

· 信息技术 ·



基于 CNN-GRU-BP 网络的急弯航道 表面碍航流态特征预报方法研究

刘振嘉¹, 任伯浩², 梁 锴¹, 王雪蓉¹, 李明伟²

(1. 长江三峡通航管理局, 湖北 宜昌 443000; 2. 哈尔滨工程大学, 黑龙江 哈尔滨 150000)

摘要: 针对急弯航道碍航流态通航安全风险问题, 为理清不同种类典型碍航流态的发生规律, 基于已知的客观条件对未来可能发生的典型碍航流态进行预报, 对不同流态特征进行重点归纳和梳理, 并进行了急弯航道表面流态特征预测方法研究。采用基于 CNN-GRU-BP 组合神经网络的预测方法, 并与实测值和传统数值方法进行了对比验证。结果表明: 组合网络预报方法对航道表面流态特征具备较好的预测性能, 能够实时、精确、有针对性地得到在输入的非线性影响因素下不同流态的特征值, 对实际航道的通航安全管控提供了数据支持, 为防范化解相关通航安全风险提供了技术支撑。

关键词: 表面流态; 预报模型; 神经网络; 通航安全

中图分类号: U612

文献标志码: A

文章编号: 1002-4972(2025)06-0158-09

Prediction method of surface obstructive flow characteristics in sharp bend waterway based on CNN-GRU-BP network

LIU Zhenjia¹, REN Bohao², LIANG Kai¹, WANG Xuerong¹, LI Mingwei²

(1. Three Gorges Navigation Authority, Yichang 443000, China; 2. Harbin Engineering University, Harbin 150000, China)

Abstract: To clarify the occurrence law of different types of typical obstructive flow patterns, and predict the typical obstructive flow patterns that may occur in the future based on the known objective conditions, this study focuses on summarizing and sorting out the characteristics of different flow patterns and carries out the research on the prediction method for the surface flow pattern characteristics of sharp bends channels to address the safety risks of navigation caused by obstructive flow patterns. The prediction method based on CNN-GRU-BP combined neural network is used, and compared with the measured values and traditional numerical methods. The results show that the combined network prediction method has good prediction performance for the surface flow characteristics of the channel, and it can obtain the characteristic values of different flow patterns in real time, accurately, and purposely under the input nonlinear influencing factors, which can provide data support for the navigation safety control of the actual channel, and technical support for the prevention and resolution of related navigation safety risks.

Keywords: surface flow pattern; forecasting model; neural network; navigation safety

随着长江航运高速发展, 货运量屡创新高, 行船密度增大, 对航运的安全管控提出了更高的要求。其中, 航道表面出现的典型碍航流态对行船的不良阻碍作用不可忽视^[1-2], 严重时将对航道通航安全造成威胁。

在航道水动力研究方面, 何云宏^[3]使用 MIKE 软件对石碑弯道进行数值模拟, 发现天然状态下, 石碑急弯河段在大流量下碍航特征明显。使用传统的数值模拟方法往往需要耗费大量的计算资源和时间成本, 并且结果的准确性较难把控。高清震^[4]使

收稿日期: 2024-08-15

作者简介: 刘振嘉 (1976—), 男, 正高级工程师, 从事枢纽航道技术管理工作。

用 BP 神经网络(反向传播神经网络, Back Propagation Neural Network)对英那河流域的径流变化规律进行研究,经验证结果准确,所构建的模型轻量简洁;叶舒然等^[5]使用卷积神经网络对流场特征进行识别研究,在流场外形优化和预测方面都有较好的效果,对深度学习在流场识别领域的应用进行了展望。Joseph 等^[6]使用基于网格的神经网络对水动力分析进行研究,发现其具有精度高、速度快的特点。其中, CNN(卷积神经网络, convolutional neural network)^[7-8]是一种基于卷积计算的深度前馈网络,常用于图像识别领域,通过对图像数据进行卷积计算从而提取特征数据; GRU(gate recurrent unit)^[9-10]为循环神经网络的一种,该网络使用了门控循环单元(更新门和重置门),解决了反向传播算法中序列长度太长产生的梯度爆炸和梯度消失问题,且具备较高的计算速度和较低的训练成本; BP 神经网络^[11]是一种基于误差的反向传播算法训练的多层前馈网络,其基本思想为梯度下降法,使网络输出值的误差达到最小。

为实现碍航流态特征的实时预报,选取长江三峡—葛洲坝两坝间典型急弯航道为研究对象,提出基于 CNN-GRU-BP 组合神经网络的碍航流态特征预测模型,对目标航道的典型碍航流态随流量变化的演化特征进行非线性拟合,进行表面碍航流态实时预测方法的研究,旨在为实际航道的碍航流态预警预报提供参考,以及为防范化解相关通航安全风险提供技术支撑。

