



引文格式: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.DOI:10.13203/j.whugis20220012

Citation:CHEN Zhigao, WU Zihao, BAN Ya, et al. Discharge Prediction in Tidal Reach Using Harmonic Analysis and VMD-BP Neural Network[J]. Geomatics and Information Science of Wuhan University, 2023, 48(8): 1389-1397. DOI: 10.13203/j. whugis20220012

## 基于调和分析及VMD-BP神经网络的感潮河段流量预报

陈志高<sup>1,2</sup> 吴子豪<sup>1,2</sup> 班 亚<sup>3</sup> 陈志平<sup>1,2</sup>

1 东华理工大学自然资源部环鄱阳湖区域矿山环境监测与治理重点实验室,江西 南昌,330013

2 东华理工大学测绘与空间信息工程学院,江西 南昌,330013

3 重庆市计量质量检测研究院,重庆,401100

**摘要:**针对感潮河段受径流和潮汐共同影响导致流量预报精度较低的问题,结合变分模态分解(variational mode decomposition, VMD)处理非平稳信号的能力与反向(back propagation, BP)神经网络处理非线性问题的优势,提出了基于潮流调和分析及VMD-BP神经网络组合模型的感潮河段流量预报方法。首先,采用潮流调和分析方法对原始流量进行潮流、余流分离;然后,根据误差逆向传播算法构建BP神经网络,并对潮流数据和经VMD处理后的余流数据进行仿真训练;最后,将仿真训练输出的潮流和余流分量叠加重构进而得到最终的流量预报结果。在长江口徐六泾断面开展流量预报实验,结果表明,单独采用BP神经网络方法相对于传统潮流调和分析方法的流量预报精度提高了约3 400 m<sup>3</sup>/s,相对精度提高了约6%;所提组合模型方法的流量预报精度相对于传统潮流调和分析方法提高了约5 000 m<sup>3</sup>/s,相对精度提高了约9%。基于调和分析及VMD-BP神经网络的组合模型可以有效提高感潮河段流量预报精度,同时也为流况多变水域的流量预报提供新思路。

**关键词:**流量预报;调和分析;变分模态分解;BP神经网络;感潮河段;长江口

中图分类号:P338

文献标识码:A

收稿日期:2022-10-20

DOI:10.13203/j.whugis20220012

文章编号:1671-8860(2023)08-1389-09

## Discharge Prediction in Tidal Reach Using Harmonic Analysis and VMD-BP Neural Network

CHEN Zhigao<sup>1,2</sup> WU Zihao<sup>1,2</sup> BAN Ya<sup>3</sup> CHEN Zhiping<sup>1,2</sup>

1 Key Laboratory of Mine Environmental Monitoring and Improving Around Poyang Lake of Ministry of Natural Resources, East China University of Technology, Nanchang 330013, China

2 School of Surveying and Geoinformation Engineering, East China University of Technology, Nanchang 330013, China

3 Chongqing Academy of Metrology and Quality Inspection, Chongqing 401100, China

**Abstract:** Objectives: In view of the low accuracy of flow forecast in tidal reach due to the combined influence of runoff and tide, combining the ability of variational mode decomposition (VMD) to process non-stationary signals and the advantages of back propagation (BP) neural network to deal with nonlinear problems, this paper proposes a new method for discharge prediction in tidal reach based on the combination model of tidal current harmonic analysis and VMD-BP neural network. Methods: First, the harmonic analysis method is used to separate the tidal discharge and residual discharge from the original discharge. Second, a BP neural network is constructed based on error backpropagation algorithm. Then, the BP neural network is used to simulate and train the power flow data and residual current data processed by VMD. Finally, the output tidal discharge and residual discharge components are superimposed and reconstructed to obtain the final dis-

基金项目:国家自然科学基金(42266006, 41806114, 41904031);江西省自然科学基金(20202ACBL214019, 20181BAB216031, 20202BABL213033)。

第一作者:陈志高,博士,副教授,主要从事ADCP流速测量及流量估计等方面的研究。531214372@qq.com

charge prediction results. **Results:** Experiments performed at the Xuliujing section of the Yangtze Estuary show that the discharge prediction accuracy of BP neural network method is better than that of traditional harmonic analysis method, with the root mean square error (RMSE) is decreased by about  $3\ 400\text{ m}^3/\text{s}$ , and the relative standard accuracy (RSD) is increased by about 6%. In addition, compared with the traditional method, RMSE of the proposed method in this paper is decreased by about  $5\ 000\text{ m}^3/\text{s}$ , and the RSD is increased by about 9%. **Conclusions:** The combined model based on harmonic analysis and VMD-BP neural network can effectively improve the prediction accuracy of discharge in tidal reach. At the same time, it also provides a new idea for the discharge prediction in the waters with variable flow conditions.

**Key words:** discharge prediction; harmonic analysis; variational model decomposition; BP neural network; tidal reach; the Yangtze Estuary

受河川径流和海洋潮汐双重作用影响,感潮河段流场变化复杂,水位、流量等水文要素的变化规律难以掌握,对其进行流量精确预报则更加困难<sup>[1]</sup>。传统的数理统计和水文模型等方法在非感潮河段的流量预报中取得了较为理想的效果<sup>[2]</sup>,但对于流场变化复杂且水位和流量的对应关系为多值的感潮河段并不适用<sup>[3]</sup>。目前,通常采用调和分析(harmonic analysis, HA)方法对感潮河段的流量进行预报<sup>[4-5]</sup>,即对流速进行调和分析以获取调和常数,然后利用调和常数对所需时段的流速进行预报,进而采用面积-流速法计算断面流量。虽然调和分析方法的物理意义较为清晰,但由于感潮河段流场在横断面方向上的非同步性,调和分析法的预报精度严重依赖代表性流速垂线位置及观测时段长短的选取<sup>[4, 6]</sup>,难以保证其预报精度。

