水利水运工程学报
HYDRO-SCIENCE AND ENGINEERING

基于时间卷积网络的长江下荆江航道水位预测

李港，李有为，舒章康，张宇，王江，查伟

Water level prediction of lower Jingjiang Waterway in Yangtze River based on temporal convolution network

LI Gang, LI Youwei, SHU Zhangkang, ZHANG Yu, WANG Jiang, ZHA Wei

在线阅读 View online: https://doi.org/10.12170/20220809002

您可能感兴趣的其他文章
Articles you may be interested in

基于BP神经网络的丁坝坝头冲刷坑变化趋势预测
Prediction of the change trends of the scour near the head of the spur dike based on BP neural network
水利水运工程学报. 2019(6): 125 https://doi.org/10.16198/j.cnki.1009-640X.2019.06.014

基于GA-BP神经网络的粗粒土渗透系数预测
Prediction of permeability coefficients of coarse-grained soil based on GA-BP neural network
水利水运工程学报. 2018(6): 92 https://doi.org/10.16198/j.cnki.1009-640X.2018.06.012

河道山地灾害的卷积神经网络快速识别方法
Fast recognition method for mountain hazards in river courses based on convolutional neural networks
水利水运工程学报. 2019(2): 65 https://doi.org/10.16198/j.cnki.1009-640X.2019.02.009

基于BP神经网络的黑龙江漠河段冰坝预测
Forecast of ice dam in Mohe reach of Heilongjiang River based on BP neural network
水利水运工程学报. 2021(2): 57 https://doi.org/10.12170/20200619002

土石坝渗压水位极值预测
Prediction of seepage water level extremum of earth rock dam
水利水运工程学报. 2021(4): 29 https://doi.org/10.12170/20200824002

利用水位变化的黑龙江开河方式和开河日期预报
Prediction of Heilong River ice break-up mode and date based on water level change
水利水运工程学报. 2020(3): 29 https://doi.org/10.12170/20200318003

扫码进入官网，阅读更多精彩文章　　关注微信公众号，获得更多资讯信息

DOI:10.12170/20220809002
李港, 李有为, 舒章康, 等. 基于时间卷积网络的长江下荆江航道水位预测 [J]. 水利水运工程学报, 2023(6): 84-92. (LI Gang, LI Youwei, SHU Zhangkang, et al. Water level prediction of lower Jingjiang Waterway in Yangtze River based on temporal convolution network[J]. Hydro-Science and Engineering, 2023(6): 84-92. (in Chinese))

基于时间卷积网络的长江下荆江航道水位预测

李 港[1,2], 李有为[1,2], 舒章康[3], 张 宇[3], 王 江[1,2], 查 伟[3]
(1. 长江航道勘察设计院 (武汉) 有限公司, 湖北 武汉 430040; 2. 国家内河航道整治工程技术研究中心, 湖北 武汉 430040; 3. 南京水利科学研究院 水灾害防御全国重点实验室, 江苏 南京 210029)

摘要: 航道水位的精准预测对保障船舶通航安全具有重要意义。以长江下荆江航道为研究区域, 采用 2019—2020 年水文时间序列数据为训练集, 2021 年数据为验证集, 构建基于时间卷积网络(TCN)的长江下荆江水位变化预测模型, 并与基于长短时记忆神经网络(LSTM)和支持向量机(SVM)的水位预测模型进行计算精度的对比。结果表明: 不同站点 TCN 对应的最优输入时间窗口存在一定差异, 监利站、调弦口站及石首站的最优输入时间窗口分别为前 2 d、前 2 d 和前 3 d; TCN 在 2021 年下荆江各站点水位预测结果的纳什系数(E_{NS})和决定系数(R^2)均高于 0.995, 均方根误差(E_{RMS})小于 0.21 m, 整体预测效果优于 LSTM, 两者预测精度均较高, 均显著优于 SVM; 但随着预测时间尺度的增加, 水位预测精度整体呈下降趋势; TCN 模型各站点枯水期大部分时段的水位预测绝对误差小于 0.2 m, 这表明 TCN 在航道水位预测领域具有较好的应用潜力。通过分析 TCN 在航道水位预测中的适用性和优越性, 可为长江航道水位预测精度提升和船舶安全通航提供技术支撑。

关 键 词: 水位预测; 航道水位; 下荆江航道; 时间卷积网络; 长短时记忆神经网络
中图分类号: TV124 **文献标志码:** A **文章编号:** 1009-640X(2023)06-0084-09

水路运输在国民运输中有着极其重要的地位, 航道水位是影响船舶通航安全的重要因素[1-2]。长江作为货运量全球第一的内河航道, 其下荆江河段蜿蜒曲折, 河槽冲刷下切, 通航条件相对较差[3]。因此, 开展长江中游下荆江河段的水位预测研究, 对保障船舶通航安全具有重要意义。

