

逐一混合遗传算法在大坝变形预报中应用

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: 建立了大坝变形预报的逐一混合遗传模型, 并将其与整体遗传模型、逐一 Levenberg-Marquardt (LM) 模型、整体 LM 模型进行了比较。工程实例表明, 在建模样本相同, 预报因子相同, 且结构参数不变的条件下, 逐一混合遗传模型和整体遗传模型的预报精度分别高于逐一 LM 模型和整体 LM 模型, 且预报结果稳定; 逐一混合遗传模型和逐一 LM 模型的预报精度分别高于整体遗传模型和整体 LM 模型; 随着样本的积累, 逐一混合遗传模型的预报精度不断提高, 并具有实时性的优点, 可以准确、有效地应用于大坝变形监测量的实时预报。

关键词: 遗传算法; BP 网络; 大坝变形监测; 实时预报

中图分类号: TV 698.1 **文献标识码:** A

0 引言

在大坝监测中, 经常需要从已有的监测数据中提取信息并对大坝未来的变化趋势进行预测。目前, 国内外大坝安全监测中主要采用统计模型、确定性模型和混合模型来进行安全评价和预报^[1]。这些模型的预报精度较大程度上取决于建模因子的选择是否恰当; 另一方面, 回归方程本身也只是确定的线性和非线性因子的组合, 由于影响监测量的因素众多, 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; 且时效变形的影响因素较多, 寻找合理的时效因子困难相对较大。为了解决这些问题, 一些学者^[2~4]提出采用人工神经网络模型进行监测量的预报。

人工神经网络是由大量神经元有机组合而成的具有高度自适应的非线性系统, 它通过大量样本的学习来挖掘隐含在样本中的因果关系, 可以表达复杂的非线性关系, 并且不要求分析对象的数学模型, 这对于大坝变形预测是适宜的。其中, 误差反向传播网络 (error back-propagation network, 简称 BP 网络) 是应用于水利水电工程领域中最有效、最活跃的方法, 且绝大多数采用了 3 层结构 (输入层、一个隐含层和输出层)。尽管一

些研究^[1~5]表明, BP 网络具有较高的预测精度, 但由于 BP 网络的固有缺点 (结构不惟一、收敛速度慢、易陷入局部极小), 极大地限制了它在实时预报和大量样本情况下的应用。为此, 一些学者提出采用 Levenberg-Marquardt 算法 (简称 LM) 修正 BP 网络的连接权, 实践证明, 该算法在快速训练网络方面功能强大, 比普遍采用的梯度下降法快将近 500 倍^[6], 因而可以大大提高学习效率。但是该方法仍然无法解决 BP 网络训练结果不惟一的缺陷。

而遗传算法^[7~8] (genetic algorithm, 简称 GA) 是一种不依赖具体问题的直接搜索方法, 它仅需给出目标函数的描述, 从一组随机产生的初始解开始, 从全局空间出发搜索问题的最优解。由于遗传算法善于全局搜索, 且能以较大的概率找到全局最优解, 利用遗传算法来训练神经网络, 就可以在相当大的程度上避免局部极小, 训练次数和最终权值也可以相对稳定, 训练速度进一步加快。

所以, 本文将遗传算法与基于 LM 训练算法的 BP 网络结合, 形成 GA-LM 混合遗传算法, 利用该算法对大坝变形监测量进行逐一预报, 从而形成逐一混合预报模型, 以更精确地实现大坝变形监测量的预报。

1 GA-IM 混合遗传算法的建模^[7-11]

1.1 网络的结构

采用具有输入层、1个隐含层和输出层的 3 层结构的神经网络建模。神经元的激励函数 $f(x)$ 采用 Sigmoid 函数,即

$$f(x) = 1/(1 + e^{-x})$$

1.2 数据的规范化

在网络训练前,将全部输入、输出因子变换到 (0,1) 范围,即

$$X' = 0.1 + \frac{0.8(X - X_{min})}{X_{max} - X_{min}}$$

式中: X 为原始数据; X_{max} 、 X_{min} 分别为原始数据每组因子的最大值和最小值; X' 为规范化后的数据。

1.3 目标函数与适应度函数

GA-IM 混合遗传算法的目标函数定义为

$$SE(W^*) \leq SE(W_i);$$

$$i = 1, 2, \dots, N, g = 1, 2, \dots, g_{max}$$

即搜索所有进化代中使网络的误差平方和最小的网络权重。

因为遗传算法只能朝着使适应度函数值增大的方向进化,所以,适应度函数可以构造成目标函数倒数的形式,即以样本误差平方和 $SE(W_i)$ 的倒数作为适应度函数。为了保证适应度函数值不至于太小,引入一个较大的系数 M ,这里取 $M = 10^6$ 。则适应度函数