近年来,神经网络<sup>[7]</sup>、小波分解<sup>[8]</sup>、遗传算法<sup>[9]</sup>等人工智能方法在水文预报领域得到推广和应用,其中反向(back propagation, BP)神经网络成为流量预报的主流方法<sup>[10]</sup>。BP神经网络具有构建简便、处理数据高效便捷、拟合能力优秀,实时学习实时优化等特点,适合处理复杂多变的非线性流量数据。文献[11]利用BP神经网络在感潮河段建立水动力洪水预报模型,为模型下边界条件的处理提供了新的途径,并提高了洪水预报的精度;文献[12]结合BP神经网络和遗传粒子群优化算法,对某海域的潮汐水位值进行预报,实验结果表明改进模型有效克服了BP神经网络阈值和权值选取敏感、易陷入局部极小值的缺点;文献[13]发现将潮流调和分析与人工神经网络方法相结合能有效提高海流的流速与流向预报的精度;文献[14]对尼罗河的主要站点流量进行了预报,结果表明,人工神经网络的预报精度远远优于传统模型,其在河流流量预测方面具有很大的潜力;文献[15]利用人工神经网络对印度尼西亚Mahakam河的感潮河段进行流量预报,将上

游河流水位、预测潮位和感潮河段历史流量作为输入数据,实验结果表明,将预测潮位作为输入数据能有效地提高模型的预报精度。

变分模态分解(variational mode decomposition, VMD)是一种自适应信号处理方法<sup>[16]</sup>,该方法是在经典的经验模态分解(empirical mode decomposition, EMD)基础上进行改进得到<sup>[17]</sup>。变分模态分解能有效将非线性、非平稳的信号分解成指定个数的固有模态分量(intrinsic mode function, IMF),与经典的EMD经验模态分解相比,它有效地避免了分解过程中的模态混叠、过包络等问题,具有较高的运算效率以及良好的抗噪声干扰。感潮河段流量由周期性的潮流和非周期性的余流构成,产生余流的动力机制主要包括潮汐、季节性风场及河流径流等。从根源上讲,余流是由常流、紊流以及潮流自身的非线性现象引起的<sup>[18]</sup>。因此,VMD分解很适合对感潮河段不规则的余流数据进行平稳化处理。此外,相较于经典的EMD,VMD还可以指定数据分解的信号个数,可减少BP神经网络的构建量,提高BP神经网络的工作效率和精度<sup>[19]</sup>。

因此,本文根据感潮河段潮流及余流流量的时序分布特点,结合VMD处理非平稳信号和指定分解信号个数的能力以及BP神经网络在非线性拟合方面的优势,提出了一种基于调和分析及VMD-BP神经网络组合模型的感潮河段流量预报方法。

## 1 研究方法

余流是由常流、紊流以及潮流自身的非线性现象引起的非周期性的水流,其变化规律通常难以准确掌握。因此,实现流量精确预报的关键是对余流流量进行有效分解及预报。首先,采用潮流调和分析方法获得潮流流量,将实测流量减去潮流流量得到余流流量;其次,利用VMD模态分解对余流流量数据进行平稳、降

噪处理;然后,根据误差逆向传播算法,构建BP神经网络对潮流数据和经VMD处理后的余流数据进行仿真训练,输出预报的潮流和余流分

量;最后,将预报得到的余流分量和潮流进行叠加重构得到最终的流量预报结果。具体步骤如图1所示。

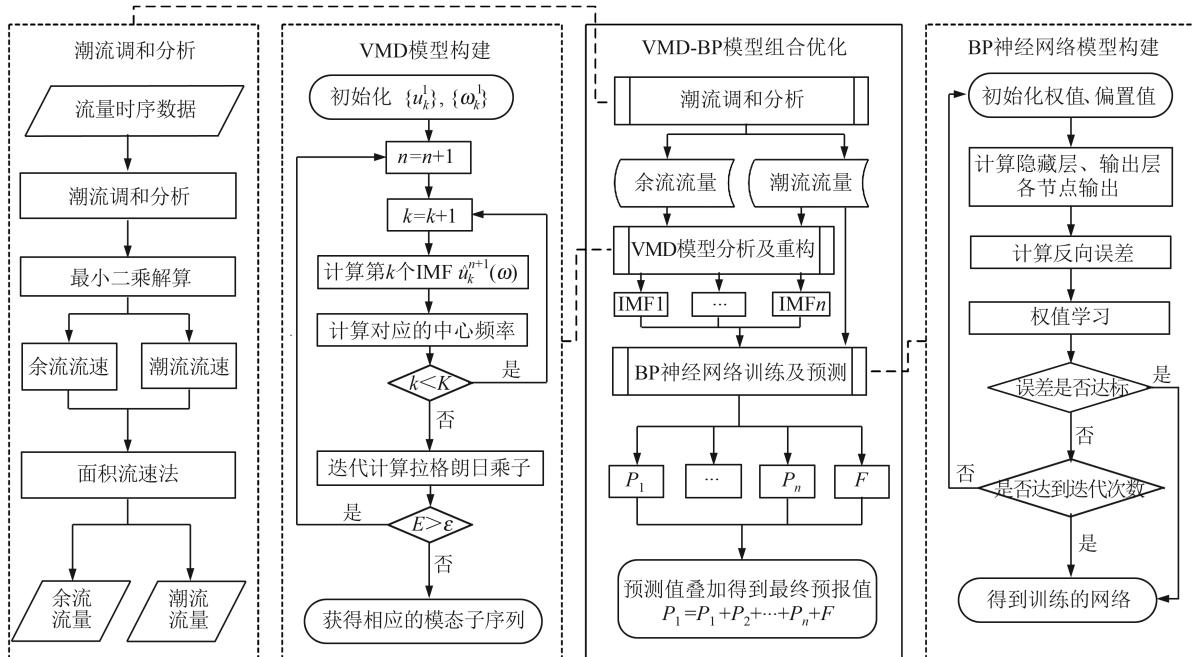


图1 本文方法流程图

Fig. 1 Flowchart of Our Proposed Method

### 1.1 潮流调和分析

流速为矢量,为了便于分析,通常将其分解为北分量和东分量。由于北分量与东分量的调和分析类似,本文仅介绍东分量  $u$  的调和分析过程。流速观测值可表示为余流和若干分潮之和:

$$u(t) = U_0 + \sum_{i=1}^m U_i \cos(\sigma_i t + v_{0i} - \zeta_i) + \epsilon(t) \quad (1)$$

