

径流序列的相空间重构神经网络预测模型

陈南祥^{1,2}, 黄 强¹, 曹连海², 徐建新³

(1. 西安理工大学水利水电学院, 陕西 西安 710048; 2. 华北水利水电学院岩土工程系, 河南 郑州 450008;
3. 华北水利水电学院水利工程系, 河南 郑州 450008)

摘要 在水文水资源领域中引入混沌理论, 将相空间重构理论与神经网络理论相结合, 提出了径流时间序列预测模型. 通过相空间重构, 把一维径流时间序列拓展为多维序列, 而多维序列可挖掘更为丰富的信息, 有利于神经网络的训练. 研究表明, 利用神经网络建模可以较好地解决非线性问题, 使预测更符合实际. 以汉江石泉水库逐月平均入库径流序列为例, 建立了径流时间序列相空间重构与神经网络耦合预测模型, 计算结果表明, 模型有较高的预测精度.

关键词 径流 相空间重构 神经网络 预测模型

中图分类号 P338 **文献标识码** A **文章编号** 1000-1980(2005)05-0490-04

混沌现象的发现开创了对时间序列分析的一个新典型: 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^[1]. 但在实际应用中, 由于受研究对象数据太少和噪声等因素影响, 预测模型精度令人无法满意. 进入 20 世纪 90 年代后, 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^[2], 而在水文水资源领域中引入混沌理论, 将混沌理论与神经网络理论有机结合, 必将大大丰富水文水资源学的研究内容. 本文基于相空间重构理论与神经网络理论, 提出了径流时间序列相空间重构与神经网络耦合预测模型, 并用该模型对汉江石泉水库逐月平均入库径流量进行了预测.

1 混沌时间序列的相空间重构

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. 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.

为了从实际的单因子变量时间序列中估计出系统的信息, Takens 在 1981 年提出了用时间序列重构吸引子的相空间图像^[3].

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,

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

通过消元法, 使其变换为一个 n 阶非线性微分方程:

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

变换后, 新轨迹为

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

式(3)描述了同样的动力学系统, 它由 $x(t)$ 加上具 $(n-1)$ 阶导数 $x^{(1)}(t), \dots, x^{(n-1)}(t)$ 所构成的相空间重组, 代替这种连续变量 $x(t)$ 和它的导数, 并可考虑不连续的时间序列和它的 $(n-1)$ 时滞位移 $X(t) = (x(t),$

$x(t + \tau), \cdots, x(t + (n - 1)\tau)$. 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 $\{x(t_i), i = 1, 2, \cdots, n\}$, 延滞时间为 $\tau = k\Delta t, k = 1, 2, \cdots$, 则可将该时间序列延拓成 m 维相空间:

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

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:

$$m = n - (m - 1)k \tag{5}$$

m 维相空间中的一个相点表示系统在某个瞬时后的状态,而相点的连线构成了点在相空间中的轨迹,这条轨迹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,有足够的信息把时间序列的动态特性展现在多维相空间上考察.

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,并具有分布式、并行性和高度鲁棒性等特点. 目前在系统识别、预测预报中常用的是 BP 网络模型,以 3 层 BP 网络为主. 3 层 BP 网络的主要算法过程为:采用 3 层 BP 网络建模,其结构如图 1 所示,输入层为 h 个成分,即输入层有 h 个结点 $x_1, x_2, \cdots, x_h$, 输出层为 1 个结点 y , 其隶属函数为




图 1 三层前馈网络

Fig.1 Three-layer BP network

$$f(u) = \frac{1}{1 + e^{-u}} \tag{6}$$

隐含层数由参考文献[4]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:

$$y_0 = f\left(\sum_{j=1}^p W_{j0} x'_j - \gamma\right) \tag{7}$$

$$x'_j = f\left(\sum_{i=1}^h V_{ij} x_i - \theta_j\right) \tag{8}$$

定义其输出误差为

$$E_{\text{总}} = \frac{1}{2} \sum_{k=1}^p (\hat{y}_0^k - y_0^k)^2 \tag{9}$$

式中: p ——样本数; $\hat{y}_0^k, y_0^k$ ——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

通常河川径流量是一个典型的时间序列 $\{x(t_i), i = 1, 2, \cdots, n\}$, 其观察时间间隔为 Δt . 对于这样的时间序列,可按上述理论预测 $\{x(t_n + l), l = 1, 2, \cdots\}$. 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 $\{x(t_i)\}$ 做漂移,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 Grassberger 等[5]提出的 G-P 算法计算 m ,也可用 Kim 等[6]提出的 C-C 算法计算 τ 和 m . m 计算要求数据资料序列较长,在实际应用中,对较短资料序列,可根据相空间重构理论的基本思想,在确定预测模型的结构时,直接分别取 2, 3, 4, $\cdots$ 维来重构相空间,以最好的模拟预测结果筛选嵌入维的取值.

