

相空间重构神经网络在 洪水灾害损失预报中的应用

曹连海, 曹 波, 陈南祥, 徐建新

(华北水利水电学院 岩土工程系, 河南 郑州 450008)

[摘要] 在灾害领域中引入混沌理论, 将相空间重构理论与神经网络相结合, 提出了洪灾成灾面积预测模型。通过相空间重构, 把一维成灾面积时间序列拓展为多维序列, 而多维序列包含着各态历经的信息, 从而可挖掘更为丰富的信息, 有利于神经网络的训练。利用神经网络模型可以较好地求解非线性问题, 因而使预测结果更符合实际。实例表明, 该模型预报精度较高。

[关键词] 相空间重构; 神经网络; 洪水灾害损失; 预报模型

[中图分类号] P426.6 [文献标识码] A [文章编号] 1672-6561(2006)02-0089-04

Application of Phase Space Reconstruction and Neural Network in Flood Disaster Losing Forecasting

CAO Lian hai, CAO Bo, CHEN Nan xiang, XU Jian xin

(Department of Geotechnical Engineering, North China College of

Water Conservancy and Hydroelectric Power, Zhengzhou 450008, Henan, China)

Abstract Introducing chaos theory in the disaster resources field, the forecasting models for the inundated area of flood disaster were brought forward integrating reconstruction of phase space and neural network. One dimension inundated area series is developed to multi dimension inundated area series with reconstruction of phase space, and the multi dimension series include ergodic information, so that more abundant information can be found in favor of ANN training. With neural network, non linear problem can be solved better, as a result, forecasting can accord well with practice even more. The example indicates that the model has highly forecasting precision.

Key words: phase space reconstruction; neural network; flood disaster losing; forecasting model

0 引言

中国是一个灾害种类较多、发生频率较高的国家。从公元前180年至公元1949年因灾害死亡人数就约2992万人, 而1949~1978年受灾农作物面积平均为 $(4\sim4.7)\times 10^7\text{ hm}^2$, 直接经济损失达100亿元^[1]。自然灾害是自然变异与社会相互作用的现象, 其定量的标志是自然变异强度与社会防御能

力的矛盾比, 其关键是社会损失的大小。灾害系统是由承灾体、致灾因子、孕灾环境以及灾情等子系统组成的、受自然和人类社会因素共同影响的复杂大系统^[2-3]。成灾面积、受灾人口和经济损失等损失因子作为灾害社会损失的重要衡量指标, 是灾情子系统中重要的定量描述指标, 其在时间分布上往往呈现出极强的随机性, 传统的统计方法已无法揭示其不确定性行为机制。

混沌理论的出现, 为解释复杂系统动力学行为

[收稿日期] 2005 06 13

[基金项目] 国家863项目(2002AAZZ4291); 2005年度河南省高校杰出科研人才创新工程项目(HAIPURT)(2005KYCX015)

[作者简介] 曹连海(1970-), 男, 河南信阳人, 讲师, 从事水环境保护与水资源研究。

机制及其预测预报等研究提供了有力的工具。有关研究表明, 自然灾害的时间序列具有混沌性质^[2, 4-6]。一方面, 混沌现象利用固有的确定性表明许多随机现象实际上是可以预测的; 另一方面, 混沌现象所固有的对初值的敏感依赖性又意味着预测能力受到新的根本性限制。从时间序列研究混沌, 始于 Packard 等提出的重构相空间理论。随着混沌理论和应用技术研究的不断深入, 混沌时间序列的建模和预测已成为混沌信息处理研究领域中的热点^[7]。但在实际应用中, 由于受研究对象的数据太少和噪声等因素影响, 使得预测模型精度无法令人满意。20 世纪 90 年代, 以神经网络为代表的非线性预测理论在认识时间序列混沌行为中的应用取得重大进展^[8], 拓宽了应用前景。

笔者将混沌理论和神经网络相结合, 提出并建立了预报灾害的相空间神经网络模型。并以 1950~1997 年洪涝灾害及成灾面积为例, 运用混沌识别方法揭示了洪涝灾害的混沌特征, 将相空间重构与神经网络结合应用于洪涝灾害损失时间序列的预报, 可进一步为洪涝灾害预报和洪涝灾害损失预报提供新的思路。

