DOI:10.3880/j.issn.1006-7647.2023.03.002

基于机器学习模型的河道水位预测

陈 珺^{1,2},黄燕华²,洪 朋³,梁培德²,祁 李²

(1.河海大学水文水资源与水利工程科学国家重点实验室,江苏南京 210098;2.河海大学水利水电学院,江苏南京 210098; 3.新沂市水务局港头水利站,江苏徐州 221400)

摘要:结合已有机器学习模型——卷积神经网络(CNN)和门控循环单元(GRU)的优点,构建了并 联卷积循环神经网络(PCNN-GRU)模型,并将其用于赣江下游外洲站日尺度水位变化的预测。结 果显示:相较于目前流行的长短时记忆(LSTM)模型、GRU模型以及卷积循环神经网络(CNN-GRU)模型,PCNN-GRU模型的均方根误差和平均绝对误差分别降低了18.39%、21.11%、15.48% 和21.31%、18.64%、14.28%,纳什-萨特克里夫效率系数和准确率分别提高至0.9992和 88.12%,表明所建模型具有良好的预测性能,可用于河道水位预测。

关键词:河道水位:机器学习:卷积神经网络:循环神经网络:赣江

中图分类号:TV124 文献标志码:A 文章编号:1006-7647(2023)03-0009-06

Prediction of river water level based on machine learning model//CHEN Jun^{1,2}, HUANG Yanhua², HONG Peng³, LIANG Peide², QI Li²(1. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China; 2. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 3. Gangtou Water Conservancy Station of Xinyi Water Conservancy Bureau, Xuzhou 221400, China)

Abstract: Combining the advantages of the existing machine learning models, convolutional neural network (CNN) and gated recurrent unit (GRU), a parallel convolutional recurrent neural network (PCNN-GRU) model was constructed and was applied to the prediction of daily water level changes at the Waizhou station in the lower reaches of the Ganjiang River. The results show that, compared with long short-term memory (LSTM), GRU and convolutional recurrent neural network (CNN-GRU) models, the root mean square error and absolute average error of the PCNN-GRU model are decreased by 18.39%, 21.11%, 15.48% and 21.31%, 18.64%, 14.28%, respectively, and the Nash-Sutcliffe efficiency coefficient and accuracy rate are increased to 0.9992 and 88.12%, respectively. This indicates that the PCNN-GRU model has good prediction performance, and can be used for river water level prediction.

Key words: river water level; machine learning; convolutional neural network; recurrent neural network; Ganjiang River

受流域降雨、河道水系、人类活动等众多因素影 响,河道水位变化具有高度复杂的非线性特点,准确 预测水位存在难度^[1]。迄今为止,水位预测方法主 要包括基于物理过程的水文水动力模型和基于数据 驱动的机器学习模型^[23]。水文水动力模型通过建 立水流方程求解水位变化,要求开发者具备相关的 专业知识并获得完整的水文地形资料和物理参数, 其建模过程复杂、难度大且耗时长,因而应用受到限 制^[45]。而机器学习模型不需要了解输入变量对输 出结果的作用机理,可自动监测变量间的相关性,实 现输入到输出的映射,是水文水动力模型的一种有 效替代方法^[68]。

在众多机器学习算法中,长短时记忆(long

short-term memory, LSTM)和门控循环单元(gated recurrent unit, GRU)模型通过层内神经元间的连接 学习输入序列的长期信息,解决了传统循环神经网络(recurrent neural network, RNN)模型的梯度消失 问题,已成功应用于各种水位预测研究^[9-11]。有不 少学者发现卷积神经网络(convolutional neural network, CNN)作为一种轻量级的网络结构,在提取 输入特征间的依赖关系和空间信息方面具有独特的 优势,故将其与 RNN 结合开发了卷积循环神经网络 (CNN-RNN)模型用于水位预测,获得了更高的精 度。例如:Pan 等^[12]建立了 CNN-GRU 模型,利用长 江干流上下相邻的3 个水文站的水位数据预测中间 水文站的水位,结果表明所建模型的预测精度高于

基金项目:国家重点研发计划(2021 YFD1700802);河海大学大学生创新训练项目(2022102941369)

