

DOI:10.3876/j.issn.1000-1980.2026.04.010

感潮河网水位智能预测方法

万安¹, 林佳威¹, 袁赛瑜^{1,2}, 唐洪武^{1,3}

(1. 河海大学水灾害防御全国重点实验室; 2. 河海大学水利部水循环与水动力系统重点实验室;
3. 华南理工大学土木与交通学院)

摘要:为解决感潮河网水位受潮汐、径流、泵闸调控耦合作用呈现非线性波动,且水系地形差异致使全域统一模拟精度低、分站点建模成本与复杂度过高的问题,基于时空聚类的多尺度融合时空注意力网络(MSTANet),提出了一种面向感潮河网的智能水位预测方法。该方法通过融合多尺度时序特征与空间依赖关系,提升了模型对潮汐、泵闸调控等多扰动下水位演化过程的模拟能力;同时引入时空聚类实现流域分区建模,有效缓解了空间异质性带来的性能下降问题。上海蕴南水利控制片区的实例验证表明,该方法具有良好的模拟精度、较高的计算效率,具备工程实用性与推广前景。

关键词:感潮河网;多扰动;水位预测;聚类算法;集成模型;机器学习

Intelligent prediction method for water level in tidal river networks

Wan An¹, Lin Jiawei¹, Yuan Saiyu^{1,2}, Tang Hongwu^{1,3}

(1. State Key Laboratory of Water Disaster Prevention, Hohai University;
2. Key Laboratory of Hydrologic-Cycle and Hydrodynamic-System of Ministry of Water Resources, Hohai University;
3. School of Civil Engineering & Transportation, South China University of Technology)

Abstract: To address the problems that the water level of tidal river networks exhibits nonlinear fluctuations under the coupling effects of tides, runoff, and sluice-pump regulation, and that topographic differences of water systems result in low accuracy of holistic unified simulation and high cost and complexity of individual station modeling, an intelligent water level prediction method for tidal river networks was proposed based on a multi-scale fusion spatiotemporal attention network (MSTANet) with spatiotemporal clustering. By integrating multi-scale temporal features and spatial dependencies, this method enhanced the simulation capability for water level evolution processes under multiple disturbances, such as tides and sluice-pump regulation; meanwhile, spatiotemporal clustering was introduced to achieve watershed subdivision modeling, effectively mitigating the performance degradation caused by spatial heterogeneity. The validation in Wennan Water Control Area of Shanghai shows that this method has good simulation accuracy and computational efficiency and possesses engineering practicability and application prospects.

Key words: tidal river network; multiple disturbance; water level prediction; clustering algorithm; ensemble model; machine learning

感潮河网作为典型的陆海交互地貌单元,承载着重要的水资源与生态功能,其沿岸地区的资源富集性与区位优势造就了人口密集、经济发达的城市群^[1-2]。然而,高强度的人类活动与感潮河网特殊的水文特性相互叠加,显著加剧了该区域的洪涝灾害风险^[3-5],因此亟须建立高精度流域水位预测模型^[6],以提升区域水安全保障能力。传统水动力预测方法主要依赖曼宁公式、圣维南方程组等物理模型,具有良好的可解释性与精度,但感潮河网尺度大、边界扰动复杂^[7],参数繁多^[8],计算成本高,传统方法难以满足实时性要求。人工神经网络(ANN)^[9]、递归神经网络(RNN)^[10]及其衍生时序模型,诸如长短期记忆网络(LSTM)^[11-12]和门控循环网络(GRU)^[13],凭借复杂场景与海量数据下高效建模能力^[14-15],在水位预测领域展现出明显优势,尤其适用于河道单一站点预测。但在感潮河网复杂动力系统中的应用仍面临两方面挑战:①时间维度上,水位过程同时受天文潮、径流与人控等^[16]多扰动影响,叠加长周期^[17]与短期随机波动^[18],动态过程高度非线性,模型拟合困难;②空间维度上,不同水系间水位驱动机制差异显著,整体建模易掩盖局部特性^[19],导致模型性能在不同区域之间有很大差异^[20],而逐站建模又造成建模成本和复杂度急剧上升,制约模型实用性。

