

基于多种机器学习模型的大汶河流域径流模拟与对比分析

肖翔¹, 李妍妍^{2,3,4}, 安晓洁^{2,3,4}, 刘健^{2,3,4}, 李璨^{5*}

1. 山东省水文中心, 山东 济南 250000
2. 山东省水利科学研究院, 山东 济南 250013
3. 山东省水网调度与水资源高效利用重点实验室, 山东 济南 250013
4. 农村供水安全保障山东省工程研究中心, 山东 济南 250013
5. 水发规划设计有限公司, 山东 济南 250013

摘要: 为探究不同机器学习模型在月径流模拟中的适用性与模拟效果, 本文以大汶河流域为研究区域, 通过 Mann-Kendall 检验和 Sen's slope 方法分析了 1961-2019 年水文气象要素的变化趋势、突变特征和相关关系, 构建了基于卷积神经网络(CNN)、长短期记忆网络(LSTM)和 Transformer 的月尺度径流模拟模型, 并系统对比了三种模型的模拟效果。结果表明: 研究时段内流域降水和径流均呈现出显著下降趋势, 气温显著上升, 蒸散发、气压和日照时长显著下降; 其中, 降水发生多次突变, 年际变化较大; 径流在 1966 年和 2013 年发生两次突变, 受人类活动影响较大; 在月径流的模拟中 Transformer 表现最佳, 测试期 NSE 和 R 分别达到 0.74 和 0.87; 此外, Transformer 具备较强的稳定性与泛化能力, 能够在人类活动干扰背景下有效提取不同时期气象要素与径流之间的内在一致性关系, 从而实现径流过程的精确模拟。

关键词: 径流模拟; 机器学习; 大汶河流域; 气候变化

中图分类号: P338+.1

文献标识码: A

文章编号: 1000-2324(2026)05-0962-10

Runoff Simulation and Comparative Analysis of the Dawen River Basin Based on Multiple Machine Learning Models

XIAO Xiang¹, LI Yan-yan^{2,3,4}, AN Xiao-jie^{2,3,4}, LIU Jian^{2,3,4}, LI Can^{5*}

1. Shandong Hydrological Center, Jinan 250000, China
2. Water Research Institute of Shandong Province, Jinan 250013, China
3. Shandong Provincial Key Laboratory of Water System Operation and Efficient Utilization of Water Resources, Jinan 250013, China
4. Shandong Engineering Research Center for Rural Water Supply Security, Jinan 250013, China
5. Shuifa Planning and Design Co., Ltd., Jinan 250113, China

Abstract: To explore the applicability and simulation performance of different machine learning models in monthly runoff simulation, this paper takes the Dawen River Basin as the study area. Using the Mann-Kendall test and Sen's slope method, it analyzes the trends, abrupt changes, and correlations of hydrometeorological variables from 1961 to 2019. It constructs monthly streamflow simulation models based on the Convolutional Neural Network (CNN), Long Short-Term Memory network (LSTM), and Transformer, and systematically compares the simulation results of the three models. The results indicate that during the study period, both precipitation and streamflow exhibited no significant decline, while temperature increased significantly, and evapotranspiration, air pressure, and sunshine duration decreased markedly. Precipitation experienced multiple abrupt changes with strong interannual variability; streamflow exhibited two abrupt shifts in 1966 and 2013, showing a strong influence of human activities. In monthly streamflow simulation, the Transformer performed best, achieving NSE and R values of 0.74 and 0.87, respectively, during the testing period. Furthermore, the Transformer demonstrated strong stability and generalization capability, effectively capturing the intrinsic consistency between meteorological variables and streamflow under the influence of human activities, thereby enabling accurate simulation of the streamflow process.

Keywords: Runoff simulation; machine learning; Dawen River Basin; climate change

在气候变化与人类活动的双重影响下, 全球水资源总量及其空间分布格局发生了显著改变, 洪水、干旱等极端水文事件频发, 加之日益增长的人类用水需求, 水资源短缺问题日趋严峻^[1,2]。

收稿日期: 2025-10-09

修回日期: 2026-09-15

基金项目: 变化环境下山东省水循环变异与水资源情势研究(山东省重点水利科技项目, No. SDSLKJ2024003)

第1作者简介: 肖翔(1987-), 男, 硕士, 高级工程师, 研究方向: 水文水资源。E-mail: xiaoxiangqd@163.com

*通讯作者: Author for correspondence. E-mail: lican0223@163.com.

