

基于平均线性粒子群算法的 神经网络在径流预报中的应用

董晓华,刘超,喻丹,李磊,吕志祥,宋三红

(三峡大学水利与环境学院,湖北宜昌 443002)

摘要:神经网络具有很强的非线性处理能力,能够有效地模拟复杂的非线性径流预报过程。传统的基于BP训练算法的神经网络具有训练时间较长,容易陷于局部最优值等缺陷,本文对训练算法加以改进,分别使用平均线性粒子群,粒子群和BP算法来优化神经网络的各项参数,首先使用标准函数测试了3种算法的全局优化性能,然后用它们对三峡水库的入库径流进行预报,以比较它们的预报性能。结果表明,在3种算法中,平均线性粒子群算法全局寻优的速度最快,稳定性最高,基于平均线性粒子群算法的神经网络的径流预报的精度也最高。

关键词:径流预报;神经网络;平均线性粒子群算法;粒子群算法;BP算法

中图分类号:TV12

文献标识码:A

文章编号:1000-0852(2013)05-0010-06

1 引言

径流预报是根据径流形成和运动的规律,利用过去和实时水文气象资料,对未来一定时段的洪水发展情况的预测。径流预报的方法可以分为过程驱动模型方法和数据驱动模型方法两大类。神经网络(Artificial Neural Networks - ANN)是一种典型的数据驱动模型,它的应用不需详细考虑水文过程的物理机制,具有很好的并行处理、自组织、自学习、自适应能力,能处理复杂的非线性问题,因而被广泛应用于径流预报。

根据连接的拓扑结构,ANN模型可以分为:前向传播网络和反馈网络^[1]。其中的前向传播网络在结构上符合流域降雨-径流物理过程中水流的单向传播特征,并且在理论上能够模拟任意非线性系统至任意精度^[2-3],因而被应用于本文的研究。传统的训练前向传播网络中的参数的算法是反向传播(Back-Propagation - BP)算法。BP算法是基于梯度下降的寻优算法,容易陷入局部最优,收敛速度缓慢。为了解决这一问题,本文使用了粒子群(Particle Swarm Optimization - PSO)

算法来训练优化ANN的参数。PSO算法通过个体间的协作和竞争实现全局搜索,降低了陷于局部最优解的风险。但是,Angeline的研究表明^[4],基本PSO算法局部搜索能力较差,收敛速度不快。为克服这一缺陷本文试图对基本PSO算法进行改进,以提高其寻优能力和速度。

本文将BP、基本PSO和改进PSO三种算法用于训练ANN,并将训练后的ANN用于径流预报,以比较它们在寻优能力和径流预报精度方面的优劣。采用的数据是三峡水库的入库径流数据,以历史入库径流数据预报将来入库径流量,以2002~2004年的日平均入库径流数据集作为训练样本,以2005年的日平均入库径流数据集作为检验样本。

2 基于神经网络的径流预报模型

2.1 神经网络原理

ANN是对人脑或自然神经网络若干基本特性的抽象和模拟,是一种基于连接学而构造的智能仿生模型,是由大量神经元组成的非线性动力系统。神经网络

收稿日期:2012-02-24

基金项目:国家自然科学基金项目(40701024)

作者简介:董晓华(1972-),湖北宜昌人,教授,博士,主要从事水文水资源领域的研究。E-mail: xhdong@ctgu.edu.cn

由互相连接的细胞(神经元)组成。神经元接受来自输入细胞或者其它神经元的脉冲信号,信号强度如果超过某一阈值,则通过转换函数(Transfer Function)对其进行转换,然后将输出传递给其它神经元或输出细胞。神经网络由互相连接的神经元层组成,接受从前层神经元发送过来的信号,作为自己的输入,将此输入传输给后面层的神经元,被传输的信号被乘以连接权值^[5],直至最终的信号从输出层的神经元输出。

