

基于 DeepTCN 与动态特征提取的多变量径流预测模型

高佳佳¹, 陈柏成², 陈越超³, 张 庆², 赵 丽²

(1. 河南理工大学软件学院; 2. 河南理工大学资源环境学院; 3. 河南理工大学应急管理学院)

摘要:为捕捉水文过程中的动态变化规律,提高预测精度,通过 3 种相关性分析结合协方差分析,系统解析了不同气象因素与径流量的相关性,动态提取了对径流预测有高贡献的特征并进行权重优化,进而基于深度时间卷积网络(DeepTCN)构建了多特征径流预测的 p-DeepTCN 模型,以捕捉径流序列数据中的长期依赖关系和短期波动。利用北海道厚真川流域 2015—2020 年的实测数据对 p-DeepTCN 模型进行验证,结果表明:构建的 p-DeepTCN 模型在预测性能上优于其他深度学习模型,p-DeepTCN 模型的纳什效率系数提升了 28.48%,均方根误差降低了 27.63%;百分比偏差虽比 WPMixer 模型高 23.34%,但比其他深度学习模型降低了 17.44%;决定系数虽比 DeepTCN 模型低 0.011,但比其他深度学习模型高 10.17%;p-DeepTCN 模型显著提高了径流预测的准确性,表现出更好的适应性和鲁棒性。

关键词:径流量预测;DeepTCN;多特征预测;动态特征提取;厚真川流域

Multivariate runoff prediction model based on DeepTCN and dynamic feature extraction//Gao Jiajia¹, Chen Baicheng², Chen Yuechao³, Zhang Qing², Zhao Li² (1. School of Software, Henan Polytechnic University; 2. School of Resources and Environment, Henan Polytechnic University; 3. School of Emergency Management, Henan Polytechnic University)

Abstract: To capture the dynamic variation laws of hydrological processes and improve runoff prediction accuracy, by combining three kinds of correlation analysis with covariance analysis, we systematically analyzed the correlation characteristics between different meteorological variables and runoff, dynamically extracted high-contribution features for runoff prediction and optimized their weights. Then, based on the deep temporal convolutional network (DeepTCN), a p-DeepTCN model for multi-feature runoff prediction was constructed to capture both the long-term dependencies and short-term fluctuations in runoff sequence. The measured data of the Atsuma River Basin in Hokkaido from 2015 to 2020 were used to verify the p-DeepTCN model, and the results show that the p-DeepTCN model achieves the optimal prediction performance compared with other deep learning models. Specifically, the Nash-Sutcliffe efficiency coefficient of the p-DeepTCN model is increased by 28.48%, and the root mean square error is reduced by 27.63%. Although its percent bias is 23.34% higher than that of the WPMixer model, it is 17.44% lower than that of the other deep learning models. Meanwhile, although its coefficient of determination is 0.011 lower than that of the original DeepTCN model, it is 10.17% higher than that of other deep learning models. In summary, the p-DeepTCN model significantly improves the accuracy of runoff prediction, and exhibits superior adaptability and robustness.

Key words: runoff prediction; DeepTCN; multi-feature prediction; dynamic feature extraction; the Atsuma River Basin

水文预测在水资源管理、洪水预警和水文模拟等领域具有关键作用,其准确性直接影响水资源优化配置、防洪策略制定以及生态环境保护^[1-4]。气候变化、土地利用变化及高强度人类活动导致水文系

统的非线性特征与不确定性显著增强,使得径流量预测面临前所未有的挑战^[5]。传统水文预测模型通常依赖单一特征分析,难以充分刻画降水量、蓄水量、土壤含水量等水文变量之间复杂的协同关系,在

基金项目:国家自然科学基金项目(42472058);陕西省煤矿水害防治技术重点实验室开放基金项目(2021SKMS04);河南理工大学 2025 年度基本科研业务费专项资金项目(NSFRF2502119);河南理工大学博士基金项目(B2022-38, B2023-59);河南理工大学教学改革研究与实践项目(2024XJJGXM25)

作者简介:高佳佳(1991—),女,助教,硕士,主要从事人工智能及机器学习模型研究。E-mail: gjj@hpu.edu.cn

通信作者:陈越超(1991—),男,副教授,博士,主要从事水文循环过程模拟及机器学习应用研究。E-mail: 10460230792@hpu.edu.cn

极端事件下预测偏差显著^[6]。因此,突破单变量建模局限、充分利用多特征数据进行预测,成为水文预测领域亟须解决的科学问题。

传统水文预测模型往往基于静态权重假设,即认为各输入特征对径流量的影响程度在整个时间序列中是固定不变的。这种假设忽略了水文系统的时变性和非平稳性。实际上,不同气象因子在不同季节或水文情势下的驱动作用存在显著差异。因此,引入动态特征提取技术对于提升预测精度至关重要。该技术能够根据实时水文状态自适应地调整各输入变量的权重,捕捉降水、蒸发、融雪等物理过程在时间维度上的演变规律,从而有效克服传统模型在面对极端气候和复杂下垫面条件时的局限性。