目前水位预测方法主要包括基于机理过程的水动力模型和基于数据驱动的统计模型[4-6]。水动力模型能够较好地实现水位变化的精细模拟, 陈炼钢等[7] 采用 EFDC 模型模拟鄱阳湖的水位变化, 提出适宜越冬水鸟的生态水位调控方案; 戴凌全等[8] 基于 MIKE Flood 构建江湖一体化耦合水动力模型, 实现洞庭湖白鹤栖息地水位波动的模拟。然而, 水动力模型的构建需要非常完善的数据作为支撑, 计算复杂, 耗时较长, 水位预测依赖于边界条件的预测, 易造成误差累积, 降低水位预测精度[9]。统计模型通过数理统计方法建立水位与影响因素之间的关系, 进而实现水位的预测, 计算效率高, 操作简便, 得到了广泛应用[10]。然而, 早期的回归方法难以刻画水位与其影响因素之间的非线性关系, 预测精度较低[11]。随着机器学习的发展, 人工神经网络(Artificial Neural Network, ANN)[12]、支持向量机(Support Vector Machine, SVM)[13] 等模型提高了水位预测精度, 但均未考虑水位时间的相关性[14]。深度学习模型中的循环神经网络(Recurrent Neural Network, RNN)可考虑短期历史信息的影响[15], 能有效提升水位预测精度, 但其网络结构仍存在梯度消失和梯度爆炸的问题, 导致模型易陷入局部最优解或训练无法收敛[16]。而长短时记忆神经网络(Long Short-term Memory, LSTM)作为 RNN 的变体, 通过加入门控单元, 实现了高精度的水位预报[17]; 郭燕等[18-19] 利用 LSTM 准确预

收稿日期: 2022-08-09
基金项目: 江苏省自然科学基金青年项目(BK20200160)
作者简介: 李 港(1997—), 男, 湖北宜昌人, 硕士, 主要从事智慧航道建设研究。E-mail: gangli9771@163.com
通信作者: 查 伟(E-mail: wzha@nhri.cn)

测了洞庭湖和鄱阳湖的水位变化; Barzegar 等[20] 基于 LSTM 模型进行了不同尺度湖泊的水位预测, 取得了较好的预测效果。时间卷积网络(Temporal Convolutional Network, TCN)结构中的因果卷积和膨胀卷积可以将时间序列与历史记忆有效结合, 计算效率高, 在部分时序任务的预测中取得了优于 LSTM 的效果[21-22]。然而, 目前在水位预测领域对 TCN 模型的相关应用还有待进一步探索。

基于此, 本研究以长江下荆江河段为研究对象, 利用 TCN 模型建立荆江下游河段水位站点的日尺度水位预测模型, 同时构建相应的 LSTM 和 SVM 水位预测模型进行对比分析, 探究 TCN 模型在下荆江水位预报中的适用性, 以期为航道内船舶通航安全提供技术支撑。

1　研究区域及数据资料

长江中游荆江河段起于湖北枝城, 止于湖南城陵矶(图 1), 全长约 347 km。以藕池口为界, 分为上荆江和下荆江, 其中下荆江河长约 175 km, 属于典型的弯曲型河道, 由石首、调关及七弓岭等 10 个弯曲段组成, 各弯道平均曲折系数为 1.82, 大部分属于急弯河段, 通航条件较差[23]。

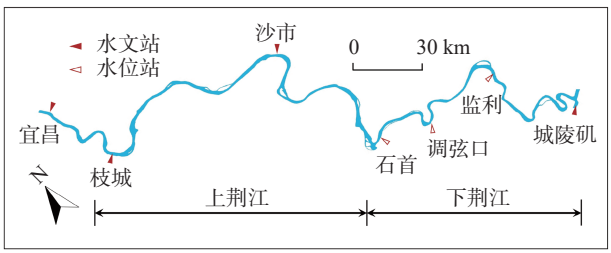

图 1　研究区域及水文水位站点分布

Fig. 1　Study area and distribution of hydrological stations

研究选用的数据资料包括宜昌站、枝城站和沙市站 2019—2021 年的逐日平均流量数据, 以及石首站、调弦口站和监利站 2019—2021 年的逐日平均水位数据, 监测站点分布见图 1。建模前需对各站点的水位流量时间序列数据进行归一化处理, 消除数据量纲影响, 加快模型训练过程中的收敛速度。采用 min-max 方法将数据归一化至 [0,1]。

2　模型与研究方法

2.1　模型基本原理

循环神经网络(RNN)是处理时间序列任务回归预测的重要手段, 卷积神经网络(Convolutional Neural Network, CNN)则主要用于解决图像识别、机器视觉等相关问题。TCN 本质是一维卷积神经网络针对时序问题的优化和改进, 网络结构见图 2(a), 通过使用因果卷积, 使 TCN 能够适用于序列建模, 同时采用扩张卷积让网络能够学到更长的时序依赖信息, 避免历史数据信息的丢失, 即使不做任何池化操作也可增大感受野的范围 , 使卷积核能够学习更大范围的信息, 并且可以并行处理序列数据, 所需训练参数较少, 计算效率较高[24-25]。扩张因果卷积的计算式为:

$$G(F,X)=(F*X)_{x_t}=\sum_{k=1}^{K}f_k x_{t-(K-k)d} \tag{1}$$

式中: $X=\{x_1, x_2, \cdots, x_t\}$为输入的时间序列; $F=\{f_1, f_2, \cdots, f_K\}$表示大小为 K 的卷积核, f_K 表示卷积操作中 filter 的数量; d 为扩张率。

