

# 基于相空间重构技术和 GA-BPNN 算法的 小麦条锈病受灾率预报模型\*

张 静

(襄樊学院 物理系, 湖北 襄樊 441000)

[摘 要] 利用混沌理论,对湖北省某地区小麦条锈病受灾率进行混沌特征验证,然后利用BP神经网络非线性逼近器能力,建立预测模型,利用重构相空间,确定神经网络的输入节点数及输入值,并引入遗传算法优化BP神经网络参数,对受灾率进行了成功预报。

[关键词] 小麦受灾率预报;混沌特征;重构相空间;GA-BPNN 模型

[中图分类号] TP391.41

[文献标识码] A

[文章编号] 1671-9387(2006)01-0063-04

在我国农业生产中,小麦生产占有重要地位,但小麦条锈病每年都给小麦生产带来严重危害,导致小麦减产。小麦条锈病受灾率时间序列预报研究,一直是科研人员关心的重要课题,且其研究难度也较大。小麦条锈病受灾率与菌源、气候有关,可认为是由许多变量组成的复杂的非线性系统。利用人工神经网络技术建立预测模型,是解决该问题的一个很好方法。但是,神经网络输入、输出信号的确定,只能基于经验或反复试验来确定,缺乏有力的理论根据。

近年来,混沌理论和分形理论的发展为研究这一问题提供了新的思路,如果该时间序列具有混沌特征,属于混沌时间序列<sup>[1]</sup>,则可以通过相空间重构技术,在嵌入空间里将有规律的轨迹(吸引子)恢复出来,为确定系统性质及预测方法提供理论依据。张静等<sup>[2]</sup>根据混沌理论和分形理论的方法,对湖北省襄樊地区小麦条锈病受灾率进行了混沌识别研究,分析了其功率谱和关联维度,结果显示该时间序列具有混沌特征,属于混沌时间序列。本研究利用BP人工神经网络非线性逼近器能力<sup>[3]</sup>,建立小麦条锈病受灾率预测模型,利用重构混沌时间序列相空间作为BP人工神经网络输入信号,并针对BP算法收敛慢、易陷入局部最优的缺点,将全局寻优的遗传算法<sup>[4-5]</sup>与BP算法相结合,更合理地确定了BP人工神经网络的权重。用该模型对湖北省某地区小麦条锈病受灾率进行预测,结果显示精度较高。现将该研究方法介绍如下。

## 1 原始数据

本研究以湖北省某地区每年小麦条锈病发病面积为原始数据,由于每年小麦播种面积不同,定义受灾率为每年小麦条锈病发病面积与该年小麦播种面积之比,取每年受灾率序列作为本研究讨论的时间序列,详见图1。

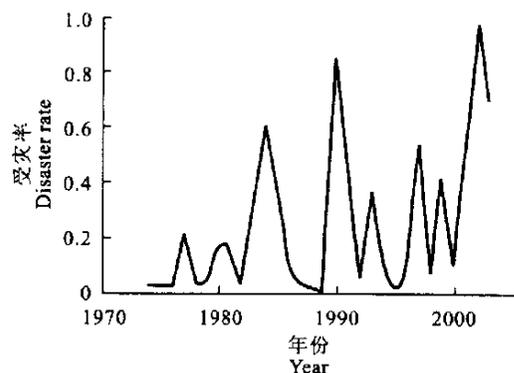


图1 小麦条锈病受灾率时间序列原始数据

Fig. 1 Disaster rate of crops time series

## 2 预测模型

### 2.1 基于重构相空间技术和遗传神经网络(GA-BPNN)预测模型的基本原理

设  $x(t)$  为离散时间序列,  $t = 1, 2, \dots, N$ , 在  $m$  维相空间中状态转移形式为:

$$Y(t+1) = f(Y(t)) \quad (1)$$

\* [收稿日期] 2005-05-10

[基金项目] 湖北省教育厅科研项目(200ID69001)

[作者简介] 张 静(1967-),女,湖北襄樊人,副教授,主要从事建模预测研究。E-mail:minda.wang@163.com

式中,  $Y(t) = (x(t), \dots, x(t + (m - 1)\tau))$ , 为相空间中点,  $\tau$  为时间延迟。文献[2]已分析计算出  $\tau = 2$ ,  $m = 4$ 。

将  $Y(t + 1)$  展开得:

$$(x(t + 1), \dots, x(t + 1 + (m - 1)\tau)) = f[x(t), \dots, x(t + (m - 1)\tau)] \quad (2)$$