作者简介:陈珺(1981—),男,副教授,博士,主要从事智慧水利研究。E-mail:chenjunhhu@hhu.edu.cn

GRU 模型; Zhang 等^[13]构建了 CNN-LSTM 模型预测 葛洲坝下游水位,与 CNN 模型和 LSTM 模型相比, 所建模型的结果更接近实际水位。然而,上述 CNN-RNN 模型为串联结构,由 CNN 接收模型的输入数 据, RNN 仅获得 CNN 提取到的信息,与输入数据之 间没有直接联系,因而当 CNN 提取到的信息有误或 者不全面时, RNN 将无法对其进行辨识和更正,其 学习能力未得到充分利用。

为提高模型提取输入数据信息的能力,获得更高的预测精度,本文将 CNN 与 GRU 并联作为输入 数据的特征提取器,建立并联结构的卷积循环神经 网络(parallel CNN-RNN, PCNN-GRU)模型。其中, CNN 和 GRU 直接接收模型的输入数据,即存在两 个输入信息特征提取器,通过调整提取器的权重来 修正提取到的信息,从而降低后续层获得有误或片 面特征的可能性。选择赣江下游作为研究区,将所 建模型应用于外洲站日尺度水位预测,并与 LSTM、 GRU 和 CNN-GRU 模型的预测结果进行比较,评估 不同模型的预测能力,以期为河道水位预测遴选更 加有效的方法。

1 材料和方法

1.1 研究区概况

· 10 ·

赣江是鄱阳湖水系中最大的支流,年平均径流 量占鄱阳湖流域的46%。它发源于武夷山西麓,主 河道长823km,自南向北纵向贯穿江西省,流域面积 约为8.29万km²,占江西省面积的51%^[14-15]。赣江 以赣州和新干作为分界点,赣州以上为上游河段,赣 州至新干为中游河段,新干以下为下游河段,于南昌 市扬子洲分东西两河流入鄱阳湖,本文主要以赣江 下游作为重点研究区域,如图1所示。



1.2 数据选择与预处理

1.2.1 数据选择

外洲站是赣江下游重要的水文站,其集水面积 占赣江流域总面积的97%。该站位置紧邻江西省 南昌市,预测其水位变化对南昌市的防洪、航运和水 资源管理具有重要意义,因此选取该站作为预测 站^[16]。在选择输入特征时,考虑到外洲站水位主要 受上游来流、水位和降雨等因素影响,结合数据的可 获得性和可量化性,选择外洲站及其上游水文站和 雨量站资料。其中,选择峡江、樟树水文站的水位和 流量代表赣江上游来流的影响:支流锦江在樟树站 下游入汇,故选用高安水文站的水位和流量代表锦 江的影响。考虑到上游较远位置的流域降雨影响已 在干流水文站的流量和水位中体现,故不再重复考 虑:洗择外洲站降水量和上游较近位置的市汊雨量 站数据来反映赣江樟树至外洲、锦江高安至外洲河 段的区间降水影响。本文备选输入特征如表1所 示,数据的时间序列长度均为2001-2019年,分辨 率均为日均数据。

表1 备选输入特征

站点	河名	输入特征
外洲站	赣江	水位、流量、降水量
市汊站	赣江	降水量
樟树站	赣江	水位、流量
峡江站	赣江	水位、流量
高安站	锦江	水位、流量

1.2.2 特征寻优

水位与多个输入特征间具有高度复杂的非线性 关系,为了得到最优的模型输入特征组合,利用网格 搜索法对模型备选输入特征进行寻优。使用经典的 3层 BP(back propagation)神经网络作为算法的基模 型,采用平均绝对误差作为评估因子筛选各变量的 组合,最终得到模型的最优输入特征组合为外洲站 水位Z_{wz}和流量Q_{wz}、樟树站流量Q_{zs}、峡江站流量 $Q_{\rm xi}$ 、高安站流量 $Q_{\rm sa}$ 和市汉站降水量 $P_{\rm sc}$ 。选择 2001-2016年的数据为训练数据,其中80%的训练 数据作为训练集用于学习映射关系,剩余20%作为 验证集用于调整模型参数以提高性能:2017-2019 年的数据作为测试集用于评估模型的泛化能力。模 型输出外洲站未来1d的水位,映射公式如式(1)所 示,预测值 y 不仅与前期水位 x 有关,还与前期辅助 输入特征 $A(A = \{a_1, a_2, a_3, a_4, a_5\} = \{Q_{wz}, Q_{zs}, Q_{xi}, a_{xi}\}$ Q_{sa},P_{se}})有关,通过调节不同输入特征的权重来更 新各输入特征的重要性,修正无效的映射规律。即 利用不同输入特征与水位间的依赖关系弱化水位的 自关联性,从而提高模型的预测精度。