作为地表水循环的关键环节,河川径流是气候条件、下垫面特征等多重因素共同作用形成的复杂水文过程的综合体现^[3]。近年来,众多流域的水文要素呈现出显著的突变或趋势性变化,对区域生态安全和社会经济发展产生了深远影响^[4-6]。因此,深入解析河川径流等关键水文要素的变异特征,不仅有助于揭示变化环境下流域水循环的演变机制,更能为水资源合理配置与管理提供科学依据,具有重要的理论价值与实践意义^[7]。

随着人工智能技术的快速发展,机器学习方法在径流模拟与预测领域展现出广阔的应用前景^[8]。凭借强大的学习能力和灵活的模型架构,机器学习方法能够有效处理多源异构数据,实现高性能的水文过程模拟。Kratzert等^[9]在融雪补给流域构建了长短期记忆神经网络(LSTM)降雨-径流模型,通过与经典萨克拉门托模型的对比研究表明,LSTM模型在模拟精度方面与传统水文模型相当。Xu等^[10]创新性地将卷积神经网络(CNN)与门控循环单元(GRU)相结合,应用于长江干支流6个水文站的径流预测,结果显示干支流预测结果的KGE系数中位数分别达到0.85和0.62以上,表明该模型能够较为准确地模拟不同流域的径流变化过程。此外,源自机器翻译领域的Transformer模型在水文模拟中也表现出色^[11],其核心的多头注意力机制能够有效捕捉序列数据的时空关联特征,显著提升模型对复杂水文过程的表征能力。Yin等^[12]提出的RR-Former模型完全基于注意力机制构建,在美国CAMELS数据集上的测试表明,该模型对7日径流预测的Nash效率系数(NSE)中位数和均值分别达到0.826 5和0.790 4,明显优于传统的LSTM序列模型;在区域尺度建模任务中,RR-Former同样展现出卓越性能,尤其适用于大样本数据场景。

大汶河是山东境内黄河下游最大的支流,在黄河流域生态保护与高质量发展国家战略实施背景下^[13],其特殊的区位条件和生态功能使其成为黄河下游生态屏障建设的关键区域,在保障防洪安全、维持南水北调水质等方面发挥着不可替代的作用。尽管大汶河流域相较于山东省其他地区具有相对优越的自然水资源条件,但在气候变化和高强度人类活动的叠加影响下,河道断流现象频发,天然径流过程已发生显著改变。因

此,系统研究大汶河流域水循环关键要素的演变规律,精确模拟流域径流动态,对于应对变化环境下的水安全挑战具有重要价值。

本研究基于大汶河流域长序列水文气象数据,采用趋势分析与突变检验方法解析流域径流及其驱动因子的演变特征。构建CNN、LSTM和Transformer三种模型模拟流域控制站-戴村坝站的月径流过程,通过对比分析评估其适用性,旨在为大汶河流域月径流模拟提供技术参考。

1 研究流域概况

1.1 大汶河流域

大汶河流域位于山东省中南部(东经116°30′—118°01′,北纬35°71′—37°60′),是黄河下游右岸最大的一级支流^[14]。该流域横跨济南市莱芜区、泰安市等多个行政区域,全长231 km,总流域面积8 944 hm²(图1)。流域地势呈现明显的东高西低格局,东部为鲁中山区,北部泰山和南部蒙山构成主要分水岭,中西部则过渡为丘陵和平原地貌,海拔高差超过1 500 m^[15]。大汶河水系由牟汶河和柴汶河两大支流组成,其中牟汶河上游又包含瀛汶河、石汶河等次级支流^[16]。河流自东向西流经莱芜盆地、大汶口盆地等构造单元,最终汇入东平湖,经调蓄后注入黄河。

大汶河流域属于暖温带半湿润大陆性季风气候,具有明显的季节性变化规律^[17]。气候系统受东亚季风环流控制,水热条件表现出显著的时空分异特征。1961—2019年气象观测数据显示,研究区年平均气温为12.9℃,年蒸发量约为564.83 mm。在降水方面,流域多年平均降水量为674.02 mm,主要集中在4—10月的暖季,该时段降水量达522.6 mm,约占全年总量的四分之三。其中6月下旬至9月中旬为强降水集中期,暴雨事件频发。从年际变化来看,降水波动幅度较大,最大年降水量(1964年1 327.8 mm)与最小年降水量(1988年455.2 mm)之比达到2.2,反映出显著的年际变率。

