

文章编号: 1000-7598-(2006)08-1344-05

大坝安全诊断的混沌优化神经网络模型

曹茂森^{1,2}, 邱秀梅², 夏 宁¹

(1. 河海大学 土木工程学院, 南京 210098; 2. 山东农业大学 水利土木工程学院, 泰安 271018)

摘 要: 为了提高大坝变形的预测精度, 采用小波变换和分形理论对大坝位移观测数据的非线性动力学特性进行了分析, 揭示了其具有低维混沌动力特性, 这为大坝变形预测模型的建立提供了理论依据和先验知识。基于低维混沌动力特性, 设计了能捕获大坝位移观测数据全局动力特性, 兼具神经网络模型结构优化和动力机制时新的混沌优化神经网络大坝变形预测模型。在工程实例中, 由多个度量指标组成量化评价体系, 对模型预测性能进行综合评价, 结果表明, 所建模型比传统 BP 神经网络和 ARMA 模型具有更高的预测精度。

关 键 词: 大坝位移; 低维混沌; 动力特性; 小波变换; 混沌优化神经网络

中图分类号: TV 698; O 233

文献标识码: A

A chaos-optimized neural network model for dam safety monitoring

CAO Mao-sen^{1,2}, QIU Xiu-mei², XIA Ning¹

(1. College of Civil Engineering, Hohai University, Nanjing 210098, China;

2. College of Water Conservancy and Civil Engineering, Shandong Agricultural University, Tai'an 271018, China)

Abstract: Dam deformation prediction is important for dam safety monitoring and has become a focus of increasing interest in recent years. In this study, on the basis of nonlinear dynamic property analysis of the observations of dam displacements, a novel methodology is proposed to establish dam deformation prediction model with improved prediction precision. Firstly, the dynamic properties of observations of dam displacements are studied by combined wavelet transform with fractal, and the results reveal that dam displacements possess certain low dimensional chaotic character. This provides theoretical foundation and transcendental knowledge for relational establishment of dam deformation prediction model. Moreover, derived from the low dimensional chaotic character, a chaos-optimized neural network model for dam deformation prediction is constructed, which is not only capable of capturing the dynamic properties of observations of dam displacements but also of implementing the model's structural optimization and dynamic mechanism refreshing. Finally, in the practical application of dam deformation prediction, the model performance is quantificationally assessed by multiple indices. The result demonstrates that chaos-optimized neural network model holds higher prediction precision than the conventional back propagation (BP) neural network and ARMA models; and therefore, it is promising for dam safety monitoring.

Key words: dam displacements; low dimensional chaos; dynamic properties; wavelet transform; chaotic-optimal neural networks

1 引 言

分析大坝原型观测数据和建立大坝变形实时预测模型是大坝安全诊断的重要内容^[1]。大坝位移观测数据反映了大坝在荷载和环境作用下产生效应量的动态演化, 承载了坝体性态的丰富信息。基于对位移观测数据进行科学分析, 建立大坝变形实时预测模型具有重要意义。在观测数据的分析方面, 文献[2]论证了大坝位移观测数据中存在混沌现象, 这

对于建立预测模型具有重要意义; 在实时预测模型建立方面, 文献[3]利用位移观测数据的混沌性质确定自变量个数, 提出了大坝变形的相空间神经网络预测模型, 用法比较新颖。然而, 上述两文均没有深入分析对建立预测模型至关重要的混沌程度问题。此外, 文献[4, 5]提出了基于时间序列分析的大坝变形神经网络预测方法。作为以上研究的进一步延伸拓展, 本文对以下两个问题进行研究: (1) 大坝位移观测数据中的混沌动力学特性 (混沌呈现、

