http://www.renminzhujiang.cn 人民珠江
DOI:10.3969/j.issn.1001-9235.XXXX.XX.001 PEARL RIVER

秦礼晶,陈柱锋,刘悦忆等.基于傅里叶时间特征增强GRU的感潮河网多站点流量预测方法[J].人民珠江,DOI:10.3969/j.issn.1001-9235.XXXX.XX.001.

基于傅里叶时间特征增强GRU的感潮河网多站点流量预测方法

秦礼晶[1],陈柱锋[2],刘悦忆[3],邹晓波[4]

(1.广东省水文局惠州水文分局,广东 惠州 516000;2.东莞市运河治理中心,广东 东莞 523000;3.东莞理工学院生态环境与建筑工程学院,广东 东莞 523008;4.东莞市水务局,广东 东莞 523000)

摘 要:针对潮汐控制型河网流量过程同时具有显著周期性与非平稳性的特点,以感潮河网为研究对象,提出了一种基于傅里叶时间特征增强的门控循环单元(GRU)多站点流量预测方法。首先,基于水文工程中心河流分析系统(HEC-RAS)构建一维水动力模型,生成连续且具有物理一致性的多站点流量数据;在此基础上,引入滑动时间窗口构建多站点时序样本,并通过傅里叶变换对时间信息进行周期编码,将其与原始流量数据融合构建模型输入;随后,利用GRU网络实现多站点联合建模与多步预测。结果表明:相比传统自回归积分滑动平均模型(ARIMA)模型,GRU模型显著提升预测性能(NSE由-0.002提升至0.77);进一步引入傅里叶时间特征后,模型性能稳定提升(NSE提升至0.78),表明显式周期建模能够增强模型对潮汐驱动过程的刻画能力。机理分析表明,模型性能在不同流量区间呈现显著差异:低流量区间预测精度较高且稳定,中等流量区间存在动态范围压缩现象,高流量区间存在系统性低估与误差扩散问题;傅里叶特征在稳定工况与高流量阶段具有正向作用,在过渡区间效果相对有限。此外,输入时长与预测步长对模型性能具有显著影响,短时预测(3~6 h)表现最优。研究结果表明,所提出方法在潮汐河网流量预测中具有良好的适用性,并为周期性与非平稳特征协同建模提供了参考。

关键词:潮汐河网;流量预测;GRU;傅里叶时间特征;多站点建模;HEC-RAS

中图分类号: **文献标识码**: **文章编号**:1001-9235(XXXX)XX-0001-10

东江下游河网受上游径流与海洋潮汐共同作用,流量过程具有显著的周期性、非线性和非平稳性[1-5]。潮汐波在复杂河网中的传播与反射进一步增强了不同河段之间的时空耦合,并可能引起局部流向反转[6-12]。因此,准确预测感潮河网流量对于防洪排涝、水资源调度及河网管理具有重要意义。

传统水动力学模型虽能够描述整个物理过程,但通常依赖大量参数设定与边界条件,计算成本较高且难以满足实时预测需求[13-14]。近年来,基于数据驱动的深度学习方法在流量预测中取得了一定进展,例如循环神经网络(RNN)及其变体(如门控循环单元GRU、长短期记忆模型LSTM)能够有效捕捉时间序列中的非线性依赖关系[15-16]。然而,这类方法通常依赖模型对时间特征的隐式学习,难以稳定刻画潮汐驱动下的周期性变化规律,从而限制了其在潮汐河段中的预测性能。

针对上述问题,近年来逐渐出现将物理模型与数据驱动方法相结合的研究思路,即通过水动力模型生成连续且具有物理一致性的模拟数据,再利用深度学习模型进行高效预测,从而兼顾物理可解释性与计算效率[17]。在潮汐影响显著的河网区域,该类方法能够在一定程度上缓解观测数据不足的问题,同时为数据驱动模型提供更加稳定的训练基础。然而,仅依赖传统深度学习结构仍难以充分刻画潮汐过程中的周期性特征,特别是在多站点联合预测与多步预测场景下,模型对周期信息的表达能力仍存在不足。

为此,以东江下游感潮河网为研究对象,针对

收稿日期:2026-07-14 **修回日期**:2026-09-20

潮汐驱动下流量序列显著的周期性特征，提出一种基于GRU的多站点流量预测方法，并通过引入傅里叶时间特征对时间序列中的周期信息进行显式编码，实现对不同断面流量变化的协同建模，提高整体预测的稳定性与一致性。