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,输出层节点数为 1. 网络的输入、输出为

学习样本输入

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

期望输出

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

3.3 学习

在确定网络的输入、输出结构后,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.

3.4 预测

网络训练成功后,把最后 $m-1$ 维相空间加入网络输入中,可实现对 $x(t_n+l)$ 的预测,即建成了相空间重构与神经网络的耦合预测模型.

4 应用实例

以汉江石泉水库 1954~1992 年逐月平均入库径流量序列为例.取 1954~1990 年实测数据作为相空间重构和神经网络学习的基本数据,将 1991~1992 年的实测数据作为预报检验.

为了尽可能满足 BP 网络 Trainscg 函数条件,对一维径流量数据 $Q(t_i)$ 序列进行归一化处理,即

$$x_i = \frac{Q(t_i) - Q_{\min}}{Q_{\max} - Q_{\min}}$$

(10)

式中, $Q_{\max}$ 和 $Q_{\min}$ 分别为样本序列中的最大值和最小值.

用自相关法求得延滞时间 $\tau=2$. 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 $m=11$, 然后根据笔者研究河川径流混沌特征的经验^[7], 在确定预测模型的基本结构时,取 $m=9, 10, 11, 12, 13$ 分别组合重构相空间,以最好的预测结果筛选饱和嵌入维数 m . 经计算模拟训练和预测结果检验,当 $\tau=2$ 和 $m=12$ 时误差最小.

采用的 3 层网络的输入层为 11 个节点,隐含层为 20 个节点,输出层为 1 个节点,经 13 646 次迭代,收敛误差达到标准,学习结束. 网络学习的拟合值与实测值的比较见图 2(因数据太多,这里仅给出 4 年的数据).

由图 2 可见,所建相空间重构与神经网络的耦合预测模型的拟合精度较高. 根据训练好的网络参数,预测 1991~1992 年的平均月径流量,并与实测数据比较,结果见表 1(表 1 同时给出了 $m=11, m=13$ 的预测结果). 结果表明,当 $\tau=2$ 和 $m=12$ 时所建预测模型的预测效果较好,大部分预测数据的相对误差小于 5%,仅个别预测数据的相对误差达 10.71%.

5 结 论

研究结果表明:(a)一维时间序列中包含着吸引子的结构,通过相空间重构,将一维时间序列拓展为多维序列,而多维序列包含着各态的信息,因而使预测更符合实际.(b)通过对汉江石泉水库逐月平均入库径流量的预测,结果表明,基于相空间重构理论与神经网络理论提出的径流量时间序列相空间重构与神经网络耦合预测模型有很高的预测精度.(c)本次研究的月平均径流过程,时间尺度比较大,常常掩盖了实际径流过程的复杂性,因此该模型所适用的时间尺度需要深入研究.(d)本文的研究是初步的,还需研究相空间重构理论与其他相关理论、技术相结合的方法,如遗传算法、小波变换算法等.