基金项目: 国家自然科学基金项目(U2340221);国家重点研发计划项目(2022YFC3202602)

作者简介: 万安(2000—),男,硕士研究生,主要从事水位预测研究。E-mail:374891682@qq.com

通信作者: 袁赛瑜(1987—),男,教授,博士,主要从事水力学及河流动力学研究。E-mail:yuansaiyu@hhu.edu.cn

本文提出面向感潮河网的流域水位预测方法。时间维度上,聚焦多扰动边界特性,构建融合长周期性与短期随机性的集成模型建模框架;空间维度上,提出基于水位响应差异的子流域划分策略,以降低建模复杂度并提升模型区域泛化能力,实现流域整体与局部最优的模型建模表现。在上海蕴南河网数字孪生系统中的应用表明,本文方法可为提升洪涝风险预警能力、水资源调度效率及水环境治理能力提供有力支撑。

1 研究方法

针对河网的空间异质性和水位变化的多尺度特征,本文融合时空聚类策略与集成学习模型提出了感潮河网的水位预测方法。该方法依托时空聚类算法完成水位时序预处理,将水文特征相近的子流域归为同类,可有效降低建模复杂度并缓解维度灾难;针对潮汐、陆域径流、泵闸调度等多重扰动驱动因子,基于耦合卷积网络、门控循环单元、残差网络与注意力机制,引入线性校正模块,多维度提升感潮河网非线性水位过程的拟合与预测性能。

1.1 水位预测流程

感潮河网水位预测流程如图 1 所示,具体步骤如下:①时空聚类。基于动态时间规整(dynamic time warping, DTW)算法^[21],分别构建各站点水位时序、全域站点分月水位数据的序列相似度距离矩阵,然后采用层次聚类算法,对水位变化趋势相近的站点时序与分月样本实现分组划分,完成时空聚类处理,同类样本表征水位演变具备一致的时空变化规律。②子流域建模。确定最佳聚类后将站点和各月的水位数据分别分类为 n 、 m 个类别($n \in \{1, 2, \dots, N\}$, $m \in \{1, 2, \dots, 12\}$, 其中 N 为总站点数),分别构建 $n \times m$ 个多尺度融合时空注意力网络(MSTANet)模型,用于预测同一聚类下各站点水位。




图 1 感潮河网水位预测流程

Fig. 1 Flowchart of water level prediction for tidal river networks

1.2 时空聚类


潮汐涨落、泵闸调度等多重驱动因子共同作用下,感潮河网各站点水位演变存在显著空间异质性,为全域水位预测带来挑战:对全部 N 个站点逐一搭建独立模型会造成模型参数量随站点数量大幅增长,极易诱发维度灾难;而采用单一全域统一模型时,不同站点水文驱动机制的差异性易造成特征混杂,大幅削弱局部区域的水位预测精度。为此,本文采用分区建模思路:先通过聚类方法划分水文特征相近的子流域,将全域河网拆解为 n ($n < N$) 个内部水文特性均质的分区,再针对各分区分别构建预测模型。子流域聚类的关键在于度量站点水位序列间的相似性,常用方法为 DTW 算法,该算法通过动态规划计算最优匹配路径,最小化序列间的累计距离,可处理序列间时间轴非线性变形,具备无需参数、时间偏移鲁棒性强等优势,可有效挖掘序列间的整体相似程度^[22]。

基于 DTW 算法的时空聚类流程如下:①初始化和空间聚类。提取各站点的水位时间序列向量合并为空间簇 $C = \{Z_1, Z_2, \dots, Z_N\}$;将全部站点水位归一化处理后逐时刻计算全域站点均值构建综合时间序列,并按月份切分成 12 个时间片段作为时间簇 $T = \{T_1, T_2, \dots, T_{12}\}$ 。②根据 DTW 算法分别计算空间与时间各簇内部各个特征的相似度距离矩阵。③根据相似度距离矩阵,合并各簇内距离最近的两个特征 (Z_i, Z_j) 、 $(T_a,$

T_b), 并生成新的特征 Z_{ij} 、 T_{ab} 。④更新相似度距离矩阵, 以反映新的特征与原始其余特征簇之间的邻近性。⑤重复步骤③, 直到只剩一个特征, 并分别记录合并过程至空间与时间聚类树。⑥输出空间站点聚类与时间各月份聚类结果, 完成空间与时间聚类。