式(2)中, 仅  $x(t + (m - 1)\tau)$  未知。

因此, 神经网络的输入节点数及输入值可由重构相空间技术确定, 然后利用BP 人工神经网络的非线性逼近器能力, 建立预测模型。BP 人工神经网络是目前应用最广泛的人工神经网络之一, 但其具有收敛慢、易陷入局部最优、健壮性不好的缺点。将全局寻优、健壮性好的遗传算法与BP 算法相结合, 能发挥神经网络的泛化映射能力, 同时使神经网络具有更快的收敛性和更强的学习能力。

遗传算法和BP 算法的结合主要有 2 种形式: 网络训练(学习网络各层间的连接权值)和优化网络拓扑结构。本研究使用的是前者, 其预测模型基本原理为: (1) 利用重构混沌时间序列相空间得出相关预报因子, 将其作为BP 人工神经网络输入信号, 确定输入层节点数; (2) 确定网络拓扑结构、激励函数和输出; (3) 训练网络, 交叉使用具有附加动量法和自适应学习率的BP 算法和遗传算法, 快速得到网络训练结果, 即输入层和隐含层、隐含层和输出层的连接权重; (4) 将检验数据预处理, 代入训练后的网络进行检验至符合要求; (5) 将有关数据预处理, 代入训练后的网络进行预测, 得预测结果。

### 2.2 具有附加动量法和自适应学习率的BP 算法

使用具有附加动量法和自适应学习率的BP 算法<sup>[3]</sup>的主要目的, 是为了加快训练速度, 避免陷入局部极小值。

附加动量法使网络在修正其权值时, 不仅考虑误差在梯度上的作用, 而且考虑其在误差曲面上的变化趋势。在无附加动量的作用下, 网络可能陷入浅的局部极小值, 而利用附加动量的作用可能滑过这些极小值。该方法是在BP 算法基础上, 在每一个权值变化上加上一项正比于前一次权值变化量的值, 并根据BP 算法产生新的权值变化, 权值调节公式为:

$$\Delta w_{ij}(k + 1) = (1 - mc)\eta\delta_j + mc\Delta w_{ij}(k)$$

$$\Delta b_i(k + 1) = (1 - mc)\eta\delta_i + mc\Delta b_i(k) \quad (3)$$

式中,  $\Delta w_{ij}(k + 1)$  为第  $k + 1$  次权值变化量;  $k$  为迭代次数;  $w_{ij}$  为权值;  $mc$  为附加动量因子, 常取 0.95;  $\eta$  为学习率;  $\delta_i$  为中间量<sup>[4-5]</sup>;  $p_j$  为第  $j$  个学习样本;

$\Delta b_i(k)$  为第  $k$  次偏差变化量。

训练程序中对采用附加动量法的判断方法为:

$$mc(k + 1) = \begin{cases} 0, SSE(k) > SSE(k - 1) \times 1.04 \\ 0.95, SSE(k) < SSE(k - 1) \\ mc(k), \text{其他} \end{cases} \quad (4)$$

式中,  $SSE$  为误差平方和。

对学习率的选择十分重要, 选择合适的学习率常凭经验, 但即使训练初期效果较好的学习率, 未必对后期训练合适, 使用自适应学习率的BP 算法, 可解决此问题。调解学习率的准则是: 权值的修正值若降低了误差函数, 则可对学习率增加一个量, 否则应减少学习率。当较大的学习率仍能使网络稳定学习, 使误差继续减小时, 则增加学习率, 使其以更大的学习率进行训练。自适应学习率的调整公式为:

$$\eta(k + 1) = \begin{cases} 1.05\eta(k), SSE(k + 1) < SSE(k) \\ 0.7\eta(k), SSE(k + 1) > SSE(k) \\ \eta(k), \text{其他} \end{cases} \quad (5)$$

### 2.3 基于遗传算法的权重优化算法

遗传算法是一种仿生算法<sup>[4-5]</sup>, 其模拟“优胜劣汰、适者生存”的原理激励好的结构。该算法通过模拟变异理论在迭代中保持已有的结构, 同时寻找更好的结构, 以其并行性、通用性、全局优化性和稳健性等优点而得到广泛应用。利用遗传算法优化权重, 即对权重编码、形成染色体; 对染色体进行选择、交叉、变异, 使染色体进化产生代表最优解的染色体; 反编码得优化的权重。其中值得注意的问题如下:

#### (1) 定义连接权重的优化问题

优化问题为:

$$\min SSE = f(w_1, w_2, \dots, w_N) \quad (6)$$

约束条件为  $a_i \leq w_i \leq b_i$

式中,  $SSE$  为误差平方和;  $(w_1, w_2, \dots, w_N)$  为网络二维的连接权重经统一编号后生成的一维连接权重;  $a_i$  和  $b_i$  是权重  $w_i$  的下、上限。

#### (2) 网络二维连接权重与一维连接权重的相互转换

网络二维连接权重需转换成遗传算法优化问题中的一维连接权重, 优化后代表最优解的一维连接权重也需转换成网络二维连接权重, 转化公式为:

$$w_k = w_{kp}, k = 1, 2, \dots, l$$

$$w_{m(k-1)+i} = w_{ik}, k = 1, 2, \dots, l; i = 1, 2, \dots, m \quad (7)$$

式中,  $w_{kp}$  为输入层和隐含层节点连接权重;  $w_{ik}$  为隐

含层和输出层节点连接权重;  $l, m$  分别为隐含层和输入层的节点数。

### 2.4 预测模型的实现

预测模型的具体实现步骤如下:

(1) 重构混沌时间序列相空间  $Y(t_i) = [x(t_i), x(t_i+2), x(t_i+4), \dots, x(t_i+(4-1) \times 2)]$ , 确定相关预报因子, 进而确定输入层节点数。(2) 确定网络拓扑结构(层数)、隐含层与输出层节点数、激励函数并输出。(3) 随机产生各网络权重  $w_{ij}$ , 使用具有附加动量法和自适应学习率的 BP 算法计算网络输出值及  $SSE$ 。(4) 判断  $SSE$  是否小于  $\epsilon$  ( $\epsilon$  为误差目标), 若是则结束训练, 转入步骤(8); 否则继续下一步。(5) 计算新的网络权重  $w_{ij}$ , 使用具有附加动量法和自适应学习率的 BP 算法计算网络新的输出值及  $SSE$ 。(6) 判断  $SSE$  是否小于  $\epsilon$  如是则结束训练, 转入步骤(8); 否则计算  $\Delta SSE(t) = SSE(t) - SSE(t-1)$ , 若  $\Delta SSE > \beta$  ( $\beta$  为给定值), 则转入步骤

(5); 若  $\Delta SSE < \beta$ , 转入步骤(7); 调用遗传优化算法。(7) 设定群体规模、优秀个体数目等参数, 进行遗传算法, 计算权重; 计算  $SSE$ , 如果  $SSE < \epsilon$  继续下一步; 否则用优化后的权重作为网络权重, 转入步骤(5)。(8) 输出最优权值。(9) 利用训练后的上述模型进行预测。

## 3 应用

利用 MATLAB 编写程序, 对湖北省某地区每年小麦条锈病受灾率序列作建模预测, 根据前面的分析, 输入节点数是 4 个, 输出节点数是 1 个; 经数据试验确定隐层节点数为 6 个; 隐含层和输出层分别取为 Sigmoid 型和线性函数。有关参数设定如下: 最终网络训练误差上限  $\epsilon = 0.0001$ ; 2 次网络训练误差之差下限  $\beta = 0.002$ , 网络学习系数为 0.01; 动量因子为 0.95; 群体规模为 50, 优秀个体数为 5。

训练后, 输入与隐含层连接的权重为:

$$W = \begin{bmatrix} 0.900 & -0.007 & -0.169 & -0.758 & 0.405 & -0.279 \\ 0.624 & 0.658 & 0.196 & -0.851 & 0.790 & -0.793 \\ 0.844 & -0.314 & -0.566 & 0.946 & 0.941 & 0.574 \\ -0.808 & 0.032 & 0.846 & 0.718 & 0.014 & 0.301 \end{bmatrix}$$

隐含层与输出层连接权重为:

$$w = [0.391 \quad 0.233 \quad -0.060 \quad 0.117 \quad 0.402 \quad -0.308]$$

用训练后的网络模型分别作一步、二步预测, 将预测结果与文献[6]的结果进行比较, 结果见表 1。

表 1 网络模型与文献[6]预测结果的比较

Table 1 Comparison of the forecasting results between the network model and the reference [6]

