

文章编号: 1000-7598-(2003)04-0634-05

基于进化神经网络混凝土大坝变形预测

李守巨¹, 刘迎曦¹, 刘玉静²

(1. 大连理工大学工业装备结构分析国家重点实验室, 大连 116024; 2. 长春工业大学基础科学系, 长春 130012)

摘 要: 根据丰满大坝多年变形观测数据, 建立了基于进化神经网络混凝土大坝变形预测方法。经典的 BP 神经网络的缺陷在于收敛速度慢和泛化能力弱等特性。与普通的多元回归方法和传统的 BP 神经网络相比, 采用遗传算法训练的人工神经网络预测模型预报大坝的变形具有精度高和全局收敛的特点。在丰满大坝工程实际应用表明, 所建立的基于进化神经网络混凝土大坝变形预报方法与广泛采用的统计方法相比, 可以显著提高大坝变形预报精度。

关 键 词: 人工神经网络; 变形预报; 混凝土大坝; 遗传算法

中图分类号: TU454, O233 **文献标识码:** A

Dam deformation forecasting by evolving artificial neural network

LI Shou-ju¹, LIU Ying-xi¹, LIU Yu-jing²

(1.State Key Laboratory of Structural Analysis of Industrial Equipment, Dalian University of Technology, Dalian 116023, China;

2. Basic Science Department, Changchun University of Technology, Changchun 130012, China)

Abstract: Based on the measured data of Fengman dam deformations for many years, the artificial neural network evolved by a genetic algorithm was adopted for forecasting the dam deformation. The shortcomings of the traditional BP artificial neural network lie in the slowness in the convergence rate and the weakness in the generalization ability. Compared with the popular multi-factor regression model and BP artificial neural network, the forecasting model based on artificial neural network evolved by a genetic algorithm had the characteristics of accurately forecasting and global convergence. The practical application to Fengman concrete dam shows that, compared with a commonly used statistical method, the forecasting method proposed can obviously enhance the forecasting precision of dam deformation.

Key words: artificial neural network; deformation forecasting; concrete dam; genetic algorithm

1 引 言

大坝变形预报是大坝安全监测系统中重要的组成部分,对于确保大坝安全运行具有重要的作用。到目前为止,有关大坝水平位移预报的研究主要为时间序列预报方法和多元回归方法^[1-6]。毫无疑问,几十年来,这些经典的预报方法对于解决大坝变形预报起到了相当重要的作用。但是,为了有效地预测大坝的变形特性,时间序列预报方法需要分析大坝的全部历史观测数据,此方法的缺点在于要求大坝变形观测数据具有等时性和稳定性,并且,对大坝变形有明显影响的诸多因素无法列入其中。由于大坝位移观测干扰多、时间序列长,要想做到等时

性和稳定性是相当困难的。而回归分析模型强调相关变量与大坝变形有较强的联系,其主要缺点是需要建立复杂的数学模型,并且,通过求解线性方程组得到各个回归系数,当线性方程组出现病态或奇异时,回归方法是无能为力的;同时,所建立的回归数学模型与大坝实际变形实际情况贴近程度直接影响到大坝变形的预报精度。人工神经网络方法已经广泛地应用于参数反演、模式识别、电力载荷预报和基坑变形预报中^[7-12]。与传统的基于回归模型大坝位移预测系统相比,人工神经网络方法无需假设输入变量与输出变量复杂的相关假设。但是,经典的 BP 神经网络的缺陷在于收敛速度慢和泛化能力弱等特性。遗传算法被用来优化神经网络的结构

收稿日期: 2002-04-10

基金项目: 国家自然科学基金资助项目(批准号:10072014); 高校博士点基金资助项目。

作者简介: 李守巨,男,1960年生,副教授,博士生,从事岩土力学及其反问题研究工作。

和神经元之间的连接权值，解决大坝变形预测精度问题。

本文的目的在于根据丰满大坝多年变形观测数据，建立基于进化神经网络混凝土大坝变形预测方法，进一步提高大坝变形预报精度，为大坝安全监测系统和管理决策机构提供更高质量的预报信息。