1 研究方法

1.1 问题定义

针对感潮河网多站点流量预测问题，设研究区域内共有N个监测站点，在时间步t时刻各站点流量可表示为：

$$x_t \in R^N \tag{1}$$

式中：$\boldsymbol{x}_t$为时间步t时研究区域内所有监测站点的流量状态向量；R^N为N维实数空间；N为研究区域内监测站点数量。

给定过去L个时间步的历史流量序列：

$$[x_{t-L+1}, x_{t-L+2}, \cdots x_t] \tag{2}$$

式中：L为历史输入时间窗口长度，即模型利用过去L个时间步的流量信息进行预测；x_{t-L+1}和x_t分别为输入窗口起始时刻和当前时刻的多站点流量状态。

目标是预测未来H个时间步的流量变化：

$$[x_{t+1}, x_{t+2}, \cdots x_{t+H}] \tag{3}$$

式中：H为预测时间长度，即模型需要预测未来的时间步数；x_{t+1}至x_{t+H}表示未来各预测时刻所有监测站点的流量状态。

1.2 方法总体框架

本文采用“水动力模拟-数据驱动预测”的两阶段建模框架。首先，利用HEC-RAS模拟上游径流与下游潮位共同作用下的多站点连续流量过程；随后，对模拟数据进行时间对齐、缺失值处理和标准化，并通过滑动时间窗口构建训练样本。在此基础上，将傅里叶时间特征与流量序列融合输入GRU，实现多站点、多步流量预测。

1.3 时间特征构建（傅里叶时间特征）

针对潮汐河段流量序列中显著的周期性特征，本文引入基于时间戳的傅里叶时间特征对周期信息进行显式建模。具体而言，将时间序列中的小时信息归一化为：

$$\mathrm{h} = \frac{hour}{24} \tag{4}$$

式中：hour表示当前时间步对应的小时数（0~23）；h为归一化后的小时变量，用于将离散时间信息转换为连续周期变量。并构建如下周期特征：

日周期（24 h）：

$$sin(2\pi \mathrm{h}),\ cos(2\pi \mathrm{h}) \tag{5}$$

式中：$sin(2\pi \mathrm{h})$和$sin(2\pi \mathrm{h})$分别为正弦和余弦周期映射函数，用于编码24 h日周期变化。

半日周期（12 h）：

$$sin(4\pi \mathrm{h}), cos(4\pi \mathrm{h}) \tag{6}$$

其中，4πh对应12 h周期编码，用于描述潮汐河段中典型半日潮周期变化。最终，在每个时间步引入4维时间特征：

$$t_t \in R^4 \tag{7}$$

式中：$\boldsymbol{t}_t$表示时间步t对应的傅里叶时间特征向量，由日周期和半日周期对应的4个正余弦特征组成；R^4表示4维实数空间。并与原始流量数据拼接，形成增强输入：

$$\widetilde{x_t} = [x_t, t_t] \in R^{N+4} \tag{8}$$

式中：$\widetilde{\boldsymbol{x}_t}$为融合流量信息和周期时间信息后的增强输入向量；$[x_t, t_t]$为2个特征向量的拼接操作；$N$+4表示融合后的输入维度。

该方法能够将离散时间信息映射为连续周期信号，从而提高模型对潮汐周期变化的表达能力。

1.4 GRU多站点预测模型

本文采用门控循环单元（GRU）作为核心时序建模。GRU通过门控机制能够有效捕捉时间序列中的长短期依赖关系，适用于复杂水文过程建模。

模型结构如下：首先，将输入序列X输入GRU网络，得到每个时间步的隐藏状态；随后提取最后一个时间步的隐藏状态作为全局特征表示：

$$h = \mathrm{h}_L \tag{9}$$

式中：h表示GRU网络最终时间步输出的隐藏状态，用于表征历史输入序列中的综合时序特征；h_L表示第L个时间步对应的隐藏状态。

然后通过全连接层将其映射为未来多步预测结果：

$$\hat{Y} = Linear(\mathrm{h}) \tag{10}$$

式中：Yˆ为模型预测得到的未来流量序列；Linear(·)为全连接映射层，用于将GRU提取的高维隐藏特征转换为目标预测空间。并重构为：

$$\hat{Y} \in R^{H \times N} \tag{11}$$

式中：$R^{H \times N}$为预测结果矩阵的维度；H表示未来预测时间步数；N表示预测站点数量，即每个预测时刻包含所有站点的流量预测结果。

该结构实现了多站点联合建模与多步预测的统一框架。

1.5 模型训练与优化

在模型训练过程中，采用均方误差（Mean Squared Error，MSE）作为损失函数：

$$L = \frac{1}{HN}\sum(\hat{Y} - Y)^2 \tag{12}$$

式中：L为模型训练损失；H为预测时间步数量；N为预测站点数量；$\hat{Y}$为模型预测的流量值；Y为对应时刻和站点的真实流量值

优化器采用Adam算法进行参数更新。为避免数据泄露，标准化参数（均值与方差）仅基于训练集计算，并应用于测试集数据。

为避免随机划分造成时间信息泄露，本文按照时间顺序划分训练集和测试集，其中前80%的时间序列用于模型训练，后20%的时间序列用于独立测试。

1.6 评价指标

为全面评估模型性能，本文采用多种评价指标，包括均方根误差（RMSE）、平均绝对误差（MAE）、纳什效率系数（NSE）和Kling-Gupta效率系数（KGE）等。