1.2 资料与数据

本文采用大汶河流域1961—2019年的气象与水文观测资料开展分析与模拟研究。气象数据来源于中国气象局国家气象信息中心,包括流域及其周边14个气象站的逐月观测数据(其中




图1 大汶河流域

Fig. 1 Map of the Dawen River Basin

济南站、章丘站和泰山站为国家气象站,其他站点为省、市及县级气象站),涵盖降水、气温、最高气温、最低气温、2 m 风速、日照时数及相对湿度等要素。径流数据取自戴村坝水文站的逐月流量观测资料,实际蒸发数据为戴村坝实测数据,由山东省水文中心提供。

2 研究方法

2.1 趋势分析与突变检验

本研究采用 Sen's slope 方法^[18]分析大汶河流域气象与水文要素在长时间尺度上的变化趋势,并使用 Mann-Kendall 趋势检验评估结果的显著性。Sen's slope 法是一种非参数统计方法,用于定量估计时间序列趋势的变化速率。该方法通过计算所有可能观测点两两之间的斜率中位数,来获得总体趋势斜率,从而避免了极端值对结果的影响。具体计算公式为:

$$\text{slope} = \text{median} \left(\frac{x_j - x_k}{j - k} \right) (j = 2, 3, \dots, n; k = 1, 2, \dots, j - 1) \quad (1)$$

其中, x_j 与 x_k 分别表示时间序列中第 j 和第 k 个观测值。

Mann-Kendall 趋势检验是一种用于检测时间序列数据趋势并评估其显著性的统计方法。计算方法如下:

假定一组时间序列(n 为变量的个数且 $n \geq 10$):

$$X = (x_1, x_2, x_3, \dots, x_n) \quad (2)$$

建立标准正态分布统计量 Z :

$$Z = \begin{cases} \frac{S - 1}{\sqrt{\text{var}(S)}}, & S > 0 \\ 0, & S = 0 \\ \frac{S + 1}{\sqrt{\text{var}(S)}}, & S < 0 \end{cases} \quad (3)$$

其中,

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(x_j - x_i) \quad (4)$$

$$\text{sgn}(x_j - x_i) = \begin{cases} 1, & (x_j - x_i) > 0 \\ 0, & (x_j - x_i) = 0 \\ -1, & (x_j - x_i) < 0 \end{cases} \quad (5)$$

$$\text{var}(S) = n(n-1)(2n+5)/18 \quad (6)$$

式中, S 为近似服从均值为 0 的正态分布统计量, $\text{var}(S)$ 为 S 的方差, $\text{sgn}()$ 为阶跃函数。

Z 大于 0 时表示序列呈上升趋势,反之下降。给定显著性水平,通过比较 Z 值与标准正态分布检验阈值判断趋势是否显著,若 $|Z|$ 大于临界值 1.96 则表示通过置信度 95% 的显著性检验,认为时间序列存在显著的单调趋势。

本文使用 Mann-Kendall 突变检验方法识别气象与水文要素时间序列中的突变特征与转折点。MK 检验是一种常用的非参数检验方法,目前已被广泛应用于水文气象时间序列的突变检测研究^[19],其计算步骤如下:

对于样本量为 n 的时间序列 x 构造秩序列:

$$s_k = \sum_{i=1}^k r_i (k=2, 3, \dots, n) \quad (7)$$

其中,

$$r_i = \begin{cases} 1, x_i > x_j \\ 0, x_i \leq x_j \end{cases} (j=1, 2, \dots, i) \quad (8)$$

在时间序列随机独立的假设下,定义服从标准正态分布的统计量:

$$UF_k = \frac{[s_k - E(s_k)]}{\sqrt{\text{Var}(s_k)}} (k=1, 2, \dots, n) \quad (9)$$

其中, $UF_1 = 0$ 。 $E(s_k)$ 、 $\text{Var}(s_k)$ 是累计数 s_k 的均值和方差,可由下式表示:

$$E(s_k) = \frac{n(n-1)}{4} \quad (10)$$

$$\text{Var}(s_k) = \frac{n(n-1)(2n+5)}{72} \quad (11)$$

按时间序列 x 逆序 $x_n, x_{n-1}, \dots, x_1$, 再重复上述过程计算逆序列的 UF_k , 定义为 UB_k 。若 UF_k 和 UB_k 随时间变化的曲线交点位于置信区间内, 则此点为突变点。

