

DOI: 10.19322/j.cnki.issn.1006-4710.2016.04.017

改进 BP 神经网络算法在中小流域洪水 预报中的应用研究

王建金¹, 石朋^{1,2}, 瞿思敏¹, 肖紫薇¹, 戴韵秋¹, 陈颖冰¹, 陈星宇¹

(1. 河海大学 水文水资源学院, 江苏 南京 210098;

2. 河海大学 水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098)

摘要: 定安河流域位于海南省的中部, 是万泉河的一级支流, 属于典型的中小流域。针对利用 BP 神经网络进行洪水预报时预报结果不平滑、冒异常值等问题, 在考虑水文过程性质的基础上, 提出了多时段综合算法和修匀算法。选取海南省定安河流域作为研究区域, 采用深层前向 BP 神经网络, 构建多组预报方案进行对比分析。结果表明, 本文所提方法可以弥补原有算法的不足, 提高洪水预报精度, 作为传统预报方式的有益参照, 具有较好的实用价值。

关键词: 洪水预报; BP 神经网络; 模型改进; 定安河流域

中图分类号: P338

文献标志码: A

文章编号: 1006-4710(2016)04-0475-06

Application of improved BP neural network algorithm in flood forecasting in the middle and small watershed

WANG Jianjin¹, SHI Peng^{1,2}, QU Simin¹, XIAO Ziwei¹, DAI Yunqiu¹,
CHEN Yingbing¹, CHEN Xingyu¹

(1. College of Hydrology and Water Resources, Hohai University, Nanjing 210098, China;

2. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University,
Nanjing 210098, China)

Abstract: Dingan river watershed, one of the primary tributary of Wanquan River and located at the central part of Hainan Province, is a typical middle and small watershed. Aiming at solving the problems of prediction results unsmooth and in risk presenting outliers when using BP neural network flood forecasting, the multi-time synthesis algorithm and smoothing algorithm are proposed considering the characteristics of hydrological processes. Selecting the Dingan River watershed of Hainan province as the study area and adopting multiplayer feed-forward BP neural network are to build several different plans for comparison and analysis. The results show that the proposed method can be used to compensate for the deficiency of the original algorithm in improving the accuracy of flood forecasting, with a good practical value as a useful reference for the traditional forecasting methods.

Key words: flood forecasting; BP neural network; model improvement; Dingan River watershed

洪水预报作为一种重要的防洪非工程措施, 预报的精度直接影响着水利工程的调度运行以及防汛抢险措施的开展^[1]。中小流域相对于大流域, 防洪基础设施建设缓慢, 地域差异较大, 具有历时短、汇流快, 容易成灾等特性^[2], 对当地的人民群众的生命财产安全造成极大的影响。寻求更为精准的短期预报方式

以达到趋利避害的目的是水利工作者不断努力的方向之一。

BP 神经网络作为从模式识别领域引进的一种智能算法, 在处理非线性系统中展现出优异的特性, 在学习数据充足的情况下, 可以精准的重现出目标结果, 在河川水质的分类、水文洪水过程预报、水资源规

收稿日期: 2016-03-29

基金项目: 国家自然科学基金资助项目(51479062, 41371048); 中央高校基本科研业务费专项资金资助项目(2015B14314)

作者简介: 王建金, 男, 硕士生, 研究方向为水文物理规律模拟及水文预报。E-mail: qiudyonly@163.com

通讯作者: 石朋, 男, 教授, 博士, 研究方向为流域水文模拟。E-mail: ship@hhu.edu.cn

划与管理等众多水利工程领域^[3-5]多有涉及。为了进一步增强 BP 神经网络预测的准确性,众多学者在网络结构、学习速率、激发函数等方面提出了大量的改进措施^[6],神经网络算法与粒子群算法、遗传算法等相结合的预报方法也越来越多的得到了应用^[7-9],但这些改进通常为算法本身的改进,结合水文预报特性开展的算法改进还有待进一步研究。

1 算法改进

本文选取目前应用最为广泛的 BP 神经网络^[10-11]作为研究对象,首先综合多种现有改进算法构建基准模型,然后结合水文物理规律进一步改进算法,并选取实际流域构建多种方案与基准模型的预报结果进行对比分析,得出最终结论。

