

融合水文模型与深度学习的青海湖流域径流模拟

李娜^{1,2}, 赵永^{1,2}, 梁四海^{1,2*}, 王旭升^{1,2}, 万力^{1,2}

¹中国地质大学(北京)水资源与环境学院, 北京

²中国地质大学(北京)深时数字地球前沿科学中心, 北京

收稿日期: 2025年9月5日; 录用日期: 2025年9月30日; 发布日期: 2025年10月30日

摘要

本文聚焦我国青海湖流域的水文过程, 基于多年气象和水文动态数据, 发展了一种融合概念性水文模型FLEX (FluxExchange)和门控循环单元(Gated Recurrent Unit, GRU)的混合模型对流域内最大支流布哈河的逐日径流进行了模拟和预测。在构建混合模型中, 采用了三种策略提升模拟精度: 引入差分进化自适应算法DREAM_(zs)反演水文参数优化FLEX模型; 采用变分模态分解(VMD)提取径流数据的信息和特征; 利用麻雀搜索算法(SSA)优化深度学习GRU的参数。研究将FLEX模型的模拟结果连同气象数据一起作为神经网络的输入, 从而构建了FLEX-VMD-SSA-GRU混合模型。同时, 探讨了不同的气象输入条件对模拟结果的影响和贡献: 基于7个主要气象要素, 由少及多设置了14组输入情景模拟。最后通过SHAP对深度学习结果的分析, 揭示了气象变量对径流长期趋势的贡献和重要度。

关键词

径流模拟, 概念性水文模型FLEX, 门控循环单元GRU, FLEX-VMD-SSA-GRU混合模型, Shapley Additive Explanations (SHAP)

Integrating Deep Learning with Hydrological Models for Runoff Simulation in the Qinghai Lake Basin

Na Li^{1,2}, Yong Zhao^{1,2}, Sihai Liang^{1,2*}, Xusheng Wang^{1,2}, Li Wan^{1,2}

¹School of Water Resources and Environment, China University of Geosciences (Beijing), Beijing

²Frontiers Science Center for Deep-Time Digital Earth, China University of Geosciences (Beijing), Beijing

Received: September 5, 2025; accepted: September 30, 2025; published: October 30, 2025

作者简介: 李娜(1981-), 女, 陕西汉中, 博士, 副教授, 主要从事非饱和带土壤水文学研究。Email: lina@cugb.edu.cn

*通讯作者 Email: liangsh@cugb.edu.cn

文章引用: 李娜, 赵永, 梁四海, 王旭升, 万力. 融合水文模型与深度学习的青海湖流域径流模拟[J]. 水资源研究, 2025, 14(5): 458-470. DOI: 10.12677/jwrr.2025.145050

Abstract

This paper focuses on the hydrological processes of the Qinghai Lake Basin in China. Based on meteorological and hydrological data, this research developed a hybrid model that integrates the conceptual hydrological model FLEX (FluxExchange) with the deep learning model GRU (Gated Recurrent Unit) to simulate and predict the daily runoff of the Buha River, the largest tributary in the basin. To enhance the simulation accuracy of the hybrid model, three strategies were employed: The DREAM_(zs) was used to invert hydrological parameters and optimize the FLEX model. Variational Mode Decomposition (VMD) was applied to extract hidden information and features from the runoff time series. The Sparrow Search Algorithm (SSA) was used to optimize the parameters of the GRU neural network. By placing the FLEX model in the first layer of the neural network, this research constructed the FLEX-VMD-SSA-GRU hybrid model. This paper also explored the influence and contribution of different meteorological input conditions on the simulation results by creating 14 input scenarios with varying numbers of the seven main meteorological elements. Finally, SHAP (Shapley Additive Explanations) was used to analyze and reveal the contribution and importance of each meteorological variable to the long-term runoff trend.

Keywords

Runoff Simulation, Conceptual Hydrological Model (FLEX), Gated Recurrent Unit (GRU), FLEX-VMD-SSA-GRU Hybrid Model, SHAP (Shapley Additive Explanations)

Copyright © 2025 by author(s) and Wuhan University & Bureau of Hydrology, Changjiang Water Resources Commission. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 研究背景与意义