2.2 机器学习模型

卷积神经网络 CNN 的基本原理是通过卷积层识别输入序列的局部特征, 并借助多层次结构逐步提取高阶特征信息^[20]。在水文时间序列建模中, CNN 可捕捉降水、温度等气象要素的短期变化模式, 从而提取与径流响应密切相关的时空特征。本文所构建的 CNN 模型结构如图 2(a) 所示, 共包括 4 个卷积单元, 其中每个卷积单元由 2 个卷积层和 1 个池化层组成, 卷积核数量和卷积核大小分别为 96 和 7, 全连接层大小为 256, 失活率为 0.1, 批大小为 128。

长短期记忆网络 (LSTM) 是循环神经网络的重要变体。引入遗忘门和记忆单元, 有效克服了传统循环神经网络在长序列建模中的梯度衰减问题, 能够更准确地捕捉气象驱动与径流响应之间的时序依赖关系^[21]。本文采用的模型有 1 个 LSTM 层和 1 个全连接层, LSTM 层的隐藏层大小为 128, 失活率为 0.2, 批大小为 16。模型结构如图 2(b) 所示, 其中, h_{t-1} 和 C_{t-1} 分别为上个时段的隐藏状态及单元状态, x_t 表示输入, i_t 、 f_t 和 o_t 分别为输入门、遗忘门和输出门。

Transformer 通过自注意力机制直接建立输入序列中各时刻间的关联, 能够同时关注全局与

局部特征。相比传统循环神经网络, Transformer 具备更强的长程依赖建模能力与更高的计算效率^[22]。不同于循环网络逐步处理时间序列的方式, Transformer 可在时间维度上实现并行计算, 显著提升模型训练速度, 其结构如图 2(c) 所示。本文构建的 Transformer 模型包括输入层、编码器、池化层、全连接层和输出层。每个编码器层由自注意力层和前馈全连接层两部分组成, 并在两者外部分别引入残差连接与层归一化操作。最后一个编码器层的输出经池化层后输入全连接层进行回归。模型参数设置为: 编码器层数 2、隐藏层维度 32、多头注意力头数 8、失活率 0.1、批大小 32。

机器学习模型的输入变量包括降水、气温、最高气温、最低气温等 11 个气象要素, 输出变量为径流量, 水文气象序列均完整无缺失, 各气象要素采用泰森多边形法计算得到流域的面平均值。选取 1961—1995 年数据作为训练集, 1996—2003 年数据作为验证集, 2004—2010 年数据作为测试集。由于气象数据与径流数据的尺度与单位存在差异, 本文采用 max-min 归一化方法对数据进行预处理, 将所有变量标准化至 $[0, 1]$ 区间。此外, 三种模型均基于 Python 语言的 PyTorch 框架构建与训练, 超参数通过贝叶斯优化算法自动率定。

2.3 模型设置与评价指标

为评价各模型模拟效果, 选取均方根误差 (RMSE)、平均绝对误差 (MAE)、纳什效率系数 (NSE) 和皮尔逊相关系数 (R) 作为评价指标, 计算方法如下:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (12)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (13)$$

$$\text{NSE} = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (14)$$

$$R = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{\sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2 \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (15)$$

式中: N 为观测数, y_i 为实测径流量 (m^3/s), $\bar{y}$ 为实




图2 模型结构示意图

Fig. 2 Model structure diagram

注:(a)、(b)、(c)分别对应CNN、Transformer和LSTM。

Note: (a), (b), and (c) correspond to CNN, Transformer, and LSTM, respectively.

测径流量的平均值(m^3/s), $\hat{y}_t$ 为模拟径流量(m^3/s), $\bar{\hat{y}}$ 为模拟径流量的平均值(m^3/s)。NSE取值范围是 $(-\infty, 1]$, R 的取值范围是 $[-1, 1]$, 越接近1说明模型精度越高; RMSE和MAE表示模拟径流与实测径流的差异, 值越小表明模型误差越小。

