

文章编号:1004-8227(2011)01-0040-08

长江上游月降水人工神经网络预测模型

冯亚文^{1,2},任国玉²,张丽¹,罗华超¹

(1. 华北水利水电学院,河南 郑州 450011; 2. 中国气象局气候研究开放实验室,国家气候中心,北京 100081)

摘要:长江上游月降水量预测对于三峡库区及整个长江流域水资源管理具有重要意义。根据长江上游不同气候区降水差异,选取玉树、九龙和宜宾3个代表性气象站点近60 a的月降水量数据,运用反向传播神经网络、径向基函数神经网络、广义回归神经网络和多元线性回归法,确定降水时滞和降水月份,建立月降水预测模型,来预测未来一个月的降水量,并采用均方误差和判定系数来验证和对比各种模型的模拟效果。结果显示:人工神经网络模型总体上优于多元线性回归,特别是反向传播神经网络的模拟结果各站表现较好,在确定合理的输入变量和网络结构后,可以尝试作为长江上游各站月降水预测模型。

关键词:长江上游流域;人工神经网络;月降水量预测;多元线性回归

文献标识码:A

长江上游流域陆面环境多样,不同地区各月降水变率相对较大。了解上游降水的变化趋势对于生态和环境建设、三峡大坝年度和季节性蓄水的调度,均具有重要现实意义^[1]。但是,如何利用历史观测资料,预测长江上游流域未来年到年代尺度的降水,还是一个探索中的问题。在已有的中、长期时间尺度降水预测研究中,多采用统计方法,其不足之处在于假定了变量之间的确定的函数关系^[2,3]。近年来,神经网络逐渐被广泛用于降水预测研究^[4~7],但主要针对短期降水预测,且对于不同神经网络模型的预测效果说法不一,针对长江上游地区间降水变率大的特点,月降水量的准确预测则更加困难,如何提高月降水量神经网络预测模型的稳定性以及预测精度,需要根据地区差异选择合适的预测模型,合理设置模型的结构和参数。

本文尝试在长江上游不同类型气候区中选一个代表性国家基准气象站点,将站点历史月降水量和时间作为预测指标,运用反向传播神经网络、径向基函数神经网络、广义回归神经网络和多元线性回归方法建立月降水量预测模型,评价不同模型在月降水预测方面的效果,选取针对各个典型站点月降水量预测的最佳方法,为该地区未来降水—径流预测及水资源管理提供参考。

1 研究区域和数据

1.1 研究区域概况

长江发源于青藏高原唐古拉山脉主峰各拉丹东雪山西南侧,长江干流湖北宜昌以上为上游(如图1),宜昌站控制长江上游流域面积100.6万km²,约占长江总流域面积的55%,上游流经青海、西藏、四川、云南、重庆、湖北6个省、自治区、直辖市。长江上游地区,由于地域辽阔,地形复杂,降水的时空分布很不均匀,以四川盆地降水较多,长江源区降水偏少,其它大部分地区年降水在600~1 100 mm^[8]。

1.2 气象站点选取和数据

根据中国气象局对中国气候区域的划分和中国年降水量图^[9],本文从江源开始依次选取降水数据连续性好且序列时间长的玉树、九龙和宜宾等3个国家基准气象站为代表站(如图1),分别代表青南—昌都高原气候区、波密—川西高原气候区和四川中亚热带气候区,各站具体位置及气象站点降水量数据起止时间见表1。