青海湖作为青藏高原最大的湖泊,是我国西部生态安全屏障和水资源调配的核心组成部分[1]。流域内水文过程长期变化的定量化模拟对于研究生态环境演化具有十分重要的科学意义。特别地,流域径流量的准确评估在灌溉调度、水资源管理系统的设计和实施、生态环境保护、洪水预警和防治等领域中发挥着关键作用[2]-[5]。然而,径流受多种相互制约的因素控制,如降水、融雪、气温、土地利用、河流形态、湖面面积和集水区特征等[6] [7],因此径流的准确模拟和预测一直是水文学领域的挑战性问题。此外,径流变化规律受气候、流域自然地理条件以及人类活动等多元因素影响,呈现出复杂多变的特性,包括多时间尺度、突变性和非线性等特点。

近年来,水文过程模拟方法通常包括基于过程的物理模型,如 SWAT、HBV、VIC、新安江模型等[8],以及基于机器学习/深度学习的数据驱动模型,如 SVM、LSTM、GRU、Transformer 等[9]。水文过程驱动模型通常需要多种输入数据,如气象、土壤、地形、植被、土地利用等。水文过程模型能够对预测结果的成因做出物理解释,然而模型的简化程度、数据误差以及对流域水文过程概念性模型的偏差带来了水文模型的误差和不确定性。数据驱动模型不考虑这些复杂因素与水文过程之间直接的物理关系和影响机制,旨在建立最佳的输入和输出之间的数学关系,避免了模型参数和模型的不确定性带来的建模误差,在水文过程模拟中逐渐展现出较强的应用潜力。然而,这类方法通常被称为黑箱模型,难以清晰展示模型输入对输出的约束以及两者的物理关系。因此,耦合物理模型和数据驱动模型,整合并利用两者各自的优势,为水文过程模拟和预测带来了新的思路。特别是随着深度学习方法快速发展,建立耦合径流预测模型已成为一种广泛的研究趋势[10] [11],特别是对高寒缺资料地区具有更大的应用潜力[12] [13]。

基于上述背景,本文分析了青海湖流域气象水文要素的演变规律,构建了基于水文模型 FLEX 和深度学习算法 GRU 的混合模型,模拟预测了 2000~2011 年青海湖流域逐日径流演变规律,并利用 SHAP 可解释性算法揭示了影响径流变化的关键驱动因子。FLEX (FluxExchange)水文模型是集总式概念性水文模型[12],由主衰退曲线推导出蓄存-排泄关系,克服了通常对低流量的忽略,能够高性能地模拟峰值流量。这一模型适合于干旱、寒冷区域,展示了模型框架在刻画流域多样性多尺度性方面的潜力[14]。门控循环单元(GRU)隶属递归神经网络(Recurrent Neural Network, RNN),是长短期记忆(Long Short-Term Memory, LSTM)网络的一种有效变种[15]。GRU 在表达上更优化和简洁,擅长捕捉长时间序列数据特征,并已成功应用于水文预报领域[16]。

同时,为了增强 FLEX-GRU 混合模型的性能,本文采用了三种策略:1)应用差分进化自适应算法(Differential Evolution Adaptive Metropolis algorithm, DREAM_(zs)) [17]反演 FLEX 水文模型参数从而优化模型;2)在深度神经网络训练模型之前采用变分模态分解(Variational Model Decomposition, VMD) [18]提取径流序列数据的隐含信息和特征;3)利用麻雀搜索算法(Sparrow Search Algorithm, SSA) [19]对深度学习 GRU 的超参数进行优化。此外应用 Shapley Additive Explanations (SHAP)方法[20]分析输入特征对输出的贡献从而揭示气象要素对径流的影响及重要度。

本文以青海湖流域的第一大支流布哈河为研究区域,基于 2000~2011 年布哈河口水文站的逐日气象和径流观测数据,首先采用 DREAM_(zs)方法优化 FLEX 水文模型对多年径流进行模拟,然后通过变分模态分解 VMD 对 FLEX 水文模型得到的径流数据预处理,并将其与构建的 SSA-GRU 多维神经网络模型进行结合进行模型训练,构建组合模型 FLEX-VMD-SSA-GRU,最后利用 SHAP 结果分析影响日径流的关键气象因子。模拟结果显示,将水文模型和深度学习方法相结合,并引入更多的气象因子作为输入,显著提高了对径流峰值的预测精度,为高海拔寒旱区流域水文过程的模拟和预测提供了一种新方法,并阐释了影响水文过程的关键气象要素。

