

# 基于自适应粒子群算法优化神经网络的多沙水库 冲淤预测模型研究及应用

吴 巍,周孝德,王新宏,程 文

(西安理工大学 西北水资源与环境生态教育部重点实验室,陕西 西安 710048)

**【摘 要】**【目的】针对传统多沙水库冲淤预测模型难以准确、迅速预测某一具体水库调度运行方式下泥沙的冲淤变化过程,无法为制定合理水库调度运行方式提供决策依据的不足,构建一种计算效率高、能保证一定计算精度且相对简便的泥沙冲淤预测模型。【方法】将人工神经网络及粒子群优化算法引入到多沙水库冲淤预测中,构建基于自适应粒子群算法优化 BP 神经网络的多沙水库冲淤预测模型,并将该模型应用于冯家山水库库区泥沙冲淤形态、冲淤量的预测,验证其实用性。【结果】将多沙水库冲淤变化过程视为一个非线性动力系统,利用人工神经网络处理大规模复杂非线性动力学问题的优势,在采用自适应粒子群优化算法对 BP 神经网络的初始连接权值和阈值进行优化的基础上,成功构建了基于自适应粒子群算法优化 BP 神经网络的多沙水库冲淤预测模型。该模型在冯家山水库冲淤预测中的应用结果表明,模型计算值与实测值之间吻合良好,可满足实际水库管理的需要。【结论】所构建模型具有较强的合理性及较广的适用性,为多沙水库冲淤预测提供了一条有效途径。

**【关键词】** 多沙水库;冲淤预测模型;BP 人工神经网络;自适应粒子群优化算法

**【中图分类号】** TV697.3<sup>+1</sup>

**【文献标识码】** A

**【文章编号】** 1671-9387(2011)04-0216-11

## Research and application on the deposition-scouring prediction model based on the neural network optimized by the adaptive particle swarm optimization algorithm in the heavily sediment-laden reservoir

WU Wei,ZHOU Xiao-de,WANG Xin-hong,CHENG Wen

(Key Lab of Northwest Water Resources and Environment Ecology of MOE at XAUT,Xi'an,Shaanxi 710048,China)

**Abstract:**【Objective】The traditional deposition-scouring prediction model of the heavily sediment-laden reservoir was difficult to predict accurately and quickly the process of scour and deposition in a specific reservoir operational mode. And the traditional mode was unable to provide decision basis to develop a reasonable reservoir operational mode. For above reason,it was necessary to build an efficient, high precision and relatively simple deposition-scouring prediction model.【Method】The artificial neural network and particle swarm optimization algorithm were brought into the deposition-scouring predication of the heavily sediment-laden reservoir. Based on the BP artificial neural network optimized by the adaptive particle swarm optimization algorithm,the deposition-scouring predication model was built in the heavily sediment-laden reservoir. Then the model was applied to predict the deposition-scouring amount and pattern of the Fengjiashan reservoir.【Result】The deposition-scouring process of heavily sediment-laden reservoir was regarded as a nonlinear dynamic system. Using the artificial neural network advantages in aspect of handling

\* [收稿日期] 2011-02-18

[基金项目] 国家科技重大水专项(2009ZX07212-002-001-04,2008ZX07106-4-01)

[作者简介] 吴 巍(1980—),男,山西寿阳人,在读博士,主要从事水力学及河流动力学研究。E-mail:wuweifirst@126.com

large and complex nonlinear dynamics problem, the deposition-scouring predication model of heavily sediment-laden reservoir was successfully built. Meanwhile, the adaptive particle swarm optimization algorithm was utilized to optimize the initial weight and bias values of BP artificial neural network to improve performance. The predication results of Fengjiashan reservoir showed that the calculated and measured values were in good agreement, so the model could meet the practical needs of reservoir management. 【Conclusion】 The model had strong rationality and wide applicability. An effective way was provided to predict the deposition-scouring process of heavily sediment-laden reservoir.

**Key words:** heavily sediment-laden reservoir; deposition-scouring prediction model; BP artificial neural network; adaptive particle swarm optimization algorithm

建于多泥沙河流上的水库始终备受泥沙淤积问题的困扰,为保障水库效益的充分发挥,就必须妥善解决泥沙淤积这一难题,而水库库区冲淤变化主要受上游来水来沙及调度运行方式2个因素的影响。其中,上游来水来沙受制于流域产流、产沙情况,与所属流域特性及水土保持状况等相关,在一个相对较短的时间尺度内属于随机性因素;水库调度运行方式则与之不同,不同调度运行方式下的冲淤变化过程各具特点,属可主动控制性因素。因此,制定合理的调度运行方式,是解决水库泥沙淤积这一难题的有效途径之一,而相应的水库泥沙冲淤预测计算作为其前提和基础,直接影响着水库调度运行方式的制定。

目前,水库泥沙冲淤预测计算的方法主要有水动力学方法和水文学方法<sup>[1]</sup>。水动力学方法考虑了泥沙冲淤的物理过程,能够揭示冲淤变化过程的内在机理,在实际工程中应用广泛,但计算所需参数众多,过程较为繁琐,所需时间亦较长<sup>[2]</sup>。水文学方法则缺乏一定的物理基础,其结果主要是通过对大量实测资料的统计分析得出的,因此实际应用的广度及深度受到很大限制<sup>[2]</sup>。

在实际水库管理过程中,多沙水库调度运行方式的制定是根据库区泥沙冲淤变化过程及水库的其他兴利目标,通过实时动态反复调整水库运行策略而实现的。在此过程中,若调用前述2种方法对水库泥沙冲淤变化过程进行预测计算,则水动力学方法会由于其计算速度的限制而无法满足现实需求,水文学方法则难以保证计算精度。为此,需要构建一种计算效率高、能保证一定计算精度且相对简便的泥沙冲淤计算模型,该模型能够根据上游来水来沙条件,准确、迅速地预测出某一具体水库调度运行方式下泥沙的冲淤变化过程,从而为水库管理提供决策依据。