2.2 径流预报模型构建

(1)输入层的神经元数的确定。在水文预报中,预报变量与输入变量之间存在一定的内在联系,所以本文采用自相关函数对径流量进行自相关分析,以此来确定输入层的神经元数。所得结果如图1所示^[6]。

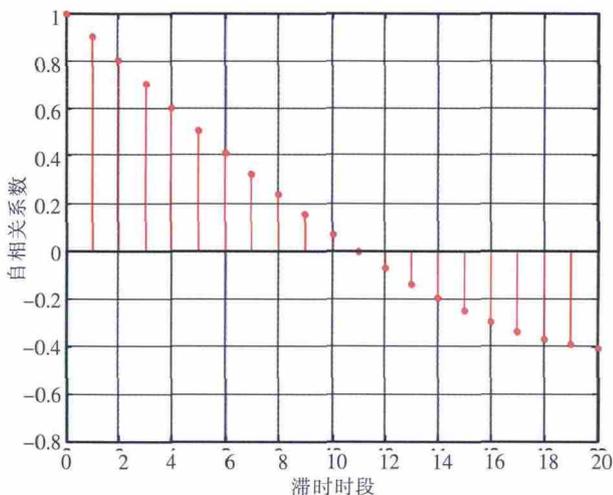


图1 径流量滞时-自相关系数关系曲线图

Fig.1 The relation between runoff lag time and auto-correlation coefficient

由图1所示,当前时段的前4个时段与当前时段的自相关系数大于0.6,可以认为与当前时段的相关程度最大,所以取当前时段的前4个时段的径流量为输入层神经元的输入信息,故输入层的神经元数取为4个。

(2)隐含层神经元数的确定。根据文献^[7]隐含层神经元个数和输入层神经元个数之间有以下经验关系:

$$n_2 = 2n_1 + 1 \quad (1)$$

式中: n_2 为隐含层神经元个数; n_1 为输入层神经元个数。

根据以上经验公式确定隐含层神经元个数为9。

(3)输出层神经元数的确定。由于本文考虑的是对三峡入库径流量的预报,所以输出层神经元数取为1。所以,本文所建立的ANN网络模型结构为4-9-1。

3 网络训练算法

网络训练算法实质上就是训练规则,是通过一组样本数据来训练网络。由于结构体系的不同,训练的规则也不相同,但大部份的规则可以被分为二大类别:监管的及非监管的。监管方式的训练规则需要“教师”告诉他们特定的输入应该作出怎样的输出。然后训练规则会调整所有需要调整的权重值,而整个过程会重头开始直至网络计算的输出与观测值之间的吻合度达到预先设定的精度。

网络训练算法有许多种,下面分别介绍本文应用的BP算法、PSO算法、平均粒子群算法。

3.1 BP算法

BP算法也称误差反向传播算法(Error Back-propagation Algorithm),是一类有监管的学习算法,用于BP网络的权值和阈值学习。BP算法学习过程由信号的正向传播与误差的反向传播两个过程组成。这种信号正向传播与误差反向传播的各层权值调整过程,是周而复始地进行的。此过程一直进行到网络输出的误差减少到可接受的程度,或进行到预先设定的学习次数为止^[8]。

3.2 粒子群算法

PSO算法是一种群体优化算法,是Kennedy和Eberhart在1995年为模拟鸟群和鱼群的社会行为时开发的^[9]。最初用于解决连续优化问题。由于算法收敛速度快、简单易行,近年来的应用越来越广泛。