$$Eval(W_i) = \frac{10^6}{SE(W_i)}; i = 1, 2, \dots, N$$

$$SE(W_i) = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

式中: N 为种群规模; n 为输出层节点数; y_i 和 $\hat{y}_i$ 分别为样本的实测值和网络输出值。

1.4 GA 优化 BP 网络的初始权值和阈值

(1) 编码

采用浮点编码,直接利用网络的权重作为染色体进行编码。

对于一个 3 层的 BP 网络,任一组完整的神经网络权重

$$W_i = \{k_{1i}, k_{2i}, b_{1i}, b_{2i}; i = 1, 2, \dots, N\}$$

相当于一个染色体,这样的染色体共有 N 个,即种群规模为 N 。染色体长度 S 等于全部权值和偏差之和。

(2) 遗传操作

① 选择继承

评价各个体的适应值,适应值越大的个体被选择的概率越大。

② 交叉运算

采用算术交叉算子,即两个父代以线性交叉的方式产生子代。

③ 变异运算

对由交叉运算生成的各个体,采用非均匀变异算子进行变异操作。

④ 优化保存策略

对于前一代中最佳的个体及适应值最大的个体,直接保存到下一代中,以避免上一代的最优个体被交叉操作和变异操作所破坏。

⑤ 进化终止条件

如果满足既定的终止条件,则以最优的适应度个体作为最优解输出;否则,从当前父代和子代的各种取值中重新排序选择出 N 个适应值较大的个体作为下一代的样本。转步骤 (1) 重新进行训练,直到训练目标得到满足为止。

(3) 解码

经遗传优化的最优个体(染色体)解码,即得到 BP 网络优化的初始权值 k_1, k_2 和阈值 b_1, b_2 。

1.5 利用 IM 算法调整 BP 网络权重

已知 BP 网络的最优初始权值和阈值,然后利用 IM 算法训练网络,逐步调整网络的权重,使网络的期望输出和实际输出的误差平方和最小。网络权重调整的计算公式为

$$W^{t+1} = W^t + \Delta W$$

$$W = (k_1 \quad b_1 \quad k_2 \quad b_2)^T$$

式中: 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;上标 t 表示迭代次数。

权值的变化

$$\Delta W = (J^T J + \lambda I) J^T e$$

式中: J 为雅可比矩阵,表示误差对权值的微分; J^T 为雅可比矩阵的转置阵; λ 为常数,是自适应调整的,当 λ 很大时,上式就近似于梯度法,当 λ 很小时,上式就成了 Levenberg-Marquardt 法; I 为单位阵; e 为误差向量。

IM 算法训练过程可以利用 Matlab 的工具箱函数 `trainlm` 实现。重复此过程直至训练误差达到一个预定的目标极限误差。

1.6 仿真输出结果

将测试样本数据输入训练好的网络进行仿真输出,得到预测的大坝变形监测量。

以上计算过程全部使用 Matlab 6.5 编程完成。

2 工程应用

丰满水电站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. 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. 大坝观测工作始于 1954 年, 观测项目包括坝顶水平位移、纵向扬压力、横向扬压力和漏水量等. 1984 年建成真空激光观测系统, 并于 1986 年底实现了自动化观测, 1993 年实现了从数据采集到数据整理分析的一整套自动化系统, 观测精度和观测效率得到很大提高.

本文针对丰满大坝 8 号坝段 1993~1998 年的 127 组坝顶水平位移观测数据, 应用上述方法建立逐一混合遗传模型 (简称 SGA-LM), 用 1999-01-14~2000-06-14 的 18 组数据作为检验样本, 对所建立的预报模型进行检验.

模型为多输入单输出模式, 输入量即影响因子数, 坝体水平位移的影响因素包括水位、温度和时效^[1]. 水压因子取 H 、 H^2 、 H^3 、 H^4 (H 为测点所在坝段的水深); 温度分量取正弦、余弦谐波因子各 2 项, 即 $\sin(2\pi it/365)$ 和 $\cos(2\pi it/365)$, 其中 $i=1, 2$, t 为从始测日到观测日的累计天数; 温度因子取 T_0 (当天气温)、 T_7 (前 7 d 平均气温)、 T_{15} (前 15 d 平均气温)、 T_{30} (前 30 d 平均气温)、 T_{60} (前 60 d 平均气温)、 T_{90} (前 90 d 平均气温)、 T_{120} (前 120 d 平均气温); 时效分量取 2 项, 即 θ 、 $\ln \theta$, 其中 $\theta=0.01t$, 故网络模型的输入层节点数为 17 个; 隐含层节点数取为 18 个; 输出量 1 项, 即模型预报值, 这里为坝顶水平位移. 因此, 学习样本采用 17-18-1 的网络结构形式.