多沙水库冲淤受上游来流量、来沙量、库区地形

及下游控制基准面等动力因子的共同影响,可视为一个复杂的非线性动力系统,在这一系统中,以水流、泥沙及边界等条件为输入,水库冲淤变化(冲淤量、冲淤形态等)为输出。人工神经网络<sup>[3-4]</sup>作为一种新兴的方法,其主要特征之一就是高度的非线性作用,能够实现从输入状态到输出状态的非线性映射,具有处理大规模复杂非线性动力学问题的能力,而且其良好的容错性、鲁棒性以及自适应、自学习功能,也为其处理非线性问题提供了保证。因此,神经网络模型的这些特点,决定了其适用于解决多沙水库冲淤这一非线性问题。目前,应用最多、研究比较成熟的多层前馈网络误差反传递算法模型,即BP神经网络(Back Propagation Network),是人工神经网络的核心模型之一。但在应用BP神经网络进行模拟预测时,其对初始权值的依赖性较大,同时有诸如网络结构等诸多参数需要调整拟定,这些参数取值的合理与否直接影响着模型的收敛速度和预测精度,而且当目标函数存在多个极值点时亦容易陷入局部最优,这些缺陷导致BP神经网络的输出具有不一致性和不可预测性,降低了模拟预测的可靠性。

为了改善上述问题,可引入自适应粒子群优化算法(Adaptive Particle Swarm Optimization, AP-SO)对BP神经网络进行优化。自适应粒子群优化算法是粒子群优化算法(Particle Swarm Optimization, PSO)<sup>[4-5]</sup>的一种改进形式,是一种新兴的全局随机优化算法,其需要调整的参数不多,结构简单,易于实现,具有较强的通用性和全局寻优能力。应用自适应粒子群优化算法对BP神经网络进行优化,主要是对网络的初始连接权值和阈值进行优化,在计算中先用自适应粒子群优化算法对网络权值和阈值进行全局最优化搜索,待搜索范围缩小至一定区间后,再返回利用BP神经网络进行精确求解,从而达到全局搜索与精确求解的良好结合,缩短BP神经网络的训练时间,避免网络陷入局部最优,提高

网络训练精度。

鉴于以上分析,本研究将人工神经网络及粒子群优化算法引入到多沙水库冲淤预测计算中,构建基于自适应粒子群算法优化的 BP 神经网络模型,以此进行多沙水库泥沙冲淤的快速预测计算,并将其应用到渭河一级支流千河上的冯家山水库,对库区泥沙冲淤形态、冲淤量等进行计算,对模型实效进行检验,以期多沙水库冲淤预测计算提供一条新的有效途径。

## 1 基于 APSO-BP 的多沙水库冲淤预测模型的构建

### 1.1 模型构建的基本原理

1.1.1 BP 神经网络<sup>[3,6]</sup> BP 神经网络是人工神经网络中最为重要的模型之一,该网络的主要特点是信息正向传递、误差反向传播。在信息正向传递中,输入的信息由输入层经隐含层到输出层逐层处理,并计算得到各神经元节点的预测输出值,计算中每一层的神经元状态只影响下一层神经元状态。网络预测输出与期望输出之间的误差若未达到允许值,则转入反向传播,根据误差确定网络权值和阈值的修正量,自后往前逐层修改各层神经元节点的连接权值和阈值,从而使 BP 神经网络的预测输出不断逼近期望输出。

设有 3 层 BP 神经网络,输入层节点数为  $n$ ,隐含层节点数为  $l$ ,输出层节点数为  $m$ ,网络输入为  $x_i$  ( $i=1,2,\dots,n$ ),预测输出为  $y_k$  ( $k=1,2,\dots,m$ ),输入层与隐含层节点之间的连接权值为  $w1_{ji}$  ( $i$  同上;  $j=1,2,\dots,l$ ),隐含层与输出层节点之间的连接权值为  $w2_{kj}$ ,隐含层阈值为  $\theta1_j$ ,输出层阈值为  $\theta2_k$ ,隐含层传递函数为  $f(x)$ ,输出层传递函数为  $g(x)$ 。当期望输出为  $t_k$  时,BP 算法的数学推导过程如下:

1)信息正向传递过程。

① 隐含层输出:

$$y'_j = f\left(\sum_{i=1}^n w1_{ji}x_i + \theta1_j\right)。 \quad (1)$$

② 输出层预测输出:

$$y_k = g\left(\sum_{j=1}^l w2_{kj}y'_j + \theta2_k\right)。 \quad (2)$$

③ 误差函数:

$$E = \frac{1}{2} \sum_{k=1}^m (t_k - y_k)^2。 \quad (3)$$

2)误差反向传播过程。BP 神经网络在误差反向传播过程中,逆向对网络权值和阈值进行修正,具体数学描述为:  $w'^{t+1} = w' + \eta \Delta w'$ ,  $\theta'^{t+1} = \theta' + \eta \Delta \theta'$ ,其

中  $w'^{t+1}$ 、 $\theta'^{t+1}$  分别为修正后的网络权值和阈值,  $w'$ 、 $\theta'$  分别为当前的网络权值和阈值,  $\Delta w'$ 、 $\Delta \theta'$  分别为网络权值和阈值的修正量,  $\eta$  为学习速率。修正采用梯度下降法进行,即沿着误差函数下降最快的方向(负梯度方向)来计算网络权值和阈值的修正量。

① 输出层权值及阈值修正。

权值修正量:

$$\Delta w2_{kj} = -\eta \frac{\partial E}{\partial w2_{kj}} = \eta(t_k - y_k)g'y'_j = \eta\delta_{kj}y'_j。 \quad (4)$$

式中:  $e_k = t_k - y_k$ ,  $\delta_{kj} = e_k g'$ 。

阈值修正量:

$$\Delta \theta2_k = -\eta \frac{\partial E}{\partial \theta2_k} = \eta(t_k - y_k)g' = \eta\delta_{kj}。 \quad (5)$$

② 隐含层权值及阈值修正。

权值修正量:

$$\Delta w1_{ji} = -\eta \frac{\partial E}{\partial w1_{ji}} = \eta \sum_{k=1}^m (t_k - y_k)g'w2_{kj}f'_{x_i} = \eta\delta_{ji}x_i。 \quad (6)$$

式中:  $e_j = \sum_{k=1}^m \delta_{kj}w2_{kj}$ ,  $\delta_{ji} = e_j f'$ 。

阈值修正量:

$$\Delta \theta1_j = -\eta \frac{\partial E}{\partial \theta1_j} = \eta \sum_{k=1}^m (t_k - y_k)g'w2_{kj}f' = \eta\delta_{ji}。 \quad (7)$$

在实际应用中,用上述梯度下降法修正网络权值和阈值时,最初阶段下降较快,但随着其向最优值的逼近,梯度趋于零,致使误差函数下降缓慢,不可避免地使 BP 神经网络存在迭代次数多、运算时间长、收敛性差的缺陷。因此,目前 BP 神经网络常采用 Levenberg-Marquardt 优化算法来改进权值和阈值,该算法能使每次迭代不再沿着单一的负梯度方向下降,而是允许误差沿着恶化的方向进行搜索,因而大大提高了网络的收敛速度。