近年来,遥感技术、传感器网络和地理信息系统等技术的飞速发展,为高时空分辨率水文多特征数据的获取提供了技术支撑^[7]。这些多源数据不仅揭示了水文过程的时空异质性,还为径流量预测提供了多维信息基础。研究表明,其提供的全面水文信息可以显著增强对径流量预测结果的解释能力^[8],也为模型构建提供了更多的约束条件。例如:Samantaray 等^[9] 研究结果表明,降水量、温度、水位、比湿度和相对湿度这 5 个关键数据项在评估径流预测模型时尤为重要;Di Nunno 等^[10] 通过将温度、土壤湿度、地下水位和积雪等多特征数据纳入集成径流预测模型的建模过程中,有效提升了流速预测的可靠性和准确度。通过综合考量不同特征之间的相互作用,可以更精准地捕捉水文系统的复杂性和非线性特征,深入揭示降雨、蓄水和土壤水分等过程之间的内在联系,从而深化对径流量生成机制的理解,提高模型预测精度和鲁棒性^[11]。

传统的水文预测方法中,通常使用基于单个特征的模型进行分析和建模。这种方法基于降水量、流量或其他单个变量来预测径流量,忽略了多个水文变量之间的潜在相关性^[12]。水文系统本质上是多变量耦合的动态网络,多个变量之间存在着复杂的相互作用关系,这种相互作用是径流形成和演变的核心驱动机制,也是提升预测精度的关键突破口。例如:Iamampai 等^[13] 提出基于机器学习模型改进的降雨-径流模型,通过引入土壤湿度指数和累积降水量增强对径流特征的表征,提高模型的预测精度,也验证了降水量和土壤含水量之间可能存在一定的时间延迟关系。变量间复杂的相互作用在预测水文过程中起着关键作用,利用变量间的协变关系可显著提升模型的物理一致性与预测精度^[14]。例如:Anzolin 等^[15] 提出了改进的非平稳洪水频率分析方法,通过引入 5 种气候驱动因素作为协变量,建立洪

水与气候因子之间的动态关系,有效提高了模型的预测能力;Huang 等^[16] 提出了一种结合机器学习和变量选择的方法,通过递归特征消除算法选择最优的环境协变量组合,进一步模拟环境因子与土壤的反馈机制,达到较好的预测效果。此外,变量相关性分析还可揭示水文过程的驱动机制。

为了克服单特征模型局限,近年来出现了多特征预测方法,尝试通过挖掘多变量间的相关性提高预测精度。例如:Liao 等^[17] 提出了一种基于集合经验模态分解和人工神经网络的长期径流预测混合模型,通过筛选与径流密切相关的气象因素,并结合多核并行算法显著提高了预测精度和效率;Zhao 等^[18] 利用 BP 神经网络进行敏感性分析,研究关键气象因素与雪融水径流之间的相关性,建立了经验方程以量化关键气象因素对雪融水径流的贡献,可实现中长期雪融水径流的准确预测;Jia 等^[19] 提出了一种基于气候驱动的混合模型用于月径流预测,通过降低数据噪声,使用相关系数和互信息方法筛选与径流具有较强相关性的气象因素来提高预测精度。此外,Horton 等^[20] 采用模拟方法,通过搜寻历史相似气象情景对降水量进行预测,该方法可自动筛选与关键降雨天气过程密切相关的气象因子,为多变量数据相关性挖掘提供了新思路;Wang 等^[21] 基于注意力机制(AM)和长短期记忆网络(LSTM)构建了 AM-LSTM 模型,采用注意力层改进从隐藏层中提取的信息,从而更准确地反映径流相关因素之间的关系,使得模型 10d 径流预测的准确度大幅提升;Han 等^[22] 提出了一种在输入层和隐藏层均结合 AM 的 AT-LSTM 模型,对 130 个气候现象指标赋予权重,动态分析水文变量间的相关性,进一步提高了预测效果。这些方法通过分析降水量、蓄水量、土壤含水量、气象因子等多个变量之间的相关性,构建复杂的水文模型,提高预测的准确性,但此类模型在径流预测时仍有不足^[23-24]。基于人工神经网络的预测模型虽然能捕捉局部非线性特征,却难以有效解析流域尺度的时空关联^[25];传统卷积神经网络受限于固定感受野,无法适应水文序列的长期依赖性;而 LSTM 有强大的长期依赖捕捉能力,但因其计算复杂度高,容易出现过拟合^[26]。这些问题使得深度学习模型无法深入挖掘多变量间的潜在相关性,严重制约了对复杂水文系统的精准刻画。

基于多特征径流预测中的变量相关性,本文建立基于深度时间卷积网络(deep temporal convolutional network,DeepTCN)的多特征径流预测 p-DeepTCN 模型,通过堆叠膨胀因果卷积层,在扩大时序特征感受野的同时保持时序因果性,实现对输

入数据的多特征提取和复杂相关性建模^[27],并结合相关性分析动态捕捉多变量间的非线性交互作用,实现水文过程的多尺度特征提取。

1 研究方法

试验设计包括数据预处理、模型构建和训练以及模型性能评估 3 个步骤:①对原始数据进行预处理,包括对缺失值处理和特征标准化等;②构建 p-DeepTCN 模型,利用选定的数据集进行模型训练和优化;③比较预测结果与实际观测值的差异,并比较 p-DeepTCN 模型与其他深度学习模型的效果差异,利用纳什效率系数(NSE)、决定系数(R^2)、百分比偏差(PB)和均方根误差(RMSE)等指标综合评估 p-DeepTCN 模型在多特征径流预测中的效果。在 p-DeepTCN 模型参数设定中,选用 adam 作为训练优化器,设定学习率为 10^{-3} 、训练中每次输入模型样本数量为 64、模型输入时间序列长度为 14、模型输出时间序列长度为 1、扩张卷积的扩张基数为 4、卷积核大小为 3、卷积层中卷积核数量为 32、优化函数为均方误差、n_epochs 训练轮数为 400,并使用 Dropout 正则化技术以 0.1 的概率随机丢弃一些神经元,防止模型过拟合,以达到最佳的模型训练效果。

