

基于人工神经网络的农业病虫害预测模型及其效果检验

李祚泳¹, 彭荔红²

(1 成都气象学院, 成都 610041; 2 厦门大学环境科学研究中心, 厦门 361005)

摘要: 选取与病虫害有关的因子作为样本的输入特征, 建立了农业病虫害年分类预测的 B-P 人工神经网络模型。该方法应用于稻瘟病的预测建模结果的拟合率为 100%, 预留样本检验批准率为 83%。

关键词: 人工神经网络; B-P 算法; 病虫害; 预测; 农业

Prediction model of agricultural plant diseases and insect pests based on artificial neural network and its verification

LI Zuo-Yong¹, PENG LiHong² (1. Chengdu Institute of Meteorology, Chengdu 610041, China; 2 Research Center of Environment Sciences, Xiamen University, Xiamen 361005 China)

Abstract A model is developed for the classified prediction of agricultural plant diseases and insect pests using B-P artificial neural network with factors related to agricultural plant diseases and insect pests as input features of sample. The results of prediction to rice blast show that the qualified rates of fitting and predicting using this model acquire 100% and 83%, respectively.

Key words artificial neural network; B-P algorithm; diseases and insect pests prediction; agriculture

文章编号: 1000-0933(1999)05-0759-04 中图分类号: S431 文献标识码: A

我国幅员广大, 每年都有不同地区的农作物遭受病虫害, 直接影响农作物产量, 给国民经济带来很大损失^[1], 若能早期作出预报, 及时采取防治措施, 可使病虫害对农作物危害造成的损失减少到最低限度。

与病虫害有关的前期因子较多, 而且很复杂, 其中气象因子与病虫害关系密切。不过, 气象因子与病虫害的关系并非非线性关系。因此, 用常规的数理统计方法找出气象因子与病虫害之间的某种函数关系有一定难度。80年代以来, 迅速发展的人工神经网络由于它模拟人脑思维结构, 具有很强的自学习、自组织、自适应和容错性强等特点, 它特别适用于非线性问题的处理^[2]。本文在选取了与农业病虫害有密切关系的前期因子基础上, 采用误差反向传播算法的人工神经网络(以下简称 B-P 网络)建立病虫害的分类预测模型, 为人工神经网络用于农业病虫害预测开辟了新途径。

1 前馈式的 B-P 网络原理及学习过程简介

人工神经网络是 80 年代迅速兴起的一门非线性科学。在神经网络模型中, 前馈式的 B-P 网络是一种最简单而用途广泛的人工神经网络^[3, 4]。它适用于非线性的模式识别和分类预测问题。最基本的 B-P 网络是由输入层、隐层和输出层组成的 3 层前馈网络。每层有若干个互不连接的神经元节点, 相邻两层节点通过权连接, 如图 1 所示。B-P 网络的操作分为学习和应用两个过程。第 1 过程为正向学习过程, 具体实现方法见图 1。① 根据问题性质, 设定网络结构, 赋予相邻各层节点之间的连接权值 k_j , V_k 和隐层节点及输出层节点的阈值 θ_j , θ_k 为 $(-1, 1)$ 之间的任一随机小数; ② 从输入节点输入学习样本的信息 x_i , 并向前传播, 由式 (1) 的 Sigmoid 函数计算出隐节点和输出节点的输出 H_j , O_k :

$$f(x) = 1/[1 + \exp(-x)] \quad (1)$$

$$H_j = f(x_j) = f(\sum W_{ji}x_i + \theta_j) \quad (2)$$

基金项目: 四川省应用科学研究基金资助项目。

收稿日期: 1996-11-07; 修订日期: 1998-09-25




图 1 3层 B-P神经网络模型

Fig 1 The model of B-P neural network with 3 stratum

$$O_k = f(H_j) = f\left(\sum V_{kj}H_j + V_k\right) \quad (3)$$

第 2阶段为误差传播阶段。

(3)计算输出节点的输出误差:

$$\Delta_k = (O_k - D_k)O_k(1 - O_k) \quad (4)$$

式中, D_k 为学习样本的期望输出。

(4)计算隐节点的误差:

$$\epsilon_j = \left(\sum \Delta_k V_{kj}\right)H_j(1 - H_j) \quad (5)$$

(5)用下述公式对权值和阈值加修正:

$$V_{kj} = V_{kj} + \tau \Delta_k H_j \quad (6)$$

$$V_k = V_k + \tau \Delta_k \quad (7)$$

$$W_{ji} = W_{ji} + \tau \epsilon_j x_i \quad (8)$$

$$\theta_j = \theta_j + \tau \epsilon_j \quad (9)$$

以上诸式中, τ 为在 (0, 1) 之间取值的 learning rate

(6)依次输入学习样本, 经以上两个阶段反复交替学习, 待全部样本学完一遍后, 计算误差:

$$E = \frac{1}{N} \sum_{k=1}^N (O_k - D_k)^2 \quad (10)$$

若 $E \leq \epsilon$ (ϵ 为指定误差限值), 则学习终止, 得到学习终止时网络的权值和阈值。否则, 更新学习次数, 再将样本重新输入学习, 直到式 (10) 满足收敛条件为止。投入使用时, 只要将新的样本信息输入训练好的 B-P 网络, 就可以从网络输出端获得需要的结果。B-P 网络的原理和算法详见文献 [5]

2 B-P网络用于农业病虫害分类预测建模的一个检验实例

经分析影响稻瘟病的主要因子是气象因子。根据文献 [6] 将 B-P 网络用于某地区稻瘟病流行年的分类预报时, 应选取与稻瘟病有关的 7 个主要气象因子为: X_1 当年 7~8 月平均最高气温; X_2 上年 10 月下旬平均最低气温; X_3 上年 11 月中、下旬日照时数; X_4 当年 3 月中旬平均气温; X_5 当年 6 月上旬平均气温; X_6 当年 4 月中、下旬雨日; X_7 当年 7 月中旬~8 月上旬平均气温。已有的 41 个病虫害年样本分为 A、B、C 三类。B-P 网络用于分 K 类预报时, 其各类样本的期望输出通常设定为 K 维向量 $D_1(1, 0, \dots, 0)$, $D_2(0, 1, 0, \dots, 0)$, \dots , $D_k(0, 0, \dots, 0, 1)$ 。在本实例中, 由于训练样本由历史实测资料组成, 因此不能完全代替总体的未来病虫害年样本。考虑到由于训练样本的不完全性造成的抽样误差, 使建立的预测模型有一定的推广能力, 必须对样本的期望输出留有一定余地, 故本实例每类样本相应的网络期望输出如下:

样本类别	A 类 (轻病年)	B 类 (中病年)	C 类 (重病年)
期望输出 D_j	(0.9 0 0)	(0 0.9 0)	(0 0 0.9)

首先将样本的各因子观测数据按下述公式规格化:

$$X_i'(t) = (X_i(t) - X_{i,\min}') / (X_{i,\max}' - X_{i,\min}') \quad t = 1 \sim 41 \quad i = 1 \sim 7$$

全部 41 个样本因子规格化后数值及其类别见表 1。用前 35 个样本作为 B-P 网络建模学习样本, 后 6 个留作检验样本。建立 7 个输入节点, 5 个隐节点和 3 个输出节点的 3 层 B-P 网络结构。随机赋予网络的初始权值和阈值后, 将表 1 中前 35 个样本因子数值及样本期望输出依次输入 B-P 网络。由于 τ 取值对学习速度有明显影响。取值太小, 收敛可能很慢; 若太大, 可能出现连续不稳定。一般经多次调节, 选取一个适当大小的中间值。本实例中, 经过选不同 τ 组合进行训练, 最后选取 $\tau = 0.35$ 时训练较理想。经过 435 遍学习后, $E \leq 0.01$ 得到终止学习后的权值和阈值 (见表 2)。由表 2 中的权值和阈值及公式 (1)~(3), 可得前 35 个样本的拟合和后 6 个样本的预报检验结果亦见表 1。其拟合率为 100%, 预报准确率为 83.3%。

表 1 样本因子规格化值及分类、拟合和预测检验结果

Table 1 Normalized values of factors and classification fitting and predicting results of samples

