

混沌-支持向量机模型及其在地下水 动态预报中的应用

胡国杰,魏晓妹,蔡明科,许义和,杨 婷,黄朝轩

(西北农林科技大学 水利与建筑工程学院,陕西 杨凌 712100)

[摘要] 【目的】建立混沌时间序列的支持向量机预报模型,为地下水动态提供新的可行的预报方法。【方法】以重构相空间理论为基础,探讨了混沌时间序列的支持向量机预报模型的建模思路、特点及参数的选取,借助 G-P 算法、C-C 方法和 Wolf 方法,计算了武威盆地 3 眼观测井地下水水位埋深序列的 Lyapunov 指数,并利用自适应方法对支持向量机的参数进行了选择;基于高斯径向基核函数,建立了混沌时间序列的支持向量机预报模型。【结果】武威盆地地下水水位埋深序列的 Lyapunov 指数均大于 0,表明该时间序列具有混沌特性;所建立的混沌-支持向量机模型可以用于武威盆地地下水水位埋深预报,经过检验,武威盆地 3 眼观测井的预报精度分别为 0.98,0.92 和 0.86,表明建立模型预报精度较为理想。【结论】建立了混沌-支持向量机模型,该模型可用于地下水水位埋深动态预报。

[关键词] 地下水动态;混沌;时间序列;相空间重构;Lyapunov 指数;支持向量机

[中图分类号] P641.2

[文献标识码] A

[文章编号] 1671-9387(2011)02-0229-06

Prediction model of chaotic based on support vector machine and its application to underground Water

HU Guo-jie, WEI Xiao-mei, CAI Ming-ke, XU Yi-he,
YANY Ting, HUANG Chao-xuan

(College of Water Resources and Architecture Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: 【Objective】 The objective was to establish a chaotic based prediction model on support vector machine for the groundwater. 【Method】 Chaos theory and support vector machine have great capability of dealing with nonlinear matter. Based on the phase space reconstitution theory, the prediction model of chaos time series was built by using the support vector machine in this paper. The method, the characteristic, and the selecting of the key parameters in the modeling was discussed. With G-P arithmetic, C-C arithmetic and Wolf method, Lyapunov from 3 observation well of underground level depth in Wuwei basin was calculated. At the same time the method of adaptive support vector machine parameters was selected. A model was established about chaotic time series based on support vector machine with Gaussian radial basis function. 【Result】 Lyapunov indexes were greater than zero in Wuwei basin, indicating that the time series is chaotic. The model can be used on the Wuwei basin to predict the depth of groundwater level. After testing, the accuracy of three prediction results were 0.98, 0.92 and 0.86, indicating that this mode has high prediction accuracy. 【Conclusion】 The prediction model of chaotic based on support vector machine can be used in forecasting the movement of underground water depth.

* [收稿日期] 2010-07-22

[基金项目] 国家自然科学基金项目(50879071);水利部公益性行业科研基金项目(200801104)

[作者简介] 胡国杰(1987-),男,甘肃武威人,在读硕士,主要从事水文水资源系统研究。E-mail:huguojie123@126.com

[通信作者] 魏晓妹(1957-),女,甘肃甘谷人,教授,博士生导师,主要从事农业水资源转化理论与调控技术研究。

E-mail:weixiaomei57@tom.com

Key words: groundwater dynamic; chaos; time series; phase space reconstruction; Lyapunov exponent; support vector machine

地下水文系统是一个受水文地质条件控制,并受降雨、气候和人类工程活动等多种因素影响而发展演化的非线性耗散动力结构,且具有明显的混沌特征^[1]。对地下水文系统,一般通过数值模拟求解渗流模型来研究地下水动态的变化规律,但这种方法要求较高^[2],对一些资料缺乏、时空变异较大的研究区预测结果往往较差;随机模型虽然成本小、周期短,但地下水动态时间序列常常是非平稳或非线性的,目前常用的随机模型大多是基于平稳或线性序列建模,因而其预测效果也不甚理想。

近年来,混沌理论、分形理论以及非线性预测方法的发展为地下水动态研究提供了新的思路。由于混沌系统内在的有序性和规律性,利用重构相空间的方法,即可对地下水动态进行分析、预测。混沌时间序列预测是建立在 Takens^[3]提出的嵌入定理和相空间重构理论基础上的,其基本思想是系统中任一分量的演化由与之相互作用的其他分量决定,这些相关分量的信息就隐含在任一分量的发展过程中。由此可以从一批仅与时间相关的混沌数据中提取和恢复系统原来的规律,该规律可表达为高维空间下的一种轨迹。而基于 Takens 的理论,人们已提出了许多预测混沌时间序列的方法,基于支持向量机的预测方法就是其中一种,并取得了较好的结果^[4]。