2 混凝土大坝变形特征分析

为了建立预报混凝土大坝变形的人工神经网络，必须首先了解影响混凝土大坝变形的主要因素，以便确定人工神经网络输入层的结构。混凝土大坝水平位移按其成因可分为三个分量：由水位变量 h 所产生的弹性分量；由温度变量 T 所产生的弹性分量；由坝体混凝土和坝基岩石的徐变、塑性变形以及基岩地质构造的压缩变形和坝体裂缝引起的不可逆变形（非弹性分量），即时效分量，它与时间 t 有关^[5]。表1给出了丰满混凝土重力坝32坝段1980年水平位移观测值，图1为1980~1981年大坝上游水位变化曲线，图2为1980~1981年丰满气温变化曲线。丰满大坝35坝段和38坝段1985年坝顶水平位移多元回归方法的预报值与观测值的对比见图3和图4。通过图1，图2和图3的对比可以看出，坝顶水平位移与水库水位有明显的相关效应，水库水位增加，坝顶水平位移随着增加；而坝顶水平位移与气温之间有明显的滞后效应。从图3和图4可以看出，采用多元回归方法预报大坝的水平位移的精度是十分有限的。因此，十分有必要建立人工神经网络方法预报大坝的坝顶水平位移，为大坝管理机构对大坝的安全运行状态评价和决策提供高精度的理论依据。

表1 32坝段1980年水平位移观测值
Table 1 Measured horizontal displacements at the block 32 in 1980

时间/d	上游水位/m	气温/℃	水平位移/mm
22	251.25	-16.6	1.0
53	248.63	-12.3	-2.3
90	247.43	-2.3	1.7
115	249.77	4.5	2.6
142	255.18	14.9	2.7
173	255.95	20.6	1.4
203	257.02	21.8	1.9
219	258.08	21.7	1.8
244	259.33	14.4	3.8
278	258.35	5.6	4.8
314	259.57	0.7	5.1
338	260.65	-17.6	7.8




图1 1980-1981年大坝上游水位变化曲线
Fig. 1 Curve of water level at the upstream from 1980 to 1981




图2 1980-1981年丰满气温变化曲线
Fig. 2 Curve of air temperature in the locality from 1980 to 1981




图3 1985年38坝段坝顶水平位移观测值与预报值对比
Fig. 3 Comparison between measured and forecast horizontal displacements at dam crest in 1985




图4 1985年38坝段坝顶水平位移观测值与预报值对比
Fig. 4 Comparison between measured and forecast horizontal displacements at dam crest in 1985

3 进化神经网络模型

3.1 用于大坝变形预测的人工神经网络模型

如果采用多元线性回归方法,当回归函数的形式确定后,其预报曲线的基本现状也随之确定了。因此,经典的多元回归方法无法较为精确地预报复杂多变的坝顶水平位移现状。人工神经网络是人工建立的以有向图为拓扑结构的动态系统,它通过对连续或断续的输入作状态响应而进行信息处理。其优点在于,人工神经网络无需任何复杂的数学模型或者大坝变形输入和输出数据之间的定量联系。人工神经网络方法具有较强的映射功能,为有效地解决这一课题提供了有力的方法手段。神经网络泛化能力主要取决于网络模型的复杂程度。太简单的网络模型无法使近似输入数据与输出数据之间真实的联系,而过度复杂的网络结构对观测数据的噪音比较敏感。如何合理地确定神经网络的结构已经引起众多学者的广泛关注。模拟人工神经网络的性能不仅与输入变量的选择有关,而且,与网络的结构有关。本文采用三层结构的神经网络,用遗传算法训练网络的权值。在训练过程开始时,神经网络的结构和初始权值由经验确定。神经网络的输入包括:上游水位、时间和气温;神经网络的输出为坝顶水平位移。神经网络结构如图 5 所示。对于第 p 组训练样本,隐含层数和输出层的输入为:

$$net_{jp} = \sum_{i=1}^M w_{ih_{ij}} x_{ip} \quad (j=1,2,\dots,J; p=1,2,\dots,N) \quad (1)$$

$$net_{kp} = \sum_{j=1}^J w_{oh_{kj}} y_{jp} \quad (k=1,2,\dots,L; p=1,2,\dots,N) \quad (2)$$