1.1 p-DeepTCN 模型

在水文预测中引入变量相关性分析,旨在通过优化模型结构,显著提升训练效率与预测精度。模型包括前处理层、相关性分析层、DeepTCN 层 3 个处理层,具体结构如图 1 所示。




图 1 p-DeepTCN 模型结构

Fig. 1 Structure of p-DeepTCN model

1.2 前处理层

前处理层主要负责数据缺失值填补、异常值处理及归一化,以消除数据噪声和量纲差异对模型训

练的影响。具体步骤为:①对原始数据集进行完整性检查。统计发现,受设备故障或传输延迟影响,各站点径流量数据缺失率为 7.85%,其他特征数据缺失率较低,为 0.14%~2.24%。为保持时间序列的连续性,采用线性样条插值法对缺失数据进行补齐,该方法能够较好地拟合水文数据的局部趋势。②针对雷达观测可能产生的异常值采用标准分数法以 3σ (σ 为标准差) 阈值识别异常值。对于超出阈值的极端异常点,使用前后时间窗口的移动平均值对异常值进行平滑替代,以防止噪声误导模型的特征学习。③由于降水量、径流量和日总辐射量等特征的量纲和数量级差异巨大,直接输入模型会导致梯度更新不稳定,因此,采用最大-最小归一化方法,消除不同变量的物理量纲与量级差异,为后续模型训练提供标准化输入。

1.3 相关性分析层

相关性分析层对前处理后的多特征数据进行相关性分析,识别可能存在的多重共线性问题,通过了解特征量之间的相关性,更好地理解数据集中的模式和关系,从而更好地选择和设计模型,并尽可能避免模型过度拟合或不稳定现象。DeepTCN 模型中的卷积层和 LSTM 层需要输入数据的特征量具有一定的相关性,以便从中提取出有用的信息。因此,在使用 DeepTCN 模型进行时间序列预测或分类任务前,进行输入数据特征量之间的相关性分析非常重要。

为了挖掘多变量间的潜在相关性,参考集成模型思想对多特征数据进行权重设置。集成模型通常选择多个神经网络模型作为基分类器,分别从不同视角对数据进行预测,根据各模型预测表现以动态分配权重的方式对多个基分类器的预测结果进行整合,实现对模型的误差修正^[28-31]。如陈娟等^[32]采用 DS 证据理论从多维度分析不同筛选方法的预测因子,集成随机森林、BP 神经网络、贝叶斯网络模型的预测结果,大幅提升了径流预测精度。受这些研究的启发,本文提出了一种基于多视角集成的动态权重重置策略。该策略通过构建综合权重矩阵 W 对输入特征进行自适应加权,强化有效特征。

在相关性分析层中选择径流量为目标变量,分别通过皮尔逊相关系数、Spearman 秩相关系数、Kendall 秩相关系数、协方差等 4 种分析方法,从线性相关程度、秩相关程度、协同波动幅度 3 个互补视角,量化评估各气象特征与径流量的关联关系。在此基础上,综合多种方法的分析结果,构建统一的特征权重,并对原始输入特征进行加权重构。具体算法流程如下:

a. 计算单一相关性向量。分别利用皮尔逊相

关系数、Spearman 秩相关系数、Kendall 秩相关系数、协方差计算各输入特征与目标变量(径流量)之间的统计量,得到与 4 种分析方法对应的 4 个特征相关性向量 C_P 、 C_S 、 C_K 、 C_{Cov} 。

b. 构建综合权重矩阵。为消除不同统计方法的量纲、量级差异,综合多方法的关联评估结果,采用分向量独立归一化与算术平均集成的策略计算综合权重,计算公式为:

$$w_i = (|C'_{P,i}| + |C'_{S,i}| + |C'_{K,i}| + |C'_{Cov,i}|) / 4 \quad (i = 1, 2, \dots, n) \quad (1)$$

式中: w_i 为第 i 个特征权重; $C'_{P,i}$ 、 $C'_{S,i}$ 、 $C'_{K,i}$ 、 $C'_{Cov,i}$ 分别为 C_P 、 C_S 、 C_K 和 C_{Cov} 经过归一化处理的第 i 个数值; n 为参与综合计算的特征总数。

c. 特征加权重构。将综合权重矩阵 W 与原始输入特征矩阵 X 相乘,得到加权后的输入数据 X' :

$$X' = XW \quad (2)$$

通过上述步骤,模型能够自动增强与径流演变强相关的特征信号(如降水量),同时抑制弱相关特征(如日总辐射量)引入的背景噪声,从而为 DeepTCN 模型提供更具辨识度的输入特征。

1.4 DeepTCN 层

DeepTCN 模型是一种基于卷积神经网络(CNN)和时间循环神经网络(RNN)的时间序列预测模型^[33]。旨在结合 CNN 的平移不变性和 RNN 的时间依赖性,以学习时间序列数据的复杂模式。相较于其他时间序列预测模型,DeepTCN 模型不仅结构简单,易于训练和调整,而且可以自动提取时间序列数据中的特征,处理非线性和非平稳的序列数据。DeepTCN 层利用 DeepTCN 模型学习特征生成预测值,并在 DeepTCN 模型的输出部分增加反归一化层对预测值进行反归一化处理生成最终预测值。

