顾及大坝位移残差序列混沌效应的 GA-BP 预测模型

魏博文^①, 彭圣军^{①②}, 徐镇凯^{①*}, 姜振翔^①

① 南昌大学建筑工程学院, 南昌 330031;

② 江西省水利科学研究院, 南昌 330029

* E-mail: xzkncu@126.com

收稿日期: 2014-07-30; 接受日期: 2014-11-03

国家自然科学基金(批准号: 51409139)和江西省教育厅青年科学基金(批准号: GJJ14223)资助项目

摘要 针对大坝观测数据常规模型训练后的残差混沌效应及模型回归方法的拟合度等问题, 文中融合遗传算法与神经网络的数据训练优势, 通过构建的遗传神经网络(GA-BP)算法对大坝变形观测序列资料进行回归提取残差序列. 基于位移回归残差序列的混沌特性, 利用混沌理论对其残差序列进行数值分析, 并将残差预测结果与 GA-BP 预测模型进行叠加. 据此, 提出了考虑大坝变形残差序列混沌效应的 GA-BP 监控预测模型. 实例表明, 文中建立的预测模型的计算精度及收敛速度均得到提高, 且考虑残差影响的大坝监控模型的预测效果得到了有效的提升. 该模型的建模方法亦可推广应用于边坡及其他水工建筑物的安全预警.

关键词

大坝

残差序列

遗传神经网络

(GA-BP)

混沌理论

1 引言

变形是最能直观可靠地反应大坝运行状况的重要观测量之一, 对变形原始观测资料进行处理分析也是近年来国内外研究大坝运行状况的主要方法之一. 变形观测资料处理分析的方法主要有回归分析、时间序列分析、灰色系统理论和模糊数学等^[1~4]. 由于大坝变形是一个非线性过程, 且变形与各影响因素之间存在复杂的非线性关系, 而以上几种方法并没有很好地体现出这种非线性关系, 从而影响了预测结果的可靠性. BP 神经网络是由大量处理单元互联组成的非线性、自适应信息处理系统, 在解决这类非线性预测问题上具有一定的优势. 一般的 BP 神经

网络存在易陷入局部极小值和收敛速度慢等问题, 遗传算法具有全局寻优的能力, 很好地弥补了 BP 神经网络的这种缺点^[5,6]. 将 BP 神经网络和遗传算法相结合, 用遗传算法来优化神经网络的权值和阈值, 可以达到优势互补.

在一般的水工建筑物变形研究工作中, 尽管可以通过以上方法建立变形监控模型, 但由于此类模型只考虑了主要影响因子而未加入对残差的分析, 往往会出现模型拟合效果好而预测结果不佳的问题^[7]. 事实上, 残差序列的演化与外界影响因子及研究系统存在某种关系, 且表现出一定程度的非线性和复杂性, 看似随机但却是确定性非线性系统的表象, 即残差序列具有混沌特征. 为此, 文中基于遗传算法

引用格式: 魏博文, 彭圣军, 徐镇凯, 等. 顾及大坝位移残差序列混沌效应的 GA-BP 预测模型. 中国科学: 技术科学, 2015, 45: 541–546
Wei B W, Peng S J, Xu Z K, et al. The GA-BP prediction model considering chaos effect of dam displacement residual (in Chinese). Sci Sin Tech, 2015, 45: 541–546, doi: 10.1360/N092014-00181

改进 BP 神经网络的基础上, 运用混沌理论进一步对残差进行分析预测, 并将残差预测结果添加到未考虑残差的常规监控模型中, 以提高模型的预测效果。

2 遗传算法优化 BP 神经网络

遗传算法(genetic algorithm, GA)^[8]是借鉴达尔文的进化论和孟德尔的遗传学说而发展起来的一种随机搜索方法。经实践证明 GA 能较好地收敛于问题的全局最优解, 具有应用范围广、鲁棒性强等优点^[9-11]。作为人工神经网络中主要模型之一的 BP 神经网络, 采用误差梯度下降的方式修改各层权值, 且具有很强的自适应、自组织及自学习的能力。但是 BP 神经网络易陷入局部极小值, 在网络训练过程中, 初始权值、阈值是随机生成的, 所以存在收敛速度慢的问题。为此, 将 GA 与 BP 神经网络结合, 利用 GA 优化 BP 神经网络的初始权值、阈值, 提高网络的计算精度和收敛速度。