式中,  $u(t)$  为时刻  $t$  的观测值;  $U_0$  为余流;  $m$  为分潮个数;  $\sigma_i$  为分潮  $i$  的角速度;  $v_{0i}$  为分潮  $i$  在  $t=0$  时的格林尼治天文相位角;  $U_i$  为分潮  $i$  的振幅;  $\zeta_i$  为分潮  $i$  的迟角;  $\epsilon(t)$  为误差差。

若忽略误差项  $\epsilon(t)$ , 并令  $v_0 - \zeta = -\theta$ ,  $b = U \cos \theta$ ,  $c = U \sin \theta$ , 则式(1)可以表示为:

$$u(t) = U_0 + \sum_{i=1}^m U_i \cos(\sigma_i t - \theta_i) = U_0 + \sum_{i=1}^m [b_i \cos(\sigma_i t) + c_i \sin(\sigma_i t)] \quad (2)$$

利用最小二乘法对其进行解算即可得到余流  $U_0$  及各个分潮的  $b$ 、 $c$  值,从而得到振幅  $U$  和相位  $\theta$ <sup>[20]</sup>。在获得各分潮的流速后,可以计算和预报不同时刻的潮流流速值,进而根据流速-面积法获得潮流流量。将原始流量减去潮流流量即可获得余流流量,用于后续的VMD模态分解。

### 1.2 VMD模态分解

VMD的分解过程实际是变分问题的求解过

程,通过迭代求取最优解来确定各个分解分量的频率中心和宽带。利用VMD分解可以对调和分析得到的余流流量  $q_k(t)$  进行平稳化处理,并分解成多个具有原始数据特征的IMF分量。

将每个模态函数  $q_k(t)$  通过 Hilbert 变换得到其解析函数  $B$ <sup>[16]</sup>:

$$B = \left[ \delta(t) + \frac{j}{\pi t} \right] * q_k(t) \quad (3)$$

式中,  $\delta(t)$  表示单位脉冲函数;  $*$  表示卷积;  $j$  为虚数单位。

将式(3)所得各模态的解析函数  $B$  与指数协调项  $e^{-j\omega_k t}$  相乘,实现将  $q_k(t)$  中心频段移动到基频段:

$$C = \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * q_k(t) \right] * e^{-j\omega_k t} \quad (4)$$

由此得到  $q_k(t)$  的受约束的变分方程  $D$ ,以及相应的约束条件:

$$\begin{cases} D = \min_{\{q_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * q_k(t) \right] * e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_k q_k = f \end{cases} \quad (5)$$

式中,  $\{q_k\} = \{q_1, q_2, \dots, q_k\}$  为各模态函数集;  $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$  为各模态对应的中心频率集;  $f$  为

原始序列。

在求得变分方程后,需对其进行求解。引入二次惩罚因子 $\alpha$ 和拉格朗日乘子 $\lambda(t)$ ,为了确保公式的收敛性且使得约束变分问题不受约束,将约束变分公式转变为无约束变分公式。由于二次惩罚因子 $\alpha$ 是足够大的正数,可保证信号的重构精度,而拉格朗日乘法算子则确保约束条件的严格性。扩展后的拉格朗日乘法算子表达式如下:

$$\begin{aligned} L\left(\{q_k(t)\}, \{\omega_k\}, \lambda(t)\right) = & \\ & \alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * q_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k q_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k q_k(t) \right\rangle \end{aligned} \quad (6)$$

利用乘法算子交替方向法对式(6)进行解算<sup>[21]</sup>,并不断迭代更新 $q_k^{m+1}$ 的值,直到精度 $E$ 大于判别精度 $\epsilon$ 即停止迭代,最后得到流量数据的分量分解组合 $\{q_1, q_2, \dots, q_k\}$ 。计算如下:

$$\hat{q}_k^{m+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{q}_i(\omega) + \hat{\lambda}(\omega)}{1 + 2\alpha(\omega - \omega_k)^2} \quad (7)$$

$$E = \frac{\sum_k \left\| \hat{q}_k^{m+1} - \hat{q}_k^m \right\|_2^2}{\left\| \hat{q}_k^m \right\|_2^2} \quad (8)$$

式中, $m$ 为迭代次数; $\hat{q}_k^{m+1}(\omega)$ 和 $\hat{\lambda}(\omega)$ 分别为 $q_k^m(t)$ 和 $\lambda(t)$ 对应的傅里叶变化结果。

### 1.3 BP神经网络训练

BP神经网络是一种非线性算法,具有较好的非线性映射能力,由输入层、输出层与隐含层构成,其具体拓扑结构如图2所示。

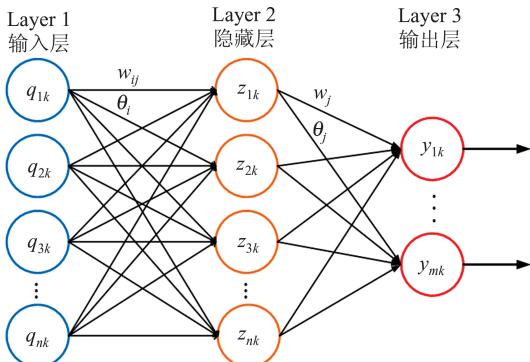


图2 BP神经网络拓扑结构

Fig. 2 Topology of BP Neural Network

经VMD变分模态分解处理后的流量数据需首先划分为输入数据 $Q$ 与输出数据 $Y$ ,以便输入

BP神经网络进行训练。

$$\left\{ \begin{array}{l} Q = \begin{bmatrix} q_{11} & q_{21} & \cdots & q_{n1} \\ q_{12} & q_{22} & \cdots & q_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ q_{1k} & q_{2k} & \cdots & q_{nk} \end{bmatrix} \\ Y = \begin{bmatrix} y_{11} & y_{21} & \cdots & y_{m1} \\ y_{12} & y_{22} & \cdots & y_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ y_{1k} & y_{2k} & \cdots & y_{mk} \end{bmatrix} \end{array} \right. \quad (9)$$