PSO算法的基本原理为:设寻优空间为 D 维,总粒子数为 n ,向量 $X_i=(x_{i1}, x_{i2}, \dots, x_{id}, \dots, x_{iD})$ 表示第 i 个粒子的位置,其中 x_{id} 表示第 i 个粒子在第 d 维的位置; $P_i=(p_{i1}, p_{i2}, \dots, p_{id}, \dots, p_{iD})$ 表示第 i 个粒子迄今为止搜索到的最优位置, p_{id} 表示第 i 个粒子迄今为止搜索到的最优位置在第 d 维上的坐标;整个粒子群迄今为止搜索到的最优位置为 $P_g=(p_{g1}, p_{g2}, \dots, p_{gd}, \dots, p_{gD})$;向量 $V_i=(v_{i1}, v_{i2}, \dots, v_{id}, \dots, v_{iD})$ 表示第 i 个粒子的位置变化率(速度),其中 v_{id} 表示第 i 个粒子在第 d 维上的位置变化率(速度)。第 i 个粒子在 $t+1$ 时刻在 d 维空间上的速度 $v_{id}(t+1)$ 和位置 $x_{id}(t+1)$,以前一时刻 t 的速度 $v_{id}(t)$ 和位置 $x_{id}(t)$ 为基础,按以下公式进行更新变化:

$$v_{id}(t+1) = v_{id}(t) + c_1 \times r_1 \times (p_{id}(t) - x_{id}(t)) + c_2 \times r_2 \times (p_{gd}(t) - x_{id}(t)) \quad (2)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1), i=1, 2, \dots, n; d=1, 2, \dots, D; \quad (3)$$

式中: c_1, c_2 为加速因子, c_1 调节粒子飞向自身最好的位置方向的步长, c_2 调节粒子向全局最好位置飞行的步长; r_1, r_2 为 $[0, 1]$ 之间的随机数; c_1 和 c_2 的数值一般取 2.0。

然后根据公式(2)、(3)对网络的每个个体的位置和速度进行迭代更新^[9-10]。

3.3 平均线性粒子群算法

上述基本粒子群算法在应用中发现容易陷入局部最优, 导致收敛精度低和收敛速度慢^[11]。因此本文使用一种改进的粒子群算法, 希望通过使粒子在获得更多的信息的前提下来调整自己的状态, 降低陷入局部最优的几率。对基本粒子群算法中的个体极值 p_{best} 改变其取值方式, 并加入惯性权重, 惯性权重线性递减, 改变粒子群的搜索规则。

改进的粒子群算法如下:

$$w(i) = w_{\max} - \frac{w_{\max} - w_{\min}}{iter \max} * i \quad (4)$$

$$\bar{p}_{i,v} = (p_{v,1}, p_{v,2}, \dots, p_{v,V}) \quad (5)$$

$$p_{v,j} = (p_{1j} + p_{2j} + \dots + p_{ij}) / n, j = 1, 2, \dots, D; \quad (6)$$

式中: $w(i)$ 表示第 i 代的惯性权重; i 表示代数; w_{\max}, w_{\min} 分别表示最大惯性权重和最小惯性权重; $iter \max$ 表示最大迭代次数; $\bar{p}_{i,v}$ 表示第 i 代整个粒子群的速度平均值; $p_{v,j}$ 表示整个粒子群在第 j 维上的速度平均值。

改进后的速度更新公式为:

$$v_{id} = w_i * v_{id} + c_1 * r_1 * (p_{id} - x_{id}) + c_2 * r_2 * (p_{gd} - x_{id}) \quad (7)$$

将基本粒子群中的 p_{id} 改为 v_{id} , 有以下几方面好处: 从信息量的角度说, 新算法中每个粒子借鉴了其它粒子的经验; 从行为方式上讲, 粒子不再在群最优和自身最优之间进行搜索, 而是在群最优和粒子最优中心位置之间进行搜索, 改进后的粒子群算法粒子的行为方式不同于基本粒子群, 并且, 不是所有的粒子都参与群最优的邻域搜索, 部分粒子会在个体平均极值和全局极值之间进行邻域搜索, 而且, 在收敛过程中, 个体平均极值和全局极值的位置不断被粒子搜索拉近, 使得算法最终收敛。在此给它命名为平均线性粒子群算法, 英文名为 Mean linear particle swarm optimization 简记为 ML-PSO。