1 CNN-GRU-BP 组合深度学习网络流态特征预报方法

1.1 流态特征预测网络构建

从实际航道环境出发,针对其表面流态特征变化的多样性和复杂性,由于 BP 神经网络具有强大的模型拟合能力、并行处理能力、泛化能力强、自动提取特征、适应性强、高度可解释性以及灵活性和多样性等优点,采用 BP 神经网络^[12-13]搭建

流态特征的预测网络模型,该模型以流态特征的非线性影响因素作为输入,以目标流态的特征数据作为输出。BP 神经网络算法的模型结构流程见图 1。

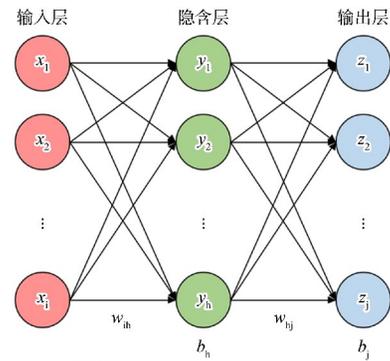


图 1 BP 神经网络结构

Fig. 1 BP neural network architecture

该模型的流程步骤为:

1) 初始化神经网络。在开始训练之前,需要初始化神经网络的参数,包括权重 w 和偏置 b 。这些参数通过随机初始化确定。

2) 正向传播。在正向传播过程中,输入样本从输入层开始,经过隐含层,最终到达输出层。在每一层中,均根据上一层的输出作为本层的输入和当前 w 、 b 计算得出神经元的输出。此过程一直持续到最终的输出层,并给出网络对输入样本的预测结果。

3) 计算误差。一旦前向传播完成,就可以通过损失函数式(1)计算预测结果与实际结果之间的误差。

4) 反向传播。在反向传播过程中,误差会通过网络反向传播回去,以更新 w 和 b 。通过计算损失函数对 w 和 b 的梯度式(2),使用梯度下降算法以更新 w 和 b ,进而减小误差。

5) 迭代优化。反复进行上述过程,直到达到预设的迭代次数,或者误差小于阈值。在每次迭代中,网络都会根据新的 w 和 b 进行正向传播和反向传播,以不断优化模型性能。

$$E_k = \frac{1}{2} \sum_{i=1}^l (y_i - y_k)^2 \quad (1)$$

$$w_{ij}^{\text{new}} = w_{ij} + \Delta w_{ij} = w_{ij} - \eta \frac{\partial E_k}{\partial w_{ij}} \quad (2)$$

式中： E_k 为损失值； k 为第 k 条训练集； l 为训练集中的第 l 列； y_i 为第 l 列中第 i 个预测值； y_k 为实测值； w_{ij}^{new} 为更新后的权重值； w_{ij} 为更新前的权重值； Δw_{ij} 为权重的偏置量，下角标 i 为此值对应上一层的元素位置， j 为此值对应下一层的位置； η 为权重的学习率。

1.2 流态特征非线性影响因素数据提取

在航道表面流态演化的过程中，影响流态特

征变化的流量、风速、水位等因素呈现不同的变化规律，且难以具体描述其变化规律，造成了人工表示其周期特征较为困难。在此前提下，采用循环神经网络 GRU 进行流态非线性变化影响因素的自动提取，通过 CNN 将序列卷积为高维张量，展平后输入 GRU 进行循环迭代，最终输出为多个不同的特征张量，见图 2。

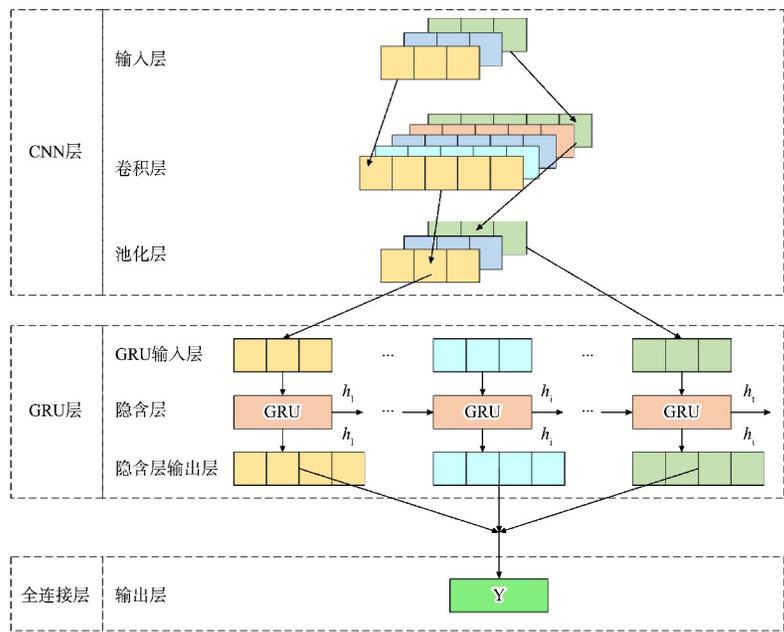


图 2 CNN-GRU 组合网络结构
Fig. 2 Composite network structure of CNN-GRU

GRU 网络是对传统 RNN 神经网络的一种实现，优化了梯度消失和梯度爆炸问题，且网络结构较为简单，计算速度较快，在 CPU 时间的收敛性和参数泛化更新方面具有较好的效果，GRU 的控制门及状态计算为：

$$z_t = \phi(\mathbf{W}_z \cdot x_t + \mathbf{U}_z \cdot h_{t-1}) \quad (3)$$

$$r_t = \phi(\mathbf{W}_r \cdot x_t + \mathbf{U}_r \cdot h_{t-1}) \quad (4)$$

$$\tilde{h}_t = \tanh(\mathbf{W} \cdot x_t + \mathbf{U}(r_t \odot h_{t-1})) \quad (5)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (6)$$