此外, TCN 还增加了残差连接, 将数据跳过中间的卷积操作, 经过 1×1 的卷积后直接与经过中间卷积操作的数据相加作为本层最终的输出数据, 可有效避免中间层堆叠导致模型在训练过程中出现梯度消失的问题[26]。因果扩张卷积加上残差连接构成了 TCN 模型的基本单元, 其结构如图 2(b)所示。

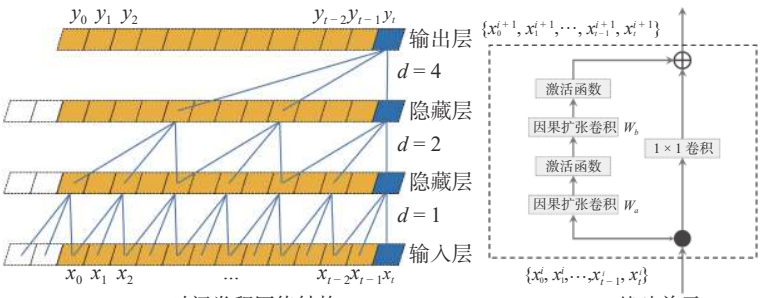

(a) 时间卷积网络结构 (b) 基础单元

图 2 时间卷积网络结构和基础单元示意

Fig. 2 Structure of TCN and schematic diagram of TCN basic unit

为了探究 TCN 模型在水位预测中的适用性和优越性, 同时构建了 LSTM 模型及 SVM 模型进行水位预测, 并进行 TCN 模型和两者预报精度的对比分析。LSTM 结构主要包括输入门、输出门和遗忘门 3 个门控单元, 能够缓解 RNN 的梯度消失和梯度爆炸问题, 是目前常用于时间序列回归预测的深度学习模型[27]。SVM 是建立在统计学 VC 维理论和结构风险最小化原理上的机器学习模型, 能够根据样本在模型复杂性和预测学习能力之间取得最佳平衡, 在水位预报领域得到了较为广泛的应用[5, 28-29]。

2.2 水位预测方法

研究以 2019 年和 2020 年流量水位数据为模型的训练数据集, 2021 年的水位数据为验证数据集; 采用宜昌站、枝城站及沙市站的日均流量, 以及待预测站点的水位作为输入数据, 分别预测下荆江河段石首、调弦口及监利站 2021 年的水位。考虑到下荆江各站点的水位与上游各站点的流量之间存在时间滞后, 分别设置宜昌站、枝城站、沙市站 3 个站点及待预测站点前 1 d 至前 10 d 共 30 种滞时方案下的流量水位作为输入, 进行下荆江河段石首、调弦口及监利站未来 1 d 的水位训练与预测, 以确定最优的输入时间窗口, 获得最佳的水位预测效果。由于网络训练过程中, 初始权重赋值的随机性, 会使模型的水位预报结果存在一定差异, 因此, 最终的水位预报结果为同一参数下进行 10 次数值试验的平均值。

本研究所有的数值试验均在 Windows 系统上(CPU: AMD R7-5800H@3.2GHz, GPU: NVIDIA GeForce RTX 3050Ti), 采用 Python 开发语言 (3.6.12) 基于 TensorFlow(2.1.0) 和 Keras(2.3.1)深度学习框架实现。

模型选取纳什系数(Nash-Sutcliffe Efficiency Coefficient, E_{NS})、均方根误差(E_{RMS})及决定系数(R^2)3 个指标进行石首、调弦口及监利站水位的模拟预测精度评价。

3 结果与分析

3.1 模型参数确定

3.1.1 *模型超参数* 超参数设置对模型的预报精度具有较大影响。模型采用的优化算法是适应性动量估计算法(Adaptive moment estimation, Adam), 能自适应学习率加快网络收敛速率, 沿梯度的负方向更新参数, 是目前深度学习中应用最为广泛的优化算法[14]; 激活函数选用 ReLU 函数, 其优势在于能够快速训练网络, 防止模型训练过程中出现梯度消失问题[30]; 同时模型的 Dropout 层以一定比例随机丢弃神经元, 能有效防止模型发生过拟合。此外, 对模型性能影响较大的超参数还包括卷积核尺寸和卷积核个数。分别设置 Dropout 为 0.2、0.3、0.5, 卷积核尺寸为 2、3、4、5, 以及卷积核个数为 8、16、32、64, 采用网格搜索法确定最优的参数组合; 其余如初始学习、率膨胀因子等敏感性较低的超参数按照经验值设置[31], 最终 TCN 模型的超参数取值见表 1。

3.1.2 *最优输入时间窗* 除了模型的超参数外, 输入时间窗口对水位的预报精度也有较大影响, 因为流量

和水位并不是同步变化, 存在一定的时间滞后, 进行模型不同输入时间窗的优选计算, 分析滞后时长对当前水位的影响程度, 确定流量-水位之间最优滞后关系, 进而获得最佳的水位预测效果。本研究计算并比较了输入时间窗为 1~10 d 时各站点在训练期和预测期水位的模拟预测精度, 计算结果见图 3。可见, 不同时间窗下, TCN 模型在训练期和测试期的水位模拟预测精度存在一定差异, 各站点训练期最优精度对应的输入时间窗口与测试期的相同, 模型训练期和测试期模拟预测精度均较高, 具有较好的一致性, 不存在过拟合现象, 这表明模型具有较好的鲁棒性和泛化能力。总体而言, TCN 模型在合适的输入时间窗口下能够获得高精度的水位预测效果, 监利站、调弦口站及石首站对应的最优输入时间窗口分别为 2、2 和 3 d。