3 结果与分析

3.1 气象、水文要素变化趋势分析及突变检验

1961到2019年大汶河流域降水年际变化趋势分析和突变检验结果如图3(a)所示。大汶河流域多年平均降水量为674.92 mm, 整体呈现不显著减少的趋势($P > 0.05$), Sen's slope斜率为 -0.6576 mm/a 。年降水量的最大值为1167 mm, 出现在1964年, 远高于多年平均降水量。从季节分布来看, 该地区的降水主要集中在夏季, 多年平均降水量为424.0 mm, 占全年总降水量的62.68%, 冬季降水则明显偏少。MK突变检验显示降水量在1965年发生了第一次突变, 在2000年后发生多次突变, 表明降水的年际变化波动较大。

图3(b)展示了大汶河流域1961到2019年气温序列的趋势分析与突变检验结果。多年平均气温为 12.96°C , 1961到2019年间呈显著上升($P < 0.05$)趋势, Sen's slope斜率为 0.0306°C/a , 与全球气候变暖的背景相一致。春季和冬季升

温速率较大, 分别为 0.0440°C/a 和 0.0443°C/a , 是年均气温显著升高的主要贡献者, 夏季和秋季变化幅度较小。MK突变检验未识别到显著的突变点, 表明流域气温整体变化过程较为平稳。

如图3(c)所示, 大汶河流域1961到2010年多年平均实际蒸散发为1062.62 mm, 整体表现为显著下降趋势($P < 0.05$), Sen's slope斜率为 -12.83 mm/a 。其中, 春季与夏季蒸散发量较大, 且下降速率较快, 分别为 -4.92 mm/a 和 -4.97 mm/a , 说明年尺度下降趋势主要由春、夏两季主导。在1996年前后, 年实际蒸散发量先减少后增加, 最低值为682.6 mm。

1961到2019年气压呈现出显著的下降趋势($P < 0.05$), Sen's slope斜率为 -0.0364 hPa/a , 其中极低值出现在1962年(图3(d))。各季节气压变化趋势一致, 均表现为缓慢下降。其中冬季气压最高, 夏季气压最低, 具有明显的季节性。1997年后多年平均气压明显降低。MK突变检验的结果表明气压在2004年前后发生突变。

图3(e)展示了1961到2019年日照时长的年际与季节变化特征及其趋势检验结果。年平均日照时长呈显著下降趋势($P < 0.05$), Sen's slope斜率为 -0.0222 h/a , 多年平均值为6.68 h, 最低值出现在21世纪初。各季节日照时长均有不同程度的下降, 其中春季变化最小, 秋季与冬季下

降幅度较大,冬季日照时长最低,表现出显著的季节差异。MK突变检验结果表明,日照时长的变化趋势在1982年左右发生转折并在此后一段时间内持续下降。

1961到2019年径流序列的趋势分析和突变检验结果如图3(f)所示。趋势分析结果表明,四季和全年的径流量都未展现出显著的长期变化

趋势($P>0.05$),年径流的Sen's slope斜率为 $-0.2833\text{ m}^3/\text{s}/\text{a}$ 。多年平均径流量为 $29.79\text{ m}^3/\text{s}$,最大值出现在1964年,年均流量高达 $191.7\text{ m}^3/\text{s}$ 。该年夏季和秋季平均径流量分别为 $370.3\text{ m}^3/\text{s}$ 和 $331.3\text{ m}^3/\text{s}$,较其他年份偏高,是年径流偏高的主要原因。MK突变检验共检测出两个显著的突变点,分别在1965年和2013年。




图3 各季节、年气象要素和径流趋势分析及突变检验

Fig. 3 Meteorological elements and runoff trends analysis and abrupt-change tests on seasonal and annual scales

注:(a)、(b)、(c)、(d)、(e)、(f)分别对应降水、气温、实际蒸散发、气压、日照时长和径流。

Note: (a), (b), (c), (d), (e), and (f) correspond to precipitation, temperature, actual evapotranspiration, pressure, sunshine duration and runoff, respectively.