式中 N 为样本组数; M 为输入层节点数; J 为隐含层节点数; L 为输出层节点数; $w_{ih_{ij}}$ 和 $w_{oh_{kj}}$ 分别为连接输入层与隐含层的权值和连接隐含层与输出层之间的权值, x_{ip} 和 y_{jp} 为输入层和隐含层的输出, net_{jp} 和 net_{kp} 为隐含层和输出层的输入。采用如下 sigmoid 作用函数:

$$f(\xi) = \frac{1}{1 + \exp(-\xi)} \quad (3)$$

对于第 p 组训练样本,隐含层和输出层的输出为:

$$y_{jp} = \frac{1}{1 + \exp\left\{-\left(\sum_{i=1}^M w_{ih_{ij}} x_{ip} + \theta_j\right)\right\}} \quad (j=1,2,\dots,J; P=1,2,\dots,N) \quad (4)$$

$$z_{kp} = \frac{1}{1 + \exp\left\{-\left(\sum_{j=1}^J w_{oh_{kj}} y_{jp} + \theta_k\right)\right\}} \quad (k=1,2,\dots,L; P=1,2,\dots,N) \quad (5)$$

式中 θ_j 和 θ_k 为隐含层和输出层的阈值, z_{kp} 为输出层的输出。定义第 p 组训练样本网络的误差如下:

$$E_p = \frac{1}{2} \sum_{k=1}^L (z_{kp} - o_{kp})^2 \quad (p=1,2,\dots,N) \quad (6)$$

则, N 组训练样本网络的总误差为:

$$E = \sum_{p=1}^N E_p \quad (7)$$




图 5 人工神经网络结构
Fig. 5 ANN structure

3.2 调整人工神经网络权值的进化算法

遗传算法是模拟自然选择和继承的随机搜索算法,它与人工神经网络和模拟退火算法一样具有全局搜索能力,已经广泛地应用于结构损伤识别、初值和边值问题参数反演、跨孔地震层析成像、岩体应力场参数反演、飞机机翼面荷载识别以及结构动力荷载识别等领域^[13-15]。遗传算法具有计算编码简单和强有力的全局搜索能力的特点。与传统的优化方法相比,遗传算法的另一个特点是不要求目标函数连续、可微。它是一种迭代算法,在每一次迭代时都拥有一组解答,这组解答最初是随机生成的。每个解答都由一个适应度函数给与评价,而且,这一过程不断重复,直到达到某种形式上的收敛。新的一组解答,不但可以有选择的保留一些适应度函数值高的旧的解答,而且可以包括一些经由其他解答结合而得到的新的解答。问题的一个解用一个符号串或染色体表示。染色体由决定其自身特性的基因构成,而基因又可以有称为等位基因的不同取值。一组染色体的集合称为种群。遗传操作通过模拟进化和继承过程而生成符号串。繁殖、交叉和突变是三个简单的遗传操作。

个体的适应度 F_j 定义为如下形式

$$F_j = C - E_j \quad j=1,2,\dots,P \quad (8)$$

式中 C 是适应度函数的上界; P 为种群规模。实际计算时, 它可以用到当前代为止各进化代中适应度的最大值。将人工神经网络中的权值用一向量 χ 表示:

$$\begin{aligned} \chi &= \{\chi_1, \chi_2, \dots, \chi_T\}^T \\ &= \{w_{ih_{11}}, w_{ih_{12}}, \dots, w_{ih_{1J}}, w_{ih_{21}}, w_{ih_{22}}, \dots, \\ &\quad w_{ih_{2J}}, \dots, w_{ih_{M1}}, w_{ih_{M2}}, \dots, w_{ih_{MJ}}, who_{11}, \\ &\quad who_{12}, \dots, who_{1L}, who_{21}, who_{22}, \dots, who_{2L}, \\ &\quad \dots, who_{J1}, who_{J2}, \dots, who_{JL}\}^T \end{aligned} \quad (9)$$

则, 遗传算法的作用就是如何搜索网络的权值 χ , 使得人工神经网络总的误差函数最小。其计算步骤如下:

step1: 设定解空间 Π 与 GA 搜索空间 S , 选择 $\Pi \Leftrightarrow S$ 之间转换, 即编码和译码方式。设解空间一维参数 $x_i \in (x_{i\min}, x_{i\max})$, 则编码(由 GA 搜索空间 S 转换为解空间 Π)公式为:

$$x_i = x_{i\min} + (x_{i\max} - x_{i\min}) \sum_{j=1}^Q g_j 2^j / (2^Q - 1) \quad (10)$$