2 研究结果

2.1 研究区域

东江下游位于珠江三角洲，是典型的感潮河网区域（图1）。河网受上游径流与珠江口潮汐共同作用，具有明显的双向流动和周期性变化特征。频谱分析表明，典型站点流量存在约12.42 h的主周期，同时在24 h附近存在明显周期峰值，反映出半日潮和日周期共同作用。受潮汐顶托影响，部分河段涨潮期间还可能出现流向反转，体现出复杂的河网水动力特征。

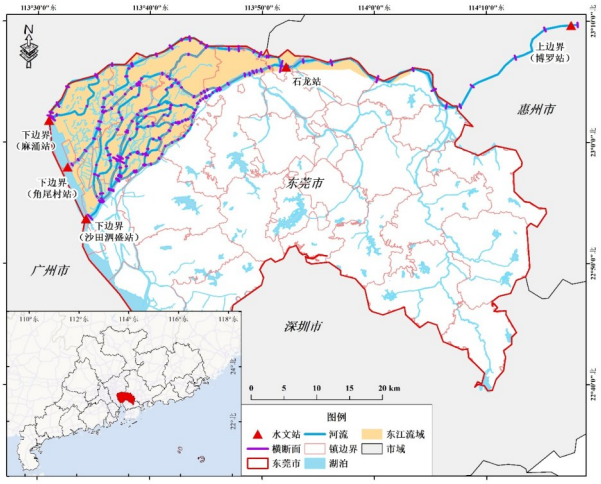


图1 研究范围

Fig. 1 Study area

2.2 HEC-RAS模型

为获取连续且具有物理一致性的多站点流量数据，本文基于HEC-RAS构建东江下游感潮河网一维水动力模型。模型上边界设置于博罗水文站，采用《珠江流域水文资料》中2023年4月5日至10月5日的逐日平均流量；下边界设置于河网下游4个入海口，采用国家海洋局南海预报中心广东省海洋预报台同期小时潮位数据；河道断面采用实测资料。模型计算时间步长为1 h。

采用石龙水文站实测水位对模型进行率定和验证，其中2023年7月1—18日为率定期，8月1—18日为验证期。率定期和验证期R^2分别为0.87和0.63（图2），模拟水位与实测水位总体变化趋势一致，表明模型能够较好地描述研究区域水动力过程，可为后续多站点流量预测提供数据基础。

率定与验证结果表明，HEC-RAS模型能够较好地模拟研究区域水位变化，模拟值与实测值总体趋势一致。率定期和验证期R^2分别为0.87和0.63（图2）。尽管水位快速变化阶段存在一定滞后或低估，但模型总体能够捕捉潮汐作用下的周期性变化特征，可满足后续流量预测建模的数据需求。

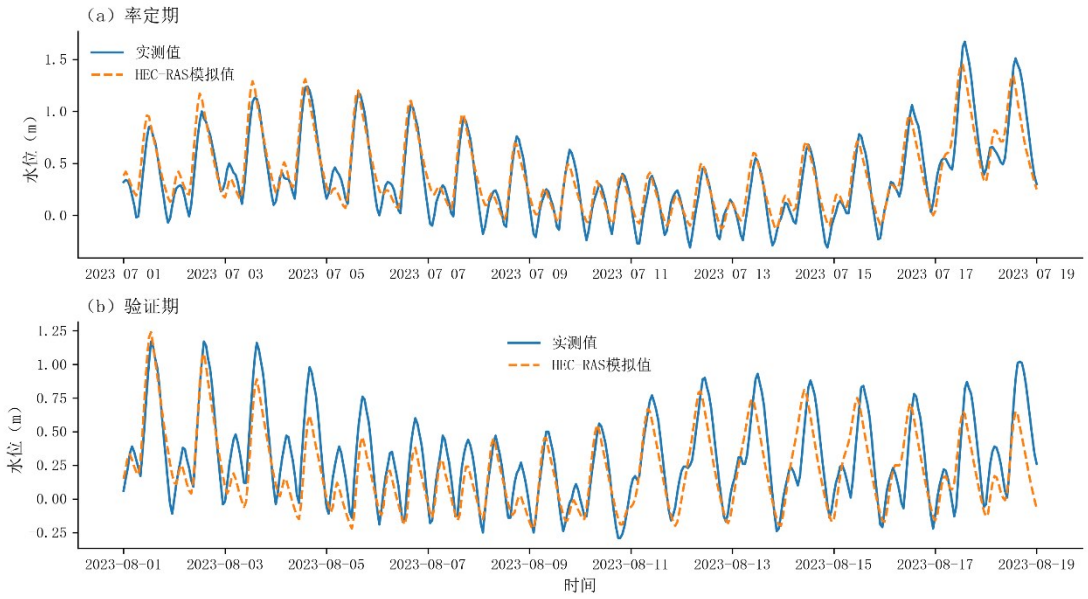


图2　石龙水文站率定期与验证期水位过程对比

Fig. 2 Comparison of observed and simulated water levels at Shilong Hydrological Station during the calibration and validation periods