3.2 卷积神经网络、长短期记忆网络、Transformer 模拟结果

图 4(a) 为训练期月径流过程模拟结果, CNN、LSTM 和 Transformer 在训练期的 NSE 分别为 0.939、0.638 和 0.739(表 1), CNN 模拟效果最佳。整体而言, 三种模型对于非汛期(11 月—次年 3 月)^[23]流量的模拟效果较好, 对主汛期(6 月—9 月)^[23]流量的模拟值偏低。由散点图可知, LSTM 的峰值模拟偏差最大, CNN 的散点均匀地分布在参考线两侧偏差最小。进一步对比

降水过程与径流过程可发现, 不同时期的降雨径流响应关系存在明显差异。例如, 1964 年 4 月降水量为 179.8 mm, 对应径流量为 820 m³/s; 1980 年 7 月降水量为 147.2 mm, 但径流量仅为 140 m³/s。这种差异可能与流域水利工程建设密切相关: 1970 年前大汶河流域水利工程较少, 河道基本处于天然状态; 1970 年以后逐步修建了大量水利工程, 目前已有 23 座大中型水库建成并投入运行, 并分布有数量可观的小型水库^[23]。这些工程的运行显著改变了径流过程, 使得在相同重




图 4 训练期和测试期径流过程模拟结果

Fig. 4 Simulation results of runoff processes during the calibration, validation and testing periods

注: (a)、(b)、(c) 分别表示训练期、验证期和测试期的模拟结果。

Note: (a), (b), and (c) represent the simulation results for the training, validation, and testing periods, respectively.

表1 机器学习模型模拟精度评价指标
Table 1 Performance metrics for machine-learning model simulation

模型 Model	时段 Period	NSE	<i>R</i>	RMSE/ (m^3/s)	MAE/ (m^3/s)
CNN	训练期	0.939	0.972	19.71	11.60
	验证期	0.574	0.758	37.49	14.21
	测试期	0.675	0.829	39.82	18.89
LSTM	训练期	0.638	0.810	48.09	22.51
	验证期	0.489	0.701	41.08	19.32
	测试期	0.710	0.848	37.59	19.72
Transformer	训练期	0.739	0.866	40.80	21.18
	验证期	0.479	0.693	41.47	21.79
	测试期	0.737	0.882	35.81	22.22

现期条件下的洪水来水量较未建库时期明显减少。

验证期月径流模拟结果如图4(b)所示, CNN、LSTM和Transformer的相关系数分别为0.758、0.701和0.693, NSE分别为0.574、0.489和0.479,表明三种模型均能够捕捉径流的总体变化趋势,但难以捕捉峰值的出现时间和大小。根据径流过程线可知,验证期径流变化过程极不规律,只有1996、1998、2001和2003年的峰值达到 $200 \text{ m}^3/\text{s}$ 以上,其余年份峰值均不足 $100 \text{ m}^3/\text{s}$,严重不符合该地区的水文气象特征,表明该时段的径流可能受多重因素影响。

如图4(c)所示,三种模型在测试期均表现出较好的模拟效果。CNN、LSTM和Transformer的NSE分别达到0.68、0.71和0.74,说明模型的泛化性能良好。其中,Transformer能够较准确地捕捉峰值出现的时间与大小;LSTM对径流的时序变化模拟较为平滑,对非汛期的径流变化过程的拟合较为理想;CNN则高估部分大洪峰的峰值,对峰值模拟的偏差最大。与训练期相比,测试期在洪峰模拟中同时出现了模拟值偏高和偏低的现象。这可能是因为21世纪以来大汶河流域人类活动增强,基于历史降雨-径流关系的模拟产生了一定误差。此外,模型训练前采用了最大-最小值归一化处理,该方法使得径流数据的整体分布受太极值影响较大,导致中小洪峰值被压缩至较小数值区间,从而削弱了模型对中小洪峰流量变化的响应能力,造成模拟结果出现偏差。

4 讨论

由图3可知,从降水趋势来看,尽管不同季节和全年降水量均未表现出显著的上升或下降趋势,但年际之间的降水量波动较大,这种年际波动可能与气候变异及其年际性变化有关^[24,25],相应的年径流和夏季径流也呈现出明显的年际波动趋势。此外,径流在1965年和2013年左右发生了显著突变,其中1965年左右的突变可能主要与1964年发生的特大降水有关,而2013年左右的突变则可能与农业灌溉、工业用水和水利工程等人类活动导致的频繁断流有关。这些活动不仅直接削减了径流量,还通过改变下垫面条件、植被覆盖和水循环过程,进一步对径流造成了长期影响^[26,27]。1961—2010年间实际蒸散发显著下降但气温显著上升,而气温对潜在蒸散发是有促进作用的,说明气温以外的因子(如日照时长减少)对实际蒸散发的抑制作用更强,导致其在整体上呈现下降趋势^[28]。