样品序号 Number code of sample	X_1	X_2	X_3	X_4	X_5	X_6	X_7	D_1	D_2	D_3	预测结果	实际结果
											Prediction	Practical
											classes	classes
1	0.4468	0.5700	0.3345	1.0000	0.2909	0.4545	0.8000	0.9827	0.0114	0.0048	A	A
2	0.7234	0.3500	0.1745	0.8553	0.4727	0.8182	0.9143	0.9868	0.0092	0.0040	A	A
3	0.2766	0.5000	0.0000	0.9605	0.3818	0.0909	0.5439	0.7972	0.1474	0.0101	A	A
4	0.3617	0.0000	0.6238	0.5658	0.0364	0.4545	0.6571	0.0115	0.0000	0.9791	C	C
5	0.3830	0.3500	0.4834	0.0000	0.1818	0.2727	0.6000	0.0002	0.0494	0.9550	C	C
6	0.7660	0.4500	0.0468	0.2368	0.4182	0.0000	0.7143	0.0112	0.9620	0.0500	B	B
7	0.1064	0.4600	0.7123	0.8158	0.2182	0.5455	0.0000	0.0209	0.0001	0.9331	C	C
8	0.3404	0.2300	0.6017	0.7500	0.0000	0.7273	0.6000	0.0974	0.0000	0.8989	C	C
9	0.1702	0.2600	0.6323	0.2368	0.4182	0.4545	0.5143	0.00004	0.0059	0.9750	C	C
10	0.3617	0.6800	0.4179	0.6842	0.4000	0.9090	0.5429	0.9694	0.0067	0.0084	A	A
11	0.3191	1.0000	0.4996	0.5658	0.1273	0.9090	0.2571	0.1896	0.7990	0.0134	B	B
12	0.3830	0.6700	0.5668	0.9605	0.5091	0.7273	0.7429	0.9852	0.0108	0.0040	A	A
13	0.6383	0.9600	0.6255	0.3553	0.0909	1.0000	0.6286	0.9817	0.0079	0.0048	A	A
14	0.4255	0.4300	0.2179	0.4079	0.7273	0.4545	0.4173	0.0717	0.7241	0.0375	B	B
15	0.1702	0.3300	0.4119	0.5395	0.5455	0.6364	0.3143	0.0140	0.0035	0.7933	C	C
16	0.2553	0.1300	0.8681	0.3684	0.6364	0.4545	0.6571	0.0004	0.0026	0.9816	C	C
17	0.5532	0.4600	0.4000	0.6447	0.6727	0.7273	0.6857	0.8894	0.0247	0.0132	A	A
18	0.5745	0.7500	0.4690	0.5263	0.2182	0.6364	0.7429	0.9674	0.0177	0.0058	A	A
19	0.4468	0.5000	0.5396	0.9211	0.6182	0.6364	0.7714	0.9569	0.0088	0.0104	A	A
20	0.7660	0.7900	0.6817	0.3158	0.1818	0.5455	0.7714	0.8325	0.0362	0.0142	A	A
21	0.4468	0.2700	0.0800	0.3684	0.8909	0.3636	0.8857	0.0228	0.9022	0.0485	B	B
22	0.0426	0.2600	0.5847	0.4605	0.6727	0.7273	0.2857	0.0018	0.0022	0.9536	C	C
23	0.8085	0.8100	0.7200	0.3684	0.2000	0.5455	0.8571	0.9269	0.0330	0.0076	A	A
24	0.4894	0.3100	0.0570	0.3947	1.0000	0.3636	1.0000	0.0636	0.9586	0.0136	B	B
25	0.1064	0.2900	1.0000	0.5000	0.7273	0.8182	0.3714	0.0028	0.0004	0.9722	C	C
26	0.4255	0.0000	0.6613	0.5395	0.1273	0.7273	0.7143	0.0248	0.0000	0.9692	C	C
27	0.4468	0.4100	0.4417	0.0132	0.2727	0.3636	0.6571	0.0007	0.1123	0.8467	C	C
28	1.0000	0.4300	0.1251	0.2632	0.4545	0.1818	0.9143	0.1155	0.9113	0.0128	B	B
29	0.1915	0.4600	0.771	0.6711	0.2909	0.3636	0.0000	0.0019	0.0017	0.9596	C	C
30	0.4255	0.2600	0.6451	0.7237	0.0727	0.5455	0.6286	0.0807	0.0000	0.8884	C	C
31	0.1915	0.2500	0.8757	0.2632	0.5273	0.2727	0.5429	0.0001	0.0219	0.9831	C	C
32	0.4255	0.6000	0.4817	0.6053	0.5091	0.7273	0.6000	0.8738	0.0144	0.0186	A	A
33	0.3830	0.8800	0.5328	0.5000	0.1273	0.3636	0.5714	0.7502	0.0862	0.0134	A	A
34	0.4468	0.6000	0.5643	0.8421	0.5636	0.7273	0.7714	0.9738	0.0103	0.0064	A	A
35	0.6383	0.8900	0.7268	0.3289	0.1455	0.3664	0.7429	0.9143	0.0209	0.0104	A	A
36	0.3404	0.3900	0.1966	0.3816	0.8545	0.4545	0.8000	0.0390	0.8487	0.0407	B	B
37	0.0000	0.3200	0.5617	0.4605	0.5636	0.3664	0.3429	0.0025	0.0023	0.9423	C	C
38	0.4043	0.1700	0.5949	0.9474	0.0909	0.6364	0.4857	0.0960	0.0000	0.8976	C	C
39	0.5532	0.2700	0.4366	0.9079	0.1636	0.5455	0.6000	0.4333	0.0002	0.4376	C	C
40	0.2128	0.1600	0.1064	0.9250	0.1818	0.3636	0.4286	0.1385	0.0002	0.7320	C	A
41	0.3830	0.6900	0.1889	0.5921	0.2182	0.7273	0.7714	0.9847	0.0159	0.0030	A	A