BP神经网络算法的核心步骤分为正向传播和反向传播两个部分。正向传播部分,首先输入数据 $q_{nk}$ ,沿着网络的指向乘以对应的权重 $w_{ij}$ ,下一步累加偏置 $\theta_i$ 传入隐藏层;然后,通过传递函数 $f_i(x)$ 计算后输出隐藏层得到 $z_{nk}$ ;最后,将 $z_{nk}$ 乘以相应的权重 $w_j$ 并加上偏置值 $\theta_j$ 传递到输出层,得到预报值 $y_{mk}$ 。反向传播部分,计算预报值 $y_{mk}$ 与实测值 $v_{mk}$ 的误差 $E$ ,判断误差是否超限,如果超限,则将误差反向传播到隐藏层,调整更新权值及偏置值并重新进行以上步骤,直到误差小于设定阈值或超过设定的最大迭代次数,得到最终训练好的网络。具体计算如下:

$$f_i(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (10)$$

$$z_{nk} = f_i \left( \sum w_{ij} q_{nk} + \theta_i \right) \quad (11)$$

$$y_{mk} = f \left( \sum w_j z_{nk} + \theta_j \right) \quad (12)$$

$$E = o_{mk} - y_{mk} \quad (13)$$

式中, $w_{ij}$ 为第*i*个输入层和第*j*个隐藏层的权重; $q_{nk}$ 为经VMD分解后得到的第*k*个分量的第*n*个值; $z_{nk}$ 为对应的隐藏层值; $y_{mk}$ 为对应的输出层值; $o_{mk}$ 为实际观测值。经过以上步骤构建BP神经网络后,可将潮流流量的输入数据输入到神经网络,进行训练仿真来获取潮流流量的预报值 $F$ 。然后将余流流量经VMD分解后得到的各IMF分量输入到相对应的网络结构进行计算,获取各分量预报值 $P_1, P_2, \dots, P_n$ ,最后将潮流预报值和余流预报值叠加得到最终的流量预报结果:

$$P = P_1 + P_2 + \cdots + P_n + F \quad (14)$$

## 2 实验数据与预处理

### 2.1 实验区域

本文以长江口徐六泾断面(见图3)作为研究对象来检验各方法的有效性。长江口水量丰沛,输沙量大。据大通站水文测验资料可知,其年均流量

为  $2.87 \times 10^4 \text{ m}^3/\text{s}$ , 年均输沙量为  $4.33 \times 10^8 \text{ t}$ <sup>[22]</sup>。徐六泾断面距长江口门约 110 km, 既是南支、北支的分流点, 又是整个长江口多级分汊的起点。作为长江进入河口区的重要边界点, 徐六泾断面的流量研究不仅对河口科学的研究本身非常重要, 而且对探讨长江三峡大坝、南水北调和长江口深水航道等重大工程对河口地区的影响都显得非常重要。

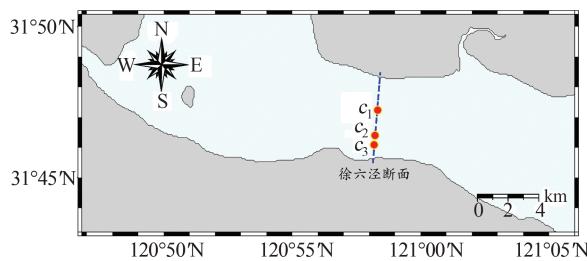


图 3 实验区域

Fig. 3 Study Area

采用多垂线方法获取徐六泾断面的实时流量。本文实验将 3 台 RDI 公司生产的 300 kHz 的四探头声学多普勒流速剖面仪(acoustic Doppler current profiler, ADCP)布设在徐六泾断面作为固定垂线, 仪器布设位置如图 3 所示。仪器设置的水深单元长度为 1.0 m, 采样间隔为 0.5 h。根据 3 台 ADCP 获得的每 0.5 h 一组的流速剖面数据, 采用多垂线模型进行断面流量实时估计, 流量估计精度均优于 5%。具体的实验布设方案及多垂线流量实时估计方法详见参考文献[6]。

为了检验存在流量差异情况下不同年份的各流量预报模型的效果, 本文选取了徐六泾断面 2012 年和 2020 年全年的逐半时(0.5 h)的流量数据作为研究对象。对于传统的调和分析方法, 预报流量的时段为每个月的最后一天, 而每个月其余天数的流量数据用于调和常数的计算; 对于 BP 神经网络方法和本文提出的 VMD-BP 神经网络组合模型方法, 将 2012 年数据作为训练集, 2020 年数据作为测试集来检验模型的预报效果。

## 2.2 数据预处理

对 2012 年和 2020 年的原始流量数据进行潮流调和分析, 将其分解为潮流流量和余流流量两部分。2012-01-01—01-03、2012 年 1 月及 2012 年整年, 即短期、中期及长期原始流量的调和分析结果如图 4 所示。此外, 为了进行 BP 神经网络模型训练, 还需对所有流量数据集进行划分, 从 2012-01-01 开始, 以每 3 d 的流量划为一组, 其中输入数据为前两天流量, 输出数据为第 3 天的流量。

