

基于遗传神经网络的渗流实时预报方法研究

闫 滨^{1, 2}, 周 晶¹

(1 大连理工大学 土木水利学院, 辽宁 大连, 116024; 2 沈阳农业大学 水利学院, 辽宁 沈阳, 110161)

摘 要: 考虑渗流的主要影响因子, 运用遗传神经网络建立了大坝渗流实时预报模型。该模型具有再学习能力, 在应用过程中, 可以用新的观测资料对模型不断地进行学习训练, 且随着样本的积累, 模型预报精度不断提高, 预报速度很快, 因而完全满足实时预报的需要。利用该模型对丰满大坝横向扬压力进行了建模预报, 预报值与实测值基本吻合, 预测精度高, 证明该方法用于大坝渗流实时预报的有效性和实用性。

关 键 词: 渗流; 实时预报; 遗传算法; 人工神经网络

中图分类号: O224; TV 139.11

文献标识码: A

Seepage real-time forecast model based on genetic neural network

YAN Bin^{1, 2}, ZHOU Jing¹

(1. School of Civil and Hydraulic Engineering, Dalian University of Technology, Dalian 116024, China;

2. College of Water Conservancy, Shenyang Agricultural University, Shenyang 110161, China)

Abstract: In terms of main influencing factors of seepage, a seepage real-time forecast model is established based on genetic algorithm and neural network. The model can be trained sequentially with new observed data in further application; and the accuracy of the model can be improved in less training time with the accumulation of samples. Thus, it can satisfy the demand of real-time forecast. The predicted results agree well with the measured ones in the forecast of transverse uplift pressure of Fengman Dam so as to indicate that the proposed method has high prediction accuracy and is valid and practical for seepage real-time forecast.

Key words: seepage; real-time forecast; genetic algorithm; artificial neural network

1 引 言

水库建成蓄水后的渗流量及扬压力是评价大坝工作性态的重要物理量之一, 对大坝的渗流监测资料选择合理的模型进行及时的分析是大坝安全监控的主要内容, 对于验算大坝稳定, 监视坝基渗透情况, 了解坝基帷幕和排水系统的工作效能, 都具有十分重要的意义。目前, 渗流分析预报一般采用统计模型, 确定性模型以及混合模型^[1], 这些方法本质上都是用某一确定的显式函数来表达变量间的关系, 由于监测量影响因素众多, 且相互间关系复杂, 应用一个精确的数学模型很难得到一个满意的回归效果。本文基于渗流预报的高度复杂性和非线性特征, 引入人工智能技术, 利用人工神经网络 (Artificial Neural Network, 简称 ANN) 的非线性映射能力和遗传算法 (Genetic Algorithm, 简称 GA)

的全局随机搜索能力, 同时结合渗流的变化特点, 提出一种随着新监测数据的不断补充, 不断调整网络模型参数进行实时建模、预报的方法。最后, 以丰满大坝为例验证该方法的有效性。

2 人工神经网络模型

2.1 人工神经网络建模原理

人工神经网络^[2]是模拟人脑的结构和功能而形成的一种动态信息处理系统, 它将知识信息分布式存储于网络的连接权上, 运算速度快, 具有良好的自适应性、容错性和鲁棒性。它采用类似“黑匣子”的方法, 通过对大量样本的学习和记忆来挖掘隐含在样本中的因果关系, 进而建立输入到输出的非线性映射, 因此, 非常适合于渗流分析预报。其中, 应用最为广泛的是误差反向传播网络 (Error Back-Propagation Network, 简称 BP 网络), 且绝大

多数采用了三层结构,即 1 个输入层、1 个隐含层和 1 个输出层,见图 1。




图 1 三层 BP 网络结构图

Fig.1 Structure of BP neural network with three layers

设 BP 神经网络的输入层节点数为 m , 输出层节点数为 n , 隐含层节点数为 l 。为表述方便,用 i 表示输入层节点, k 表示隐含层节点, p 表示输出层节点。