$$y = f(x, A) = wx + \sum_{i=1}^{m} w_i a_i + b$$
 (1)

式中: x_{y} 分别为预测因子(即 Z_{wz})和预测值(未来 1 d 的 Z_{wz});m为辅助输入特征的数量,本文m=5; $w_{x}w_{i}$ 分别为x和辅助输入特征 a_{i} 的权重;b为 偏差。

1.2.3 标准化

为了减轻模型的学习压力,加快收敛速度,同时 消除量纲不同对评估模型的影响,使用最大最小标 准化方法将各特征统一缩放至[0,1]。标准化公式 如下:

$$F = \frac{F - F_{\min}}{F_{\max} - F_{\min}}$$
(2)

式中:F为训练数据或测试集的某一输入特征的值; F_{min}、F_{max}分别为训练数据中该特征的最小值和最 大值。

1.3 PCNN-GRU 模型结构

为了充分提取输入数据的有效信息,本文结合 一维 CNN 和 GRU 的优点^[17],构建并联卷积循环神 经网络(PCNN-GRU)模型,具体结构如图 2 所示。 该结构将卷积层与循环层并联以接收输入数据,利 用卷积块提取数据的空间特征,循环块提取时间特 征,然后使用全连接层实现两个模块的输出到预测 值的映射。相当于网络中存在两个特征提取器,在 误差反向传播过程中,若其中某一提取器获得的特 征有误,则会降低该特征提取器的权重,避免下一层 接收到错误信息,这与残差结构的功效相似^[18]。具 体计算流程如下:

a. 输入数据 $U(U = \{u_1, u_2, \dots, u_n\}, n$ 为输入序



图 2 PCNN-GRU 网络结构

列的时间长度)分别经过 K 个卷积块和全局平均池 化层得到包含空间信息和局部时间信息的特征 u_A, 经过 L 个循环块得到包含长期时间依赖关系的特征 u_{g,L}。u_{e,k}、u_A、u_{g,I}的计算公式分别为

$$u_{c,k} = \text{ELU}(w_{c,k}u_{c,k-1} + b_{c,k})$$
 (3)

$$u_{\rm A} = {\rm GAP}(u_{\rm c,K}) \tag{4}$$

$$u_{g,l} = \text{ELU}(\text{GRU}(u_{g,l-1}))$$
(5)

式中:u。k、U。l分别为第 k 个卷积块和第 l 个循环块 的输出;u₄为全局平均池化层的输出;GAP(•)表 示全局平均池化函数;卷积块的索引 $k = \{1, 2, \cdots, n\}$ K, K为卷积块的数量, 当 k=1 时, u_{c0}=U; 循环块 的索引 l= {1,2,…,L},L为循环块的数量,当 l=1 时, $u_{g0} = U$; w_{gk} 和 b_{gk} 分别表示第k 层卷积滤波器的 权重和偏差;GRU(·)表示 GRU 层的计算公式,详 见文献[17];ELU(•)为指数线性单位,是一种非 饱和激活函数,计算公式见文献[17]。每个卷积块 包括一个一维卷积层 Conv1D、一个 ELU 激活函数 和 Dropout 层,其中,Conv1D 层可有效提取输入数据 的空间信息,ELU 激活函数能够学习数据间的非线 性映射关系并减少模型的训练时间,而 Dropout 层 则可降低模型过拟合的风险:每个循环块包含一个 GRU 层和一个 ELU 激活函数, GRU 层能够学习数 据的长期时间信息,并且其训练参数少于 LSTM 层, 收敛速度更快。

b. 将 *u*_A 和 *u*_{g,L}相加后得到的包含时空特征的 映射 *u* 馈入激活函数为 ELU 的全连接层并输出 *o*₁。

c. 输出层接收 *o*₁后输出所需预测值 *o*,其计算 公式为

$$o_{1} = \text{ELU}(w_{o1}u + b_{o1}) = \text{ELU}(w_{oA1}u_{A} + w_{og1}u_{g,L} + b_{o1})$$
(6)
$$o = w_{o}o_{1} + b_{o}$$
(7)