收稿日期: 2004-02-05

修改稿收到日期: 2004-12-05

基金项目: 中国博士后科学基金资助项目(No. 2005038236); 国家自然科学基金资助项目(No. 50379005)。

作者简介: 曹茂森, 男, 1971 年生, 博士, 副教授, 主要从事土木工程健康诊断与损伤机理研究。E-mail: cmszhy@sohu.com

混沌程度): (2) 利用低维混沌特性构建混沌优化神经网络的方法, 以建立大坝变形实时预测模型。

2 位移测数据的混沌动力特性分析

库水位、气温、时效对大坝位移的影响相对明确, 构成位移观测数据呈确定性变化趋势; 同时大坝位移还受到若干不确定性、模糊、随机因素的影响, 尤其是观测数据中不可避免地含有噪声。根据上述特点, 采用小波变换代替传统的线性回归对观测数据进行“降趋”和“降噪”。小波变换的非线性处理能力和非参数化特点使其比线性回归具有明显优势。

图 1 为从某一大坝第 5 坝段某测点实测的水平位移观测数据序列 X (含 600 个采样点)。依据功率谱初步分析, 选择 Db4 小波作为分析小波, 将 X 分解至第 2 精度层, 分离出趋势 a_2 和噪声 d_1 , 成分 d_2 为混沌赋存项, 见图 2。




图 1 实测大坝水平位移序列 X

Fig.1 Observed dam horizontal displacements X




图 2 提取混沌赋存项 d_2

Fig.2 Extraction of component d_2 containing chaos

2.1 混沌呈现检测

参照文献[2]的方法, 对混沌赋存项 d_2 进行相空间重构, 并计算关联积分, 以判断其是否存在混沌现象。为了适应少量数据点的情形, 采用下式计算关联积分:

$$C(r) = \frac{2}{(N_m - W + 1)(N_m - W)} \sum_{n=W}^{N_m} \sum_{i=1}^{N_m-k} H(r - |Y_{i+k} - Y_i|) \quad (1)$$

式中 m 为嵌入维数; N_m 为相点数; Y_i, Y_{i+k} 为相点; $W \geq \tau |2/N_m|^{2/m}$, 其中 τ 为时间延迟; $H(J)$ 为 Heaviside 函数。当 $J > 0$ 时, $H(J) = 1$; 当 $J \leq 0$, $H(J) = 0$ 。

关联维计算为求取一极限过程:

$$D_m = \lim_{r \rightarrow 0} \frac{\ln C(r, N_m, W)}{\ln r} \quad (2)$$

如果随着嵌入维数 m 增大至 m^* , D_m 逐渐趋于饱和值: 奇异吸引子关联维, 记为 $D_2(m^*)$ 。关联维是分数值, 说明 d_2 具有混沌特征。

图 3 为 D_m 随嵌入维数 m 的变化情况。其中以白噪声 $D_m = m$ 为参照, 明显可辨 D_m 随着 m 增大趋于饱和, 关联维为 3.89。这证明 d_2 具有混沌特征, 从而表明, 大坝水平位移观测数据中蕴含混沌成分。对“去噪”后的大坝位移成分 X^1 ($X^1 = a_2 + d_2$) 进行上述分析, 当 $m^* = 6$ 时, $D_2(6) = 3.66$, 也可辨混沌特征, 但混沌特征弱于 d_2 。

功率谱分析和最大 Lyapunov 指数方法分析的结果较好地支持了上述结论。




图 3 D_m 随嵌入维数 m 的变化

Fig.3 Variation of D_m with embedding dimension m increasing

2.2 混沌程度度量

离散序列 $\{c\}$ 属于低维混沌, 而区别于高维混沌或随机噪声的一个主要特征是在其重构的相空间轨线 c 上, 邻近相点之间具有非线性相关关系。这一特征使得低维混沌序列具有初值敏感性和短期可预测性。短期可预测性表示为: $c(t+T) = f_T(c(t))$, f_T 表示邻近相点之间的非线性相关关系。若采用最近临居预测法求取 F_T 以近似 f_T , 且预测精度由预测相点与实际相点之间的相关系数 ρ 表示, 那么 $\{x\}$ 是低维混沌的判据为: ρ 随邻居个数 κ 的增大而减小, 随嵌入维数 m 的增大而饱和于 1, 且随预测距离 T 的增大而减小。

