,2</sup>, MA Xinghua<sup>3,4</sup>, CUI Guotao<sup>1,2</sup>, TAO Changdi<sup>5</sup>

- (1. School of Geography and Planning, Sun Yat-sen University, Guangzhou 510275, Guangdong, China; 2. Carbon-Water Research Station in Karst Regions of Northern Guangdong, School of Geography and Planning, Sun Yat-sen University, Guangzhou 510275, Guangdong, China; 3. Pearl River Hydraulic Research Institute, Pearl River Water Conservancy Commission, Guangzhou 510611, Guangdong, China; 4. Key Laboratory of Water Security Guarantee in Guangdong-Hong Kong-Macao Greater Bay Area of Ministry of Water Resources, Guangzhou 510611, Guangdong, China; 5. Guangxi Water & Power Design Institute Co., Ltd., Nanning 530023, Guangxi, China)

**Abstract** [Objective] Due to the frequent occurrence of disasters triggered by extreme runoff events under the influence of climate change and human activities, Long Short-Term Memory (LSTM)—a deep learning model—has been widely applied for runoff forecasting. However, it still requires improvements in both accuracy and interpretability. [Methods] A hybrid model for runoff forecasting was developed by combining the Snow Ablation Optimizer (SAO) with the LSTM model. Hydrometeorological characteristics of the watershed (runoff, precipitation, temperature) and six large-scale climate factors selected based on Pearson Correlation Coefficient (PCC) were used as model inputs. The model was compared with the Back Propagation (BP) neural network, and the Shapley value method was applied to analyze the importance and contribution of the input features. [Results] The SAO-LSTM model achieved a Mean Absolute Percentage Error (MAPE) of 0.26, a Coefficient of Determination ( $R^2$ ) of 0.80, and a Nash-Sutcliffe Efficiency (NSE) of 0.80, significantly outperforming both the LSTM and BP models and demonstrating excellent generalization ability. Shapley interpretation result indicated that precipitation was the key driving factor, while large-scale climate factors had no significant impact on small watersheds and failed to improve the model's forecasting performance. [Conclusion] The SAO-LSTM model significantly improves forecasting performance and exhibits excellent generalization ability and robustness. For runoff forecasting in small watersheds, precipitation is the key driving factor, with significantly higher importance than other feature variables, while large-scale climate factors contribute relatively little. The proposed SAO-LSTM model offers higher forecasting accuracy, provides insights into key factors influencing runoff, demonstrates excellent generalization ability, and shows promising application potential, thereby offering model support for flood control and drought decision-making.

**Keywords:** LSTM; SAO; BP; deep learning; runoff forecasting; Beiliu River; large-scale climate factors; influencing factors

## 0 引言

水文现象是复杂、多变的循环过程,同时受气候变化与人类活动的影响,导致了径流过程的高度非线性,引发了许多极端径流灾害事件<sup>[1-4]</sup>。因此准确的径流预报对实现水资源科学管理、防护决策具有重要意义。目前径流预报方法可划分为基于水文过程的物理模型和基于数学推导的机器学习模型<sup>[5]</sup>。其中物理模型的预报由于建模过程的复杂与水文过程的多变,存在数据获取困难、参数校准不准确、运行效率低等问题,不利于大范围的推广应用<sup>[6]</sup>。而机器学习模型作为一种能够直接从数据中提取时序变化规律的“黑箱”方法,因其对先验知识依赖较小、计算效率高、建模流程简便等优势,在径流预报领域得到了充分的推广<sup>[7-8]</sup>。

机器学习模型分为需要人工构建特征提取器再解因果回归关系的传统机器学习模型与具有深层映射结构能够自动提取数据特征的深度学习模型<sup>[9-10]</sup>。其中

深度学习属于机器学习的子领域,相较于传统机器学习模型,通过多个处理层学习数据的抽象表达并反向传播更新模型内部参数的建模方式在许多领域取得了重要突破<sup>[11]</sup>。在水文领域,也有许多学者比较深度学习模型和传统机器学习模型间的差异,比如SARMAD等<sup>[12]</sup>的试验结果验证了深度学习模型 Long Short-Term Memory(LSTM)在水库流入预报方面具有比传统机器学习更高的预报精度;李明伟<sup>[13]</sup>使用深度学习模型 LSTM 和多种传统机器学习模型对不同水保工程下的土壤侵蚀量进行模拟预报,结果表明 LSTM 模型的预报精度更高,适用推广应用; DANESH 等<sup>[14]</sup>将多种深度学习模型与多种传统机器学习模型进行比较,发现深度学习模型的预报结果均优于传统机器学习模型。当前众多径流预报研究已展示了深度学习的巨大应用价值,其中 LSTM 模型在水文预报流域具有广泛的应用,然而 LSTM 模型在实际应用中也存在一定的局限性。

例如,模型在不同领域的应用以及模型的串联组

合均要求设置超参数,且需要尽可能优化拟合过程才能保证模型具有良好的输出结果。因此使用优化算法率定和选择超参数对模型预测性能的影响是十分显著的<sup>[15-17]</sup>。比如使用灰狼优化算法(Grey Wolf Optimizer, GWO)优化后的支持向量机回归(Support Vector Regression, SVR)模型进行径流预报,结果显示优化后的SVR模型在收敛性、预报精度方面都具有更好表现<sup>[18]</sup>; ZHAO等<sup>[19]</sup>使用改进灰狼优化算法(Improved Grey Wolf Optimizer, IGWO)与深度学习模型Gated Recurrent Unit(GRU)的组合模型进行月流量预报试验,发现优化算法能够有效保持模型在训练集和测试集的性能一致,增强模型的预报鲁棒性; PHAM等<sup>[20]</sup>使用智能水滴算法改进多层感知器神经网络(Multi-Layer Perceptron, MLP)在流量预报中的预报性能,结果显示有效改进了全局搜索过程,显著提高了预报精度。近年发表的雪消融优化算法(Snow Ablation Optimizer, SAO)因其独特的全局搜索能力和快速收敛特性,在解决复杂优化问题方面展现出良好潜力<sup>[21]</sup>,但其在LSTM超参数优化方面的应用尚未被充分探索。