1.3 MSTANet 模型

针对感潮河网系统的水位时序特征, MSTANet 模型的整体结构如图2所示, 模型包括处理长期部分和短期部分, 以增强模型抑制局部扰动与长期趋势学习能力。长期部分经过不同的网络模块(长期依赖提取模块 A 和局部空间特征处理模块 B)处理后, 由多头注意力机制(时空特征融合模块 C)进行特征融合, 短期部分针对突变扰动, 采用线性模型(短期线性增强模块 D)对预测值进行校正。



注: 包含完整时间窗口的多站点水位时序数据为长期数据 L , 仅取最后一个时间步长的多站点水位数据为短期数据 S ; H_{conv} 为卷积层输出; H_d 为丢弃层输出; h_t 为门控循环网络输出; $L_{(1)}$ 、 $L_{(2)}$ 、 $L_{(3)}$ 分别为第 1、2、3 层残差网络输出; y_L 为长期组件最终输出; y_S 为短期组件最终输出; Y 为模型最终输出。

图2 MSTANet 模型整体结构

Fig. 2 Overall structure of MSTANet model

1.3.1 长期依赖提取模块

在潮汐主导的长周期水动力系统中, 降水、调度等噪声干扰导致传统基于门控机制的 LSTM、GRU 记忆单元遗忘河网水位的关键趋势信息。为此, 建立基于 CNN-GRU^[23] 耦合的长期依赖提取模块, 利用卷积核的频域滤波特性消除短期高频噪声, 增强 GRU 的长期依赖学习能力, 确保天文潮汐主导的周期趋势能够稳定捕捉。

a. 将长期水位数据输入卷积层中, 过滤水位序列噪声:

$$H_{\text{conv}} = \text{ReLU}(W_{\text{conv}} * L + b_{\text{conv}}) \quad (1)$$

式中: $*$ 为卷积操作; W_{conv} 、 b_{conv} 为卷积层可学习的参数; ReLU 为激活函数。

b. 经过卷积后, 为了抑制过拟合的发生, 应用了丢弃层(Dropout), 使神经元以一定的概率 P 保留:

$$H_d = \text{Dropout}(H_{\text{conv}}, P) \quad (2)$$

式中: H_d 为丢弃层输出; P 为保留节点的概率。

c. 将数据输入门控循环单元^[24], 捕捉水位对时间的长期依赖关系。

1.3.2 局部空间特征处理模块

在高密度的感潮河网中, 邻近站点水位具有显著空间相关性, 为此设计了局部空间特征处理模块, 利用擅长处理空间信息的残差网络(ResNet)^[25], 通过残差跳跃连接增强对空间特征的感知能力, 从而提高空间信息的传递效率和模型的鲁棒性。将长期数据中周边水文站水位时序输入由多个卷积层组成的 ResNet, 学习河网水位的空间特征信息。

1.3.3 时空特征融合模块

构建集成模型时, 基于简单累加权重分配下的多模型融合无法灵活适应感潮河网水动力系统的复杂性, 为提高河网水位多尺度相关性建模能力, 建立了多头自注意力^[26]驱动的时空特征融合模块。

1.3.4 短期线性增强模块

处理长期部分的模块可以有效地提取水文序列长期趋势, 但其受记忆能力限制存在响应滞后问题, 对短

期突变的水位扰动并不敏感。因此,引入线性模型来增强捕捉短期突变的能力^[27],公式如下:

$$y_s = \text{Linear}(S)$$

(3)

2 实例验证

2.1 研究区概况和研究数据

上海蕴南水利控制片区^[24](以下简称“蕴南片”)地处长江及太湖流域下游,滨江临海,河网水系密布,属于典型的感潮河网地区。蕴南片整体上可分为3个子流域系统:桃浦河-彭越浦-虹口港、树浦港、新江湾城水系(图3)。流域水位序列在天文潮汐主导下呈周期性波动,但支流交汇和泵闸调度等短时扰动使水位在时间维度上出现多尺度频谱混叠;水位的驱动因子及波动特征在空间维度上表现出明显的异质性。