1.1 基本改进算法

1) 初始化网络。为避免编程中常见的伪随机数问题,本文基于当前时刻毫秒对应的随机算子产生多组位于 $[-0.5, 0.5]$ 的随机数进行初始化网络,由试算结果筛选其中表现最佳的一组结果开展后续研究,达到全局寻优的目标。

2) 附加动量项。本文网络所有权值和阈值的修正过程均引入动量系数,该系数一般设为略大于学习速率。BP 神经网络算法在计算修正量时,采用最速下降法的思想,当本次修正方向与上一次修正方向相反时,若修正过度,网络可能发生震荡导致学习失败。为加速网络收敛并确保稳定性,本次修正量计算时同时考虑上一次的修正结果,修正方式如下:

$$\Delta w_{ij}(n) = -\beta \frac{\partial E(n)}{\partial w_{ij}} + \eta \Delta w_{ij}(n-1) \quad (1)$$

$$\Delta \theta_i(n) = -\beta \frac{\partial E(n)}{\partial \theta_i} + \eta \Delta \theta_i(n-1) \quad (2)$$

式中, n 为当前训练次数, $E(n)$ 为第 n 次训练时的误差, β 为学习速率, η 为动量修正系数, w_{ij} 为当前层第 i 个节点到下一层网络第 j 个节点的连接权值, θ_i 为当前层第 i 个节点对应的阈值。

3) 学习速率自适应。网络的收敛速率受学习速率的影响极大,误差较大时,较快的学习速率有助于加快收敛,但当误差较小时过快的学习速率则可能导致网络震荡,因此应用自适应学习速率的神经网络逐渐成为主流。本文选取与目标误差距离为 $[2, 5]$ 倍的区间与初始学习速率构建 $[0.25, 2]$ 倍的正比例函数,选取整数倍的数值组成倍比系数数组,计算误差超出该区间时取区间边界值,自适应方式如下:

$$\beta(n) = \begin{cases} k_{12}\beta_0, E(n) \leq k_{11}E_{dis} \\ k_{22}\beta_0, k_{11}E_{dis} \leq E(n) < k_{21}E_{dis} \\ \vdots \\ k_{(m-1)2}\beta_0, k_{(m-1)1}E_{dis} \leq E(n) < k_{m1}E_{dis} \\ k_{m2}\beta_0, k_{m1}E_{dis} \leq E(n) \end{cases} \quad (3)$$

式中: E_{dis} 为目标误差, β_0 为初始学习速率, k_{m1} 为第 m 项距目标误差的倍比系数, k_{m2} 为 k_{m1} 对应的学习速率修正系数, k_{m1} 和 k_{m2} 随着 m 增大而增大, k_{m1} 倍比关系越大, k_{m1} 的学习速率越快。

1.2 结合水文物理规律的改进算法

1.2.1 实时过程修匀

BP 神经网络在开展预报时,各时段的预报结果经由单独的模型输入分别计算,因而水文过程的连续性特征无法得到充足保证。相较于实测过程,预报过程存在小幅的波动是可以接受的,但个别时段偶发的冒特异值问题则值得关注。若预报中存在偏大的特异值,通常只会认为是该时段预报的精度不佳,但若是严重偏小的特异值如图 1 所示,则会被直接判定为该时段预报失败,结果无法采用,当此类情况发生在洪峰附近时问题就会更为严重。

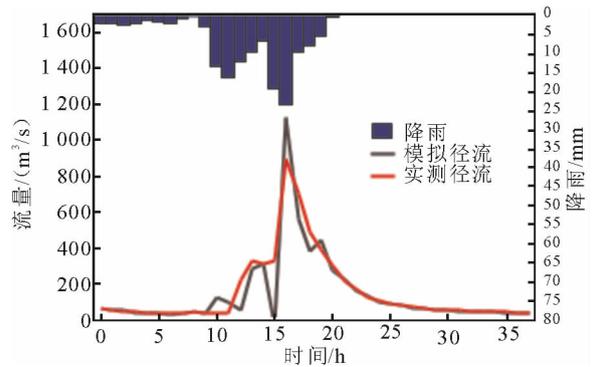


图 1 预报结果特异值示意图

Fig. 1 Forecasting outliers schematic diagram

本文将相较实测偏小的特异值定义为不合理的下降,结合多时段预报的做法进行修匀来达到水文过程具有连续性的目的,修匀方式如下:

$$Q(t) = \begin{cases} Q_{min} + k_2 \times (Q_{max} - Q_{min}), & (Q_{max} \leq Q_{min} \times (1 + k_1)) \\ Q_{min} \times (1 + k_1), & (Q_{max} > Q_{min} \times (1 + k_1)) \end{cases} \quad (4)$$

$$Q_{max} = \max(Q_1(t-1), Q_2(t)),$$

$$Q_{min} = \min(Q_1(t-1), Q_2(t)) \quad (5)$$

式中: $Q_1(t-1)$ 为 $t-1$ 时刻的预报值或实测值, $Q_2(t)$ 为 t 时刻对 $t+1$ 时刻的预报值, k_1 为修正幅度限制系数,防止偶发的错误修正时对结果影响过大,

k_2 为线性修正比例系数,根据当地涨退水过程特性而定,取 0.5 时等同于算术平均,也可采用插值算法各时段动态求解。

1.2.2 时段综合预报

中小流域洪水预报通常为短历时预报,由当前时刻对未来多个时段开展预报,其中最近时刻的预报结果通常最为重要。在这种情况下,靠后时段的预报结果得不到充分利用,大量有用的信息会被浪费掉,如果将各个时段的预报结果进行综合,进一步提高最近时刻预报结果的可靠性则显得更有价值。以 3 时段预报为例, t 时刻可同时得到当前时刻预报结果 $Q_1(t)$ 以及 $t-1$ 时刻和 $t-2$ 时刻对 t 时刻的预报结果 $Q_2(t-1)$ 以及 $Q_3(t-2)$,按各时段预报结果可靠性构建相加总和为 1 的权重系数进行均化处理,可以得到更为稳定的预报结果, n 时段综合修正公式如下:

$$Q'_1(t) = k_1 Q_1(t) + k_2 Q_2(t-1) + \dots + k_n Q_n(t-n+1) \quad (6)$$

式中: $Q_n(t-n+1)$ 为 $t-n+1$ 时段做出的第 n 个时刻的预报结果, k_n 为第 n 个时刻预报结果可靠性的权重。

2 算法验证

2.1 研究区概况

定安河流域位于海南的中部,是万泉河的一级支流,属于源头性流域,受水利工程影响较小。气象条件为热带季风气候,雨量丰沛,每年 5~11 月为多雨季节,11 月至第二年 4 月为少雨季节,年平均降雨量为 1 639mm。定安河流域内共有雨量站 11 处,控制水文站为加报站,控制站集水面积为 1 257km²,属于典型的中小流域预报,流域水文站网分布见图 2。本文采用从 1998 年到 2013 年的连续水文实测资料,资料系列的长度符合应用改进 BP 神经网络模型的要求,适宜开展本次研究。

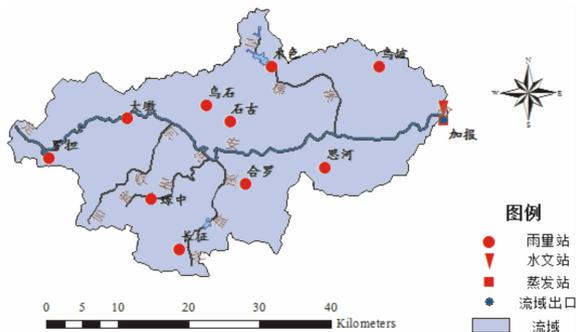


图 2 定安河流域水文站网分布图

Fig. 2 Distribution of hydrological station network in Ding'an River watershed

2.2 模型构建

理论分析证明,单隐层的神经网络可以映射所有连续函数,双隐层可以映射包括不连续函数在内的所有函数^[12]。为进一步增强非线性系统的学习能力和模型的通用性,故本文采用深层前向神经网络模型。输入层为预报时刻前 3 小时的实测流量数据和 11 个雨量站的降雨数据,输出层为预报时刻起 3 小时内的径流预报结果,双隐层节点数分别为 4 和 10,输出层激发函数选用线性叠加函数,其余层为 sigmoid 函数,采用交叉率定的有导师学习模式。