2. 研究区概况及数据收集

2.1. 研究区概况

研究区为我国青藏高原青海湖流域内的第一大支流布哈河,如图 1 所示。布哈河流域地处青海湖流域西北部,是青海湖流域内最大的子流域,研究区域主要涵盖天峻县及流域周边的刚察县和共和县。布哈河源头为疏勒南山,自西北向东南蜿蜒流动,最终汇入青海湖。流域内海拔变化显著,跨越 3185 m 到 5229 m,平均海拔为 4172 m,4000 m 至 4500 m 之间的海拔区间面积占据整个流域的 47.69%。布哈河流域的集水面积近 15,000 km²,流域宽度为 50 km,河流长度约为 286 km,多年平均流量为 $7.85 \times 10^8 \text{ m}^3$,占据青海湖入湖总量的 50%~60%。

布哈河流域多年平均降水量在 300~500 mm 之间,潜在蒸发量在 1000~2000 mm 之间,地区分布不均,年际变化较小。西格尔区上游分布有少量冰川,分布在布哈河支流中的冰川总面积约 13.29 km²,每年消融水量在 $0.07 \times 10^8 \text{ m}^3$ 左右,占布哈河每年径流量的近 0.9%。布哈河年内径流分布极不均匀,在汛期(6 月至 9 月)占全年的 82.7%,而在枯水期(12 月至次年 3 月)仅占全年的 3.24%。

2.2. 数据来源及预处理

径流数据选取布哈河口水文站 2000~2011 年的日径流观测数据。气象资料来源于中国气象数据网和青海省气象局。采用距离权重反比法对布哈河流域周边的托勒、野牛沟、张掖、祁连、山丹、德令哈、刚察、门源、都兰、共和、西宁、贵德 12 个气象站点的观测数据插值,得到布哈河流域的气象数据。模型构建中,2000~2001 年为 FLEX 模型预热期,2002~2008 年为 FLEX 模型的率定期(深度学习模型的训练期),2009~2011 年为 FLEX 模型的验证期(深度学习模型的测试期)。




图 1. 研究区概况图：左图为青海湖流域位置图，右图为布哈河流域地形图(根据高程数据用 ArcGiss 所画)

3. 主要研究方法

3.1. FLEX-DREAM_(ZS)模型

FLEX (FluxExchange)模型是一种集总式概念性水文模型，通过模拟流域内主要水文过程实现径流估算。本文采用 FLEX 建模框架构建日尺度降雨 - 径流模型，输入为日降水量与潜在蒸发量，输出为逐日径流量。模型结构由三部分组成：① 截留层，以截留水箱模拟冠层截留与蒸发；② 非饱和层，表征土壤蓄水能力及水分垂直运移；③ 径流层，由快速响应水箱(产生地表径流与壤中流)和慢速响应水箱(产生地下径流)耦合而成。产流机制以饱和过剩产流为主，径流量被参数化为流域相对蓄水量的非线性函数，弱化对降雨强度的瞬时依赖。图 2 左侧展示了 FLEX 模型的基本框架和计算流程。图中 P 表示降雨， E 表示蒸发， P_e 表示有效降雨， E_a 表示实际蒸发， S_0 表示排泄至非饱和土壤层的径流， S_f 表示排泄至快速响应水库的径流， S_s 表示排泄至慢速响应水库的径流， Q 表示总径流， Q_f 表示快速径流； Q_s 表示慢速径流。

FLEX 模型的主要参数(表 1 中所示)由 DREAM_(ZS)算法进行反演。DREAM_(ZS)(DiffeRential Evolution Adaptive Metropolis algorithm)是一种改进的多链马尔可夫链蒙特卡罗(Markov Chain Monte Carlo, MCMC)算法，结合了差分进化、子空间探索、过去状态采样以及多重尝试的 Metropolis 采样策略。该算法通过多条交互式马尔可夫链并行探索参数空间法，从而动态调整采样策略，更高效地收敛到目标分布，展现出强大的收敛能力和鲁棒性，常被用于水文模型中的贝叶斯推断和参数估计。

3.2. VMD-SSA-GRU 深度神经网络

研究表明，模态分解在处理非线性、非平稳信号时表现出色，能有效提取信号中的本征模态函数，从而去

除噪声、分离不同来源的振动成分。变分模态分解(VMD) [18]是一种将信号分解过程转化为变分优化问题的创新方法,将信号分解转化为变分优化问题,是一个完全非递归的变分模式分解模型,一次性提取 K 个本征模态,同时估计其中心频率。VMD 在其非递归框架内置维纳滤波,它表现出强大的抗干扰能力,可抑制高斯白噪声并避免模态混叠;通过约束各模式在基带解调后的平滑性,实现信号-噪声自适应分离,具有鲁棒性强、无混叠、可并行等优点。VMD 与 GRU 网络结合的流程在图 2 中间示意。