将规范化的第 t 组训练样本的输入向量 $\{r_i^t\}$ 通过输入层传递到隐含层各节点,则隐含层节点 k 的输出 Y_k^t

$$Y_k^t = f\left(\sum_{i=1}^m w_{ik} r_i^t + \theta_k\right) \quad (1)$$

式中: $i=1,2,\dots,m$, $k=1,2,\dots,l$; w_{ik} 为输入层节点 i 与隐含层节点 k 的连接权重; θ_k 为节点 k 的阈值;传递函数 $f(\cdot)$ 为 Sigmoid 函数,即:

$$f(\cdot) = \frac{1}{1 + \exp(-\cdot)}.$$

输出层各节点的输出 o_p^t

$$o_p^t = f\left(\sum_{k=1}^l w_{kp} Y_k^t + \theta_p\right) \quad (2)$$

式中 $k=1,2,\dots,l$, $p=1,2,\dots,n$; w_{kp} 为隐含层节点 k 与输出层节点 p 的连接权重; θ_p 为输出层节点 p 的阈值,传递函数仍然为 Sigmoid 函数。

若样本的期望输出为 y_p^t , 则网络的总误差为:

$$E(x) = \frac{1}{2} \sum_{t=1}^T \sum_{p=1}^n (y_p^t - o_p^t)^2 \quad (3)$$

式中 y_p^t 、 o_p^t 分别为第 t 组样本下输出层第 p 个神经元的期望输出和实际输出; T 为样本的组数。

2.2 利用 L-M 算法调整 BP 网络权重

为进一步提高网络训练速度,满足实时预报的需要,本文采用 L-M 算法代替常规的梯度下降法来训练网络,调整网络权值,以使网络的期望输出与实际输出的误差平方和最小。网络权重调整的计算

公式为:

$$\left. \begin{aligned} W^{t+1} &= W^t + \Delta W \\ \Delta W &= (J^T J + \mu I) J^T e \end{aligned} \right\} \quad (4)$$

其中: W 为输入层和隐含层之间以及隐含层和输出层之间的连接权值组成的向量, ΔW 表示权值的变化,上标 t 表示迭代次数, J 和 J^T 分别为雅可比矩阵及其转置阵, μ 是自适应调整的常数, I 是单位阵, e 表示误差向量。

重复此过程直至训练误差达到一个预定的目标极限误差。

尽管 BP 网络预测精度较高^[3],但却存在结构不唯一、收敛速度慢、稳定性差、易陷入局部极小等缺陷,因而极大限制了它在实时预报和大量样本情况下的应用和推广。为此,本文将遗传算法 GA 和基于 L-M 训练算法的 BP 网络有机结合,来改善 BP 网络的性能。

3 遗传神经网络 (GNN) 模型

遗传算法^[4]是一种基于自然选择和遗传变异等生物进化机制的全局性概率搜索方法,因其简单通用、鲁棒性强,适于并行处理,已广泛应用于不同领域。首先,利用遗传算法优化神经网络的初始连接权重,在解空间定出一个较优的搜索空间;然后,利用 L-M 算法训练网络,在这个小空间搜索出最优解,从而建立输入到输出的非线性映射关系。这样,将 GA 善于全局搜索的能力与 ANN 良好的局部搜索性能有机结合,就可以在相当大程度上避免局部极小,网络结构也相对稳定,训练速度进一步加快。

3.1 遗传神经网络权重优化算法

3.1.1 遗传神经网络权重优化问题描述

用于建立渗流监控模型的遗传神经网络的设计和学习实质上是一个带约束条件的多目标优化问题,可以描述为^[5]

$$\begin{aligned} \min E &= f\{x_1, x_2, \dots, x_S\} \\ &= f\{w_1, \dots, w_i, \dots, w_M, \theta_1, \dots, \theta_j, \dots, \theta_K\} \end{aligned} \quad (5)$$

