

基于相空间重构与 RBF 神经网络的干旱预测模型

侯姗姗, 王鹏新, 田 苗

(中国农业大学信息与电气工程学院, 北京 100083)

摘 要: 通过引入混沌和相空间重构理论, 将一维时间序列重构为多维序列, 并与径向基函数神经网络模型相结合, 建立了基于条件植被温度指数(VTCI)的干旱预测模型, 并对其进行了验证。结果表明: 干旱预测结果与实际干旱监测结果中的 VTCI 最大值、最小值、平均值及标准差十分接近, 所有样本点的预测值的相对误差的绝对值均低于 9%。经过 $\alpha=0.05$ 的显著性水平检验, 模型预测值与实测监测值的相关系数达 0.99, 表明模型预测精度较高, 预测结果在实际工作中具有一定的应用价值。

关键词: 预测; 条件植被温度指数; 相空间重构; 径向基函数神经网络

中图分类号: S423 **文献标识码:** A **文章编号:** 1000-7601(2011)01-0224-07

干旱的发生对于农业生产、粮食安全等极为不利。据了解, 我国每年遭受各种自然灾害的农田面积和粮食作物减产损失中, 旱灾要占一半以上^[1]。由于干旱成因的复杂性, 至今没有统一的预测方法, 不同的预测方法对预测结果有较大影响, 在应用中, 方法的可操作性及预测精度也各不相同, 因此如何客观、有效地预测干旱对作物生长、生态平衡等具有重要意义。

混沌(Chaos)目前普遍定义为广泛存在于连续或离散的确定性系统中的无规则运动, 主要表现为对系统初始值微小变化的敏感性。在离散系统中, 混沌常以时间序列的形式存在。刘庆军等研究了地下水位时间序列的混沌特性, 指出从混沌的角度, 可以更好地揭示水动力系统复杂的运动规律和演化过程^[2]。Jayawardena 等研究了降雨和径流时间序列的混沌特性, 并得出了用混沌的方法来模拟径流和降雨序列比传统的线性方法好的结论^[3]。

条件植被温度指数(VTCI)是王鹏新等基于归一化植被温度指数和土地表面温度特征空间呈三角形区域分布的条件下, 提出的一种干旱监测方法^[4]。并进一步讨论了植被指数和地表温度特征空间中冷、热边界的确定方法, 对 VTCI 进行了完善^[5]。VTCI 受研究区域气象条件、地表覆盖类型及水系分布等多因素的影响, 具有一定的混沌特征。

径向基函数神经网络具有通过学习逼近任意非线性映射的能力, 可以不受非线性模型的限制^[6], 而

干旱预测由于问题的复杂性, 属于带有强非线性特征的系统问题, 因此可以在 VTCI 时间序列的基础上进行基于径向基函数神经网络方法的干旱预测研究。本研究主要针对农业干旱预测问题, 选用长时间序列 VTCI 的干旱监测结果, 采用基于相空间重构与径向基函数神经网络模型的预测法对关中平原和渭北旱塬的干旱进行了预测, 并分析了所建立模型的预测精度。以期实现遥感数据和径向基函数神经网络方法相结合, 为干旱预测研究提供一种新的简单可行的方法, 并为关中平原和渭北旱塬农业生产, 防灾减灾提供服务。

1 材料与方法

1.1 研究区域和时间序列 VTCI 的生成

关中平原位于陕北黄土高原与秦岭北麓之间, 属大陆性季风半湿润气候, 年平均降水量在 500 ~ 700 mm, 是陕西省主要的粮食生产基地, 但同时该地区自然灾害较多, 主要有干旱、冰雹、滑坡、泥石流、水土流失等。本研究选用位于关中平原和渭北旱塬内的, 包括西安、渭南、蒲城、三原、永寿、扶风、凤翔、泾阳 8 个气象站附近样本点, 具体区域位于 106° ~ 110°E, 33° ~ 35°N 之间, 样本点的分布如图 1。条件植被指数的定义为:

$$VTCI = \frac{LST_{NDVI_{i,max}} - LST_{NDVI_i}}{LST_{NDVI_{i,max}} - LST_{NDVI_{i,min}}} \quad (1)$$