支持向量机是在统计学习理论上发展起来的一种新的分类和回归工具,它通过结构风险最小化原理来提高泛化能力,较好地解决了小样本、非线性、高维数、局部极小点等实际问题,已经在许多领域得到了应用,如 Liong 等^[5]已将其成功应用于水文预报,但尚未见其与混沌的耦合模型在地下水动态预报中的研究报道。

本研究尝试将支持向量机回归原理应用于混沌时间序列,对甘肃石羊河流域武威盆地地下水埋深进行预报,以期对地下水动态预测预报提供一种新的思路。

1 混沌时间序列相空间重构

对于序列长度为 n 的时间序列 x_1, x_2, \dots, x_n , Packard 等^[6]提出了用时间延迟序列重构相空间的坐标延迟重构法,该方法的本质是通过一维时间序列 x_1, x_2, \dots, x_n 的不同时间延迟来构造 m 维相空

间矢量,即

$$Y(i) = \{x(i), x(i+\tau), \dots, x(i+(m-1)\tau)\}, \\ i=1, 2, \dots, M. \quad (1)$$

式中: τ 是延迟时间; M 是重构相空间中相点的个数, $M=n-(m-1)\tau$ 。

Takens^[3]提出嵌入式定理,即对于时间序列 x_1, x_2, \dots, x_n ,总可在拓扑不变的意义上找到一个 m 维的嵌入相空间,只要嵌入维数 $m \geq 2d+1$, d 为关联维数, Takens 定理保证可以从一维混沌时间序列中重构一个与原动力系统在拓扑意义下等价的相空间。坐标延迟相空间重构技术有 2 个关键参数,即嵌入维数 m 和延迟时间 τ ,其中嵌入维数 m 应用 G-P 算法确定^[7],延迟时间 τ 采用 C-C 方法确定^[8]。

C-C 方法的基本原理是:定义嵌入时间序列的关联积分为:

$$C(m, N, r, t) = \frac{2}{M(M-1)} \cdot \\ \sum_{1 \leq i < j \leq M} H(r - \|Y_i - Y_j\|), r > 0. \quad (2)$$

式中: r 为给定的距离, Y_i, Y_j 为相空间中的点, H 为 heaviside 函数。

对于一般的时间序列,将其分成 t 个不相交的子序列,然后定义每一个子序列的 $S(m, N, r, t)$ 为:

$$S(m, N, r, t) = \frac{1}{t} \cdot$$

$$\sum_{s=1}^t [C_s(m, N/t, r, t) - C_s^m(1, N/t, r, t)]. \quad (3)$$

则当 $N \rightarrow \infty$ 时,选择对应值最大和最小的 2 个半径 r ,定义差量为:

$$\Delta S(m, t) = \max\{S(m, N, r, t)\} - \\ \min\{S(m, N, r, t)\}. \quad (4)$$

根据 BDS 统计结论计算,有:

$$S(t) = \frac{1}{16} \sum_{m=2}^5 \sum_{j=1}^4 S(m, r_j, t), \quad (5)$$

$$\Delta S(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, t), \quad (6)$$

$$S_{cor}(t) = \Delta S(t) + |S(t)|. \quad (7)$$

其中,当 $\Delta S(t)$ 达到第 1 个极小值时对应的时间即为延迟时间 τ 。

2 支持向量机的回归模型

2.1 支持向量机的原理

非线性支持向量机回归的基本思想是通过一个

非线性映射将数据映射到高维特征空间,并在这个空间进行线性回归。支持向量回归模型是从线性可分情况下的最优分类面发展而来的。在分类模型的基础上引进一个修正距离作为损失函数,它可以确保对偶变量的稀疏性,同时能够保证全局最小解的存在,提高泛化能力。该模型建立的具体步骤如下:

- 1) 给定训练样本集,通过训练学习寻求支持向量机 $f(x)^{[9]}$ 。
- 2) 选择适当的正数 ϵ 和 C ,选择核函数 $K(x_i, x_j)$ 。
- 3) 构造并求解最优化问题,有:

$$\min\left(\frac{1}{2}(\omega^T \cdot \omega) + C \sum_{i=1}^n (\epsilon_i + \epsilon_i^*)\right),$$

$$L = \frac{1}{2}(\omega \cdot \omega) + C \sum_{i=1}^n (\epsilon_i + \epsilon_i^*) - \sum_{i=1}^n a_i [(\omega \cdot x_i) - y_i + \epsilon_i + \epsilon] - \sum_{i=1}^n a_i^* [y_i - (\omega \cdot x_i) + \epsilon_i^* + \epsilon] - \sum_{i=1}^n (\epsilon_i \gamma_i + \epsilon_i^* \gamma_i^*) \quad (9)$$

式中: $a_i, a_i^*, \gamma_i, \gamma_i^*$ 为 Lagrange 乘子,均大于零, $i = 1, 2, \dots, n$ 。

对式(9)求偏微分,并令各式等于零,得:

$$\begin{cases} \frac{\partial L}{\partial \omega} = \omega - \sum_{i=1}^n (a_i - a_i^*) x_i = 0, \\ \frac{\partial L}{\partial \epsilon_i} = \gamma_i - C + a_i = 0, \\ \frac{\partial L}{\partial \epsilon_i^*} = \gamma_i^* - C + a_i^* = 0. \end{cases} \quad (10)$$

$$\max: Q(a, a^*) = -\frac{1}{2} \sum_{i,j=1}^n (a_i - a_i^*) (a_j - a_j^*) K(x_i \cdot x_j) + \sum_{i=1}^n (a_i - a_i^*) y_i -$$

$$\sum_{i=1}^n (a_i + a_i^*) \epsilon, s. t. \begin{cases} \sum_{i=1}^n (a_i - a_i^*) = 0, \\ 0 \leq a_i \leq C, 0 \leq a_i^* \leq C. \end{cases} \quad (11)$$

式中: a_i 和 a_i^* 为 Lagrange 乘子,解此二次优化问题,求得 a_i 和 a_i^* ,则可计算出 ω ,再由 $y_i(\omega \cdot x_i + b) = 1, a_i \in (0, C)$ 对应的样本计算 b 值。令 $\beta_i = a_i - a_i^*$,当 β_i 非零时,其对应的训练样本就是支持向量,又由于 $a_i \geq 0, a_i^* \geq 0$,所以支持向量也有 1 个 Lagrange 乘子 (a_i 或 a_i^*) 大于零的训练样本。

- 4) 构造决策函数,有:

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) K(x, x_i) + b. \quad (12)$$

式(12)即为所求的回归函数,其中 b 为偏差。

2.2 核函数及参数的选择

核函数的选择须满足 Mercer 条件。最常用的核函数有:

- 1) 多项式核, $K(x, y) = ((x \cdot y) + t)^p, t \geq 0, p \in N$;
- 2) 高斯径向基核, $K(x, y) = e^{-\frac{1}{2\sigma^2} \|x-y\|^2}, \sigma > 0$;
- 3) 双曲核, $K(x, y) = \tanh(a(x \cdot y) + t), a, t$ 是

$$s. t. \begin{cases} y_i - f(x_i) \leq \epsilon_i + \epsilon, \\ f(x_i) - y_i \leq \epsilon_i^* + \epsilon, \\ \epsilon_j, \epsilon_i^* \geq 0, i = 1, \dots, n. \end{cases} \quad (8)$$

式中: ω 为权值向量; C 为预先给定的一个常数, $C > 0$,表示对超出误差 ϵ 的样本的惩罚程度; ϵ_i 和 ϵ_i^* 分别为考虑到允许拟合误差引入的松弛因子。式(8)中的第 1 项使函数更为平坦,以提高泛化能力;第 2 项则为减少误差, ϵ 用于控制回归逼近误差管道的大小,以控制支持向量的个数和泛化能力。对这一凸二次优化问题,引入 Lagrange 函数,即:

将式(10)代入式(9),即得到优化问题的对偶形式,通过函数 $K(x_i, y_i) = \Phi(x_i) \cdot \Phi(x_j)$,将变换空间中的内积转化为原空间中某个函数的计算,从而间接求解输入空间向高维特征空间的映射。支持向量机方法的优点在于勿需知道映射的具体形式,而只需定义高维空间中的内积运算 $K(x_i, x_j)$ 即可。得到优化问题的对偶形式如下:

常数。

对于具体问题,不同核函数的预测性能不尽相同。针对此问题,不少研究者对常用的核函数进行了比选,认为高斯径向基核的预测能力优于双曲核和多项式核^[10-11]。因此,以后的优化均建立在高斯径向基核的基础上。本研究运用自适应参数优化的方法来选取支持向量机的参数^[12]。

3 混沌-支持向量机预报模型的建立^[13]

在重构相空间之后,就可以对支持向量机进行训练,得到时刻支持向量机的第一步预报模型为:

$$\hat{x}_{t+1} = \sum_{i=1}^{N-(m-1)\tau} (a_i - a_i^*) K(x_i, x_t) + b. \quad (13)$$

式中: m 为嵌入维数, τ 为延迟时间, $x_{t_i} = (x_t, x_{t+\tau}, x_{t+2\tau}, \dots, x_{t+(m-1)\tau})$ 。令 $x_t = x(t)$,对于相空间重构的第 $t+1$ 点,有:

$$x_{i+1} = (\hat{x}_{i+1}, x(t+\tau), x(t+2\tau), \dots, x(t+(m-2)\tau)). \quad (14)$$

再由式(13)得到对 $t+2$ 点的预报为:

$$\hat{x}_{t+2} = \sum_{i=1}^{N-(m-1)\tau} (\alpha_i - \alpha_i^*) K(x_i, x_{i+1}) + b. \quad (15)$$

于是得到第 p 步的支持向量机混沌序列预报模型为:

$$\hat{x}_{t+p} = \sum_{i=1}^{N-(m-1)\tau} (\alpha_i - \alpha_i^*) K(x_i, x_{i+p-1}) + b. \quad (16)$$

式中: p 为预报步长,

$$x_{i+p-1} = (\hat{x}_{i+p-1}, \dots, \hat{x}_{i+1}, \dots, x(t+(m-p+2)\tau)).$$

4 混沌-支持向量机模型在地下水位埋深预报中的应用

4.1 基本资料

武威盆地位于甘肃省石羊河流域中游祁连山北麓,腾格里沙漠西侧,是一个历史悠久的农业灌溉盆地。该地区地下水主要接受大气降水补给和地表水入渗补给,消耗为人工开采,武威盆地地下水位变化既反映着流域地表水与地下水的转化关系,同时又影响着盆地水资源利用格局和生态环境的演变趋势,因此研究该地区地下水位埋深的变化有重要意义。本研究选择武威盆地 534、539 和 545 号观测井为供试对象,以 1983—2002 年的月平均地下水位埋深时间序列 ($\{x(t), t=1, 2, \dots, 252\}$) 为依据,建立地下水位埋深的预报模型,并以 2003 年的月平均地下水位埋深序列对模型进行检验。

4.2 嵌入维数 m 和延迟时间 τ 的确定

以 534 号观测井为例,说明嵌入维数 m 的确定方法。取嵌入维数 $m=2, 3, \dots, 12$ 。对于每 1 个 m ,

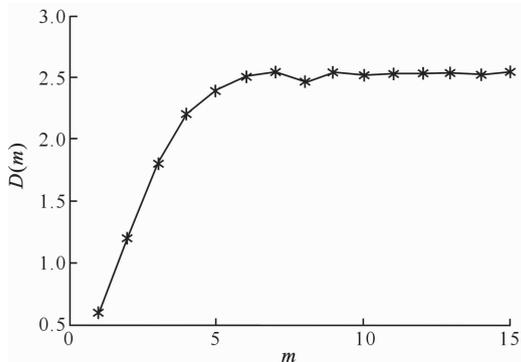


图 2 534 号观测井地下水位埋深 $D(m) - m$ 曲线

Fig. 2 $D(m) - m$ curve of underground level depth of the 534th observation well

从图 3 可以看出,534 号观测井地下水位埋深序列的延迟时间 $\tau=11$ 。同理,可得到 539 和 545 号观测井地下水位埋深序列的延迟时间 τ 分别为 8 和