为研究结果方便展示,构建以下简写:实测流量 Q_0 、实时预报流量 Q_1 、未来 1 小时预报流量 Q_2 、未来两小时预报流量 Q_3 、 Q_1 实时流量修匀结果 Q_{1s} 、算术平均时段综合预报流量 Q_{T1} 、 Q_{T1} 预报流量修匀结果 Q_{T1s} ,共计构建 6 组预报结果开展预报效果的对比分析。

2.3 结果对比与分析

2.3.1 模型率定

模型率定采用 10 场洪水率定,10 场洪水交叉验证的方式,初始学习效率 0.1,初始动量系数 0.2,数据归一化处理时采用降雨峰值 250 mm,流量峰值 3 000 m³/s,目标误差判断准则为均方根误差,目标精度 0.01,运用多次筛选后的初始神经网络开展 25 000 次循环率定,率定过程中全局误差变化情况如图 3 所示。可见率定期和验证期的误差在迭代循环达到 5 000 次以后均趋于稳定下降的阶段,并几乎同时达到稳定优值,说明该改进深层前向 BP 神经网络较好地把握住定安河流域隐含的降雨径流非线性关系,预报结果稳定可靠。考虑到文章的篇幅,结果分析仅展示验证期的 10 场洪水模拟结果。

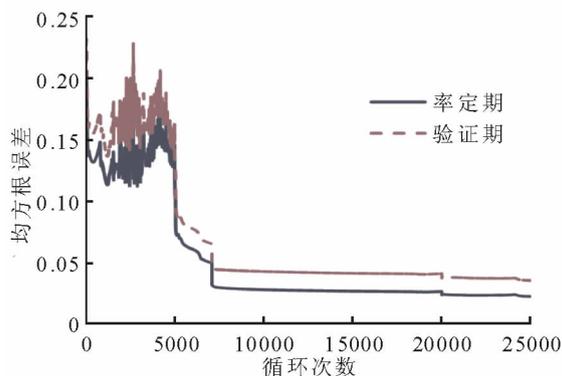


图 3 神经网络交叉验证过程全局误差变化图

Fig. 3 Global error variation of neural network cross validation process

2.3.2 洪峰精度对比分析

洪峰精度的评定采用百分比偏差,绝对值越小

代表模拟精度越高。表 1 为验证期峰精度统计表。由表 1 可知,10 场洪水平均洪峰偏差最小的是 Q_{T1} 和 Q_{TIS} ,百分比偏差为 5.81,比 $Q1$ 和 $Q1_s$ 的 8.2 小了 2.39,说明多时段综合修正对于改进深层前向 BP 网络算法的洪峰精度有一定提升。 $Q1$ 的洪峰模拟准确度优于 $Q2$ 和 $Q3$,表明中小流域出口断面流

量主要受当前时刻降雨影响,进一步推得 Q_{T1} 在时段综合过程中如果适度加大 $Q1$ 对应的权重系数,将得到更好的模拟效果。修匀算法因为是针对预报过程波动性和不合理下降而提出的,故对洪峰预报的精度不产生影响。