式中 E 为网络训练的总误差; x_i ($i=1,2,\dots,S$) 表示一组染色体, S 为染色体长度,等于全部权值和阈值之和,即 $S = m \times l + l \times n + l + n$; w_i 为网络的第 i 个连接权值; M 为连接权值的总数; θ_j 为第 j 个神经元的阈值; K 为隐含层和输出层神经元的总数。

约束条件为

$$\left. \begin{aligned} a_i &\leq w_i \leq b_i, \quad i=1, 2, \dots, M \\ c_j &\leq \theta_j \leq d_j, \quad j=1, 2, \dots, K \end{aligned} \right\} \quad (6)$$

式中 a_i 和 b_i 分别为变量 w_i 变化的下限和上限, c_j 和 d_j 分别为变量 θ_j 变化的下限和上限。

3.1.2 权重编号在神经网络与遗传算法之间的相互转换

神经网络训练中的连接权重包括输入层与隐含层节点间的连接权值 w_{ik} 、隐含层与输出层节点间的连接权值 w_{kp} 、隐含层神经元的阈值 θ_k 、输出层神经元的阈值 θ_p , 其中 w_{ik} 和 w_{kp} 为二维向量。而利用遗传算法对上述优化问题求解时, 必须把全部连接权重转化为一维连续向量 $\{x\}$, 对其重新统一编号。同样, 经过遗传算法优化后的连接权重也必须转化为形式为二维向量的连接权值 w_{ik} 和 w_{kp} 和一维向量 θ_k , θ_p 。利用以下公式实现相互间的转化:

$$\left. \begin{aligned} x_{m(k-1)+i} &= w_{ik} \\ x_{l(p-1)+k+ml} &= w_{kp} \\ x_{(m+n)l+k} &= \theta_k \\ x_{(m+n+1)l+p} &= \theta_p \end{aligned} \right\} \quad (7)$$

式中 m, l, n 分别为输入层、隐含层和输出层的节点数, $i=1, 2, \dots, m, k=1, 2, \dots, l, p=1, 2, \dots, n$ 。

3.2 遗传神经网络模型计算步骤^[4-6]

Step1: 对网络连接权进行实数编码。

Step2: 利用小区间生成法随机生成初始种群。即把待优化参数的取值范围分成群体总数个小区间, 再在各小区间中随机生成一个个体, 如此形成初始种群。

Step3: 根据适应度函数对个体性能进行评价, 适应度函数 $f(x)$ 定义为误差函数的倒数, 即 $f(x) = 1/E(x)$ 。

Step4: 对每个个体解码得到一个网络初始连接权, 并与规范化的输入样本一起输入网络, 按(1)~(3)式计算网络输出值及总误差 E 。若 $E \leq \varepsilon$ (ε 为网络训练精度), 训练结束, 转入 Step9; 否则, 转入下一步。

Step5: 对父代种群进行选择、交叉和变异操作生成子代种群;

Step6: 计算子代种群中每个个体的适应值, 并按适应度由大到小排序;

Step7: 对最优个体解码得到 BP 网络的最优初

始权重, 按(4)式调整权重并计算新的权重, 再计算权值调整后的网络输出及总误差 E 。

Step8: 若 $E \leq \varepsilon$, 则训练结束, 转入下一步; 否则, 把此优化后的连接权重作为下一次训练的初始权重, 转入 Step5;

Step9: 输出满足训练精度要求(即 $E \leq \varepsilon$)的网络连接权重, 并根据输出的训练权重值进行预报。

3.3 基于遗传神经网络的渗流实时预报步骤^[7]

Step1: 按照3.2的步骤, 利用前面 n 组规范化的实测渗流监测数据建立遗传神经网络预报模型;

Step2: 利用该模型预报第 $n+1$ 个渗流监测值;

Step3: 与第 $n+1$ 个实测渗流监测值对比, 检验预报效果, 并分析误差原因;

Step4: 利用前面 $n+1$ 组渗流实测数据, 重新建立遗传神经网络模型, 然后对第 $n+2$ 个渗流监测值进行预报, 如此反复。

依此方法, 建模过程和预报过程不断地重复下去, 每次向网络补充一个新的渗流监测数据, 重新调整网络参数, 预测下一步的渗流监测值。这样, 就能够不断地跟踪大坝渗流性态, 预报其发展趋势。