总体而言,三种机器学习模型在径流模拟中的表现存在显著差异。CNN模型在训练阶段误差最小,均方误差只有 $19.71 \text{ m}^3/\text{s}$,说明其具备较强的特征提取能力,但在验证和测试阶段误差明显增大,表明对未见样本的泛化能力不足。LSTM模型整体性能较为稳定,在不同阶段的误差变化较小,训练期、验证期和测试期的均方误差分别为 $48.09 \text{ m}^3/\text{s}$ 、 $41.08 \text{ m}^3/\text{s}$ 和 $37.59 \text{ m}^3/\text{s}$,说明其对时间序列特征的学习较为稳健,但对复杂非线性关系的捕捉能力略显不足。相比之下,Transformer模型在测试阶段误差最小,模拟流量与实测流量的相关系数达到0.882,综合各项指标来看,其在捕捉径流的时序依赖和非线性特征方面具有更强的鲁棒性和泛化能力。

由图4(c)可知,Transformer模拟点更紧密地分布在1:1参考线两侧,中高流量区(流量大于 $100 \text{ m}^3/\text{s}$)的离群点数量明显少于CNN和LSTM,反映出更好的外推稳定性。从过程线的吻合度来看,Transformer模型的模拟效果最佳,其模拟的洪峰幅度与出现时间均与实测值高度吻合,并且能紧随实测径流的涨落变化;LSTM尽管在测试期NSE(0.71)略高于CNN(0.68),但其中中高流量区仍存在持续低估,且模拟序列较为平滑,对洪峰细节的捕捉能力有限;相比之下,

CNN在测试期表现出对峰值响应过度敏感的特征,部分洪峰模拟值偏高。这反映了卷积结构有时会过度记忆高流量区间气象因子与径流的关系,在人类活动影响增强的测试阶段适应性下降。

在训练期、验证期和测试期,实测径流与降水的相关系数分别为0.67、0.51和0.67(图5),表明大汶河流域的径流成因较为复杂,可能受到人类活动的影响。其中,验证期的降雨-径流关系最弱,因此模型在该时段的模拟精度相对较低。据统计,大汶河流域断流现象十分严重,在

1996—2003年共有699 d径流量为0,占比高达23.9%。此外,该时期流域内开展了多项防洪治理工程(如丁坝、三角堰等)且水库调蓄管理体系尚不完善,人类活动(包括水利工程建设、取用水、水土保持和采砂等)对径流过程造成了严重干扰,导致水文情势发生明显变化^[29-31]。因此,本研究将该阶段数据设置为验证期,用于模型超参数的选择与稳定性检验以提高模型的泛化能力与鲁棒性,而非用于模型训练或性能评价的主要依据。




图5 降雨径流关系散点图

Fig. 5 Rainfall-runoff relationship scatter plot

注:(a)、(b)、(c)分别表示训练期、验证期、测试期的降雨径流关系。

Note: (a), (b), and (c) represent the rainfall-runoff relationships during the training, validation, and testing periods, respectively.

5 结论

本文以大汶河流域为研究对象,分析了1961—2019年水文气象要素的变化特征,并构建CNN、LSTM与Transformer三种机器学习模型开展月径流模拟与对比研究,主要结论如下:

(1)研究时段内,大汶河流域气温显著升高,实际蒸散发、气压和日照时长显著下降,而降水与径流整体呈不显著的下降趋势($P>0.05$)。降水量年际波动较大,期间发生多次突变,径流量在1966年和2013年出现突变。降水与径流的极大值均出现在1964年。

(2)相较于CNN和LSTM,Transformer能够在预测任务中更好地模拟径流变化过程,测试期的NSE和R达到0.74和0.87。在径流波动幅度较大的情况下,Transformer能够更好地捕捉径流变化过程和峰值特征,可应用于径流变率较大的流域。

(3)Transformer具备较强的稳定性和泛化能力,在受人类活动干扰的背景下,仍能够提取不

同时期气象要素与径流之间的内在关系,实现更高精度的径流预测

在未来研究中可进一步分时期建立径流模拟模型,或引入考虑水库调蓄等人类活动影响的模块,以期实现更为精确的预测结果。

参考文献

- [1] 杨大文,徐宗学,李哲,等. 水文学研究进展与展望[J]. 地理科学进展,2018,37(01):36-45.
- [2] 宋晓猛,张建云,占车生,等. 气候变化和人类活动对水文循环影响研究进展[J]. 水利学报,2013,44(07):779-790.
- [3] 徐宗学,姜瑶. 变化环境下的径流演变与影响研究:回顾与展望[J]. 水利水运工程学报,2022(01):9-18.
- [4] Piao S, Ciais P, Huang Y, et al. The impacts of climate change on water resources and agriculture in China [J]. Nature, 2010,467(7311):43-51.
- [5] Xu Y, Zhang X, Wang X, et al. Propagation from meteorological drought to hydrological drought under the impact of human activities: A case study in northern China[J]. Journal of Hydrology, 2019, 579: 124147.