图3 研究区域概况
Fig.3 Overview map of study area

为支撑流域水位预测模型的构建与评估,收集了该流域内共计27个站点的水位数据,包括11个泵闸站点(闸内、闸外分别以小写a与大写A标识)以及5个内江水位站点,辅以吴淞口站(W)潮位数据及10个泵闸站点的开度数据(9号泵闸缺失)。数据范围覆盖2021年2月1日至2022年2月1日,时间分辨率为5 min,经缺失值处理、线性插值清洗以及滑动时间窗口构造后,共获得100369条有效数据。为了正确评估模型在每个月的精度,将每个月1—6日划分为测试集(9774条)与验证集(9768条),剩余部分划分为训练集(80827条)。

2.2 实验设置

鉴于泵闸调度多以小时为单位,为更有效支持调度决策,预测模型以过去12个步长为输入窗口,预测同一聚类内各站点未来第12个步长的水位。输入包括同聚类站点的水位序列、邻近站点的泵闸开度和潮位信息(无聚类模型则统一输入全流域控制站点数据)。模型基于Python3.8、TensorFlow 2.10和Keras框架开发,运行于Windows 11平台(CPU:AMD Ryzen5 7500F;RAM:32GB;GPU:NVIDIA RTX4070Super,12 GB)。训练采用Adam优化器、MSE损失函数,迭代60轮,批次大小为512,初始学习率为0.001。为避免超参数选择对模型性能造成干扰,使用Optuna框架基于贝叶斯优化策略在预设空间内搜索1000次以确定最优超参数配置。为验证模型与聚类策略效果,设置4个实验,其信息见表1。

表 1 时空聚类 MSTANet 模型的评估实验设置

Table 1 Evaluation experiment setup of spatiotemporal clustering MSTANet model

实验	实验目的	实验安排
实验 1	验证时空聚类方法的有效性	基于时空聚类方法,对水位序列进行时间与空间聚类,评估其在感潮河网中的适用性与合理性
实验 2	分析聚类数量对精度影响	设置不同时间(1~12 类)与空间(1~27 类)聚类数,结合不同 GRU 单元规模(8~128),评估对预测精度的影响
实验 3	评价时空聚类 MSTANet 性能	比较有无聚类的 MSTANet 模型相较于 ANN、RNN、LSTM、GRU 等经典模型的预测表现
实验 4	探析时空聚类提升性能机制	分析聚类的作用路径,可视化有无时空聚类的 MSTANet 模型在特定站点与极端水位条件下的表现

2.3 评估指标

本文采用 4 种常用的统计指标对模型预测效果进行定量评估,包括纳什效率系数(NSE)、平均绝对误差(MAE)、均方根误差(RMSE)以及对称平均绝对百分比误差(SMAPE)。NSE 用于衡量模型拟合优度,MAE 和 RMSE 反映预测误差的绝对大小,SMAPE 适用于评估相对误差,特别是在数据尺度变化较大的情况下,能够提供稳定的误差衡量。通常当 MAE、RMSE 和 SMAPE 趋于 0,NSE 趋近 1,表明模型达到了理想的拟合效果。

2.4 结果与分析

2.4.1 聚类结果分析

基于实验 1,采用基于 DTW 算法的时空聚类方法,分别对 28 个站点(为表征下游潮汐边界影响,将吴淞口水位序列作为参考序列纳入空间聚类)以及各月份水位时间序列进行聚类分析,得到空间与时间聚类结果(图 4)。通过调整聚类树的截断高度,可以获得不同层级的分类结果。例如,当截断线位于图 4(a)中黑色虚线所示位置时,将在空间上对 28 条水位序列划分为两类:A1、A2、A5、A6、A7、A8、A9、A14、A15 和 W 站点水位序列为第一类,其余序列为第二类。第一类主要由不受闸门约束、以自然涨落为主的泵闸外江水位序列组成,受潮汐影响程度远高于其他序列;从空间分布看,A9 与 A15 紧邻黄浦江,在潮汐上溯过程中较 A6、A7、A8、A14 以及 A1、A2、A5 更早受到潮汐顶托作用影响,且受影响程度更强,因此表现出相似的水位特征;进一步提高分类分辨率,第一类可继续划分为 5 个子类,分别为 W、A9、A15、A6、A7、A8、A14、A1、A2、A5,上述子类在空间位置上呈现出由下游向上游递进的分布特征,反映出潮汐扰动的沿程变化。此外,同一个泵闸站点闸内外水位序列相似距离很远,说明泵闸调度等人为扰动显著改变了内外江的水位特征。由图 4(b)可知,7 月、8 月、9 月和 10 月划分为同一类,表明汛期及汛后初期水位过程可能受到暴雨、台风、外江潮汐及泵闸调度等因素共同影响,水位特征区别于其他月份。