另外,深度学习模型作为数据驱动模型,尽管在实际应用过程中的输出结果令人满意,但其相较于传统水文过程模型仍存在无法忽视的缺点,即输出过程不透明与水文因果关系不确定,导致预报结果可信度不高<sup>[22]</sup>。因此增强深度学习模型的可解释性是至关重要的,例如JING等<sup>[23]</sup>集成梯度(Integrated Gradient, IG)讨论了LSTM模型输入特征的重要性,对其背后机理进行了分析;姚泰伦等<sup>[24]</sup>在径流预报试验中同样利用IG对不同输入步长的不同特征进行了贡献度分析,揭示了不同模型在不同流量场景下捕捉关键特征的偏好。然而,Shapley值法在LSTM径流预报领域的应用并不广泛,而且现有研究较少关注大尺度气候事件对小流域径流预报的影响机制,这对于理解气候变化背景下的小流域径流变化规律具有重要意义。

总体来看,深度学习模型是突破径流预报难题的关键,而如何使用优化算法改进模型的预报性能和鲁棒性,结合特征重要性分析增强模型可解释性是提高模型精度、泛化能力与预报结果可信度的关键,也是完善水旱灾害防御体系的重要内容<sup>[25-26]</sup>。基于对现有研究的分析总结,本文旨在解决以下3个问题:(1)SAO算法能否有效优化LSTM模型超参数,提高小流域月径流预报精度并增强泛化能力?(2)SAO-LSTM组合模型相比传统神经网络BP模型在研究流

域的预报表现如何?(3)大尺度气候因子是否影响流域径流预报?本文以北流河流域金鸡水文站为研究对象,基于站点监测径流量、流域降雨量、气温与大尺度气候因子,构建雪消融优化算法(Snow Ablation Optimizer, SAO)优化的深度学习模型LSTM作为组合模型SAO-LSTM模拟预报流域的月径流量,并与反向传播神经网络(Back Propagation, BP)进行比较,最后使用Shapley值法分析不同输入特征的重要性以及对输出结果的贡献度。本研究的创新点主要体现在:(1)将SAO算法应用于LSTM模型超参数优化,构建了适用于小流域月径流预报的新型组合模型,提高了预报精度;(2)引入Shapley值法分析多种流域气象输入及气候事件对径流预报的重要性,解释北流河流域径流的主控因子;(3)从深度学习模型角度分析了大尺度气候因子对小流域月径流预报的影响,为气候变化背景下不同流域的水文预报提供了参考,助力极端径流灾害事件的“四预”能力建设,支撑新阶段水利高质量发展。

## 1 研究区域及数据资料

### 1.1 研究区域

北流河是珠江流域、西江水系的重要组成部分,为西江干流的一级支流,发源于北流市平政镇上梯村石城猫山麓(见图1),全流域控制集水面积 $9\,359\text{ km}^2$ ,其多年平均水资源量为 $32.15\text{ 亿 m}^3$ 。北流河地处低纬,北回归线以南,因地形错综复杂,暖湿气流易受抬升作用及台风入侵,雨量较充沛,蒸发量大。雨量集中在夏秋两季,4—9月降水量占全年的71%~82%,多年平均降水量 $1\,671\text{ mm}$ 。流域内气候温和,日照充足,年平均气温 $20.6\text{ }^\circ\text{C}$ ,年平均日照 $1\,761.5\text{ h}$ ,日照率40%。流域丰水期(4—9月)受湿热季风、台风影响,盛行偏南风。枯水期(10月—次年3月)受干湿季风及北方冷空气影响,盛行偏北风,无霜期长,北流市无霜期 $350\text{ d}$ ,容县无霜期 $336.4\text{ d}$ 。

金鸡水文站位于藤县金鸡镇洲地村北流河河段左岸,距北流河汇入浔江处 $39\text{ km}$ ,是北流河的下流出口控制站,流域集水面积为 $9\,111\text{ km}^2$ ,占北流河集水面积的97.35%<sup>[27]</sup>。研究将运用深度学习模型在金鸡水文站进行径流预报试验,对比分析基于优化算法改进后的深度学习模型在该流域的适用性。

### 1.2 数据资料

模型所用输入特征数据:北流河金鸡水文站月径流量(1956年1月—2016年12月)来源于广西水文年

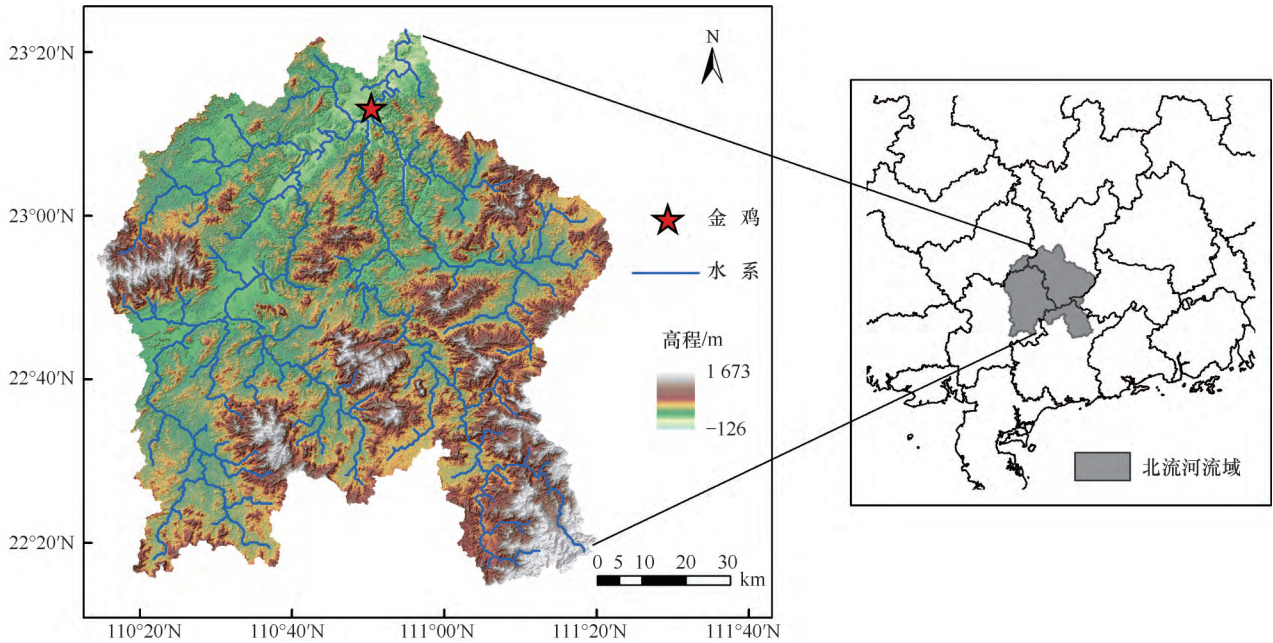


图 1 北江流域水系及金鸡水文站地形概况

Fig. 1 River system of Beijiang River Basin and topography of Jinji hydrological station