1.1.2 自适应粒子群优化算法 APSO 算法是 PSO 算法的一种改进形式。PSO 算法<sup>[4-5]</sup>源于对鸟类捕食行为的研究,鸟类捕食时,每只鸟找到食物最简单有效的方法就是搜寻当前距离食物最近的鸟的周围区域。PSO 算法受这种生物种群行为特征的启发,将其应用于求解优化问题。算法首先在可解空间中初始化一群粒子,每个粒子都代表优化问题的一个潜在解,用位置、速度和适应度值 3 项指标表示该粒子的特征,适应度值由适应度函数计算得到,其值的好坏表示粒子的优劣。粒子在解空间中运

动,通过跟踪个体极值和群体极值更新个体位置,个体极值是指个体所经历位置中计算得到的适应度最优位置;群体极值是指种群中的所有粒子搜索到的适应度最优位置。粒子每更新一次位置,就计算一次适应度值,并且通过比较新粒子的适应度值和个体极值、群体极值的适应度值,来更新个体极值和群体极值,更新过程可用如下数学形式进行描述。

设在1个 $d$ 维搜索空间中,由 $n$ 个粒子组成种群 $X=(X_1, X_2, \dots, X_n)$ ,其中第 $i$ 个粒子表示为1个 $d$ 维的列向量 $X_i=(x_{i1}, x_{i2}, \dots, x_{id})^T$ ,代表第 $i$ 个粒子在 $d$ 维搜索空间中的位置,亦即问题的一个潜在解。根据适应度函数即可计算出每个粒子位置 $X_i$ 对应的适应度值。第 $i$ 个粒子的速度为 $V_i=(v_{i1}, v_{i2}, \dots, v_{id})^T$ ,在 $t$ 时刻该粒子所经过的最佳位置(即个体极值)为 $P_i=(p_{i1}, p_{i2}, \dots, p_{id})^T$ ,群体所搜索到的最佳位置(即种群的全局极值)为 $P_g=(p_{g1}, p_{g2}, \dots, p_{gd})^T$ 。在每次迭代过程中,粒子通过个体极值和全局极值更新自身的速度和位置,更新公式为<sup>[5]</sup>:

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_1 [p_{ij} - x_{ij}(t)] + c_2 r_2 [p_{gj} - x_{ij}(t)]. \quad (8)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1), j=1, 2, \dots, d. \quad (9)$$

式中: $\omega$ 为惯性权重, $c_1$ 、 $c_2$ 为加速度因子, $r_1$ 、 $r_2$ 为 $[0, 1]$ 之间均匀分布的随机数。另外,为防止粒子的盲目搜索,需将粒子的位置、速度限制在一定的区间内,即 $v_{ij} \in [v_{\min}, v_{\max}]$ ,  $x_{ij} \in [x_{\min}, x_{\max}]$ ,当 $v_{ij} > v_{\max}$ 时取 $v_{ij} = v_{\max}$ ,当 $v_{ij} < v_{\min}$ 时取 $v_{ij} = v_{\min}$ 。

由上述更新公式可以看出,PSO算法的性能在很大程度上依赖于控制参数的取值,合理的参数取值能够有效控制与平衡算法的全局搜索和局部改良能力,对于快速、准确找到问题的最优解至关重要。PSO算法的参数改进主要体现在惯性权重和加速度因子的调节上,为此,本研究采用自适应非线性动态调节惯性权重策略及反余弦函数动态调节加速度因子策略,来改进传统粒子群优化算法,进而形成APSO算法。

1)自适应非线性动态调节惯性权重策略<sup>[5]</sup>。由粒子速度更新公式(8)可以看出,该式右侧第1部分代表粒子上时刻的速度对当前速度的影响,而惯性权重 $\omega$ 是决定粒子上时刻速度对当前速度影响的系数,通过调整该系数的值可以实现全局搜索与局部搜索之间的平衡。惯性权重值较大时,全局搜索能力强,局部搜索能力弱,有利于跳出局部极小点,避免陷入局部最优;惯性权重值较小时,全局搜

索能力弱,局部搜索能力强,有利于对当前的搜索区域进行精确局部搜索,便于算法收敛。粒子适应度值是反映粒子当前位置优劣的一个参数,与惯性权重关系密切,在实际应用中可采用自适应非线性动态调节惯性权重策略,使惯性权重值随粒子适应度值的变化而自适应调整,其计算公式如下:

$$\omega = \begin{cases} \omega_{\max}, & (fitness > fitness_{avg}), \\ \omega_{\min} + \frac{(\omega_{\max} - \omega_{\min})(fitness - fitness_{\min})}{(fitness_{avg} - fitness_{\min})}, & \end{cases} \quad (10)$$

式中: $\omega_{\min}$ 、 $\omega_{\max}$ 分别为惯性权重的最小值和最大值, $fitness$ 为粒子当前的适应度值, $fitness_{avg}$ 、 $fitness_{\min}$ 分别为所有粒子的平均适应度值和最小适应度值。由式(10)可见,当各粒子的适应度值趋于一致(趋于局部最优)时,惯性权重将增加;当各粒子的适应度值比较分散时,惯性权重将减小。同时,对于适应度值优于平均适应度值的粒子,其对应的惯性权重较小,从而保护了该粒子;反之,对于适应度值劣于平均适应度值的粒子,其对应的惯性权重较大,使得该粒子能够向较好的搜索区域靠拢。

2)非线性反余弦函数动态调节加速度因子策略<sup>[7]</sup>。同样由粒子速度更新公式(8)可以看出,该式右侧第2部分代表粒子当前位置与自己最优位置间的距离,体现了粒子自身记忆的影响;第3部分则代表粒子当前位置与群体最优位置间的距离,体现了粒子间的信息共享与合作。简言之,粒子在解空间搜索寻优时,一方面会考虑自身的经验,另一方面又会去顾及其他粒子的经验,当某一粒子认为其他粒子经验较好的时候,其将进行适应性的调整,以寻求粒子群整体的经验最优。而加速度因子 $c_1$ 和 $c_2$ 恰好决定了粒子自身经验与其他粒子经验对粒子运动轨迹的影响,反映了粒子群之间的信息交流。当 $c_1$ 值较大时,粒子将徘徊于局部解空间;当 $c_2$ 值较大时,则会使粒子过早收敛于局部最优值。比较理想的加速度因子取值原则应当是在搜索初期加快 $c_1$ 和 $c_2$ 的变化速度,让算法尽快完成对整个解空间的搜索,以便进入局部搜索;后期则取较大的 $c_2$ 值,使算法更侧重于粒子的全局特性,从而尽可能摆脱局部极值的干扰,避免早熟收敛。依此原则,采用反余弦函数来构造加速度因子的动态调节策略,该策略可随迭代次数的变化动态调节 $c_1$ 和 $c_2$ 值,其计算通式如下:

$$c = c_{\text{end}} - (c_{\text{end}} - c_{\text{start}}) \left[ 1 - \frac{\arccos\left(\frac{-2\text{Iteration} + 1}{\text{Iteration}_{\max}}\right)}{\pi} \right]. \quad (11)$$