2 实例验证

2.1 研究区概况

厚真川流域位于北海道南部($42^{\circ}34'N \sim 42^{\circ}53'N$, $142^{\circ}07'E \sim 141^{\circ}59'E$),流域面积约 382.9 km^2 ,主河道长 52.3 km ,海拔 $0 \sim 640\text{ m}$ 。厚真川流域呈海岸线气候,降雨主要集中在台风期间,年平均降水量为 $1\,235.9\text{ mm}$,年平均温度为 $6.9 \sim 7.9^{\circ}\text{C}$ 。厚真川流域的上游区域主要为山地,河道呈现溪流状;中游区域呈宽广的谷地形,山地部分分布着二次林和落叶松,农田间的河道呈现出较为缓和的蛇曲蜿蜒形态,河底大多被砂砾覆被;下游区域为广大的农田地带,河道几乎笔直穿过农田和市区,水流缓慢。

2.2 数据来源与分析

本文使用厚真川流域的气象数据和水文数据。气象数据包括来自日本气象厅和日本气象业务支持中心 2015—2020 年流域降水量、最低和最高气温、平均气温、日照时长、风速、相对湿度和日总辐射量数据。降水量数据为雷达反演数据,以 1 km^2 一个观测站点的密度,使用了流域及其周围 450 个观测站点的观测数据。水文数据为 2015—2020 年厚真大桥站的径流数据(存在缺测现象),数据来自北海道胆振综合振兴局室兰建设管理部。

气象与水文数据统计显示,该区域气温波动性显著,最高气温极值跨度大,气温极度不稳定;风速分布呈现右偏趋势,偶尔出现的强风对风速数据形态有一定的影响;总辐射量分布呈现明显的右偏趋势,最高日总辐射量大,表明该区域经常受到极端高辐射事件的影响;降水量和径流量呈现出较为异常分布,短时强降水量与偶发水文事件对该区域数据的分布有极大影响;相对湿度比较稳定,阴雨天气较为频繁。分析表明,研究区气候动态呈现出明显的季节异质性和极端事件主导性。

图 2 为 2015—2020 年径流量季节-趋势分解结果,可以从不同维度展现出径流量的变化特征:

a. 径流量原始数据。2016—2017 年径流量出现了峰值突变,其中一个峰值甚至超过了 $150\text{ m}^3/\text{s}$,表明该年份可能发生如融雪洪峰、强降水等特殊事件导致径流量剧增。而在其他年份,径流量变化相对平稳,存在小幅波动。整体来看,径流量数据波动幅度较大,离散性较强,表明径流量受多种复杂因素影响,并不稳定。

b. 径流量趋势。整体趋势相对平缓,虽然在一些时间点上径流量出现一定程度的上升或下降波动,但没有呈现出明显的持续上升或下降趋势,这说明 2015—2020 年该地区径流量未呈现出显著的长期变化倾向。相对稳定的趋势线也显示出在这段时间内,影响径流量长期变化的主要因素并没有发生本质性改变。

c. 季节性变化。径流量每年都存在一定的波动,6—9 月径流量波动尤为明显,呈现出较为明显的周期性,说明径流量受季节因素影响较大,6—9 月可能由于降水量变化、极端天气等原因导致径流量增加或减少;不同年份季节性波动的幅度和具体时间存在一定差异,表明径流量可能与每年气候条件的细微变化有关。

d. 径流量残差。去除趋势和季节性因素后的残差代表无法被趋势和季节解释的径流量随机波动情况。残差值在 0 值附近随机波动,没有出现明显




图2 径流量季节-趋势分解结果

Fig.2 Season-trend decomposition result of runoff

的规律性或趋势性,说明通过时间序列预测模型可以较好地分离出径流量数据中的趋势和季节因素,残差部分由一些随机、无法被模型捕捉解释的因素造成,符合预期。

以上分析表明可以使用时间序列预测模型来预测未来径流量的季节性变化和随机变化。

基于3种相关系数与全局归一化协方差对数据的初步分析,反映出最高气温、最低气温、风速、日总辐射量、相对湿度、降水量、平均气温、日照时长、径流量等多个气象和水文要素之间的相关关系和协同波动的相对强度。径流量与降水量间的皮尔逊相关系数为0.40,说明两者有一定的正相关关系;降水量与径流量间的Spearman秩相关系数为0.14,Kendall秩相关系数为0.1,虽然在数值上略低于皮尔逊相关系数,但也呈现正相关关系,进一步支持了上述结论。径流量与平均气温间的皮尔逊相关系数为0.20,Spearman秩相关系数和Kendall秩相关系数分别为0.34和0.23,3类相关系数均为正值,表明二者整体呈正相关关系;全局归一化协方差为0.19,反映出二者协同波动强度处于偏弱水平,说明

该正相关关系的实际联动效应有限。从水文物理机制来看,气温主要通过调控流域冰雪消融和陆面蒸发过程,对径流量产生间接影响。日总辐射量与径流量间的皮尔逊相关系数仅为0.08,而Spearman秩相关系数和Kendall秩相关系数分别为0.11和0.07,反映出两者间较弱的正相关关系;全局归一化协方差为0.11,表明二者协同波动强度较弱,日总辐射量可能通过影响蒸发间接对径流量发生作用,但其非核心驱动因子,在后续相关分析层中可以适当降低日总辐射量的权重。通过这4种方法实现对变量间线性、非线性关联及协同波动幅度的初步分析,为后续在模型相关性分析层中利用径流与这些气象特征的关联程度动态调整各特征权重提供了量化依据,使模型能够进一步挖掘变量之间的相关性,进而提高径流量预测准确度。