2.3　基于傅里叶时间特征的模型性能提升分析

模型性能评价首先分别计算各站点预测结果的RMSE、MAE和NSE指标，随后对所有预测站点的指标结果进行平均，以获得模型整体预测性能。在具体实验中，本文采用固定时间窗口构建预测样本，即利用连续24 h的历史流量序列作为输入，预测未来3 h的多站点流量变化。表1展示了ARIMA、GRU以及引入傅里叶时间特征的GRU模型在流量预测任务中的性能对比结果。

表1　不同模型在测试集上的预测性能指标对比（RMSE、MAE、NSE）

Tab. 1 Comparison of prediction performance of different models on the test set

模型	RMSE(m^3/s)	MAE(m^3/s)	NSE
ARIMA	514.23	166.49	0.00
GRU	242.32	103.74	0.77
GRU + Fourier	240.68	101.88	0.78

从整体表现来看，深度学习模型明显优于传统统计模型。ARIMA模型的NSE为0.00，接近甚至低于基准均值预测水平，表明其在该复杂水动力过程中的建模能力较弱，难以有效刻画流量的非线性变化特征。相比之下，GRU模型能够显著提升预测精度，其RMSE和MAE分别降低至242.32和103.74，NSE提升至0.77，说明基于循环神经网络的模型能够较好地捕捉时间序列中的动态依赖关系，在流量预测中具有较强的适用性。

在此基础上，引入傅里叶时间特征后，模型性能进一步得到提升。GRU + Fourier模型的RMSE和MAE分别下降至240.68和101.88，NSE提升至0.78，表明显式引入周期性时间信息有助于增强模型对流量周期变化的刻画能力，尤其是在潮汐驱动或周期性显著的水文系统中具有积极作用。

需要指出的是，尽管傅里叶特征带来的性能提升幅度相对有限，但其改进是稳定且一致的，说明周期性信息在模型中起到了补充作用。然而，从整体指标来看，模型在极端流量及快速变化阶段仍存在一定误差，这也为后续模型优化提供了方向。

2.4　各站点预测性能分布特征

进一步对235个站点的NSE指标进行统计分

析，结果如表2所示。各站点NSE的中位数为0.605，25%和75%分位数分别为0.319和0.782，表明不同站点之间的预测性能存在一定差异。其中，145个站点的NSE不低于0.5，占总站点数的61.7%；88个站点的NSE不低于0.7，占37.4%。同时，部分站点的NSE低于0.5，说明模型在局部水动力条件较为复杂的站点仍存在一定局限。因此，本文采用整体评价指标与站点指标分布统计相结合的方式评价多站点预测性能，以避免仅采用单一整体指标可能掩盖站点间性能差异的问题。

2.5 总体预测效果分析

为评估所提出模型在典型预测设置下的整体性能，选取输入时长为24 h、预测步长为3 h的情形作为代表，对模型预测结果进行分析，见图3。图中横轴为真实流量、纵轴为预测流量，并叠加样本密度分布，用于直观展示模型在不同流量区间的预测精度。对于预测步长分别为1、2、3 h，其决定系数R^2依次为0.87、0.83和0.77，说明预测结果与真实值之间具有较强的相关性，整体预测性能较为稳定。

表2 235个站点NSE指标分布统计

Tab. 2 Statistical distribution of NSE across 235 stations

统计指标	25%分位数	中位数	75%分位数	NSE≥0.5的站点
统计结果	0.319	0.605	0.782	145(61.7%)

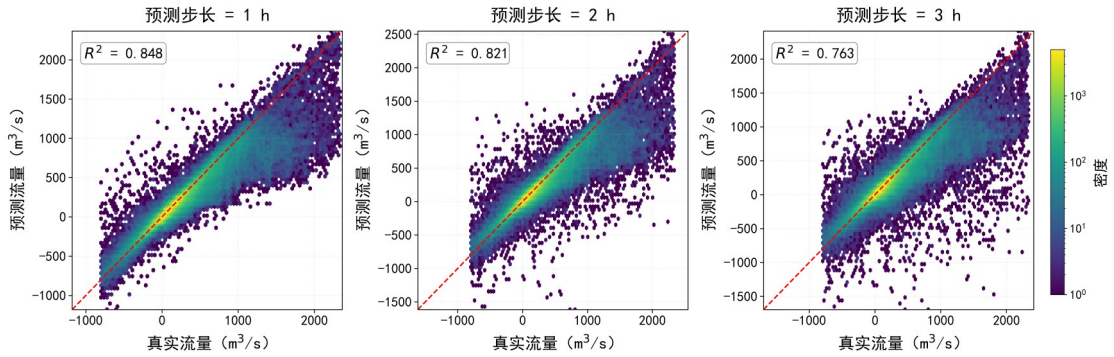


图3 GRU+傅里叶特征预测值与真实值的散点分布(预测步长1~3 h)

Fig. 3 Scatter density plots of observed and predicted discharge using GRU with Fourier features at forecast horizons of 1~3 h