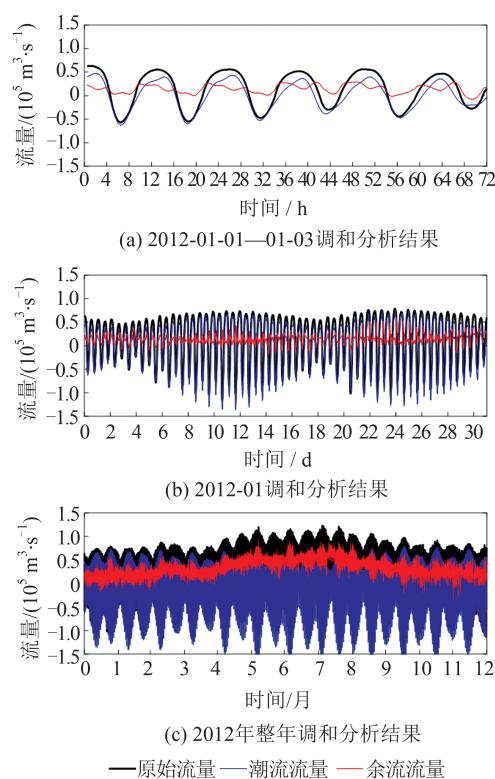
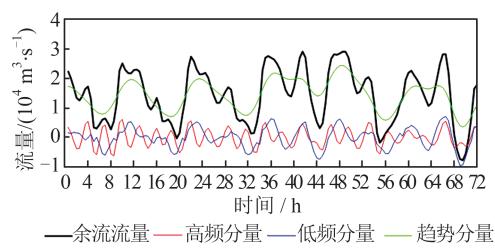


图 4 短期、中期及长期的原始流量调和分析结果

Fig. 4 Harmonic Analysis of Raw Flow Results of Short-Term, Medium-Term and Long-Term

利用 VMD 对余流数据进行分解, 与其他数据处理方法相比, 本文利用 VMD 变分模态分解将余流指定分解成 3 个分量 IMF1、IMF2 和 IMF3(即分解模态数  $k=3$ ), VMD 模型中的数据保真度约束的平衡参数 alpha 设置为默认值 2 000。

图 5 为徐六泾断面 3 天的余流流量进行 VMD 分解后的示意图, 根据其波动特征将其划分为高频分量、低频分量及趋势分量。趋势分量反映的是余流的波动趋势; 低频分量波动性不强, 反映的是余流波动的细节; 高频分量波动性较强, 反映的是余流中其他因素引起的波动。

图 5 余流流量的 VMD 分解  
Fig. 5 VMD Decomposition of Residual Discharge

感潮河段流量的数值范围分布较广, 极大值和极小值差异较大。因此, 为了减少流量数值分布对 BP 神经网络的影响, 提高 BP 神经网络的收敛速度, 需要对流量数据集进行归一化处理, 即

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{(x_{\max} - x_{\min}) + y_{\min}} \quad (15)$$

式中,  $x$  为输入数据;  $y$  为归一化输出数据。通过式(16)可将所有流量数据归一化到  $[-1, 1]$ 。

本文的 BP 神经网络结构采用比较稳定的三层网络结构, 而隐藏神经元个数一般通过经验公式计算得出<sup>[23]</sup>, 即

$$l = \sqrt{n + m} + a \quad (16)$$

式中,  $l$  为隐藏层的神经元的个数;  $n$  为输入层的节点数;  $m$  为输出层的节点数;  $a$  为  $[1, 10]$  的某一整数经验值。本文的 BP 神经网络的参数设置见表 1。

表 1 BP 神经网络的参数设置

Tab. 1 Parameter Setting of BP Neural Network

网络结构( $n \times l \times m$ )	参数	参数设置
$96 \times 15 \times 48$	迭代次数	1 000
	学习速率	0.01
	期望误差	0.000 1
	传递函数	tansig( )

### 3 实验结果与分析

#### 3.1 精度评价指标

本文采用均方根误差(root mean square error, RMSE)和相对标准偏差(relative standard deviation, RSD)作为模型的精度评价指标。

均方根误差  $E_{\text{RMSE}}$  是用来描述观测值与预报值之间的偏差, 即:

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (17)$$

式中,  $x_i$  为观测值;  $y_i$  为预报值。

为评价不同潮汐阶段流量差异较大情况下的预报精度, 通常可采用均方根误差与平均值的比值进行精度评定, 即相对标准偏差  $E_{\text{RSD}}$ :

$$E_{\text{RSD}} = \frac{E_{\text{RMSE}}}{\bar{x}} \times 100\% \quad (18)$$

由于感潮河段流量值有正有负(一般取落潮流量为正值, 涨潮流量为负值), 因此,  $\bar{|x|}$  为观测值  $x$  取绝对值后的平均。

#### 3.2 BP 神经网络训练

图 6 展示了利用 BP 神经网络对 2020-01-03 全天原始流量、潮流流量及余流流量的预报结果, 图中精度指标为全年预报的结果。

由图 6 可以看出:(1)与其他两组流量数据相比, 潮流流量的训练结果比较稳定, 其主要原因是有规律

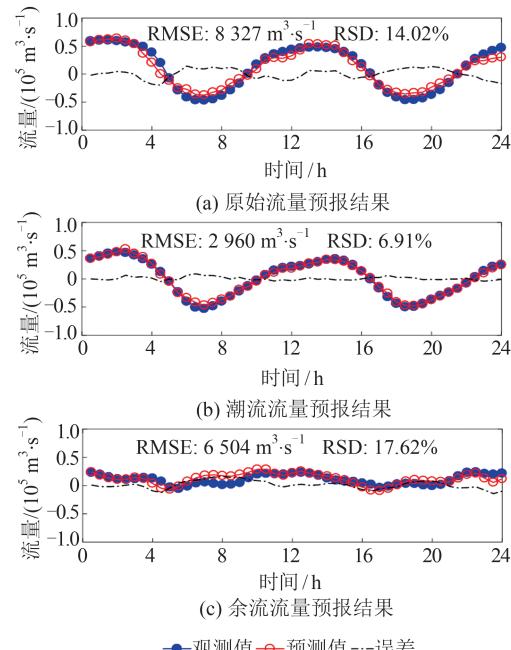


图 6 2020-01-03 全天原始、潮流、余流数据集的 BP 神经网络预报结果

Fig. 6 Prediction Results of BP Neural Network of Origin, Current and Residual Datasets in Jan.3, 2020