3.4 改进的 PSO 优化 BP 神经网络

改进 PSO 优化 BP 神经网络的基本思路: 把改进的 PSO 算法与 BP 算法计算误差方法相结合, 以网络输出值与期望值之间的误差作为适应度, 用一群粒子在可行解空间内去搜索全局最优位置即全局最优解, 最后得到的全局最优解也就是网络的最优权值和阈

值。其流程图如图 2 所示^[12]。

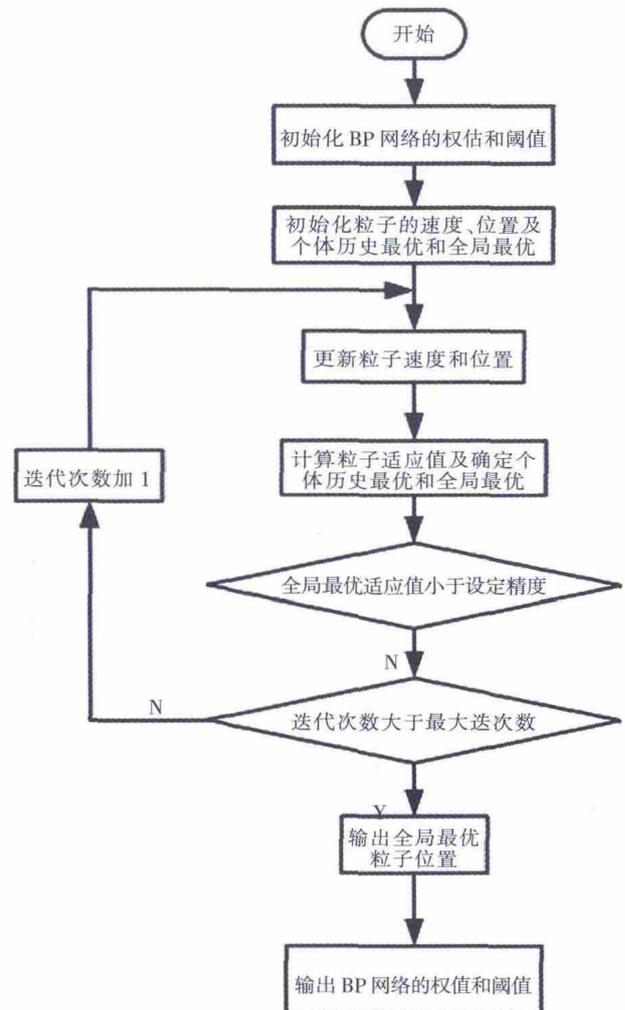


图 2 粒子群算法优化 BP 网络的流程图

Fig.2 The flow of applying PSO algorithm to optimize BP networks

图 2 表示的是用平均粒子群算法优化 BP 网络的权值和阈值。其具体过程如下: 先初始化 BP 网络结构; 再根据神经网络结构确定粒子总数, 计算每个粒子的适应度, 比较适应度, 确定每个粒子的个体极值点和全局最优极值点; 然后更新每个粒子的位置和速度; 若满足条件, 则搜索停止, 输出全局最优位置, 否则, 返回继续比较适应度, 更新每个粒子的位置和速度, 直到满足条件为止。

4 应用与结果

4.1 标准函数测试结果

为了验证改进的算法的性能, 本文采用了以下三个常用测试函数进行测试。

(1) Rosenbrock 函数

$$f(x) = \sum_{i=1}^{N-1} [100 * (x_{i+1} - x_i)^2 + (x_i - 1)^2]; x_i \in [-5, 5] \quad (8)$$

(2) Sphere 函数

$$f(x) = \sum_{i=1}^{N-1} x_i^2; x_i \in [-5.12, 5.12] \quad (9)$$

(3) Schaffer 函数

$$f(x) = \sum_{i=1}^{N-1} (x_i^2 + x_{i+1}^2)^{0.25} [\sin^2(50(x_i^2 + x_{i+1}^2)^{0.1}) + 1]; x_i \in [-100, 100] \quad (10)$$