对大坝位移观测数据成分 d_2 进行分析, 得到 ρ 随 κ , m , T 的变化关系见表 1。其中相关系数 ρ 随着 κ 的增大而减小, 随着 T 的增大而减小, 随着 m 增大至 6 而趋近于 0.651。 ρ 随着 m 增大并非趋近于 1 的原因可能是低维性使参与计算的最近临居集合中含有伪成分, 且实测数据与理论混沌模型存在差距。综合分析认为, 上述特征基本满足低维混沌判据, 可以判定 d_2 属于低维混沌。

表 1 d_2 的混沌程度分析
Table 1 Analysis on chaotic level of d_2

$\kappa \searrow \rho$		$m \searrow \rho$		$T \searrow \rho$	
κ	ρ	m	ρ	T	ρ
5	0.652	2	0.389	τ	0.652
10	0.625	3	0.452	2τ	0.635
20	0.588	4	0.564	3τ	0.606
30	0.553	5	0.650	4τ	0.592
40	0.512	6	0.651	5τ	0.568
50	0.469	7	0.651	6τ	0.523
60	0.421	8	0.651	7τ	0.465

3 混沌优化神经网络模型

大坝位移观测数据的低维混沌动力特性为建立大坝变形预测模型提供了理论基础和指导思想: 短期预测是可行的; 应采用非线性方法建模; 初值敏感性要求模型须随时间演化; 奇异吸引子分形维确定了预测自变量的个数, 其必要值是关联维数的最小上界整数: $\text{INT}(D_2(m^*)+1)$, 充分值是嵌入维数 m^* [6]。

3.1 基本模型

采用非线性方法建模的要求, 揭示了依据库水位、气温、时效因子的多元线性回归模型及时间序列线性回归 (AR) 建模存在不足, 而采用神经网络建模适应了这一要求 [7, 8]。但现有神经网络建模方法大多没有充分考虑大坝位移观测数据的动力学特性, 使所建模型不能紧扣问题实质。

对于观测数据成分 $d_2: \{d\}$, 其低维混沌性决定了在其重构相空间 q 内可进行一步短期预测, 即

$$q(t+\tau_1) = f_1(q(t)) \quad (3)$$

简化目标变量改写为

$$d(t+\tau_1) = f'_1(d(t), d(t-\tau_1), \dots, d(t-(l-1)\tau_1)) \quad (4)$$

式中 f'_1 为非线性函数; l 为分形维确定的预测自变量个数; τ_1 为时间延迟。

借鉴文献 [4, 5] 时间序列分析策略, 尝试采用神经网络建立大坝变形预测模型。基于观测数据序列 X 的去噪成分 $X^1: \{x^1\}$, 建立基本神经网络预测

模型, 其能够反映下面函数关系:

$$x^1(t+\tau) = f_0(x^1(t), x^1(t-\tau), \dots, x^1(t-(n-1)\tau)) \quad (5)$$

式中 f_0 为包括线性、混沌等成分的全局动力特性函数; τ 为时间延迟; n 取嵌入维数 m^* 。

3.2 演化学习策略

混沌的初值敏感性要求神经网络预测模型须具有时间演化特性。根据这一要求, 设计了演化学习策略, 见图 4。




图 4 预测模型的演化学习策略
Fig.4 Evolutive study strategy of prediction model

该策略包括观测数据基本动力机制提取、模型结构优化、动力机制时新三部分 [9]。实施步骤如下:

(1) 基本动力机制提取 将大坝位移观测数据序列 H 分成 Y 和 C 两个集合, C 含有最新状态的少量数据点, 称为优化-时新窗。按 3.1 节建立基本神经网络模型。将集合 Y 送入模型进行学习, 提取大坝位移的基本动力机制。

(2) 结构优化 在神经网络学习中, 采用 OBS (Optimal Brain Surgeon) 技术对网络模型冗余的连续系数进行修剪, 以使模型“神经”弱化记忆、增加泛化, 从而实现网络模型的结构优化。其中 C 作为模型性能检验集。