表 1　TCN 模型的超参数设置

Tab. 1　Hyperparameter settings of TCN model

模型超参数	参数设置	模型超参数	参数设置
优化算法	Adam	卷积核个数	32
激活函数	ReLU	膨胀因子	[1/2/4/8]
损失函数	Mean Squared Error (MSE)	学习率	0.001
Dropout	0.2	批大小	30
卷积核尺寸	3	最大迭代轮数	200

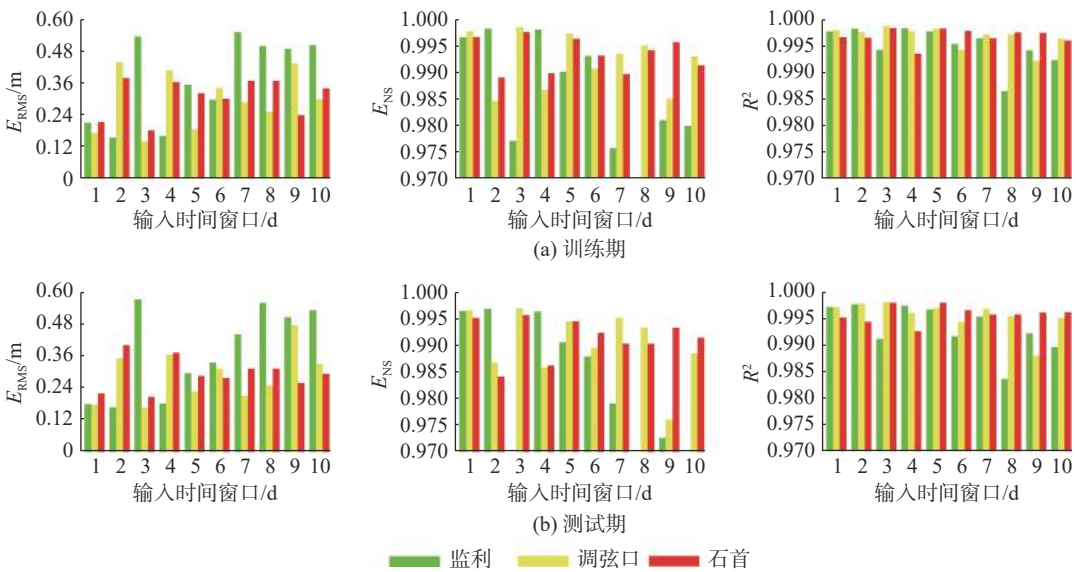

图 3　不同输入时间窗口下 3 个站点训练期和测试期的水位预测效果

Fig. 3　Water level prediction in training and testing periods of three stations under different input time windows

3.2　不同模型预测精度分析

图 4 是 TCN 模型在对应最优输入时间窗口下, 训练期和测试期 3 个站点未来 1~3 d 的水位模拟预测结果。总体而言, TCN 在下荆江不同水位站点处训练期和测试期的水位预测值与实测值吻合较好, 能较好捕捉水位的峰谷值。

表 2 是 TCN 模型与 LSTM 模型及 SVM 模型在不同站点处测试期的水位预测精度对比。整体上 TCN 预测效果最好, SVM 预测效果较差。TCN 在监利站和调弦口站的 3 个水位预测精度评价指标均略优于 LSTM, 但差异较小; 在石首站的水位预测中, TCN 的 E_{NS} 和 E_{RMS} 略低于 LSTM, R^2 优于 LSTM, 这表明 TCN 模型对石首站水位的拟合程度较高, 但预测的绝对偏差略大, 两种深度学习模型在下荆江河段 3 个站点未来 1 d 的水位预测精度均较高, 在对应的最优输入时间窗口下, E_{NS} 和 R^2 均能达到 0.995 以上, E_{RMS} 基本小于 0.2 m。随着预测时间尺度的增加, TCN 和 LSTM 的预测精度均呈现不同程度的降低, TCN 在未来 2 d 和未来 3 d 的预测精度相较于 LSTM 有了一定的提升, 3 个精度评价指标结果均优于 LSTM 模型。总体而言, LSTM 的水位预测已达到较高精度, 而 TCN 的水位预测精度更高, 这主要是因为 LSTM 虽然通过门

控单元缓解了 RNN 的梯度问题，但遗忘门还是会以一定的概率丢弃历史信息，当序列长度超过一定值后，仍会出现梯度消失问题[32]，而 TCN 反向传播路径是沿着网络深度方向，而非 LSTM 的序列时间方向，避免了 LSTM 在过长时间序列上的梯度问题，能够在一定程度上提高预测精度。