上述三个测试函数的全局极小值都是 $f(x)=0$ 。为直观体现平均线性粒子群算法的全局优化性能,将对二维 Schaffer 函数的寻优过程展示在图 3 和图 4 中。

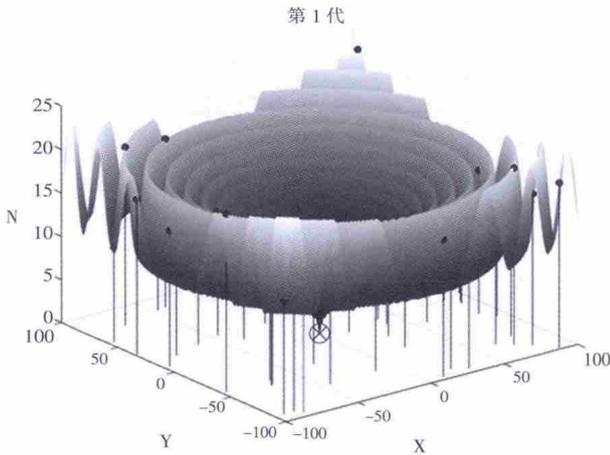


图 3 寻找 Schaffer 函数的极小值点之前随机产生的初始粒子群的位置
Fig.3 The randomly initialized positions of the particles prior to the searching of the minimum of the Schaffer function

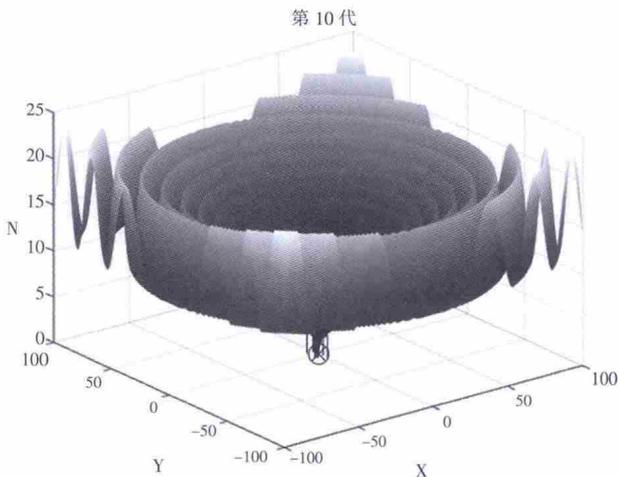


图 4 进化到第 10 代的粒子群在 Schaffer 函数上的位置
Fig.4 The positions of the particles on the Schaffer function after 10 generations evolutions

图 3 中的点是开始寻优之前,随机产生的初始粒子群的位置,均匀分布在寻优空间中。图 3 正中下方的以 \otimes 标示的点是全局最小点,坐标是 $[0, 0, 0]$ 。优化的目的是找到这一全局最小点。图 4 给出了进化到第 10 代的粒子群在 Schaffer 函数上的位置,已经都集中在最优点附近,可见对 Schaffer 函数的寻找极小值的优化到第 10 代就已经收敛的很好了,说明平均粒子群算法收敛快,具有很好的寻优能力。

根据本文预报模型的需要,又测试了优化高维函数的能力。3 个测试函数的自变量维数取 $D=20$,粒子数 $n=50$, PSO 算法参数设置如下: $c_1=2.0$, $c_2=2.0$, $W_{max}=0.9$, $W_{min}=0.3$, $V_{max}=10$,每个函数优化每次迭代 2 000 次,重复 40 次。计算结果如表 1 所示。