鉴。北流河流域月降水量、月平均气温数据来源于中国 1 km 分辨率逐月降水量数据集<sup>[28]</sup>。此外,有研究指出大尺度气候因子会对南方地区降水事件产生显著影响<sup>[29]</sup>,因此选择六项指数用于表征大尺度气候因子以探究这些大范围气候事件对北流河流域的影响,包括平均海温距平指数(Sea Surface Temperature, NINO3.4, <https://origin.cpc.ncep.noaa.gov/data/indices/>)、南方涛动指数(Southern Oscillation Index, SOI, <https://origin.cpc.ncep.noaa.gov/data/indices/>)、太平洋年代际振荡指数(Pacific Decadal Oscillation, PDO, <https://www.ncei.noaa.gov/access/monitoring/pdo/>)、大西洋涛动指数(North Atlantic Oscillation, NAO, <https://www.cpc.ncep.noaa.gov/products/precip/CWlink/pna/nao.shtml>)、北极-北大西洋震荡指数(Arctic Oscillation, AO, [https://www.cpc.ncep.noaa.gov/products/precip/CWlink/daily\\_ao\\_index/ao.shtml](https://www.cpc.ncep.noaa.gov/products/precip/CWlink/daily_ao_index/ao.shtml))、太阳黑子(Sunspot Number, SN, <https://www.sidc.be/SILSO/datafiles>)。各项数据在后续试验中 7:3 的比例划分为训练集和测试集,并以历时 12 个月作为模型的输入,预测未来一个月的月径流量。

## 2 研究方法


本研究构建了耦合雪消融优化算法的长短时记忆神经网络模型(SAO-LSTM)用于月径流预报,并从多个维度进行了性能评估。研究方法主要包括五部分:第一是 LSTM 神经网络的基本原理与径流预报,

LSTM 是本研究的核心预测模型;二是介绍传统的 BP 神经网络,其作为径流预报的对比模型;三是详述基于 SAO 的自动化超参数优化算法,以及其与 LSTM 或 BP 模型的耦合过程;四是引入 Shapley 值法作为模型解释工具,用于量化各输入特征对预测结果的贡献度,解密“黑箱”模型;五是设置多项评价指标对模型性能进行评估。

### 2.1 长短时记忆神经网络

长短时记忆神经网络(Long Short-Term Memory, LSTM)从循环神经网络(Recurrent Neural Network, RNN)发展而来<sup>[30]</sup>,能避免 RNN 的长依赖问题。LSTM 模型由多个重复的记忆结构单元组成,每个记忆结构单元(见图 2)由三个“门”控制:遗忘门决定新获取信息的舍弃量;输入门决定储存新获取信息的比例;输出门决定这一单元最终的输出信息。门结构使得 LSTM 能够遗忘无关信息并保留重要信息,在处理具有重要时间依赖关系的序列时表现出色<sup>[31]</sup>。图 2 中  $\sigma$  为 Sigmoid 激活函数,  $\tanh$  为 tanh 激活函数,  $X_t$  为  $t$  时刻输入,  $h_t$  为  $t$  时刻输出。

LSTM 径流预报流程如下。一是输入数据处理:分别将训练集、测试集输入数据重构为 LSTM 模型需要的输入形状;二是模型搭建:搭建单层 LSTM,选择“Relu”作为激活函数,Adam(Adaptive Moment Estimation)作为优化器,均方误差(Mean Squared Error, MSE)作为损失函数。在 LSTM 层后设置正则



$\sigma$ —Sigmoid 激活函数;  $\tanh$ — $\tanh$  激活函数;  $\otimes$ —不同信息流的合并并对向量的逐元素乘法, 用于控制信息的流动;  
下标  $t$ 、 $t-1$ 、 $t+1$ —本时刻、上一时刻与下一时刻;  $X_t$ — $t$  时刻输入样本;  $h_t$ — $t$  时刻输出

图2 LSTM 记忆结构单元

Fig.2 Structure of LSTM memory cell

化层( Dropout Layer) 以减少模型过拟合风险以及输出层( Dense Layer) 将 LSTM 输出映射为目标数据样式; (3) 模型训练: 根据设定的神经元数量( Hidden Units)、批次大小、学习率( Learning Rate) 等超参数编译模型并投入训练; (4) 输出预报结果。

### 2.2 反向传播神经网络

反向传播神经网络( Back Propagation, BP) 是基于多层前馈网络的一种监督学习算法, 利用梯度下降法通过误差反向传播来更新网络中的各权重和偏置, 从而使网络输出与期望目标尽可能接近<sup>[32]</sup>。BP 结构与反向传播算法实现过程如图3所示,  $X_1-X_n$  表示输入的样本序列,  $X_n$  表示第  $n$  个样本点,  $y_1-y_n$  表示对应输出的模拟值,  $y_n$  表示第  $n$  个输出的模拟值;  $Y_1-Y_n$  表示用于计算误差的观测序列,  $Y_n$  表示第  $n$  个观测样本。




图3 BP 神经网络结构与反向传播过程

Fig.3 Structure and backpropagation process of BP neural network

已有研究证明了 BP 神经网络在径流预报领域具有重要的应用价值<sup>[33-34]</sup>。针对本研究区域-北流河金鸡水文站, 已有前人构建了 BP 神经网络获得良好的

预报效果<sup>[27]</sup>, 因此本研究引入 BP 神经网络作为对比模型。BP 神经网络模型的构建过程与前文 LSTM 模型相似, 设置一层隐含层, 选择 “Relu” 作为激活函数, Adam 作为优化器, 均方误差作为损失函数。

### 2.3 雪消融优化算法

雪消融优化算法( Snow Ablation Optimizer, SAO) 是受雪升华和融化过程启发提出的一种新物理机制优化器算法<sup>[21]</sup>。SAO 通过模拟积雪消融过程中能量传递、相变机制及水流路径的转化过程, 实现了在搜索空间中全局探索与局部开发之间的平衡, 从而有效地避免了早熟收敛并提升了全局搜索能力。SAO 在开始优化问题前先随机生成由  $N$  个体组成的种群, 个体在解空间内随机分布, 之后通过引入布朗运动模拟雪或液态水转变为水蒸气的不规则扩散行为更新每个粒子的位置, 称为全局搜索阶段; 再将雪融化为液态水时水分子倾向于围绕当前最佳解聚集的过程抽象为个体在局部区域内的搜索, 称为局部优化阶段。为了兼顾全局搜索和局部优化, 算法采用了双种群机制, 将总体种群划分为两个子种群, 分别负责全局搜索阶段的更新与局部优化阶段的更新, 具体公式为

$$Z_i(m+1) = Elite(m) + BM_i(m) \otimes [\theta_1 \times (G(m) - Z_i(m)) + (1 - \theta_1) \times (\bar{Z}(m) - Z_i(m))] \quad (1)$$

$$Z_i(m+1) = MR \times G(m) + BM_i(m) \otimes [\theta_2 \times (G(m) - Z_i(m)) + (1 - \theta_2) \times (\bar{Z}(m) - Z_i(m))] \quad (2)$$