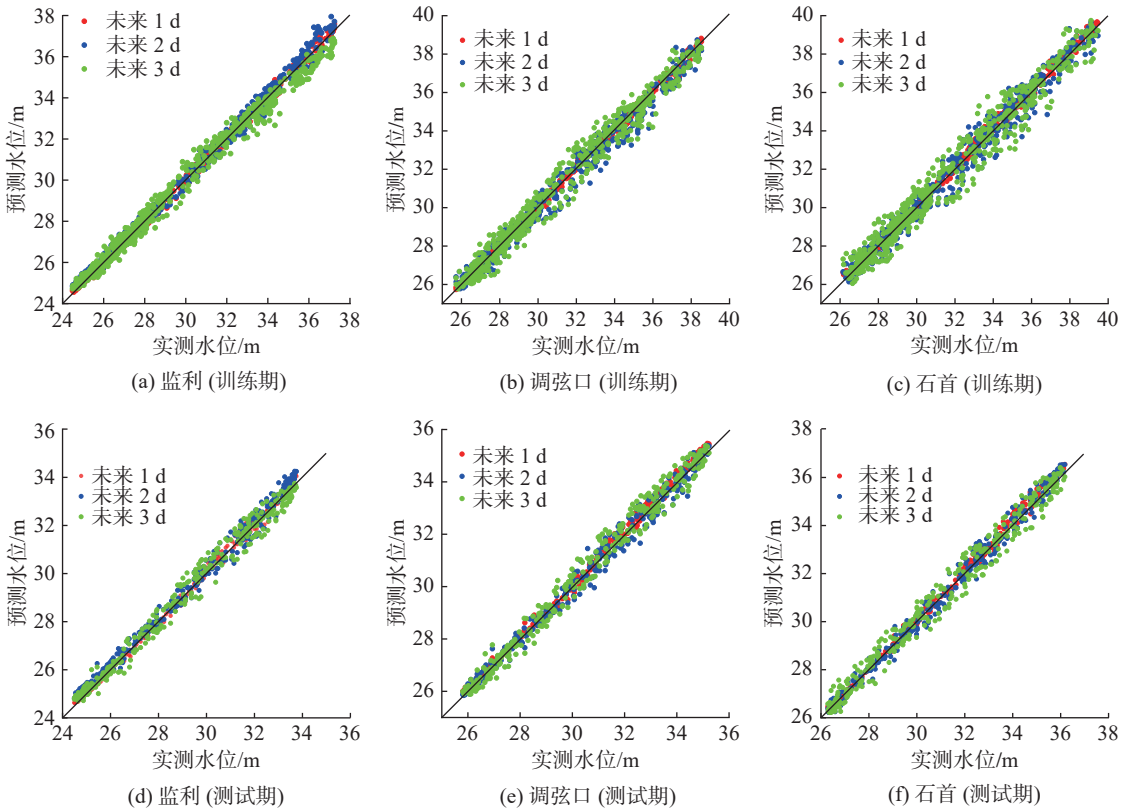

图 4 TCN 模型在不同站点处未来 1~3 d 的水位预测值与实测值对比情况

Fig. 4 Comparison of predicted and measured water level of TCN model at different stations in the next three days

表 2 TCN、LSTM、SVM 在不同站点处 2021 年的水位预测精度

Tab. 2 TCN, LSTM and SVM prediction accuracy of water level in 2021 at different stations

模型	站点	未来1 d			未来2 d			未来3 d		
		E_{NS}	E_{RMS}/m	R^2	E_{NS}	E_{RMS}/m	R^2	E_{NS}	E_{RMS}/m	R^2
TCN	监利	0.997 0	0.167 5	0.997 7	0.993 4	0.301 6	0.989 2	0.988 0	0.339 2	0.988 3
	调弦口	0.997 1	0.165 9	0.998 2	0.992 3	0.278 4	0.992 2	0.987 8	0.341 9	0.988 6
	石首	0.995 8	0.207 8	0.998 0	0.992 5	0.280 2	0.993 6	0.983 9	0.357 4	0.984 2
LSTM	监利	0.996 2	0.189 9	0.996 2	0.990 9	0.318 5	0.990 5	0.982 7	0.387 6	0.982 5
	调弦口	0.996 1	0.193 3	0.996 5	0.989 7	0.334 1	0.988 7	0.979 7	0.379 3	0.980 7
	石首	0.996 3	0.193 9	0.997 0	0.990 0	0.321 9	0.989 8	0.978 5	0.360 1	0.978 8
SVM	监利	0.993 3	0.260 9	0.996 9	0.980 2	0.402 3	0.987 3	0.966 2	0.523 9	0.973 0
	调弦口	0.992 0	0.294 8	0.996 1	0.985 4	0.437 7	0.985 6	0.964 3	0.543 8	0.976 2
	石首	0.991 7	0.291 5	0.995 8	0.977 6	0.398 1	0.984 0	0.967 6	0.520 5	0.972 4

3.3 不同时期预测精度分析

表 3 是各站点 TCN 模型水位预测结果在丰水期和枯水期不同区间绝对误差出现天数，其中，丰水期统计时段为 5—10 月，枯水期统计时段为 11 月—翌年 4 月。在未来 1 d 的水位预测结果中，枯水期的绝对误