表 1 三种函数测试结果
Table 1 The test results of three testing functions

算法	函数	平均迭代次数	平均解	均方差
	Rosenbrock	1489.5	125.26	8.62
PSO	Sphere	1458.9	0	0
	Schaffer	1652.3	59.52	4.18
	Rosenbrock	1457.8	35.12	4.29
ML-PSO	Sphere	1365.3	0	0
	Schaffer	1482.4	47.75	4.35

注:以上函数用的粒子群算法参数为:粒子个数为 50 个,维数 20,最大迭代次数 2 000。

从表 1 可以看出,改进后的粒子群算法的平均迭代次数要比基本粒子群算法要小,说明了改进后的粒子群算法要比基本粒子群算法的收敛速度快。

改进的算法的平均解比基本算法小,说明改进的粒子群算法寻优的平均水平要比基本粒子群算法要好。

寻优结果的均方差表明了算法寻优过程的稳健性,均方差越接近于 0,说明寻优轨迹在最优解附近摆动的幅度越小,算法越稳健。从表 1 的均方差值可以看出,改进后的粒子群算法要比基本粒子群算法的稳健性要好。对于 Rosenbrock 测试函数,使用 ML-PSO 算法的寻优结果的均方差值要比基本 PSO 算法的显著小, Sphere 函数的持平(均为 0),而 Schaffer 函数的反而要比算法改进前稍大。原因可能在于 Schaffer 函数的形状在 3 个测试函数中最复杂,致使寻优过程摆动幅度较大,稳健度稍差。但是表征算法优劣的寻优结果,使用改进算法于 Schaffer 函数后仍有大幅度提高

(平均解从 59.52 降低至 47.75)。

总体来说,改进后粒子群算法要比基本粒子群算法的性能要好,所以可以用它来更好地优化人工神经网络来用于径流预报。

4.2 径流预报结果

ML-PSO 算法的参数固定取粒子数为 40,最大迭代次数为 100, $c_1=c_2=2$, w 为常数 0.9。用此粒子群算法优化上面建立好的 BP 网络来训练网络,用三峡水库 2002~2004 年的数据作为训练样本,结果如图 5^[13-14]。

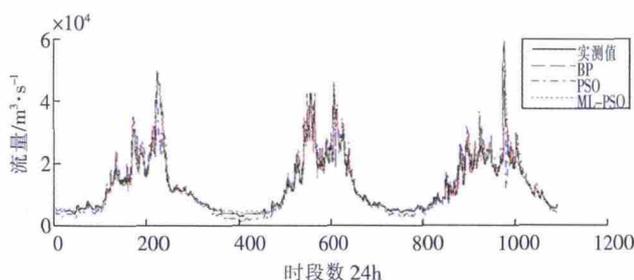


图 5 使用 3 种不同的训练算法所得的率定结果(率定期为 2002~2004 年)
Fig.5 The calibration results by using 3 training algorithms
(calibration period is from year 2002 to 2004)

从图 5 可以看出,用粒子群算法优化后的网络预报径流效果良好。训练好网络后,还需用检验样本对其进行检验。本文采用三峡 2005 年入库流量对其进行了检验并与传统网络进行了比较。

4.3 BP 网络、PSO-BP 网络与 MLPSO-BP 网络的比较

为了进一步检验用 ML-PSO 算法优化的 ANN 网络预报效果,本文又采用了 2005 年日平均流量来检验,并与传统的 BP 网络和基本 PSO 算法的预报结果进行了比较。预报的结果如图 6 所示^[15]。

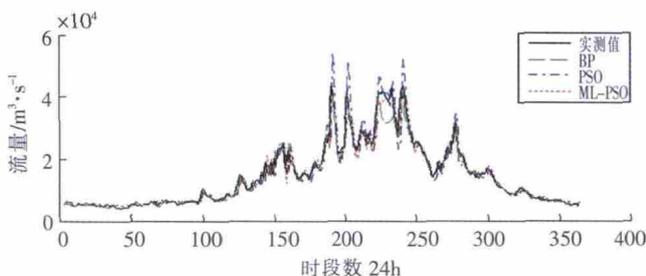


图 6 使用 3 种不同的训练算法所得的检验结果(检验期为 2005 年)
Fig.6 The test results by using 3 training algorithms
(testing period is the year 2005)