图 4 聚类结果

Fig.4 Clustering results

对于流域多站点水位预测,聚类数越少,同一个类内各站点的水位特征差异越大,越不利于模型捕获输入、输出间关系;但是聚类数越多,计算成本越高。例如,当空间聚类数分为 6 个类时,A15 和 A9 被进一步分为仅由一个水位站点组成的类。因此,权衡性能和计算成本,最后的聚类结果见表 2。

2.4.2 最佳时空聚类数目

为探究时空聚类数对预测精度的影响,基于实验 2,测试神经元个数(代表模型的复杂性)和时空聚类个

数的各种组合在测试集上的平均预测精度。由图 5 可知,GRU 单元个数较少(如 8 个)会导致预测的 NSE 降低,随着 GRU 单元个数增多,NSE 呈现增长的趋势,表明增加模型的复杂性可以在一定程度上提高预测精度。

表 2 时空聚类结果

Table 2 Spatiotemporal clustering results	
序号	站点/月份
空间聚类 1	a3、A4、a5、a6、a7、a8、a9、10、11、12、13、a14、a15、16
空间聚类 2	a1、a2、A3、a4
空间聚类 3	A1、A2、A5、A6、A7、A8、A14
空间聚类 4	A9、A15
时间聚类 I	1、2、3、4、5、6、11、12
时间聚类 II	7、8、9、10

由图 5(a)可知,GRU 单元个数较少(如 8~32 个)时,随着聚类个数的增多,整体上 NSE 显著提升,这是因为增加空间聚类个数可以将数据划分为更多相对简单的子集从而简化模型的学习任务,使模型能够更有效地捕捉数据中的模式和空间特征,从而提高精度。由图 5(b)可知,适当的时间聚类(如 2~4 个)能显著提升模型的 NSE;当聚类数达到 6 个及以上时,模型的 NSE 开始下降,特别是在 GRU 单元个数较少时,这种下降更明显。随着时间聚类个数增多,各聚类内样本量随之缩减,数据稀疏程度进一步加剧。同时,时间聚类会将全年时序数据切分为多组子集,易把具备相同时序特征的样本拆分至不同聚类中,破坏数据固有的季节性与周期性规律。聚类个数增多后,模型需拟合更多复杂时序模式;若 GRU 单元个数偏少,模型表征容量不足,难以充分学习与提取此类复杂时序特征。因此,综合考虑性能与计算成本,后续实验选择将 27 个站点的水位时间序列聚类为空间上 4 类和时间上 2 类。




图 5 聚类数与神经元数对 NSE 的影响

Fig. 5 Effect of cluster number and neuron number on NSE

2.4.3 模型性能对比评估

为评估时空聚类 MSTANet 模型在复杂水文条件下的预测性能,基于实验 3,得到该模型与各基准模型在测试集上的整体平均预测精度。由表 3 可知,GRU 等改进循环网络模型明显优于 RNN,表明门控机制在处理时间序列数据时具有一定的优势,避免了循环网络算法存在的长期依赖问题。整体性能排序由优至差依次为时空聚类 MSTANet、MSTANet、GRU、LSTM、RNN、ANN。时空聚类 MSTANet 在所有评价指标上均显著优于其他基准模型,NSE 突破 0.94(较基准 MSTANet 模型提高了 0.022),RMSE 降低至 0.052 m(较基准 MSTANet 相对降幅约 21%),SMAPE 与 MAE 分别较 MSTANet 基准模型减少 19.6%和 20%,验证了时空聚