式中,  $Z_i(m)$  表示第  $i$  个个体在第  $m$  代的位置, 在本研究中对应一组 LSTM 或 BP 模型的超参数组合(包括神经元数量、正则化率、学习率、批次大小等);  $\bar{Z}(m)$  表示种群的平均位置;  $i$  为第  $i$  个个体, 即第  $i$

个选定的超参数组合;  $m$  为迭代次数;  $BM_i(m)$  是基于正态分布的布朗运动随机向量;  $\otimes$  表示逐元素相乘;  $\theta_1$  和  $\theta_2$  分别为在  $[0, 1]$  和  $[-1, 1]$  内的随机数;  $G(m)$  为当前代的全局最优解;  $Elite(m)$  为从精英群体中随机选出的个体(例如从当前最优解、次优解或第三优解中选取);  $MR$  是基于度日法(DDF,  $DDF = 0.35 + 0.25 \times \frac{e^{\frac{m}{T_{max}}} - 1}{e - 1}$ ) 计算得到的雪融速率 ( $MR = DDF \times T(m)$ )。

SAO 优化 LSTM 的过程为: 设定超参数的搜索范围, 即公式中的  $Z_i(m)$ ; 以模型在验证集上的均方误差作为优化目标函数, SAO 算法通过最小化这一目标函数寻找最优超参数组合, 每次计算分别在公式(1)和公式(2)上进行, 一是全局搜索超参数设定范围内的组合; 二是在公式(1)搜索的基础上再进行局部的搜索, 确保模型寻找局部最优解的同时不错过局部最优解。采用 SAO 在预设定的超参数空间内搜索深度学习模型的超参数最优解, 能够有效避免手动调参数导致的过拟合、陷入局部最优解、错过全局最优解以及费时费力等问题。参与搜索的超参数包括神经元数量、正则化率、学习率、批次大小, 为了兼顾搜索性能与搜索时间, SAO 的种群大小设置为 15, 最大迭代次数设定为 15。

本研究提出的 SAO-LSTM 模型是将 SAO 算法与 LSTM 模型相结合的优化框架, 用于自动搜索 LSTM 模型的最优超参数组合。为了进行全面比较, 本研究还构建了标准 LSTM 模型(未经 SAO 优化)和 BP 神经网络模型。其中 BP 神经网络同样使用 SAO 优化算法进行超参数调优, 构建 SAO-BP 模型, 优化流程同 SAO-LSTM 流程一致。

#### 2.4 Shapley 值法

Shapley 值法来源于合作博弈论, 是一种能够公平分配各参与者贡献的分析方法, 根据不同参与者的合作方式及贡献, 计算出每个参与者的边际贡献, Shapley 值就是参与者在所有参与组合中的平均贡献<sup>[35]</sup>。在深度学习领域, Shapley 值法的核心思想是将每个输入特征视为“博弈参与者”, 并通过考察不同特征组合对模型输出的边际贡献来衡量每个特征的重要性。研究表明 Shapley 值法对增强深度学习、机器学习模型可解释性增强、预报性能提高的重要贡献<sup>[18, 36]</sup>。利用 Shapley 值法量化各输入特征对 LSTM 径流预报结果的贡献, 能够识别影响径流变化的关键因素, 增强模型可解释性, 具体公式为

$$Shapley_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! (|N| - |S| - 1)!}{|N|!} [f(S \cup \{i\}) - f(S)] \quad (3)$$

式中,  $N$  代表所有特征的集合;  $S$  代表不包含特征  $i$  的集合;  $f(S \cup \{i\})$  代表使用子集  $S$  与特征  $i$  的并集作为模型输入时的性能;  $f(S)$  代表使用子集  $S$  作为模型输入时的性能;  $|S|$  代表集合中的特征数量, 例如  $|N|$  代表集合  $N$  中的特征数量。

#### 2.5 评价指标

选用平均百分比误差 (Mean Absolute Percentage Error, MAPE)、确定系数 (Coefficient of Determination,  $R^2$ )、纳什效率系数 (Nash-Sutcliffe Efficiency, NSE) 三项指标评估模型性能。MAPE 越小表明模型误差越小,  $R^2$  越大表明模型拟合效果越好, NSE 越大表明模型预报结果越好。评估指标具体计算公式为

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{obs_i - pre_i}{obs_i} \right| \quad (4)$$

$$R^2 = \frac{\sum_{i=1}^n (obs_i - \overline{obs})^2 (pre_i - \overline{pre})^2}{\sum_{i=1}^n (obs_i - \overline{obs})^2 \sum_{i=1}^n (pre_i - \overline{pre})^2} \quad (5)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (obs_i - pre_i)^2}{\sum_{i=1}^n (obs_i - \overline{obs})^2} \quad (6)$$

式中,  $obs$  和  $pre$  分别表示观测值和预报值; 下标  $i$  表示第  $i$  个数据;  $n$  为数据总数;  $\overline{obs}$  和  $\overline{pre}$  分别表示观测值和预报值的平均值。

### 3 结果与讨论

#### 3.1 不同输入特征组合下模型性能差异

本研究以历史时期的 12 个月数据作为模型输入, 预报未来 1 个月的径流量, 共选取流域径流量、降雨量、气温、大尺度气候因子作为模型的输入特征数据。然而, 模型输入特征的选取与组合对预报结果有着显著影响, 因此将 4 种特征按照排列组合划分为 15 种输入特征组合(见表 1)作为模型输入以探究最优输入特征组合。同时, 根据使用 SAO 优化后的超参数或者默认超参数划分, LSTM 模型可分为组合 SAO-LSTM 模型与标准 LSTM 模型。