为证明模型的有效性并分析训练样本数量对

预报精度的影响, 以以下 4 种模型进行对比.

(1) 逐一混合遗传模型 (简称 SGA-LM)

利用 1993~1998 年 127 个训练样本建立 GA-LM 模型并训练, 利用训练好的网络预测第 128 个水平位移值; 同理利用前面 128 个训练样本建模, 预测第 129 个水平位移值; 依此类推, 直到利用前 144 组数据拟合, 预测第 145 个水平位移值. 每次都分别用 GA 优化 BP 网络初始权值, 然后利用 LM 算法训练网络, 得到最终的权值和阈值, 并计算仿真输出.

(2) 整体遗传模型 (简称 WGA-LM)

利用 1993~1998 年 127 个训练样本建立 GA-LM 模型并训练, 再利用训练好的网络整体预测 1999~2000 年 18 个水平位移.

(3) 逐一 LM 模型 (简称 SLM)

利用 1993~1998 年 127 个训练样本建立 BP 模型, 随机选取初始权值, 再采用 LM 算法调整权值, 应用训练好的网络预测第 128 个水平位移值; 依此类推, 直到利用前 144 组数据拟合, 预测第 145 个水平位移值.

(4) 整体 LM 模型 (简称 WLM)

利用 1993~1998 年 127 个训练样本建立 BP 网络, 采用 LM 算法修正权值; 然后利用训练好的网络整体预测 1999~2000 年的 18 个水平位移.

参数设定: 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 $p_m=0.05$ 权重初始化空间 $b=[-0.3, 0.3]$ 最大进化代数 $g_{\max}=10$ 染色体长度 $S=343$ LM 算法的误差指标 0.001.

4 种模型的拟合效果见图 1. 可以看出: SGA-LM 模型的拟合值与实测值曲线几乎重合, 拟合效果很好.

利用 4 种模型分别对 1999~2000 年的 18 个水平位移检验样本进行预报, 并采用以下 3 种统计指标对各模型的预报效果加以对比分析.




图 1 4 种模型的拟合曲线对比

Fig. 1 Fitting curves comparison of four models

平均相对误差:

$$MAPE = \frac{1}{n} \sum_{i=1}^n |100 \times (y_i - \hat{y}_i) / y_i|$$

均方误差:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

平均绝对误差:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

4种预报模型的残差比较见表 1,各评价指标的对比结果见表 2

从表 1可以看出,SGA-ILM 模型的残差普遍

小于其他 3个模型的对应值,说明 SGA-ILM 模型的预报效果最好.

分别对比表 2的 2 3两行以及 4 5两行可以看出:在建模样本相同,预报因子相同,且结构参数不变的条件下,逐一预报模型 (SLM 和 SGA-ILM) 的精度均高于对应的整体预报模型 (W LM 和 WGA-ILM) 的精度.说明随着训练样本的增加,网络的“学习”能力不断增强.同时,这也证明:各个历史样本的地位并非是平等的,实质上与预报量最近的样本信息对未来预报精度的影响比较大,而与其距离较远的样本的影响则相对较小.

表 1 4种预报模型的残差比较 (单位: mm)
Tab. 1 Residual errors comparison of four prediction models (unit mm)

日期	SLM 模型	W LM 模型	SGA-ILM 模型	WGA-ILM 模型
1999-01-14	- 0 880 5	- 0 901 6	- 0 280 5	- 1 608 8
1999-02-04	0 300 7	0 108 9	0 127 7	- 0 578 4
1999-03-12	0 557 2	0 444 7	0 118 1	0 208 0
1999-04-16	- 0 512 9	0 496 1	0 226 6	- 0 115 7
1999-05-23	- 0 808 1	- 1 158 6	- 0 971 2	- 1 700 3
1999-06-09	0 849 6	- 0 593 6	0 315 5	- 1 071 0
1999-07-21	- 1 505 2	- 1 596 2	- 0 816 0	- 1 117 0
1999-08-17	- 1 811 0	- 1 766 4	- 0 833 3	- 1 471 5
1999-09-20	0 436 0	- 0 995 7	- 0 195 2	- 0 771 8
1999-10-02	2 118 4	1 653 1	1 913 9	1 792 1
1999-11-14	- 1 969 9	- 0 147 7	- 0 628 9	0 084 4
1999-12-09	0 178 1	0 413 9	- 0 394 5	0 926 3
2000-01-10	0 117 6	0 390 3	- 0 543 4	1 254 1
2000-02-18	- 0 425 6	0 682 7	- 0 317 6	2 141 6
2000-03-08	- 0 256 8	0 856 9	- 0 356 0	1 970 9
2000-04-11	- 0 184 8	1 341 7	- 0 268 9	1 300 1
2000-05-25	- 0 883 3	0 018 1	- 0 286 7	0 053 6
2000-06-14	0 751 0	0 309 2	0 078 2	0 386 0

