

基于混合算法的径流预报模型研究

蒋林利¹ 吴建生² 曾文华¹

(1. 厦门大学 软件学院, 福建 厦门 361005;
2. 武汉理工大学 信息工程学院, 湖北 武汉 430070)

摘要: 为了提高径流预报的精度, 采用一种基于粒子群和遗传的混合方法同时优化人工神经网络结构、连接权和偏置。在进化过程中采用训练样本和验证样本共享适应度技术, 并以此建立径流预报模型。通过对柳州径流实例分析, 并与粒子群优化的人工神经网络模型、遗传进化的人工神经网络模型和时间序列模型方法对比, 研究表明, 该方法学习能力强、泛化性能高和有效提高系统预测的准确率, 为获得更高预测精度的径流预报提供了一种有效的建模方法。

关键词: 人工神经网络; 粒子群; 遗传算法; 径流预报

中图分类号: TP183 文献标识码: A

Neural network model based on hybrid algorithms and its application in runoff for ecasting

JIANG Lin-li¹, WU Jian-sheng², ZENG Wen-hua¹

(1. Soft Ware School of Xiamen University, Xiamen 361005, China;
2. School of Information Engineering, Wuhan University of Technology, Wuhan 430070, China)

Abstract: In order to improve the accuracy of runoff forecasting, a hybrid algorithm combining PSO and GA algorithm with optimizing artificial neural network structure, connection weights and bias was proposed and used to establish a runoff forecasting model. This hybrid algorithm adopts training samples and validation samples to share fitness in the evolutionary process. The algorithm was compared with two forecasting models including PSO-ANN and GA-ANN through the actual examples of Liuzhou runoff forecasting. The results show that the new approach has strong learning ability and high generalization performance and can improve the accuracy of forecasting system effectively. Thus, it is an effective modeling method to get high precision of runoff forecasting.

Key words: artificial neural network; particle swarm optimization; genetic algorithm; runoff forecasting

径流是水资源的主要来源, 是社会经济、生态环境可持续发展的重要基础。由于全球气候的变化和人类的影响, 径流发生变化的因素, 如降雨、气候、气温、蒸发和人类活动等具有大量不确定性和复杂性^[1-3], 使得径流模型的建立十分复杂, 常规的时间序列方法和协整理论等很难对径流的变化规律、变化特征有明晰的了解和准确的把握, 主要是因为径流过程表现出强烈的非线性特征。从 20 世纪 90 年代以来, 人工神经网络(Artificial Neural Networks, ANN)方法, 已经成功应用在大气学科、气候分析和径流

收稿日期: 2013-09-12; 修订日期: 2013-12-21

基金项目: 国家自然科学基金资助项目(61202143, 51065002, 11161029)

通讯作者: 曾文华(1964-), 男, 江苏兴化人, 厦门大学教授; E-mail: whzeng@xmu.edu.cn。

预测建模等领域^[4-6]。但是在利用人工神经网络方法进行预测建模研究时所确定的网络结构和初始权值等问题都是依靠研究人员的经验来设定,到目前为止,还没有找到合适的规律可循。经常会出现训练好的人工神经网络对历史样本有很好拟合结果,对未来预测结果很差,这就极大地限制了人工神经网络在实时径流预测模型中的应用^[7-9]。