将 15 种特征组合数据依次输入标准 LSTM 模型与组合 SAO-LSTM 模型, 最终得到两种模型的实际预报性能。以 NSE 评价指标为例, 模型性能对比如

表 1 模型不同输入特征组合

Table 1 Different combinations of input features for model

组合	输入特征
G1	径流量
G2	径流量+大尺度气候因子
G3	径流量+降雨量
G4	径流量+气温
G5	径流量+降雨量+气温
G6	径流量+降雨量+大尺度气候因子
G7	径流量+气温+大尺度气候因子
G8	径流量+降雨量+气温+大尺度气候因子
G9	降雨量+气温+大尺度气候因子
G10	降雨量+气温
G11	降雨量+大尺度气候因子
G12	气温+大尺度气候因子
G13	降雨量
G14	气温
G15	大尺度气候因子

图 4 所示。组合 SAO-LSTM 模型的预报性能普遍优于标准 LSTM 模型。在某些特征组合下(如 G7), 标准 LSTM 模型的  $NSE$  为负值(-0.368), 而 SAO 优化后的模型将  $NSE$  提升至 0.426, 改善效果显著; 而在一些标准 LSTM 具有较好预报性能的输入特征组合中(如 G3、G5、G6), 组合 SAO-LSTM 模型仍能够进一步提高预报精度, 且在 G5 中表现出最优的预报性能,  $NSE$  为 0.798, 相较于标准 LSTM 模型提升 11%。基于以上分析, 后续试验采用特征组合 G5(径流量、降雨量、气温)作为模型输入特征数据, 进一步对比不同模型的预报结果。

进一步分析两种模型在训练集与测试集之间的表




图 4 不同输入特征组合下标准 LSTM 与 SAO-LSTM 组合模型对比

Fig. 4 Comparison between standard LSTM and SAO-LSTM hybrid model under different combinations of input features

现差异(见图 5), 组合 SAO-LSTM 模型训练集与测试集间的  $NSE$  差值几乎为 0, 显著小于 LSTM, 表明了通过组合 SAO 算法能够有效改善深度学习模型的过拟合情况, 增强模型的泛化能力, 更接近模型训练过程中的全局最优。

### 3.2 模型预报结果对比

以 G5 作为特征组合输入模型, 使用 LSTM 模型与 BP 神经网络预报金鸡站径流量, 各模型评估指标结果如表 2 所列。从各个评价指标来看, SAO 优化的模型相较于未优化的模型在预报性能上有明显提升, 且训练集与测试集的评价指标差异显著减少, 显示出 SAO 算法可有效提高模型精度以及解决过拟合问题。此外, 从表中可以明显看出 LSTM 模型预报性能显著优于 BP 神经网络, 标准 LSTM 模型在测试集中的  $MAPE$ 、 $R^2$ 、 $NSE$  分别为 0.273、0.756、0.718, 相较于 BP 神经网络的 0.391、0.721、0.604 在性能上有显著优势; 在 SAO 优化之后, SAO-LSTM 模型的  $MAPE$ 、 $R^2$ 、 $NSE$  分别为 0.225、0.799、0.798, 仍具有比 SAO-BP 神经网络更高的预报精度, 且训练集与测试集间的精度差异更小, 表明经过 SAO 优化算法的改进, SAO-LSTM 在泛化能力上同样优于 SAO-BP。

综合来看, 在长期径流预报问题中, LSTM 模型相较于 BP 神经网络更适用于径流预报领域的研究, 邹红梅等<sup>[37]</sup>在径流的中长期预报试验中同样验证了这一点, 而本文则进一步比较 SAO 优化算法改进后 LSTM 模型与 BP 神经网络的最佳性能表现, 进一步




图 5 不同输入特征组合下模型训练集与测试集间性能差异

Fig. 5 Performance differences between training and testing sets under different combinations of input features

表 2 输入特征组合 G5 下各模型预报性能

Table 2 Prediction performance of different models under input feature combination G5

模型	训练集 MAPE	训练集 R <sup>2</sup>	训练集 NSE	测试集 MAPE	测试集 R <sup>2</sup>	测试集 NSE
LSTM	0.176	0.936	0.923	0.273	0.756	0.718
SAO-LSTM	0.229	0.841	0.837	0.255	0.799	0.798
BP	0.227	0.951	0.895	0.391	0.721	0.604
SAO-BP	0.204	0.869	0.851	0.267	0.757	0.755


佐证了这一结论。图 6 显示了性能最优的 SAO-LSTM 模型月径流预报结果。总体而言,该模型能够较好地拟合实测径流序列的变化趋势,但在径流峰值预测上存在一定偏差,尤其是部分洪峰期,这也是国内外径流预报中常面临的挑战<sup>[38-40]</sup>。径流峰值偏差问题可能与以下因素有关:一方面,洪峰期径流量通常由强降水事件引发,而此类极端事件在训练数据中占比相对较少,导致模型对极端事件的径流过程刻画不足;另一方面,在洪峰形成过程中,流域下垫面情况变化(如前期土壤湿度),且可能受到闸坝、水库等调控,而模型通常未充分考虑这些因素的影响。此外,月尺度模型可能难以捕捉短期强降雨引起的快速径流响应过程。未来研究可考虑引入日时间尺度数据,尝试提高模型对径流峰值的预报能力。

### 3.3 输入特征贡献分析


运用 Shapley 方法对输入模型的特征进行重要性以及贡献分析,能够增强深度学习模型的可解释性,并在一定程度上探究径流对输入特征响应的背后机理。首先对组合 SAO-LSTM 模型性能表现最优的特征组合 G5 进行特征分析(见图 7),其中左图为各个特

征的 *Shap* 值的绝对平均值,代表该特征在 LSTM 模型训练输出结果过程中的贡献占比;右图为不同输入特征值对该输出结果的贡献程度,具体表现为某个输入特征值影响该次输出结果升高(*Shap* 值>0)或降低(*Shap* 值<0)。

如图 7(a)所示,降雨是 SAO-LSTM 模型输出最重要的特征,其次为历史径流以及气温。从北流河流域的水文特性来看,该流域作为典型的亚热带季风气候区,降雨量时空分布不均,降雨作为径流形成的主要来源,对径流量具有决定性影响,特别是在夏秋季节的强降雨事件期间,降雨-径流转化率显著提高,因此降雨特征在 LSTM 模型预报中最为重要。历史径流作为第二重要特征反映了模型对流量的记忆效应和自相关特性。而气温排第三位,与北流河流域无冰冻期且蒸散发稳定情况有关,其影响相对有限。本研究基于 Shapley 方法的结果显示降雨是径流演变的主导因子,与前人基于归因分析对季节性河流水文过程的主导因子判断互为佐证<sup>[41]</sup>。然而,在其他流域也有研究发现气温和降水均是影响径流量的重要因素,例如,排露沟流域存在季节性冰冻期,冰雪融化对径流