表 3 各模型在测试集上的预测精度

Table 3 Prediction accuracy of each model on test set				
模型	NSE	RMSE/m	SMAPE/%	MAE/m
ANN	0.775	0.131	4.325	0.098
RNN	0.850	0.092	2.912	0.066
LSTM	0.883	0.082	2.543	0.057
GRU	0.883	0.081	2.504	0.056
MSTANet	0.925	0.066	2.001	0.045
时空聚类 MSTANet	0.947	0.052	1.609	0.036

类机制的有效性。此外,MSTANet 模型在性能上也要优于其他基准模型,尤其是 MAE 指标仅为 0.045 m,表明其相较于传统预测模型(如 ANN、LSTM、GRU 等),在感潮河网水位流域整体预测精度上具有显著优势。

由图 6 可知,内江各站点(空间聚类 1、2)的水位预测精度整体低于外江站点(空间聚类 3、4),主要是因为内江水位序列除受天文潮汐驱动外,还叠加多支流汇流、人工泵闸群调度等多重扰动因素,水文过程更为复杂,建模难度显著提升。相较于 ANN 等传统基础预测模型,MSTANet 整体预测性能更优,说明其更适配感潮河网多站点水位预报场景。引入时空聚类后的 MSTANet 在绝大多数站点上实现最优预测效果,在内江区域(即空间聚类 1)的提升效果尤为显著,例如 a9 站点的 NSE 提升超过 0.2,充分验证时空聚类机制能够有效强化模型对复杂水文演变规律的拟合能力。




图 6 各模型在测试集上不同站点的 NSE

Fig. 6 NSE of each model at different stations on test set

综上,MSTANet 模型融合潮汐扰动、邻近站点水文顶托以及泵闸调度规则等关键控制要素,使得模型在整体以及各站点的预测能力均优于传统模型。尤其是结合时空聚类策略后,进一步提升了全流域的预测准确性和稳定性,有效缓解了在进行流域整体建模时,高密度河网中不同区域站点的水位驱动因子与波动特征因地形、水系连通等因素,所带来的局部站点预测性能下降的问题^[19-20]。

2.4.4 时空聚类作用机制

实验 4 进一步分析聚类在提升流域建模精度的作用路径。图 7(a)为 MSTANet、时空聚类 MSTANet 在虹口闸内江水位(a1 站点)部分测试集(2021 年 2 月 2 日 11 时 10 分至 2021 年 2 月 3 日 18 时)的预测结果。整体来看,内江水位变化虽与外江(即吴淞口)潮位高度相关,但受泵闸调控影响,水位在周期性波动的同时也出现短时突变波动,对模型拟合能力提出较高要求。时空聚类 MSTANet 预测值与观测值趋势高度一致,明显优于 MSTANet。MSTANet 虽能跟踪整体趋势,但在波峰与波谷尤其是泵闸启闭前后局部细节上误差较大(如图 7(a)中的红色与紫色圆圈所示)。需要注意的是,在泵闸开启期间,MSTANet、时空聚类 MSTANet 均能有效预测水位走势,而在泵闸关闭期间误差较大,这是因为泵闸开启时,内江水系与外江水系连通,外江水位对内江影响增强,此时外江站点水位信息为模型提供了更具价值的输入,短暂提高了模型的性能。然而,泵闸关闭后,内江变为相对独立的系统,由于 MSTANet 仍然依赖外江站点数据作为输入,导致输入特征中包含的噪声增加,进而影响了预测精度。时空聚类可以精简输入特征,使子模型更专注于学习局部水系动




图 7 a1 站点 MSTANet、时空聚类 MSTANet 在测试集的预测结果

Fig. 7 Prediction results of MSTANet and spatiotemporal clustering MSTANet at station a1 on test set