从以上两个图可以观察出优化后的 BP 网络整体上明显要比传统 BP 网络预报误差小,特别是改进后

PSO 网络的预报效果要好,这也为三峡的主汛期的洪水预报提供一定的参考价值。

为了更客观地评估计算的与观测的流量过程的接近程度,使用相对平均绝对误差^[16](Relative Mean Absolute Error - RMAE)和确定性系数^[17](Deterministic Coefficient - DC)评定计算流量过程的误差。计算结果见表 2。

表 2 基于 BP 网络、PSO 网络
与 ML-PSO 网络的预报模型的应用效果比较
Table2 Comparison of the forecasting accuracies
among BP, PSO and ML-PSO networks

评价指标	率定期		检验期	
	RMAE	DC	RMAE	DC
BP 网络	0.055	0.96	0.07	0.89
PSO-BP 网络	0.005	0.95	0.04	0.92
MLPSO-BP 网络	0.003	0.95	0.0102	0.96

从表 2 可以看出,基本的粒子群算法优化后的人工神经网络要比传统的 BP 网络预报效果要好得多,改进的 ML-PSO 算法又要比基本粒子群算法优化的要好。

5 结论

本文使用平均线性粒子群,粒子群和 BP 算法来优化人工神经网络的参数,使用标准函数测试了 3 种算法的全局优化性能,然后用它们对三峡水库的入库径流进行预报,以比较它们的预报性能。

结果表明平均粒子群算法在寻找全局最优时收敛速度最快,最稳定。基于平均粒子群算法的人工神经网络的径流预报能力最高,其在率定期的相对平均绝对误差(RMAE)比粒子群算法减少了 40%,比 BP 算法减少了 94%;确定性系数(DC)区别不大;而在检验期相对平均绝对误差也要比粒子群算法减少了 20%,比 BP 算法减少了 54%。

参考文献:

- [1] Hayking S. Neural Networks: A Comprehensive Foundation [M]. Prentice-Hall, 1999.
- [2] Funhashi K.I. On the approximate realization of continuous mappings by neural networks[J]. Neural Networks, 1989, 2(3): 183-192.
- [3] Hornik K. Approximation capabilities of multilayer feedforward networks[J]. Neural Networks, 1991, 4(2): 251-257.
- [4] Angeline P. Evolutionary optimization versus particle swarm optimization: Philosophy and performance differences [A]. Springer, 1998: 601-610.
- [5] 努尔买买提·艾尼瓦尔. 人工神经网络及其应用[J]. 和田师范专科学校学报(汉文综合版), 2009, (1): 246-247. (Ainiwaer Nuermaimaiti. Ar-

