

# 人工神经网络模型在水稻群体分蘖动态模拟中外推能力的测试

邹应斌<sup>1</sup>, 米湘成<sup>2</sup>, 石纪成<sup>3</sup>

(1. 湖南农业大学农学院, 长沙 410128; 2 中国科学院植物研究所, 北京 100093; 3. 湖南省宁乡县农业局, 湖南宁乡 410600)

**摘要:**研究利用人工神经网络模型,以水稻群体分蘖动态为例,采用交互验证和独立验证的方式,对水稻生长 BP 网络模型进行了训练与模拟,其结果与水稻群体分蘖的积温统计模型、基本动力学模型和复合分蘖模型进行了比较。研究表明,神经网络模型具有一定的外推能力,但其外推能力依赖于大量的训练样本。神经网络模型具有较好的拟合能力,是因为有较多的模型参数,因此对神经网络模型的训练需要大量的参数来保证其参数不致过度吻合。具有外推能力神经网络模型的最少训练样本数应大于 6.75 倍于神经网络参数数目,小于 13.5 倍于神经网络参数数目。因此在应用神经网络模型时,如果神经网络模型包括较多的输入变量时,可考虑采用主成分分析、对应分析等技术对输入变量进行信息综合,相应地减少网络模型的参数。另一方面,当训练样本不足时,最好只用神经网络模型对同一系统的情况进行模拟,应谨慎使用神经网络模型进行外推。神经网络模型给作物模拟研究的科学工作者提供了一个“傻瓜”式工具,对数学建模不熟悉的农业研究人员,人工神经网络可以替代数学建模进行仿真实验;对于精通数学建模的研究人员来说,它至少是一种补充和可作为比较的非线性数据处理方法。

**关键词:**水稻;群体分蘖动态;人工神经网络;作物模型,误差逆传

## Testing the generalization of artificial neural networks in predicting rice tillering dynamics

ZOU Ying-Bin<sup>1</sup>, MI Xiang-Cheng<sup>2</sup>, SHI Ji-Cheng<sup>3</sup> (1. College of Agronomy, Hu'nan Agricultural University, Changsha 410128; 2. Institute of Botany, Chinese Academy of Sciences, Xiangshan, Beijing 100093; 3. Agricultural Bureau of Ningxiang County, Ningxiang, Hu'nan Province 410600). *Acta Ecologica Sinica*, 2004, 24(12): 2967~2972.

**Abstract:** Neural networks (NN) rely on the inner structure of available data sets rather than on comprehension of the modeled processes between inputs and outputs. Therefore neural networks have been regarded as highly empirical models with limited extrapolation capability to situations outside the range of the training and validation data sets. With rice tillering as an example, the back-propagation artificial neural networks are established to simulate the rice tillering dynamics and to compare with statistical model, basic dynamic model and composite tillering model with cross validation and independent validation. For tillering models with one input variable, the degree-day-tillering NN and days after transplanting-tillering NN have higher performance than the degree-day statistical model and basic dynamic model. At the same time, two cross-validated models have similar performance to the two independent-validated models, showing that the two NNs have ability to extrapolate. For tillering models with multiple input variables, cross-validated three-variables-tillering NN offers better performance than the degree-day-tillering NN, days after transplanting-tillering NN and composite tillering model, because three-variables-tillering NN takes more factors into consideration and has more model parameters. However, independent-validated three-variables-tillering NN has much more severe overfitting than composite tillering model. Therefore, it is shown in this study that neural network is able to extrapolate and predict tillering dynamics of the data is within the range of inputs of training set. The generalization of NN heavily depends on the large amount of training set, and inadequate amount of training data results in overfitting of available data and neural works that are not generalizable. NNs provide better performance than the algorithm

**基金项目:**国家“九五”攻关资助项目(95-001-01);农业部跨越计划和湖南省自然科学基金资助项目(01JJY2033)

**收稿日期:**2003-09-20; **修订日期:**2004-07-25

**作者简介:**邹应斌(1954~),男,湖南望城人,教授,主要从事作物栽培与作物模型研究。

**Foundation item:** National ninth Five-Year-Plan (No. 95-001-01), Transcending Plan of Chinese Agricultural Ministry, and Natural Science Foundation of Hu'nan Province (No. 01JJY2033)