式中: $c$  为  $c_1$  和  $c_2$  的通用写法, $c_{\text{start}}$ 、 $c_{\text{end}}$  分别为加速度因子的迭代初值和终值, $Iteration$  为当前迭代次数, $Iteration_{\text{max}}$  为最大迭代次数。

## 1.2 模型构建的步骤

1.2.1 影响因子分析 构建基于 APSO-BP 的多沙水库冲淤预测模型,首要前提是模型输入、输出变量的确定。出于服务水库调度运行方式制定这一目的,多沙水库冲淤预测主要侧重于库区泥沙冲淤量及冲淤形态 2 方面数据的计算,其中冲淤形态可通过直观表征河床冲刷下切及淤积升高的河床纵剖面(深泓线)来反映,因此确定预测模型的输出变量为库区泥沙冲淤量与特征断面深泓点冲淤深度。

模型输入变量的确定与影响多沙水库冲淤变化的因子相关。如前所述,多沙水库冲淤变化主要受上游来水来沙及调度运行方式等因素的影响。对于上游来水来沙这一因素,依据河流动力学原理,由其形成的水沙输移是库区河床塑造的基本动力。其中,来水作为运动的“载体”,大水挟大沙,小水挟小沙,是塑造河床的直接动力;径流量、径流过程及各流量级持续时间等要素决定了水沙两相流的造床动力特征,在河床演变中起着积极主动的作用。来沙则是运动的“荷体”,依水流条件而存在并发挥作用<sup>[6]</sup>,是改变河床形态的物质基础,输沙量、输沙过程、泥沙颗粒粗细及各含沙量级持续时间等均影响着河床冲淤变化的发展方向,在河床演变中处于被动的地位<sup>[8]</sup>。水库调度运行方式是目前水库泥沙冲淤控制的主要手段,根据对实测资料的分析认为,水库泥沙冲淤变化与之密切相关,不同水库调度运行方式下的排沙情况、冲淤部位及冲淤形态等明显不同,尤其对于普遍采用“蓄清排浑”调度运行方式的多沙水库,这一影响更为显著。而水库调度运行方式的表征则主要是通过水库下边界条件来体现,如库水位、出库水量等。此外,河道地形、人类活动、流域气候、流域地貌等诸多因素对水库冲淤变化亦会产生不同程度的影响,其中河道地形可采用河段平均比降来表征,而人类活动、流域气候及地貌等因素在一定的时空范围内具有相对稳定性,可认为它们的量基本不变,或可视不同情况对其进行量化处理。综上所述,确定预测模型的输入变量为:1)入库水量或水量过程;2)入库沙量或沙量过程;3)入库泥沙颗粒级配;4)某特征流量级、含沙量级持续时间;5)库水位;6)出库水量或水量过程;7)河段平均比降;8)其他量化因子。对于不同研究问题,可视具体情况对上述因子进行取舍。

至此,基于 APSO-BP 的多沙水库冲淤预测模型可用如下非线性映射函数来表达:

$$\varphi = f(W_{\text{in}}, W_{\text{in}} - t, S, S - t, D_s, d, Z, W_{\text{out}}, W_{\text{out}} - t, J, \dots) \quad (12)$$

式中: $\varphi$  表示泥沙冲淤变量(冲淤量或特征断面深泓点高程), $W_{\text{in}}$ 、 $W_{\text{in}} - t$  分别表示入库水量、水量过程, $S$ 、 $S - t$  分别表示入库沙量、沙量过程, $D_s$  表示入库泥沙颗粒级配, $d$  表示某特征流量级、含沙量级持续时间, $Z$  表示库水位, $W_{\text{out}}$ 、 $W_{\text{out}} - t$  分别表示出库水量、水量过程, $J$  表示河段平均比降。

1.2.2 模型计算流程 基于 APSO 算法优化 BP 神经网络的多沙水库冲淤预测模型,实质是将神经网络的权值和阈值映射为 APSO 算法中的粒子,并通过粒子速度与位置的更新来优化这些参数,从而完成模型训练和预测。具体流程如下:

1)样本的选取及预处理<sup>[9]</sup>。样本是连接预测模型与所研究问题的介质,其选取合理与否决定着预测模型在实际应用中的可靠性。样本选取包括样本特征选取及样本数目确定 2 方面内容。样本特征应能很好地反映所研究问题的基本特征,不仅在训练区内要有代表性,而且在预测区内要有普适性;样本数目取决于所研究问题的复杂性,既不能由于样本过少而使网络训练不足,又要避免样本过多而增加网络训练负担或信息量过剩导致过拟合现象。具体对多沙水库冲淤预测模型而言,选取的样本应能反映丰、平、枯各种水沙情况,同时又要适当考虑大水、大沙和枯水、枯沙情况,此外样本还应尽可能与天然水沙系列一致,以保持样本的连续性。

在选取的样本中,由于组成每个样本的影响因子量纲不同,数量级上差别较大,为避免由此造成的网络预测误差较大,防止部分网络神经元达到过饱和状态,需要对样本输入数据进行预处理,将样本数据均转化为区间 $[0, 1]$ 内的值,即进行归一化处理,归一化计算公式如下:

$$y = (y_{\text{max}} - y_{\text{min}})(x - x_{\text{min}})/(x_{\text{max}} - x_{\text{min}}) + y_{\text{min}} \quad (13)$$

式中: $x$ 、 $x_{\text{min}}$ 、 $x_{\text{max}}$  分别为各样本中的影响因子及其在样本中的最小、最大值, $y$ 、 $y_{\text{min}}$ 、 $y_{\text{max}}$  分别为归一化后的影响因子值及其最小、最大值,若归一化至区间 $[0, 1]$ ,则  $y_{\text{min}} = 0$ ,  $y_{\text{max}} = 1$ 。

2)确定 BP 神经网络拓扑结构,并初始化网络参数<sup>[10-13]</sup>。根据步骤 1)选取的网络输入、输出样本集确定网络拓扑结构,即确定网络输入层神经元数、隐含层数及其神经元数、输出层神经元数。其中,输