式中： z_t 为更新门， r_t 为重置门， h_t 为 GRU 的当前隐状态， \tilde{h}_t 为 GRU 的候选隐状态， x_t 为当前输入值， \mathbf{W} 和 \mathbf{U} 为权重矩阵， \mathbf{W}_z 为更新门输入值的权重， \mathbf{W}_r 为重置门输入值的权重， \mathbf{U}_z 为更新门上一

时刻隐状态的权重， \mathbf{U}_r 为重置门上一时刻隐状态的权重， ϕ 为 sigmoid 激活函数， \odot 为 hadamard 积。

1.3 模型评价指标确定

对于所构造组合网络模型的综合预测效率、精确度等指标的评估，采用均方根误差 S_{RME} 和纳什效率系数 E_{NS} 评价所构造模型的性能，见式(7)、(8)。采用相关性系数 R 值评估实测值和预测值的相关性，见式(9)， R 取值范围为 $[-1, 1]$ ，当 R 接近 1 时表示正相关性较强， R 值接近 -1 时表示负相关性较强， R 值接近 0 时表示实测值和预测值相关性较弱。其中， S_{RME} 是一种误差评价指标，用于衡量模型预测值与真实值之间的差异，它通过计算预测误差平方和的平均值的平方根来衡量预测的准确

性, 其数值越小越好; E_{NS} 是一种用于验证水文模型模拟结果好坏的指标, 其评价值在 0~1 范围内越大表示预测值越可信, 但过程模拟误差大时, 评价值远远小于 0 则表示预测值不可信。误差分析采用相对误差形式, 见式 (10)。

$$S_{RME} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{x}_{real} - x_{predict}^i)^2} \quad (7)$$

$$E_{NS} = 1 - \frac{\sum_{i=1}^n (x_{real}^i - x_{predict}^i)^2}{\sum_{i=1}^n (x_{real}^i - \bar{x}_{real})^2} \quad (8)$$

$R =$

$$\frac{n \sum_{i=1}^n x_{real}^i x_{predict}^i - \sum_{i=1}^n x_{real}^i \sum_{i=1}^n x_{predict}^i}{\sqrt{n \sum_{i=1}^n x_{real}^i{}^2 - \left(\sum_{i=1}^n x_{real}^i\right)^2} \sqrt{n \sum_{i=1}^n x_{predict}^i{}^2 - \left(\sum_{i=1}^n x_{predict}^i\right)^2}} \quad (9)$$

$$E_{rr} = \frac{|x_{predict} - x_{real}|}{x_{real}} \times 100\% \quad (10)$$

式中: S_{RME} 为均方根误差, E_{NS} 为纳什效率系数, R 为相关性系数, E_{rr} 为相对误差, n 为样本内的数据个数, $x_{predict}^i$ 为组合网络的预测值, x_{real}^i 为实测值, \bar{x}_{real} 为实测值的平均值。

1.4 CNN-GRU-BP 流态特征集成预报方法建立

为了将模型充分覆盖其他范围的样本数据, 将实验数据分为训练集、验证集和测试集三部分, 将训练集用于 CNN-GRU-BP 组合网络的训练, 使用 CNN-GRU 组合网络对非线性影响因素进行提

取, 使用 BP 神经网络基于提取的影响因素对流态特征进行预测。

考虑研究区域实际环境的复杂变化, 为保证模型的性能和泛化能力, 采用随机采样的方法对数据样本进行划分, 将其中 70% 划分为训练集, 20% 划分为验证集, 10% 划分为测试集。使用验证集对其组合网络模型的结果进行验证, 使用测试集对模型进行误差分析。组合网络模型的预报流程(图 3)为:

1) 数据预处理。将流态特征影响的非线性因素(流量、风速、水位等)进行数据归一化, 将其值域转化为 [0, 1], 并使其格式满足组合网络的训练要求。

2) 模型结构和参数的初始化。初始化组合网络的输入数据维度、卷积核的数量和尺寸、隐含层节点数等超参; 选择合适的卷积层数、池化层数和激活函数等结构参数。

3) 模型训练。将步骤 1 的训练样本数据输入到组合网络模型中进行训练, 获得模型输出, 计算每层网络的误差项, 按照梯度更新每一层的权重值, 并根据梯度阈值和误差阈值判断是否达到训练目标, 若达到则终止训练并进入步骤 4, 否则重复上述训练过程。