**Received date:** 2003-09-20; **Accepted date:** 2004-07-25

**Biography:** ZOU Ying-Bin, Professor, mainly engaged in agronomy and crop modeling. E-mail: zouyingbin@263.net



model mainly because of the greater number of adapted parameters, which requires a large amount of training set to grantee the robust parameterization of NNs. The smallest training set size required to enable NN to generalize and predict rice tillering dynamics is found to greater than 6.75 times and less than 13.5 times as many training patterns for each weight. When a large number of variables have to be included in the input vector of NN with inadequate amount of training data, we strongly recommend that the dimension of the input vector should be reduced using principal component analysis (PCA), correspondence analysis (CA) or similar techniques to decrease the number of weights before the training procedure to improve the generalization ability of NN. On the other hand, NN should be strictly limited to be applied in predict the situations in the same systems, and NN should be cautious to be used in predict the situations for different systems when training data is not enough to ensure a robust parameterization of NN. The artificial neural network provides convenient and fast tools to simulate rice growth and gets ride of the limitation of traditional models. The generalization of neural networks present a wide spectrum of problem, and the proposed approaches in this study are not confine to modeling rice tillering dynamics but can be applied to other agricultural and ecological systems.

**Key words:** rice; tillering dynamics; artificial neural networks; crop model; back-propagation; cross validation; independent validation

文章编号:1000-0933(2004)12-2967-06 中图分类号:TP391.9,S511 文献标识码:A

作物生长处于复杂的“气候-土壤-栽培”体系中,作物生长模拟是一个涉及多个因素、多生理过程的复杂系统工程。目前的作物生长模型已包括了作物生长发育的一些主要过程:光合作用、养分摄取、同化物分配、蒸腾作用等<sup>[1]</sup>。但目前所有的作物模拟模型都有其优点和不足之处,如现已广泛应用的作物模型如 CERES、APSIM、ORYZA 等已经包括了气象、土壤、水分及氮肥的施用等重要因素<sup>[1]</sup>,但是只能也整合部分环境变量,杂草、病虫害、磷肥等田间因素制约作物生产时,这些环境因子目前还难以整合到作物机理模型中。神经网络模型就特别适用于生理生态学还难以揭示某些环境因子与作物相互作用机理的情况<sup>[2, 3]</sup>。

人工神经网络具有大规模并行、分布式储存和处理、自组织、自适应、自学习和容错性等特点,引起众多科学家的广泛关注,成为目前国际上非常活跃的前沿领域之一,在作物生产模型中作为一种非线性模拟算法也广为应用<sup>[2-5]</sup>。神经网络模型在农业中应用由于允许模糊变量、无需建立复杂的数学模型等优点而受到欢迎;但神经网络模型颇受争议之处是:神经网络模型是一种数据驱动(data-driven)的经验模型,即神经网络模型的模拟结果是对大量训练数据的抽象,具有较强的经验性,因而其外推性较差。针对神经网络模型的这个特点,本文试图以水稻分蘖动态的模拟为例,对人工神经网络模型的外推能力进行测试。

## 1 数据的来源及处理方法

### 1.1 数据来源

本研究的数据来自农业部跨越计划 4 个基点,湖南的湘潭、宁乡、华容和湖北的监利于 2000 年、2001 年以及宁乡点 2002 年对优质早稻中鉴 100 的苗情观测实验。实验分别在 4 个基点进行,实验采用软盘育秧,每亩本田 45 个塑盘,适时移栽。施肥采用 35%复合肥(N 16% : P<sub>2</sub>O<sub>5</sub> 6% : K<sub>2</sub>O 13%)750kg/hm<sup>2</sup>,于插秧前一次性施用。在田间采用随机区组排列,3 次重复。栽培密度为 16.67cm × 20cm,小区面积为 10m<sup>2</sup>,实验田四周设保护行,每穴插 4~5 株苗,病虫害防治以及其它管理措施与大面积丰产栽培相同。分蘖从返青后开始定点观察,每 3d 记录 1 次,4 个基点 3a 共得到 141 个分蘖动态数据。气象数据分别来自湘潭、宁乡、华容和监利气象站,分别计算有效积温( $T \geq 11^{\circ}\text{C}$ )、累积日照时间,计算累积温度满足度和累积日照满足度<sup>[6]</sup>。