* 代表预测样本 Represents prediction sample

3 结论

(1) 农业病虫害的危害程度与其预报因子的关系, 大多具有非正态和非线性特征, 采用具有 Sigmoid 函数的 B-P 网络来描述它们之间的这种关系是适宜的。

(2) 用已训练好的 B-P 网络预报农业病虫害类别时, 只需将表 2 中的权值和阈值及待预测样本的因子规格化数值代入公式 (1)~ (3), 进行简单运算, 就可获得结果。

表 2 训练结束后的权值和阈值

Table 2 Trained weight and threshold values

W_{ji}	0.6574	0.9032	-0.5642	3.5349	-2.1926	3.3482	1.8829
	-1.1625	-3.8923	2.5916	-0.4164	-2.4248	1.5280	-0.5996
	-0.0607	-1.7108	0.6357	4.6326	-4.3425	4.5919	2.0800
	1.5122	4.1902	-1.9107	0.9064	1.8055	0.1095	1.0923
	1.3494	4.7251	-2.1034	1.8801	0.5863	1.8224	1.6138
V_{kj}	3.7723	-3.1786	4.6720	2.3137	4.5920		
	-3.1062	-4.5941	-5.7342	3.2277	1.7478		
	-1.4271	3.5998	0.0060	-3.8009	-4.5886		
O_j	-3.9751	1.8252	-2.4887	-3.5836	-5.1949		
\bar{Y}	-8.7650	1.3437	1.7505				

(3) B-P 网络具有自适应、抗干扰和容错性强能力, 个别学习样本的分量偏差对网络的学习效果影响较小, 因此模型的稳定性较好。

(4) B-P 网络建模精度高低仍与因子的选取有关。因此, 本实例中选择与病虫害相关性好的因子建模是很重要的。

(5) 由于 B-P 网络学习过程中, 有可能出现“局部极小”、“收敛速度慢”等问题。若遇此情况, 可参阅文献 [7] 指出的方法加以解决。随着 B-P 网络模型的不断改进和完善, B-P 网络用于病虫害预测将是可行的。

参考文献:

- [1] 汤金仪, 等. 我国水稻迁飞性害虫猖獗成因及其治理对策建议. 生态学报, 1996 16(2): 167-173
- [2] Widrow B. 30 years of adaptive neural networks: perceptron, Madaline, and B-P. Proc IEEE, 1990 78(9): 1415-1442
- [3] Rumelhart D, Hinton G, Williams R. Learning representation by backpropagating errors. Nature, 1986 (323): 533-536
- [4] Stornetta W, Huberman B. An improved three-layer backpropagation algorithm. Proceeding of the IEEE First Inter Conf on Neural Networks, 1987 (II): 637-644
- [5] 王伟编著. 神经网络原理——入门与应用. 北京: 北京航空航天大学出版社, 1995: 52-76
- [6] 周洪祥, 等. 模糊数学在农业病虫害预报中的应用. 模糊数学, 1986 6(1): 41-44
- [7] 高洪深, 陶有德. BP 神经网络模型的改进. 系统工程理论与实践, 1996 16(1): 67-71