式中: w_{o1} 、 b_{o1} 分别为第一个全连接层的权重和偏差; w_{oA1} 、 w_{og1} 分别为 u_A 和 $u_{g,L}$ 对应的权重; w_o 、 b_o 分别为 输出层的权重和偏差; o_1 、o分别为输出层的输入和 输出。

网络的反向传播过程与其他类型的神经网络相同,沿着由损失函数计算所得误差梯度的负方向来 更新各层参数。例如,当卷积块提取到错误信息,那 么在反向传播过程中,网络将减小卷积块的权重 w_{oA1} ,循环块的权重 w_{ogl} 相应增加,从而降低错误信 息对预测结果的影响,提高网络的学习能力。考虑 到水文数据中存在大量极值,选择平均绝对误差 MAE 作为模型的损失函数。

1.4 模型的评估指标

选用均方根误差 RMSE、平均绝对误差 MAE、纳 什-萨特克里夫效率系数 NSE 和准确率 QR 共4 个 *E-mail*:*iz*[@] *hhu*, *edu*, *cn http://jour.hhu*, *edu*, *cn ·*11 · 指标评价模型的预测效果。RMSE 和 MAE 越接近 0,NSE 和 QR 越接近 1,模型的预测效果越好。

2 结果与分析

2.1 PCNN-GRU 模型预测结果分析

模型的参数设置在很大程度上影响预测效果, 对于模型训练阶段的超参数,参考同类研究进行取 值^[19-20]。对于网络的超参数则使用5倍k-fold 交叉 验证的网格搜索法确定,寻优范围及最优参数如 表2所示。模型的输入数据为前24d的外洲站的日 均水位和日均流量,樟树站、高安站和峡江站的日均 流量,以及市汊站的日均降水量,输出外洲站未来 1d的日均水位。

参数	寻优范围	最优值	寻优方法	
卷积块数量/个	{1,2,3}	2	网格搜索法	
循环块数量/个	{1,2,3}	1	网格搜索法	
卷积层神经元数量/个	{16,32,64}	16	网格搜索法	
循环层神经元数量/个	{16,32,64}	64	网格搜索法	
Dropout 率	{0.1,0.2,0.3, 0.4,0.5}	0.3	网格搜索法	
时间步长/d	{6,12,18, 24,30,36}	24	网格搜索法	
优化器		Adam	参考同类研究取值	
批量大小		100	参考同类研究取值	
学习率		0.01	参考同类研究取值	

PCNN-GRU模型对 2017—2019 年外洲站日均水 位的评估结果显示, RMSE 和 MAE 分别为 0.071 m 和 0.048 m, NSE 接近 1, QR 为 88.12%, 表明其具 有良好的预测效果, 能较好地预测赣江下游外洲站 未来 1 d 的水位。为更好地反映水位变化趋势对预 测结果的影响, 绘制 2017—2019 年预测与实测水位 的过程线和绝对偏差如图 3 所示。预测水位过程线 和实测水位过程线的拟合程度较高。当水位波动较 小时, 预测值几乎与实测值重合; 而当水位变化较大 时, 预测值与实测值存在一定的偏差。预测结果的 绝大部分偏差小于 0.1 m。但由于汛期水位波动幅



度大,变化规律复杂,因此汛期存在少量绝对偏差大于0.2m的预测值。总的来说,PCNN-GRU 模型能够准确预测水位的变化趋势,可作为一种有效的预测方法。

2.2 不同结构模型的对比分析

通过与目前在水位预测中应用较多的 LSTM 模型、GRU 模型以及 CNN-GRU 模型进行对比,合理评价 PCNN-GRU 模型的性能。上述模型均采用网格 搜索法进行超参数寻优,除模型结构不同外,模型的 输入数据、训练阶段的超参数等均保持一致。表 3 为不同模型的评估指标计算结果,预测水位和实测 水位的绝对偏差如图 4 所示,通过比较指标值和绝 对偏差的大小来评价不同模型的性能。