差基本小于 0.2 m, 而丰水期则基本小于 0.5 m; 未来 2 d 和未来 3 d 的预测结果中, 预测精度随预测时间尺度的增加呈降低趋势, 绝对误差大于 0.5 m 的天数增加, 丰水期绝对误差大于 0.5 m 的最大出现天数为 27, 枯水期为 13。总体而言, 各站点枯水期在不同时间尺度的预测绝对误差均显著优于丰水期, 这主要是因为历史数据中丰水期的水位流量高值数据相对较少, 模型训练过程中, 为达到最优精度, 预测结果会向样本数量较多的枯水期低水位值趋近[33]。对于航道水位预测, 保证枯水期的水位预测精度可以有效保障船舶的通航安全, 而丰水期的水位预测可以在后续研究中通过加入更多年份的历史数据进行模型训练, 进而提升丰水期水位预测精度。

表 3　3 个站点未来 1~3 d 预测结果不同区间绝对误差在丰、枯水期出现天数

Tab. 3　The number of days with different absolute error in the next three days in dry season and wet season　　单位: d

预测时期	绝对误差/m	监利			调弦口			石首		
		未来1 d	未来2 d	未来3 d	未来1 d	未来2 d	未来3 d	未来1 d	未来2 d	未来3 d
丰水期(5—10月)	<0.2	108	96	80	107	94	79	98	91	78
	[0.2, 0.5]	75	71	85	77	76	81	84	72	79
	>0.5	1	17	19	0	14	24	2	21	27
枯水期(11月—翌年4月)	<0.2	168	112	107	165	145	111	174	138	116
	[0.2, 0.5]	11	63	63	14	29	55	5	36	52
	>0.5	0	4	9	0	5	13	0	5	11

注: 绝对误差为2019年测试期内水位模型预测值与真实值的差值。监利站未来1~3 d的水位最大绝对误差为0.518 8、0.814 4和0.837 8 m, 调弦口的为0.441 7、0.809 5和0.918 0 m, 石首的为0.661 8、0.796 8和0.933 1 m。

4　结　语

本文利用 TCN 模型进行了下荆江航道不同站点未来 1~3 d 的水位预测, 并与当前广泛应用的 LSTM 和 SVM 模型进行预测效果的对比, 分析了 TCN 模型在水位预测中的适用性和优越性, 可为船舶通行安全提供技术支撑, 主要研究结论如下:

(1)监利站、调弦口站及石首站对应的最优输入时间窗口分别为 2、2 和 3 d 时, TCN 模型能够获得下荆江各站点未来 1 d 的最佳预测效果, E_{NS} 和 R^2 均大于 0.995, E_{RMS} 基本小于 0.2 m; 但随着预测时间尺度的增大, 预测精度整体呈降低趋势。

(2)TCN 模型和 LSTM 模型的预测效果显著优于 SVM 模型, 在水位预测领域具有较好的应用潜力, TCN 模型在不同时间尺度下的预测精度整体优于 LSTM 模型。

(3)TCN 模型在枯水期的水位预测效果优于丰水期, 枯水期各站点未来 1~3 d 水位预测绝对误差大于 0.5 m 的最大天数为 13, 大部分时段水位预测的绝对误差低于 0.2 m, 可有效保证枯水期的船舶通航安全。

参　考　文　献:

[1] 交通运输部水运局. 2018年水路运输市场发展情况和2019年市场展望[J]. 中国水运, 2019(4): 10-11. (Water Transport Bureau of the Ministry of Transport of the People's Republic of China. Development of waterway transport market in 2018 and market outlook in 2019[J]. China Water Transport, 2019(4): 10-11. (in Chinese))

[2] ZHOU T, JIANG Z, LIU X, et al. Research on the long-term and short-term forecasts of navigable river's water-level fluctuation based on the adaptive multilayer perceptron[J]. Journal of Hydrology, 2020, 591(2): 125285.

[3] 杨成刚, 李思璇, 董炳江, 等. 三峡水库运用后长江中下游枯水位变化成因研究[J]. 泥沙研究, 2021, 46(5): 34-40. (YANG Chenggang, LI Sixuan, DONG Bingjiang, et al. Study on the mechanism of lower water level in middle and lower reaches of

the Yangtze River after impounding of the Three Gorges Reservoir[J]. Journal of Sediment Research, 2021, 46(5): 34-40.(in Chinese))

[4] 施勇, 栾震宇, 陈炼钢, 等. 长江中下游江湖关系演变趋势数值模拟[J]. 水科学进展, 2010, 21(6): 832-839.(SHI Yong, LUAN Zhenyu, CHEN Liangang, et al. Numerical study of the evolution trend in the river-lake relationship in the middle and lower reaches of the Yangtze River[J]. Advances in Water Science, 2010, 21(6): 832-839.(in Chinese))

[5] HU T F, MAO J Q, PAN S Q, et al. Water level management of lakes connected to regulated rivers: an integrated modeling and analytical methodology[J]. Journal of Hydrology, 2018, 562: 796-808.

[6] ZHAO G, PANG B, XU Z X, et al. A hybrid machine learning framework for real-time water level prediction in high sediment load reaches[J]. Journal of Hydrology, 2020, 581: 124422.