1 混沌时间序列的相空间重构理论

相空间重构的目的在于在高维相空间中恢复混沌吸引子, 混沌吸引子作为混沌系统的特征之一, 体现着混沌系统的规律性。对于决定系统长期演化任一变量的时间序列, 均包含了系统所有变量长期演化信息。因此, 可以从任一决定系统长期演化蕴含系统参与运动的全部变量痕迹的单变量时间序列恢复提取系统长期演化信息。时间序列的恢复特征是混沌系统所产生的某一特定轨迹(混沌吸引子), 经过类似拉伸和折叠后演化的结果。

为了从实际的单因变量时间序列中估计出系统的信息, Packand 在 1980 年提出了用时间序列重构吸引子的相空间图像^[9]。

设时间序列 $\{x_i\}$, 其时间间隔是 Δt (单位时间)。对于 n 个变量的动力系统有

$$dx_i/dt = f_i(x_1, x_2, \dots, x_n), i = 1, 2, \dots, n \quad (1)$$

通过消元法, 使其变换为 n 阶非线性微分方程

$$x^{(n)} = f(x, x^1, \dots, x^{n-1}) \quad (2)$$

变换后, 新轨迹

$$X(t) = [x(t), x^1(t), \dots, x^{n-1}(t)] \quad (3)$$

描述了同样的动力学系统, 它在由坐标 $x(t)$ 加上具 $n-1$ 阶导数 $x^1(t), \dots, x^{n-1}(t)$ 所构成的相空间中演变。代替这种连续变量 $x(t)$ 和它的导数, 可考虑不连续的时间序列和它的 $n-1$ 时滞位移 $X(t) = [x(t), x(t+\tau), \dots, x(t+(n-1)\tau)]$, 只要将时滞 τ 选作时间序列的时间尺度, 将会保证延滞坐标线性无关。

设单变量时间序列为 $\{x(t_i), i = 1, 2, \dots, n\}$, 延滞时间 $\tau = k \cdot \Delta t, k = 1, 2, \dots$, 则可将此时间序列延拓成 m 维相空间

$$X_i(t) = \{x(t_i), x(t_i + \tau), \dots, x[t_i + (m-1)\tau]\} \quad i = 1, 2, \dots, m \quad (4)$$

式中: $X_i(t)$ 为 m 维相空间中的一个相点, 任一相点 $X_i(t)$ 有 m 个分量, m 满足条件: $m = n - (m-1)k$ 。 m 维相空间中的一个相点表示系统在某个瞬时后状态, 而相点的连线构成了点在相空间中的轨迹, 这条轨线便表示了系统状态随时间的演化。于是在 m 维相空间中得到了一个相型, 从原则上讲, 便有了足够的信息把体系的动态展现在多维相空间上来考察。

2 神经网络的基本原理

人工神经网络(ANN)是一种模拟人的神经系统而建立起来的非线性动力学模型, 有自组织、自学习和联想记忆功能^[10], 并具有分布式、并行性和高度鲁棒性等特点^[11]。

目前在系统识别、预测预报中常用的是 BP 网络模型, 并以 3 层 BP 网络为主, 3 层 BP 网络的主要算法过程是: 采用 3 层 BP 网络建模, 其结构如图 1, 输入层为 h 个成分, 即输入层有 h 个结点 x_1, x_2, \dots, x_h , 输出层为 1 个结点 y , 其隶属函数为

$$f(u) = \frac{1}{1 + e^{-u}} \quad (5)$$




图 1 三层前馈网络

Fig. 1 Three Layer BP Network

隐含层数目由文献[12]的方法确定。设输入层与隐含层之间的权为 V_{ij} , 阈值为 θ_j , 隐含层与输出层之间的权为 W_{j0} , 阈值为 γ , 则各层神经元的输出满足下列公式

$$y_0 = f(\sum_{j=1}^p W_{j0} x'_j - \gamma) \tag{6}$$

$$x'_j = f(\sum_{i=1}^h V_{ij} x_i - \theta_j) \tag{7}$$

定义其输出误差为

$$E_{\text{总}} = \frac{1}{2} \sum_{k=1}^p (y_0^k - y_0^k)^2 \tag{8}$$

式中: p 为样本数; y_0^k 、 y_0^k 分别为第 k 个样本学习算法的输出值和实际值。

3 基于相空间重构与神经网络耦合的径流量预测模型的建立

在灾害系统中, 单个社会损失因子通常是个单变量时间序列 $\{x(t_i), i = 1, 2, \dots, n\}$, 其观察时间间隔为 Δt 。对于这样的时间序列, 若要预测 $\{x(t_n + l), l = 1, 2, \dots\}$, 首先根据上述相空间重构理论, 按延滞时间 τ 对单变量时间序列 $\{x(t_i)\}$ 作漂移, 拓展成 m 维序列。其次, 需要构造 BP 网络的结构形式。然后, 选取学习网络的输入样本和期望输出。

