

# 基于RBF网络的冯家山水库 出库含沙量预测研究<sup>\*</sup>

李亚娇, 李怀恩, 沈冰

(西安理工大学 水利水电学院, 陕西 西安 710048)

**[摘 要]** 蓄洪排沙是冯家山水库的排沙方式, 然而在实际调度运行过程中, 对入库洪量和出库排沙泄量的调配缺乏共性关联, 排沙泄量未能从定性定量上予以科学界定。针对此问题, 文章对冯家山水库蓄洪排沙过程进行了研究, 采用RBF网络建立了该水库出库含沙量预测模型, 模型根据沙峰、洪峰入库时间与开闸排沙时间的不同分别选择网络结构。采用冯家山水库历史排沙资料对模型进行检验的结果表明, 模型训练及检验结果确定性系数均较大。可见, 采用RBF网络建立的出库含沙量预测模型是可行的。

**[关键词]** RBF网络; 冯家山水库; 出库含沙量; 预测

**[中图分类号]** TV 145<sup>+</sup>. 3; TV 149. 2 **[文献标识码]** A **[文章编号]** 1671-9387(2005) 10-0134-05

冯家山水库位于渭河左岸, 千河支流下游, 是一座以为灌溉、城市、工业供水为主, 兼有防洪、发电、旅游、养殖功能的综合利用工程。水库坝址以上控制流域面积3 232 km<sup>2</sup>, 占全流域面积的93%。水库1982年竣工, 设计正常蓄水位712 m (现行710 m), 总库容3.89亿m<sup>3</sup>。根据文献[1]可知, 水库自投入运行至2000年, 已淤积泥沙8 481万m<sup>3</sup>, 其中有效库容淤积泥沙4 335万m<sup>3</sup> (占水库有效库容2.86亿m<sup>3</sup>的15.4%), 死库容淤积泥沙4 146万m<sup>3</sup> (占死库容0.91亿m<sup>3</sup>的45.2%), 总库容已损失21.6%。水库年平均总淤积泥沙量326万m<sup>3</sup>, 年平均有效库容淤积泥沙量为167m<sup>3</sup>。由此可见, 冯家山水库的泥沙淤积情况已相当严重。

冯家山水库运用20多年来, 采用蓄洪排沙的运行方式, 在水库的泥沙淤积和异重流排沙方面积累了不少经验, 这对提高水库综合调度水平、延长水库使用寿命和提高水库经济效益发挥了巨大作用。然而在实际调度运行过程中, 对入库洪量和出库排沙泄量的调配缺乏共性关联, 对排沙泄量未能从定性定量上予以科学界定; 在洪水调度中, 对把握闸门开启度、开启时间及排沙泄量持续时间仅凭感觉、靠经验操作。因此, 根据历史观测数据, 寻找适合冯家山水库特性的泄量调配规律, 得出比较合理的入库洪量与排沙泄量的关系, 尽量减少决策上的盲目性和

操作上的随意性, 为科学决策提供参考, 这在水资源匮乏的今天, 具有重大的经济意义。

近年来, 人工神经网络在水科学研究领域得到迅速发展<sup>[2]</sup>。径向基函数(RBF)网络的连接权与输出呈线性关系, 使得其具有唯一的最佳逼近点, 可以采用保证全局收敛的线性优化算法来优化<sup>[3]</sup>。由于RBF网络的以上优点, 其已被广泛应用于模式识别、信号处理、在线故障检测与控制等研究领域, 并取得了较好效果。由于水库的出库含沙量预测也具有明显的模式识别性, 本研究应用RBF网络建立了冯家山水库蓄洪排沙出库含沙量预测模型, 并用该水库历史排沙资料对模型进行了检验, 以为其水库实际调运提供参考。

## 1 模型建立

### 1.1 径向基函数人工神经网络(RBF)

径向基函数网络是一种常用的前馈型神经网络, 其基本结构如图1所示。这种网络的特点是: 只有1个隐层, 隐层单元采用径向基函数作为其输出特性, 输入层到隐层之间的权值固定为1; 输出节点为线性求和单元, 隐层到输出节点之间的权值可调, 因此输出结果为隐层的加权和。

所谓径向基函数, 就是某种沿径向对称的标量函数<sup>[4, 5]</sup>。通常定义为空间中任一点 $x$ 到某一中心 $t$

<sup>\*</sup> [收稿日期] 2005-03-07

[基金项目] 高等学校优秀青年教师教学科研奖励计划项目(2001-282)