2 方法介绍

20世纪80年代至今,人工神经网络(Artificial

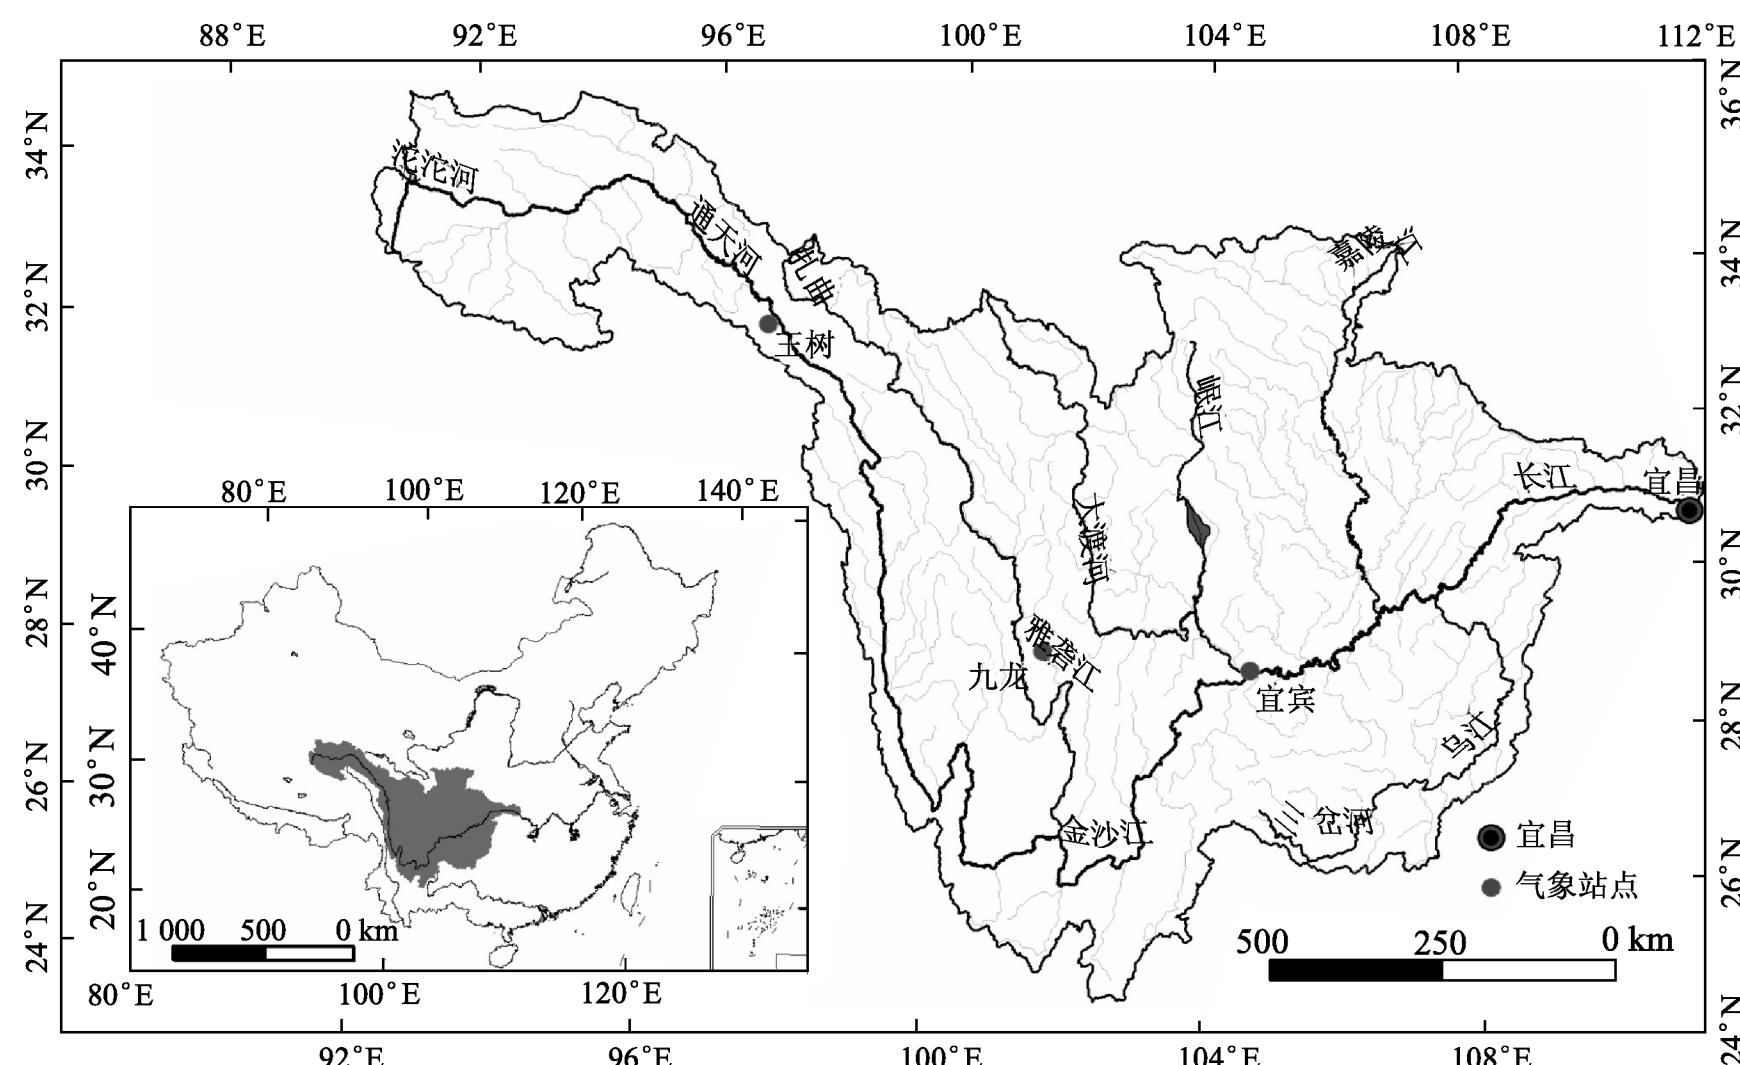


图1 研究区位置及气象站点分布

Fig. 1 Study Area and Distribution of Meteorological Stations in the Upper Yangtze River

表1 长江上游3个代表气象站年降水量数据统计特征

Tab. 1 Statistical Characteristics of the Annual Precipitation in the Selected Meteorological Stations of the Upper Yangtze River

站点	纬度 (°)	经度 (°)	海拔 (m)	起止时间	平均值 (mm)	标准差	中位数	Cv	Cs	最大值 (年份)	最小值 (年份)
玉树	33.02	97.02	3 681	1953~2008	479.3	68.4	480.5	0.14	-0.01	638.3(1989)	321.7(1983)
九龙	29.00	101.50	2 987	1953~2008	909.2	121.2	896.6	0.13	0.33	1 217.5(1965)	663.4(1994)
宜宾	28.80	104.60	341	1951~2008	1 104.2	200.2	1 118.6	0.18	0.17	1 624.8(1954)	710.4(1993)

Neural Network,简称 ANN)发展很快,代表性的网络有多层反向传播网络(Back Propagation Artificial Neural Network,简称 BP-ANN)、径向基函数神经网络(Radial Basis Function Artificial Neural Network,简称 RBF-ANN)和广义回归神经网络(Generalized Regression Artificial Neural Network,简称 GR-ANN)等。ANN 具有模拟人的形象思维的能力,是人脑的某种抽象、简化和模拟,且有自学习、自适应、自组织和概括、非线性映射、并行处理和多变量系统数据融合等特点^[10,11],使其在各学科得到了广泛应用,水文、地质、气候是 3 个使用 ANN 模型较多的学科,主要用于分类、预测、评价、模式识别、模拟和优化等研究,其中最重要的用途是预测^[12]。

BP-ANN 模型一般有一个输入层,一个或多个隐含层和一个输出层。一个 3 层的 BP 网络可以完成任意精度的 m 维到 n 维的近似映照^[10]。因此,在设计 BP 网络时应优先考虑使用 3 层神经网络结构,每层有一定数量的神经元,输入层变量的个数决

定了输入层神经元个数,隐含层神经元的个数目前没有很明确的原则,一般来说,对于 3 层 BP 网络,隐含层神经元个数为输入层神经元个数 n 的 $n \sim 2n$ 。RBF-ANN 也包含输入层、隐含层和输出层,其中在隐含层,径向基传递函数将输入向量转换为一个非线性形式的新向量,模型的输出通过纯线性传递函数计算。GR-ANN 模型在结构上与 RBF 网络较为相似^[13],它由四层构成,分别为输入层、模式层、加和层和输出层,模式层的传递函数为径向基函数,通常采用非负非线性函数高斯函数作为网络的传递函数。多元线性回归(Multiple Linear Regression,简称 MLR)是研究一个随机变量与多个变量之间相关关系的方法。

3 指标选取和 ANN 模型构建

3.1 模型输入变量及预测效果判定指标选取

对于 ANN 网络,输入变量的合理选择决定了模型试错阶段的效率。参考已有研究^[4],本文选取

以下指标为输入变量： X_{t-1} ， X_{t-2} ， X_{t-12} 和 P_t ，这里的 t 为模拟的月份， X_{t-1} 和 X_{t-2} 分别为模拟月前 1 个月和前 2 个月的降水量， X_{t-12} 为模拟月前 1 a 当月降水量， P_t 为时间参数，这里 $P_t = \sin(2\pi t/12) + \cos(2\pi t/12)$ 。