收稿日期: 2010-03-19

基金项目: 国家自然科学基金项目(40871159, 40571111, 40371083); 国家高技术研究发展计划课题(2007AA12Z139); 欧盟 FP7 项目(Call FP7 - ENV - 2007 - 1 212921)

作者简介: 侯姗姗(1988-), 女, 贵州贵阳人, 硕士生, 研究方向为基于条件植被温度指数的干旱预测研究。E-mail: nydxnydx@126.com。

通讯作者: 王鹏新(1965-), 男, 陕西礼泉人, 博士生导师, 主要从事定量遥感及其在农业中的应用研究。

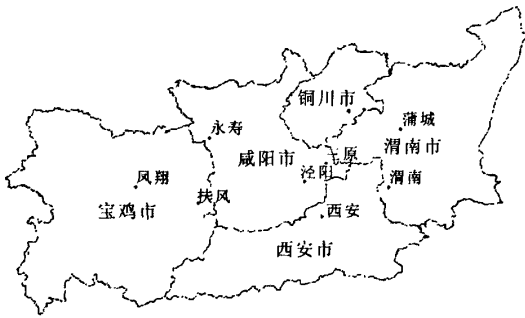


图 1 样本点分布

Fig.1 Distribution of the sampling sites

其中:

$$\begin{aligned} LST_{NDVI_{i,max}} &= a + bNDVI_i \\ LST_{NDVI_{i,min}} &= a' + b'NDVI_i \end{aligned} \quad (2)$$

式中, $LST_{NDVI_{i,max}}$ 和 $LST_{NDVI_{i,min}}$ 分别表示在研究区域内, $NDVI_i$ 值等于某一特定值时的土地表面温度的最小值和最大值, 二者也分别被称作冷、热边界。在热边界上, 土壤水分有效性很低, 干旱程度最严重; 冷边界上, 土壤水分不是作物生长的限制因素。 a, b, a', b' 为待定系数, 可通过绘制研究区域 $NDVI$ 和 LST 的散点图近似获得。VTCI 的取值范围为 $[0, 1]$ 。通常 VTCI 的值越小, 干旱程度越严重, VTCI 的值越大, 干旱程度越轻或没有旱情发生, VTCI 的取值范围与干旱等级之间的对应关系如表 1^[7]。

表 1 VTCI 干旱分级划分标准

Table 1 Drought categories based on VTCI

范围 Range	干旱等级 Drought category
$VTCI > 0.55$	无旱 Near normal
$0.46 < VTCI \leq 0.55$	轻旱 Moderately dry
$0.37 < VTCI \leq 0.46$	中旱 Severely dry
$VTCI \leq 0.37$	重旱 Extremely dry

研究采用通过定量遥感反演得到的关中平原和渭北旱源 8 个样本点, 2000 ~ 2007 年每年 3 月上旬至 6 月上旬 (每年计 10 旬) 的 VTCI 数据, 将一维时间序列进行延拓, 构造建模数据, 作为径向基函数网络模型的输入, 将模型的预测输出值与实测值进行比较, 分析模型的预测精度。

1.2 混沌时间序列的相空间重构

从时间序列研究混沌, 始于 Packard 等提出的相空间重构理论^[8]。该理论认为: 系统中的任一变量的演化都是由与之相互作用着的其它变量所决定的, 与此对应, 该变量也就包含了系统所有变量长期演化的信息。因此从某种意义上来说, 可通过利用

系统长期演化的任一变量时间序列来研究系统的混沌行为。Takens 等证明了重构系统与原始系统在系统特征上具有等价关系^[9]。延迟时间和相空间维数是重构相空间需要确定的两个重要参数。确定延迟时间的方法有自相关法、互信息量法、高阶相关法、相空间扩展法等, 相空间维数的确定主要有 G - P 算法确定关联维法、假邻接法、Cao 等方法^[10]。各个算法的优缺点不同, 本研究采用自相关法确定延迟时间和 G - P 算法确定关联维法来确定相空间维数。