4 工程实例

丰满水电站位于吉林省吉林市第二松花江干流中游。水库正常高水位263.5 m, 死水位242.1 m。大坝为混凝土重力坝, 坝顶全长1 080 m, 最大坝高91.7 m, 坝顶高程267.7 m。大坝共60个坝段, 每个坝段长18 m, 坝顶宽9.0~13.5 m。渗流观测内容包括纵向扬压力、横向扬压力和漏水量等。

首先, 本文选择丰满大坝8号坝段1993-1-5~1998-12-2的100组横向扬压力及同期库水位、温度和时效的实测资料进行学习和训练, 应用上述方法建立基于遗传神经网络的渗流实时预报模型; 然后, 利用此模型预报1999-1-11的横向扬压力; 接下来, 再选择1993-1-5~1999-1-11的101组实测数据进行学习和训练, 重新建立渗流预报模型, 并用此模型预报1999-2-1的横向扬压力。如此反复, 每增加一个监测数据就重新建立一次遗传神经网络实时预报模型, 并对下一个数据进行预报。

模型输入量即影响因子数, 扬压力影响因素^[1]在帷幕、排水既定的条件下只有上下游水位、温度、时效以及坝前泥沙淤积条件等, 而坝前泥沙淤积条件可归入时效影响。考虑到水库运行的初始状态对横向扬压力的影响, 选择用于大坝横向扬压力预测的网络模型输入量为: 水压分量4个, 即 $H_i - H_{0i}$, $i=0, 5, 10, 20$, H_i 为观测前 i 天的平均库水位;

温度分量5个, 即 $T_j - T_{0j}$, $j = 5, 15, 30, 60, 90$, T_i 为观测前 j 天的平均气温; 时效分量2个, 即 $\theta - \theta_0$ 和 $\ln \theta - \ln \theta_0$, θ 为从观测起始日期算起的天数的1%, H_{0i} , T_{0j} , θ_0 分别为第一个观测样本对应的前 i 天的平均库水位、前 j 天的平均气温以及从观测起始日期算起的天数的百分之一, 故网络输入层结点数为11个。隐含层结点数18个, 输出层结点数1个, 即坝基横向扬压力。因此, 学习样本采用11-18-1的网络结构形式。

选取种群规模 $N = 100$, 选择概率 $p_s = 0.95$, 交叉概率 $p_c = 0.4$, 变异概率 $p_m = 0.05$, 初始权值 $b = [-0.3, 0.3]$, 最大进化代数 $termgen = 10$, L-M算法误差精度0.001。

为证明本文建立的模型的有效性, 同时建立了基于L-M算法的BP神经网络模型和逐步回归模型, 对其预报效果加以对比。各种模型的预报结果见表1, 评价指标的对比结果见表2。

从表1可以看出, GNN 模型的预测相对误差普遍小于对应的BP模型和逐步回归模型。GNN 模型的最大相对误差为1.459%, 而BP模型和逐步回归模型分别为3.89%和2.16%。可见, GNN 模型的预测值与实测值比较吻合, 预测效果明显优于BP模型和逐步回归模型。

表1 各种模型预报结果对比 (单位: kN/m)
Table 1 Forecast results comparison between various models (unit: kN/m)