[作者简介] 李亚娇(1978-), 女, 辽宁大石桥人, 在读博士, 主要从事旱区水文水资源研究。E-mail: liyajiao@163.com

之间欧氏距离的单调函数, 可记作  $k(\|x - t\|)$ , 其作用往往是局部的, 即当  $x$  远离  $t$  时函数取值很小。最常用的径向基函数是高斯函数, 形式为:

$$k(\|x - t\|) = \exp\left(-\frac{\|x - t\|^2}{2\sigma^2}\right) \quad (1)$$

式中,  $t$  为核函数中心;  $\sigma$  为函数的宽度参数, 控制了函数的径向作用范围。在RBF网络中, 这2个参数与隐层到输出层的权值  $w$  是可调的。




图1 RBF神经网络结构

Fig 1 The RBF neural networks architecture

目前, RBF网络的径向基函数多采用高斯函数, 以高斯函数为径向基函数的RBF网络结构式为:

$$y = \sum_{i=1}^m w_i \exp\left(-\frac{\|x - t_i\|^2}{2\sigma_i^2}\right) \quad (2)$$




图2 沙峰与洪峰出现前开闸排沙的  
出库含沙量变化过程(1979-07-25)

Fig 2 The discharging sediment hydrograph  
of outflow sediment concentration for  
opening before the emergence of sediment  
peak and flood peak (1979-07-25)

对实测的11场蓄洪排沙数据计算次洪水滞留沙量, 并作图与出库含沙量过程对比(图4)发现, 出库含沙量确实与入库剩余沙量有关。由图4可以看出, 开闸初始, 出库含沙量随次洪水滞留沙量变化明显, 但随着排沙的进行, 入库流量、含沙量逐渐减少, 库中异重流流速变小, 能够到达坝前的泥沙就越少,

式中,  $t_i$  为隐层第  $i$  个节点的中心向量;  $y$  为与  $x$  对应的期望输出;  $m$  为隐节点数;  $\sigma_i$  为隐层第  $i$  个节点的高斯函数宽度。

## 1.2 冯家山水库蓄洪排沙出库含沙量预测模型

为合理地建立冯家山水库出库含沙量预测模型, 首先对实测的入库、出库流量与含沙量数据进行分析。由于资料所限, 只收集到11场冯家山水库蓄洪排沙数据<sup>[1]</sup>, 对这些数据进行分析发现, 根据开闸时刻与洪峰、沙峰入库时刻的先后, 可将11场排沙过程分为2类: 一类为沙峰与洪峰出现之前开闸排沙, 另一类为沙峰与洪峰出现后开闸排沙。分别对这两类排沙过程进行分析, 发现第一类排沙过程由于开闸时刻在沙峰和洪峰出现之前, 开闸后随着入库含沙量和流量的增加, 泄流含沙量也不断增加; 沙峰和洪峰出现之后, 入库含沙量和流量不断减少, 泄流含沙量也不断减少, 因此第二类排沙过程为一条有峰值的曲线, 见图2。而第二类排沙过程开闸时刻在沙峰和洪峰出现之后, 开闸后随着入库含沙量和流量的减少, 泄流含沙量不断减少, 因此第二类排沙过程为一条递减的曲线, 见图3。由此可以认为, 随着入库沙量在水库中的剩余量(不包括沉入库底的沙量)的增加或减少, 出库含沙量也增加或减少。




图3 沙峰与洪峰出现后开闸排沙的  
出库含沙量变化过程(1979-07-21)

Fig 3 The discharging sediment hydrograph  
of outflow sediment concentration for  
opening after the emergence of sediment  
peak and flood peak (1979-07-21)

因而排沙后期出库含沙量变化较小, 次洪水滞留沙量的变化对其影响不大。

根据上述分析, 冯家山水库蓄洪排沙出库含沙量预测模型可用下式表示:

$$S(n) = f(S(n-1), t, S_{\text{total}}) \quad (3)$$

式中,  $S(n)$  为  $n$  时刻出库含沙量 ( $\text{kg}/\text{m}^3$ );  $t$  为次洪水

起涨时刻至当前时刻的时间间隔(h);  $S_{\text{total}}$  为次洪水滞留沙量, 等于入库沙量减去出库沙量(t);  $S_{(n-1)}$  为  $n$  时刻上一时段水库出库含沙量( $\text{kg}/\text{m}^3$ )。