本文采用均方误差和判定系数来检验模型的有效性，其中均方误差 MSE (Mean Square Error) 和判定系数 R^2 (或称拟合优度、决定系数)^① 用下面的公式来计算：

$$MSE = \frac{\sum_{i=1}^N (P_{o,i} - P_{f,i})^2}{N} \quad (1)$$

$$R^2 = \left[\frac{\sum_{i=1}^N (P_{o,i} - \bar{P}_o)(P_{f,i} - \bar{P}_f)}{\sqrt{\sum_{i=1}^N (P_{o,i} - \bar{P}_o)^2} \sqrt{\sum_{i=1}^N (P_{f,i} - \bar{P}_f)^2}} \right] \quad (2)$$

式中： $P_{o,i}$ 为第 i 月的降水实测值； $P_{f,i}$ 为第 i 月的降水模拟值(或预测值)； N 为总的月数； \bar{P}_o 为实测月降水量的平均值； \bar{P}_f 为模拟月降水量的平均值。

3.2 ANN 模型构建

BP-ANN 隐含层神经元个数的选择：给定 BP 神经网络输入变量和输出变量，先任意选择 X_{t-1} ， X_{t-2} 和 X_{t-12} 的组合作为输入变量，之后加入时间参数 P_t ，隐含层神经元个数分别取 n 到 $2n$ (n 为输入变量的个数)之间的数，尝试获得最佳神经元数(表 2)。当 MSE 越小，同时 R^2 越大时，模型越优。BP 网络在训练时采用梯度下降算法，学习速率设为 0.005。

表 2 3 个气象站点月降水预测的 BP-ANN 模型构建

Tab. 2 BP-ANN Models Developed for Monthly Precipitation Forecasting for the Selected Stations

输入变量	隐含层神经元数	玉树		九龙		宜宾	
		MSE(mm) ²	R ²	MSE(mm) ²	R ²	MSE(mm) ²	R ²
1 X_{t-1}, X_{t-12}	3	511.03	0.73	1 616.9	0.75	3 577.7	0.55
2 X_{t-1}, X_{t-2}	3	910.12	0.53	2 602.0	0.59	4 957.0	0.37
3 X_{t-1}, X_{t-12}, P_t	4	402.43	0.79	1 341.3	0.79	2 847.0	0.64
4 X_{t-1}, X_{t-12}, P_t	5	402.09	0.79	1 244.5	0.80	2 902.3	0.64
5 X_{t-1}, X_{t-12}, P_t	6	384.02	0.80	1 398.5	0.78	2 810.5	0.65
6 $X_{t-1}, X_{t-2}, X_{t-12}$	4	521.77	0.73	1 508.8	0.76	3 405.4	0.57
7 $X_{t-1}, X_{t-2}, X_{t-12}$	5	501.08	0.74	1 469.4	0.77	3 501.3	0.56
8 $X_{t-1}, X_{t-2}, X_{t-12}$	6	464.54	0.76	1 409.2	0.78	3 429.9	0.57
9 $X_{t-1}, X_{t-2}, X_{t-12}, P_t$	4	391.00	0.79	1 100.3	0.83	2 727.8	0.66
10 $X_{t-1}, X_{t-2}, X_{t-12}, P_t$	5	406.52	0.79	1 208.8	0.81	2 640.9	0.67
11 $X_{t-1}, X_{t-2}, X_{t-12}, P_t$	6	400.42	0.79	1 116.3	0.82	2 720.3	0.66
12 $X_{t-1}, X_{t-2}, X_{t-12}, P_t$	7	365.67	0.81	1 125.2	0.82	2 731.2	0.66
13 $X_{t-1}, X_{t-2}, X_{t-12}, P_t$	8	387.52	0.80	1 106.2	0.83	2 675.9	0.66

样本数据归一化采用以下公式：

$$x_n = \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}}$$

式中： x_n 为标准化以后的数据； x_0 为原始数据； x_{\min} ， x_{\max} 分别为原始数据中最小和最大降水量。

从表 2 可以看出，加入时间参数后，模型预测的效果要比无时间参数的好，各个站点最理想的 BP 网络模型结构为：玉树站 4—7—1(#12)；九龙站 4—4—1(#9)；宜宾站 4—5—1(#10)，即采用 X_{t-1} 、 X_{t-2} 、 X_{t-12} 和时间参数 P_t 模拟的结果最好。训练完成以后，最优模型的权重和隐含层神经元个数被用于检验样本，从而测试模型的稳定性和有效性。

RBF-ANN 网络结构：RBF 网络在 3 站最适合

的隐含层神经元数经过同样尝试得到其最佳网络结构：玉树站为 4—9—1，九龙站为 4—12—1，宜宾站为 4—28—1，径向基函数分布密度为 2。

GR-ANN 网络结构为 4—x—2—1，光滑因子为 0.1；与 RBF-ANN 一样，传递函数模式层均为高斯函数，输出层均为线性函数，输入和输出层变量值为 0~1。

4 模型训练验证及结果分析

4.1 模型训练

根据确定的模型输入指标及结构，对于每个站点，月降水量数据序列被分成 2 个部分，最后 10 a

①判定系数 R^2 表示在 Y 的总平方和中，由 X 引起的平方和所占的比例。判定系数的大小决定了相关性的密切程度。 R^2 越接近 1 时，表示相关的方程式参考价值越高。

120个月的样本数据用于模型验证及模拟效果评价,其它500多个月的样本数据用于ANN训练(各站点时间序列见表1)。综合考虑 R^2 、MSE、MAE(平均绝对误差)、 a (回归系数)、 b (截距)几个指标,当 R^2 、 a 越大,MSE、MAE、 b 越小时,模型为最优。

模型训练结果见表3,玉树站GR-ANN网络最

优,其他两种神经网络较GR网络稍差一些,但都比MLR模型效果好;九龙站BP网络最优,MLR模型最差;宜宾站RBF网络表现最好,MLR模型最差。总的来看,人工神经网络要优于多元线性回归,而不同站点最佳的ANN模型不同,且宜宾站的训练结果不如玉树、九龙两站理想。

表3 神经网络及线性回归模型训练阶段的性能评价

Tab. 3 Performance Measures for the Calibration Period

	玉树				九龙				宜宾			
	BP	RBF	GR	MLR	BP	RBF	GR	MLR	BP	RBF	GR	MLR
R^2	0.80	0.80	0.83	0.66	0.83	0.80	0.80	0.72	0.68	0.70	0.66	0.50
MSE	379.41	382.26	325.40	662.68	1 105.00	1 269.10	1 235.10	1 768.50	2 549.30	2 388.90	2 742.40	4 005.10
MAE	12.54	12.73	11.68	17.08	21.60	23.93	23.74	28.77	32.68	32.09	33.83	41.93
a	0.83	0.80	0.88	0.75	0.84	0.80	0.75	0.79	0.71	0.70	0.60	0.63
b	0.01	7.90	4.80	5.40	0.00	15.00	17.00	9.10	0.02	28.00	35.00	24.00