近年来,基于群体智能的粒子群算法(Particle Swarm Optimization, PSO)和基于人类进化的遗传算法(Genetic Algorithm, GA)已广泛地应用于优化设计神经网络。1995年由 EBERHART R C 和 Kennedy J 提出的粒子群算法具有原理简单、参数少、收敛速度较快,通过不断更新粒子的位置和速度搜索最优解^[10]。对于一些简单的问题,一种简单的优化算法或许能得到满意的解。但在实际的应用中,往往是复杂多维的优化问题,粒子群算法在优化过程中往往会出现局部收敛的现象。为了避免离子群局部收敛现象,研究者提出了各种改进的 PSO 算法优化神经网络,其中由 KIRABYAZ S 等^[11]提出了一个新的多维粒子群优化技术自动设计优化神经网络结构的方法具有很好的泛化能力;由吴建生等^[12]提出使用 BP 算法避免粒子群算法局部搜索过程中的收敛停滞现象建立优化人工神经网络的降水预报模型。遗传算法^[8](Genetic Algorithm, GA)具有良好的全局搜索和局部优化的特性。不同于传统的非线性优化技术,遗传算法是为保留群体寻找一个更好的解决方法,已成功地应用在人工智能、搜索和优化等各个领域^[13]。其中由 SEDKI A 等^[1]提出的基于实数编码的遗传算法的神经网络模型具有很好的径流预测能力,并为训练神经网络提供一个很好的预测工具。在理论上,对于高维复杂优化问题,混合的群体智能优化方法比单一的优化算法更能提高算法的性能^[14]。为此本文针对复杂多维的柳江径流问题,提出一种基于粒子群优化算法(PSO)和遗传算法(GA)的混合方法同时优化人工神经网络结构、连接权重和偏置权重(PSOGA-ANN),利用遗传算法局部搜索避免粒子群算法陷入早期的局部最优解,以此加快算法的收敛速度,提高最优解的精度,并共享训练样本和验证样本的适应度,防止过拟合现象,并以此建立混合优化神经网络的径流预报模型。

1 基于混合算法的神经网络模型

1.1 人工神经网络

人工神经网络是一个具有自组织、自学习能力和非线性容错性较强等特点的动态系统。典型的三层神经网络通常由输入层、隐层和输出层组成,通过连接权、偏置和非线性函数组合实现输入到输出非线性映射,其结构如图 1 所示。

图 1 中,神经网络有 n 个输入, m 个隐层和 1 个输出,输入和隐层采用 sigmoid 函数,则输出为:

$$Y = \sum_{k=1}^m \left(\text{sigmoid} \left(\sum_{i=1}^n x_i w_{ij} + w_{j0} \right) \right) w_{jk} + w_{k0} ,$$

其中 x_i 是输入变量, w_{ij} 和 w_{jk} 分别是输入与隐层神经元之间的连接权值和隐层与输出层之间的权值, w_{j0} 和 w_{k0} 分别是第 j 个和第 k 个神经元的偏置, i, j 和 k 分别是神经元的数量。由图 1 模型结构可以看出,由输入层、输出层和隐层组成三层神经网络,而建模样本决定输入层、输出层节点的个数,故而在优化网络结构的时候,其实是优化它的隐节点的个数。该神经网络的网络参数由输入层到隐层的连接权和偏置,隐层到输出层的连接权和偏置组成,在优化时需要一组实数。

为了优化隐节点和人工神经网络的相关参数,本文采取混合编码方法,及每个个体同时采用二进制编码和实数编码,二进制便控制网络的隐节点,实数编码部分对应网络连接权和偏置。其中在二进制编码部分的串是由 0-1 两个字符组成的,其中“0”表示是无连接,“1”表示是有连接,而实数编码部分直接用变量范围内的实数表示,并把编码按一定的顺序级联成一个长串。

1.2 PSOGA 混合算法进化人工神经网络

假定训练数据是 $(x_i, y_i)_{i=1}^N$, 其中 $x_i \in \mathbf{R}^n$ 是输入向量, y_i 是输出值, N 是样本个数,首先把样本分

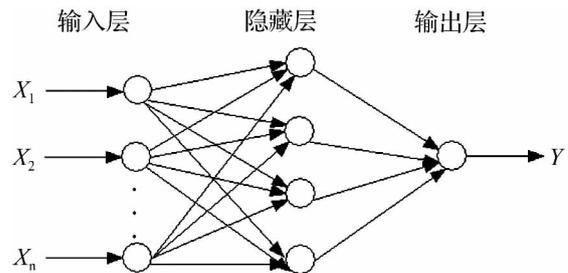


图 1 神经网络的模型结构

Fig. 1 Architecture of neural network model

成三个部分: 训练数据 T_1 , 验证数据 T_2 和测试数据 T_3 , 适应度函数定义如下:

$$f(T_1) = 1 / \left[1 + \frac{1}{N} \sum_{i=1}^{N_1} (y_i - \hat{y}_i)^2 \right], \quad (1)$$

其中, \hat{y}_i 是网络输出, 该算法具体实现步骤如下:

① 初始化群体的位置和速度, 随机生成 L 个体, 每个个体是由两部分组成, 即第一部分和第二部分分别是群体的位置矩阵和对应粒子的速度矩阵; 其中群体位置矩阵包含连接结构矩阵和参数矩阵, 图 2 为第 i 个个体粒子编码示意图。个体结构矩阵是二进制变量矩阵, 它对应的连接权如存在, 则该变量表示为 1, 否则为 0; 权重系数矩阵是浮点数矩阵, 其值取 $[-1, 1]$ 上的均匀分布随机数, 它是控制整个网络的连接权值和偏置值的大小。

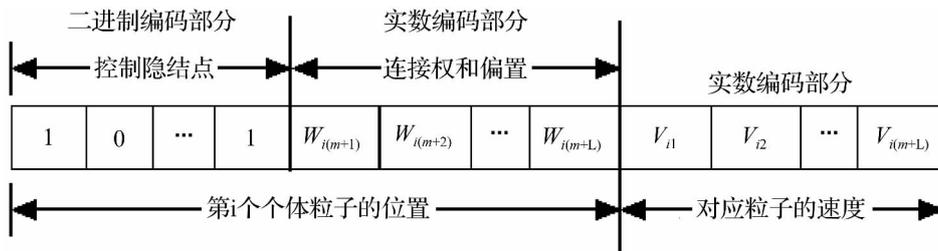


图 2 第 i 个个体粒子编码示意图

Fig. 2 The schematic diagram of the i individual particle code

其中由 0-1 组成的串为 m , 它的值可由输入节点个数的 1.5 倍来确定, 然而网络参数码主要是控制网络的连接权重和偏置, 粒子的位置串长和速度串长相同, 均为:

$$L = n \times m + m + m \times p + p,$$

其中 n 为输入节点的个数, p 为输出节点个数, 该串对应一组网络结构和连接。

② 输入训练样本, 根据式 (1) 计算每个粒子的适应度, 并初始化个体经历最好位置 $P_{best}(t)$ 和群体经历的最好位置 $P_{gbest}(t)$ 。

③ 进行 PSO 优化过程, 以此更新粒子的速度和位置, 速度进化方程:

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_1 (P_{best}(t) - x_{ij}(t)) + c_2 r_2 (P_{gbest}(t) - x_{ij}(t)),$$

$$\omega(t) = \omega_{max} - \frac{(\omega_{max} - \omega_{min})}{iter_{max}} \times iter,$$

其中 ω_{max} , ω_{min} 分别是惯性权重的最大值和最小值, $iter$, $iter_{max}$ 分别是当前迭代次数和最大的迭代次数。

为了保证连接结构矩阵进化后仍然能取 0 或 1, 依据文献 [13] 连接结构位置进化方程取为:

$$x_{ij}(t+1) = \begin{cases} 0, & r \geq \frac{1}{1 + \exp(-v_{ij}(t))} \\ 1, & r < \frac{1}{1 + \exp(-v_{ij}(t))} \end{cases},$$

其中, r 为 $[0, 1]$ 均匀分布的随机数。对于实数编码位置进化方程为: 连接权位置进化方程为:

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1).$$

④ 进行 GA 优化。为进行局部搜索, 为了保留群体中适应度最高的个体, 它不参与交叉和变异运算, 是直接将其复制到下一代。而对群体中的其他个体, 则采用轮盘赌选择法进行选择。其中控制隐结点的二进制码串则采用基本遗传算法中的方法。由于连接参数用实数编码, 这就需要设计新的交叉算子和变异算子。这里以 p_c 的概率对选择后的个体进行交叉, 根据下列方程计算交叉的连接权重:

$$\begin{cases} x_i^{t+1} = \alpha_i \times x_i^t + (1 - \alpha_i) \times x_{i+1}^t \\ x_{i+1}^{t+1} = (1 - \alpha_i) \times x_i^t + \alpha_i \times x_{i+1}^t \end{cases},$$

其中, x_i^t, x_{i+1}^t 是一对交叉前的个体, x_i^{t+1}, x_{i+1}^{t+1} 是交叉后的个体, α_i 是在区间 $[0, 1]$ 均匀分布的一个随机