4) 模型精度测试。使用测试集对训练完毕的组合模型进行精度测试, 若精度达标, 则完成模型, 否则返回步骤 2、3, 调整模型结构和超参进行再次训练。

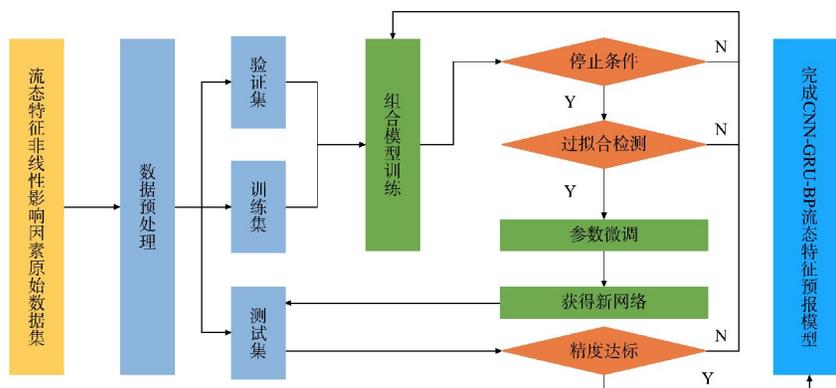


图 3 CNN-GRU-BP 流态特征预报流程

Fig. 3 Flow characteristics prediction process of CNN-GRU-BP

2 实例分析

2.1 样本选取

为了验证构造组合网络模型的预测性能，选取长江三峡—葛洲坝两坝间石碑弯道(长江上游航道里程 22.5 ~ 23.8 km)为实例测试区域(图 4)。该地区全年平均降雨量 1 155.2 mm，年平均风速 1.6 m/s，能见度小于 1 000 m 的年平均雾日 24 d，年最多雾日 70 d，河床床面起伏，剪刀水、泡旋水、回流等不良流态复杂多变。

研究对象选取航道表面的典型碍航流态，提取其流态特征影响因素和历史观测数据作为训练样本。样本来源于历史水文观测资料，对其中各不良流态随流量变化的位置、强度、范围等参数进行整理。其中，由于三峡坝区的宏观调控影响，研究航段的流量大小可作为已知量，因此选取流量作为模型的主要输入值，风速和水位作为辅助输入值，以典型流态的最大流速、范围等特征参数作为模型的输出值。



图 4 研究航段及特征流态位置
Fig. 4 Location of studied river section and characteristic flow pattern

2.2 样本数据修补

对于样本数据中缺损的部分，使用线性插值法对其进行修补，以保证样本数据的连续性，选取回流的最高流速和对应的流量为例，展示修补前

后的数据样本，见图 5。

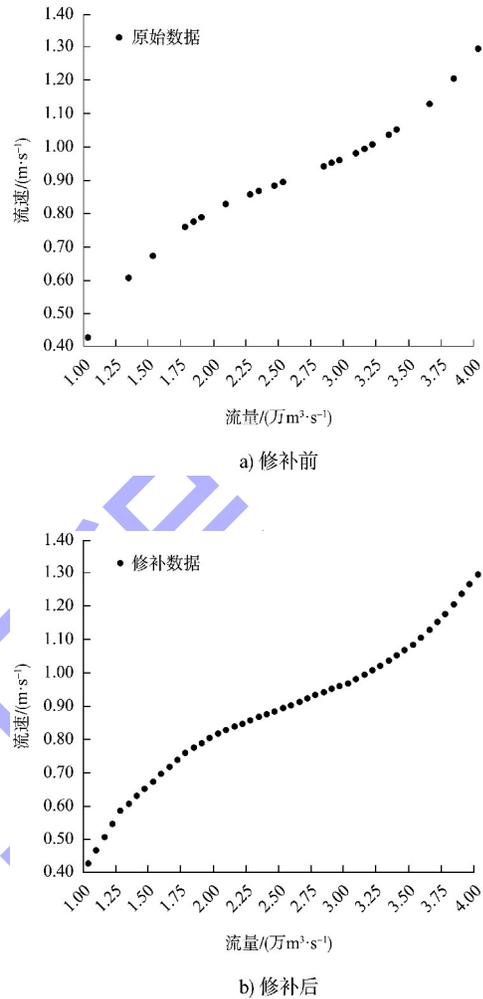


图 5 修补前后的数据样本
Fig. 5 Data samples before and after repair

2.3 模型预报性能和效果

利用模型对样本集进行训练，同时结合水动力数值仿真 (computational fluid dynamics, CFD) 方法对同种流态参数得出的结果进行对比，并结合实测值进行验证。其中，水动力数值仿真数据来源于基于 MIKE21 的二维数值模拟结果^[14]，数值模型基于实地采样数据进行建模，采用三角形非结构网格进行划分，网格数为 56 865 (图 6)。由于不同碍航流态对通航的影响机理各异，实际通航中，需要根据流态的种类关注不同的重点碍航特征，因此根据不同流态的重点特征进行针对性分析。