3.1 确定相空间饱和嵌入维数 m 和延滞时间 τ

在重构相空间中, 时间延迟 τ 和嵌入维数 m 的选取具有十分重要的意义。选取方法有多种, 一般可采用自相关法和复相关法计算 τ , 再用 $G-P$ 算法计算 m , 也可用 $C-C$ 算法计算 τ 和 m 。 m 计算要求数据资料序列较长, 实际应用中, 对较短资料序列, 可根据相空间重构理论的基本思想, 在确定预测模型结构时, 直接取 2、3、4……维来重构相空间, 以最好的模拟预测结果来筛选嵌入维的取值^[13]。

3.2 建立网络

根据混沌时间序列的嵌入维数 m , 用 $m - 1$ 作为网络的输入层节点数, 输出层节点为 1。网络的输入、输出为

$$\begin{matrix} & \text{学习样本输入} \\ \left[\begin{array}{cccc} x(1) & x(2) & \cdots & x(n - (m - 1)\tau) \\ x(1 + \tau) & x(2 + \tau) & \cdots & x(n - (m - 2)\tau) \\ x(2 + \tau) & x(3 + \tau) & \cdots & x(n - (m - 3)\tau) \\ \vdots & \vdots & \vdots & \vdots \\ x(1 + (m - 2)\tau) & x(2 + (m - 2)\tau) & \cdots & x(n - 1) \end{array} \right]^T \end{matrix}$$

期望输出

$$\begin{bmatrix} x(1 + (m - 1)\tau) \\ x(2 + (m - 1)\tau) \\ x(3 + (m - 1)\tau) \\ \vdots \\ x(n) \end{bmatrix}$$

在确定网络的输入、输出的结构后, 可从已知序列中提取学习样本构成训练集, 对网络进行训练, 直至达到一定的误差精度要求为止。网络训练完成后, 把最后 $m - 1$ 维相空间加入到网络输入中, 可实现对 $x(t_n + l)$ 的预测, 即建立了相空间重构与神经网络的耦合预测模型。

4 应用实例

在洪水灾害系统中, 洪水造成的成灾面积是十分重要的社会损失因子, 准确的预测和预报成灾面积, 便于国家合理的准备救灾物资救济灾民, 减少人民的生命财产损失。笔者以中国 1950 ~ 1997 年洪灾的成灾面积为例^[14]。用自相关法求得时间延迟 $\tau = 2$ 。对饱和嵌入维数 m 的确定, 考虑到本例实测数据系列不是很长, 首先用 $G-P$ 算法计算得 $m = 11$ 。

利用 1950 ~ 1990 年 41 年的数据建立模型, 以 1950 年数据为 $x(1)$, 1951 年为 $x(2)$, 1990 年的数据为 $x(41)$, 用建立好的模型预测 1991 ~ 1997 年的受灾及成灾面积, 将预测的结果与实际数据进行对比, 检验模型的精度。

以重构相空间的相点作为网络的输入层结点^[15], 采用的 3 层网络输入层有 6 个节点, 如以 $[x(1), x(3), \dots, x(19)]$ 为第 1 个输入结点, 以 $[x(2), x(4), \dots, x(20)]$ 为第 2 输入结点, 依此类推即可得到 6 个输入结点。隐含层为 12 个节点, 输出层为 1 个节点, 经 4 441 次迭代, 收敛误差达到标准, 学习结束。网络的拟合值与实际数据的比较如图 2。由图 2 可见, 所建的相空间重构与神经网络的耦合预测模型的拟合精度较高, 最大相对误差是 1976 年的 11.32%, 最小相对误差是 1956 年的 0.02%, 其中小于 10% 占 94.3%, 大于 10% 为 5.7%。根据训练好的网络参数, 预测 1991 ~ 1997 年的洪灾成灾面积, 并与实测数据比较(表 1), 相对误差均小于 10%, 表明所建预测模型的预测效果很好。