数。接着根据下列公式以 p_m 的概率进行实数编码交叉后的个体进行变异:

$$x_i^{t+1} = x_i^t + \beta_i$$

其中, x_i 代表第 t 代的第 i 个粒子的实际值, x_i^t 是交叉前的值, x_i^{t+1} 是交叉后的值 β 是在 $[0-1]$ 的一个随机数。

⑤ PSO 和 GA 优化过程中适应度是采用在训练样本利用公式(1)计算,在 PSO 和 GA 进化到一定代数终止优化,以适应最小者解码位置矩阵得到网络结构和对应连接权重和偏置,带验证样本计算适应度。若训练样本的适应度和验证样本的适应度之差绝对值小于 0.001,停止进化,否则转步骤③,迭代的最大次数作为终止标准。

⑥ 判断验证数据终止条件,一旦满足终止条件,即可输出最后获得合适的网络结构和连接权值的解,输入检测样本输出检测结果。具体算法流程如图 3 所示。

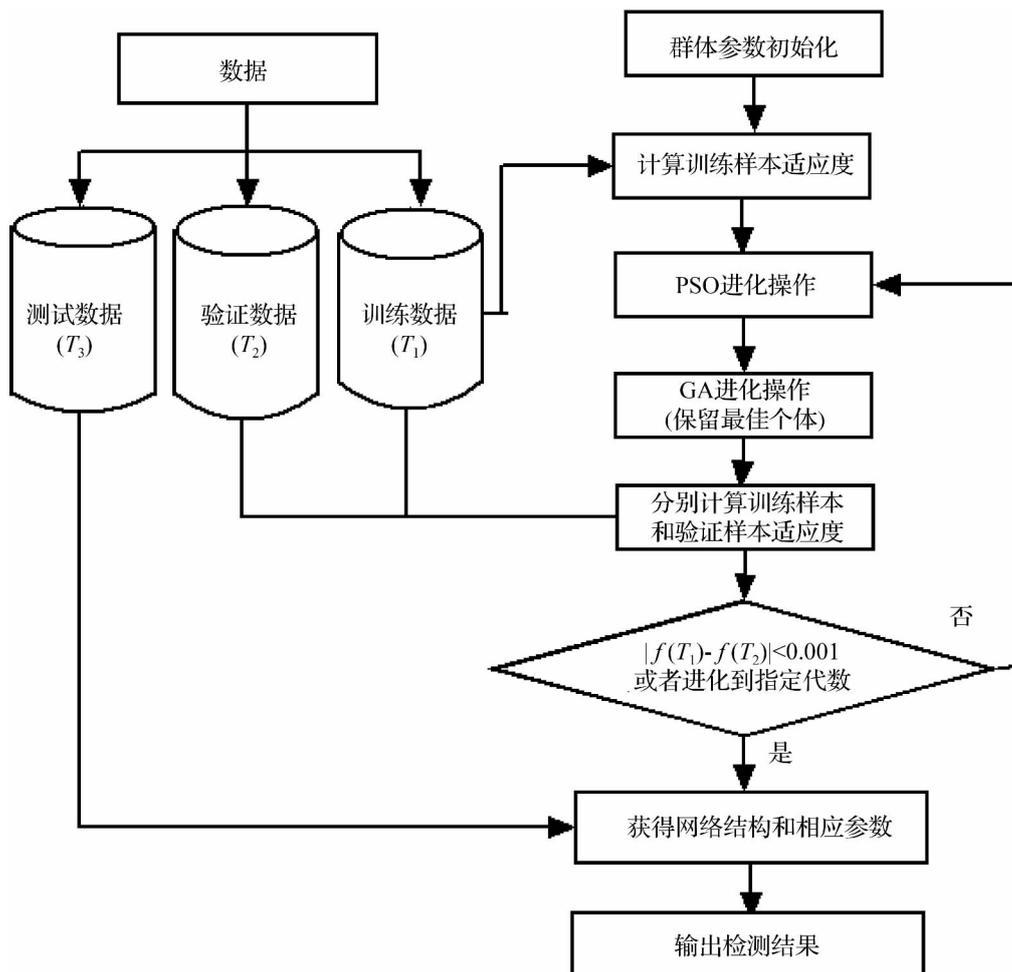


图 3 PSOGA-ANN 算法流程图

Fig. 3 Flowchart of the PSOGA-ANN algorithm

2 径流预报应用

笔者通过基于混合算法的人工神经网络建立径流预报模型,采用西江流域的柳江柳州观测点 2001 年 1 月 1 日~2005 年 12 月 31 日的每日平均水位数据建立模型,共 1 826 个,其中 2001 年 1 月 1 日~2003 年 6 月 30 日数据作为训练数据,共 911 个;2003 年 7 月 1 日~2004 年 12 月 31 日数据作为验证数据,共 550 个;2005 年全年数据作为检测样本,共 365 个。