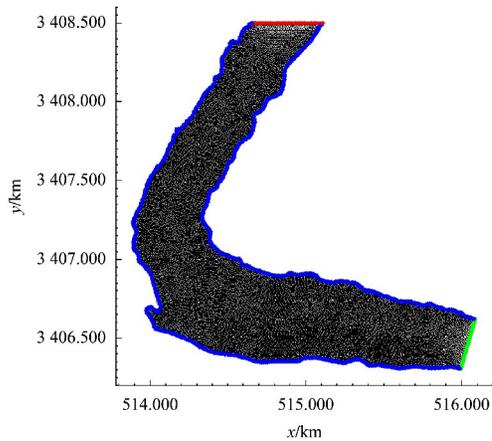
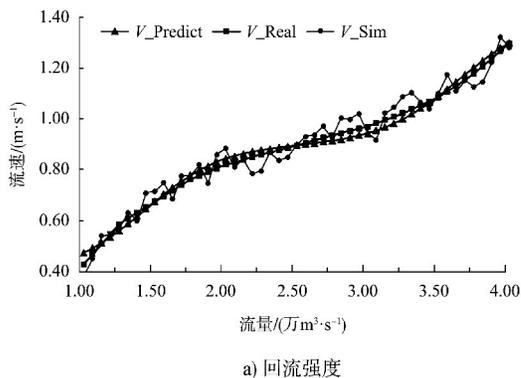


图 6 数值模型网格划分

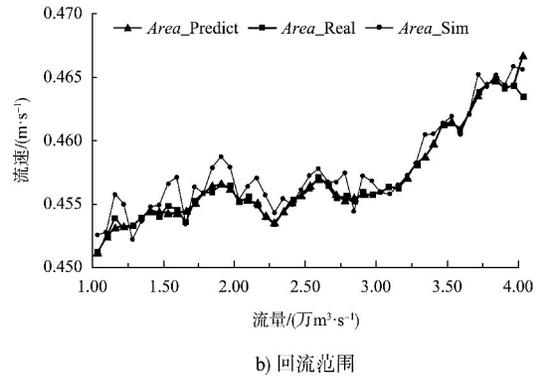
Fig. 6 Grid discretization of numerical model

2.3.1 回流的范围和强度特征

回流对通航的影响主要包括流速强度和影响范围两方面, 根据历史观测资料, 所研究航段的回流区为固定区域, 利用该回流区域的最大流速代表回流的强度, 覆盖面代表回流影响范围。所构造的神经网络模型预测了当流量增加时, 回流的范围和最大流速的变化趋势 (图 7), 对比传统 CFD 方法, 发现本模型所得到的预测值与实测值的吻合程度显著高于数值仿真方法的模拟值, 具备更低的误差和更优的准确性 (图 8)。同时发现在流量增加时, 回流的覆盖面仅在较小范围内缓缓增加, 均在 0.46 km^3 上下浮动; 而最大流速则随流量增大显著增加, 从流量 $1.00 \text{ 万 m}^3/\text{s}$ 时的 0.47 m/s 增大到流量 $4.00 \text{ 万 m}^3/\text{s}$ 时的 1.30 m/s 。



a) 回流强度

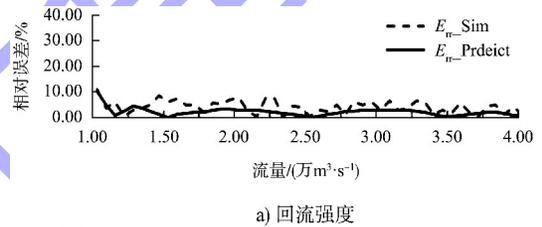


b) 回流范围

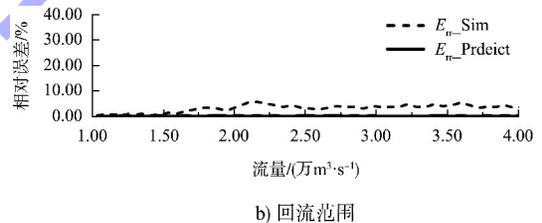
注: V_{Predict} 、 $Area_{\text{Predict}}$ 、 L_{Predict} 为模型输出的预测值, V_{Real} 、 $Area_{\text{Real}}$ 、 L_{Real} 为实测值, V_{Sim} 、 $Area_{\text{Sim}}$ 、 L_{Sim} 为数值仿真方法得出的模拟值。

图 7 回流强度和回流范围变化趋势

Fig. 7 Variation trend of reflux intensity and reflux range



a) 回流强度



b) 回流范围

图 8 回流强度和回流范围预测值的误差

Fig. 8 Error of predicted for reflux intensity and reflux range

2.3.2 剪刀水的范围和强度特征

剪刀水对通航的影响主要为水流集中形成加速流, 对行船的正常航线产生干扰。根据历史观测资料, 所研究航段的剪刀水流态在不同流量下均发生在一固定区域内, 采用剪刀水的最大流速代表强度, 采用剪刀水沿航道水流方向的长度代表实际影响范围。当流量增加时, 预测剪刀水的范围和最大流速的变化趋势 (图 9)。从模型的输出结果中发现, 对比传统 CFD 方法, 模型在剪刀