4.2 模型检验及结果分析

各个模型性能评价结果见表4,3个站均是BP表现最优,玉树、九龙站人工神经网络总体表现比多元线性回归好,这也说明了BP网络的泛化能力较强,宜宾站BP、RBF网络比MLR模拟效果相对好一些,GR网络比MLR稍差;但宜宾站的整体预测效果不如玉树和九龙站,这可能是宜宾站平均降水

量大,各月降水变率相对较大的原因。从表3、表4模型的训练和检验也可以看出,MLR总体上预测效果虽然不如BP和RBF好,但是从判定指标可以看出,训练和检验结果值相差不大,这些说明MLR模型在稳定性方面与ANN模型相比有其一定的优势。下面将进一步分析各种模型的预测效果。

表4 神经网络及线性回归模型稳定性检验阶段的性能评价

Tab. 4 Performance Measures for the Validation Period

	玉树				九龙				宜宾			
	BP	RBF	GR	MLR	BP	RBF	GR	MLR	BP	RBF	GR	MLR
R^2	0.79	0.77	0.76	0.66	0.80	0.77	0.77	0.72	0.59	0.52	0.47	0.50
MSE	334.80	368.59	378.09	624.45	1 360.90	1 509.50	1 513.30	2 195.80	2 507.60	2 973.30	3 265.60	3 850.60
MAE	12.14	12.62	13.05	16.50	24.73	25.99	27.85	32.28	32.56	35.60	37.06	41.93
a	0.80	0.76	0.77	0.75	0.79	0.78	0.73	0.80	0.65	0.63	0.52	0.56
b	8.00	8.80	9.30	5.60	17.00	17.00	20.00	10.00	30.00	32.00	39.00	26.00

限于篇幅,这里仅给出玉树站4种模型的检验结果,如图2,3,4,5,6。为了说明模型在检验阶段的稳定性,这里画出了120个月降水量模拟值和实际观测值的对比及残差图,残差时间序列在整个检验序列中波动相似,就说明模型表现稳定。图2b,3b,4b,5b为模拟值和观测值的散点图,其线性拟合方程标于散点图之上,该方程反映了两个变量间相互依存的数量关系($y=ax+b$),回归系数 a 越接近1,截距 b 越接近0,表明依存关系越好, a 、 b 值也可参见表4。同时,为分析比较模型月降水模拟的平均误差,图6给出了各月降水的平均残差曲线。

对120个月降水的模拟值和观测值对比分析结果如下:

(1)模拟值与观测值对比:由于输入变量中加入

了时间参数,与MLR相比,其它3个神经网络模型预测的月降水量未出现无意义的负值,MLR在预测中出现无意义的负值较多。

(2)月降水量残差对比:从残差曲线可以看出,各个模型在月降水较大的月份模拟效果误差较大;MLR低估(残差为正值)月降水量最大超过了100 mm,而3种ANN都在90 mm以下,其中BP网络在80 mm以下,高估值(残差为负值)MLR达到近80 mm,ANN均在50 mm之内。

(3)模拟值和观测值的线性拟合:与RBF、GR网络相比,BP网络模拟值与观测值的回归系数较大,截距较小,模型模拟效果好;MLR与3种ANN模型相比,散点分布较不均匀。