表 3	不同结构模型在 2017—2019 年水位
	测试集的评估指标计算结果

模型	RMSE/m	MAE/m	NSE	QR/%
PCNN-GRU	0.071	0.048	0.9992	88.12
LSTM	0.087	0.061	0.9988	84.46
GRU	0.090	0.059	0.9987	84.55
CNN-GRU	0.084	0.056	0.9989	85.56



图 4 不同结构模型预测水位和实测水位的绝对偏差

如表3所示,相对于LSTM、GRU和CNN-GRU 模型, PCNN-GRU 模型的 RMSE 和 MAE 分别降低了 18.39%、21.11%、15.48% 和 21.31%、18.64%、 14.28%, 且拥有最高的 NSE 和 OR, 表明 PCNN-GRU 模型的预测性能最佳。从图 4 也可以看出. PCNN-GRU 模型预测结果的绝对偏差最小. CNN-GRU 模型次之:两种循环结构模型的结果最差,最 大偏差分别高达 0.5 m 和 0.7 m。该结果与文献 [12-13]的试验结果一致,即借助 CNN 和 RNN 分别 学习水文序列的空间信息和时间信息的能力,可有 效提升模型的预测性能:进一步佐证了 Pak 等^[21]和 Collado-Villaverde 等^[22]的研究结论,将 CNN 与 RNN 结合是提高时间序列预测精度的一种新方法。此 外,PCNN-GRU 模型的结果优于 CNN-GRU 模型,表 明采用卷积层和循环层并联的结构可降低后续层获 得有误或片面信息的可能性,从而降低模型的预测 误差,进一步证明了提出结构的有效性。

2.3 模型输入特征的影响

输入特征对机器学习模型的训练非常重要^[23]。 为研究输入特征对水位预测结果的影响,同时检验 本文选用输入特征的合理性,采用6种输入特征组 合分别建立 PCNN-GRU、LSTM、GRU 和 CNN-GRU 模型进行试验,以充分评价模型输入特征的影响。 表4为模型的6种输入条件,在同一种结构模型的 试验中,除输入特征不同外,其他参数均保持一致。

输入条件	特征变量
条件 A	$Z_{_{ m WZ}}$
条件 B	$Z_{ m wz}$, $Q_{ m wz}$
条件 C	$Z_{\rm wz}$ $Q_{\rm wz}$ $Q_{\rm zs}$
条件 D	$Z_{\rm wz}$ $Q_{\rm wz}$ $Q_{\rm zs}$ $Q_{\rm xj}$
条件 E	$Z_{ m wz}$, $Q_{ m wz}$, $Q_{ m zs}$, $Q_{ m xj}$, $Q_{ m ga}$
条件 F	$Z_{ m wz}$ $Q_{ m wz}$ $Q_{ m zs}$ $Q_{ m zj}$ $Q_{ m ga}$ $P_{ m sc}$

不同输入条件下4种模型的损失结果如表5所 示.图5为不同模型在测试集上的评估指标。可以 看出,仅采用Z_作为输入条件时,模型的预测效果 很差,各模型的 MAE 均大于 0.1 m, QR 均小于 70%。当仅添加 Q_{m} 时,模型的预测误差降低幅度 很小(比较输入条件 A 和 B),训练损失的降低幅度 为0.001~0.004m.表明由于外洲站的水位流量关 系发生变化,模型无法学习到有效的水位流量映射 关系。而进一步添加 Q₂时,精度得到显著提升(比 较输入条件 B 和 C),4 种模型的 RMSE 和 MAE 大 幅降低, NSE 和 QR 明显提高。在此基础上逐步添 加 Q_{xi} 、 Q_{sa} 和 P_{sc} 时,随着输入特征的增加,模型的预 测效果得到不同程度的改善(比较输入条件 C、D、E 和 F)。总的来说,4 种模型在输入条件 F 下的损失 最低,评估指标最优,表明考虑时空影响因子与水位 间的依赖关系能够降低水位自身的关联影响,从而 提高水位的预测精度。此外,在相同输入条件下, PCNN-GRU 模型均获得了最优的预测结果,进一步 证明了其具有较强的竞争力。