(a) 训练集



(b) 测试集

图6 SAO-LSTM组合模型的月径流预报结果

Fig. 6 Monthly runoff forecasting results of SAO-LSTM hybrid model




图7 组合G5中SAO-LSTM输入特征

Fig. 7 Input features of SAO-LSTM in combination G5

形成贡献显著, 因此对该流域而言气温重要性相对较高<sup>[42]</sup>。相比之下, 本研究区北流河流域无冰冻期,

且主要受台风与暖湿气流影响, 夏秋两季降雨产生高径流, 降雨对径流量的贡献大于气温。

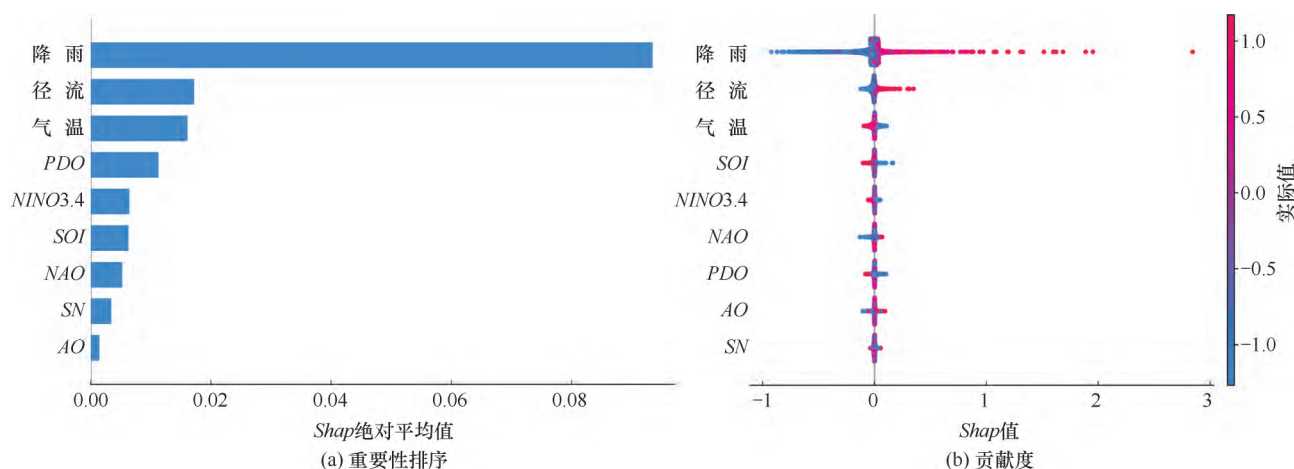


图 8 组合 G8 中 SAO-LSTM 输入特征

Fig. 8 Input features of SAO-LSTM in combination G8

图 7( b) 显示了各特征值对输出结果的具体贡献，高降雨量显著增加模型的输出结果，低降雨量则降低模型的输出结果，反映了降雨对产流过程的促进作用。但是气温对径流量的贡献则表现出了相反的趋势，这可能是高温通过加剧蒸散发、降低土壤湿度从而抑制流域的汇流过程。然而受流域特性影响，气温对径流量的影响不如降雨过程直接作用明显，导致了其 *Shap* 值较低。

进一步分析包含所有特征的组合 G8( 见图 8)。结果显示前三个关键特征排序与 G5 一致，而部分大尺度气候因子( *PDO*、*NINO3.4*、*SOI*、*NAO*、*SN*) 对模型有一定贡献，但显著低于主要水文气象因子。李蔚等<sup>[43]</sup>在分析我国南方地区气象干旱空演变规律的研究中指出，大尺度气候因子是影响该地区干湿变化的重要因素。然而，本研究结果显示，以 G8( 加入大尺度气候因子) 作为输入的预报精度反而低于以 G5 作为输入的模型，表明加入大尺度气候因子未能提升模型性能。该差异可能源于本研究所选流域空间尺度较小，因而与大尺度气候事件的联系不显著。因此，推测小流域的降水事件与大尺度气候事件联系并不密切，但其中部分指数仍在一定程度上影响着径流过程，比如高强度的 *SOI* 表现为降低流域径流量，而高强度的 *NAO* 则表现为促进径流量的增加。

#### 4 结论

本文提出了 SAO-LSTM 组合模型，在不同输入特征场景下讨论模型性能变化。通过多特征组合对比试验，比较分析了不同模型预报精度，阐述了 SAO-LSTM 模型与其他常用模型( BP 神经网络) 的性能差异。最后使用 Shapley 值法分析了不同输入特征的特

征重要性与贡献度。研究结论如下。

( 1) SAO 能够显著提高 LSTM 模型的预报精度，有效改善过拟合问题，减少模型在训练集和测试集的性能差异，提高泛化能力。

( 2) 对于深度学习模型，选取降雨量、径流量和气温作为模型输入特征可得到最佳模型预报精度。并且，在结合 SAO 算法或不结合 SAO 算法的两种情况下，LSTM 模型的预报性能均优于 BP 神经网络。

( 3) 降雨是最为关键的输入特征，很大程度上决定了模型的预报值。特征贡献度显示降雨量与预报径流值呈正相关，气温与预报径流值呈负相关。而大尺度气候事件对小流域的径流过程影响不明显，在模型输入中加入相关指数未明显提高预报性能。

本研究提出的 SAO-LSTM 组合模型在输入特征为降雨、径流、气温时达到最高预报精度，为北流河流域的水资源管理决策提供精确径流信息，同时提高了模型泛化能力。所构建的预报模型可有力支撑流域“四预”工作，降低洪涝灾害及干旱损失，也为推进径流预报模型的发展提供一定参考。

#### 参考文献( References) :

[1] 黄靖涵,王兆才,吴俊豪,等. 基于深度学习集合优化模型的径流区间预测研究[J]. 水利学报,2025,56( 2): 240-252.  
HUANG J H, WANG Z C, WU J H, et al. Research on streamflow interval prediction based on deep learning ensemble optimization model[J]. Journal of Hydraulic Engineering, 2025, 56( 2): 240-252.

[2] 夏军,左其亭. 国际水文科学研究的新进展[J]. 地球科学进展, 2006, 21( 3): 256-261.  
XIA J, ZUO Q T. Advances in international hydrological science research[J]. Advances in Earth Science, 2006, 21( 3): 256-261.