(4)月平均降水量误差:若忽略5 mm以内的误

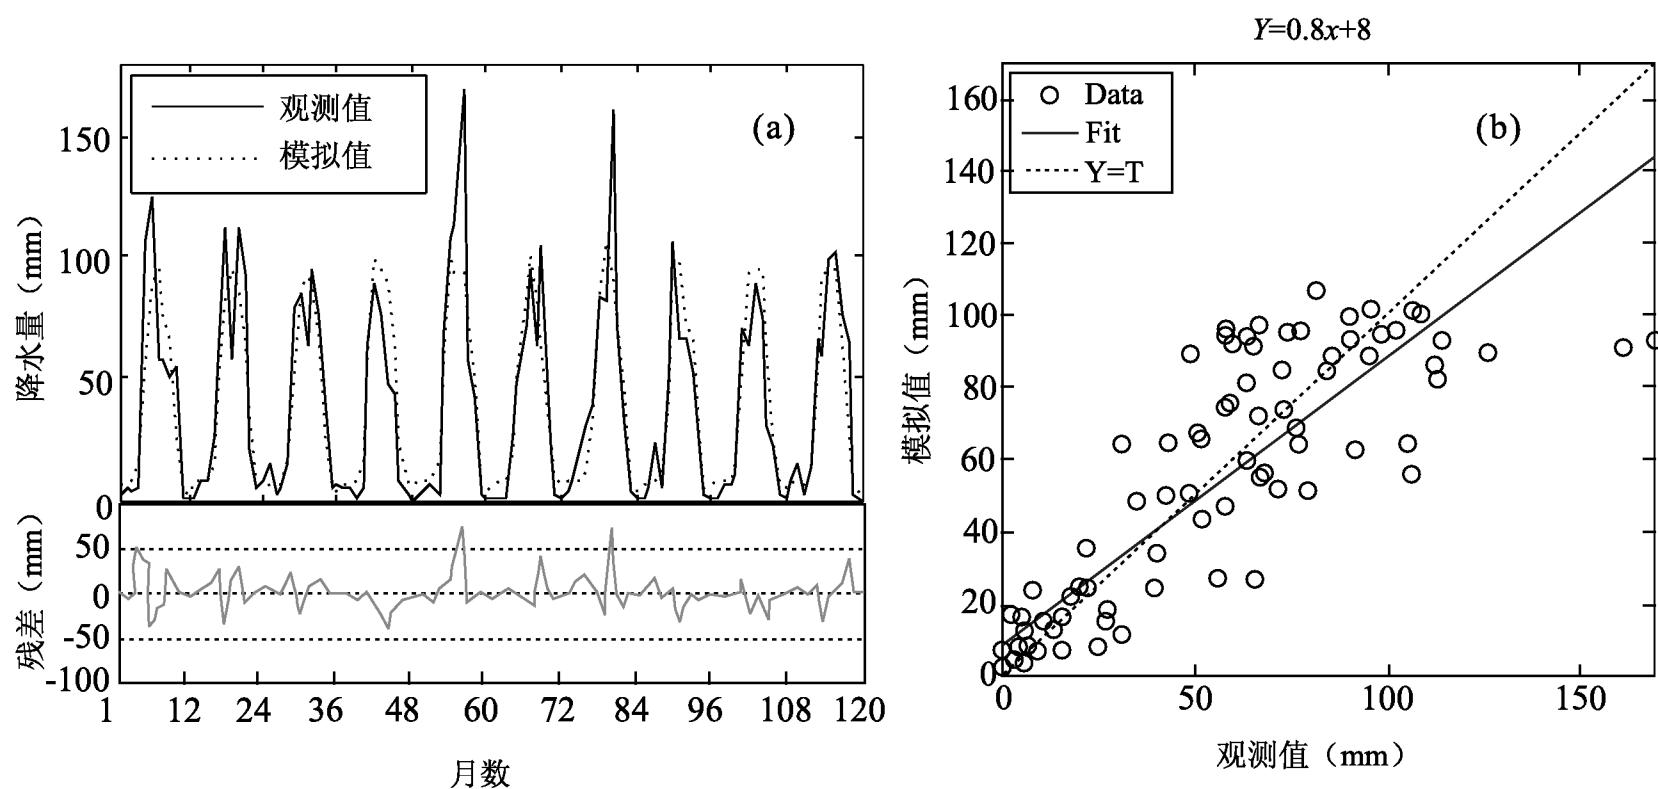


图 2 玉树站 BP-ANN 月降水量模拟值与实际观测值对比、残差曲线及回归图(b 图为观测值和模拟值的线性拟合关系)

Fig. 2 Results Using the BP-ANN Model for the Validation Data Set of Yushu Station(a:the Forecasted and Observed Time Series and Residuals;b:the Scatter Diagram Between the Forecasted and Observed Precipitation)

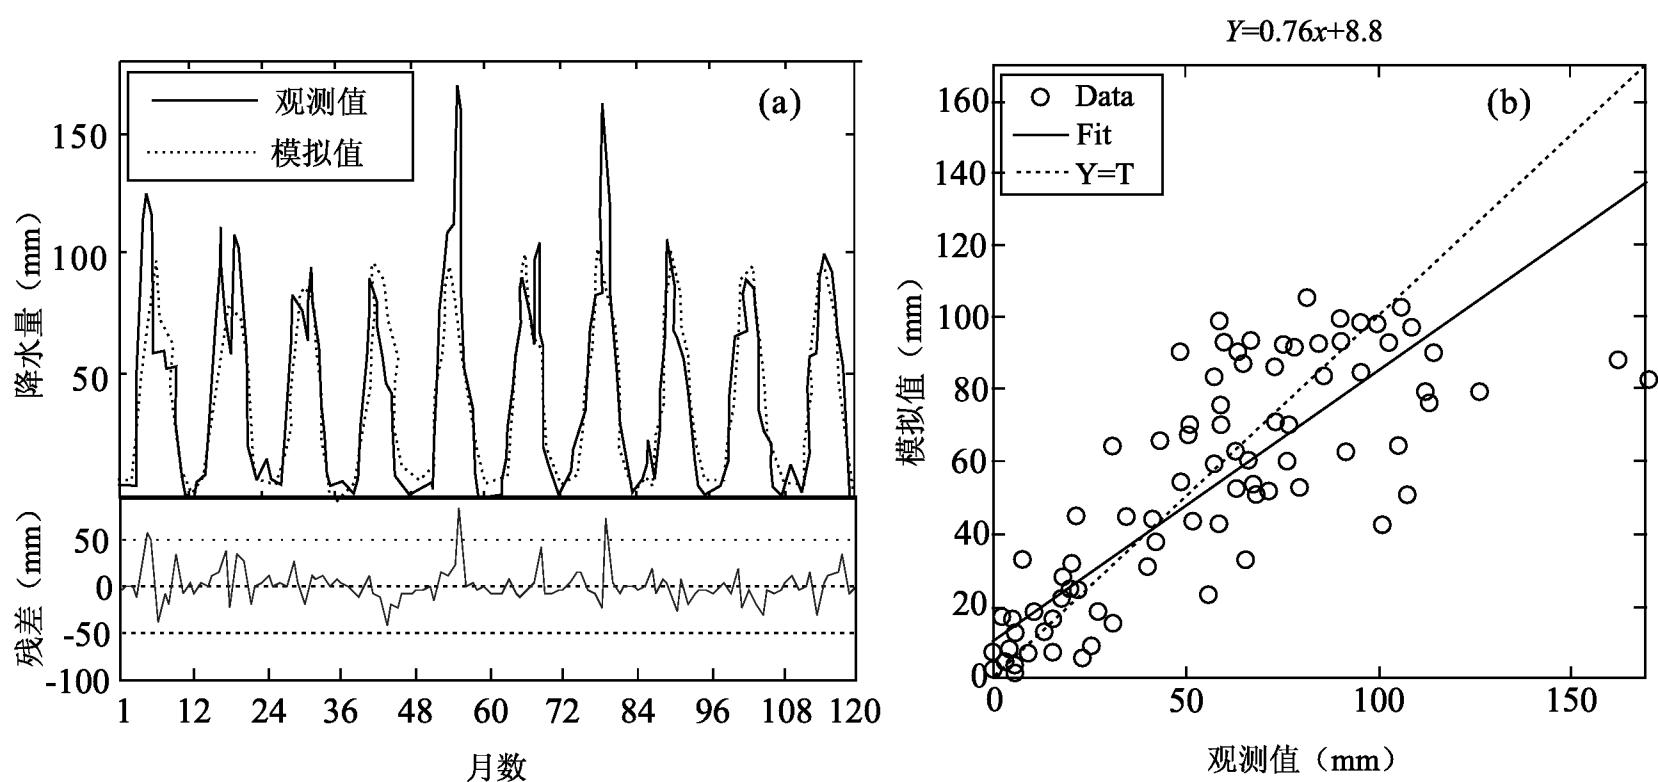


图 3 玉树站 RBF-ANN 月降水量模拟值与实际观测值对比、残差曲线及回归图

Fig. 3 Results Using the RBF-ANN Model for the Validation Data Set of Yushu Station(a:the Forecasted and Observed Time Series and Residuals;b:the Scatter Diagram Between the Forecasted and Observed Precipitation)