性和周期性, 各个分潮叠加之后的结果便是潮流。(2)余流流量的 RMSE 较原始流量的更小, 但是由于余流数据分布较集中, 均值也较小, 因此, RMSE 和余流均值的比值 RSD 反而较大, 其预报结果较差。(3)BP 神经网络主要在对非线性的余流流量进行拟合时效果不理想, 因此余流流量的预报误差是主要误差来源。

以上结果表明, 感潮河段流量预报结果的好坏严重依赖于余流流量的预报精度。因此, 需要采用 VMD 变分模态分解对余流流量序列进行降噪与平稳化处理。

#### 3.3 VMD 变分模态分解

对余流流量进行 VMD 变分模态分解后, 将得到的趋势分量、高频分量及低频分量进行 BP 神经网络训练, 各分量预报的结果如图 7 所示。由图 7 可知, 趋势分量的预报效果整体来说较平稳, 在前半天预报误差较大, 但预报效果相比余流整体来说有所提升; 高频分量与低频分量的预报精度则明显较高, 二者的数据分布范围也相对于趋势分量来说较集中。因此, 从对余流预报结果的总体影响上考虑, 高频与低频分量并不是预报精度的主要影响因素。

#### 3.4 方法比较

图 8 展示了 VMD 重构后的余流 BP 神经网络预报结果, 对比图 6、图 8 结果可知, 对余流流量

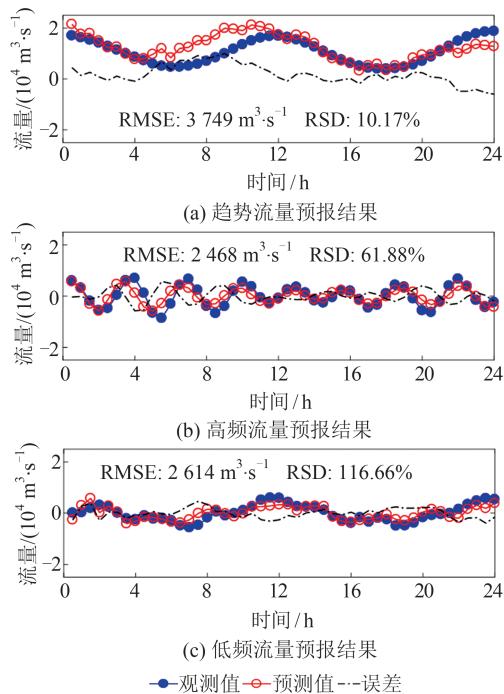


图 7 趋势、高频、低频数据集的BP神经网络预报

Fig. 7 Prediction Results of BP Neural Network of Trend, High Frequency and Residual Low Frequency Datasets

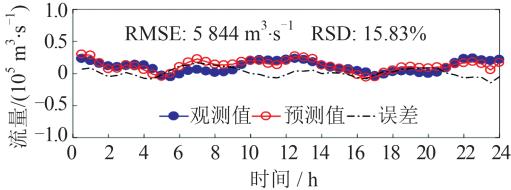


图 8 VMD 重构后的余流 BP 神经网络预报结果

Fig. 8 BP Neural Network Prediction Results of Residual Discharge After VMD Reconstruction

进行VMD分解后得到的趋势、低频和高频3个分量经过叠加重构后,组合模型预报的RMSE相对单一BP神经网络结果减小约20%,相应的相对标准偏差RSD降低了约3%,说明本文的VMD-BP组合模型流量预报精度显著提高。

另外,将图8所示的余流流量与图6中的潮流流量预报结果叠加重构,可得到总流量的预报结果,如图9所示。相比于图6所示的采用单一BP神经网络的预报结果,本文提出的基于潮流调和分析和VMD-BP神经网络组合模型法的RMSE和RSD这两个精度指标均得到提高,预报曲线也更符合感潮河段实际的流量变化趋势。

为进一步分析各种方法在不同潮汐时段(大潮、中潮和小潮)对应的不同流量大小下的预报效果,本文选取了2020年01-01—01-03(小潮)、01-08—01-10(大潮)以及01-20—01-22(中潮)这3个典型潮汐时段各3天的流量数据作为研究对

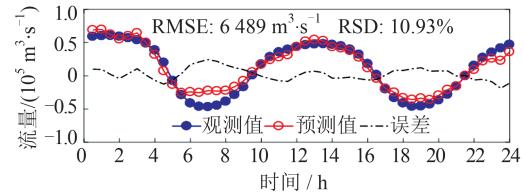


图9 基于潮流调和分析及VMD-BP神经网络组合模型的原始流量预报结果

Fig. 9 Prediction Results of Original Discharge Based on Current Harmonic Analysis and VMD-BP Neural Network Combination Model

象(前两天数据用于建模,第3天数据用于预报验证),然后分别采用潮流调和分析方法、单一BP神经网络方法以及本文的VMD-BP神经网络组合模型进行流量预报,结果如图10所示。