1.2.1 延迟时间的确定 根据相空间重构理论, 时间序列的延迟时间, 应满足重构相空间中各个分量相互独立的关系, 若延迟时间选取过大, 会造成相邻延迟序列无关而不能反应系统特性; 相反, 延迟时间选取过小, 又会导致相邻延迟序列数据冗余。因此出现了用自相关函数来确定延迟时间的方法。对于一维时间序列 $x_1, x_2, x_3, \dots, x_n$, 其自相关函数可描述为:

$$f = \frac{\sum_{i=1}^{n-\tau} x'_i x'_{i+\tau}}{\sum_{i=1}^{n-\tau} (x'_i)^2} \quad (3)$$

式中, n 为时间序列数, $x'_i = x_i - \bar{x}$, \bar{x} 为时间序列的平均值。延迟时间 τ 的选取原则为既降低时间序列内元素间的相关性, 又要保证时间序列所包含的系统信息不丢失^[11]。一般, 可通过先画出时间序列的自相关函数, 然后做出自相关函数关于延迟时间的图像, 根据数值分析结果, 当自相关函数下降到初始值的 $1 - 1/e$ 时, 所得时间即为重构相空间所需的时间延迟。

1.2.2 相空间维数的确定 用相空间结构来描述确定性系统时, 相空间的轨迹描述了从已知的初始状态开始的演变过程。如果无论初始状态如何, 相空间的轨迹都收敛于一个单个的子空间, 则可称该相空间轨迹为“吸引子”。当系统对初始状态敏感, 吸引子具有非整数维时, 此时的吸引子即为混沌吸引子。系统的相空间维数可能很高, 甚至无穷, 但吸引子的维数一般都低于系统相空间的维数^[12]。通过计算混沌吸引子的维数, 在原系统中支起一个嵌入空间, 再利用吸引子维数与系统相空间维数之间的关系, 即可得到系统重构相空间的维数。一个可行的方法是 Grassberger 和 Procaccia 提出的 G - P 算法, 该算法的主要步骤为:

(1) 对于一维 VTCI 时间序列 $x_1, x_2, x_3, \dots, x_n$, 取较小的值 $p (p < n)$, 得到序列的前 p 个值, $x_1,$

x_2, x_3, \dots, x_p , 作为 p 维相空间的一个向量 $v t c i_1 = (x_1, x_2, x_3, \dots, x_p)$, 取延迟时间 τ 构成 p 维相空间的另一个向量 $v t c i_2 = (x_{1+\tau}, x_{2+\tau}, x_{3+\tau}, \dots, x_{p+\tau})$, 依此类推, 得到一个对应的重构相空间: $\{v t c i_i | v t c i_i = v t c i_1, v t c i_2, \dots, v t c i_N\}, i = 1, 2, \dots, N$, 其中 $N = n - p + 1$ 为重构相空间中向量个数。

(2) 计算关联函数 $c(r)$:

$$c(r) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N H(r - |v t c i_i - v t c i_j|) \quad (4)$$

其中, $|v t c i_i - v t c i_j|$ 表示任意两相点 $v t c i_i$ 与 $v t c i_j$ 之间的距离; r 为重构相空间的标量, 表示以 $v t c i_i$ 为中心, 以 r 为半径的体积元内重构后时间序列的个数。令, $u = r - |v t c i_i - v t c i_j|$, $H(u)$ 为 Heavyside 函数, 满足 $u < 0$ 时, $H(u) = 0$, $u \geq 0$ 时, $H(u) = 1$ 。 $c(r)$ 实质为一个积分函数, 表示相空间中吸引子两点之间距离小于 r 的概率。

(3) 对于 r 的某个适当范围, 吸引子的维数 D 与累积分布函数 $c(r)$ 满足对数线性关系:

$$D = \lim_{r \rightarrow 0} \frac{\ln c(r)}{\ln r} \quad (5)$$

由此, 拟合每条 $\ln c(r) - \ln r$ 曲线中对应直线部分的斜率, 可求出对应于 p 的吸引子空间维数估计值 $D(p)$ 。

(4) 增加嵌入维数 $p_1 > p$, 重复步骤(2)和步骤(3), 至 D 不再随 p 的增大而在一定误差范围内保持不变, 此时对应的嵌入维数即为重构相空间的维数。