入层、输出层神经元数根据实际问题需要来确定,输入层神经元数为非线性映射函数式(12)的自变量数,亦即影响因子的个数,输出层神经元数为函数式(12)的因变量数;隐含层数及其神经元数的确定目前尚无明确的理论依据,通常采用试算法加以确定,所依据的原则是既要保证预测精度,又不致使网络训练时间过长。在确定网络拓扑结构的同时,对相关网络参数进行初始化赋值,网络参数主要包括最大训练次数、训练误差目标、学习系数、学习系数下降因子、学习系数上升因子以及隐含层、输出层传递函数等。

3)调用 APSO 算法,建立 APSO 算法中粒子与 BP 神经网络权值和阈值之间的映射关系,即将 BP 神经网络中的 1 组权值和阈值视为 APSO 算法中的 1 个粒子,通过粒子寻优确定 BP 神经网络的初始连接权值和阈值。具体寻优流程如下<sup>[4-5,14]</sup>。

① 初始化 APSO 算法参数,包括粒子种群规模、每个粒子的维数、惯性权重最大值和最小值、加速度因子的迭代初值和终值、算法迭代次数及收敛目标值等。其中,粒子种群规模根据所研究问题的复杂程度决定,对于一般问题取 20~40 个粒子即可满足计算要求;每个粒子的维数由优化问题决定,神经网络中有多少个连接权值和阈值,每个粒子就有多少维。

② 设定粒子位置变化范围 $[x_{\min}, x_{\max}]$ 以及最大速度 $v_{\max}$ 、最小速度 $v_{\min}$ ,随机初始化种群中各粒子的位置和速度。

③ 计算种群中每个粒子的适应度函数值,并将当前各粒子的位置和计算所得适应度值分别赋值给个体极值和个体最优适应度值,同时将所有粒子中适应度值最小粒子的位置和适应度值分别赋值给群体极值和群体最优适应度值。其中,适应度函数采用 BP 神经网络计算输出与期望输出之间的均方误差来表征,具体形式为:

$$\text{fitness}(\text{pop}) = \frac{1}{P} \sum_{p=1}^P \sum_{k=1}^m (t_k^p - y_k^p)^2, \quad (\text{pop}=1, 2, \dots, \text{population}). \quad (14)$$

式中: $\text{population}$ 表示种群规模, $\text{fitness}(\text{pop})$ 表示第 $\text{pop}$ 个粒子的适应度值, $P$ 为样本个数, $m$ 为网络输出神经元个数, $t_k^p$ 、 $y_k^p$ 分别表示第 $p$ 个样本的第 $k$ 个网络期望输出值与计算输出值。

④ 依据式(8)、(9)以及式(10)、(11),计算更新各粒子的速度和位置,同时据此更新值计算每个粒子的新适应度函数值。

⑤ 比较种群中各粒子当前适应度值与其个体最优适应度值,若当前适应度值更优,则用粒子的当前位置和适应度值更新其个体极值和个体最优适应度值,否则仍保留原值。

⑥ 比较种群中各粒子当前个体最优适应度值与群体最优适应度值,若当前个体最优适应度值更优,则用粒子的当前个体极值和个体最优适应度值更新群体极值和群体最优适应度值,否则仍保留原值。

⑦ 判断迭代终止条件是否满足,若满足则输出群体极值及群体最优适应度值并停止算法,否则转向步骤④继续进行迭代计算。

4)将经步骤3)优化输出的群体极值映射为 BP 神经网络的权值和阈值,并以此为网络最优初始权值和阈值,采用步骤1)选取的输入、输出变量样本训练 BP 神经网络,通过进一步调整更新网络连接权值和阈值,得到可用于预测计算的 BP 神经网络。

## 2 基于 APSO-BP 的多沙水库冲淤预测模型的应用

### 2.1 算例概况

冯家山水库位于渭河左岸一级支流千河下游,控制流域面积 3 232 km<sup>2</sup>,总库容 3.89 亿 m<sup>3</sup>,是一座以灌溉、城市供水为主,兼顾防洪、发电、旅游、养殖等综合利用的大(2)型水库,是陕西省宝鸡市的主要水源地之一。水库所处流域大部位于黄土高原沟壑区,侵蚀模数高达 1 620 t/km<sup>2</sup>,来水来沙多由暴雨形成,且汛期入库水量、沙量主要集中在几场洪水过程中,整体呈现显著的多沙特性。另据入库水文站千阳站 1974—2000 年实测水沙资料统计,冯家山水库多年平均入库径流量为 3.30 亿 m<sup>3</sup>,多年平均入库悬移质输沙量为 299.01 万 t,多年平均入库含沙量为 9.05 kg/m<sup>3</sup>,属多沙水库。

冯家山水库自 1974-03 投入运行以来,采取了蓄洪为主同时辅以异重流排沙的调度运行方式,但随着运行时间的延长,水库泥沙淤积问题日渐凸显,库容逐渐减小,水资源供需矛盾日益加剧。据相关统计资料显示,截止 2000 年水库运行 27 年来,累计泥沙淤积量为 8 481 万 m<sup>3</sup>,其中有效库容淤积 4 335 万 m<sup>3</sup>,死库容淤积 4 146 万 m<sup>3</sup>,总库容淤损近 21.6%,年平均淤积量达 326 万 m<sup>3</sup>,年平均有效库容淤积量为 167 m<sup>3</sup>,库区泥沙淤积相当严重<sup>[15]</sup>。因此,需对水库调度运行方式作进一步优化以减缓水库淤损。基于此,将本研究构建的 APSO-BP 多沙