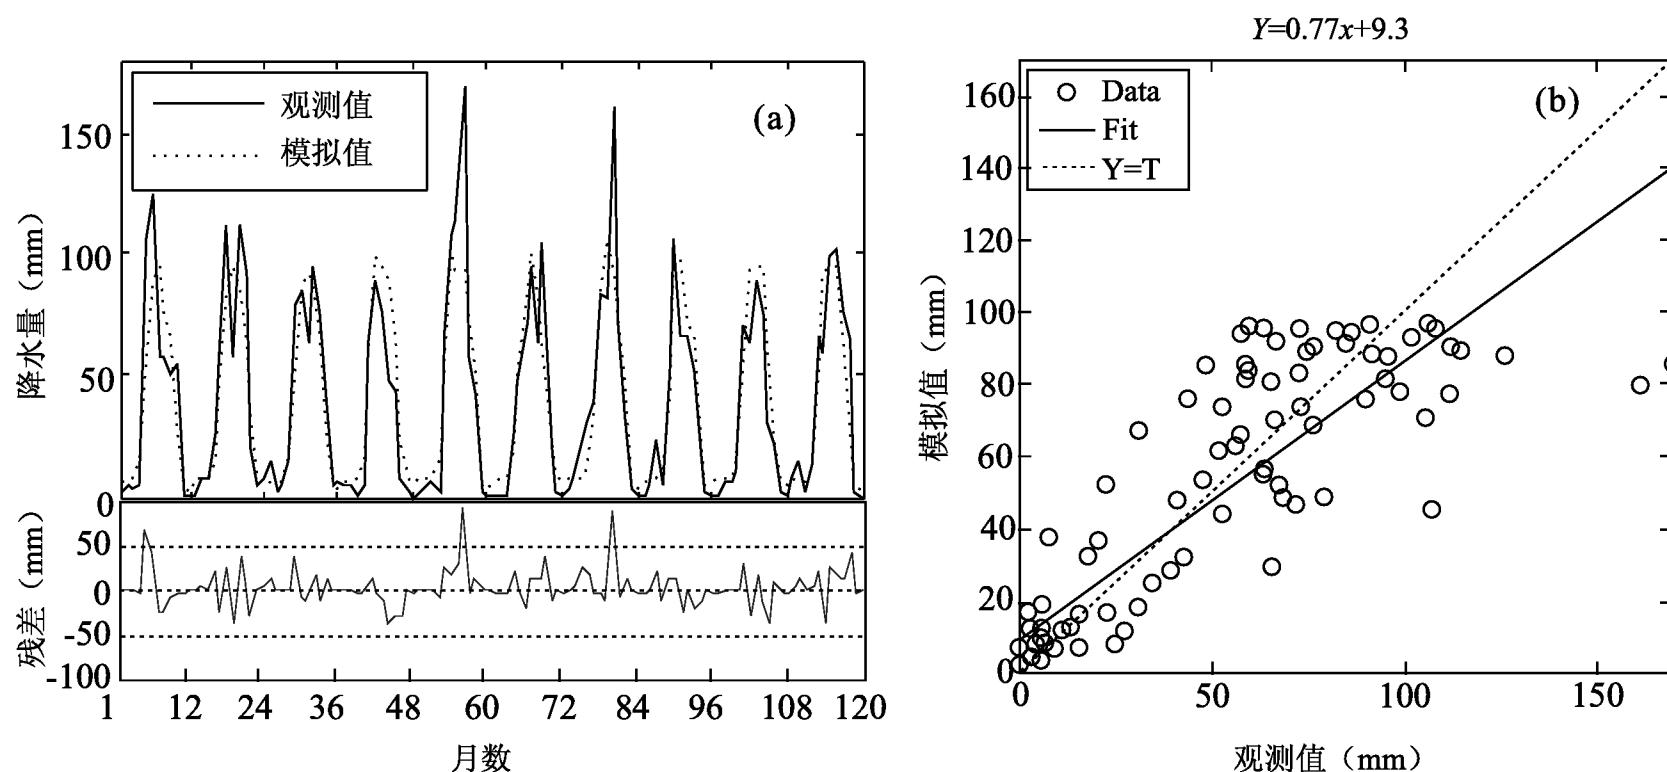


图 4 玉树站 GR-ANN 月降水量模拟值与实际观测值对比、残差曲线及回归图

Fig. 4 Results Using the GR-ANN Model for the Validation Data Set of Yushu Station(a:the Forecasted and Observed Time Series and Residuals;b:the Scatter Diagram Between the Forecasted and Observed Precipitation)