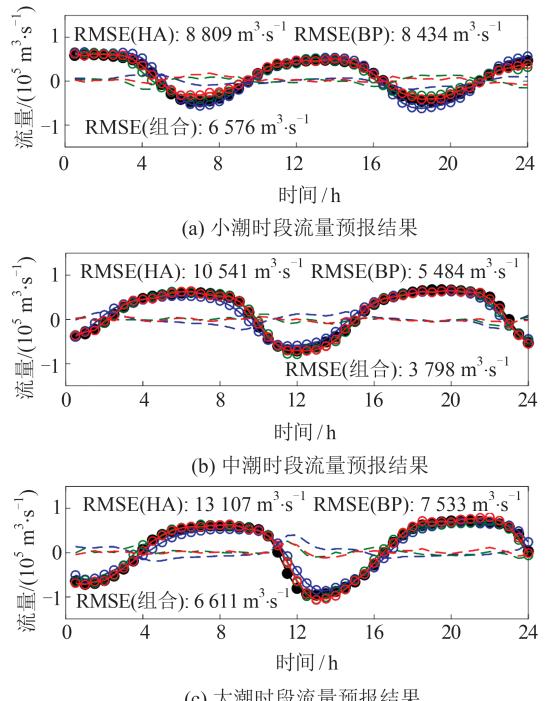


图10 小潮、中潮及大潮时段3种方法的流量预报结果

Fig. 10 Forecast Results Using Three Methods in Three Periods

由图10可知:(1)潮流调和分析方法对小潮流量预报效果较好,但对于中潮与大潮的流量预报效果并不理想,特别是大潮流量的预报误差高达 $13 107 \text{ m}^3/\text{s}$ 。由于潮流调和分析方法的本质是根据前两天的潮流变化拟合调和常数并用来预报后一天的潮流趋势,而大潮时期各观测时刻间(0.5 h)的流量变化较大。因此,从预报结果也可以看出,潮流调和分析预报的精度也随着引潮力的增强而显著下降。(2)相较于潮流调和分析方法,单一

BP神经网络方法在小潮时段的流量预报精度提升并不明显,但在潮汐作用较大的中潮与大潮时段的预报精度则显著提高。原因是在样本足够的情况下,BP神经网络就能在进行训练时能无限逼近于潮流量变化的非线性连续函数,经过不断的自学习与自适应,尽可能提取并建构输入数据与输出数据之间的规则,即表现为BP神经网络强大的非线性拟合能力。因此,BP神经网络能较好地模拟潮汐变化导致的流量周期性(非线性)变化。(3)本文组合方法的预报精度在3个时段均明显优于传统的两种方法,特别是在中潮时段其预报精度显著提升,预报曲线和实际的流量曲线吻合的很好,表明了本文方法在感潮河段的实用性。

为验证各流量预报方法的稳健性,实验分别采用上述3种方法对徐六泾2020年全年流量进行预报,其中潮流调和分析方法采用分月预报,即每月预报最后一天,然后对12个月的预报结果计算RMSE和RSD的均值;单一BP神经网络方法和本文组合方法则均重复运行了100次并计算预报结果的平均值,结果如表2所示。

表2 3种方法的流量预报结果

Tab. 2 Discharge Prediction of Three Methods

方法	RMSE/(m <sup>3</sup> ·s <sup>-1</sup> )	RSD/%
潮流调和分析	11 819	19.90
BP神经网络*	8 427	14.18
本文组合方法*	6 786	11.42

注:\*表示模型运行100次后取得的均值。

由表2可知,传统的潮流调和分析方法的流量预报精度为11 819 m<sup>3</sup>/s,其相对误差接近20%;BP神经网络方法的流量预报RMSE为8 427 m<sup>3</sup>/s,相对误差约为14%,相比潮流调和分析方法分别提高了约3 400 m<sup>3</sup>/s和6%;本文提出的基于潮流调和分析及VMD-BP神经网络组合模型方法的流量预报精度为6 786 m<sup>3</sup>/s,比BP神经网络方法的精度又提高了约3%,验证了本文方法的有效性。同时,该对比实验结果也表明,感潮河段的潮汐潮流涨落多变,采用传统方法进行流量预报难度较大。本文方法在结合传统潮流调和分析方法和BP神经网络方法的优点上引进了VMD变分模态分解,有效地降低了感潮河段流量数据的波动性和非线性,显著提高了流量预报的精度。

## 4 结语

本文根据感潮河段流量的时序变化特点,结

合变分模态分解VMD处理非平稳信号的能力与BP神经网络处理非线性拟合的优势,提出在潮流调和分析基础上进行VMD-BP神经网络组合模型训练的感潮河段流量预报方法。在长江口徐六泾断面开展的流量预报实验结果表明:(1)本文组合模型法的流量预报精度相对于传统的潮流调和分析方法提高了5 000 m<sup>3</sup>/s,相对精度提高了9%;相对于单一的BP神经网络方法,其精度则提高了约3%。对于年均流量为2.87×10<sup>4</sup> m<sup>3</sup>/s的长江口这种大型感潮河段来说,较小的相对精度提高同样必要且有意义。(2)本文所提出的流量预报组合模型避免了传统调和分析预报方法受观测时段长短影响显著的缺点,并利用调和分析能有效分离余弦潮波的能力,结合BP神经网络出色的非线性拟合能力与VMD的分解降噪优势,实现了感潮河段流量的精确预报。(3)本文所提出的流量预报模型需以水文站长期流量监测数据为基础进行训练,但模型训练结束后,则只需短时间的流量数据便可进行流量预报。下一步若想进一步提升预报精度,则可引入更多变量(水文要素),例如将感潮河段的上游河段流量(未受潮汐影响的径流流量,如长江大通水文站流量)作为影响因素,或是采用更长时段的流量观测数据作为模型训练基础。

## 参 考 文 献

- [1] Wu Lingli. Study on Determination of Design Water Level Method and Water Level Forecast in Tidal Reach[D]. Nanjing: Hohai University, 2006. (吴玲莉. 感潮河段设计水位方法确定与水位预报研究[D]. 南京: 河海大学, 2006.)
- [2] Xiong L H, O'Connor K M. Comparison of Four Updating Models for Real-Time River Flow Forecasting [J]. *Hydrological Sciences Journal*, 2002, 47(4): 621-639.
- [3] Chen Zhigao. Construction of Local Spatiotemporal Flow Field and Accurate Estimation of Real-Time Flow in the Yangtze River Estuary[D]. Wuhan: Wuhan University, 2015. (陈志高. 长江口局域时空流场构建及实时流量精确估计[D]. 武汉: 武汉大学, 2015.)
- [4] Fang Guohong. Analysis and Forecast of Tides and Tidal Currents [M]. Beijing: Ocean Press, 1986. (方国洪. 潮汐和潮流的分析和预报[M]. 北京: 海洋出版社, 1986.)
- [5] Tang Yan, Bao Jingyang, Liu Yanchun, et al. Research on Orthogonal Response Analysis of Tide and Current Using Short Term Data[J]. *Geomatics and*