表 1 验证期洪峰精度统计表

Tab. 1 Accuracy of flood peak statistics in calibration period

洪号	Q0			Q1		Q2		Q3		Q1 _s		Q _{T1}		Q _{TIS}	
	流量/ (m ³ /s)	流量/ (m ³ /s)	差值/ %												
Y051006	2560	2886	12.75	2858	11.66	2669	4.24	2886	12.75	2572	0.46	2572	0.46		
Y071011	1620	1616	-0.24	1608	-0.77	1818	12.19	1616	-0.24	1481	-8.56	1481	-8.56		
Y081003	1090	1059	-2.82	1057	-3	1089	-0.1	1059	-2.82	1053	-3.41	1053	-3.41		
Y081012	2810	3088	9.9	3175	12.98	3063	9.01	3088	9.9	3004	6.9	3004	6.9		
Y090922	1860	2031	9.22	1941	4.38	2016	8.39	2031	9.22	1861	0.08	1861	0.08		
Y101012	3250	3132	-3.64	3196	-1.66	3062	-5.78	3132	-3.64	3097	-4.7	3097	-4.7		
Y110924	2460	2872	16.74	3006	22.2	2952	19.98	2872	16.74	2796	13.67	2796	13.67		
Y111107	2630	2904	10.4	2969	12.88	2854	8.54	2904	10.4	2777	5.6	2777	5.6		
Y120615	526	606	15.27	631	19.96	693	31.8	606	15.27	603	14.64	603	14.64		
Y131110	3110	3142	1.04	3202	2.96	3063	-1.5	3142	1.04	3112	0.07	3112	0.07		
平均值			8.20		9.25		10.15		8.20		5.81		5.81		

注:平均值一栏为各项绝对值的平均值,非直接相加求平均。

2.3.3 洪量精度对比分析

次洪的径流深评价指标采用偏差,验证期径流深精度统计表见表 2。由表 2 可知,验证期 10 场洪水的平均偏差各方案只有修匀修正后的结

果 $Q1_s$ 达到 15.4 mm 小于 20 mm,说明改进深层 BP 神经网络算法在水量平衡方面有待提高,依据前后时段预报流量进行修匀修正对该问题有一定的弥补作用。

表 2 验证期径流深精度统计表

Tab. 2 Accuracy of depth of runoff statistics in calibration period

洪号	Q0			Q1		Q2		Q3		Q1 _s		Q _{T1}		Q _{TIS}	
	径流深/ mm	径流深/ mm	差值/ mm	径流深/ mm	差值/ mm	径流深/ mm	差值/ mm	径流深/ mm	差值/ mm	径流深/ mm	差值/ mm	径流深/ mm	差值/ mm	径流深/ mm	差值/ mm
Y051006	223.4	198.0	-25.3	196.5	-26.9	190.0	-33.4	200.6	-22.8	194.8	-28.6	195.0	-28.3		
Y071011	253.1	216.6	-36.5	217.6	-35.5	214.6	-38.5	220.3	-32.8	216.4	-36.7	217.7	-35.4		
Y081003	86.2	77.4	-8.7	78.4	-7.8	78.2	-8.1	79.4	-6.8	78.0	-8.2	78.7	-7.5		
Y081012	433.9	419.5	-14.3	416.6	-17.5	401.2	-33.1	431.0	-2.9	412.4	-21.5	415.6	-18.2		
Y090922	319.2	307.6	-11.6	310.6	-8.9	307.5	-12.3	317.0	-2.2	308.5	-10.7	311.6	-7.6		
Y101012	561.5	528.8	-32.7	520.0	-41.5	492.9	-68.6	546.1	-15.3	513.9	-47.6	518.1	-43.4		
Y110924	547.8	489.5	-58.4	499.9	-48.1	499.8	-48.2	506.1	-41.7	496.4	-51.5	500.2	-47.7		
Y111107	165.9	145.8	-20.1	145.2	-20.7	140.6	-25.3	147.4	-18.5	143.8	-22.1	145.1	-20.8		
Y120615	60.4	53.5	-6.9	54.8	-5.7	55.9	-4.6	54.9	-5.5	54.7	-5.7	54.9	-5.5		
Y131110	255.7	245.5	-10.2	238.2	-17.6	221.2	-34.7	249.9	-5.8	235.0	-20.7	235.9	-19.8		
平均值			22.5		23.0		30.7		15.4		25.3		23.4		

注:平均值一栏为各项绝对值的平均值,非直接相加求平均。

2.3.4 纳什效率系数和峰现时差对比分析

纳什效率系数 NSE(Nash-Sutcliffe efficiency coefficient)在国内又称为确定性系数,统计结果见表 3。6 种预报方案在验证期次洪模拟时均有优异表现,NSE 平均最低为 Q3 的 0.904,最高为 Q1_s 的 0.96。由表 3 可知峰现时差 ΔT 各方案均较为准确,其中 Q_{T1} 的平均时差最小为 1.2 小时,