图 2 3 层 BP 网络期望输出和实际输出

Fig.2 Expect output and real output of the three-layer BP network

表 1 1991~1992 年平均月径流量实测值和预测值对比

Table 1 Comparison of observed and predicted data of monthly mean runoff for 1991—1992																	
时 间		实测值/ ($\text{m}^3 \cdot \text{s}^{-1}$)	$m = 11$		$m = 12$		$m = 13$		时 间		实测值/ ($\text{m}^3 \cdot \text{s}^{-1}$)	$m = 11$		$m = 12$		$m = 13$	
			预测	相对	预测	相对	预测	相对				预测	相对	预测	相对	预测	相对
			值/($\text{m}^3 \cdot \text{s}^{-1}$)	误差 / $\%$	值/($\text{m}^3 \cdot \text{s}^{-1}$)	误差 / $\%$	值/($\text{m}^3 \cdot \text{s}^{-1}$)	误差 / $\%$				值/($\text{m}^3 \cdot \text{s}^{-1}$)	误差 / $\%$	值/($\text{m}^3 \cdot \text{s}^{-1}$)	误差 / $\%$	值/($\text{m}^3 \cdot \text{s}^{-1}$)	误差 / $\%$
1991 年	1月	78	67.70	13.2	78.42	0.53	87.05	11.6	1月	46	55.80	21.3	45.97	0.06	54.60	18.7	
	2月	60	64.68	7.8	60.47	0.78	52.62	12.3	2月	39	45.51	16.7	38.15	2.17	45.08	15.6	
	3月	116	120.71	4.1	115.88	0.10	88.04	24.1	3月	89	102.88	15.6	89.24	0.27	104.84	17.8	
	4月	136	157.22	15.6	136.01	0.01	143.74	5.7	4月	131	123.01	6.1	130.74	0.26	118.56	9.5	
	5月	150	133.35	11.1	149.97	0.02	174.30	16.2	5月	113	130.82	15.8	118.39	4.77	132.31	17.1	
	6月	559	493.62	11.7	578.47	3.48	607.32	8.6	1992 年	6月	233	261.71	12.3	232.51	0.21	264.96	13.7
	7月	316	367.51	16.3	315.80	0.06	362.45	14.7	7月	600	483.60	19.4	600.20	0.03	500.40	16.6	
	8月	302	340.35	12.7	302.09	0.03	328.41	8.7	8月	372	356.38	4.2	370.31	0.45	317.32	14.7	
	9月	154	180.95	17.5	154.00	0.00	124.89	18.9	9月	795	697.33	12.2	759.37	4.48	658.45	17.2	
	10月	103	97.87	5.0	101.80	1.16	87.14	15.4	10月	417	319.84	23.3	416.71	0.07	327.76	21.4	
	11月	75	62.40	16.8	74.22	1.04	80.03	6.7	11月	139	112.73	18.9	138.94	0.05	155.12	11.6	
	12月	55	61.93	12.6	54.08	1.66	45.32	17.6	12月	87	95.49	9.8	77.68	10.71	71.92	17.3	

参考文献：

[1] 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.
[2] 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,2002,35(2):191—195.
[3] TAKENS F. Detecting strange attractors in turbulence [A]. In :Lecture Notes in Mathematics Vol 898 [C]. Berlin :Springer-Verlag, 1981.366—381.
[4] 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,1993.183—197.
[5] GRASSBERGER P,PROCACCIA I. Measuring the strangeness of strange attractors[J]. Physica D,1983,9:189—208.
[6] KIM H S,EYKHOLT R,SALAS J D. Nonlinear dynamics, delay times, and embedding windows[J]. Physica D,1999,127:48—60.
[7] 陈南祥,张金炳,张民安.一维水文要素时间序列的可预报时间尺度研究[J].灌溉排水,2003,21(1):41—44.

Neural network forecasting model for phase space reconstruction of runoff series

CHEN Nan-xiang^{1,2}, HUANG Qiang¹, CAO Lian-hai², XU Jian-xin³
(1. Institute of Water Resources and Hydro-Electric Engineering,
Xi 'an University of Technology, Xi 'an 710048, China ;
2. Department of Geotechnical Engineering, North China Institute of
Water Conservancy and Hydroelectric Power, Zhengzhou 450008, China ;
3. Department of Water Conservancy Engineering, North China Institute of Water Conservancy and
Hydroelectric Power, Zhengzhou 450008, China)

Abstract The chaos theory was introduced into hydrology and water resources field, and a runoff time-series forecasting model was proposed by combination of the theories of phase space reconstruction with neural network. One-dimensional runoff time-series was developed to multi-dimensional runoff time-series by reconstruction of phase space. As the multi-dimensional runoff time-series involves the ergodic information, it can provide abundant information, which is favorable for ANN training. The modeling with ANN can effectively solve the nonlinear problems, and make the result of forecasting in good accordance with the reality. As a case study of the monthly average runoff into the Shiquan Reservoir of the Hanjiang River, a phase space reconstruction and neural network combined runoff time-series forecasting model was established, and the result shows that the model is of high precision of forecasting.

Key words runoff ; phase space reconstruction ; neural network ; forecasting model