1.3 基于径向基函数神经网络的预测方法

1988 年, Moody 等首次提出径向基函数 (Radial Basis Function, RBF) 神经网络^[13], 该网络的优点在于能以任意精度逼近任意连续函数, 因而在复杂非线性输入-输出系统建模中得到了广泛应用。RBF 神经网络通常具有三层网络结构, 分别为输入层、隐层、输出层。输入层神经元将输入信号传递到隐层, 隐层神经元通过基函数对输入信号产生局部响应, 当输入信号靠近基函数的中心时, 隐层神经元将产生较大的输出, 反之, 则产生较小的输出, 输出层神经元通常采用简单的线性函数产生网络输出信号。RBF 网络常用的基函数为高斯基函数, 定义为:

$$R_i(x) = \exp[-\|x - h_i\|^2 / (2\sigma_i^2)] \quad (6)$$


$i = 1, 2, \dots, k$

式中, $R_i(x)$ 为隐层第 i 个神经元的输出; x 为输入向量, $x = \{x_p | x_p \in R^N, p = 1, 2, \dots, N\}$, N 为输入样本数; h_i 为隐层第 i 个神经元高斯基函数的中心, 与 x 具有相同的维数; σ_i 为隐层第 i 个神经元的归一

化参数, 决定了相应高斯基函数围绕中心点的宽度; k 为隐层神经元个数。

按照基函数中心选取方法不同可以将 RBF 网络学习方法分为随机算法、自组织学习法、最近邻聚类学习法及正交最小二乘法等^[14]。由于最近邻聚类学习法不需要事先确定隐层神经元个数, 更适于建立动态 RBF 网络模型, 因此本研究采用最近邻聚类学习法确定基函数中心。

对于给定的混沌时间序列, 设计径向基函数网络结构, 网络输入神经元数目为重构相空间的维数, 由网络按照给定的误差自动生成合适的隐层神经元数目, 输出即为预测值的 VTCl 值, 因此, 输出层的神经元个数为 1。用于实际预测的神经网络结构如图 2 所示。依次输入训练数据 $v t c i_k$ 和对应的理论输出值 $v t c i_{(k + \Delta t)}$, 对径向基函数神经网络进行训练。本研究中, 按照各样本点 VTCl 时间序列的延迟时间和重构相空间维数, 每个样本点选取最后 10 组拓展后的时间序列用于径向基函数神经网络模型的验证, 其余序列作为模型的输入, 用于对模型进行训练。



输入层 Input layer 隐含层 Hidden layer 输出层 Output layer

图 2 径向基函数网络预测示意图

Fig.2 Prediction map of RBF neutral network

2 结果与分析

2.1 VTCl 时间序列的相空间重构

2.1.1 VTCl 时间序列的延迟时间确定 根据自相关函数的定义做出各样本点的自相关函数图(图 3)。图中对应于每一个延迟时间的值, 自左向右依次为西安、渭南、蒲城、三原、永寿、扶风、凤翔、泾阳各样本点的自相关函数值。从图中分析可得, 各样本点取延迟时间为 1 时, 自相关函数均已下降到初始值的 $1 - 1/e$, 因此, 可知各样本点时间序列相空间重构后延迟时间均为 1。