- [3] 周长乐,种法政,闫林,等. 新疆石城子河流域径流量变化规律研究[J]. 水利科学与寒区工程, 2024, 7(12): 70-78.  
ZHOU Changle, ZHONG Fazheng, YAN Lin, et al. Study on the variation characteristics of runoff in the Shichengzi River Basin, Xinjiang. *Hydro Science and Cold Zone Engineering*, 2024, 7(12): 70-78.
- [4] 张楠. 基于深度卷积神经网络的降雨径流预测方法[J]. 水利科学与寒区工程, 2024, 7(1): 90-94.  
ZHANG Nan. Rainfall-runoff prediction method based on deep convolutional neural network [J]. *Hydro Science and Cold Zone Engineering*, 2024, 7(1): 90-94.
- [5] 段亭亭,李鹏峰,邱顺添,等. 城市雨洪管理中绿灰蓝融合系统的布局优化和联合调度优化: 现状及未来方向 [J]. 水利水电技术(中英文), 2025, 56(7): 77-108.  
DUAN Tingting, LI Pengfeng, KHU Soonthiam, et al. Layout configuration and joint scheduling optimization of green-grey-blue integrated system for urban stormwater management: Current status and future directions [J]. *Water Resources and Hydropower Engineering*, 2025, 56(7): 77-108.
- [6] 严登华,袁喆,王浩,等. 水文学确定性和不确定性方法及其集合研究进展[J]. 水利学报, 2013, 44(1): 73-82.  
YAN D H, YUAN Z, WANG H, et al. Progress of certainty and uncertainty methods of hydrologic and the framework of ensemble analysis[J]. *Journal of Hydraulic Engineering*, 2013, 44(1): 73-82.
- [7] 畅明琦,刘俊萍. 兰州站径流支持向量机预测[J]. 水力发电学报, 2010, 29(4): 32-38.  
CHANG M Q, LIU J P. Prediction of the runoff at Lanzhou station with a support vector machine model [J]. *Journal of Hydroelectric Engineering*, 2010, 29(4): 32-38.
- [8] 何映颖,陈晓宏,张云,等. BP神经网络在小流域径流模拟中的应用[J]. 水文, 2015, 35(5): 35-40.  
HE Y Y, CHEN X H, ZHANG Y, et al. Application of BP neural network model in runoff simulating for small watershed[J]. *Journal of China Hydrology*, 2015, 35(5): 35-40.
- [9] 陈云飞,刘祖钰,刘秀花,等. EMD及其扩展方法在水文学中的研究进展及应用综述 [J]. 灌溉排水学报, 2025, 44(2): 101-112.  
CHEN Y F, LIU Z Y, et al. Advances and applications of empirical mode decomposition and its variants in hydrology: A review [J]. *Journal of Irrigation and Drainage*, 2025, 44(2): 101-112.
- [10] 胡义明,陈腾,罗序义,等. 基于机器学习模型的淮河流域中长期径流预报研究[J]. 地学前缘, 2022, 29(3): 284-291.  
HU Y M, CHEN T, LUO X Y, et al. Medium to long term runoff forecast for the Huai River Basin based on machine learning algorithm [J]. *Earth Science Frontiers*, 2022, 29(3): 284-291.
- [11] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [12] LATIF S D, AHMED A N. Streamflow prediction utilizing deep learning and machine learning algorithms for sustainable water supply management [J]. *Water Resources Management*, 2023, 37(8): 3227-3241.
- [13] 李明伟. 基于LSTM模型预测不同水保工程措施条件下土壤侵蚀量: 以辽西北地区为例[J]. 水土保持通报, 2023, 43(4): 162-169.  
LI M W. Estimating soil erosion under different soil and water conservation engineering measures using LSTM model: A case study in Northwest Liaoning Province [J]. *Bulletin of Soil and Water Conservation*, 2023, 43(4): 162-169.
- [14] DANESH M, GHAREHBAGHI A, MEHDIZADEH S, et al. A comparative assessment of machine learning and deep learning models for the daily river streamflow forecasting [J]. *Water Resources Management*, 2025, 39(4): 1911-1930.
- [15] IBRAHIM K S M H, HUANG Y F, AHMED A N, et al. A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forecasting [J]. *Alexandria Engineering Journal*, 2022, 61(1): 279-303.
- [16] MALIK A, TIKHAMARINE Y, SOUAG-GAMANE D, et al. Support vector regression optimized by meta-heuristic algorithms for daily streamflow prediction [J]. *Stochastic Environmental Research and Risk Assessment*, 2020, 34(11): 1755-1773.
- [17] 齐旭,芦钰冰. 基于LSTM-TCN模型的尚庄炉水库中长期径流预报研究[J]. 水利科学与寒区工程, 2025, 8(7): 30-34.  
QI Xu, LU Yubing. Research on medium and long-term runoff prediction of Shangzhuanglu Reservoir Based on LSTM-TCN Model [J]. *Hydro Science and Cold Zone Engineering*, 2025, 8(7): 30-34.
- [18] HUANG F Y, ZHANG X Y. A new interpretable streamflow prediction approach based on SWAT-BiLSTM and SHAP [J]. *Environmental Science and Pollution Research*, 2024, 31(16): 23896-23908.
- [19] ZHAO X H, LYU H F, LV S J, et al. Enhancing robustness of monthly streamflow forecasting model using gated recurrent unit based on improved grey wolf optimizer [J]. *Journal of Hydrology*, 2021, 601: 126607.
- [20] PHAM Q B, AFAN H A, MOHAMMADI B, et al. Hybrid model to improve the river streamflow forecasting utilizing multi-layer perceptron-based intelligent water drop optimization algorithm [J]. *Soft Computing*, 2020, 24(23): 18039-18056.
- [21] DENG L Y, LIU S Y. Snow ablation optimizer: A novel metaheuristic technique for numerical optimization and engineering design [J]. *Expert Systems with Applications*, 2023, 225: 120069.
- [22] NÚÑEZ J, CORTÉS C B, YÁÑEZ M A. Explainable artificial intelligence in hydrology: Interpreting black-box snowmelt-driven streamflow predictions in an arid Andean Basin of north-central Chile [J]. *Water*, 2023, 15(19): 3369.
- [23] JING X, LUO J G, ZUO G G, et al. Interpreting runoff forecasting of long short-term memory network: An investigation using the integrated gradient method on runoff data from the Han River Basin [J]. *Journal of Hydrology: Regional Studies*, 2023, 50: 101549.
- [24] 姚泰伦,肖培伟,陆宝宏,等. 考虑水文机理的深度学习径流预测模型及其可解释性[J]. 水力发电, 2025, 51(3): 12-21.  
YAO T L, XIAO P W, LU B H, et al. Deep learning-based runoff prediction models incorporating hydrological mechanisms and an analysis of model interpretability [J]. *Water Power*, 2025, 51(3): 12-21.