- [6] 周国逸,李琳,方雪纯,等.近60a来全球河川径流量变化趋势及影响因素分析[J].大气科学学报,2021,43(06):1076-1085.
- [7] 牛凯杰,吴为,刘庚,等.永定河流域水文响应变化归因与驱动因素研究[J].水资源保护,2026,42(02):140-150.
- [8] 张力,王红瑞,郭排楠,等.基于时序分解与机器学习的非平稳径流序列集成模型与应用[J].水科学进展,2023,34(01):42-52.
- [9] 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.
- [10] Xu W, Chen J, Zhang X J, et al. A framework of integrating heterogeneous data sources for monthly streamflow prediction using a state-of-the-art deep learning model[J]. Journal of Hydrology, 2022, 614: 128599.
- [11] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30.
- [12] Yin H, Guo Z, Zhang X, et al. RR-Former: Rainfall-runoff modeling based on Transformer[J]. Journal of Hydrology, 2022, 609: 127781.
- [13] 夏军,占车生,曾思栋,等.长江模拟器的理论方法与实践探索[J].水利学报,2022,53(05):505-514.
- [14] 何振芳,牟婷婷,郭庆春,等.1979—2019年大汶河流域湿地时空演变与分异研究[J].水资源保护,2024,40(02):134-140.
- [15] 雒艳玲,乔新贺,徐植信,等.大汶河流域水文要素时空分布特征研究[J].山东农业大学学报(自然科学版),2024,55(04):613-626.
- [16] 徐珊,李环,陈新,等.基于遥感数据的大汶河流域济南段水体面积变化分析及生态流量评价[J].中国农村水利水电,2024(12):52-59+73.
- [17] 廖安栋.大汶河流域洪水预报及参数不确定性分析[D].北京:华北水利水电大学,2024.
- [18] Sen P K. Estimates of the regression coefficient based on Kendall's tau[J]. Journal of the American Statistical Association, 1968, 63(324): 1379-1389.
- [19] Sneyers R. Sur l'analyse statistique des séries d'observations: Note technique N. 143[M]//Genève: Secrétariat de l'Organisations Météorologique Mondiale, 1975.
- [20] Lecun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.
- [21] 刘建伟,宋志妍.循环神经网络研究综述[J].控制与决策,2022,37(11):2753-2768.
- [22] Yin H, Zhu W, Zhang X, et al. Runoff predictions in new-gauged basins using two transformer-based models[J]. Journal of Hydrology, 2023, 622: 129684.
- [23] 杨旭洋.变化环境下流域径流演变特征及归因分析研究[D].西安:西安理工大学,2023.
- [24] 杨彦武,于强,王靖.近40年华北及华东局部主要气候资源要素的时空变异性[J].资源科学,2004(04):45-50.
- [25] 任国玉,战云健,任玉玉,等.中国大陆降水时空变异规律——I.气候学特征[J].水科学进展,2015,26(03):299-310.
- [26] 张建云,张成凤,鲍振鑫,等.黄淮海流域植被覆盖变化对径流的影响[J].水科学进展,2021,32(06):813-823.
- [27] 刘昌明,王恺文,王冠,等.1956—2016年黄河流域径流及其影响因素的变化分析[J].人民黄河,2022,44(09):1-5+16.
- [28] 刘园,王颖,杨晓光.华北平原参考作物蒸散量变化特征及气候影响因素[J].生态学报,2010(04):923-932.
- [29] 李勇刚,赵龙,李建新,等.黄河下游大汶河流域水文要素演变特征研究[J].山东农业大学学报(自然科学版),2023,54(01):104-111.
- [30] 郭坤荣.大汶河生态健康评价研究[D].济南:山东师范大学,2007.
- [31] 孙蓉,孙秀玲,宫雪亮,等.大汶河戴村坝径流序列一致性影响分析[J].水电能源科学,2017,35(09):17-21.