GA 优化 BP 神经网络的步骤为

1) BP 神经网络对观测数据进行训练, 得到网络权重值 W_i :

$$W_i = (w_{1,i}, w_{2,i}, w_{3,i}, b_{1,i}, b_{2,i}, b_{3,i}, i=1, 2, \dots, P), \quad (1)$$

W_i 可看做为遗传算法中的染色体, 共 P 个, 即种群规模。采用浮点编码对权重值进行编码, 则每个染色体上的基因为二维矩阵, 整个染色体为三维矩阵。将染色体上对应的权值、阈值代入 BP 神经网络, 可得到染色体的训练误差 ΔE_i , 误差 ΔE_i 的倒数为适应值。为避免适应值过小, 引入一大数 M , 则染色体的适应值为

$$F(i) = M / \Delta E_i. \quad (2)$$

2) 选择操作, 选择概率为

$$p_s = F(i) / \sum F(i). \quad (3)$$

选择操作过程中, 适应值大的个体直接作为下一代, 而不进行交叉变异操作。

3) 交叉操作, 产生新个体

$$\begin{cases} P_1 = \alpha P_1 + (1-\alpha)P_2, \\ P_2 = (1-\alpha)P_1 + \alpha P_2, \end{cases} \quad (4)$$

式中, α 为 [0,1] 的随机数; P_1, P_2 为随机选择的基因座上的基因, 由于染色体是三维的, 因此要以交叉概率 p_c 随机选择 3 次。

4) 变异操作, 选择两条染色体上的不同基因座上的基因进行变异, 与交叉操作一样, 也要选择 3 次。

5) 重复步骤 2), 3), 4), 直到 BP 神经网络的误差最小, 得到一组优化的初始权值、阈值。

将优化后的权值、阈值代入 BP 神经网络, 对观测数据进行训练、仿真, 得到计算值, 根据计算值与实际观测值可得到一组残差序列 $\{\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n\}$ 。

3 运用混沌理论对残差进行预测

运用混沌理论的相空间重构技术, 将残差序列 $\{\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n\}$ 嵌入到重构的相空间中, 在此相空间中可以发现残差序列系统的演化规律, 从而对下一时间段的残差 ε_{n+1} 进行预测。

1) 残差序列相空间重构

相空间重构理论^[12]认为, 对于时间序列 $\{\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n\}$ 以及延迟时间 τ , 嵌入维数 m , 可得到 m 维相空间:

$$\varphi_i = [\varepsilon_i, \varepsilon_{i+\tau}, \dots, \varepsilon_{i+(m-1)\tau}]^T, \quad (i=1, 2, \dots, N). \quad (5)$$

式中, φ_i 为 m 维相空间中的一个相点; N 为相空间中的相点个数, $N = n - (m-1)\tau$ 。所以重构相空间关键是确定延迟时间 τ 和嵌入维数 m 。

2) 嵌入维数 m 的计算

G-P 算法^[13,14]认为, 在延迟时间 τ 已知情况下, 先给定一个小值 m_0 , 可以得到一个重构的相空间, 由此相空间可以计算关联维数 $C(\lambda)$:

$$C(\lambda) = \frac{1}{N^2} \sum_{\substack{i,j=1 \\ i \neq j}}^N H(\lambda - \|\varphi_i - \varphi_j\|), \quad (6)$$

式中, $H(\theta)$ 为 Heaviside 函数, $H(\theta) = \begin{cases} 1, & \theta > 0 \\ 0, & \theta \leq 0 \end{cases}$; λ

为一给定正数; $\|\varphi_i - \varphi_j\|$ 为相点 φ_i 与 φ_j 的距离。

对于 λ 的某个适当范围, 混沌吸引子的维数 d 与 $C(\lambda)$ 满足对数线性关系:

$$d(m) = \frac{\ln C(\lambda)}{\ln \lambda}. \quad (7)$$

据此可求出对应于 m_0 的维数 $d(m_0)$ 。增大嵌入维数 m , 重复以上步骤, 直到 $d(m)$ 不再随 m 的增大而发生较大的变化, 即在一定误差范围内保持不变。此时的 m 即为所求的嵌入维数。