3 讨论

3.1 傅里叶时间特征对潮汐周期信息表达能力的影响

相比传统GRU，引入傅里叶时间特征后RMSE、MAE和NSE均有所改善(表1)，表明显式周期编码能够增强模型对潮汐周期过程的表达能力。传统GRU需要从流量序列中隐式学习周期结构，而傅里叶特征通过正弦—余弦编码显式提供日周期和半日周期信息，有助于模型识别潮汐变化的周期与相位特征[18]。但由于流量同时受上游径流和局部非平稳扰动影响，其总体提升幅度相对有限。当前性能提升幅度相对有限，主要原因在于潮汐河网流量不仅受周期性因素控制，还受到上游来水波动、局部扰动以及非平稳过程的影响。这些非周期性成分仍主要依赖GRU进行建模，因此傅里叶特征的改进效果在整体指标上呈现为渐进式提升。未来可通过结合非平稳特征建模或引入物理约束机制，进一步释放周期建模方法的潜力。

图4展示了不同流量区间下2种模型的预测性能对比结果。从整体上看，模型性能在不同流量范围内呈现出显著差异，表明流量水平对预测精度具有重要影响。在低流量区间，两种模型均表现出较高的预测精度，其中GRU+傅里叶模型在NSE指标上略优于GRU(0.86 vs 0.84)，同时在RMSE和MAE上也略有降低，说明显式周期特征能够在稳定工况下进一步提升预测精度。在中等流量区间，GRU模

型在NSE指标上表现更优(0.54 vs 0.49),而GRU+傅里叶模型的RMSE和MAE略有增加,表明在流量变化较为复杂的过渡区间,引入固定周期特征可能在一定程度上削弱模型对非平稳动态的适应能力。

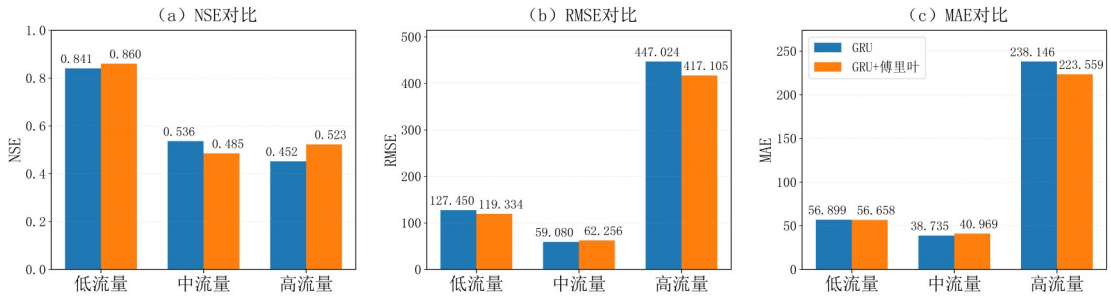


图4 不同流量区间下模型预测性能对比

Fig. 4 Comparison of model prediction performance across different discharge ranges

在高流量区间,2种模型的性能均显著下降,反映出极端流量条件下预测难度明显增加。然而,相较于GRU模型,GRU+傅里叶模型在NSE指标上表现更优(0.52 vs 0.45),同时RMSE和MAE显著降低(RMSE由447.02降低至417.11,MAE由238.15降低至223.56),说明傅里叶特征在高流量阶段有助于改善模型对流量变化幅度的刻画能力。这一结果表明,尽管傅里叶特征在中等流量区间存在一定负面影响,但在极值阶段能够有效缓解振幅压缩问题,提高模型对高流量过程的响应能力。

3.2 输入时间长度对预测性能的影响

为分析输入时间窗口长度对模型预测性能的影响,本文分别选取6、12、24、48 h作为输入时长进行对比实验,其结果见表3。

表3 不同输入时长下模型预测性能对比

Tab. 3 Comparison of model prediction performance under different input lengths

输入长度/h	RMSE/($m^3 \cdot s^{-1}$)	MAE/($m^3 \cdot s^{-1}$)	NSE	KGE
6	239.08	99.68	0.788	0.64
12	240.34	100.58	0.78	0.63
24	241.70	101.67	0.78	0.62
48	244.58	105.77	0.77	0.60

随着输入时长由6 h增加至48 h,模型性能总体呈下降趋势(表3)。6 h输入条件下性能最佳,RMSE、MAE、NSE和KGE分别为239.08 m^3/s、99.68 m^3/s、0.788和0.64;当输入时长增加至48 h时,各项指标均有所下降。

这一结果表明,感潮河网短期流量预测主要依赖近期状态及潮汐周期信息。6–12 h的历史序列已包含较强的近期水动力信息,而过长窗口可能引入更多上游来流波动和非平稳扰动,增加特征提取难度。因此,在当前模型配置下,较短输入窗口更适合短期预测。