[7] 陈炼钢, 陈黎明, 徐祎凡, 等. 基于越冬水鸟生境模拟的拟建鄱阳湖水利枢纽生态控制水位探讨[J]. 湖泊科学, 2020, 32(5): 1519-1528.(CHEN Liangang, CHEN Liming, XU Yifan, et al. Ecological water level for proposed hydraulic construction locking Lake Poyang based upon wintering waterfowls habitat modelling[J]. Journal of Lake Sciences, 2020, 32(5): 1519-1528.(in Chinese))

[8] 戴凌全, 王煜, 汤正阳, 等. 三峡水库枯水期补水调度对洞庭湖越冬白鹤(Grus leucogeranus)摄食栖息地的影响[J]. 湖泊科学, 2022, 34(4): 1208-1218.(DAI Lingquan, WANG Yu, TANG Zhengyang, et al. Impact of water supply of the Three Gorges Reservoir on the foraging habitat of Grus leucogeranus in Lake Dongting during the dry season[J]. Journal of Lake Sciences, 2022, 34(4): 1208-1218.(in Chinese))

[9] NOURANI V, HOSSEINI BAGHANAM A, ADAMOWSKI J, et al. Applications of hybrid wavelet-Artificial Intelligence models in hydrology: a review[J]. Journal of Hydrology, 2014, 514: 358-377.

[10] MOROVATI K, NAKHAEI P, TIAN F, et al. A Machine learning framework to predict reverse flow and water level: A case study of Tonle Sap Lake[J]. Journal of Hydrology, 2021, 603: 127168.

[11] ZHANG Q, YE X C, WERNER A D, et al. An investigation of enhanced recessions in Poyang Lake: comparison of Yangtze River and local catchment impacts[J]. Journal of Hydrology, 2014, 517: 425-434.

[12] 李云良, 张奇, 李淼, 等. 基于BP神经网络的鄱阳湖水位模拟[J]. 长江流域资源与环境, 2015, 24(2): 233-240.(LI Yunliang, ZHANG Qi, LI Miao, et al. Using BP neural networks for water level simulation in Poyang Lake[J]. Resources and Environment in the Yangtze Basin, 2015, 24(2): 233-240.(in Chinese))

[13] 胡腾飞, 施勇, 毛劲乔, 等. 基于结构-参数同步优化的河湖水位模型及应用[J]. 排灌机械工程学报, 2022, 40(5): 461-466, 481.(HU Tengfei, SHI Yong, MAO Jinqiao, et al. River-lake water level model based on structure-parameter synchronized optimization and its application[J]. Journal of Drainage and Irrigation Machinery Engineering, 2022, 40(5): 461-466, 481.(in Chinese))

[14] 欧阳添, 闪锟, 周博天, 等. 基于LSTM网络的在线藻类时序数据预测研究: 以三峡水库为例[J]. 湖泊科学, 2021, 33(4): 1031-1042.(OUYANG Tian, SHAN Kun, ZHOU Botian, et al. Research on the online forecasting of algal kinetics based on time-series data and LSTM neural network: taking Three Gorges Reservoir as an example[J]. Journal of Lake Sciences, 2021, 33(4): 1031-1042.(in Chinese))

[15] 邱俊杰, 郑红, 程云辉. 基于多尺度LSTM预测模型研究[J]. 系统仿真学报, 2022, 34(7): 1593-1604.(QIU Junjie, ZHENG Hong, CHENG Yunhui. Research on prediction of model based on multi-scale LSTM[J]. Journal of System Simulation, 2022, 34(7): 1593-1604.(in Chinese))

[16] CHANG F J, CHEN P A, LU Y R, et al. Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control[J]. Journal of Hydrology, 2014, 517: 836-846.

[17] ZHU S L, HRNJICA B, PTAK M, et al. Forecasting of water level in multiple temperate lakes using machine learning models[J]. Journal of Hydrology, 2020, 585: 124819.

[18] 郭燕, 赖锡军. 基于循环神经网络的洞庭湖水位预测研究[J]. 长江流域资源与环境, 2021, 30(3): 689-698.(GUO Yan, LAI Xijun. Research on water level prediction of Dongting Lake based on recurrent neural network[J]. Resources and Environment in the Yangtze Basin, 2021, 30(3): 689-698.(in Chinese))

[19] 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))

[20] BARZEGAR R, AALAMI M T, ADAMOWSKI J. Coupling a hybrid CNN-LSTM deep learning model with a Boundary Corrected Maximal Overlap Discrete Wavelet Transform for multiscale Lake water level forecasting[J]. Journal of Hydrology, 2021, 598: 126196.

[21] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. arXiv: 1803.01271. (2018-04-18)[2022-08-06] https://arxiv.org/abs/1803.01271

[22] 严冬梅, 何雯馨, 陈智. 融合情感特征的基于RoBERTa-TCN的股价预测研究[J]. 数据分析与知识发现, 2022, 6(12): 123-133. (YAN Dong, HE Wenxin, CHEN Zhi. Research on stock price prediction based on RoBERTa-TCN with emotional characteristics[J]. Data Analysis and Knowledge Discovery, 2022, 6(12): 123-133. (in Chinese))

[23] 刘鑫, 夏军强, 邓珊珊, 等. 下荆江急弯段凸冲凹淤演变过程与机理[J]. 科学通报, 2022, 67(22): 2672-2683. (LIU Xin, XIA Junqiang, DENG Shanshan, et al. Analysis of evolution processes and mechanisms of sharp bends in the Lower Jingjiang Reach[J]. Chinese Science Bulletin, 2022, 67(22): 2672-2683. (in Chinese))