水库冲淤预测模型应用于冯家山水库,对库区泥沙冲淤形态、冲淤量等进行预测计算,以便为水库调度运行方式的优化提供决策依据。

## 2.2 水库冲淤形态的预测

**2.2.1 影响因子及网络结构的确定** 对于冯家山水库冲淤形态预测,需对前文非线性映射函数式(12)中的影响因子作进一步分析,以便做出取舍。由于本研究主要着眼于水库年冲淤变化过程的预测,预测的是水库不同运用年的冲淤形态,反映的是以年为度量时段的水库冲淤变化情况,因此影响因子选用年入库水量、沙量以及出库水量,而不采用入库水量过程、沙量过程以及出库水量过程。就入库泥沙颗粒级配这一影响因子而言,冯家山水库自 1974 年建成运行至今,悬移质泥沙颗粒级配整体虽呈细化过程,但量值变化不大,因此对不同运用年库区河床冲淤的影响暂可不予考虑。至于表征河道地形的河段平均比降,在水库冲淤形态预测中其本身即是未知量,不能作为影响因子加以选用。此外,在冯家山水库的多年运行实践中,总结出当入库流量大于  $50 \text{ m}^3/\text{s}$ ,且含沙量大于  $30 \text{ kg}/\text{m}^3$  时,可产生异重流,进而可通过异重流排沙减缓库区泥沙淤积,因此大于  $50 \text{ m}^3/\text{s}$  流量级、 $30 \text{ kg}/\text{m}^3$  含沙量级的持续天数这一影响因子对水库冲淤形态有重要影响。综上所述,确定冯家山水库冲淤形态预测模型选取的影响因子(即模型输入变量)为:1)年入库水量;2)年入库沙量;3)大于  $50 \text{ m}^3/\text{s}$  流量级、 $30 \text{ kg}/\text{m}^3$  含沙量级的持续天数;4)年平均库水位;5)年出库水量。对于模型的输出变量,则选用冯家山水库库区 1<sup>#</sup>、6<sup>#</sup>、9<sup>#</sup>、12<sup>#</sup>、21<sup>#</sup> 共计 5 个特征断面的深泓点冲淤深度,其中 1<sup>#</sup>~6<sup>#</sup> 为坝前锥体段、6<sup>#</sup>~9<sup>#</sup> 为过渡段、9<sup>#</sup>~12<sup>#</sup> 为三角洲前坡段、12<sup>#</sup>~21<sup>#</sup> 为三角洲顶坡段。

网络结构设计中,输入层神经元数为选取的影响因子个数 5;输出层神经元数为输出变量个数 5;至于隐含层数,考虑到冯家山水库泥沙冲淤预测是一个复杂的非线性问题,为了既保证预测精度,又不致使网络训练时间过长,确定采用双隐含层,其神经元数经试算分别确定为 15 和 12。因此,本研究采用的 BP 神经网络拓扑结构为 5-15-12-5。

**2.2.2 样本的选取及参数确定** 依据前文提到的样本选取原则,结合冯家山水库的实际水沙资料,模型训练及预测样本从冯家山水库 1974—2000 年共计 27 年的水沙系列及实测冲淤资料中选取,这 27 年涵盖了各种水沙条件变化及组合,其中包括 1981—1985 年丰水丰沙段,1987—1991 年平水平沙

段,1995—1999 年枯水枯沙段,同时 1981 年为冯家山水库建库以来历史最大洪水年,样本无论就代表性还是普适性均表现良好。在 1974—2000 年 27 个样本中,由于 1974、1975、1986、1989、1994、1995、1999 年未施测河床纵剖面,无法用于模型训练及预测,故将这 7 个样本剔除,确定模型训练样本为 1976—1985 年+1987—1988 年+1990—1993 年共计 16 个,预测样本则选 1996—1998 年+2000 年共计 4 个。

预测模型参数包括 BP 算法参数及 APSO 算法参数 2 部分。BP 算法参数中最大训练次数取 100,训练目标取均方误差  $\leq 10^{-5}$ ,学习系数的初始值、下降因子及上升因子分别为 0.001、0.7 和 1.2,输入层与第 1 隐含层之间的传递函数采用双曲正切 S 型传递函数,形式为  $\text{tansig}(x) = (1 - e^{-2x}) / (1 + e^{-2x})$ ,第 1 隐含层与第 2 隐含层之间的传递函数采用对数 S 型传递函数,形式为  $\text{logsig}(x) = 1 / (1 + e^{-x})$ ,第 2 隐含层与输出层之间的传递函数采用线性传递函数,形式为  $\text{purelin}(x) = x$ ;APSO 算法参数中粒子种群规模取 35,每个粒子的维数为 347,惯性权重最大值和最小值分别为 0.9 及 0.4,加速度因子采用非对称方式取值, $c_1$  的迭代初值和终值分别为 2.75 及 1.25, $c_2$  的迭代初值和终值分别为 0.5 及 2.25,收敛目标为迭代次数  $> 150$  或均方误差  $\leq 10^{-4}$ 。

**2.2.3 模型训练** 采用经预处理的前述 16 个训练样本及确定的相关参数,对基于 APSO-BP 的冯家山水库冲淤预测模型进行训练。训练分 2 个阶段进行:首先是基于 APSO 算法的 BP 神经网络初始权值和阈值的迭代寻优;其次是 BP 神经网络对权值和阈值的进一步调整更新。

针对训练的第 1 阶段,图 1 给出了种群的群体最优适应度值(均方误差)随迭代次数的变化过程。由图 1 可以看出,APSO 算法群体最优适应度值随迭代次数的增加不断减小,经反复迭代 150 次后达到最大迭代次数,此时群体最优适应度值为  $7.5195 \times 10^{-3}$ ,与之对应的粒子位置即为传递给 BP 神经网络的最优初始权值和阈值。

针对训练的第 2 阶段,图 2 给出了模型的训练均方误差曲线,图 3 给出了模型训练输出与期望输出之间的相关分析。由图 2 可以看出,模型训练误差曲线包括训练集、验证集及测试集 3 条,之所以有 3 条误差曲线,主要是因为模型实际训练过程中,并不是全部 16 个训练样本均参与训练,而是依 10:3:3 的比例随机划分为训练集、验证集及测试

集 3 部分来进行,其中 10 个训练集样本用于对模型进行正常训练,3 个验证集样本用于在模型训练的同时监控模型的训练进程,3 个测试集样本则用于评价模型的训练结果以及判定样本集划分的合理性,这样做的目的主要是为了保证模型的泛化能力,防止模型训练过度。模型训练时,训练集训练、验证集监控及测试集评价交替进行,每经过一次训练即统计一次训练集均方误差,然后保持网络权值和阈值不变,分别采用验证集、测试集样本运行模型,并统计验证集、测试集的均方误差<sup>[16]</sup>。

在图 2 中,随着训练次数的增加,3 部分样本的均方误差均保持递减趋势,经过 4 次训练后,训练集均方误差即递减为  $8.823\,3\times 10^{-6}$ ,达到网络训练目标,停止训练,此时验证集、测试集的最小均方误差分别为 0.047 1 和 0.082 2,误差值较小,均在模型计算可接受的范围内,且变化趋势保持同步,表明 3 部分样本集划分合理。由图 3 可以看出,模型训

练输出与期望输出形成的点群基本集中于直线  $y=x$  的附近,且两者之间的相关系数为 0.714 1,相关度较高,拟合得到的线性趋势线斜率达到 0.955 6,接近于直线  $y=x$  的斜率 1。表明模型训练效果好,可用于冯家山水库库区冲淤形态的预测计算。