最大时差由 4 小时减少为 2 小时,表明时段综合算法在总体上有利于改善峰现时差和最大偏差。对于没有改善的 Y051006 和 Y081003 查询实测数据得知这两场洪水在洪峰附近的三小时流量都大体接近,相较于数千流量的洪峰几十流量的偏差导致的峰现时差可以认为不影响该算法的实际应用。

表 3 验证期纳什效率系数和峰现时差统计表

Tab. 3 Accuracy of the NSE and the error of peak time statistics in calibration period

洪号	Q1		Q2		Q3		Q1 _s		Q _{T1}		Q _{T1s}	
	$\Delta T/h$	NSE	$\Delta T/h$	NSE	$\Delta T/h$	NSE	$\Delta T/h$	NSE	$\Delta T/h$	NSE	$\Delta T/h$	NSE
Y051006	1	0.975	2	0.964	3	0.940	1	0.974	2	0.975	2	0.975
Y071011	1	0.955	-7	0.923	-6	0.874	1	0.963	1	0.939	1	0.943
Y081003	1	0.964	1	0.942	-5	0.904	1	0.964	2	0.959	2	0.960
Y081012	1	0.962	2	0.928	3	0.878	1	0.962	1	0.957	1	0.959
Y090922	-4	0.968	-2	0.955	-1	0.924	-4	0.962	-1	0.968	-1	0.966
Y101012	2	0.974	3	0.960	4	0.935	2	0.973	2	0.974	2	0.974
Y110924	-1	0.939	0	0.918	1	0.880	-1	0.932	0	0.936	0	0.935
Y111107	-1	0.974	0	0.952	1	0.898	-1	0.976	1	0.966	1	0.967
Y120615	1	0.895	2	0.889	2	0.872	1	0.917	1	0.909	1	0.911
Y131110	1	0.980	2	0.966	3	0.930	1	0.978	1	0.977	1	0.977
平均值	1.4	0.959	2.1	0.940	2.9	0.904	1.4	0.960	1.2	0.956	1.2	0.957