态,提升了对调控响应的精度和适应性。

图 7(b)归一化的水位预测值与观测值散点图可以定量对比评估 MSTANet、时空聚类 MSTANet 在测试集上的预测性能,结果表明,在小于 0.25 和大于 0.75 的极端水位区间,两种模型预测值均存在一定程度的发散,但未聚类模型的偏差更加显著,说明该模型在极端条件下的预测稳定性较低。这一发散现象主要由于数据分布的不均衡,极端水位样本较少尤其在极端高水位区间(仅占 3%数据量),数据驱动模型难以充分学习极端水位过程中的关键特征及驱动因素,进而放大了模型预测的误差;同时,由于极端水位条件下流域水力特性非线性增强,水位变化对驱动因素(如潮汐、降雨、泵闸调度)更为敏感。MSTANet 采用统一的参数配置,难以精确学习局部水位对驱动因子的不同响应,因此预测误差较大。对于神经网络模型,参数总数通常用来衡量模型复杂度和表达能力^[28],但过多的参数可能导致过拟合。相对而言,经过时空聚类将流域划分为多个子流域后,聚类模型参数配置更灵活(表 4),有助于提升泛化能力,降低过拟合风险。

综上,时空聚类基于水位时间序列的相似性,优化了输入特征和模型复杂度,实现了对不同水系特征的自适应建模,显著提升了复杂和极端条件下的预测能力,尤其是在极端水位条件与人为强扰动情况下,这一特性对于感潮河网的水位预报和调控决策具有重要的应用价值。

3 结 语

本文构建的 MSTANet 模型及基于时空聚类的流域水位建模方法能够准确地预测感潮河网水位变化过程。流域水位平均纳什效率系数(NSE)达 0.947,高于传统 GRU 模型的 0.883;特别是受水闸启闭和泵站调度影响较强的典型站点,模型仍保持较高预测精度。上述结果表明,面向感潮河网水位受潮汐、径流和工程调控共同影响的特点,本文构建的多尺度时空建模框架能够有效提升复杂扰动条件下河网水位预测的精度与稳定性。

时空聚类结果表明,感潮河网内部不同区域的水位响应并非完全一致,呈现出可识别的空间分区特征。基于该特征进行分区建模,在保持流域整体建模效率的同时,缓解了统一建模造成的局部站点预测性能下降问题,也避免了逐站建模带来的高计算成本与模型冗余。本文方法在上海蕴南水利控制片河网水位预报中得到成功应用,表明其具备一定的工程适用性。后续研究可进一步从多源数据融合、自适应聚类优化、物理约束融合、极端水位建模与提升计算效率等方面拓展方法的实用性与智能化水平。

参考文献:

[1] Savenije H H G. Prediction in ungauged estuaries: an integrated theory[J]. Water Resources Research, 2015, 51(4): 2464-2476.

[2] Tao Hai, Al-Bedry N K, Khedher K M, et al. River water level prediction in coastal catchment using hybridized relevance vector machine model with improved grasshopper optimization[J]. Journal of Hydrology, 2021, 598: 126477.

[3] Talke S A, Jay D A. Changing tides: the role of natural and anthropogenic factors[J]. Annual Review of Marine Science, 2020, 12(1): 121-151.

[4] Luo Xiaoya, Zhang Wei, Chen Shijia, et al. Evolution of reversal of the lowest low waters in a tidal river network[J]. Journal of Hydrology, 2020, 585: 124701.

[5] 刘丁蓉, 杨凯, 孙仕. 珠三角城市群内涝灾害韧性综合评估及障碍因子识别[J]. 水利经济, 2024, 42(4): 23-29. (Liu Dingrong, Yang Kai, Sun Shi. Comprehensive assessment and obstacle factor recognition of waterlogging disaster resilience in Pearl River Delta urban agglomeration[J]. Journal of Economics of Water Resources, 2024, 42(4): 23-29. (in Chinese))

[6] 袁赛瑜, 陈逸鸿, 罗霄, 等. 知识数据双驱动的感潮河网水力智能模拟方法[J]. 水科学进展, 2025, 36(1): 28-38. (Yuan Saiyu, Chen Yihong, Luo Xiao, et al. Knowledge-and data-driven intelligent simulation method for tidal river network hydrodynamics[J]. Advances in Water Science, 2025, 36(1): 28-38. (in Chinese))

[7] Zhang Wei,Feng Haochuan,Hoitink A J F,et al. Tidal impacts on the subtidal flow division at the main bifurcation in the Yangtze River Delta[J]. Estuarine, Coastal and Shelf Science,2017,196:301-314.

[8] Devia G K,Ganasri B P,Dwarakish G S. A review on hydrological models[J]. Aquatic Procedia,2015,4:1001-1007.