2.1 算法参数设置和模型性能评价

本文基于 Windows XP 操作系统 ,Inter Core i5 处理器 ,CPU 为 3.01 GHz ,内存为 3.00 GHz ,利用 Matlab9.0 开发环境 ,PSOGA 参数设置为: 训练总次数 100 粒子群群体个数 40 ,惯性权值为 2 ,学习因子 2 ,遗传算法的交叉概率为 0.8 ,变异概率 0.05。本文采用平均绝对相对误差 (AARE) ,均方根误差 (RMSE) 和相关性能系数(PRC) 评价模型的性能 ,具体的数学表达式参见文献 [12]。

根据径流水位时间序列建模方法(即 AR 模型) ,是延迟 6 阶自回归模型 ,表达式如下:

$$x_t = 1.41x_{t-1} + 0.892x_{t-2} + 0.458x_{t-3} - 0.191x_{t-4} + 0.105x_{t-5} + 0.043x_{t-6} + 4.617。$$

本文利用这 6 个变量建立 PSOGA - ANN 模型 ,文献 [3] 是利用遗传算法进化神经网络连接权 ,以此建立径流预测模型 ,文献 [12] 利用粒子群算法进化神经网络的结构和连接权建立降水预测模型 ,为了进一步和文献对比算法的性能 ,本文同时建立遗传算法的进化神经网络模型(GA-ANN) 和粒子群算法的进化神经网络模型(PSO-ANN) 并对径流预测建模。

2.2 结果分析

图 4 为 PSOGA-ANN 进化训练阶段训练样本的适应度和验证样本适应度随进化次数的变化曲线 ,从图 4 训练样本适应度随着训练次数增加 ,越来越稳定趋向 1 ,验证样本的适应度会随着训练次数增加 ,也逐渐稳定趋向 1 ,并且在进化过程有波动现象 ,由于训练样本采用是 PSO 全局进化 ,GA 局部进化并保留最佳个体不至于破坏原来最佳个体 ,从训练样本适应度变化曲线可以看出 ,在前 10 次 ,适应度变化很快 ,在 10 ~ 30 次时 ,适应度变化较慢 ,在 31 次时 ,适应度较大再次增加 ,这些现象进一步说明 ,在利用 PSOGA 进化 ANN 过程 ,适应度变化会有停滞情况 ,及陷入局部解 ,而随着遗传算法局部搜索 ,可以使得进化过程跳出局部解。

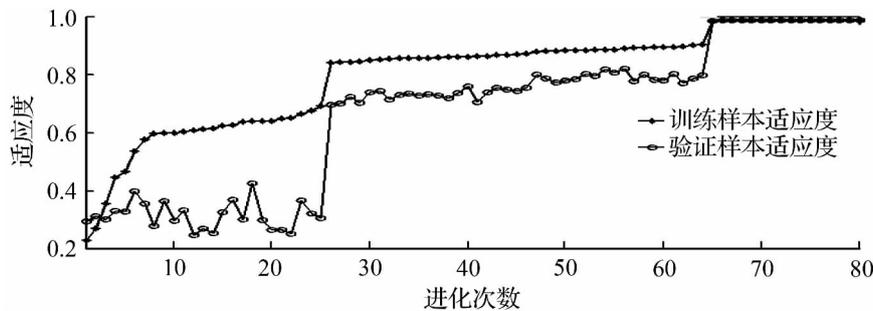


图 4 PSOGA-ANN 适应度变化曲线

Fig. 4 The fitness curve of PSOGA-ANN

图 5 ~ 图 8 是 AR(6) ,GA-ANN ,PSO-ANN 和 PSOGA-ANN 四种不同预报模型柳江径流水为 365 个检测样本预测结果图。从图 5 ~ 图 8 的对比可以看出 ,PSOGA-NN 模型对 365 个检测样本的预测输出与实际值具有良好的一致性。