2.3 数据集划分

为了科学评估模型的泛化能力并防止过拟合,严格按照时间序列顺序对数据集进行划分。数据集涵盖2015—2020年逐日观测数据,具体划分为:①训练集,选取2015年1月1日至2018年12月31日的数据,用于模型的参数学习和特征提取;②验证集,选取2019年1月1日至2019年12月31日的数据,用于超参数微调(如学习率、卷积核大小)及早停机制的判定;③测试集,选取2020年1月1日至2020年12月31日的数据,仅用于模型最终性能的客观评估,不参与任何训练过程。

2.4 结果与分析

利用时间卷积网络模型(temporal convolutional network,TCN)、轻量级梯度提升机模型(light gradient boosting machine,LightGBM)、LSTM模型、神经基展开可解释时间序列预测模型(neural basis expansion analysis for interpretable time series forecasting,N-BEATS)、变换器模型(Transformer)、小波分块混合器模型(wavelet patch mixer,WPMixer)、多尺度分块Transformer模型(MultiPatchFormer)、DeepTCN模型和p-DeepTCN模型预测2020年厚真川流域径流量,得到各模型预测结果(图3)。从图3可以看出,p-DeepTCN模型预测效果明显优于其他模型。通过对比不同模型在不同步长下的预测性能,综合量化评估时间序列预测模型的有效性。

2.4.1 模型性能对比

利用NSE、 R^2 、PB、RMSE对比p-DeepTCN模型与其他深度学习模型日尺度径流预测性能,结果如表1所示。结果显示p-DeepTCN模型综合性能全面领先。与其他深度学习模型相比,p-DeepTCN模




图 3 2020 年各模型预测和实测结果对比

Fig.3 Comparison between measured results and predicted results of each model in 2020

表 1 各模型性能对比

Table 1 Comparison of model performance

模型	NSE	R^2	PB/%	RMSE/(m^3/s)
TCN	0.288	0.816	20.41	1.360
LightGBM	0.378	0.713	9.66	1.271
LSTM	0.625	0.816	7.16	0.988
N-BEATS	0.536	0.780	2.81	1.098
Transformer	0.086	0.705	5.66	1.532
WPMixer	0.615	0.786	1.88	1.001
MultiPatchFormer	0.608	0.784	3.01	1.009
DeepTCN	0.367	0.910	26.74	1.282
p-DeepTCN	0.803	0.899	2.32	0.715

型的纳什效率系数提升了 28.48%，均方根误差降低了 27.63%；百分比偏差虽比 WPMixer 模型高 23.34%，但比其他深度学习模型降低了 17.44%；决定系数虽比 DeepTCN 模型低 0.011，但比其他深度学习模型高 10.17%，在所有对比模型中表现最优。

p-DeepTCN 模型的 NSE 为 0.803，在所有模型中最高，对径流时序动态的捕捉能力显著优于其他模型；其 RMSE 为 $0.715\text{ m}^3/\text{s}$ ，在所有模型中最优；其 PB 为 2.32%，仅略高于 WPMixer 模型；其 R^2 为 0.899，仅略低于 DeepTCN 模型。尽管 DeepTCN 模型 R^2 最高，但其 PB 为 26.74%、RMSE 为 $1.282\text{ m}^3/\text{s}$ ，预测偏差显著偏高。p-DeepTCN 模型通过相关性分析层优化了多要素关联表征能力，在拟合效果与预测精度间实现最优平衡，超越了 DeepTCN 模型。近年来主流前沿时间序列模型 WPMixer 与 MultiPatchFormer 表现处于中等偏上水平，二者 NSE 分别为 0.615、0.608，性能优于 LSTM、N-BEATS 等经典时间序列模型，但在 NSE、RMSE 等核心指标上与 p-DeepTCN 仍存在明显差距。其余模型中，Transformer 模型表现最差，NSE 仅 0.086，其全局 AM 弱化了对径流预测关键局部时序特征的捕捉，在该流域适配性较差；LSTM、TCN 等经典时间

序列模型表现中等，综合性能弱于 p-DeepTCN；传统机器学习模型 LightGBM 对人工特征工程依赖较强，难以挖掘序列深层非线性关联特征，综合性能弱于多数深度学习模型。

2.4.2 步长对预测性能的影响

不同步长下模型预测结果的评价指标如表 2 所示，不同步长数值表示基于当前及历史数据预测未来第 1、2、4、6、8 天的径流量。步长越大，预测难度越高，不确定性也越大。从表 2 可以看出，DeepTCN 模型步长从 1 增至 8 时，其 NSE 从 0.367 降至 -3.932，PB 值从 26.74% 增至 82.46%，RMSE 从 $1.282\text{ m}^3/\text{s}$ 增至 $3.533\text{ m}^3/\text{s}$ ，步长增加，预测性能急剧下降。相比之下，p-DeepTCN 模型表现出较强的稳定性，当步长为 8 时，NSE 仍为 0.813；步长从 1 增至 8 时，PB 值仅从 2.32% 增至 6.24%，RMSE 从 $0.590\text{ m}^3/\text{s}$ 增至 $0.755\text{ m}^3/\text{s}$ 。