表 5	不同输入条件下不同结构模型的损失

模型	训练损失/m					
	条件 A	条件 B	条件 C	条件 D	条件 E	条件 F
PCNN-GRU	0.098	0.097	0.062	0.048	0.039	0.026
LSTM	0.102	0.098	0.075	0.054	0.046	0.042
GRU	0.105	0.102	0.076	0.062	0.050	0.045
CNN-GRU	0.100	0.098	0.066	0.052	0.048	0.044
模型	验证损失/m					
	条件 A	条件 B	条件 C	条件 D	条件 E	条件 F
PCNN-GRU	0.103	0.102	0.066	0.053	0.044	0.037
LSTM	0.105	0.102	0.075	0.058	0.049	0.046
GRU	0.106	0.104	0.073	0.063	0.053	0.050
CNN-GRU	0.102	0.100	0.070	0.054	0.051	0.049



图 5 不同输入条件下不同结构模型的评估结果

3 结 语

为提高机器学习模型预测河道水位的精度,结 合已有机器学习算法的优点,构建了 PCNN-GRU 模 型,将所建模型应用于赣江下游外洲站的水位预测, 其预测结果优于 LSTM、GRU 和 CNN-GRU 模型,表 明使用并联的 CNN 和 RNN 同时提取输入序列时空 信息可提高模型的预测精度。综合考虑上游流量、 水位和降水的影响,开展特征组合寻优以选择模型 输入特征,可明显改善模型的预测效果。总之,本文 构建的基于时空信息输入的 PCNN-GRU 水位预测 模型具有良好的预测性能,可作为一种有效的水位 预测方法。考虑到所建模型采用了递归结构,并行 性不强,后续工作将侧重开发基于全卷积神经网络 的模型,以提高模型的并行能力,缩短模型的训练时 间。另外,本文输入特征只考虑了部分影响因素,还 可以进一步探讨河道地形、下游湖泊水位等多种因 素对模型预测结果的影响。

参考文献:

- [1] DENG Bin, LAI S H, JIANG Changbo, et al. Advanced water level prediction for a large-scale river-lake system using hybrid soft computing approach: a case study in Dongting Lake, China [J]. Earth Science Informatics, 2021,14(4):1987-2001.
- [2] YAN Shaofeng, YU Shuangen, WU Yubai, et al. Understanding groundwater table using a statistical model
 [J]. Water Science and Engineering, 2018, 11(1):1-7.
- [3] LI Yunliang, ZHANG Qi, YAO Jing, et al. Hydrodynamic and hydrological modeling of the Poyang Lake Catchment System in China [J]. Journal of Hydrologic Engineering,

水利水电科技进展,2023,43(3) Tel;025-83786335 E-mail;jz@hhu.edu.cn http://jour.hhu.edu.cn •

2014,19(3):607-616.