式中 S 为 2 进制位串长度; g_j 为 GA 搜索空间的第 j 个基因。

Step2: 确定 GA 算子及其有关运算次数, 包括: 种群规模 P , 交叉概率 P_c , 变异概率 P_m , 2 进制位串长度 Q 。

Step3: 在 GA 空间随机产生初始种群, 译码至问题空间。

Step4: 计算误差函数和适应度函数。

Step5: 执行收敛准则。本文采用的收敛准则为:

$$\min E \leq \varepsilon \quad (11)$$

式中 ε 为事先给定的充分小的正数, 其大小与观测仪器的精度或分辨率有关。对进化结果进行评价, 如果满足收敛准则, 与适应度 $F_{\max}$ 相对应的一组解, 即为所求问题的解(又称构型), 计算结束; 否则, 转至下步。

step6: 在 GA 空间, 进行 GA 操作: 即选择、交叉和变异。生成下一代种群, 译码至问题空间。判断是否执行梯度搜索策略见文献[15]。如果需要执行梯度搜索策略, 转至 Step7, 否则, 转至 Step4。

Step7: 执行梯度搜索策略, 转至 Step4。

3.3 观测数据的归一化处理

由于人工神经网络的输入数据是密集型的, 数据之间的差别太小, 如果直接将数据输入神经网络进行训练会引起混淆。因此, 必须对人工神经网络的输入数据和输出数据进行归一化处理 (Normalization Processing), 并且, 使得人工神经

网络输入层的输入值介于 $[-1, 1]$ 之间, 而输出层的输出值介于 $[0, 1]$ 之间。

$$x_{ip} = 2\{(\xi_{ip} - \xi_{i\min}) / (\xi_{i\max} - \xi_{i\min})\} - 1 \quad (12)$$

$$i = 1, 2, \dots, M; \quad p = 1, 2, \dots, N$$

式中 $\xi_{i\max}$ 和 $\xi_{i\min}$ 为神经网络输入层第 i 个节点 N 组训练样本的最大值和最小值;

$$\xi_{1p} = h_p, \quad \xi_{2p} = T_p, \quad \xi_{3p} = t_p \quad (13)$$

$$z_{kp} = (d_{kp} - d_{k\min}) / (d_{k\max} - d_{k\min}) \quad (14)$$

$$k = 1, 2, \dots, L; \quad p = 1, 2, \dots, N$$

式中 h_p 为上游水位; T_p 为气温; t_p 为日期; $d_{k\max}$ 和 $d_{k\min}$ 为神经网络输出层第 k 个节点 N 组训练样本的最大值和最小值。在人工神经网络训练结束后, 进行网络的预报操作。在神经网络预报操作阶段, 需要对数据网络的输出进行反归一化处理:


$$d_k^* = z_k^* (d_{k\max} - d_{k\min}) + d_{k\min} \quad (15)$$

式中 z_k 为未经反归一化神经网络输出; d_k 为经反归一化神经网络输出。

4 工程应用

丰满大坝位于吉林省吉林市第二松花江干流中游。该水电站以发电为主, 兼有防洪、灌溉、航运、城市及工业用水、养殖和旅游等综合效益。大坝始建于 1937 年, 1942 年工程未全面完工就利用临时断面蓄水, 1943 年第一台机组发电。1948~1949 年进行了恢复工作, 1951~1953 年进行了扩建和改建, 1953 年大坝全面建成。电站原装机容量 554 MW, 经不断扩机和改造, 现装机容量 1004 MW。丰满混凝土大坝为重力坝, 坝顶全长 1 080 m, 最大坝高 91.7 m, 坝顶原高程为 266.5 m, 加高后高程为 267.7 m。当水库水位 266.5 m 时, 水库总库容 107.8 亿 m^3 , 当坝顶到 267.7 高程时, 增加防洪库容 6.86 亿 m^3 。水库正常水位 263.5 m, 死水位 242.1 m。大坝共 60 个坝段, 每个坝段长 18 m, 坝顶宽 9~13.5 m。图 6 为 32 坝段断面图。根据丰满大坝 1978~1983 年坝顶位移观测数据, 采用进化算法对人工神经网络进行训练, 然后预报 1984 和 1985 年的坝顶水平位移。