表 2 不同步长下预测结果的评价指标

Table 2 Evaluation indicators of prediction results under different step lengths

模型	步长	NSE	R^2	PB/%	RMSE/(m^3/s)
DeepTCN	1	0.367	0.910	26.74	1.282
	2	0.395	0.958	44.44	1.899
	4	-1.691	0.935	61.86	2.628
	6	-2.651	0.895	71.36	3.049
	8	-3.932	0.857	82.46	3.533
p-DeepTCN	1	0.803	0.899	2.32	0.715
	2	0.865	0.944	3.53	0.590
	4	0.819	0.925	4.56	0.681
	6	0.776	0.904	4.95	0.755
	8	0.813	0.945	6.24	0.690

2.4.3 残差分析

为探究 p-DeepTCN 模型在多步长预测中对系统非标准波动的刻画能力与不确定性特征，统计了各预测步长下的残差，即预测值与真实值之差，结果如图 4 所示。核心统计量包括均值 (μ)、标准差 (σ)、峰度 (K) 和偏度 (S)。结果表明：①受相关性特征噪声与无关变量的抑制作用，所有步长残差分布中心均处于零误差基准线附近，当步长从 1 增至 8 时，均值仅从 $0.09\text{ m}^3/\text{s}$ 微增至 $0.26\text{ m}^3/\text{s}$ ，验证了模型较强的多步动态无偏估计能力；②残差呈“尖峰短尾”非局部平稳特性，峰度为 10.60~26.78，远高于正态分布理论基准，佐证了模型极高的信号拟合精度；残差的偏度为 -1.50~-3.98，呈现负向偏态，源于模型记忆惯性导致的小幅预测滞后，符合真实序列的自然波动规律；③随着步长增加，残差边界虽有小幅度扩展，标准差呈可控震荡，但相较于传统循环类长时间序列预测模型（如 LSTM）普遍存在的长步长预测下均值溃散、方差失控的固有瓶颈，p-




图4 不同步长残差直方图

Fig. 4 Residual histogram with different step lengths

DeepTCN 模型误差弥散速率显著降低,各预测步长范围内的残差分布与置信区间始终保持高收敛性。

综上,本文构建的 p-DeepTCN 模型不仅提升了宏观预测精度,更在残差微观分布上展现出优异的抗系统漂移和抗长期衰变稳健性,从底层机理解释了模型的高预测精度。

2.4.4 讨论

在多特征数据预测领域,深入挖掘变量间潜在相关性是提升预测结果准确性和可靠性的关键。本文基于 DeepTCN 构建的 p-DeepTCN 模型通过内置相关性分析层,运用皮尔逊相关系数、Spearman 秩相关系数、Kendall 秩相关系数和协方差 4 种分析方法对多特征数据进行综合相关性分析,实现对特征权重的动态重置。这种机制不是简单的特征选择,而是根据各气象特征与径流量的相关性强弱对模型输入数据进行自适应加权或抑制,使模型聚焦于与径流量相关性更强的特征,进一步挖掘多特征数据变量之间复杂的相关性,使得 p-DeepTCN 模型展现了最优的整体性能,其相对较低的 PB 和 RMSE 值验证了模型的预测精度与稳定性。此外,本文还验证了 p-DeepTCN 模型在不同步长预测场景中的表现。由于 DeepTCN 模型对输入特征的敏感性极高,长序列输入更容易引入冗余噪声信息,针对这一特性,p-DeepTCN 模型通过相关性分析层的动态加权机制,有效抑制了冗余噪声的干扰,增强了模型对径流序列数据中长期依赖关系和短期波动的捕捉能力,使得模型预测误差随步长的累积效应减弱,模型展现出了显著的稳定性优势。

尽管 p-DeepTCN 模型在各项指标上表现优异,但预测结果仍存在一定的不确定性。误差来源主要可归纳为以下 3 个方面:①数据源的不确定性。本文使用的降水量数据源自雷达反演,虽然空间覆盖度高,但在极端暴雨天气下,雷达回波信号可能出现衰减或漂移,导致输入端降水量数据与地面实际降

水量存在偏差。②物理机制的简化。p-DeepTCN 模型属于数据驱动模型,虽然通过相关性分析间接捕捉了物理规律,但对融雪、土壤入渗及地下水补给等复杂物理过程的刻画仍显不足,融雪期气温升高导致的径流滞后效应可能无法被完全精准预测。③人类活动的干扰。厚真川下游涉及农田灌溉取水及城市排水系统,这些人为的水资源调度行为具有高度随机性和非自然性,往往导致枯水期径流量出现难以预测的突变,是模型误差的重要来源之一。

p-DeepTCN 模型通过引入动态相关性分析层和深层因果卷积结构,在大幅提升预测精度(NSE 提升 28.48%)的同时,也增加了计算复杂度。在配置为 Tesla T4 GPU 的环境下,该模型在训练集上的平均训练单轮次耗时约为 34 s,与 DeepTCN 模型的 28 s 相比,单轮次训练时间增加了约 21.4%。尽管计算资源消耗有所上升,但考虑到水害预警对精度的严苛要求,这种成本的增加可以接受。未来的研究将致力于模型的轻量化改进,例如引入深度可分离卷积替代标准卷积,从而在保持精度的前提下显著降低参数量,实现边缘端的高效部署。

3 结 语

本文构建的 p-DeepTCN 模型不仅能够利用动态特征提取技术识别和选择对径流预测至关重要的特征,还通过引入 DeepTCN 模型进一步挖掘多特征变量之间的相关性,增强了对径流序列数据中长期依赖关系和短期波动的捕捉能力。具体来说,就是通过广泛的特征分析,从多个角度考察不同输入变量与径流量之间的相关性,从而确定一系列对预测效果有显著影响的关键特征,并基于相关性对关键特征重置权重。将 p-DeepTCN 模型应用于北海道厚真川流域径流预测的实证研究中,结果表明,与其他深度学习模型相比,p-DeepTCN 模型预测精度显著提升,能够更好地应对复杂多变的水文环境。

参考文献:

[1] Zhou Yi, Duan Yilin, Yao Hong, et al. Incorporating hydrological constraints with deep learning for streamflow prediction[J]. Expert Systems with Applications, 2025, 259:125379.