由此, 基于径向基函数网络的冯家山水库蓄洪排沙出库含沙量预测模型的输入节点分别为  $S_{(n-1)}$ ,  $t$ ,  $S_{\text{total}}$ , 输出节点为  $S_{(n)}$ , 则任一时刻出库泄量含沙量为:

$$S_j = \sum_{i=1}^m w_i \exp\left(-\frac{\|x_j - t_i\|^2}{2\sigma_i^2}\right) \quad (4)$$

式中,  $x_j$  为输入向量,  $x_j = (S_{(n-1)}, t, S_{\text{total}})$ ;  $t_i$  为函数中心向量, 初始值由实测输入数据聚类得到;  $\sigma_i$  为高斯函数宽度, 初始值由实测输入数据聚类得到;  $w_i$  为隐层到输出层权值, 若样本已进行归一化, 则初始

值在(0, 1)随机确定。

目标函数:

$$\min(E) = \min\left(\frac{1}{2} \sum_{j=1}^N e_j^2\right) \quad (5)$$

$$e_j = d_j - F(x_j) = d_j - \sum_{i=1}^m w_i \exp\left(-\frac{\|x_j - t_i\|^2}{2\sigma_i^2}\right) \quad (6)$$

式中,  $d_j$  为第  $j$  个样本的期望输出。

如前所述, 根据开闸时刻与入库沙峰、洪峰出现时刻的先后, 出库含沙量的变化有2种不同的过程。因此, 在建立模型时这2种情况应分别处理, 即按类分别训练以得到不同的网络参数, 最后用不同的网络参数进行预测。




图4 冯家山水库蓄洪排沙次洪水滞留沙量与出库含沙量的比较

- □ - . 出库含沙量; — . 次洪水滞留沙量

Fig 4 Comparison of retarding sediment and outflow sediment concentration of Fengjia Shan Reservoir storing flood and discharging sediment

- □ - . Outflow sediment concentration; — . Retarding sediment

## 2 实例计算与结果分析

网络的输入向量各分量有不同的物理意义, 因而有不同的量纲, 其取值量级相差较大, 如1976-09-06排沙过程的第1个输入样本  $x_0 = (12, 2\ 090\ 387,$

398 02)。这种量级上的差别会严重影响网络的识别精度。为避免这种情况, 对输入数据进行归一化处理, 相应的输出数据也进行归一化, 归一化方法采用比例缩放法, 数据归一化后各节点最大值为0.9, 最小值为0.1。

## 2.1 沙峰、洪峰出现后开闸

这类情况的出库含沙量过程为一条递减的曲线, 已收集到的排沙过程中这种情况有8次, 即1979-07-21, 1980-07-02, 1980-08-02, 1981-08-21, 1983-08-31, 1985-07-31, 1988-08-08 和 1989-07-16的排沙过程, 但1989-07-16的排沙比为1.18, 大于1, 情况较为特殊, 建模时将其去除。因而网络训练采用1979-07-21, 1980-07-02, 1980-08-02 和 1981-08-21这4次洪水入库, 出库数据作为训练样本, 采用基于梯度下降法的误差纠正算法, 用1983-08-31, 1985-07-31 和1988-08-08这3次洪水入库, 出库数据进行预测。

隐层节点数采用适选法确定为32。网络训练时首先初始化网络参数, 然后运用梯度下降法调整网络参数, 计算中函数中心向量、函数宽度及隐层到输出层的权值学习因子均取为0.0001, 迭代20000次




图5 实测与预测的1983-08-31 出库含沙量变化过程比较

Fig 5 Comparison of outflow sediment concentration for surveying and forecasting on Aug 31, 1983




图7 实测与预测的1988-08-08 出库含沙量变化过程比较

Fig 7 Comparison of outflow sediment concentration for surveying and forecasting on Aug 8, 1988

由图5~7可见, 预测的出库含沙量变化过程与

目标函数值为  $E \leq 0.29$ ,  $E$  为利用归一化后数据计算的目标函数值。

网络训练完成后, 用其余3场蓄洪排沙数据进行预测并检验网络精度。水库泄流排沙过程中, 出库含沙量的变化是多种因素共同作用的结果, 其微观机理非常复杂。出库含沙量的预测是一个宏观过程, 其略去了一些影响较小的因素, 这样不可避免地会带来一些误差, 这一问题可以通过人工神经网络的自适应来解决。在预测检验过程中, 每预测一个样本, 根据输出与实测值间的“新息”, 调整隐层到输出层的权值, 并依据新的网络参数预测下一个样本, 然后再根据新的“新息”, 调整隐层到输出层的权值, 这样逐步计算, 使预测结果更为理想。1983-08-31, 1985-07-31 和1988-08-08 的预测采用训练—预测一再训练的方法, 预测结果见图5~7。