麻雀搜索算法(SSA)是一种受自然启发的元启发式优化算法。该算法是以麻雀的觅食和防捕食行为为模型的群体智能仿生算法[19],模拟了麻雀种群在觅食过程中不同个体间的分工与社会互动。此外,算法中预警机制的引入有效防止了算法陷入局部最优。因为算法的结构简单、收敛快,已被广泛用于时间序列预测、神经网络参数优化等任务。图 2 右侧展示了 SSA 的主要步骤。

门控循环单元(GRU)通常被视为更复杂的 LSTM 网络的简化版本。它专门设计用于处理序列数据并解决基础 RNN 的常见问题。GRU 通过合并 LSTM 中的遗忘门和输入门,保留原有的重置门,从而简化了模型结构。这一简化使得 GRU 在计算时减少了矩阵乘法的计算,因此在大规模样本时,能够在保持预测效果的同时,显著降低计算时间。GRU 的基本结构展示在图 2 中间。

3.3. FLEX-VMD-SSA-GRU 混合模型

基于上述方法将 FLEX 模型的模拟结果与其相关数据一起作为深度学习的输入进行模型训练,构建了 FLEX-VMD-SSA-GRU 混合模型,结构如图 2 所示。




图 2. FLEX-VMD-SSA-GRU 混合模型结构示意图

3.4. SHAP 可解释性方法

SHAP 是以合作博弈论为基石的机器学习结果解释模型,通过计算 Shapley 值精确量化其对单次预测结

果的边际贡献。与传统“全局重要性”仅能排序不同，SHAP 同时给出方向与强度。SHAP 值的最大优势是能反映每个变量特性的影响，并且还显示出正负影响。SHAP 为正，则贡献为正影响推高预测，否则贡献为负影响抑制预测，从而揭示影响模型结果的原因和程度。SHAP 的绝对值越大，说明特征 i 的贡献越大。其计算公式为：

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} [f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S)] \quad (1)$$

式中： ϕ_i 为特征在样本中的 SHAP 值， S 是特征的子集； F 是所有特征子集的集合； x_S 表示集合 S 中输入特征的值； $f_{S \cup \{i\}}$ 是用特征 i 训练模型 f 。

3.5. 模型评价指标

为了评估所构建的混合在径流模拟中的性能，选用了纳什效率系数 NSE、平均绝对误差 MAE、平均相对误差 MAPE、均方根误差 RMSE，以及决定系数 R^2 等五种评价指标。这些指标从不同角度反映了模型的预测能力、稳定性和准确性。其中，NSE 能够综合评估模型的预测效能，而 MAPE 和 R^2 则用以衡量模型的稳定程度；MAE 和 RMSE 则侧重于反映模型的预测准确程度。它们的表达式如下：

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - y_o)^2}{\sum_{i=1}^n (y_o - \bar{y}_o)^2} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_o| \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y_o}{y_o} \right| \times 100\% \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y_o)^2}{n}} \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_o - y_i)^2}{\sum_{i=1}^n (|y_o - \bar{y}_o| + |y_i - \bar{y}_i|)^2} \quad (6)$$

上式中， y_i 表示径流模拟值， y_o 表示径流实测值， $\bar{y}_o$ 表示实测径流的平均值， n 为径流序列样本个数。

4. 结果与分析

4.1. 基于 FLEX-DREAM_(ZS)模型的径流模拟

首先结合 FLEX 水文模型和参数优化方法 DREAM_(ZS) 对 2000~2011 年布哈河径流量进行模拟。输入数据为日降水和日蒸发数据。为了削弱初始状态的不确定性对模型预测结果的影响，将 2000 年 1 月 1 日~2001 年 12 月 31 日作为模型的预热期，2002 年 1 月 1 日~2011 年 12 月 31 日的数据对模型进行率定和验证。其中，2002 年 1 月 1 日~2008 年 12 月 31 日为率定期，2009 年 1 月 1 日~2011 年 12 月 31 日为验证期。

采用 DREAM_(ZS) 反演 FLEX 水文模型的七个水文参数，包括最大截留量 $I_{\max}$ ，土壤蓄水量 $S_{\max}$ ，最大下渗率 $Q_{\max}$ ，蒸发量参数 α_E ，径流参数 α_F ，快速水库响应时间常数 K_F 和慢速水库响应时间常数 K_S ，率定结果如表 1 所示。