[2] Yifru B A, Lim K J, Lee S. Enhancing streamflow prediction physically consistently using process-based modeling and domain knowledge: a review [J]. Sustainability, 2024, 16(4) :1376.

[3] Sheng Ziyu, Wen Shiping, Feng Zhongkai, et al. A survey on data-driven runoff forecasting models based on neural networks[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2023, 7(4) :1083-1097.

[4] Peng Liling, Lin Hui, Fan Guofeng, et al. Runoff prediction based on the IGWOLSTM model: achieving accurate flood forecasting and emergency management [J]. Journal of Hydro-Environment Research, 2024, 56:28-39.

[5] Mai J, Craig J R, Tolson B A, et al. The sensitivity of simulated streamflow to individual hydrologic processes across North America[J]. Nature Communications, 2022, 13(1) :455.

[6] Yan Kun, Gao Shang, Wen Jinhua, et al. A multi-factor combination model for medium to long-term runoff prediction based on improved BP neural network [J]. Water, 2023, 15(20) :3559.

[7] Mdegela L, De Bock Y, Municio E, et al. A multi-modal wireless sensor system for river monitoring: a case for Kikuletwa River floods in Tanzania[J]. Sensors, 2023, 23(8) :4055.

[8] Liu Yang, Wang Yize, Liu Xuemei, et al. Research on runoff prediction based on Time2Vec-TCN-Transformer driven by multi-source data [J]. Electronics, 2024, 13(14) :2681.

[9] Samantaray S, Das S S, Sahoo A, et al. Monthly runoff prediction at Baitarani River Basin by support vector machine based on Salp swarm algorithm[J]. Ain Shams Engineering Journal, 2022, 13(5) :101732.

[10] Di Nunno F, de Marinis G, Granata F. Short-term forecasts of streamflow in the UK based on a novel hybrid artificial intelligence algorithm [J]. Scientific Reports, 2023, 13(1) :7036.

[11] Zhang Zongjia, Zeng Yiping, Huang Zhejun, et al. Multi-source data fusion and hydrodynamics for urban waterlogging risk identification[J]. International Journal of Environmental Research and Public Health, 2023, 20(3) :2528.

[12] Lakshmi P J, Apaza R A, Alkhayyat A, et al. Hybrid wavelet-gene expression programming and wavelet-support vector machine models for rainfall-runoff modeling [J]. Water Science & Technology, 2022, 86(12) :3205-3222.

[13] Iamampai S, Talaluxmana Y, Kanasut J, et al. Enhancing rainfall-runoff model accuracy with machine learning models by using soil water index to reflect runoff characteristics[J]. Water Science & Technology, 2024, 89(2) :368-381.

[14] Guo Tianli, Song Songbai, Liu Xin, et al. A comparison of several cyclo-stationary and fractionally differenced time-varying autoregressive models in runoff simulation and prediction[J]. Journal of Hydrology, 2024, 638:131509.

[15] Anzolin G, Chaffe P L B, Vrugt J A, et al. Using climate information as covariates to improve nonstationary flood frequency analysis in Brazil [J]. Hydrological Sciences Journal, 2023, 68(5) :645-654.

[16] Huang Jun, Liu Jia, Ye Yingcong, et al. Mapping soil properties in the Haihun River sub-watershed, Yangtze River Basin, China, by integrating machine learning and variable selection[J]. Sensors, 2024, 24(12) :3784.

[17] Liao Shengli, Wang Huan, Liu Benxi, et al. Runoff forecast model based on an EEMD-ANN and meteorological factors using a multicore parallel algorithm[J]. Water Resources Management, 2023, 37(4) :1539-1555.

[18] Zhao Hongling, Li Hongyan, Xuan Yunqing, et al. Investigating the critical influencing factors of snowmelt runoff and development of a mid-long term snowmelt runoff forecasting[J]. Journal of Geographical Sciences, 2023, 33(6) :1313-1333.

[19] Jia Zhuo, Peng Yuhao, Li Qin, et al. Monthly runoff forecasting using a climate-driven model based on two-stage decomposition and optimized support vector regression [J]. Water Resources Management, 2024, 38(14) :5701-5722.

[20] Horton P, Martius O, Grimm S L. Automated input variable selection for analog methods using genetic algorithms[J]. Water Resources Research, 2024, 60 (4) :e2023WR035715.

[21] Wang Yiyang, Wang Wenchuan, Xu Dongmei, et al. A compound approach for ten-day runoff prediction by coupling wavelet denoising, attention mechanism, and LSTM based on GPU parallel acceleration technology[J]. Earth Science Informatics, 2024, 17(2) :1281-1299.

[22] Han Dongyang, Liu Pan, Xie Kang, et al. An attention-based LSTM model for long-term runoff forecasting and factor recognition [J]. Environmental Research Letters, 2023, 18(2) :024004.

[23] Hasan F, Medley P, Drake J, et al. Advancing hydrology through machine learning: insights, challenges, and future directions using the CAMELS, caravan, GRDC, CHIRPS, PERSIANN, NLDAS, GLDAS, and GRACE datasets [J]. Water, 2024, 16(13) :1904.