日期	横 向 扬压力 实测值	GNN 模型 预测值	相对 误差 /(%)	BP 模型 预测值	相对 误差 /(%)	逐步回 归模型 预测值	相对 误差 /(%)
1999-1-11	11 331.6	11 258.8	0.642	10 890.8	3.890	11 360.5	0.255
1999-2-1	10 986.7	11 076.6	0.818	10 726.4	2.369	11 097.6	1.010
1999-3-11	10 657.2	10 674.0	0.158	10 590.8	0.623	10 698.2	0.385
1999-4-12	10 726.1	10 681.2	0.419	10 408	2.966	10 666.1	0.559
1999-5-10	11 001.2	11 030.8	0.269	10 689.6	2.832	11 006.6	0.049
1999-6-7	11 058.0	10 972.6	0.772	10 711.2	3.136	11 020.7	0.337
1999-7-13	10 679.4	10 682.8	0.032	10 648	0.294	10 700.8	0.200
1999-8-9	10 592.6	10 646.0	0.504	10 685.6	0.878	10 805.1	2.007
1999-9-14	10 551.6	10 542.0	0.091	10 544.8	0.064	10 779.5	2.160
1999-10-13	10 431.9	10 413.2	0.179	10 405	0.258	10 609.1	1.699
1999-11-16	10 275.7	10 125.8	1.459	10 248.8	0.262	10 394.0	1.151
1999-12-8	10 158.9	10 085.2	0.725	10 225.6	0.657	10 242.6	0.823
2000-1-12	9 952.8	10 005.2	0.526	10 078.8	1.266	10 013.2	0.607
2000-2-21	9 808.6	9 822.4	0.141	9 811.6	0.031	9 793.1	0.158
2000-3-7	9 833.5	9 803.0	0.310	9 759.2	0.756	9 780.0	0.544
2000-4-11	9 974.1	10 029.4	0.554	9 954.8	0.194	10 052.8	0.789
2000-5-24	10 269.3	10 199.0	0.685	10 250	0.188	10 289.1	0.192
2000-6-13	10 135.5	10 146.6	0.110	10 196.2	0.599	10 246.6	1.096

表2 评价指标对比
Table 2 Comparison of evaluation indexes

模 型	GNN 模型	BP 模型	逐步回归模型
平均相对误差 / (%)	0.466	1.181	0.779
平均绝对误差 / kN · m	48.972	127.683	81.305

由表2各模型评价指标的对比可以看出, GNN 模型预测平均相对误差仅为0.466%, 远小于BP模型的1.181%和逐步回归模型的0.779%; 平均绝对误差为48.972 kN/m, 亦显著小于BP模型和逐步回归模型的对应值, 这说明GNN 模型的预测精度是相当高的。

另外, GNN 模型对每一个数据的平均预报时间仅仅4.3s, 完全满足实时预报的需要。

5 结 论

通过上述遗传神经网络实时预报模型的建立与预报, 可以得出以下结论:

(1) 本文基于遗传神经网络建立的渗流监控模型, 预报值与实测值非常吻合, 为大坝渗流实时预报提供了一种有效的方法;

(2) 在相同条件下, 本文建立的渗流实时预报模型的预测精度显著高于BP模型和逐步回归模型, 而且预报时间非常短, 完全满足实际工程实时预报的需要;

(3) 利用本文建立的渗流实时预报模型可以对大坝渗流性态进行连续性预报, 并对未来的变化趋势进行有效的预测;

(4) 大坝渗流实时预报模型的预报结果与实测数据相互验证, 可以作为检验监测仪器是否正常工作, 以及观测值是否准确、可靠的一个依据!

参 考 文 献

- [1] 吴中如, 沈长松, 阮焕祥. 水工建筑物安全监控理论及其应用[M]. 南京: 河海大学出版社, 1990.
- [2] 从爽. 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, 1998.
- [3] 赵斌, 吴中如, 张爱玲. BP 模型在大坝安全监测预报中的应用[J]. 大坝观测与土工测试, 1999, (6): 1—4.
- [4] 周明, 孙树栋. 遗传算法原理及应用[M]. 北京: 国防工业出版社, 1999.
- [5] 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.
- [6] 王志旺, 张保军. 大坝变形监测遗传神经网络模型[J]. 岩土力学, 2003, 24(增): 130—133.
- [7] 刘勇健, 李彰明, 张建龙, 等. 基于遗传-神经网络的深基坑变形实时预报方法研究[J]. 岩石力学与工程学报, 2004, 23(6): 1 010—1 014.