2.1.2 VTCl 时间序列重构维数确定 当两相点间距离小于给定正数 r 时, 称它们为相关联的相点。若 r 取值过小时, 两相点相关性为 0; r 取值过大时, 任意两相点相关性又都变成了 1, 两种情况都将导

致无法反应时间序列的动态特征。同时,嵌入维数 p 的取值过小,相空间过于离散,不足以表征时间序

列的数据特性; p 的取值过大,将会降低重构后的时间序列对数据内部特性变化的灵敏性。




图 3 各样本点自相关函数图

Fig.3 Autocorrelation function map of the sampling sites

因此实际计算中,通常 r 的取值应介于任意两相点距离最小和最大值之间,并让 r 的值由小增大,直至吸引子空间维数趋于稳定,不再随嵌入维数发生明显改变。本研究中,VTCI 数据取值范围在 $[0, 1]$ 之间,任意两相点间距离也在 $[0, 1]$ 之间,经反复实验验证,取 $r = (e^{-7}, e^{-6.9}, \dots, e^0)$,对应 $\ln r = (-7, -6.9, \dots, 0)$ 时,能较好地揭示 VTCI 时间序列相点间的相关性关系,而各样本点单年 VTCI 数据均为 10 旬,因此取嵌入维数 $p = (3, 4, \dots, 11)$ 。按照从上到下的顺序排列,得到对应不同嵌入维数时,各样本点 $\ln r - \ln c(r)$ 关系图(图 4)。图中可看出, r 取值较小时,对应图中左边水平部分,取值较大时,对应右边水平部分,均不能较好地反映时间序列的特性。

当 r 在一定范围时,各样本点的关联积分曲线近似为一段非水平的直线(图 4),由公式(5)可知,拟合求出每段斜率不为 0 的近似直线的斜率,即可得到各样本点取不同嵌入维数时重构相空间吸引子的维数 D 。并可根据得到的相空间吸引子维数,作出各样本点吸引子维数随嵌入维数改变时的变化趋势图(图 5)。

分析图 5,得到关联维数饱和(关联维数不再随嵌入维数的增大而变化,在一定误差范围内保持不变)时,各样本点嵌入维数值,即为各样本点重构相空间维数,其中西安、永寿、扶风样本点相空间维数为 7,三原、凤翔及泾阳样本点相空间维数为 8,渭南、蒲城样本点的相空间维数为 6。

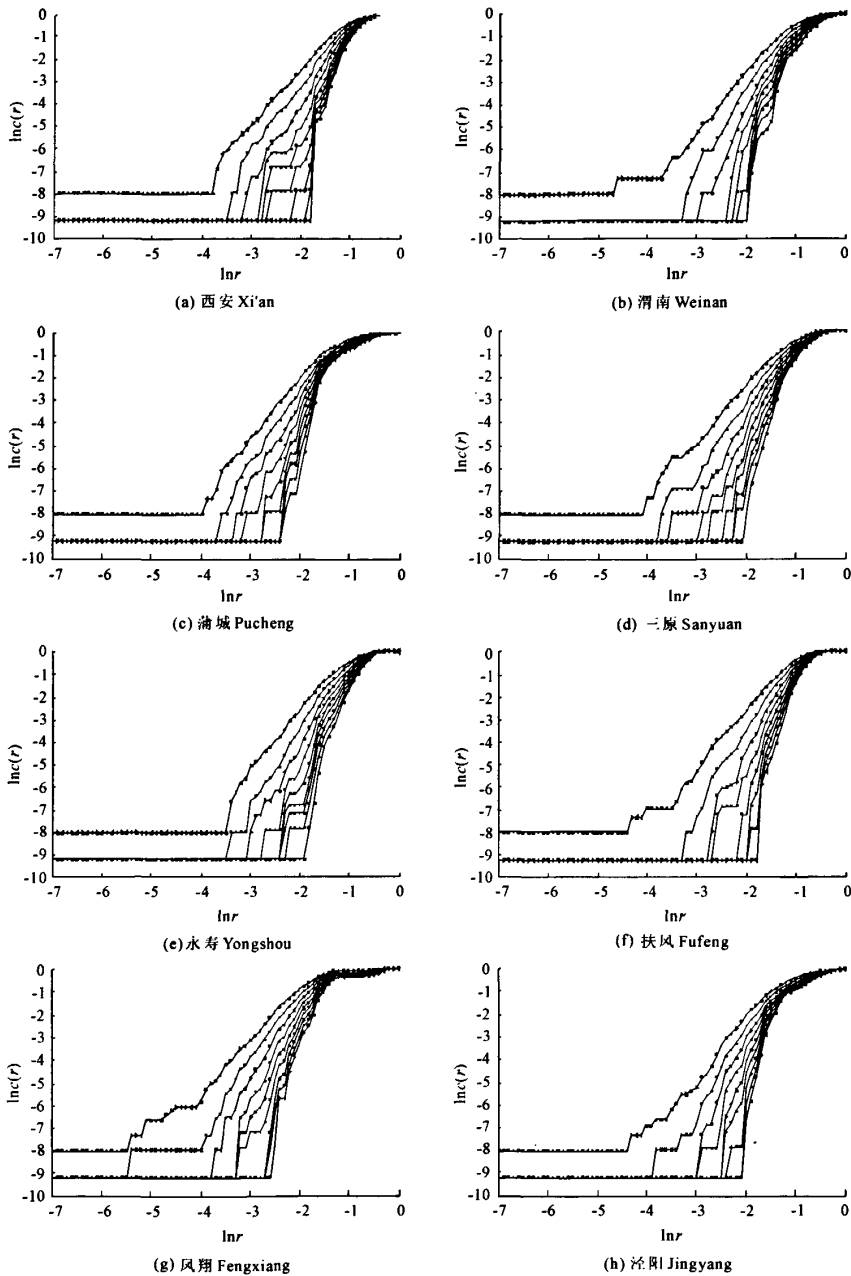
根据以上分析得到的各样本点 VTCI 数据延迟时间和重构相空间维数,对各样本点一维 VTCI 时间