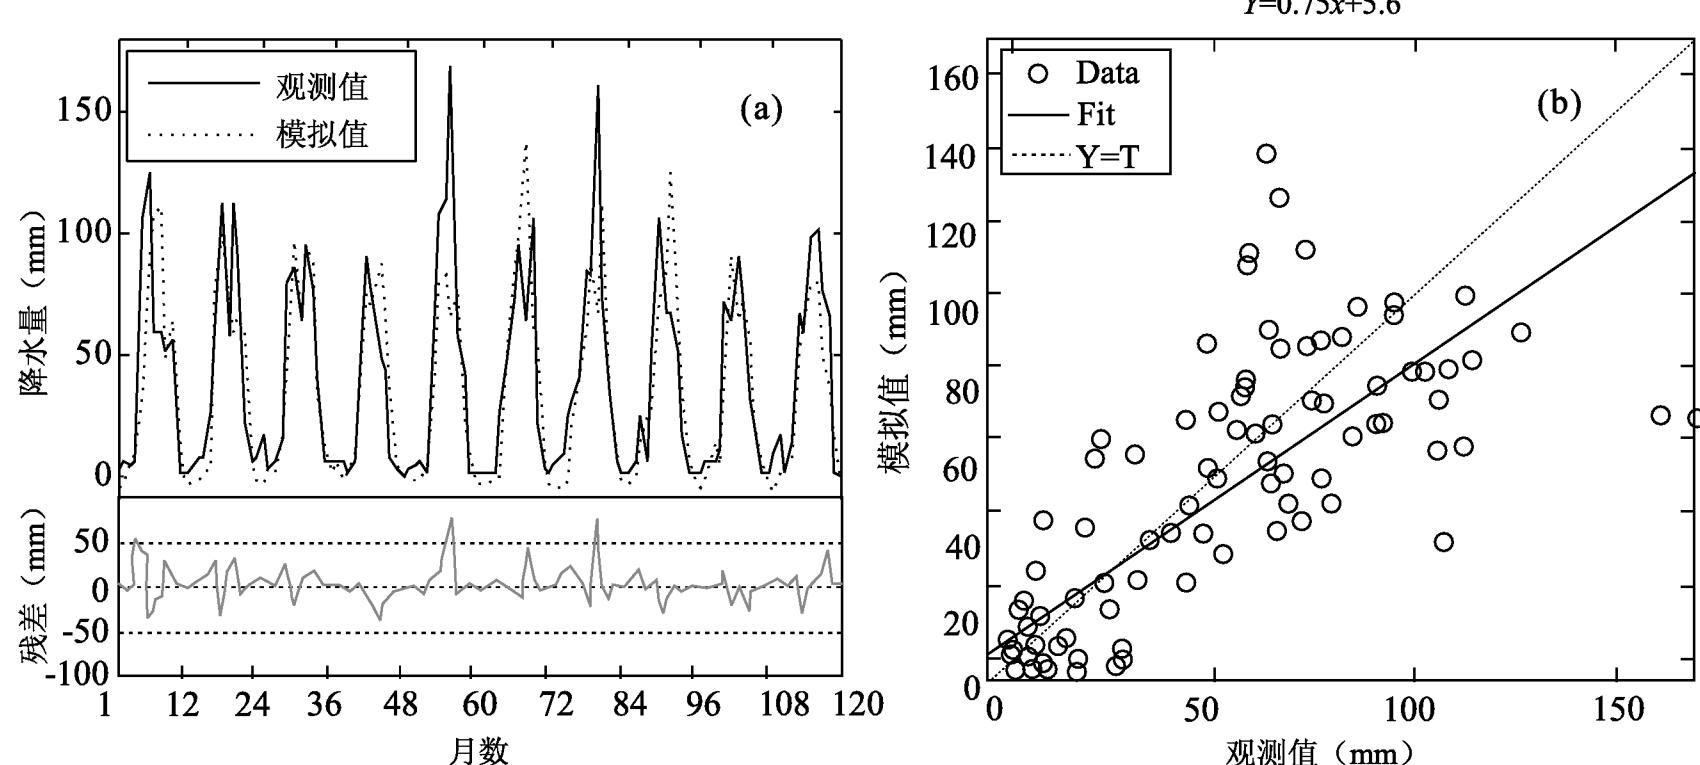


图 5 玉树站 MLR 月降水量模拟值与实际观测值对比、残差曲线及回归图

Fig. 5 Results Using the MLR Model for the Validation Data Set of Yushu Station(a:the Forecasted and Observed Time Series and Residuals;b:the Scatter Diagram Between the Forecasted and Observed Precipitation)

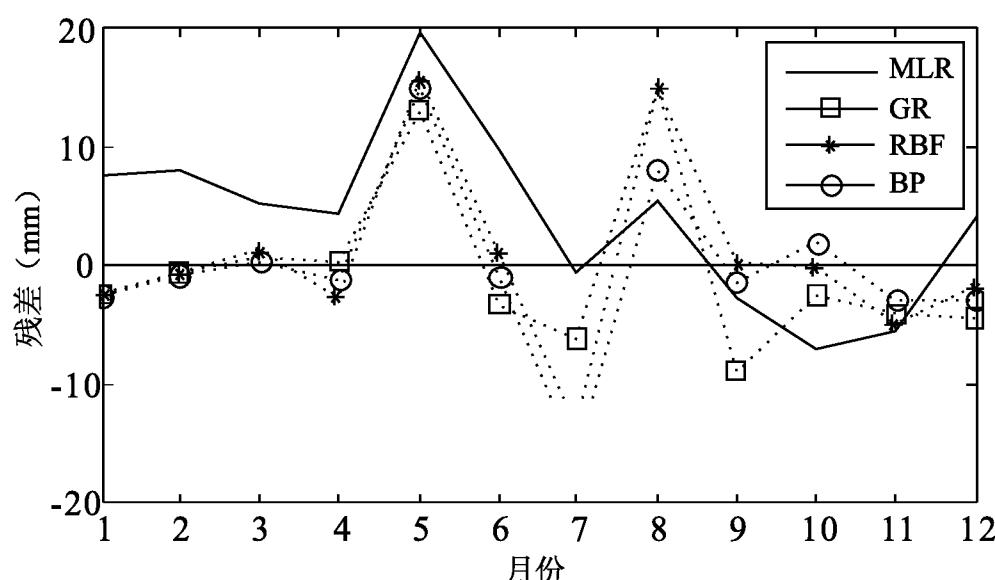


图 6 玉树站 4 种模型月降水量各月平均残差对比

Fig. 6 Average Monthly Precipitation Residuals Comparison for the Four Models in Yushu Station

差, BP、RBF 网络仅高估了 7 月份的降水, 低估了 5 月和 8 月份的降水, GR 网络高估了 7 月和 9 月份的降水, 低估了 5 月和 8 月份的降水; 各月平均误差来说, ANN 低估值在 15 mm 以内, MLR 达到 20 mm, 高估值 MLR 比 ANN 少; 值得一提的是, MLR 模型 7、8 月份 10 a 平均月残差比 3 种 ANN 都小, 7 月接近 0, 8 月接近 5 mm, 但是从图 5a 也可以看出, 这两个月份模拟值高估与低估值可近似相互抵消可能是造成这种现象的原因; 整体来看, MLR 模型误差较大。

由于所选研究区降水量年内分配很不均匀, 冬季(12~2 月份)降水量为全年最少, 春季(3~5 月份)降水量逐月增加, 夏、秋季节连续最大 4 个月(6~9 月份)降水量占年总量的 60%~80%, 月最大降水量多出现在 7、8 月份, 其降水量占全年 40% 左右。根据研究区降水的特点, 对所模拟时段观测值

和模拟值进行年、月、4~10 月份降水量的平均值、标准差、最大值和最小值的统计分析比较, 对于分析模型表现效果及实际应用参考很有意义, 结果如表 5。

从表 5 中可以看出:

(1) 平均值: BP 网络在玉树和九龙站模拟结果较好, GR 网络在宜宾站表现较好, MLR 在 3 站表现均较差。

(2) 标准差: 除宜宾站月降水外, 其他均是 MLR 较接近观测值。

(3) 最大值和最小值: 各模型模拟结果都不是很好理想, 年、4~10 月份最小值 MLR 模型模拟较好, 月最小值玉树站 RBF 网络、九龙站 BP 网络、宜宾站 RBF 网络较接近观测值; 年最大值来说, 玉树站 GR 网络, 九龙、宜宾站均是 RBF 网络表现较好; 月最大值玉树、九龙站 MLR 较好, 宜宾站 RBF 网络较接近观测值; 4~10 月份最大值玉树站 GR 网络、九龙站 MLR、宜宾站 RBF 网络较接近观测值。

与已有研究中进行的月降水预测相似^[3~5], 即使神经网络大部分方面较多元线性回归预测效果好, 但是所有模型在降水量最大最小值预测方面的精度都很有限。

5 结论与讨论

以上分析可以看出:

(1) 人工神经网络用于所选研究区 3 个气象站的月降水模拟结果相对优于传统的多元线性回归方

表 5 各站模拟值和观测值年、月、4~10 月降水平均值、标准差、最大最小值比较

Tab. 5 Annual, Seasonal and Monthly Analysis of Observed and Forecasted Precipitation