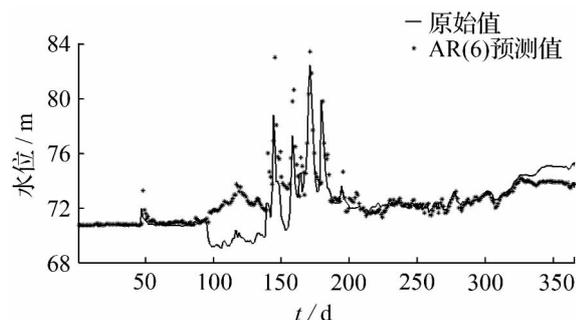


图 5 AR(6) 模型预测效果

Fig. 5 The predicted effect of AR(6)

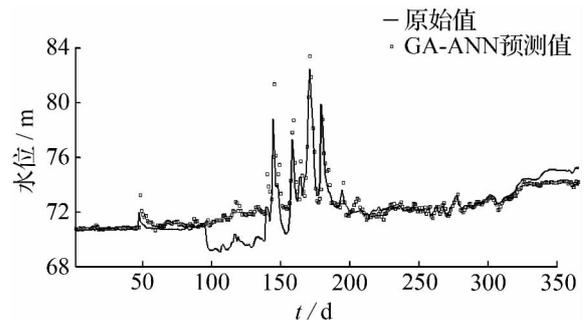


图 6 GA-ANN 模型预测效果

Fig. 6 The predicted effect of GA-ANN

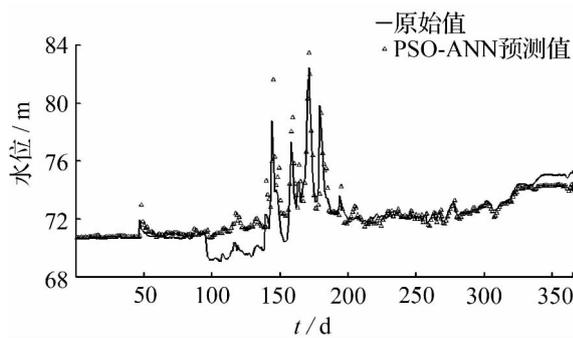


图 7 PSO-ANN 模型预测效果

Fig. 7 The predicted effect of PSO-ANN

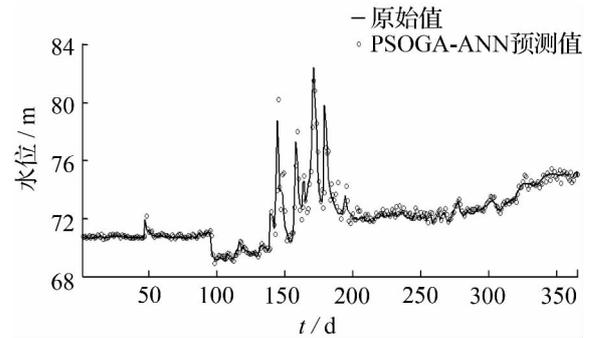


图 8 PSOGA-ANN 模型预测效果

Fig. 8 The predicted effect of PSOGA-ANN

表 1 给出 AR(6)、GA-ANN、PSO-ANN 和 PSOGA-ANN 四种不同模型对训练样本、验证样本和检测样本各项评价指标的结果,从中可以看出,在所有预报模型中,PSOGA-ANN 模型无论是训练样本的拟合、验证样本的校验和检测样本的预测,其结果都是最好的。评价指标 PRC 是相关性性能系数,主要衡量模型趋势性能,从表中看出,PSOGA-ANN 的 PR 值最大,说明模型可以刻画径流变化趋势,跟踪水位变化过程。

表 1 4 种模拟和预测降水预报的性能统计

Tab. 1 The performance statistics of the four models for runoff fitting and forecasting

模型	训练数据			验证数据			测试数据		
	平均绝对相对误差/%	均方根误差	相关性系数	平均绝对相对误差/%	均方根误差	相关性系数	平均绝对相对误差/%	均方根误差	相关性系数
AR(6)	0.510 1	0.789 1	0.899 3	0.722 5	1.031 2	0.848 7	1.172 0	1.374 6	0.766 7
GA-NN	0.351 3	0.579 2	0.947 1	0.488 4	0.721 3	0.929 7	0.928 3	1.049 0	0.859 7
PSO-NN	0.353 1	0.546 5	0.952 0	0.486 9	0.687 8	0.936 2	0.832 9	0.964 3	0.882 8
PSOGA-NN	0.362 0	0.542 8	0.953 1	0.382 5	0.561 7	0.941 1	0.435 3	0.675 6	0.940 1