(下转第 178 页)

2022,38(1):34-42. (in Chinese))

[26] 张丹,梁瀚续,何小聪,等. 基于 CMIP6 的金沙江流域径流及水文干旱预估[J]. 水资源保护,2023,39(6):53-62. (Zhang Dan, Liang Hanxu, He Xiaocong, et al. Estimation of runoff and hydrological drought in the Jinsha River Basin based on CMIP6 [J]. Water Resources Protection,2023,39(6):53-62. (in Chinese))

[27] Jones P W. First- and second-order conservative remapping schemes for grids in spherical coordinates[J]. Monthly Weather Review,1999,127(9):2204-2210.

[28] O'Neill B C, Tebaldi C, Van Vuuren D P, et al. The scenario model intercomparison project (ScenarioMIP) for CMIP6[J]. Geoscientific Model Development, 2016, 9(9):3461-3482.

[29] Eyring V, Bony S, Meehl G A, et al. Overview of the coupled model intercomparison project phase 6 (CMIP6) experimental design and organization [J]. Geoscientific Model Development, 2016, 9(5):1937-1958.

[30] 涂圣哲,李新通. 基于 CMIP6 的分权多模式集合对福建省的降水模拟评价[J]. 亚热带资源与环境学报, 2023, 18(2):111-119. (Tu Shengzhe, Li Xintong. Evaluation of precipitation simulation based on weighted multi-model ensemble mean of CMIP6 in Fujian Province [J]. Journal of Subtropical Resources and Environment, 2023, 18(2):111-119. (in Chinese))

[31] Tong Yao, Gao Xuejie, Han Zhenyu, et al. Bias correction of temperature and precipitation over China for RCM simulations using the QM and QDM methods[J]. Climate Dynamics, 2021, 57(5/6):1425-1443.

[32] Taylor K E. Summarizing multiple aspects of model performance in a single diagram [J]. Journal of Geophysical Research: Atmospheres, 2001, 106(D7):7183-7192.

[33] Donat M G, Alexander L V, Yang H, et al. Global land-based datasets for monitoring climatic extremes [J]. Bulletin of the American Meteorological Society, 2013, 94(7):997-1006.

[34] 刘俏华,姚秀萍,马嘉理,等. 青藏高原夏季极端降水研究进展与展望[J]. 大气科学学报,2024,47(5):737-754. (Liu Qiaohua, Yao Xiuping, Ma Jiali, et al. Research progress and prospects on summer extreme precipitation over the Qinghai-Xizang Plateau [J]. Transactions of Atmospheric Sciences, 2024, 47(5):737-754. (in Chinese))

(收稿日期:2025-06-02 编辑:施业)

(上接第 168 页)

[24] Kareem B A, Zubaidi S L, Al-Ansari N, et al. Review of recent trends in the hybridisation of preprocessing-based and parameter optimisation-based hybrid models to forecast univariate streamflow[J]. Computer Modeling in Engineering & Sciences, 2024, 138(1):1-41.

[25] Liu Ze, Zhou Jingzhao, Yang Xiaoyang, et al. Research on water resource modeling based on machine learning technologies[J]. Water, 2024, 16(3):472.

[26] Sheikh M R, Coulibaly P. Review of recent developments in hydrologic forecast merging techniques [J]. Water, 2024, 16(2):301.

[27] Tian Qingqing, Luo Wei, Guo Lei. Water quality prediction in the Yellow River source area based on the DeepTCN-GRU model[J]. Journal of Water Process Engineering, 2024, 59:105052.

[28] Solanki H, Vegad U, Kushwaha A, et al. Improving streamflow prediction using multiple hydrological models and machine learning methods [J]. Water Resources Research, 2025, 61(1):e2024WR038192.

[29] Zhou Lanting, Long Guanlin, Hu Cancan, et al. Reservoir water level prediction using combined CEEMDAN-FE and RUN-SVM-RBFNN machine learning algorithms [J]. Water Science and Engineering, 2025, 18(2):177-186.

[30] 嵇晓燕,杨凯,陈亚男,等. 基于 ARIMA 和 Prophet 的水质预测集成学习模型[J]. 水资源保护, 2022, 38(6):111-115. (Ji Xiaoyan, Yang Kai, Chen Ya'nan, et al. An ensemble learning model for water quality forecast based on ARIMA and Prophet[J]. Water Resources Protection, 2022, 38(6):111-115. (in Chinese))

[31] 周鹏,许月萍,周欣磊,等. 基于多模型融合的椒江流域季节性径流集合预报[J]. 水利水电科技进展, 2025, 45(3):62-69. (Zhou Peng, Xu Yueping, Zhou Xinlei, et al. Ensemble forecasting of seasonal streamflow in the Jiaojiang River Basin based on multi-model fusion [J]. Advances in Science and Technology of Water Resources, 2025, 45(3):62-69. (in Chinese))

[32] 陈娟,徐琦,曹端祥,等. 基于多因子多模式集成的中长期径流预测模型[J]. 水科学进展, 2024, 35(3):408-419. (Chen Juan, Xu Qi, Cao Duanxiang, et al. Medium and long-term runoff prediction model based on multi-factor and multi-model integration [J]. Advances in Water Science, 2024, 35(3):408-419. (in Chinese))

[33] Chen Yitian, Kang Yanfei, Chen Yixiong, et al. Probabilistic forecasting with temporal convolutional neural network[J]. Neurocomputing, 2020, 399:491-501.

(收稿日期:2025-04-20 编辑:施业)