所设计的人工神经网络的输入包括: 上游水位、观测日期和观测当日的气温。神经网络的输出是坝顶水平位移的预报值。其中, 输入层 3 个节点, 隐含层 6 个节点, 输出层 1 个节点, 收敛准则为目标函数 $E < 0.01$ 。遗传算法参数选取如下: 种群规模



100, 交叉概率 0.65, 变异概率 0.025, 二进制编码

图 6 32 坝段断面图

Fig. 6 Cross section of black 32

长度 20。图 7 为丰满大坝 38 坝段 1985 年坝顶水平位移观测值和预报值对比。从图 7 中可以看出, 与多元回归方法相比, 人工神经网络方法能够明显提高大坝水平位移的预报精度。




图 7 38 坝段 1985 年坝顶水平位移观测值和预报值对比

Fig. 7 Comparison between measured and forecast horizontal displacements at crest of dam in 1985

5 结 语

大坝安全运行监测资料是大坝安全监控的第一手数据, 它包含着大坝实际工况的各种信息。正确地从中认识和提取信息、了解大坝的工作状态, 对于大坝的安全管理和扩大水电站的经济效益和社会效益有着重要的意义。大坝安全监测的主要目的是了解坝体及其基础的实际工作状态, 尽早发现异常现象, 进行必要的技术处理, 以确保大坝的安全运行。研究表明, 与确定性预测模型相比, 基于统计模型的多元回归方法虽然拟合精度较高, 但与进化神经网络预测模型相比, 其预测效果精度较低。

工程实践表明, 采用遗传算法训练的人工神经网络预测模型预报大坝的变形具有精度高和全局收敛的特点。

参 考 文 献

- [1] 荆岫岩. 积分因子在丰满坝顶水平位移分析中的应用[J]. 东北电力技术, 1999, 6: 5—8.
- [2] 藤凯. 关于大坝变形预测模型的进一步研究[J]. 岩土工程技术, 2001, 3: 125—129.
- [3] 吴中如, 顾冲时. 大坝安全综合评价专家系统[M]. 北京: 北京科学技术出版社, 1997.
- [4] 王永岩. 软岩巷道围岩变形时序预测方法的研究[J]. 辽宁工程技术大学学报, 2001, 20(4): 505—506.
- [5] 张进平. 大坝安全监测的位移分布数学模型[J]. 水利学报, 1995, 5: 28—35.
- [6] 付文生, 李廷芥. 长潭水电厂混凝土大坝变形观测分析研究[J]. 岩土力学, 1998, 19(3): 87—92.
- [7] 高浪. 基于神经网络理论的深基坑土钉墙变形预测[J]. 岩石力学与工程学报, 2001, 20(增): 1 107—1 110.
- [8] Bakirtzis A G, Theocharis J B, Kiartzis S J, et al. Short term load forecasting using fuzzy neural networks[J]. *IEEE Transactions on Power Systems*. 1995, 10 (3): 1 518—1 524.
- [9] Kiartzis S J, Bakirtzis A G, Petridis V. Short-term load forecasting using neural networks[J]. *Electric Power Systems Research*, 1995, 33 (1): 1—6.
- [10] 李守巨, 刘迎曦, 王登刚. 基于神经网络的混凝土大坝弹性参数识别[J]. 大连理工大学学报, 2000, 40(5): 531—535.
- [11] Kim K H, Park J K, Hwang K J, et al. Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems[J]. *IEEE Transactions on Power Systems*. 1995, 10 (3): 1 534—1 539.
- [12] Maifeld T, Sheble G. Short-term load forecasting by a neural network and a refined genetic algorithm [J]. *Electric Power Systems Research*, 1994, 31 (3): 147—152.
- [13] Chou Jung-Huai. Genetic algorithm in structural damage detection[J]. *Computers & structures*, 2001, 79 (14): 1 335—1 353.
- [14] 李守巨, 刘迎曦, 王登刚. 基于遗传算法的结构振动参数识别方法[J]. 中国矿业大学学报, 2001, 30(3): 256—260.
- [15] Vittorio Maniezzo. Genetic evolution of the topology and weight distribution of neural networks[J]. *IEEE Transactions on Neural Networks*, 1994, 5(1): 39—53.