基于反演得到的水文模型参数，模拟和预测布哈河的径流变化。图 3 中展示了 FLEX 模型模拟的日径流和

实际观测值的对比。可以看到，无论是在率定期还是验证期，模拟值与实测值的变化趋势大致相同，同时模型总体上能够捕捉到径流量的峰值，特别是对低谷值有很好的刻画。然而 FLEX 模型在高峰值模拟方面仍然面临挑战，特别是在 2002、2005、2006 和 2008 年。因此尝试将 FLEX 模型和深度学习方法相结合，旨在提高径流模拟的精度。

表 1. FLEX 模型参数的率定结果

参数	单位	范围	率定值
最大截留量(I_{max})	mm	0~1	0.292
土壤蓄水量(S_{max})	mm	1~5000	4593.396
最大下渗率(Q_{smax})	mm/d	0~100	75.758
蒸发系数(α_E)	-	0~200	169.696
径流系数(α_F)	-	-100~100	47.996
快速水库响应时间(K_F)	days	0~100	1.282
慢速水库响应时间(K_S)	days	0~200	5.783




图 3. FLEX 模型模拟的日径流和实际观测值的对比

4.2. 基于 FLEX-VMD-SSA-GRU 的径流模拟

4.2.1. VMD 分解结果

在利用 GRU 训练径流模型之前，首先采用 VMD 分解算法对 FLEX 模型模拟得到的径流序列进行预处理，提取径流序列的主要特征。VMD 算法核心参数为模态分量个数 K ，由图 4 所示，针对布哈河径流数据的 K 值为 13。




图 4. 基于 VMD 的布哈河流域径流数据的分解图

4.2.2. VMD-SSA-GRU 模型参数及输入设置

本文采用麻雀搜索算法 SSA 优化深度神经网络 GRU 模型的超参数。SSA 的种群规模为 100，最大迭代次数为 50，20%为发现者，其余为追随者，警告值为 0.8。设置 GRU 层神经元个数 N_1 、 N_2 和每批次样本数量的取值范围分别为[10, 200]，[10, 200]和[100, 500]。优化得到的 GRU 的隐藏层个数为 2，隐含层节点为 10，初始学习率为 0.001。

为了筛选出合理有效的气象因子作为混合模型的输入，本研究采用通过皮尔逊、肯德尔、斯皮尔曼三种相关性分析方法评估了各气象因子与径流的相关性，确定了相关性较高的日降水 P 、日蒸发 E 、基于日温度的最大、最小和平均温度($T_{\max}$, $T_{\min}$, T_{mean})、相对湿度 RH 和地表净辐射 R_n 七个气象要素。各气象变量与模拟日径流的相关性如表 2 所示。这七个气象要素将与 FLEX 模型模拟的日径流通过设置不同的组合方式一同作为深度神经网络模型的输入。与 FLEX 模型保持一致，2002 年 1 月 1 日~2008 年 12 月 31 日为模型训练期(占全部数据集的 70%)，2009 年 1 月 1 日~2011 年 12 月 31 日为模型测试期(占全部数据集的 30%)。

表 2. 各气象因子与日径流的相关性

相关性 分析方法	日蒸发/ E	日降水/ P	日均温度/ T_{mean}	日最高温度/ $T_{\max}$	日最低温度/ $T_{\min}$	相对湿度/ RH	地表净辐射/ R_n	日照时长/ N	风速/ U
皮尔逊	0.45	0.37	0.57	0.57	0.65	0.56	0.42	0.03	0.12
肯德尔	0.3	0.17	0.45	0.42	0.49	0.42	0.24	0.03	0.07
斯皮尔曼	0.45	0.27	0.66	0.62	0.70	0.63	0.37	0.04	0.11

以这七个气象变量与 FLEX 模拟结果进行不同组合，共设置 14 组不同输入的情景。其中情景 FLEX 为仅以 FLEX 的输出结果 Q_F 作为深度学习的输入；情景 1~情景 7 是在 Q_F 的基础上，增加单一气象变量；情景 8~情景 13 是在 Q_F 的基础上，依次累加一个气象变量。表 3 列出了用于实现 FLEX 模型和神经网络结合的混合模型的输入组合。

表 3. 混合模型的输入设置(F-VSG 中 F 代指 FLEX, VSG 代指 VMD-SSA-GRU)