图 1  水库冲淤形态预测模型的最优适应度变化曲线  
Fig. 1  Best fitness curve of the deposition-scouring patterns prediction model




图 2  水库冲淤形态预测模型训练的均方误差曲线  
Fig. 2  Mean square error curve of the deposition-scouring patterns prediction model training

2.2.4 模型预测  采用上述训练完成的 APSO-BP 水库冲淤预测模型,并调取经预处理后的 4 个预测样本,对冯家山水库 1996、1997、1998、2000 年 5 个特征断面的深泓点冲淤深度进行预测,为更直观地




图 3  水库冲淤形态预测模型训练输出与期望输出的相关分析  
Fig. 3  Correlation analysis between training output and desired output of the deposition-scouring patterns prediction model  
表征历年水库冲淤形态,将模型预测所得的各断面深泓点冲淤深度换算为深泓点高程,并与实测深泓点高程进行对比,结果见图 4~7。




图 4  1996 年库区纵剖面预测值与实测值的对比  
Fig. 4  Comparison of predicted and measured longitudinal profile in reservoir zone in 1996




图 5  1997 年库区纵剖面预测值与实测值的对比  
Fig. 5  Comparison of predicted and measured longitudinal profile in reservoir zone in 1997




图 6 1998 年库区纵剖面预测值与实测值的对比  
Fig. 6 Comparison of predicted and measured longitudinal profile in reservoir zone in 1998




图 7 2000 年库区纵剖面预测值与实测值的对比  
Fig. 7 Comparison of predicted and measured longitudinal profile in reservoir zone in 2000

由图 4~7 可以看出,模型预测值与实测值之间吻合良好,其中吻合程度最佳的年份为 1996 年,其 5 个特征断面深泓点高程预测值与实测值平均相差仅为 0.6 m;其次为 1998、1997 及 2000 年,平均高程差分别为 0.89、1.20 及 1.47 m。就预测精度而言,1996、1997、1998 和 2000 年 4 个预测样本的平均相对误差依次为 9%,13%,10%和 15%,均满足通常泥沙数学模型相对误差不大于 30%的精度要求,表明本研究所构建的模型可满足实际水库调度运行中对库区冲淤形态进行准确、迅速预测的需要。

2.3 水库冲淤量的预测

2.3.1 影响因子及网络结构 对于冯家山水库冲淤量预测,除需考虑前述冲淤形态预测中确定的 5 个影响因子外,还需加入表征河道地形的河段平均比降这一因子,即模型输入变量为:1)年入库水量;2)年入库沙量;3)大于 50 m<sup>3</sup>/s 流量级、30 kg/m<sup>3</sup> 含沙量级的持续天数;4)年平均库水位;5)年出库水量;6)库区纵剖面平均比降。模型的输出变量则为水库库区泥沙冲淤量。网络结构同样采用双隐层,其拓扑结构为 6-30-25-1。

2.3.2 样本选取及参数确定 模型训练、预测样本选取同前文冲淤形态预测一致,这里不再赘述。参

数确定中除每个粒子的维数调整为 1 011 外,其余亦同前文。

2.3.3 模型训练 对于 APSO 算法中模型初始权值和阈值的迭代寻优,图 8 给出了种群的群体最优适应度值随迭代次数的变化过程。由图 8 可以看出,与图 1 相同,APSO 算法群体最优适应度值随迭代次数的增加而不断减小,经反复迭代 150 次后,群体最优适应度值为  $6.245\ 5\times 10^{-4}$ 。




图 8 水库冲淤量预测模型的最优适应度变化曲线  
Fig. 8 Best fitness curve of the deposition-scouring amount prediction model

对于 BP 神经网络对权值和阈值的调整更新,图 9 给出了模型的训练均方误差曲线,图 10 给出了模型训练输出与期望输出之间的相关分析。




图 9 水库冲淤量预测模型训练的均方误差曲线  
Fig. 9 Mean square error curve of the deposition-scouring amount prediction model training




图 10 水库冲淤量预测模型训练输出与期望输出的相关分析  
Fig. 10 Correlation analysis between training output and desired output of the deposition-scouring amount prediction model

由图9可以看出,随着训练次数的增加,3部分样本的均方误差均保持递减趋势,仅经过3次训练后,训练集均方误差即递减为 $1.0219 \times 10^{-6}$ ,达到网络训练目标,停止训练,此时验证集、测试集最小均方误差较小,分别为0.0144和0.0623,均在模型计算的可接受范围内,且其变化趋势保持同步,表明3部分样本集划分合理。由图10可知,模型训练输出与期望输出形成的点群基本集中于直线 $y=x$ 的附近,且两者之间的相关系数为0.8184,相关度较高,拟合得到的线性趋势线斜率达到1.0604,接近于直线 $y=x$ 的斜率1,表明模型训练效果良好,可用于冯家山水库库区冲淤量的预测计算。

2.3.4 模型预测 采用经上述训练完成的 APSO-BP 水库冲淤预测模型,并调取经预处理后的4个预测样本,对冯家山水库1996、1997、1998、2000年的冲淤量进行预测,图11给出了模型历年累计冲淤量预测值与实测值之间的对比情况。




图11 库区累计冲淤量预测值与实测值的对比

Fig. 11 Comparison chart of the predicted and measured accumulated scour and silting amount

由图11可以看出,模型预测值与实测值之间吻合良好,其中吻合程度最佳的年份为2000年,其累计冲淤量预测值与实测值的相对误差为1.71%;其次为1998、1997及1996年,相对误差分别为2.89%、3.57%和8.36%,预测精度较高,表明本研究所构建的模型可满足实际水库调度运行中对库区冲淤量进行准确、迅速预测的需要。

### 3 结 语

多沙水库的泥沙淤积问题是制约水库效益发挥的主要因素,而制定合理的水库调度运行方式是解决这一难题的有效途径之一。在实际水库管理过程中,水库调度运行方式的制定主要是根据库区泥沙冲淤变化过程及水库其他兴利目标,通过实时动态反复调整水库运行策略而实现的,这期间需要采用

泥沙冲淤预测模型准确、迅速地预测出某一具体水库调度运行方式下泥沙的冲淤变化过程,而传统的水动力学、水文学泥沙冲淤预测模型难以满足这种要求。为此,本研究将人工神经网络及粒子群优化算法引入到多沙水库冲淤预测计算中,构建了基于自适应粒子群算法优化BP神经网络的多沙水库冲淤预测模型。