[24] 刘杰, 金勇杰, 田明. 基于VMD和TCN的多尺度短期电力负荷预测[J]. 电子科技大学学报, 2022, 51(4): 550-557. (LIU Jie, JIN Yongjie, TIAN Ming. Multi-scale short-term load forecasting based on VMD and TCN[J]. Journal of University of Electronic Science and Technology of China, 2022, 51(4): 550-557. (in Chinese))

[25] 唐贤伦, 陈洪旭, 熊德意, 等. 基于极端梯度提升和时间卷积网络的短期电力负荷预测[J]. 高电压技术, 2022, 48(8): 3059-3067. (TANG Xianlun, CHEN Hongxu, XIONG Deyi, et al. Short-term power load forecasting based on extreme gradient boosting and temporal convolutional network[J]. High Voltage Engineering, 2022, 48(8): 3059-3067. (in Chinese))

[26] 李文武, 张鹏宇, 石强, 等. 基于聚合混合模态分解和时序卷积神经网络的综合能源系统负荷修正预测[J]. 电网技术, 2022, 46(9): 3345-3357. (LI Wenwu, ZHANG Pengyu, SHI Qiang, et al. Correction prediction of integrated energy system load based on aggregated mixed mode decomposition and TCN[J]. Power System Technology, 2022, 46(9): 3345-3357. (in Chinese))

[27] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[28] BUYUKYILDIZ M, TEZEL G, YILMAZ V. Estimation of the change in lake water level by artificial intelligence methods[J]. Water Resources Management, 2014, 28(13): 4747-4763.

[29] 李伶杰, 王银堂, 胡庆芳, 等. 基于随机森林与支持向量机的水库长期径流预报[J]. 水利水运工程学报, 2020(4): 33-40. (LI Lingjie, WANG Yintang, HU Qingfang, et al. Long-term inflow forecast of reservoir based on Random Forest and support vector machine[J]. Hydro-Science and Engineering, 2020(4): 33-40. (in Chinese))

[30] LIM H, RYU H, RHUDY M B, et al. Deep learning-aided synthetic airspeed estimation of UAVs for analytical redundancy with a temporal convolutional network[J]. IEEE Robotics and Automation Letters, 2022, 7(1): 17-24.

[31] 刘丽, 裴行智, 雷雪梅. 基于时间卷积注意力网络的剩余寿命预测方法[J]. 计算机集成制造系统, 2022, 28(8): 2375-2386. (LIU Li, PEI Xingzhi, LEI Xuemei. Temporal convolutional attention network for remaining useful life estimation[J]. Computer Integrated Manufacturing Systems, 2022, 28(8): 2375-2386. (in Chinese))

[32] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: continual prediction with LSTM[J]. Neural Computation, 2000, 12(10): 2451-2471.

[33] 张成成, 陈求稳, 徐强, 等. 基于支持向量机的太湖梅梁湾叶绿素a浓度预测模型[J]. 环境科学学报, 2013, 33(10): 2856-2861. (ZHANG Chengcheng, CHEN Qiuwen, XU Qiang, et al. A chlorophyll-a prediction model for Meiliang Bay of Taihu based on Support Vector Machine[J]. Acta Scientiae Circumstantiae, 2013, 33(10): 2856-2861. (in Chinese))

Water level prediction of lower Jingjiang Waterway in Yangtze River based on temporal convolution network

LI Gang[1, 2], LI Youwei[1, 2], SHU Zhangkang[3], ZHANG Yu[3], WANG Jiang[1, 2], ZHA Wei[3]

(1. *Changjiang Waterway Survey Design and Research Institute* (*Wuhan*), *Wuhan* 430040, *China*; 2. *National Engineering Research Center for Inland Waterway Regulation*, *Wuhan* 430040, *China*; 3. *The National Key Laboratory of Water Disaster Prevention*, *Nanjing Hydraulic Research Institute*, *Nanjing* 210029, *China*)

Abstract: Accurate prediction of water level in waterway is of great significance for ensuring ships' navigational safety. The lower Jingjiang waterway in the Yangtze River was taken as the research area, and the hydrological data from 2019 to 2020 and from 2021 were adopted as the train set and test set, respectively. A temporal convolution network (TCN) model was developed for water level prediction of the Lower Jingjiang waterway. Then the long short-term memory network (LSTM) and the support vector machine (SVM) were constructed for accuracy comparing with TCN. The results showed that there were differences of optimal input time windows of TCN in different stations. Jianli station, Tiaoxiankou station and Shishou station's optimal input time windows were 2 days, 2 days and 3 days, respectively. In 2021, the Nash-Sutcliffe efficiency coefficient and determination coefficient of the water level prediction of TCN at each station in the lower Jingjiang River were higher than 0.995, and the RMSE was basically below 0.21 m. The overall performance of TCN was better than LSTM, and both of them could accurately predict the water level process and perform better than SVM. However, with the increase of prediction time scale, the prediction accuracy of water level showed a downward trend. In terms of different periods, the absolute error of TCN water level prediction in dry season was basically below 0.2 m, indicating that TCN has a great potential in the field of water level prediction. By analyzing the applicability and superiority of the TCN model, this study can provide technical support for improving the accuracy of water level prediction in the Yangtze River channel and the safe navigation of ships.

Key words: water level prediction; water level in waterway; lower Jingjiang Waterway; temporal convolutional network; long short-term memory network