图 2 BP 网络期望输出和实际输出比较

Fig. 2 Comparison of the Expectance Export with Real Export of the BP Network

表 1 实测值和预测值对比

Tab. 1 Data Comparison of Observation and Prediction

年份	1991	1992	1993	1994	1995	1996	1997
预测值	1 536.65	413.21	843.27	1 167.12	781.23	1 043.61	563.34
实测值	1 461.40	446.40	861.07	1 074.40	763.00	1 085.00	584.00
相对误差 /%	5.15	7.43	2.07	8.63	2.39	3.81	3.54

5 结语

(1) 研究表明, 将混沌相空间理论用于洪水灾害系统的中长期预测, 较传统途径可以更多地利用时间序列中包含的丰富信息, 也就是从任一决定系统长期演化蕴含系统参与运动的全部变量痕迹的单变量时间序列恢复提取系统长期演化信息, 可以更好地揭示洪水灾害动力系统复杂的运动规律。混沌重构相空间理论与神经网络模型相结合, 对揭示灾害动力系统复杂的非线性结构是非常有效的, 它是不同于传统确定性和随机性途径预测方法的一种新途径。

(2) 利用神经网络建模可以解决普通模型不能较好解决的非线性问题, 利用相空间重构能够较好

地揭示洪水灾害系统随机现象内在的规律。将相空间重构理论与神经网络模型相结合, 对 1991 ~ 1997 年成灾面积预测的实际应用表明, 相空间重构神经网络模型是可行的, 对于洪水灾害系统的中长期变化模拟预报能力较高, 可以取得较为理想的结果。

[参 考 文 献]

[1] 梁鸿光. 减灾必读[M]. 北京: 地震出版社, 1990.

[2] 赵 晶, 徐建华. 1950 ~ 1997 年我国洪涝灾害成灾面积的分形特征研究[J]. 自然灾害学报, 2003, 12(2): 31 ~ 35.

[3] 朱良峰, 吴信才, 殷坤龙, 等. 基于信息量模型的中国滑坡灾害风险区划研究[J]. 地球科学与环境学报, 2004, 26(3): 52 ~ 56.

[4] Yang Siqian, Chen Yaning, Wang Angsheng. Dynamic Mechanism of Flood Disaster on the Basis of Chaotic Theory [J]. 中国科学院研究生院学报, 2003, 20(4): 446 ~ 451.

[5] 卢志光, 白丽萍, 卢 丽. 运用混沌理论制作长期灾害预测模型初探[J]. 中国农业大学学报, 2002, 7(3): 43 ~ 46.

[6] 汪华斌, 李江凤, 吴树仁. 滑坡灾害系统非线性研究进展[J]. 地球科学进展, 2000, 15(3): 271 ~ 276.

[7] 马军海, 盛昭瀚. 混沌经济时序非线性动力系统的预测方法研究[J]. 系统工程学报, 2002, 17(2): 97 ~ 102.

[8] 李冬梅, 王正欧. 基于 RBF 网络的混沌动力系统辨识[J]. 天津大学学报: 自然科学版, 2002, 35(2): 191 ~ 195.

[9] 林振山. 长期预报的相空间理论和模式[M]. 北京: 气象出版社, 1993.

[10] 杨中宝, 彭省临, 李朝艳. 基于 GIS 的人工神经网络矿产预测系统设计与应用[J]. 地球科学与环境学报, 2005, 27(1): 30 ~ 33.

[11] Leung H, Dubash N, Xie N. Detecting of Small Objects in Clutter using a GA RBF Neural[J]. IEEE Trans AES, 2002, 38(1): 98 ~ 117.

[12] 张立明. 人工神经网络的模型及其应用[M]. 上海: 复旦大学出版社, 1993.

[13] Potapov A, Ali M K. Chaotic Neural Control[J]. Phys Rev E, 2001, 63(1): 1 ~ 15.

[14] 温 书, 陈 平, 达庆利. 我国洪涝灾害受灾及成灾面积的预测分析[J]. 生物数学学报, 2000, 15(4): 452 ~ 456.

[15] Liu Chin teng. Controlling chaos by GA-based Reinforcement Learning Neural Network[J]. IEEE Trans on Neural Networks, 1999, 10(4): 846 ~ 859.