注:平均值一栏为各项绝对值的平均值,非直接相加求平均。

结合上文对比分析的结果可知:本文所提方法在一定程度上可以弥补原有算法的不足,具有较好

的实用价值,考虑到篇幅仅展示次洪 Y101012 的预报结果对比图,见图 4。

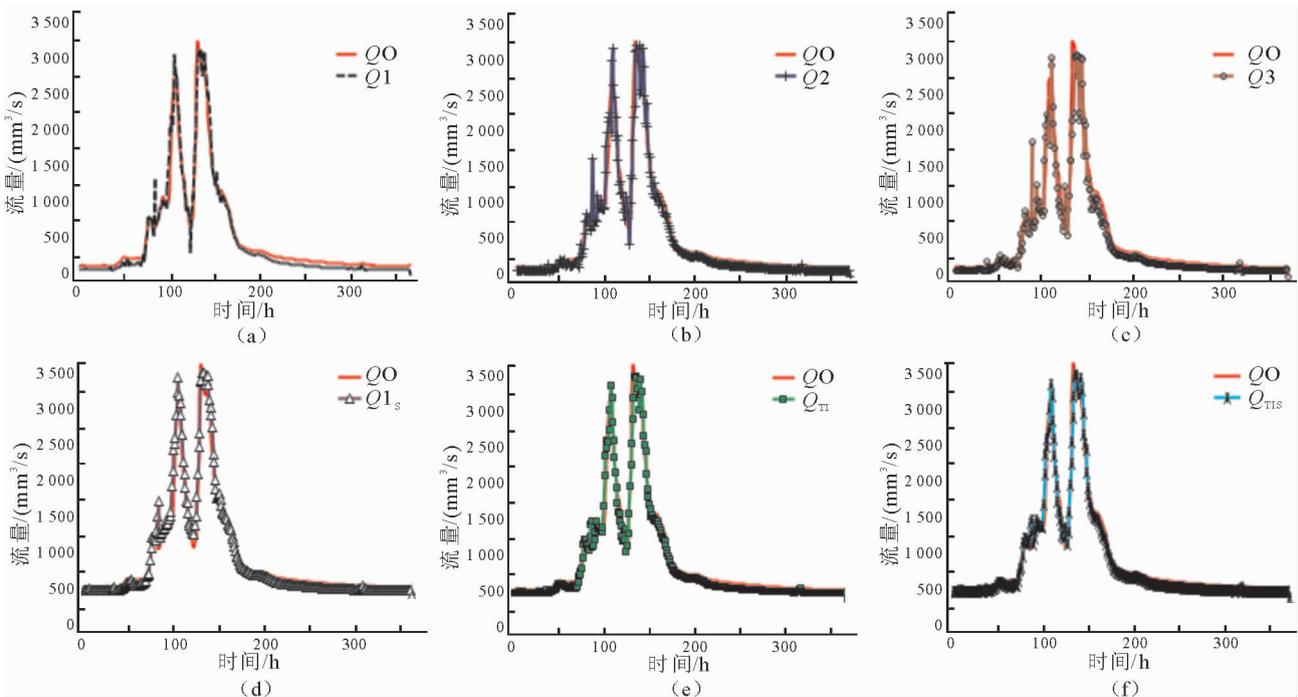


图 4 次洪 Y101012 预报结果对比图

Fig. 4 Comparison of simulated and observed streamflows in the flood Y101012

3 结论与展望

1) 应用改进 BP 深层前向神经网络算法, 在海南省定安河流域进行实例模拟, 率定网络稳定, 模拟结果基本可靠。

2) 综合考虑多个时段对未来同一时刻预报的结果, 对实时预报结果进行时段综合修正, 可以提高洪峰预报的准确性, 提升预报结果的整体稳定性。

3) 考虑前后时段预报结果, 构建修匀算法处理神经网络预报过程中不合理波动的问题, 有助于规避因冒异常值导致预报失败的情况, 同时可以使模拟的径流过程更平滑, 更符合实际水文过程, 对径流深预报的精度也有所提升。

4) 时段综合算法和修匀算法两者的预报结果各具特性, 作为传统洪水预报的有益参照, 具有较好的实用价值。

参考文献:

- [1] 包为民. 水文预报[M]. 北京: 中国水利水电出版社, 2006.
- [2] 晋磊. 中小流域洪水预报预警系统研究[D]. 郑州: 郑州大学, 2014.
JIN Lei. Research of flood forecasting and early warning system at small and middle watershed; the Shuangji River as example[D]. Zhengzhou: Zhengzhou University, 2014.
- [3] HARTMANN H, BECKER S, KING L, et al. Forecasting water levels at the Yangtze River with neural networks[J]. Erdkunde, 2008, 62(3): 231-243
- [4] ELSAFI S H. Artificial neural networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan[J]. Alexandria Engineering Journal, 2014, 53

(3): 655-662.

- [5] 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.
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.
- [6] 程玥. BP 神经网络的算法改进与应用研究[D]. 重庆: 重庆大学, 2011.
CHENG Yue. Study on improved algorithm and application of BP neural network[D]. Chongqing: Chongqing University, 2011
- [7] HOSSEINI S M, MAHJOURI N. Integrating support vector regression and a geomorphologic artificial neural network for daily rainfall-runoff modeling[J]. Applied Soft Computing, 2016, 38: 329-345.
- [8] 肖蕾, 李郁侠. 基于自适应 Elman 神经网络的短期风电功率预测[J]. 西安理工大学学报, 2014, 30(1): 102-107.
XIAO Lei, LI Yuxia. Short-term wind power prediction based on adaptive Elman neural network[J]. Journal of Xi'an University of Technology, 2014, 30(1): 102-107.
- [9] JAIN A, SRINIVASULU S. Development of effective and efficient rainfall-runoff models using integration of deterministic, real-coded genetic algorithms and artificial neural network techniques [J]. Water Resources Research, 2004, 40(4): W04302
- [10] GOVINDARAJU R S. Artificial neural networks in hydrology. I: preliminary concepts [J]. Journal of Hydrologic Engineering, 2000, 4: 115-123.
- [11] 赵林明. 多层前向人工神经网络[M]. 郑州: 黄河水利出版社, 1999.
- [12] 韩力群. 人工神经网络教程[M]. 北京: 北京邮电大学出版社, 2006.

(责任编辑 杨小丽)