3.3 不同预测步长对模型性能的影响

为分析预测步长对模型性能的影响,在固定输入时长为24 h的条件下,分别选取预测步长为3、6、12、24 h进行对比实验,其结果见表4。

表4 不同预测步长下模型预测性能对比(输入时长为24 h)

Tab. 4 Comparison of model prediction performance at different forecast horizons (input length = 24 h)

预测步长	RMSE/($m^3 \cdot s^{-1}$)	MAE/($m^3 \cdot s^{-1}$)	NSE	KGE
3	239.97	100.97	0.78	0.62
6	264.64	118.60	0.73	0.59
12	281.02	131.79	0.70	0.55
24	287.40	135.58	0.69	0.53

随着预测步长由3 h增加至24 h,模型性能持续下降(表4)。RMSE由239.97 m^3/s增至287.40 m^3/s,NSE由0.78降至0.69,KGE由0.62降至0.53,表

明预测时效增加会明显降低模型精度。

这是由于随着预测时效延长，流量状态与当前观测之间的相关性逐渐减弱，而潮汐、径流及局部扰动共同作用带来的不确定性不断增加，使模型更难同时准确刻画周期结构和非周期变化。因此，当前模型更适用于3~6 h的短时流量预测。

3.4 流量振幅刻画能力分析及模型局限

为定量评估模型对流量振幅变化的刻画能力，本文采用标准差作为振幅表征指标，对不同模型的预测结果进行统计分析。表5表明，GRU预测序列的标准差为370.29 m^3/s，仅为真实序列的0.72，存在明显的振幅压缩。引入傅里叶时间特征后，标准差提高至379.26 m^3/s，比例增至0.74，说明周期编码能够一定程度改善流量波动幅度的刻画。然而，固定周期特征难以充分描述上游径流及复杂边界条件引起的非平稳扰动，因此仍未完全消除振幅压缩。

表5 振幅统计指标对比

Tab. 5 Comparison of discharge amplitude statistics

模型	标准差/($m^3 \cdot s^{-1}$)	标准差比值(预测/真实)
真实值	513.98	1.00
GRU	370.29	0.72
GRU+傅里叶特征	379.26	0.74

这主要是由于感潮河网流量变化不仅受到周期性潮汐作用影响，同时还受到上游径流输入、河网调蓄作用以及复杂边界条件变化的共同影响。对于具有强非平稳特征或突发变化的流量过程，仅依靠固定周期函数进行时间编码仍存在一定局限。因此，未来研究可进一步结合动态水动力特征、物理约束机制以及自适应时间编码方法[19-22]，提高模型对复杂水文过程的刻画能力。

4 结论

本文以感潮河网为研究对象，构建了“水动力模拟 + 数据驱动预测”的两阶段建模框架，并提出了一种基于傅里叶时间特征增强的GRU多站点流量预测方法。研究结果表明。

a)相比传统统计模型，GRU能够有效捕捉流量序列中的非线性时序依赖关系，而引入傅里叶时间特征后，模型在RMSE、MAE及NSE等指标上均得到稳定提升，说明显式周期建模能够增强模型对潮汐驱动过程的表达能力；

b)模型在不同流量区间表现出明显差异：低流量区间预测精度较高且稳定，中等流量区间存在动态范围压缩问题，高流量区间则表现为系统性低估与误差扩散；傅里叶特征在稳定工况与极值阶段具有正向作用，但在过渡区间对非平稳扰动的刻画能力仍有限；

c)输入时长与预测步长对模型性能具有显著影响，较短输入窗口(6~12 h)与短时预测(3~6 h)表现更优，说明潮汐主导型河网流量预测更依赖近期信息与周期性特征；

d)振幅分析表明，GRU模型存在明显的动态范围压缩现象，而傅里叶时间特征能够在一定程度上缓解该问题，使预测结果在波动幅度上更接近真实序列。

综上，所提出方法在多数潮汐河网站点流量预测中表现出较好的预测能力，能够有效刻画整体流量变化趋势，但对于受强潮汐作用和局部复杂水动力影响的站点，预测性能仍存在提升空间。未来可通过引入变化率特征、极值增强策略及物理约束机制，并结合多源观测数据，进一步提升模型在复杂水动力条件下的预测精度与泛化能力。

参考文献：

[1] 陆佳玉，葛建忠，丁平兴. 潮控型分汊河口分流过程探讨：以长江北支口为例[J]. 华东师范大学学报(自然科学版)，2020(3)：1-12.

Lu Jiayu, Ge Jianzhong, Ding Pingxing. Study on the diversion process of a tide-controlled bifurcated estuary: A case study of the North Branch of the Yangtze Estuary[J]. Journal of East China Normal University (Natural Science), 2020 (3): 1-12. (in Chinese)

[2] 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.

[3] Hoitink A J F, Jay D A. Tidal river dynamics: implications for deltas [J]. Reviews of Geophysics, 2016,54(1):240-272.

[4] Song Chao, Shao Quanxi, Chen Xiaohong, et al. Evaluating and understanding tide-river interactions based on both physical models and data analysis [J]. Journal of Hydrology, 2024, 632: 130765.