3 结 语

准确的径流水位建模预测非常重要,可以为生产实际的预报方案、科学管理水利工程等提供重要的信息。本文针对地处亚热带、水资源丰富、降雨年内分配不均、地区分布差异和时空分布不均匀等情况的柳州建立径流预测模型,该模型利用粒子群遗传算法混合进化人工神经网络的连接权重、偏置和网络结构,并在进化时采用训练样本和验证样本共享适应度技术,该方法具有:

① 克服人工神经网络在建模时无法确定网络结构和连接权的问题,同时也克服人工神经网络出现过拟合现象问题。

② 利用 PSO 全局搜索,GA 局部搜索可以加速算法收敛到最优解,而且避免 PSO 算法过早收敛、跳出局部最优解,提高了人工神经网络的性能,对比结果可以看出,相对单纯 PSO 进化人工神经网络,单纯 GA 进化神经网络来说,PSOGA-ANN 能更准确刻画出径流变化趋势,具有较高的预测性能,所以该模型可以作为一种获得更高预测精度的径流预报建模工具。

参考文献:

- [1] SEDKI A, OUAZAR D, MAZOUZI E E. Evolving neural network using real coded genetic algorithm for daily rainfall-runoff forecasting [J]. Expert Systems with Applications, 2009, 36(3): 4523-4527.
- [2] 丁红, 杨杰. 小波变换集遗传算法神经网络的径流预报建模 [J]. 广西大学学报: 自然科学版, 2012, 37(3): 0580-0587.
- [3] 吴建生, 金龙. 基于非参数回归的神经网络集成降水预报模型 [J]. 计算机工程与设计, 2008, 29(17): 4541-4561.
- [4] WU J J. An Effective hybrid semi-parametric regression strategy for rainfall forecasting combining linear and nonlinear

- regression [J]. *International Journal of Applied Evolutionary Computation*, 2011, 2(4): 50-65.
- [5] 钟伟, 宋洋. 基于 FCM 的小波神经网络模型在径流预测中的应用 [J]. *系统工程学报* 2009, 24(1): 68-73.
- [6] DAWSON C W, WILBY R L. Hydrological modeling using artificial neural networks [J]. *Progress in Physical Geography*, 2001, 25(1): 80-108, 2001.
- [7] GHILE Y B, SCHULZE R E. Use of an ensemble reordering method for disaggregation of seasonal categorical rainfall forecasts into conditioned ensembles of daily rainfall for hydrological forecasting [J]. *Journal of Hydrology*, 2009, 37(1): 85-97.
- [8] 吴建生, 金龙, 汪灵枝. 遗传算法进化设计 BP 神经网络气象预报建模研究 [J]. *热带气象学报* 2009, 22(4): 411-416.
- [9] WU J J. A novel nonparametric regression ensemble for rainfall forecasting using particle swarm optimization technique coupled with artificial neural network [J]. *Lecture Note in Computer Science*, 2009, 5553(3): 49-58.
- [10] KRNNEDY J, EBERHART R. Particle swarm optimizer [C]//*Proceedings of IEEE International Conference of Neural Networks*. Piscataway, USA: IEEE Service Center, 1995: 1942-1948.
- [11] KIRABYAZ S, INCE T, YILDIRIM A, et al. Evolutionary artificial neural networks by multidimensional particle swarm optimization [J]. *Neural Networks*, 2009, 22(10): 1448-1462.
- [12] 吴建生, 刘丽萍, 金龙. 粒子群-神经网络集成学习算法气象预报建模研究 [J]. *热带气象学报* 2008, 24(6): 679-686.
- [13] OYSU C, BINGUL Z. Application of heuristic and Hybrid-GASA algorithms to tool-path optimization problem for minimizing airtime during machining [J]. *Engineering Applications of Artificial Intelligence*, 2009, 22(3): 389-396.
- [14] LI S, WU X, TAN M. Gene Selection using hybrid particle swarm optimization and genetic algorithm [J]. *Soft Computer*, 2008, 12(11): 1039-1048.

(责任编辑 梁碧芬)