情景	模型	输入
0	FLEX	Q_F
1	F-VSG1	Q_F, P
2	F-VSG2	Q_F, E
3	F-VSG3	Q_F, RH
4	F-VSG4	Q_F, R_n
5	F-VSG5	Q_F, T_{mean}
6	F-VSG6	Q_F, T_{max}
7	F-VSG7	Q_F, T_{min}
8	F-VSG8	Q_F, P, E
9	F-VSG9	$Q_F, P, E, T_{\text{mean}}$
10	F-VSG10	$Q_F, P, E, T (T_{\text{mean}}, T_{\text{max}})$
11	F-VSG11	$Q_F, P, E, T (T_{\text{mean}}, T_{\text{max}}, T_{\text{min}})$
12	F-VSG12	$Q_F, P, E, T (T_{\text{mean}}, T_{\text{max}}, T_{\text{min}}), RH$
13	F-VSG13	$Q_F, P, E, T (T_{\text{mean}}, T_{\text{max}}, T_{\text{min}}), RH, R_n$

4.2.3. FLEX-VMD-SSA-GRU 模型的径流模拟结果

14 种情景下的径流模拟结果显示在图 5(a)和图 5(b)中，可以看到所有模型能够刻画径流的总体趋势。为了更清晰地对比不同输入的模拟结果，将 2010 年 12 月的结果进行了局部放大，如图中所示。F-VSG13 相比于其他组合更接近实测值，特别在低径流时期，围绕实测值波动，且波动幅度更小。

为了进一步量化评估混合模型在不同输入情景下的模拟结果，将上面 14 个模型模拟的径流与实测数据对比，并统计了评价指标，详见表 4。总体来看，随着输入中气象变量的增加，FLEX 模拟的日径流精度逐步提高，其中输入因子最多的情景 F-VSG13 的模拟精度也最高。与单独 FLEX 水文模型结果相比，F-VSG13 得到的测试集对应的 NSE 和 R^2 分别提高了 10%和 5%，MAE、MAPE 和 RMSE 分别降低 21%、19%和 15%。由此可见，水文模型对深度学习的优化策略具有引导作用，同时利用了深度学习对数据特征较强的学习能力，相较于水文模型，混合模型在模拟和预测径流过程中展示出模拟精度的优势。

表 4. 混合模型模拟结果的评价指标(F-VSG 中 F 代指 FLEX, VSG 代指 VMD-SSA-GRU)

评价指标	训练集					测试集				
	NSE	MAE	MAPE	RMSE	R^2	NSE	MAE	MAPE	RMSE	R^2
FLEX	0.755	0.069	0.586	0.141	0.871	0.719	0.080	0.477	0.157	0.851
F-VSG1	0.744	0.070	0.604	0.145	0.864	0.721	0.080	0.477	0.156	0.851
F-VSG2	0.742	0.071	0.731	0.145	0.864	0.723	0.080	0.572	0.155	0.852

续表

F-VSG3	0.744	0.070	0.640	0.145	0.864	0.723	0.079	0.510	0.156	0.852
F-VSG4	0.742	0.070	0.608	0.145	0.864	0.722	0.079	0.458	0.156	0.852
F-VSG5	0.772	0.068	0.621	0.136	0.880	0.760	0.074	0.427	0.145	0.874
F-VSG6	0.744	0.070	0.603	0.144	0.865	0.759	0.074	0.419	0.145	0.873
F-VSG7	0.744	0.070	0.602	0.145	0.864	0.759	0.074	0.425	0.145	0.873
F-VSG8	0.744	0.071	0.758	0.145	0.864	0.725	0.080	0.605	0.155	0.852
F-VSG9	0.772	0.069	0.675	0.136	0.880	0.758	0.075	0.454	0.145	0.873
F-VSG10	0.781	0.068	0.637	0.134	0.884	0.765	0.074	0.476	0.143	0.876
F-VSG11	0.789	0.066	0.635	0.131	0.891	0.771	0.073	0.451	0.142	0.879
F-VSG12	0.799	0.065	0.586	0.128	0.895	0.780	0.072	0.434	0.138	0.885
F-VSG13	0.806	0.064	0.550	0.126	0.898	0.793	0.068	0.367	0.134	0.892




图 5. 不同输入条件下得到的日径流模拟值与实测值之间的对比：左图为情景 F-VGS1~F-VGS7 与情景 FLEX 的对比，右图 为情景 F-VGS8~F-VGS13 与情景 FLEX 的对比