- tical neural network and its application[J]. Hetian Normal School Journal, 2009, (1): 246-247. (in Chinese)
- [6] 袁飞, 任立良, 姜红梅, 等. MATLAB 神经网络工具箱在径流模拟中的应用[J]. 人民长江, 2003, 34(6): 38-40.(YUAN Fei, REN Liliang, JIANG Hongmei, et al. The application of matlab neural network tool in runoff simulation[J]. Yangtze River, 2003, 34(6): 38-40. (in Chinese))
- [7] Kannan S., Slochanal S., Subbara J P., et al. Application of particle swarm optimization technique and its variants to generation expansion planning problem [J]. Electric Power Systems Research, 2004, 70(3): 203-210.
- [8] 贾丽会, 张修如. BP 算法分析与改进 [J]. 计算机技术与发展, 2006, 16(10): 101-103.(JIA Lihui, ZHANG Xiuru. Analysis and improvement of BP algorithm [J]. Computer Technology and Development, 2006, 16(10): 101-103. (in Chinese))
- [9] Kennedy J., Eberhart R. Particle swarm optimization [A]. IEEE, 1995:1942-1948.
- [10] 徐旭, 姜飞. 简述粒子群算法的原理及改进[J]. 计算机学报, 2008, 2 (12).(XU Xu, JIANG Fei. The brief introduction to the principle and improvement of the particle swarm optimization algorithm[J]. Computer, 2008, 2(12). (in Chinese))
- [11] 王存睿, 段晓东, 刘向东, 等. 改进的基本粒子群优化算法 [J]. 计算机工程, 2004, 30 (21): 35-37.(WANG Cunrui, DUAN Xiaodong, LIU Xiangdong, et al. A modified basic particle swarm optimization algorithm[J]. Computer Engineering, 2004, 30(21): 35-37. (in Chinese))
- [12] 王涛, 王晓霞, 刘敬刚. 基于改进粒子群优化的神经网络训练算法 [A]. 第二届中国智能计算大会论文集 [C], 2008.(WANG Tao, WANG Xiaoxia, LIU Jinggang. The training algorithm of neural network based on the improved particle swarm optimization algorithm [A]. The Proceedings of the Second Chinese Intelligent Computation Conference[C], 2008. (in Chinese))
- [13] 何伟, 李亚伟, 金栋, 等. 基于 PSO 的模糊人工神经网络径流预报模型 [J]. 气象水文海洋仪器, 2004, (2): 18-21.(HE Wei, LI Yawei, JING Dong, et al. Fuzzy artificial neural network runoff prediction model based on the particle swarm optimization algorithm[J]. Meteorological Hydrological Marine Instrument, 2004, (2): 18-21. (in Chinese))
- [14] 杨道辉, 马光文, 杨梅. 粒子群小波人工神经网络组合模型的径流预测[J]. 水力发电, 2009, (1): 4-6.(YANG Daohui, MA Guangwen, YANG Mei. Monthly runoff forecasting by WANN model based on PSO[J]. Hroelectric Power, 2009, (1): 4-6. (in Chinese))
- [15] 冯国章, 李佩成. 人工神经网络结构对径流预报精度的影响分析 [J]. 自然资源学报, 1998, 13 (2): 169-174.(FENG Guozhang, LI Peicheng. An analysis of effect of artificial neural network structures on precision of stream flow forecasting [J]. Journal of Natural Resources, 1998, 13(2): 169-174. (in Chinese))
- [16] Maidment D.R. Handbook of Hydrology [M]. McGraw-Hill Inc., 1992.
- [17] Nash J E, Sutcliffe J V. River flow forecasting through conceptual models (part I): A discussion of principles[J]. Journal of Hydrology, 1970, 10(3): 282-290.

Application of Artificial Neural Networks in Runoff Forecasting Based on Mean Linear Particle Swarm Optimization Method

DONG Xiaohua, LIU Chao, YU Dan, LI Lei, LV Zhixiang, SONG Sanhong

(College of Hydraulic and Environmental Engineering, China Three Gorges University, Yichang 443002, China)

Abstract: Artificial neural networks (ANNs) are effective tools in forecasting runoff in river because of their power capability in mapping in-output relations. However, the traditional ANNs based on back-propagation training algorithm need improvement because they have shortcomings in long training times and prone in falling into local optimum points. Therefore, 3 algorithms were used to train the ANNs—mean linear particle swarm optimization (ML-PSO) method, original particle swarm optimization (PSO) method and BP method. Their global optimization capabilities were first tested by using the 3 standard mathematical functions, and the ANNs based on the 3 training algorithms were applied in runoff forecasting to test their performances. The results show that among the 3 algorithms, the ML-PSO algorithm is the fastest and most robust one in finding global optimum, and it also is the most accurate one in forecasting runoff.

Key words: runoff forecasting; artificial neural networks; mean linear particle swarm optimization algorithm; particle swarm optimization algorithm; back-propagation algorithm