图6 实测与预测的1985-07-31 出库含沙量变化过程比较

Fig 6 Comparison of outflow sediment concentration for surveying and forecasting on July 31, 1985

实测的出库含沙量变化过程较为接近, 且其确定性系数  $D_c$  较大, 分别为0.52, 0.58 和 0.78, 预测结果较好。

## 2.2 沙峰、洪峰出现前开闸

这类情况的出库含沙量过程为一条有峰值的曲线, 已收集到的此类排沙过程仅有3场, 即1976-09-06, 1977-07-27 和 1979-07-25 的排沙过程, 选取1976-09-06 和 1977-07-27 的排沙数据进行网络训练, 用1979-07-25 的排沙数据进行预测。隐层节点数采用适选法确定为14。训练、预测方法如前所述, 此类神经网络预测检验结果见图8。由图8可以看出, 预测出库含沙量过程与实测出库含沙量过程较为接近, 且其确定性系数  $D_c$  为0.86, 较大, 预测结果较好。




图8 实测与预测的1979-07-25 出库含沙量变化过程比较

Fig 8 Comparison of outflow sediment concentration for surveying and forecasting on July 25, 1979

### 3 结 语

本文采用RBF 网络建立了冯家山水库出库含

沙量预测模型, 根据洪峰、沙峰入库时间与开闸排沙时间的不同分别选择网络结构, 训练及检验结果的确定性系数均较大, 预测效果较好。

但鉴于作者水平和其他客观条件所限, 本研究还不够深入, 有些问题还没有涉及到, 仅提出以下几点:

(1) 本研究利用RBF 网络对水库出库含沙量的预测预见期只有一个时段, 预见期应更长。

(2) 资料所限, 文中仅收集到冯家山水库 11 场蓄洪排沙资料, 应有更多资料对文中所述模型予以检验。

(3) 受神经网络自身影响, 隐层节点数的确定至今没有一个较好的方法, 这也是神经网络研究中亟待解决的一个问题。文中隐层节点数采用适选法确定, 是根据现有样本适选出来的, 随着样本的增多, 隐层节点数应适当增加, 否则该隐层节点数将会越来越不适应问题需要。

#### [参考文献]

- [1] 宝鸡市冯家山水库管理局. 冯家山水库洪量与泄量优化调配研究技术总结[R]. 陕西宝鸡: 宝鸡市冯家山水库管理局, 2000
- [2] 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
- [3] 阎平凡, 张长水. 人工神经网络与模拟进化计算[M]. 北京: 清华大学出版社, 2000
- [4] 徐丽娜. 神经网络控制[M]. 哈尔滨: 哈尔滨工业大学出版社, 1998
- [5] 边肇祺, 张学工. 模式识别[M]. 北京: 清华大学出版社, 2000

## The application of RBF neural network in forecast of out flow sediment concentration of Fengjiashan Reservoir

L I Ya-jiao, L I Hua-i-en, SHEN Bing

(College of Water Resources and Hydroelectric Engineering, Xi'an University of Technology, Xi'an, Shaanxi 710048, China)

**Abstract:** Storing flood and discharging sediment is the most effective discharging sediment measure of Fengjiashan reservoir. But in fact, allocation between input flood hydrograph and outflow sediment concentration hydrograph lacks general relevancy, and discharging sediment hydrograph has not been defined scientifically in quality and quantity. So output sediment concentration hydrograph of Fengjiashan reservoir is researched. RBF ANN is used to establish forecast model of the outflow sediment concentration of the reservoir. The two kinds of ANN architectures are selected to establish the forecast model based on the difference between the time of entering the reservoir of the sediment peak and flood peak and the time of opening up gate for discharge. At the same time, previous data of discharging sediment of the reservoir are used to check the model, not only DC of the training but also those of the testing are bigger. This shows that it is feasible that RBF ANN is used to establish the forecast model of outflow sediment concentration.

**Key words:** RBF neural network; Fengjiashan Reservoir; out-flow sediment concentration; forecast