实际值/% The actual value	本文一步预测结果 One step forecasting results of this paper		本文二步预测结果 Two steps forecasting results of this paper		文献[6]一步预测结果 One step forecasting results of the reference [6]	
	预测值/% The forecasting value	绝对误差 The absolute error	预测值/% The forecasting value	绝对误差 The absolute error	预测值/% The forecasting value	绝对误差 The absolute error
97			89.51	7.49		
70	71.55	1.55	65.13	4.87	67.75	2.25

由表 1 可以看出, 本文模型预测值与实际值很接近, 其预报误差较文献[6]用经验选择神经网络结构法的预报误差小, 可见本模型精度更高。本模型一步预测绝对误差较二步预测绝对误差小, 表明其短期预测精度较长期预测精度高。

## 4 讨论

利用 BP 神经网络非线性逼近器能力建立预测

模型, 并引入遗传算法优化 BP 神经网络参数来预测时间序列, 已有许多成功应用的报道<sup>[7-8]</sup>。但是如何确定神经网络的输入节点数及输入值, 却一直缺乏理论依据, 若验证某序列是混沌的, 则利用混沌理论和重构相空间技术可较好解决此问题。本文应用实例证明, 基于相空间重构技术和 GA-BPNN 算法建立的小麦条锈病受灾率预报模型是适用的。

### [参考文献]

[1] 吕金虎, 陆君安, 陈士华. 混沌时间序列及其应用[M]. 武汉: 武汉大学出版社, 2002

[2] 张 静, 洪新兰. 小麦受灾率时间序列混沌特征研究[J]. 西北农林科技大学学报: 自然科学版, 2005, 33(9): 63-68

- [3] 丛爽. 面向MATLAB工具箱的神经网络理论与应用[M]. 合肥: 中国科技大学出版社, 2003
- [4] 张文修, 梁怡. 遗传算法的数学基础[M]. 西安: 西安交通大学出版社, 2003
- [5] 周明, 孙树栋. 遗传算法原理及应用[M]. 北京: 国防工业出版社, 1999
- [6] 张静. 基于神经网络的受灾面积预测精度研究[J]. 襄樊学院学报, 2004, 25(2): 24-26
- [7] 陈守煜, 王大刚. 基于遗传算法的模糊优选BP网络模型及应用[J]. 水利学报, 2003, (5): 116-121
- [8] 曹永强, 张道军. 非线性智能组合预测模型及其应用[J]. 中国矿业大学学报, 2004, 33(4): 428-432

## Research on chaotic characteristics of the disaster rate of crops and its GA-BPNN forecasting model

ZHANG Jing

(Department of Physics, Xiangfan University, Xiangfan, Hubei 441000, China)

**Abstract:** The chaos theory is used to test chaotic characteristics of the disaster rate of wheat rust certain part of Hubei province. Then the forecasting model is established to forecast the disaster rate by combining BP-NN with GA. With reconstruction of phase space, determining the input numbers and values and the optimized BP algorithms, the disaster rate has been successfully forecasted.

**Key words:** wheat disaster rate forecast; chaos character; reconstruction of phase space; GA-BPNN model

(上接第 62 页)

**Abstract ID:** 1671-9387(2006)01-0056-CA

## 引发剂、杀真菌剂和生物制剂对洋葱种子的抑菌作用

卫亚红<sup>1</sup>, Dorna H<sup>2</sup>

(1 西北农林科技大学 资源环境学院, 陕西 杨凌 712100;

2 波兹南农业大学 种子科学技术系, 波兰 波兹南 62-081)

**[摘要]** 以洋葱种子“Wolska”为材料, 研究了在 10 时杀真菌剂、生物制剂、PEG 8000 和水引发单独处理及复合处理对洋葱种子的抑菌效果。结果表明, 未处理的对照种子主要受青霉菌感染; 杀真菌剂(单独处理)在很大程度上可减少青霉菌的感染率; 而生物制剂(Biozym 生物合剂, Promot 助长剂分别单独处理)未能很好地控制青霉菌的感染; 水引发剂处理后, 种子青霉菌的感染率极显著地低于未处理的对照种子; 在杀真菌剂与 PEG 8000 同时处理种子和杀真菌剂先于水引发剂处理种子的 2 种复合处理中, 可检测到高比例的未染菌种子。

**[关键词]** 洋葱种子; 引发剂; 杀真菌剂; 生物制剂

**[中图分类号]** S436.33