[5] Cai Hao, Savenije H H G, Toffolon M. Linking the river to the estuary: influence of river discharge on tidal damping [J]. Hydrology and Earth System Sciences, 2014,18(1):287-304.

[6] Pareja-Roman L F, Orton P M, Talke S A. Effect of estuary urbanization on tidal dynamics and high tide flooding in a coastal lagoon [J]. Journal of Geophysical Research: Oceans, 2023, 128:e2022JC018777.

[7] Cao Yu, Zhang Wei, Zhu Yuliang, et al. Impact of trends in river discharge and ocean tides on water level dynamics in the Pearl River Delta [J]. Coastal Engineering, 2020,157:103634.

[8] 陈志高,吴子豪,班亚,等. 基于调和分析及VMD-BP神经网络的感潮河段流量预报[J]. 武汉大学学报(信息科学版), 2023,48(8):1389-1397.

Chen Zhigao, Wu Zihao, Ban Ya, et al. Discharge forecasting for tidal river reaches based on harmonic analysis and VMD-BP neural network[J]. Geomatics and Information Science of Wuhan University, 2023, 48(8): 1389-1397. (in Chinese)

[9] 郑航,刘悦忆,赵建世,等. 极端干旱下河口咸潮上溯对径流过程的响应(Ⅰ):特征与规律[J]. 水利水电技术(中英文),2022, 53(10):121-131.

Zheng Hang, Liu Yueyi, Zhao Jianshi, et al. Response of estuarine saltwater intrusion to runoff processes under extreme drought (I): Characteristics and patterns [J]. Water Resources and Hydropower Engineering, 2022, 53 (10): 121-131. (in Chinese)

[10] 刘悦忆,郑航,赵建世,等. 极端干旱下河口咸潮上溯对径流过程的响应(Ⅱ):深度学习预测[J]. 水利水电技术(中英文), 2022,53(10):132-143.

Liu Yueyi, Zheng Hang, Zhao Jianshi, et al. Response of estuarine saltwater intrusion to runoff processes under extreme drought (II): Deep learning prediction[J]. Water Resources and Hydropower Engineering, 2022, 53(10): 132-143. (in Chinese)

[11] 刘修恒,左翔,马剑波,等. 基于机理与数据联合驱动的感潮河段潮位预报模型研究[J]. 中国农村水利水电,2025,(11): 6-12.

Liu Xiuheng, Zuo Xiang, Ma Jianbo, et al. Research on a Tide Level Forecasting Model for Tidal River Sections Driven by Mechanism and Data Integration [J]. China Rural Water and Hydropower , 2025, (11): 6-12. (in Chinese)

[12] Godin G. The propagation of tides up rivers with special considerations on the upper saint Lawrence River [J]. Estuarine, Coastal and Shelf Science, 1999,48(3):307-324.

[13] 杨芳,胡豫英,宋利祥,等. 基于动态网格和局部时间步长技术的城市洪涝模型加速方法[J]. 清华大学学报(自然科学版), 2024,64(12):2132-2143.

Yang Fang, Hu Yuying, Song Lixiang, et al. Acceleration method for urban flood models based on dynamic mesh and local time-stepping techniques [J]. Journal of Tsinghua University (Science and Technology), 2024, 64 (12): 2132-2143. (in Chinese)

[14] 李旭,林宁亚,杨柳,等. 基于复杂水动力水质模型的感潮河口营养盐来源定量解析[J]. 环境工程技术学报,2025,15(5): 1563-1572.

Li Xu, Lin Ningya, Yang Liu, et al. Quantitative analysis of nutrient sources in tidal estuaries based on a complex hydrodynamic-water quality model[J]. Journal of Environmental Engineering Technology, 2025, 15 (5): 1563-1572. (in Chinese)

[15] 杨婷婷,虞佳颖,肖姚,等. 基于Embedding-GRU的水库水位预测模型[J]. 南水北调与水利科技(中英文),2023,21(5): 940-950.

Yang Tingting, Yu Jiaying, Xiao Yao, et al. Reservoir water level prediction model based on Embedding-GRU[J]. South-to-North Water Transfers and Water Science & Technology, 2023, 21 (5): 940-950. (in Chinese)

[16] 周兰庭,陈思思,孙永明. 基于深度学习提取时空信息的流域内库水位预测模型研究[J]. 水电能源科学,2024,42(04):133-136,132.

Zhou Lanting, Chen Sisi, Sun Yongming. Reservoir water level prediction model based on deep learning extraction of spatiotemporal information [J]. Water Resources and Power, 2024, 42(04): 133-136,132. (in Chinese)

[17] Shen Chaopeng. A transdisciplinary review of deep learning research and its relevance for water resources scientists [J]. Water Resources Research, 2018,54(11):8558-8593.

[18] Tancik M, Srinivasan P, Mildenhall B, et al. Fourier features let networks learn high frequency functions in low dimensional domains[J]. Advances in neural information processing systems, 2020, 33: 7537-7547.