为了更加全面评估 FLEX-VMD-SSA-GRU 模型对大小不同程度径流量的模拟能力,将实测径流数据按照<5%、5%~95%、>95%的标准划分为三个区间:低径流(0~0.01 mm/d)、中径流(0.01~0.8 mm/d)和高径流(>0.8 mm/d),并通过评估指标对比了 FLEX 模型和 F-VSG13 模型在不同区间对径流模拟的结果,如图 6(a)、图 6(b)和图 6(c)所示。总体上,对于高中低三个区间的径流动态, F-VSG13 的模拟精度都高于 FLEX 模型。更进一步,相较于 FLEX 模型, F-VSG13 对高径流的模拟精度提升幅度较大, MAE、MAPE 和 RMSE 分别下降 50.7%、50.9%和 54.7%;中径流模拟精度的提高幅度次之, MAE、MAPE 和 RMSE 分别下降 13.6%、21.7%和 14.9%;低径流模拟精度提升的幅度最小, MAE、MAPE 和 RMSE 分别下降 17%、16.7%和 13.6%。这表明混合模型对于刻画高径流更有优势。

4.3. 基于 SHAP 的可解释性分析

为了解释模型的输入和输出之间的决策关联,提高混合模型的透明度,采用 SHAP 可解释性方法计算了各输入变量对径流长期趋势的贡献,结果如图 7 所示。图 7(a)为各气象变量对应的 SHAP 值,按照从大到小排列,图 7(b)为各气象变量的 SHAP 平均值,蓝色表示低值,红色表示高值。从图中可见,气温(包括 T_{mean} 、 T_{max} 、 T_{min})对径流长期趋势的影响最为显著,且 T_{mean} 和 T_{min} 与径流量之间存在较强的正相关关系。其原因可归于布哈河流域处于青藏高原这一高海拔地区,上游分布有部分冰川,因此在解冻期内冰川融雪增加了布哈河径流量。同时,温度引起的季节性冻土融化也会导致径流增加。影响径流的因素其次有蒸发 E 、降水 P 和相对湿度 RH ,其中蒸发主要表现为负相关关系,降水主要表现为正相关关系。地表辐射 R_n 影响程度最低。




图 6. FLEX 模型和 F-VSG13 模型模拟的日径流对应的误差指标直方图: (a) MAE, (b) MAPE, (c) RMSE




图 7. 不同气象变量对径流长期趋势的贡献: (a) 各气象变量的 SHAP 值, (b) 各气象变量的平均贡献值

5. 结论

本研究基于概念性水文模型 FLEX 和深度学习方法 GRU 构建了一种径流模拟预测的混合模型 FLEX-VMD-SSA-GRU, 并将模型应用于我国青海湖流域的第一大支流布哈河。该模型基于优化的 FLEX 模拟得到的径流结果, 并利用变分模态分解 VMD 对模拟数据进行预处理, 然后和 GRU 神经网络(通过麻雀搜索算法 SSA 优化网络超参数)相结合得到径流模拟的混合模型。模拟结果显示, 混合模型能够有效模拟径流的总体局势和峰值, 并且更多的气象输入因子有利于获得更高的模拟精度。此外, 采用 SHAP 可解释性方法评估了日降水量、日潜在蒸发量、日平均、日最低和日最高气温、相对湿度和地表净辐射七种气象变量对径流长期趋势的贡献。研究表

明气温对于径流有着最为重要的影响, 因此输入中加入气温能够有效提高径流模拟精度。

基金项目

国家自然科学基金项目“基于多变量多尺度数据反演变饱和带水力参数的理论与方法”(项目编号: 42272280); 中央高校基本科研业务费“深时数字地球”前沿科学中心“深时数字地球”中央高校科技领军人才团队项目(项目编号: 2652023001); 中国科学院战略性先导科技专项(项目编号: XDA20100103)。