序列进行相空间重构,并按照径向基函数神经网络模型输入/输出的规定,可知西安、永寿、扶风三个样本点为 2000 年 3 月上旬至 2006 年 3 月下旬共 63 组 VTCI 重构数据用于预测模型输入;同时,三原、凤翔、泾阳样本点为 2000 年 3 月上旬至 2006 年 3 月中旬共 62 组重构数据用于网络模型输入;渭南、蒲城样本点为 2000 年 3 月上旬至 2006 年 4 月上旬共 64 组重构数据用于网络模型输入。

2.2 RBF 网络模型预测结果及分析

根据各样本点的网络模型输入,分别对各样本点 VTCI 多维时间序列进行了径向基函数神经网络模型的训练,当预测值不再发生明显变化时,各样本点预测模型达到稳定。用各样本点的验证数据对模型进行验证,得到各样本点的预测相对误差如表 2。

分析表 2,并结合各样本点 VTCI 重构后时间序列,可知西安在 2006 年 5 月下旬,渭南在 2007 年 3 月下旬,蒲城在 2007 年 3 月中旬,三原在 2006 年 5 月下旬,永寿在 2007 年 3 月中旬,扶风在 2007 年 3 月中旬,凤翔在 2006 年 5 月下旬,泾阳在 2007 年 3 月下旬的 VTCI 预测值误差较大,原因可能为这些时间点的 VTCI 反演精度较低,多存在数值上的突变,导致模型预测误差较大。但与实测数据比较,预测值的相对误差均小于 10%。进一步将预测结果与 VTCI 实测结果相比,最小值、最大值、平均值及标准差的统计分析结果如表 3。表中可以看出最大值、最小值,及平均值误差基本在 -0.02 ,标准差最小误差为 -0.01 ,最大误差为 0.15。

图 4 各样本点 $\ln r - \ln c(r)$ 关系图Fig. 4 $\ln r - \ln c(r)$ diagram of the sampling sites

总体来看,各样本点预测数据平均误差分别为 -2.69% , -2.18% , -1.3% , -1.9% , -0.47% , -1.13% , 1.01% , -0.66% , 均方根误差分别为 6.89×10^{-4} , 4.78×10^{-4} , 6.11×10^{-4} , 7.37×10^{-4} , 8.19×10^{-4} , 8.76×10^{-4} , 1.87×10^{-5} , 9.15×10^{-4} 。所有样本点预测值平均误差为 -0.7385% , 总的均方根误差为 5.68×10^{-4} 。同时,经过 $\alpha = 0.05$ 的显