3) 延迟时间 τ 的计算

对于一般的系统, 采用去偏复自相关法^[15], 计算公式为

$$C(\tau) = \frac{1}{n} \sum_{i=0}^{n-1} \sum_{j=1}^{m-1} (\varepsilon_i - \bar{\varepsilon})(\varepsilon_{i+j\tau} - \bar{\varepsilon}), \quad (8)$$

式中, n 为序列长度; m 为嵌入维数; $\bar{\varepsilon}$ 为序列均值. 据此可以作出 $C(\tau) - \tau$ 关系曲线, 当 $C(\tau)$ 减小到初始值的 $1-1/e$ 时所对应的 τ 即为重构相空间的时间延迟.

4) 残差 ε_{i+1} 的预测

混沌时间序列预测的方法有全域法和局域法. 全域法是将相空间中的全部相点用来拟合求解, 所以计算量大, 当嵌入维数 m 较高、预测函数又比较复杂时, 预测精度将减小. 对于预测函数简单, 噪声小的情形, 全域法比较适合. 与全域法不同的是, 局域法只采用了部分相点进行预测, 通常是将相空间中的最后一个相点最为预测中心点, 找出离中心点最近的那些相点, 并对这些相点进行拟合, 以估计系统轨迹的下一点走向, 最后从预测得到的轨迹点中分离出所需的预测项. 局域法中有零阶局域法、一阶局域法及最大 Lyapunov 指数法等. 下面介绍最大 Lyapunov 指数法预测的过程.

若需对 ε_{i+1} 进行预测, 则选取相点 φ_i 为预测中心点, 并假设相点 φ_i 的最近邻点为 φ_j 且最大 Lyapunov 指数为 $\lambda_{\max}$, φ_i 与 φ_j 之间的距离为

$$d = \min_j \|\varphi_i - \varphi_j\| = \|\varphi_i - \varphi_j\|. \quad (9)$$

最大 Lyapunov 指数预测模型的表达式为

$$\|\varphi_i - \varphi_{i+1}\| = \|\varphi_i - \varphi_{i+1}\| e^{\lambda_{\max}}. \quad (10)$$

(10) 式中只有 φ_{i+1} 的最后一个分量 ε_{i+1} 是未知的, 所以对 ε_{i+1} 进行预测是可行的.

通过以上混沌时间序列预测法对残差 ε 进行预测, 将残差预测结果添加到未考虑残差影响的常规数学监控模型中, 形成一种考虑残差混沌效应的混沌混合监控模型, 以提高模型的预测效果. 考虑残差混沌效应的大坝位移混沌混合监控模型的表达式可以表示如下:

$$\delta = F(\delta_H, \delta_T, \delta_\theta) + \varepsilon, \quad (11)$$

式中, ε 为利用混沌理论得到的位移残差预测值; δ_H , δ_T , δ_θ 分别为位移的水压、温度及时效分量, 具体

可参考文献[1].

综上所述, 可得到考虑残差混沌效应的混沌混合监控模型的形成流程图, 如图 1 所示.

4 工程实例

某拦河主坝为碾压混凝土重力坝, 坝顶高程 179.0, 最大坝高 111.0, 坝顶总长 300.0, 坝顶宽 7.0 m, 分为 6 个坝段, 编号为 1~6 #. 为确保大坝的安全运行, 在建筑物表面及内部布置了变形、渗流、温度及应力应变等较为全面的监测项目. 其中, 大坝变形监测项目有正垂线、倒垂线、引张线和视准线. 本次选取 2# 坝段某一测点引张线水平位移自动化观测数据为试验样本, 观测资料起止日期为 2003 年 1 月 1 日~2008 年 12 月 31 日.

分别采用一般 BP 神经网络和遗传算法改进后的 BP 神经网络对测点 2003 年 1 月 1 日~2007 年 12 月 31 日的监测数据进行训练, 其训练过程如图 2 所示.