水最大流速和长度的预测值上具有更低的误差和与实测值更优的吻合程度(图 10)。同时可以发现剪刀水的最大流速和长度与流量大小呈现较强的正相关性,在流量增加时,剪刀水的最大流速和长度均显著增加。

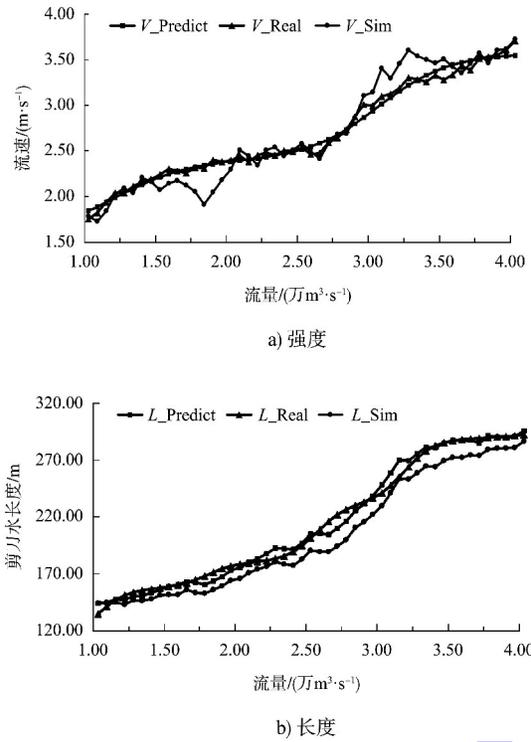


图 9 剪刀水强度和长度的变化趋势

Fig. 9 Variation trend of scissor water strength and length

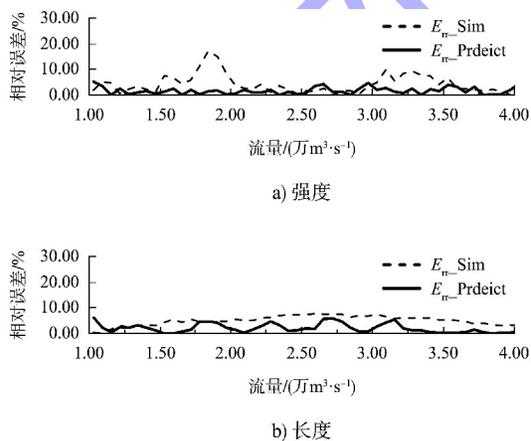


图 10 剪刀水强度和长度预测值的误差

Fig. 10 Error of predicted scissor water strength and length

2.3.3 泡漩的范围和强度特征

泡漩对船只通航的影响在于影响范围和强度,选取所研究航段表面的一处固定区域,该区域泡

漩现象密集,以其中泡漩的最大流速代表强度,以泡漩的直径代表影响范围。当流量增加时,预测泡漩的范围和最大流速的变化趋势(图 11)。结果发现,所构建的预测模型对比传统 CFD 方法,具备更低的误差,与实测值的吻合程度更高(图 12)。同时,泡漩的大小直径与最大流速均随流量增加而显著增大,并可通过所构建的模型进行较好的预测。