- [4] LOPES V A R, FAN F M, PONTES P R M, et al. A first integrated modelling of a river-lagoon large-scale hydrological system for forecasting purposes [J]. Journal of Hydrology, 2018, 565; 177-196.
- [5] LAI Xijun, JIANG Jiahu, LIANG Qiuhua, et al. Large-scale hydrodynamic modeling of the middle Yangtze River Basin with complex river-lake interactions [J]. Journal of Hydrology, 2013, 492:228-243.
- [6] YIN Wenjie, FAN Zongwen, TANGDAMRONGSUB N, et al. Comparison of physical and data-driven models to forecast groundwater level changes with the inclusion of GRACE: a case study over the state of Victoria, Australia [J]. Journal of Hydrology, 2021, 602:126735.
- [7]周聂,侯精明,陈光照,等.基于机器学习的山洪灾害快速预报方法[J].水资源保护,2022,38(2):32-40.
 (ZHOU Nie, HOU Jingming, CHEN Guangzhao, et al. A rapid forecasting method for mountain flood disaster based on machine learning algorithms [J]. Water Resources Protection,2022,38(2):32-40. (in Chinese))
- [8] 刘艳,张婷,康爱卿,等. Seq2Seq 模型的短期水位预测
 [J].水利水电科技进展,2022,42(3):57-63. (LIU Yan,ZHANG Ting,KANG Aiqing, et al. Short-term water level prediction based on Seq2Seq model[J]. Advances in Science and Technology of Water Resources, 2022,42 (3):57-63. (in Chinese))
- [9] 刘亚新,樊启祥,尚毅梓,等. 基于 LSTM 神经网络的水 电站短期水位预测方法[J].水利水电科技进展,2019, 39(2):56-60. (LIU Yaxin, FAN Qixiang, SHANG Yizi, et al. Short-term water level prediction method for hydropower station based on LSTM neural network [J]. Advances in Science and Technology of Water Resources, 2019,39(2):56-60. (in Chinese))
- [10] 王亦斌,孙涛,梁雪春,等. 基于 EMD-LSTM 模型的河流 水量水位预测[J].水利水电科技进展,2020,40(6): 40-47.(WANG Yibin, SUN Tao, LIANG Xuechun, et al. Prediction of river water flow and water level based on EMD-LSTM model [J]. Advances in Science and Technology of Water Resources,2020,40(6):40-47.(in Chinese))
- [11] 郭燕,赖锡军. 基于长短时记忆神经网络的鄱阳湖水位 预测[J]. 湖泊科学,2020,32(3):865-876. (GUO Yan, LAI Xijun. Water level prediction of Lake Poyang based on long short-term memory neural network [J]. Journal of Lake Sciences,2020,32(3):865-876. (in Chinese))
- [12] PAN Mingyang, ZHOU Hainan, CAO Jiayi, et al. Water level prediction model based on GRU and CNN[J]. IEEE Access, 2020, 8:60090-60100.

- [13] ZHANG Zhendong, QIN Hui, YAO Liqiang, et al. Downstream water level prediction of reservoir based on convolutional neural network and long short-term memory network [J]. Journal of Water Resources Planning and Management, 2021, 147 (9):04021060.
- [14] WANG Zhichao, XU Xinfa, HUANG Zhiwen, et al. Siltation characteristics of the tail reach of Ganjiang River under the regulation of estuary gates [J]. Water Supply, 2020,20(8):3707-3714.
- [15] HUANG Feng, OCHOA C G, GUO Lidan, et al. Investigating variation characteristics and driving forces of lake water level complexity in a complex river-lake system
 [J]. Stochastic Environmental Research and Risk Assessment, 2021, 35(5):1003-1017.
- [16] ZHU Di, MEI Yadong, BEN Yue, et al. Inter- and intraannual trend analysis of water level and flow in the middle and lower reaches of the Ganjiang River, China [J]. Hydrological Sciences Journal, 2020,65(12):2128-2141.
- [17] GÉRON A. Hands-on machine learning with scikit-learn, keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems [M]. 2nd ed. Sebastopol: O' Reilly Media, Inc. ,2019:390-452.
- [18] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2015.
- [19] BENHADDI M, OUARZAZI J. Multivariate time series forecasting with dilated residual convolutional neural networks for urban air quality prediction [J]. Arabian Journal for Science and Engineering, 2021, 46(4): 3423-3442.
- [20] BOROVYKH A, BOHTE S, OOSTERLEE C W. Dilated convolutional neural networks for time series forecasting
 [J]. Journal of Computational Finance, 2019, 22(4):73-101.
- [21] PAK U, KIM C, RYU U, et al. A hybrid model based on convolutional neural networks and long short-term memory for ozone concentration prediction [J]. Air Quality, Atmosphere & Health, 2018, 11(8):883-895.
- [22] COLLADO-VILLAVERDE A, MUÑOZ P, CID C. Deep neural networks with convolutional and LSTM layers for SYM-H and ASY-H forecasting[J]. Space Weather, 2021, 19(6):e2021SW002748.
- [23] KIM D,HAN H C,WANG W, et al. Improvement of deep learning models for river water level prediction using complex network method[J]. Water, 2022, 14(3):466. (收稿日期:2022-11-07 编辑: 俞云利)