(3) 动力机制时新 将集合 H 作为学习集送入结构优化后的网络模型进行学习。由于 OBS 的系数更新操作, 此时实质上只是对与 C 有关的最新样本进行学习, 模型突出学习了新信息, 更新思维, 实现时间演化特性。

上述方法所建模型以大坝位移观测数据的低维混沌动力特性为理论基础, 且融合 OBS 和动力机制时新技术来优化、提高神经网络的预测性能, 称之为混沌优化神经网络模型。

4 试验分析

某混凝土拱坝高 90 m, 坝顶弧长为 247 m, 坝顶厚 20 m。拟以第 5 坝段某测点实测的水平位移观测数据 (见图 1) 为分析对象, 建立大坝变形实时一步预测的混沌优化神经网络模型, 从而建立该坝段的安全诊断系统。

4.1 基本网络模型

第 2 节分析结果表明, 该观测数据具有低维混沌动力特性。对于大坝位移成分 X^1 , 当 $m^*=6$ 时, $D_2(6)=3.66$, 据此将输入神经元个数取为 6。基本的神经网络拓扑结构 (输入层-隐层-输出层) 见图 5(a)。将 X^1 分为子集 H (序号 1~575) 和 T (序号 576~600)。将 H 进一步分为 Y, C (维数为 6)。将 Y 送模型学习, 以捕获观测数据的基本动力机制。图 5(a)中实、虚线展现了连接系数大于和小于零的分布状况。







图 5 神经网络模型的结构优化与动力机制时新
Fig.5 Structural optimization and dynamic mechanism refreshing of neural network model

4.2 结构优化与动力机制时新

基本神经网络模型的结构优化操作见图 5 (b), 其中实线和虚线展示了系数修剪过程中训练误差 E_t 及关于 C 的泛化误差 E_c 的变化。OBS 运行方向上, E_t 的渐增表示模型性能由记忆向泛化转化, 由 E_c 曲线上较稳定的低值确定的优化网络结构见图 5(c)。网络连接系数由最初的 65 个裁剪为 29 个, 减少了 54 %。将 H 送结构优化后的模型进行学习, 模型突出学习新知识, “与时俱进”, 达到最佳预测性能。动力机制时新操作使输入层 (含 1 个偏差单元) 至隐层的连接系数空间由最初的 W_{11} 变化为 W_{21} , 相对变化见图 5(d)。

4.3 预测结果与性能评价

对 H 进行模拟和对 T 进行一步预测的结果见图 6。为了对模型性能进行综合量化评价, 选用 $RMSE$, CR , $NMSE$ 等 3 种性能度量指标:

$$RMSE = \lg \left| \frac{\sum_{k=1}^N [y(k) - \hat{y}(k)]^2}{\sum_{k=1}^N y(k)^2} \right| \quad (6)$$

$$CR = \sqrt{1 - \frac{\sum_{k=1}^N [y(k) - \hat{y}(k)]^2}{\sum_{k=1}^N [y(k) - \frac{1}{N} \sum_{k=1}^N y(k)]^2}} \quad (7)$$

$$NMSE = \frac{1}{N\sigma^2} \sum_{k=1}^N [y(k) - \hat{y}(k)]^2 \quad (8)$$

式中 $y(k)$, $\hat{y}(k)$ 分别为实测和预测值; σ^2 为相应于预测集的实测数据点的方差; N 为预测点数。





图 6 大坝变形预测
Fig.6 Predictions of dam deformation

将文中混沌优化神经网络与传统 BP 神经网络和 ARMA 模型进行比较,通过多次改变基本网络模型连接系数的预赋初值和隐层神经元的个数来实现多个预测过程,以指标均值作为模型性能测度,见表 2。可见文中方法优于 BP 神经网络,更优于 ARMA 模型。

表 2 三种预测模型的比较

Table 2 Comparisons of three prediction methods

度量指标	NMSE	RMSE	CR
混沌优化神经网络	0.329 9	-1.752 7	0.977 0
BP 神经网络	0.461 9	-1.567 5	0.948 8
ARMA 模型	0.651 3	-1.164 1	0.880 8