		年				月				4~10 月			
		平均值	标准差	最大值	最小值	平均值	标准差	最大值	最小值	平均值	标准差	最大值	最小值
玉树	观测值	467.92	71.01	578.00	349.60	38.99	40.03	169.60	1.00	444.56	67.71	562.10	335.20
	BP	471.28	17.91	514.27	448.91	39.27	36.07	106.47	0.81	439.21	18.54	484.50	415.90
	RBF	460.50	18.02	492.53	437.66	38.37	34.63	105.40	-0.11	429.04	17.74	460.50	405.26
	GR	471.49	23.60	530.16	440.38	39.23	35.11	97.05	4.35	436.73	24.31	497.11	402.30
九龙	MLR	419.02	42.68	479.49	350.16	34.92	37.57	138.57	-5.56	415.21	43.95	485.80	343.81
	观测值	961.05	101.85	1 097.00	763.80	80.08	81.67	341.10	0.00	917.17	118.28	1 080.00	666.40
	BP	970.96	41.68	1 035.85	905.88	80.91	72.75	254.68	0.95	910.52	41.74	979.41	840.08
	RBF	952.51	48.05	1 037.86	878.84	79.38	72.34	232.61	-2.36	894.40	51.75	980.72	821.80
宜宾	GR	938.68	38.39	985.50	874.57	78.22	67.49	210.53	11.46	863.17	38.05	909.90	798.86
	MLR	893.19	84.51	1 006.32	733.21	74.43	78.75	274.36	-8.54	877.38	97.97	1 004.75	678.35
	观测值	985.96	174.83	1 306.50	749.10	82.16	78.30	398.90	4.00	851.65	190.13	1 214.10	562.30
	BP	1 002.26	41.25	1 069.09	928.14	83.52	66.24	261.43	21.18	872.91	41.87	929.84	803.48
宜宾	RBF	1 006.79	74.91	1 113.27	879.19	83.90	67.87	322.22	2.63	874.64	71.59	975.45	747.35
	GR	979.64	65.91	1 082.85	870.58	81.64	59.73	254.25	24.02	831.92	66.04	928.59	718.81
	MLR	865.74	81.93	966.03	727.32	72.14	67.33	267.48	-3.51	791.68	87.14	940.15	627.58

法,其中 BP 模型模拟结果在 3 站中精度较好,模型表现均较稳定,RBF 和 GR 两种 ANN 模型在玉树、九龙站结果相对较好,宜宾站稍差一些;

(2)从 3 个站点的总体模拟效果来看,降水量越大的站点(如宜宾站),模型的模拟误差越大,这可能主要是年内月际间变率较大的原因;

(3)从月降水量的多年平均残差值来看,MLR 模型在某些月份的模拟有一定的优越性,如 MLR 在 7、8 月份降水的模拟上平均误差比 ANN 模型要小。总的来说,人工神经网络模型中,BP 网络的泛化能力较强,在确定合理的输入变量和网络结构后,BP 模型可以尝试作为长江上游一种有效的月降水预测模型。

ANN 模型虽然在长江上游代表站点月降水的模拟预测中表现出了一定的优势,但也存在一定的误差,尤其是在最大最小值的模拟上,从 3 站的表现结果来看,月降水量越大、变率越大的站点,模拟效果表现越差。以后的研究中,在降水量最大最小值的预测上,如果考虑分季节单独处理,可能会减小误差,若能将 ANN 方法与其他方法结合起来使用,在大流域的预测中,ANN 表现结果可能会相对理想一些。

参考文献:

[1] 徐俊杰,何青,刘红,等.2006 年长江特枯径流特征及其原

- [2] 魏凤英,曹鸿兴.长期预测的数学模型及其应用[M].北京:气象出版社,1990.
- [3] DELLEUR J W,KAVVAS M L.Stochastic models for monthly rainfall forecasting and synthetic generation[J].Appl Meteorol,1978,17(10):1 528~1 536.
- [4] AKSOY H,DAHAMSHEH A.Artificial neural network models for forecasting monthly precipitation in Jordan[J].Stoch Environ Res Risk Assess,2009,23:917~931.
- [5] 薛宇峰,宋丽红,罗泽举.湛江降水量的径向基神经网络预测模型[J].热带气象学报,2006,22(1):91~95.
- [6] 胡江林,张礼平,字如聪.神经网络模型预报湖北汛期降水量的应用研究[J].气象学报,2001,59(6):776~783.
- [7] 段婧,苗春生.人工神经网络在梅雨期短期降水分级预报中的应用[J].气象,2001,31(8):31~36.
- [8] 杨达源.现代自然地理研究[M].北京:科学出版社,2008.
- [9] 刘明光.中国自然地理图集[M].北京:中国地图出版社,1998.
- [10] 张立明.人工神经网络的模型及其应用[M].上海:复旦大学出版社,1993:13~47.
- [11] 张德丰.MATLAB 神经网络应用设计[M].北京:机械工业出版社,2009.
- [12] 李双成,郑度.人工神经网络模型在地学研究中的应用进展[J].地球科学进展,2003,18(1):67~74.
- [13] SPECHT D F.A general regression neural network[J].IEEE Trans Neural Networks,1991,2:568~576.

ARTIFICIAL NEURAL NETWORK MODELS FOR FORECASTING MONTHLY PRECIPITATION IN THE UPPER YANGTZE RIVER

FENG Ya-wen^{1,2}, REN Guo-yu², ZHANG Li¹, LUO Hua-chao¹

(1. Faculty of Water Conservancy Engineering, North China University of Water Resources and Electric Power, Zhengzhou 450011, China;

2. Laboratory for Climate Studies, China Meteorological Administration, National Climate Center, Beijing 100081, China)

Abstract: Monthly precipitation forecast for the upper Yangtze River is very essential to the water resources management for the entire Yangtze River basin. Three typical meteorological stations were selected respectively in three different climatic zones. All the selected stations contained nearly 60 years of monthly precipitation records in the upper Yangtze River. This paper estimated the month of precipitation and precipitation time delay parameter, and established monthly precipitation forecasting model using back-propagation neural network, radial basis function neural network, generalized regression neural network and multiple linear regression method respectively, to predict the precipitation of coming month. Then, the mean square error and coefficient of determination were used to verify the simulation accuracy of various models and the model simulation results. The results show that artificial neural network prediction model is superior to multiple linear regression in general. Especially, the performance of the back-propagation neural network is better than the others. It can be determined as an effective monthly precipitation methods for the upper Yangtze River after determining reasonable input variables and network structure.

Key words: the upper Yangtze River; artificial neural network; monthly precipitation forecasting; multiple linear regression