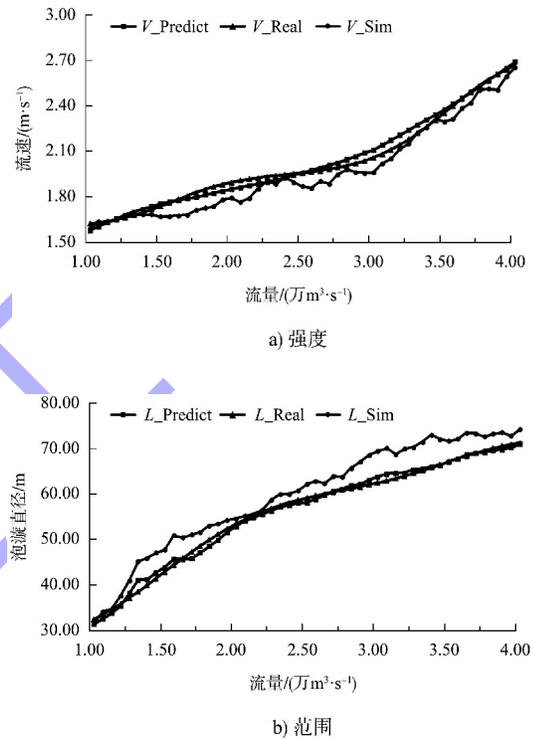


图 11 泡漩强度和范围的变化趋势

Fig. 11 Variation trend of bubble vortex intensity and range

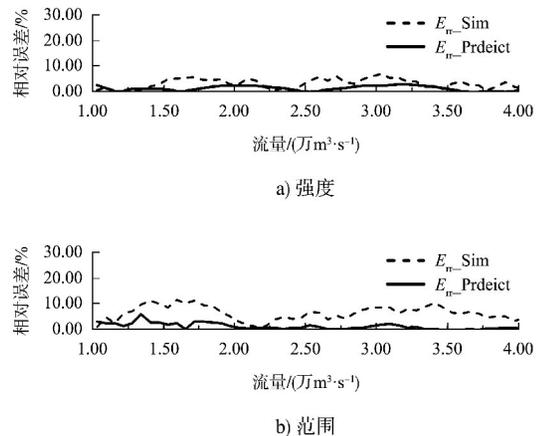


图 12 泡漩强度和范围预测值的误差

Fig. 12 Error of predicted bubble vortex intensity and range

2.3.4 流态特征预测效果评价

如表1所示,将组合神经网络与实测值进行对比分析,并对比传统CFD方法,发现组合神经网络的预测结果的各项评价指标均明显优于传统CFD方法,可较好地对实际流态特征进行预测。

同时,对模型的次要输入变量(风速和水位)与输出值进行相关性对比,从表2可看出,相关性系数 R 最大值为0.2412,最小值为-0.3758,且均处于0附近,可认为风速和水位对各输出特征变量的相关性较弱。

表1 流态特征预测效果评价

Tab.1 Evaluation of fluidity characteristic prediction effect

| 研究对象 | 研究方法 | 相关性系数 R (越大越好) | S_{RME} (越小越好) | E_{NS} (越大越好) | 相对误差/%(越小越好) |
|-------|---------|------------------|------------------------|-----------------|--------------|
| 回流强度 | 组合神经网络 | 0.9957 | 0.0193 m/s | 0.9914 | 2.10 |
| | 传统CFD方法 | 0.9817 | 0.0407 m/s | 0.9617 | 4.18 |
| 回流范围 | 组合神经网络 | 0.9906 | 0.0051 km ³ | 0.9979 | 0.19 |
| | 传统CFD方法 | 0.7373 | 0.0157 km ³ | -17.6219 | 2.99 |
| 剪刀水强度 | 组合神经网络 | 0.9933 | 0.0611 m/s | 0.9867 | 1.69 |
| | 传统CFD方法 | 0.9784 | 0.1493 m/s | 0.9206 | 4.24 |
| 剪刀水范围 | 组合神经网络 | 0.9948 | 5.4300 m | 0.9789 | 2.07 |
| | 传统CFD方法 | 0.9973 | 12.1459 m | 0.9481 | 5.09 |
| 泡漩强度 | 组合神经网络 | 0.9943 | 0.0336 m/s | 0.9874 | 1.41 |
| | 传统CFD方法 | 0.9902 | 0.0774 m/s | 0.9333 | 3.32 |
| 泡漩范围 | 组合神经网络 | 0.9948 | 0.8887 m | 0.9937 | 1.47 |
| | 传统CFD方法 | 0.9931 | 3.9796 m | 0.8823 | 6.59 |

表2 输入输出值相关性

Tab.2 Correlation between input and output values

| 输入变量 | 输出变量 | 相关性系数 R (越大越好) |
|------|-------|------------------|
| 风速 | 回流强度 | 0.1080 |
| 水位 | | 0.1605 |
| 风速 | 回流范围 | -0.3758 |
| 水位 | | -0.2788 |
| 风速 | 剪刀水强度 | -0.1266 |
| 水位 | | -0.0304 |
| 风速 | 剪刀水范围 | -0.0978 |
| 水位 | | -0.0277 |
| 风速 | 泡漩强度 | -0.2068 |
| 水位 | | -0.0744 |
| 风速 | 泡漩范围 | 0.2034 |
| 水位 | | 0.2412 |

3 结论

1) 通过与历史观测数据进行对比分析,所提出的预报模型在不同流态特征的预测中表现出优异的性能,能够为实际通航安全管理提供有效的数据支持。

2) 相较于传统数值方法和人工观测法,CNN-GRU-BP组合网络方法可以更加精确、实时地获取目标航道表面的流态特征,弥补人工观测的不足,降低时间和经济成本,同时节约了大量

计算资源。

3) 本研究的训练样本覆盖流量范围有限,当输入数据接近或超出样本上下限时(如流量小于1.00万m³/s或大于4.00万m³/s),预报误差可能增加。因此,需要更大范围和更多数量的训练样本进一步增强模型性能。

参考文献:

- [1] 周晶.有关航道弯道整治特征及其方法分析[J].科技与企业,2016(7):111.
ZHOU J. Analysis of characteristics and methods of channel bendregulation [J]. Technology and enterprise, 2016 (7):111.
- [2] 刘临雄,李俊娜,黄文辉.西江长洲水利枢纽至界首河段航道碍航分析及整治措施[J].水运工程,2020(7):158-163,174.
LIU L X, LI J N, HUANG W H. Analysis of channel obstruction from Changzhou water control project to Jieshou reach and its regulation measures [J]. Port & waterway engineering, 2020(7): 158-163, 174.
- [3] 何云宏.三峡两坝间石牌急弯河段通航水流条件及改善措施研究[D].重庆:重庆交通大学,2021.
HE Y H. Research on navigable flow conditions and

improvement measures of Shipai acute bend reach between the two dams of the Three Gorges [D]. Chongqing: Chongqing Jiaotong University, 2021.