5 结 论

基于大坝观测数据的非线性动力学特性分析,建立了混沌优化神经网络大坝变形预测模型。与 BP 神经网络、ARMA 模型相比,该模型有效地提高了预测效果。可见,对于神经网络这一门先进的数学理论,既然三层网络能够逼近任何非线性关系,那么用其解决实际工程问题时,追求“科学应用”,包括增强其与工程本质的有机匹配性及排除高精度带有偶然性现象,有时比追求“先进学习算法”更重要。本文是在水利工程领域对上述思想的一些初步实践,研究有待于进一步深入。

参 考 文 献

- [1] 付文生, 李廷芥. 长潭水电站混凝土大坝变形观测研究[J]. 岩土力学, 1998, 19(3): 87—92.
FU Wen-sheng, LI Ting-jie. Analysis of deformation data observed from Changtan hydropower station dam[J]. **Rock and Soil Mechanics**, 1998, 19(3): 87—92.
- [2] 汪树玉, 刘国华, 杜王盖, 等. 大坝观测数据序列中的混沌现象[J]. 水利学报, 1999, (7): 22—26.
WANG Shu-yu, LIU Guo-hua, DU Wang-gai, et al. Chaotic phenomenon in observation data of dam monitoring[J]. **Journal of Hydraulic Engineering**, 2002, (7): 22—26.
- [3] 徐洪钟, 吴中如, 李雪红. 相空间神经网络在大坝安全监控中的应用[J]. 水利学报, 2001, (6): 67—71.
XU Hong-zhong, WU Zhong-ru, LI Xue-hong. Neural network of phase space and its application in dam safety monitoring[J]. **Journal of Hydraulic Engineering**, 2001, (6): 67—71.
- [4] 邓兴升, 王新洲. 根据历史位移预报大坝变形的神经网络方法[J]. 水电自动化与大坝观测, 2004, 28(2): 51—53.
DENG Xing-sheng, WANG Xin-zhou. A neural network methodology for dam deformation predictions using historical displacements[J]. **Journal of Hydropower Automation and Dam Monitoring**, 2004, 28(2): 51—53.
- [5] 陈继光. 基于 Lyapunov 指数的观测数据短期预测[J]. 水利学报, 2001, (9): 64—67.
CHEN Ji-guang. Short term observation data forecasting based on Lyapunov exponent[J]. **Journal of Hydraulic Engineering**, 2001, (9): 64—67.
- [6] ZHANG Sheng, LIU Hong-xing, GAO Dun-tang, et al. Determining the input dimension of a neural network for nonlinear time series prediction[J]. **Journal of Chinese Physics**, 2003, (12): 594—598.
- [7] 王志旺, 张保军, 李迪, 等. 大坝变形监测遗传神经网络模型[J]. 岩土力学, 2003, 24(增刊): 130—133.
WANG Zhi-wang, ZHANG Bao-jun, LI Di, et al. Dam deformation monitoring model based on genetic algorithm of neural network[J]. **Rock and Soil Mechanics**, 2003, 24(Supp.): 130—133.
- [8] 李守巨, 刘迎曦, 刘玉静. 基于进化神经网络混凝土大坝变形预测[J]. 岩土力学, 2003, 24(4): 635—638.
LI Shou-ju, LIU ying-xi, LIU Yu-jing. Dam deformation forecasting by evolving artificial neural network[J]. **Rock and Soil Mechanics**, 2003, 24(4): 635—638.
- [9] 曹茂森, 任青文, 毛伟兵. 基于解耦子波和优化神经网络的大坝变形预测[J]. 岩石力学与工程学报, 2005, 24(10): 1 751—1 757.
CAO Mao-sen, REN Qing-wen, MAO Wei-bing. New prediction model for dam deformation based on decoupled wavelet and optimal neural networks[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2005, 24(10): 1 751—1 757.