- 12-21.
- [25] 徐刚,胡婷婷,王琛倪. 基于深度学习的流域洪水预报模型研究[J]. 水文,2023,43(3): 82-87.  
XU G, HU T T, WANG C N. Research on watershed flood forecasting model based on deep learning[J]. Journal of China Hydrology, 2023, 43(3): 82-87.
- [26] 叶晓雨,王栋,邓清文,等. 融合双重分解与深度学习的径流预报模型构建[J]. 水文,2025,45(6): 7-15.  
YE X Y, WANG D, DENG Q W, et al. Construction of a runoff forecasting model integrating dual decomposition and deep learning[J]. Journal of China Hydrology, 2025, 45(6): 7-15.
- [27] 朱颖洁. 北流河金鸡站水沙时间变化规律及预测研究[J]. 泥沙研究,2015,40(2): 47-52.  
ZHU Y J. Study on regulation and prediction of water and sediment of Jinji station in Beiliu River[J]. Journal of Sediment Research, 2015, 40(2): 47-52.
- [28] PENG S Z, DING Y X, LIU W Z, et al. 1 km monthly temperature and precipitation dataset for China from 1901 to 2017 [J]. Earth System Science Data, 2019, 11(4): 1931-1946.
- [29] 李宏毅,林朝晖,宋燕,等. 我国华南3月份降水异常的可能影响因素因子分析[J]. 大气科学,2013,37(3): 719-730.  
LI H Y, LIN Z H, SONG Y, et al. Analysis of the possible factors that influence March precipitation anomalies over South China [J]. Chinese Journal of Atmospheric Sciences, 2013, 37(3): 719-730.
- [30] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [31] HU F C, YANG Q L, YANG J R, et al. Incorporating multiple grid-based data in CNN-LSTM hybrid model for daily runoff prediction in the source region of the Yellow River Basin [J]. Journal of Hydrology: Regional Studies, 2024, 51: 101652.
- [32] 段勇,任磊. 基于BP神经网络的黄河中游日径流预测研究[J]. 人民黄河,2020,42(S2): 5-8.  
DUAN Y, REN L. BP neural network-based daily runoff forecasting in the Yellow River Basin [J]. People's Yellow River, 2020, 42(S2): 5-8.
- [33] 付佳祥,孙甲岚,李匡,等. 基于径流特性的BP神经网络模型在中长期来水预报中的应用: 以天津市于桥水库为例[J]. 中国防汛抗旱,2025,35(2): 19-23.  
FU J X, SUN J L, LI K, et al. Application of BP neural network model based on runoff characteristics in medium and long term inflow forecasting: A case study of Yuqiao Reservoir in Tianjin City [J]. China Flood & Drought Management, 2025, 35(2): 19-23.
- [34] 王建金,石朋,瞿思敏,等. 改进BP神经网络算法在中小流域洪水预报中的应用研究[J]. 西安理工大学学报,2016,32(4): 475-480.  
WANG J J, SHI P, QU S M, et al. Application of improved BP neural network algorithm in flood forecasting in the middle and small watershed [J]. Journal of Xi'an University of Technology, 2016, 32(4): 475-480.
- [35] 许莉,常雨晴,柴霁轩,等. 基于合作博弈 Shapley 值法的类激活映射算法[J]. 计算机工程与设计,2025,46(3): 795-803.  
XU L, CHANG Y Q, CHAI J X, et al. Class activation mapping algorithm based on cooperative game Shapley value [J]. Computer Engineering and Design, 2025, 46(3): 795-803.
- [36] AAS K, JULLUM M, LØLAND A. Explaining individual predictions when features are dependent: More accurate approximations to Shapley values [J]. Artificial Intelligence, 2021, 298: 103502.
- [37] 邹红梅,朱成涛. 基于 LSTM 和 BP 神经网络的水库入库径流中长期预测比较研究[J]. 水文,2024,44(4): 27-31.  
ZOU H M, ZHU C T. Comparative study on mid-long term prediction of reservoir inflow based on LSTM and BP neural network [J]. Journal of China Hydrology, 2024, 44(4): 27-31.
- [38] CHEN C, JIANG J G, LIAO Z, et al. A short-term flood prediction based on spatial deep learning network: A case study for Xi County, China [J]. Journal of Hydrology, 2022, 607: 127535.
- [39] LANE R A, COXON G, FREER J E, et al. Benchmarking the predictive capability of hydrological models for river flow and flood peak predictions across over 1000 catchments in Great Britain [J]. Hydrology and Earth System Sciences, 2019, 23(10): 4011-4032.
- [40] 张景帅,胡彩虹. 基于深度学习模型的中小河流洪水模拟[J]. 水电能源科学,2024,42(10): 11-15.  
ZHANG J S, HU C H. Flood simulation of small and medium-sized rivers based on deep learning model [J]. Water Resources and Power, 2024, 42(10): 11-15.
- [41] 王玲,潘增辉,王春景,等. 变化环境下大清河不同支流径流演变及归因分析[J]. 南水北调与水利科技(中英文),2025,23(2): 333-342.  
WANG L, PAN Z H, WANG C J, et al. Runoff evolution and attribution analysis of different tributaries of the Daqing River under the changing environments [J]. South-to-North Water Transfers and Water Science & Technology, 2025, 23(2): 333-342.
- [42] 康永德,陈佩,许尔文,等. 基于BO-LSTM的排露沟流域气象水文演变分析及径流预测模型建立[J]. 水利水电技术(中英文),2025,56(4): 1-11.  
KANG Y D, CHEN P, XU E W, et al. Analysis of meteorological and hydrological evolution and establishment of runoff prediction model in Pailugou Watershed based on BO-LSTM [J]. Water Resources and Hydropower Engineering, 2025, 56(4): 1-11.
- [43] 李蔚,陈晓宏,吴孝情. 中国南方高度城市化地区气象干旱时空演变规律分析: 以深圳市为例[J]. 华北水利水电大学学报(自然科学版),2016,37(3): 11-18.  
LI W, CHEN X H, WU X Q. Spatio-temporal variation of meteorological drought in a highly urbanized area in Southern China, a case study in Shenzhen City [J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2016, 37(3): 11-18.

(责任编辑 王海锋)