该模型将多沙水库冲淤变化过程视为一个非线性动力系统,以入库水沙量、库水位及出库水量等诸多影响水库冲淤变化的因子为输入,以表征水库冲淤变化过程的库区冲淤量及冲淤形态为输出,利用人工神经网络在处理大规模复杂非线性动力学问题方面的优势,实现从输入状态到输出状态的非线性映射,进而完成对多沙水库冲淤过程的预测。同时,为进一步提高与改善人工神经网络的收敛速度和预测精度,采用自适应粒子群优化算法对BP神经网络的初始连接权值和阈值进行优化,该算法参数少,结构简单,易于实现。

为检验模型的实际应用效果,本研究将其应用到冯家山水库冲淤预测计算中,采用16个样本训练模型,4个样本预测库区泥沙冲淤形态及冲淤量,结果表明,本研究所构建模型的预测值与实测值吻合良好,可满足实际水库调度运行中对库区泥沙冲淤变化过程进行准确、迅速预测的需要,模型具有较强的合理性及较广的适用性,为多沙水库冲淤预测计算提供了一条新的有效途径。

### [参考文献]

- [1] 李荣,李义天. 基于神经网络理论的河道水情预报模型[J]. 水动力学研究与进展,2002(2):238-244.  
Li R, Li Y T. Model for flood prediction based on neural network theory [J]. Journal of Hydrodynamics, 2002(2): 238-244. (in Chinese)
- [2] 陈建. 水库调度方式与水库泥沙淤积关系研究[D]. 武汉:武汉大学,2007:7-8.  
Chen J. Research on the relation between operation regulation and sediment deposition of reservoir [D]. Wuhan: Wuhan University, 2007: 7-8. (in Chinese)
- [3] 苑希民,李鸿雁,刘树坤,等. 神经网络和遗传算法在水科学领域的应用[M]. 北京:中国水利水电出版社,2002:1-26.  
Yuan X M, Li H Y, Liu S K, et al. Application of neural networks and genetic algorithms in water science [M]. Beijing: China Waterpower Press, 2002: 1-26. (in Chinese)
- [4] 李丽,牛奔. 粒子群优化算法[M]. 北京:冶金工业出版社,2009:108-117.  
Li L, Niu B. Particle swarm optimization algorithm [M]. Beijing: Metallurgical Industry Press, 2009: 108-117. (in Chinese)

- [5] 王 凌,刘 波.微粒群优化与调度算法 [M].北京:清华大学出版社,2008:1-14,36-37.  
Wang L,Liu B. Particle swarm optimization and scheduling algorithms [M]. Beijing: Tsinghua University Press, 2008: 1-14, 36-37. (in Chinese)
- [6] 丛 爽.面向 MATLAB 工具箱的神经网络理论与应用 [M].合肥:中国科学技术大学出版社,2009:65-67.  
Cong S. Neural networks theory and applications with MATLAB toolboxes [M]. Hefei: Press of USCT, 2009: 65-67. (in Chinese)
- [7] 陈水利,蔡国榕,郭文忠,等. PSO 算法加速因子的非线性策略研究 [J]. 长江大学学报, 2007(4): 1-4, 16.  
Chen S L, Cai G R, Guo W Z, et al. Study on the nonlinear strategy of acceleration coefficient in particle swarm optimization algorithm [J]. Journal of Yangtze University, 2007(4): 1-4, 16. (in Chinese)
- [8] 张根广,王新宏,赵克玉,等. 潼关高程抬升成因相关分析 [J]. 泥沙研究, 2004(1): 56-62.  
Zhang G G, Wang X H, Zhao K Y, et al. Cause of formation of riverbed aggradations at Tongguan [J]. Journal of Sediment Research, 2004(1): 56-62. (in Chinese)
- [9] 陈一梅,徐造林. 基于神经网络的河道浅滩演变预测模型 [J]. 水利学报, 2002(8): 68-72.  
Chen Y M, Xu Z L. Model based on neural network for predicting the evolution of shoal in river [J]. Journal of Hydraulic Engineering, 2002(8): 68-72. (in Chinese)
- [10] 李 荣,李义天. 基于神经网络理论的河道水情预报模型 [J]. 水科学进展, 2000(5): 427-431.  
Li R, Li Y T. Application of the neural network theory to the flood prediction [J]. Advances in Water Science, 2000(5): 427-431. (in Chinese)
- [11] 刘媛媛,练继建. 遗传算法改进的 BP 神经网络对汛期三门峡水库泥沙冲淤量的计算 [J]. 水力发电学报, 2005(4): 110-113.  
Liu Y Y, Lian J J. Calculation of sediment and scour of Sanmenxia reservoir in flood season by the BP neural network improved by GA [J]. Journal of Hydroelectric Engineering, 2005(4): 110-113. (in Chinese)
- [12] 张金良,刘媛媛,练继建. 模糊神经网络对汛期三门峡水库泥沙冲淤量的计算 [J]. 水力发电学报, 2004(2): 39-43.  
Zhang J L, Liu Y Y, Lian J J. Calculation of sedimentation and scour of Sanmenxia reservoir in flood season by the fuzzy neural network [J]. Journal of Hydroelectric Engineering, 2004(2): 39-43. (in Chinese)
- [13] 李明超,冯耀龙. 基于 MATLAB 神经网络的三门峡水库泥沙冲淤变化预测分析 [J]. 泥沙研究, 2003(4): 57-60.  
Li M C, Feng Y L. BP neural network based MATLAB forecast and analysis of silt scour and siltation for Sanmenxia reservoir [J]. Journal of Sediment Research, 2003(4): 57-60. (in Chinese)
- [14] 罗云霞,王万良,周慕逊. 基于自适应粒子群算法的梯级小水电群优化调度研究 [J]. 水力发电学报, 2008(4): 7-11.  
Luo Y X, Wang W L, Zhou M X. Research of optimum operation based on APSO for cascaded small hydropower station [J]. Journal of Hydroelectric Engineering, 2008(4): 7-11. (in Chinese)
- [15] 李亚娇,李怀恩,沈 冰. 基于 RBF 网络的冯家山水库出库含沙量预测研究 [J]. 西北农林科技大学学报: 自然科学版, 2005(10): 134-138.  
Li Y J, Li H E, Shen B. The application of RBF neural network in forecast of out flow sediment concentration of Fengjiashan Reservoir [J]. Journal of Northwest A&F University: Nat Sci Ed, 2005(10): 134-138. (in Chinese)
- [16] 雷 蕾. 人工神经网络在大气污染预报中的应用研究 [D]. 北京: 北京工业大学, 2007.  
Lei L. Research on air pollution forecasting based on artificial neural networks [D]. Beijing: Beijing University of Technology, 2007. (in Chinese)