[9] Mihel A M,Lerga J,Krvavica N. Estimating water levels and discharges in tidal rivers and estuaries;review of machine learning approaches[J]. Environmental Modelling & Software,2024,176:106033.

[10] Bowes B D,Sadler J M,Morsy M M,et al. Forecasting groundwater table in a flood prone coastal city with long short-term memory and recurrent neural networks[J]. Water,2019,11(5):1098.

[11] 梁晨. 基于长短时记忆网络的洞庭湖水位预测以及三峡工程对洞庭湖水位的影响研究[D]. 武汉:武汉大学,2019.

[12] 郭明辰,张润润,闻余华. 基于 PSO-LSTM 模型的平原河网汛期水位预测[J]. 水利水电科技进展,2024,44(6):64-70. (Guo Mingchen, Zhang Runrun, Wen Yuhua. Prediction of water level of plain river network during flood season based on PSO-LSTM model[J]. Advances in Science and Technology of Water Resources,2024,44(6):64-70. (in Chinese))

[13] Pan Mingyang,Zhou Hainan,Cao Jiayi,et al. Water level prediction model based on GRU and CNN[J]. IEEE Access,2020,8:60090-60100.

[14] Luo Xiao,Yuan Saiyu,Tang Hongwu,et al. Enhanced physics-informed neural networks for efficient modelling of hydrodynamics in river networks[J]. Hydrological Processes,2024,38(4):e15143.

[15] 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.

[16] 朱晓琳,李一平,许益新,等. 时间尺度对平原感潮河网水动力水质模拟精度的影响[J]. 水资源保护,2020,36(3):67-75. (Zhu Xiaolin,Li Yiping,Xu Yixin,et al. Effects of time scale on simulation accuracy of hydrodynamic water quality of plain tidal river network[J]. Water Resources Protection,2020,36(3):67-75. (in Chinese))

[17] Pawlowicz R,Beardsley B,Lentz S. Classical tidal harmonic analysis including error estimates in MATLAB using T_TIDE[J]. Computers & Geosciences,2002,28(8):929-937.

[18] 张小琴,包为民. 感潮河段水位预报方法浅析[J]. 水电能源科学,2009,27(3):8-10. (Zhang Xiaoqin,Bao Weimin. Brief review on water level forecasting for tidal river[J]. Water Resources and Power,2009,27(3):8-10. (in Chinese))

[19] Kratzert F,Klotz D,Shalev G,et al. Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets[J]. Hydrology and Earth System Sciences,2019,23(12):5089-5110.

[20] Beven K. Deep learning,hydrological processes and the uniqueness of place[J]. Hydrological Processes,2020,34(16):3608-3613.

[21] Salvador S,Chan P. Toward accurate dynamic time warping in linear time and space[J]. Intelligent Data Analysis,2007,11(5):561-580.

[22] Izakian H,Pedrycz W,Jamal I. Fuzzy clustering of time series data using dynamic time warping distance[J]. Engineering Applications of Artificial Intelligence,2015,39:235-244.

[23] Kashem A,Das P,Hasan M M,et al. Hybrid deep learning models for multi-ahead river water level forecasting[J]. Earth Science Informatics,2024,17(4):3021-3037.

[24] 闫毓,袁赛瑜,唐洪武,等. 上海蕴南水利控制片河网水动力再造[J]. 河海大学学报(自然科学版),2021,49(4):329-334. (Yan Yu,Yuan Saiyu,Tang Hongwu,et al. Hydrodynamic reconstruction of Wennan river network in Shanghai City[J]. Journal of Hohai University (Natural Sciences),2021,49(4):329-334. (in Chinese))

[25] 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,2016:770-778.

[26] Vaswani A,Shazeer N,Parmar N,et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach:Curran Associates Inc.,2017:6000-6010.

[27] Chen Yongping,Gan Min,Pan Shunqi,et al. Application of auto-regressive (AR) analysis to improve short-term prediction of water levels in the Yangtze estuary[J]. Journal of Hydrology,2020,590:125386.

[28] Moosavi V,Gheisoori Fard Z,Vafakhah M. Which one is more important in daily runoff forecasting using data driven models;input data,model type,preprocessing or data length? [J]. Journal of Hydrology,2022,606:127429.