[4] 高清震. 基于 BP 人工神经网络的英那河流域径流模拟研究[J]. 黑龙江水利科技, 2020, 48(3): 16-20.

GAO Q Z. Study on runoff simulation of yingna river basin based on BP artificial neural network [J]. Heilongjiang hydraulic science and technology, 2020, 48(3): 16-20.

[5] 叶舒然, 张珍, 王一伟, 等. 基于卷积神经网络的深度学习流场特征识别及应用进展 [J]. 航空学报, 2021, 42(4): 185-199.

YE S R, ZHANG Z, WANG Y W, et al. Progress in deep convolutional neuralnetwork based flow field recognition and its applications [J]. Acta aeronautica et astronautica sinica, 2021, 42(4): 185-199.

[6] JOSEPH N S, BANERJEE C, REASOR D A, et al. Mesh based neural networks for estimating high fidelity CFD from low fidelity input [C]//Southeast Con 2022. New York: IEEE Press, 2022: 565-574.

[7] GU J X, WANG Z H, KUEN J, et al. Recent advances in convolutional neural networks[J]. Pattern recognition: The Journal of the Pattern Recognition Society, 2018, 77: 354-377.

[8] ALZUBAIDI L, ZHANG J L, HUMAIDI A J, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions [J]. Journal of big data, 2021, 8(1): 53.

[9] DEY R, SALEM F M. Gate-variants of gated recurrent unit

(GRU) neural networks [C]//2017 IEEE 60th internationalmidwest symposium on circuits and systems: MWSCAS. Boston: IEEE, 2017: 1597-1600.

[10] WEERAKODY P B, WONG K W, WANG G J, et al. A review of irregular time series data handling with gated recurrent neural networks [J]. Neurocomputing, 2021, 441(21): 161-178.

[11] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323: 533-536.

[12] 李萍, 曾令可, 税安泽, 等. 基于 MATLAB 的 BP 神经网络预测系统的设计 [J]. 计算机应用与软件, 2008, 25(4): 149-150, 184.

LI P, ZENG L K, SHUI A Z, et al. Design of forecast system of back propagation neural network based on Matlab [J]. Computer applications and software, 2008, 25(4): 149-150, 184.

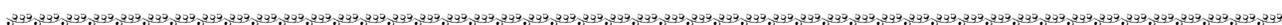
[13] 戚德虎, 康继昌. BP 神经网络的设计 [J]. 计算机工程与设计, 1998, 19(2): 48-50.

QI D H, KANG J C. Design of BP neural network [J]. Computer engineering and design, 1998, 19(2): 48-50.

[14] 梁锴, 任伯浩, 李明伟, 等. 三峡枢纽典型碍航河段复杂流态分析 [J]. 水运工程, 2024(7): 138-144, 164.

LIANG K, REN B H, LI M W, et al. Complex flow pattern in typical navigation obstructed region of Three Gorges Project [J]. Port & waterway engineering, 2024(7): 138-144, 164.

(本文编辑 赵娟)



(上接第 152 页)

[10] 刘志敏, 李志成. 湘祁二线船闸平面布置方案及设计优化创新 [J]. 水运工程, 2023(1): 137-142.

LIU Z M, LI Z C. Layout plan and optimal design innovation of Xiangqi second-line ship lock [J]. Port & waterway engineering, 2023(1): 137-142.

[11] 中交第二航务工程勘察设计院有限公司. 赣江龙头山枢纽二线船闸工程施工图设计报告 [R]. 武汉: 中交第二航务工程勘察设计院有限公司, 2022.

CCCC Second Harbor Consultants Co., Ltd. Engineering construction drawing design report of second ship lock project of Longtoushan hub in Ganjiang River [R]. Wuhan: CCCC Second Harbor Consultants Co., Ltd., 2022.

[12] 南京水利科学研究所. 赣江龙头山水电站枢纽船闸工程整体物理模型试验研究报告 [R]. 南京: 南京水利科学研究所, 2022.

Nanjing Hydraulic Research Institute. Report of overall physical model test of lock project of Longtoushan hydropower station in Ganjiang River [R]. Nanjing: Nanjing Hydraulic Research Institute, 2022.

[13] 船闸总体设计规范: JTJ 305—2001 [S]. 北京: 人民交通出版社, 2001.

Code for master design of shiplocks: JTJ 305—2001 [S]. Beijing: China Communications Press, 2001.

(本文编辑 王璵)