致谢

感谢硕士研究生: 樊雨萱、邢琳婧在图 1 和图 2 制作中的贡献。

参考文献

- [1] ZHANG, G., RAN, Y., WAN, W., et al. 100 years of lake evolution over the Qinghai-Tibet Plateau. *Earth System Science Data*, 2021, 13(8): 3951-3966. <https://doi.org/10.5194/essd-13-3951-2021>
- [2] MEHR, A. D. An improved gene expression programming model for streamflow forecasting in intermittent streams. *Journal of Hydrology*, 2018, 563: 669-678. <https://doi.org/10.1016/j.jhydrol.2018.06.049>
- [3] AWCHI, T. A. River discharges forecasting in northern Iraq using different ANN techniques. *Water Resources Management*, 2014, 28: 801-814. <https://doi.org/10.1007/s11269-014-0516-3>
- [4] VOGEL, R. M., LALL, U., CAI, X., et al. Hydrology: The interdisciplinary science of water. *Water Resources Research*, 2015, 51(6): 4409-4430. <https://doi.org/10.1002/2015wr017049>
- [5] KISI, O., PARMAR, K. S. Application of least square support vector machine and multivariate adaptive regression spline models in long term prediction of river water pollution. *Journal of Hydrology*, 2016, 534: 104-112. <https://doi.org/10.1016/j.jhydrol.2015.12.014>
- [6] YASEEN, Z. M., EBTEHAJ, I., BONAKDARI, H., et al. Novel approach for streamflow forecasting using a hybrid ANFIS-FFA model. *Journal of Hydrology*, 2017, 554: 263-276. <https://doi.org/10.1016/j.jhydrol.2017.09.007>
- [7] ADNAN, R. M., LIANG, Z., HEDDAM, S., et al. Least square support vector machine and multivariate adaptive regression splines for streamflow prediction in mountainous basin using hydro-meteorological data as inputs. *Journal of Hydrology*, 2020, 586: 124371. <https://doi.org/10.1016/j.jhydrol.2019.124371>
- [8] HORTON, P., SCHAEFLI, B. and KAUZLARIC, M. Why do we have so many different hydrological models? A review based on the case of Switzerland. *WIREs Water*, 2022, 9: e1574.
- [9] MOHAMMADI, B. A review on the applications of machine learning for runoff modeling. *Sustainable Water Resources Management*, 2021, 7(6): 98. <https://doi.org/10.1007/s40899-021-00584-y>
- [10] YU, Q., JIANG, L., WANG, Y. and LIU, J. Enhancing streamflow simulation using hybridized machine learning models in a semi-arid basin of the Chinese Loess Plateau. *Journal of Hydrology*, 2023, 617: 129115. <https://doi.org/10.1016/j.jhydrol.2023.129115>
- [11] JIANG, S., ZHENG, Y. and SOLOMATINE, D. Improving ai system awareness of geoscience knowledge: Symbiotic integration of physical approaches and deep learning. *Geophysical Research Letters*, 2020, 47(13): e2020GL088229. <https://doi.org/10.1029/2020gl088229>
- [12] ZHONG, L., LEI, H. and YANG, J. Development of a distributed physics-informed deep learning hydrological model for data-scarce regions. *Water Resources Research*, 2024, 60(6): e2023WR036333.638. <https://doi.org/10.1029/2023wr036333>
- [13] 南天一, 陈杰, 丁智威, 李威, 陈华. 基于深度学习的青藏高原多源降水融合[J]. *中国科学: 地球科学*, 2023, 53(4): 836-855.
- [14] FENICIA, F., KAVETSKI, D. and SAVENIJE, H. H. G. Elements of a flexible approach for conceptual hydrological modeling: 1. motivation and theoretical development. *Water Resources Research*, 2011, 47(11): W11511. <https://doi.org/10.1029/2010wr010174>
- [15] 王璟京, 高红凯, 刘敏, 等. 参数区域化在全球水文模型 FLEX-Global 中的应用[J]. *中国科学: 地球科学*, 2021, 51(5): 805-823.
- [16] HU, R., FANG, F., PAIN, C. C., et al. Rapid spatio-temporal flood prediction and uncertainty quantification using a deep learning method. *Journal of Hydrology*, 2019, 575: 911-920. <https://doi.org/10.1016/j.jhydrol.2019.05.087>
- [17] VRUGT, J. A. Markov chain monte carlo simulation using the dream software package: Theory, concepts, and Matlab implementation.

- Environmental Modelling & Software, 2016, 75: 273-316. <https://doi.org/10.1016/j.envsoft.2015.08.013>
- [18] LAHMIRI, S. Long memory in international financial markets trends and short movements during 2008 financial crisis based on variational mode decomposition and detrended fluctuation analysis. Physica A: Statistical Mechanics and Its Applications, 2015, 437: 130-138. <https://doi.org/10.1016/j.physa.2015.05.067>
- [19] XUE, J., SHEN, B. A novel swarm intelligence optimization approach: Sparrow search algorithm. Systems Science & Control Engineering, 2020, 8(1): 22-34. <https://doi.org/10.1080/21642583.2019.1708830>
- [20] LUNDBERG, S. M., ERION, G., CHEN, H., et al. From local explanations to global understanding with explainable AI for trees. Nature Machine Intelligence, 2020, 2(1): 56-67. <https://doi.org/10.1038/s42256-019-0138-9>