[19] Sit M, Demiray B Z, Xiang Zhongrun, et al. A comprehensive

review of deep learning applications in hydrology and water resources [J]. Water Science and Technology, 2020, 82(12): 2635-2670.

[20] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. Journal of Computational Physics, 2019, 378: 686-707.

[21] 汪卫,廖杰林,朱少坤. 机器学习在大坝渗流预测中的应用、挑战与展望[J]. 人民珠江,2024,45(4):1-10.
Wang Wei, Liao Jielin, Zhu Shaokun. Application, Challenges, and Prospect of Machine Learning in Dam Seepage Prediction[J]. Pearl River, 2024, 45(4): 1-10. (in Chinese)

[22] 罗玮,吴佳豪,陈灵强,等. 基于积分时滞启发的深度学习水位预测模型[J]. 人民珠江,2025,46(11):91-99.
Luo Wei, Wu Jiahao, Chen Lingqiang, et al. Deep Learning-Based Water Level Prediction Model Inspired by Integrator Delay [J]. PEARL RIVER, 2025, 46(11): 91-99. (in Chinese)

A Multi-Station Flow Prediction Method for the Lower Reaches of the Dongjiang River Based on GRU Enhanced by Fourier Time Features

QIN Lijing[1], *CHEN Zhufeng*[2], *LIU Yueyi*[3], *ZOU Xiaobo*[4]

(1. Huizhou Hydrological Branch of Guangdong Provincial Hydrological Bureau, Huizhou516000, China; 2. Dongguan Canal Management Center, Dongguan,523000, China; 3. School of Environment and Civil Engineering, Dongguan University of Technology, Dongguan523008, China; 4. Dongguan Bureau of Water Affairs, Dongguan523000, China)

Abstract: Accurate discharge forecasting in tidal river networks is challenging because river flow is jointly controlled by upstream runoff and ocean tides, resulting in pronounced periodicity, non-stationarity, flow reversal, and complex spatiotemporal interactions among interconnected channels. To improve the representation of periodic information in data-driven forecasting, this study proposes a multi-station discharge forecasting method based on a gated recurrent unit (GRU) network enhanced with Fourier temporal features. The lower tidal river network of the Dongjiang River is used as the study area. A one-dimensional hydrodynamic model is first established using the Hydrologic Engineering Center's River Analysis System (HEC-RAS) to generate continuous and physically consistent hourly discharge series at 235 computational stations. The hydrodynamic model is calibrated and independently validated against observed water levels at Shilong Hydrological Station. Based on the simulated discharge series, historical observations are organized using sliding time windows, while daily and semi-daily periodic information is explicitly encoded through sine and cosine Fourier features and combined with the original discharge inputs. The resulting sequences are then used by the GRU network for joint multi-station and multi-step forecasting. The results demonstrate that the GRU model substantially outperforms the conventional autoregressive integrated moving average (ARIMA) model. Under the representative forecasting configuration, the Nash - Sutcliffe efficiency (NSE) increases from approximately 0.00 for ARIMA to 0.77 for GRU, while the root mean square error (RMSE) and mean absolute error (MAE) decrease to 242.32 and 103.74 m^3/s, respectively. Incorporating Fourier temporal features further improves the overall forecasting performance, reducing RMSE and MAE to 240.68 and 101.88 m^3/s and increasing NSE to 0.78. Analysis across the 235 stations shows substantial spatial heterogeneity in forecasting skill, with a median station-level NSE of 0.605 and 61.7% of stations achieving NSE values of at least 0.5. Scatter-density analysis further indicates that predictive agreement gradually decreases with increasing forecast horizon, with coefficients of determination (R^2) of 0.87, 0.83, and 0.77 for 1, 2, and 3 h forecasts, respectively. Further analysis reveals that model performance varies markedly among different discharge regimes. Both models perform relatively well under low-flow conditions, whereas the medium-flow range exhibits dynamic-range compression and the high-flow range shows larger errors and systematic underestimation. Fourier temporal features provide clear improvements under low- and high-flow conditions, particularly during high-flow periods, although their contribution is limited in the transitional medium-flow regime. Sensitivity experiments show that relatively short input windows of 6 - 12 h are more effective than longer historical sequences, while forecasting accuracy progressively deteriorates as the forecast horizon increases from 3 to 24 h. Amplitude analysis also demonstrates

that the conventional GRU tends to underestimate discharge variability; Fourier temporal encoding partially alleviates this compression by improving the representation of tidal periodicity and phase information. Overall, the proposed framework provides an efficient approach for short-term multi-station discharge forecasting in tidal river networks and demonstrates that explicitly incorporating periodic temporal information can improve the representation of complex hydrodynamic processes characterized by the coexistence of periodic tidal forcing and non-stationary runoff disturbances.

Keywords: Tidal river network; Discharge forecasting; GRU; Fourier temporal features; Multi-station modelling; HEC-RAS

（责任编辑：高天扬）