著性水平检验,模型预测值与实测值相关系数均在 0.99 左右。对比表 1 中 VTCI 干旱等级划分标准,所有 VTCI 预测值与实测值均处在相同的干旱等级内,预测模型达到了较高的预测精度,可以认为利用时间序列 VTCI 建立重构相空间,再利用径向基函数神经网络模型进行干旱预测的方法,较好地解决了研究区域的干旱预测问题,且预测精度较高。




图 5 各样本点嵌入维数 - 关联维数关系

Fig.5 Embedding dimension-correlation dimension diagram of the sampling sites

表 2 各样本点对应相对预测误差 (%)

Table 2 Relative prediction error of the sampling sites

西安 Xi'an	渭南 Weinan	蒲城 Pucheng	三原 Sanyuan	永寿 Yongshou	扶风 Fufeng	凤翔 Fengxiang	泾阳 Jingyang
-0.39	-1.71	0.09	-2.13	0.85	-0.29	0.47	-1.13
-4.06	-2.18	-1.67	1.38	-1.85	-1.33	0.35	-0.41
-1.10	-2.46	-1.62	-1.33	-2.04	0.45	-0.20	0.29
-2.51	-1.19	-1.46	-0.55	-3.59	-1.49	-0.56	-0.07
-8.69	-0.53	-1.15	-4.57	3.26	-2.96	0.54	-3.45
-3.78	-3.30	-2.70	7.45	-3.09	-1.66	-2.48	3.29
-1.84	-2.53	-5.75	2.32	-4.27	-2.33	-0.74	2.96
-3.89	4.28	-4.41	-4.55	-6.75	-6.33	-1.49	-6.83
1.26	-2.32	-3.00	-4.21	0.98	2.28	-1.66	-4.12
-1.92	-2.64	-2.61	-1.65	-1.79	-1.96	2.22	2.86

表 3 各样本点预测、实测及误差统计分析

Table 3 Statistics for forecasting, monitoring results of the sampling sites

统计量 Statistics		西安 Xi'an	渭南 Weinan	蒲城 Pucheng	三原 Sanyuan	永寿 Yongshou	扶风 Fufeng	凤翔 Fengxiang	泾阳 Jingyang
最大值 Maximal value	预测 Predicted	0.98	0.98	0.97	0.95	0.98	0.98	0.43	0.95
	实测 Measured	1.00	1.00	1.00	1.00	1.00	1.00	0.44	1.00
	误差 Difference	-0.02	-0.02	-0.03	-0.05	-0.02	-0.02	-0.01	-0.05
最小值 Minimal value	预测 Predicted	0.49	0.49	0.47	0.51	0.41	0.58	0.22	0.54
	实测 Measured	0.52	0.47	0.49	0.49	0.43	0.57	0.21	0.53
	误差 Difference	-0.03	0.02	-0.02	0.02	-0.02	0.01	0.01	0.01
平均值 Mean value	预测 Predicted	0.76	0.79	0.75	0.75	0.73	0.79	0.30	0.79
	实测 Measured	0.78	0.81	0.77	0.76	0.75	0.81	0.32	0.80
	误差 Difference	-0.02	-0.02	-0.02	-0.01	-0.02	-0.02	-0.02	-0.01
标准差 Standard deviation	预测 Predicted	0.24	0.02	0.17	0.15	0.28	0.21	0.06	0.17
	实测 Measured	0.25	0.01	0.02	0.16	0.30	0.22	0.08	0.19
	误差 Difference	-0.01	0.01	0.15	-0.01	-0.02	-0.01	-0.02	-0.02

3 讨论与结论

相空间重构更充分地挖掘了 VTCI 时间序列数据之间的关联信息,强调了遥感定量反演得到的地表参数自身在建立预测模型时的重要性;径向基函数神经网络模型为干旱预测提供了不同于传统确定性预测模型的新方法,该方法选用参数少,模型具有可操作性且预测精度较高,预测结果在实际应用中具有一定的参考价值。