由图 2 可看出, 利用遗传算法优化后的 BP 神经网络的训练次数不到一般 BP 神经网络的训练次数的 1/2, 且遗传算法优化后的 BP 神经网络训练过程线的斜率变幅比一般 BP 神经网络训练过程线的斜率变幅大, 由此说明了遗传算法优化后的 BP 神经网络的计算速度大大提高了. 这主要是由于遗传算法对 BP 神经网络的权重进行了优化, 解决了一般 BP 神经网络因随机产生初始权重而导致训练速度慢等问题.

图 1 混沌混合监控模型形成流程图

图2 两种算法训练过程

(a) BP 神经网络训练过程; (b) 遗传神经网络(GA-BP)训练过程

利用训练好的 GA-BP 神经网络建立大坝位移监控模型, 并得到测点训练数据的拟合过程线及残差过程线, 如图 3 和图 4 所示. 为检验 GA-BP 模型的预测效果, 利用其对测点 2008 年 1 月 1 日~2008 年 1 月 31 日的水平位移进行预测, 图 5 为位移预测值和实测值对比图

选取 GA-BP 模型对测点 2003 年 1 月 1 日~2007 年 12 月 31 日的位移拟合残差(图 4)作为待分析的残差序列, 并将该残差序列记作 $\{\varepsilon_i\}$. 以下根据第 3 节所述混沌理论对残差进行预测.

首先采用 G-P 算法对相空间重构所需的嵌入维数 m 进行确定. 分别取 $m=2,3,\dots,9$, 由 G-P 算法得到 $\ln C(r)$ 与 $\ln r$ 的关系图, 如图 6 所示.

由图 6 可以看出, $\ln C(r)$ 与 $\ln r$ 关系曲线中存在直线部分, 该直线的斜率为不同嵌入维数 m 所对应的

图3 GA-BP 模型训练数据拟合过程线

图4 GA-BP 模型训练数据残差过程性

图5 水平位移实测值与预测值

图6 $\ln C(r)$ 与 $\ln r$ 的关系图

吸引子维数. 可以看出, 当 $m=7$ 时, 直线部分的斜率基本不变, 即此时吸引子维数维持在一个稳定值, 由此确定嵌入维数 m 为 7.

确定嵌入维数 m 后, 采用去偏复自相关法确定延迟时间 τ . 具体做法是根据(8)式作出去偏复自相关函数关于时间 $\tau(\tau=1,2,\dots)$ 的关系曲线图, 当函数值下降到初始值的 $1-1/e$ 时, 所对应的时间 τ 即为所

要确定的延迟时间. 经计算得到延迟时间 $\tau = 2$.

确定延迟时间 τ 和嵌入维数 m 后, 即可对残差序列 $\{\varepsilon_i\}$ 进行相空间重构, 并采用最大 Lyapunov 指数的预测法对残差进行预测. 将残差预测值添加到未考虑位移残差影响的 GA-BP 模型中, 形成考虑残差混沌效应的大坝位移混沌混合监控模型. 为比较 GA-BP 模型与混沌混合模型的预测效果, 将两种模型对测点 2008 年 1 月 1 日~2008 年 1 月 30 日的位移预测结果绘制于图 7.

由图 7 可以看出, 相比于未考虑位移残差混沌效应的常规 GA-BP 监控模型, 考虑位移残差混沌效应

图 7 (网络版彩图)位移预测结果对比图

的混合监控模型对大坝水平位移的预测结果整体上更接近于实测值, 由此验证了所建立的混沌混合监控模型的合理性和科学性, 同时也说明位移残差存在混沌特性. 从图中也可以看出混沌混合监控模型前期预测结果要优于后期预测结果, 随着时间的增大, 其预测结果偏离实际值较大, 这主要是因为混沌现象本身所固有的对初值的敏感性, 导致混沌现象短期可以预测, 而长期不能预测.

5 结论

1) GA-BP 模型有机地结合了遗传算法全局寻优能力和 BP 神经网络的局部寻优能力, 解决了 BP 神经网络因随机产生初始权重而导致训练速度慢等问题.

2) 考虑位移残差混沌效应的混沌混合监控模型减小了预测误差, 其预测效果要优于常规数学监控模型, 验证了混沌混合监控模型的合理性, 同时也说明位移残差具有混沌特性.