按照 G-P 算法,计算得到一系列 $\ln r$ 与 $\ln C(r)$ 值,并作其关系图(图 1)。图 1 中直线段的斜率即为关联维数。

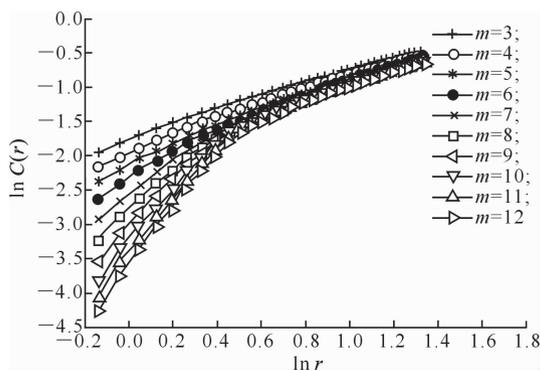


图 1 534 号观测井地下水位埋深 $\ln C(r) - \ln r$ 曲线
Fig. 1 $\ln C(r) - \ln r$ curve of underground level depth of the 534th observation well

图 2 为关联维数 $D(m)$ 随嵌入维数 m 增加而变化的曲线。从图 2 可以看出,地下水位埋深序列在 $m \geq 8$ 时,关联维数 $D(m)$ 不再随嵌入维数 m 的增加而增大,表明所求的嵌入维数 m 即是饱和嵌入维数。因此,可选择此时对应的维数 $m=8$ 为 534 号观测井地下水位埋深序列的最佳相空间嵌入维数。同理,可得到 539 和 545 号观测井地下水位埋深序列的嵌入维数 m 均为 7。

同样以 534 号观测井为例,说明延迟时间 τ 的计算方法。根据 C-C 法作出变量 $\Delta S(m, t), \Delta S(t), S(t), S_{cov}(t)$ 关于 t 的变化趋势,为了观察方便将 4 个变量放在同一幅图中,其结果如图 3 所示。由 C-C 法原理可知,当 $\Delta S(t)$ 达到第 1 个极小值时,对应时间即为延迟时间 τ 。

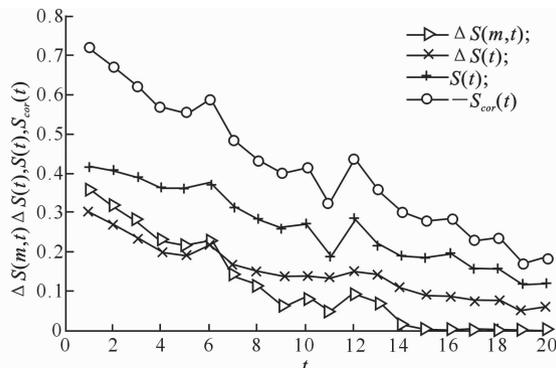


图 3 534 号观测井的 C-C 法曲线

Fig. 3 Curve of C-C method of the 534th observation well

12。

4.3 时间序列混沌特性的识别

混沌系统运动的基本特点是对初值条件极为敏

感,初始状态的微小不确定性将会迅速地按指数速度扩大,这种轨迹收敛或发散的速度,称为 Lyapunov 指数 λ 。对一维系统而言,当 $\lambda < 0$ 时,系统具有稳定的不动点;当 $\lambda = 0$ 时,系统出现周期现象;当 $\lambda > 0$ 时,系统出现混沌性质。因此,常用 λ 来判定时间序列是否具有混沌性质。确定 λ 的方法较多,本研究运用 Wolf 法计算得到武威盆地 534、539 和 545 号观测井地下水位埋深序列的最大 Lyapunov 指数 λ 分别为 0.021,0.126,0.155,表明该序列具有混沌特性,因此上述混沌时间序列的支持向量机预报模型可用于地下水位埋深序列的预报。

4.4 地下水位埋深预报模型的建立

根据上述计算结果,对 534、539 和 545 号观测井地下水位埋深序列分别进行相空间重构,由重构相空间嵌入相点构成训练样本集,得到用于向量学习的样本形式为:

$$\mathbf{X} = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(m-1)\tau} \\ \vdots & \vdots & \cdots & \vdots \\ x_{n-(m-1)\tau} & x_{n-(m-1)\tau+1} & \cdots & x_{n-1} \end{bmatrix},$$

$$\mathbf{Y} = \begin{bmatrix} x_{2+(m-1)\tau} \\ x_{3+(m-1)\tau} \\ \vdots \\ x_n \end{bmatrix}. \quad (17)$$

本研究选取 1983—2002 年重构后的地下水水位埋深数据作为训练集,用于样本内的数据拟合和

模型参数的确定。剩余的数据作为模型的测试集,用于模型预测能力的测试。

根据式(17)构造的学习样本,对支持向量机回归函数进行学习,其中 ϵ 是控制函数拟合误差大小的参数,用以控制支持向量的个数和泛化能力,本研究选取 $\epsilon = 0.001$ 。