但运用混沌理论,通过重构时间序列相空间的方法进行干旱预测时,只能对干旱进行短期预测,不利于掌握干旱发生的长期规律。且由于干旱成因的复杂性,及 VTCI 数据的混沌特性,当初始条件发生细微改变时,干旱是否发生及发生等级都有可能发生较大的变化,因此,基于相空间重构与径向基函数神经网络的干旱预测模型虽然预测精度较高,但在初始条件发生改变时,需要对模型进行重新训练,以适应新的条件,这使得模型的通用性受到了一定的限制。

同时,通过本文研究,发现该研究方法还存在可提高之处,例如在关联积分曲线近似为直线段,计算各样本点重构维数时,直线段端点的选取具有较强的主观因素,对斜率计算影响较大,进而影响重构相空间维数的确定。又如,有些时间点的预测精度还有待进一步提高,适当增加用于建模的训练数据,可以进一步提高模型预测精度,但是需要进一步的验证。

Application of phase space reconstruction and RBF neural network model in drought forecasting

HOU Shan-shan, WANG Peng-xin, TIAN Miao

(College of Information and Electrical Engineering, China Agricultural University, Beijing 00083, China)

Abstract: The chaos theories and phase reconstruction are introduced into drought forecasting, and the vegetation temperature condition index (VTCI) time series are expanded to multivariate time series. Based on multi-dimension VTCI time series, phase reconstruction and neural network model are combined to establish the drought forecasting model. The results show that the minimum, maximum, average and standard deviation between predicted value and measured value are very close, all the sample sites predictive values of the relative error are less than 10%, which indicates that the predictive method has high accuracy. And after $\alpha = 0.05$ significance level test, the correlation coefficients between the predicted value and measured value are all around 0.99. The method also demonstrates the utility and efficiency for drought forecasting.

Keywords: forecasting; vegetation temperature condition index; phase reconstruction; RBF neural network

参考文献:

- [1] 冯强,田国良,王昂生,等.基于植被状态指数的全国干旱遥感监测试验研究(1)[J].干旱区地理,2004,27(2):131-136.
- [2] 刘庆军,王雅华,李继伟.地下水位时间序列的混沌特征分析[J].人民黄河,2007,29(7):40-42.
- [3] Jayawardena A W. 降雨和径流时间序列的混沌分析与预测[J].人民长江,1996,27(6):43-45.
- [4] 王鹏新, WAN Zheng-ming, 龚健雅,等.基于植被指数和土地表面温度的干旱监测模型[J].地球科学进展,2003,18(4):527-531.
- [5] 孙威,王鹏新,韩丽娟,等.条件植被温度指数干旱监测方法的完善[J].农业工程学报,2006,22(2):22-26.
- [6] 葛哲学,孙志强.神经网络理论与 MATLAB R2007 实现[M].北京:电子工业出版社,2007:117-120.
- [7] 孙威,王鹏新.条件植被温度指数干旱监测方法的量化研究[D].北京:中国农业大学,2008.
- [8] Packard N H, Crutchfield J P, Farmer J D, et al. Geometry from a time series[J]. Phys Rev Lett, 1980,45(6):712-716.
- [9] Takens F. Determining strange attractors in turbulence[J]. Lecture notes in mathematics, 1988,898:361-381.
- [10] 谢忠玉,张立.相空间重构参数选择方法的研究[J].中国科技信息,2009,16:42-44.
- [11] 陈敏,徐德智,罗庆云.时间序列相空间重构及其应用研究[J].计算机与信息技术,2005,11(3):7-9.
- [12] 吕金虎,陆君安,陈士华,等.混沌时间序列分析及其应用[M].武汉:武汉大学出版社,2002:8-10.
- [13] Moody J E, Darken C. Fast learning in networks of locally tuned processing units[J]. Neural Computation, 1989,1(2):281-294.
- [14] Robert J. Schilling James, Carroll J. Approximation of nonlinear systems with radial basis function neural networks[J]. IEEE: Transactions on neural networks, 2001,12(1):21-28.