- Information Science of Wuhan University*, 2010, 35(10): 1151-1156. (唐岩, 暴景阳, 刘雁春, 等. 短期潮汐潮流数据的正交潮响应分析研究[J]. 武汉大学学报(信息科学版), 2010, 35(10): 1151-1156.)
- [6] Zhao J H, Chen Z G, Zhang H M, et al. Multiprofile Discharge Estimation in the Tidal Reach of Yangtze Estuary [J]. *Journal of Hydraulic Engineering*, 2016, 142(12): 04016056.
- [7] Qi Dehu, Kang Jichang. On Design of the BP Neural Network [J]. *Computer Engineering and Design*, 1998, 19(2): 48-50. (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.)
- [8] Criswell J A., Lin E B. River Flow Forecasting Using An Inverse Wavelet Transform Neural Network Approach [J]. *International Journal of Applied Mathematics, Computational Science and Systems Engineering*, 2021, 3:67-70.
- [9] Yao Zhen, Xu Jiping, Kong Jianlei, et al. Prediction of River Water Level by GA-Elman Model [J]. *Journal of Yangtze River Scientific Research Institute*, 2018, 35(9): 34-37. (要震, 许继平, 孔建磊, 等. 基于GA-Elman的河流水位预测方法研究[J]. 长江科学院院报, 2018, 35(9): 34-37.)
- [10] Hecht-Nielsen R. Theory of the Backpropagation Neural Network [M]. Amsterdam: Elsevier, 1992.
- [11] Wang Yan, Wang Chuanhai, Wang Ni, et al. Application of BP Neural Network in Tidal River Hydrodynamic Flood Forecasting [J]. *Water Power*, 2016, 42(2): 21-25. (王炎, 王船海, 王妮, 等. BP 神经网络在感潮河段水动力洪水预报中的应用[J]. 水力发电, 2016, 42(2): 21-25.)
- [12] Qin Siyuan, Li Jinjun, Long Bingxin, et al. Tide Forecast Model Based on GPOS-BP Neural Network [J]. *Marine Information*, 2020, 35(2): 1-5. (秦思远, 李进军, 龙冰心, 等. 基于GPOS-BP神经网络模型的潮汐预报[J]. 海洋信息, 2020, 35(2): 1-5.)
- [13] Zhang Feng, Wang Qi, Lu Mei, et al. Study of Tidal Current Prediction Based on Artificial Neural Network [J]. *Marine Forecasts*, 2018, 35(4): 41-46. (张峰, 王琪, 卢美, 等. 基于人工神经网络的海流预报研究[J]. 海洋预报, 2018, 35(4): 41-46.)
- [14] Elganiny M A, Eldwer A E. Enhancing the Forecasting of Monthly Streamflow in the Main Key Stations of the River Nile Basin [J]. *Water Resources*, 2018, 45(5): 660-671.
- [15] Hidayat H, Hoitink A J F, Sassi M G, et al. Prediction of Discharge in a Tidal River Using Artificial Neural Networks [J]. *Journal of Hydrologic Engineering*, 2014, 19(8): 04014006.
- [16] Dragomiretskiy K, Zosso D. Variational Mode Decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [17] Huang N E, Shen Z, Long S R, et al. The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Non-stationary Time Series Analysis [J]. *Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903-995.
- [18] Wan Meng. Study on Residual Current Characteristics and Its Influencing Factors in Xiangshan Port [D]. Hangzhou: Zhejiang University, 2015. (万猛. 象山港余流特征及其影响因素研究[D]. 杭州: 浙江大学, 2015.)
- [19] Zhao Lixue. Study on Forecasting Method of River Water Level and Discharge Based on Hybrid BP Neural Network [D]. Wuhan: Wuhan University of Technology, 2019. (赵力学. 基于混合BP神经网络的河流水位流量预测方法研究[D]. 武汉: 武汉理工大学, 2019.)
- [20] Zhang Hongmei, Huang Jiayong, Zhao Jianhu, et al. An Improved Tidal Current Separation Method of Radial Basis Function Using Gradient Training [J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(12): 1811-1817. (张红梅, 黄家勇, 赵建虎, 等. 基于梯度训练法的径向基函数潮流分离方法[J]. 武汉大学学报(信息科学版), 2017, 42(12): 1811-1817.)
- [21] Luo Yiyong, Huang Cheng, Zhang Jingying. Denoising Method of Deformation Monitoring Data Based on Variational Mode Decomposition [J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(5): 784-790. (罗亦泳, 黄城, 张静影. 基于变分模态分解的变形监测数据去噪方法[J]. 武汉大学学报(信息科学版), 2020, 45(5): 784-790.)
- [22] Wang Yaping, Pan Shaoming, Wang H V, et al. Measurements and Analysis of Water Discharges and Suspended Sediment Fluxes in Changjiang Estuary [J]. *Acta Geographica Sinica*, 2006, 61(1): 35-46. (汪亚平, 潘少明, 王H V, 等. 长江口水沙入海通量的观测与分析[J]. 地理学报, 2006, 61(1): 35-46.)
- [23] Shen Huayu, Wang Zhaoxia, Gao Chengyao, et al. Determining the number of BP neural network hidden layer units [J]. *Journal of TianJin University of Technology*, 2008, 24(5): 13-15. (沈花玉, 王兆霞, 高成耀, 等. BP 神经网络隐含层单元数的确定[J]. 天津理工大学学报, 2008, 24(5): 13-15.)