C 和 σ 共同影响支持向量机的训练误差以及预报精度^[14]。经过自适应优化,本研究得到 534、539 和 545 号观测井地下水位埋深序列训练集的 C 、 σ 分别为(56,0.75),(19.52,2.83)和(102.4,23.41),从而得到的预报结果如表 1 所示,将该结果与 534、539、545 号观测井的实测结果进行比较。

4.5 模型的检验

预报精度可以反映预测值与实测值在其均值附近偏离程度之间的相关性,故常选择预报精度 E_{PA} 来评价模型预报效果^[15]。 E_{PA} 取值在 -1 与 +1 之间,预测无误差时 E_{PA} 值为 1。 E_{PA} 计算公式如下:

$$E_{PA} = \frac{\sum_{t=1}^n \{ [\hat{y}(t) - \hat{y}_m][y(t) - y_m] \}}{(n-1)\sigma_y \sigma_{\hat{y}}}. \quad (18)$$

式中: $y(t)$ 、 $\hat{y}(t)$ 分别为期望输出和实际输出, y_m 、 \hat{y}_m 分别表示模型期望值与预测值序列的平均期望, σ_y 、 $\sigma_{\hat{y}}$ 分别表示期望值与预测值序列的方差。利用表 1 的结果,根据式(18)计算可知,534、539 和 545 号观测井的 E_{PA} 分别为 0.98,0.92 和 0.86,均接近于 1,说明建立的模型预报精度较为理想。

表 1 武威盆地 3 个观测井 2003 年月平均地下水位埋深预报结果与实测结果的比较

Table 1 Predicted Monthly Underground Level Depth comparison of measured results at basin 3 observation wells on Wuwei in 2003

月份 Month	534号观测井 534th observation well			539号观测井 539th observation well			545号观测井 545th observation well		
	实测值 Measured value	预测值 Predicted value	相对误差/% Relative error	实测值 Measured value	预测值 Predicted value	相对误差/% Relative error	实测值 Measured value	预测值 Predicted value	相对误差/% Relative error
1	12.25	12.02	1.9	10.65	10.58	0.7	23.70	23.51	0.8
2	11.53	11.75	1.9	10.31	10.44	1.3	23.14	23.42	1.2
3	10.98	10.92	0.5	10.04	10.26	2.2	23.57	23.28	1.2
4	11.80	11.65	1.3	9.71	10.04	3.4	23.15	23.08	0.3
5	11.84	11.72	1.0	9.82	10.12	3.1	22.80	22.99	0.8
6	11.98	11.93	0.4	10.50	10.34	1.5	24.48	23.15	5.4
7	12.36	12.02	2.8	11.11	10.57	4.9	24.83	23.98	3.4
8	12.49	12.21	2.2	12.10	11.21	7.4	25.22	24.86	1.4
9	12.54	12.34	1.6	11.30	11.32	0.2	25.01	24.74	1.1
10	12.37	12.39	0.2	10.76	11.09	3.1	24.39	24.52	0.5
11	12.10	12.35	2.1	10.14	10.62	4.7	24.18	24.44	1.1
12	12.17	12.33	1.3	10.28	10.44	1.6	24.08	24.35	1.1

5 结论与讨论

1)本研究利用相空间重构技术和支持向量机回

归理论,建立了地下水位埋深的预报模型。利用相空间重构技术可有效挖掘单变量序列中的信息,支持向量机回归模型具有很好的泛化能力,并且克服

了局部寻优的缺点,因此该预报方法可以提高地下水位埋深的预报精度,为地下水位埋深的动态模拟提供了一种新的思路。

2)本研究结果表明,地下水位埋深序列存在较为明显的混沌成分。因此,对其预报不能局限于原有的趋势性和周期性方面,应该考虑将混沌理论与其他非线性理论进行耦合,以进一步探求地下水的动态变化规律。

3)由于混沌现象对初值的敏感性^[16],使本研究建立的混沌-支持向量机模型的预报能力受到一定限制,因而其更适用于短、中期预报,而对于长期预报并不理想。另外,该模型中关键参数的选择还没有明确的原则,因此进一步研究寻求更高效的定参方案是非常必要的。

[参考文献]