表 2 4种预报模型 的各评价指标的对比
Tab. 2 Comparison of evaluation index of four prediction models

模型	MAPE %	MAE /mm	MSE /mm
SLM 模型	32 619 2	0 972 8	1 269 1
W LM 模型	48 911 7	1 160 0	1 449 6
SGA-ILM 模型	16 521 1	0 522 4	0 701 5
WGA-ILM 模型	40 944 7	1 094 4	1 292 6

另外还可以看出:无论是整体预报还是逐一预报,基于 GA-ILM 算法的模型 (SGA-ILM 和 WGA-ILM) 的预报精度均明显高于对应的单纯

基于 LM 算法的模型 (SLM 和 W LM) 的精度,而且预报结果稳定.这是由于 GA-ILM 算法优化了 BP 网络的初始权重,克服了经典 BP 模型初始权值选择的随机性所带来的网络振荡,预报结果比较稳定.

综合考虑各种评价指标,给出 4种模型预报精度的排序为 SGA-ILM > SLM > WGA-ILM > W LM.

尽管采用 SGA-ILM 模型预报时,需要的总预报时间相对较长.但是,对于每一个待预测样本,平均预报时间仅 12 s 完全满足实时预报的需要,

而且具有相当高的精度.

3 结 论

(1) SGA-IM 模型利用 GA-IM 算法进行逐一预报, 预报时间短, 且精度非常高, 完全满足实时预报的需要.

(2) 常规的 BP 模型易受初值选择随机性的影响, 预报结果不稳定. 而基于 GA 算法的 SGA-IM、WGA-IM 模型比 SLM 和 WLM 模型预报效果好, 且预报结果稳定.

(3) 在建模样本相同、预报因子相同, 且结构参数不变的条件下, 逐一预报模型 (SGA-IM 和 SLM) 的精度普遍高于对应的整体预报模型 (WLM 和 WGA-IM) 的精度.

(4) SGA-IM 模型不依赖于初值的选取, 是一种稳定、高精度的预报方法.

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 5-120
[2] 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
[3] 杨 杰, 吴中如, 顾时冲. 大坝变形监测的 BP 网络模型与预报研究 [J]. 西安理工大学学报, 2001(1): 25-29

[4] MAIER H R, DANDY G C. The use of artificial neural networks for the prediction of water quality parameters [J]. Water Resour Res 1996 32(4): 1013-1022
[5] 蔡煜东, 姚林声. 径流长期预报的人工神经网络方法 [J]. 水科学进展, 1995(1): 61-65
[6] 李守巨, 刘迎曦, 吴玉良, 等. 基于神经网络的建筑结构节点损伤识别方法 [J]. 大连理工大学学报, 2003, 43(3): 270-273
(LI Shou-ju, LIU Ying-xi, WU Yu-liang, et al. Damage identification of building structure with IM artificial neural networks [J]. J Dalian Univ Technol 2003 43(3): 270-273)
[7] 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 18-89
[8] 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 29-98
[9] 王述红, 田 军. 遗传神经网络方法预测地下工程位移演化规律 [J]. 东北大学学报 (自然科学版), 2000(5): 562-565
[10] 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(增): 130-133
[11] 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, 1998 55-89

Application of serial hybrid genetic algorithm to prediction of dam deformation

YAN Bin^{1,2}, ZHOU Jing^{* 1}

(¹ School of Civil and Hydraul Eng, Dalian Univ of Technol, Dalian 116024, China
² College of Hydraul Eng, Shenyang Agric Univ, Shenyang 110161, China)

Abstract A new model named serial hybrid genetic algorithm model based Levenberg-Marquardt algorithm (SGA-IM) is developed to predict dam deformation. The model is compared with whole genetic algorithm model based Levenberg-Marquardt algorithm (WGA-IM), serial hybrid Levenberg-Marquardt model (SLM) and whole Levenberg-Marquardt model (WLM). Case study shows that SGA-IM and WGA-IM are superior to SLM and WLM respectively, and SGA-IM and SLM are superior to WGA-IM and WLM respectively in prediction accuracy under the circumstances of the same modeling samples, forecasting factors and structure parameters. The SGA-IM has characteristics of real-time and stable forecasting results. With accumulation of samples, the forecasting precision of SGA-IM is continually improved. Thus, SGA-IM is comparatively effective in real-time prediction of dam deformation.

Key words genetic algorithm; BP network; monitoring of dam deformation; real-time prediction