3) 由于混沌现象本身所固有的对初值的敏感依赖性, 对混沌时间序列进行预测的尺度受到一定的限制, 即混沌现象短期可以预测, 而长期不能预测.

参考文献

- 1 吴中如. 水工建筑物安全监控理论及其应用. 北京: 高等教育出版社, 2003
- 2 徐峰, 汪洋, 杜娟, 等. 基于时间序列分析的滑坡位移预测模型研究. 岩石力学与工程学报, 2011, 30: 746-751
- 3 李恒凯, 刘传立. 基于灰色理论的变形智能预测模型库研究. 岩土力学, 2011, 32: 3119-3124
- 4 黎良辉, 魏博文, 徐镇凯. 考虑混凝土坝坝体移动力突变盲点的安全监控模型. 人民长江, 2013, 44: 58-62
- 5 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. 水力发电学报, 2005, 24: 110-113
- 6 Xie S C, Zhou H, Zhao J J, et al. Energy-absorption forecast of thin-walled structure by GA-BP hybrid algorithm. J Cent South Univ, 2013, 20: 1122-1128
- 7 包腾飞, 吴中如, 顾冲时. 基于统计模型与混沌理论的大坝安全监测混合预测模型. 河海大学学报: 自然科学版, 2003, 31: 534-538
- 8 Zhou A, Qu B Y, Li H, et al. Multiobjective evolutionary algorithms: A survey of the state of the art. Swarm Evol Comput, 2011, 1: 32-49
- 9 赵万忠, 王春燕. 基于遗传算法优化的 EPS 路感混合 H_2/H_∞ 控制. 中国科学: 技术科学, 2012, 42: 248-256
- 10 Ramkumar B, Schoen M P, Lin F. Hybrid enhanced continuous tabu search and genetic algorithm for parameter estimation in colored noise environments. Exp Syst Appl, 2011, 38: 3909-3917
- 11 Hu L M, Chen F, Li Y Z. Research of optimal design for gravity dam based on niche genetic algorithm. In: Barbosa S, Chen P, Cuzzocrea A, et al., eds. Communications in Computer and Information Science. Berlin Heidelberg: Springer-Verlag, 2011. 323-328
- 12 Liu S Y, Zhang Y X, Zhu S J, et al. Study on predication of chaotic time series based on phase space reconstruction. In: Janusz Kacprzyk, eds. Advances in Intelligent and Soft Computing. Berlin Heidelberg: Springer-Verlag, 2011. 87-97
- 13 Dong C J, Shao C F, Zhang H, et al. Phase space reconstruction of traffic flow parameters on expressway based on G-P algorithm. Eng Technol Ed, 2012, 42: 594-599
- 14 董春娇, 邵春福, 张辉, 等. 基于 G-P 算法的快速路交通流参数相空间重构. 吉林大学学报(工学版), 2012, 42: 594-599
- 15 吕金虎, 陆君安, 陈士华. 混沌时间序列分析及其应用. 武汉: 武汉大学出版社, 2002

The GA-BP prediction model considering chaos effect of dam displacement residual

WEI BoWen¹, PENG ShengJun^{1,2}, XU ZhenKai¹ & JIANG ZhenXiang¹

¹ School of Civil Engineering and Architecture, Nanchang University, Nanchang 330031, China;

² Jiangxi Provincial Institute of Water Sciences, Nanchang 330029, China

Aiming at the problems of residual chaos effect in dam common monitoring model and the fitting degree of model regression methods, the dam deformation observation data fitting residual was extracted with genetic neural network (GA-BP) algorithm by combining the advantage of genetic algorithm and neural network. For the chaotic characteristics of deformation fitting residual, chaos theory was used to analyze residual series, and the residual prediction results were added in GA-BP prediction model. Hereby, the GA-BP prediction model considering chaos effect of dam displacement residual was established. Example showed that the calculation accuracy and convergence rate of this prediction model were all improved, and the prediction effect of this model was better. Furthermore, the modeling methods introduced in this paper could be applied to security early warning in slope and other hydraulic structures.

dam, residual series, genetic neural network (GA-BP), chaos theory

doi: 10.1360/N092014-00181