- [1] 宋宇,陈家军,孙雄. 地下水位时间序列中的混沌特征[J]. 水文地质工程地质, 2004(1):14-16.
Song Y, Chen J J, Sun X. Chaotic analysis of groundwater time series [J]. Hydrogeology and Engineering Geology, 2004(1): 14-16. (in Chinese)
- [2] 陈南祥,张海丰,李松海. 基于混沌时间序列的地下水位多步预测模型[J]. 地球科学与环境学报, 2007, 3(1): 67-68.
Chen N X, Zhang H F, Li S H. Multi-steps prediction model of underground water table based on chaotic time series [J]. Journal of Earth Sciences and Environment, 2007, 3(1): 67-68. (in Chinese)
- [3] Takens. Detecting strange attractors in turbulence [J]. Lecture Notes in Mathematics, 1981, 896: 366-370.
- [4] 于国荣,夏自强. 支持向量机的混沌序列预测模型及在径流中应用[J]. 水利学报, 2007, 10(增刊): 455-458.
Yu G R, Xia Z Q. The prediction model of chaotic series based on support vector machine and its application to runoff [J]. Journal of Hydraulic Engineering, 2007, 10(Supplement): 455-458. (in Chinese)
- [5] Liang S Y, Sivapragasm C. Flood stage forecasting with SVM [J]. Journal of the American Water Resources Association, 2002, 38(1): 173-186.
- [6] Packard N H. Geometry format time series [J]. Phy Rev lett, 1980, 459: 712-714.
- [7] 李目,何怡刚,周少武,等. 混沌时间序列的混合遗传神经网络预测方法[J]. 系统仿真学报, 2008, 11(21): 5825-5826.
Li M, He Y G, Zhou S W, et al. Hybrid genetic neural network method for predicting chaotic time series [J]. Journal of System Simulation, 2008, 11(21): 5825-5826. (in Chinese)
- [8] 马金虎,陆君安,陈士华. 混沌时间序列分析及其应用[M]. 武汉: 武汉大学出版社, 2002.
Ma J H, Lu J A, Chen S H. Chaotic time series analysis and its application [M]. Wuhan: Wuhan University Press, 2002. (in Chinese)
- [9] 邓乃扬,田英杰. 数据挖掘中的新方法-支持向量机[M]. 北京: 科学出版社, 2004.
Deng N Y, Tai Y J. A new method of datamining- support vector machine [M]. Beijing: Science Press, 2004. (in Chinese)
- [10] Hsu C W, Chang C C, Lin C J. A practical guide to support vector classification [R]. Taiwan: Department of Computer Science and Information Engineering, National Taiwan University, 2003.
- [11] 刘隽,周涛,周佩玲. GA 优化支持向量机用于混沌时间序列预测[J]. 中国科学技术大学学报, 2005, 4(2): 259-260.
Liu J, Zhou T, Zhou P L. Predicting chaotic time series using support vector machines optimized by genetic algorithm [J]. Journal of University of Science and Technology of China, 2005, 4(2): 259-260. (in Chinese)
- [12] 刘涵,刘丁,李琦. 基于支持向量机的混沌时间序列非线性预测[J]. 系统工程理论与实践, 2005, 9(9): 94-96.
Liu H, Liu D, Li Q. Chaotic time series nonlinear prediction based on support vector machines [J]. Systems Engineering-Theory and Practice, 2005, 9(9): 94-96. (in Chinese)
- [13] 于国荣,夏自强. 混沌时间序列支持向量机模型及其在径流预测中的应用[J]. 水科学进展, 2008, 1(1): 117-119.
Yu G R, Xia Z Q. Prediction model of chaotic time series based on support vector machine and its application to runoff [J]. Advances in Water Science, 2008, 1(1): 117-119. (in Chinese)
- [14] 罗福来. 人民币汇率的混沌特征分析及其基于支持向量机的预测[D]. 长沙: 湖南大学, 2008.
Luo F L. Analysis of RMB exchange rate chaotic characteristics and its forecast based on support vector machines [D]. Changsha: Hunan University, 2008. (in Chinese)
- [15] 韩敏. 混沌时间序列预测理论与方法[M]. 北京: 中国水利水电出版社, 2007.
Han M. Prediction theory and method of chaotic time series [M]. Beijing: China Water Power Press, 2007. (in Chinese)
- [16] 董玉乾. 混沌时间序列法在地下水位预测中的应用研究[D]. 西安: 长安大学, 2009.
Dong Y Q. Study and Apply in the Chaotic time series method in the ground water level Prediction [D]. Xi'an: Chang'an University, 2009. (in Chinese)