### 1.2 数据处理方法

**1.2.1 群体茎蘖消长的 BP 网络模型** 适合的水稻茎蘖密度是水稻高产的重要指标之一。水稻茎蘖动态受多个因素的影响,包括:温度、光照、水分、土壤肥力、间距和栽培管理措施等。水稻栽培管理的重要目标之一是优化水稻分蘖数和穗数以达到最高产量<sup>[7]</sup>。根据不同的环境因子对水稻分蘖的影响,已有多个模型从不同的侧面对水稻分蘖动态进行模拟,如蒋德隆的积温统计模型<sup>[8]</sup>、王夫玉的基本动力学模型<sup>[9]</sup>和黄耀的复合模型<sup>[6]</sup>等。在本研究中水分和土壤肥力满足的条件下,温度和日照是影响水稻分蘖的重要因素。本研究建立了 3 个不同的神经网络模型对水稻分蘖动态进行了模拟。

误差逆传神经网络(Back-Propagation Artificial Neural Networks, BPANN)是常用的前馈型神经网络,在农业生态研究中应用较多<sup>[2-3]</sup>。现有的研究中多采用 3 层的神经网络进行模拟,由一个输入层、一到多个隐含层和一个输出层组成,一个 3 层的 BP 网络能模拟任何连续函数<sup>[4]</sup>,而且简单的神经网络不仅足以模拟任何连续函数,容易解释、训练速度快,产生过度吻合(overfitting)的可能性也较小<sup>[2, 3]</sup>。训练的样本数量一般的经验是:训练的样本数应该是网络权值(weight)数量的 5~10 倍,才不致样本数过少而导致模型的对训练数据<sup>[10]</sup>。根据以上规则,本文建立了 3 个神经网络模型:(1) 以有效积温为输入变量,以水稻分蘖数输出变量的积温-分蘖网络模型;(2) 以水稻移栽后天数为输入变量,以水稻分蘖数为输出变量的移栽天数-分蘖网络



模型,以上两个网络模型都是单变量的神经网络,结构都为 1-4-1;(3)以有效积温、移栽后天数和日照时数为输入变量,以水稻分蘖数为输出变量三变量分蘖网络模型,该网络模型的结构为 3-4-1。

神经网络模型可以采用标准的 BP 学习算法或其它的快速学习算法。在本研究中采用弹性逆传的优化学习算法<sup>[11]</sup>,并将网络预期逼近误差预定为 0.2,训练后对全部样本采用网络模型进行模拟实验。

1.2.2 水稻群体茎蘖消长的统计模型、基本动力学模型和复合模型 采用蒋德隆的积温统计模型和王夫玉的基本动力学模型和黄耀的水稻分蘖复合模型,比较神经网络模型的仿真能力。蒋德隆的积温统计模型<sup>[8]</sup>的表达式为:

$$y = a_0 + (a_f - a_0)e^{\frac{-c(d-T)^2}{T^2}}$$

(1)

式中, $T$  为有效积温, $y$  为分蘖密度, $a_0$  为移栽后的初始密度, $a_f$  为最大分蘖密度, $c$ 、 $d$  为模型参数。

王夫玉的基本动力学模型<sup>[9]</sup>为:

$$N = \frac{A}{1 + c_1e^{-b_1t}} + \frac{B}{1 + c_2e^{b_2t}} + C$$

(2)

式中, $N$  为水稻群体茎蘖数, $t$  为移栽返青后的天数, $c_1$ 、 $c_2$ 、 $b_1$ 、 $b_2$  和  $A$ 、 $B$ 、 $C$  为模型参数。

黄耀的分蘖复合模型较复杂,其主要原理是:在水稻拔节前,拟合日均温和日辐射量对水稻分蘖增长的作用;在水稻拔节后,拟合水稻光合产量对水稻分蘖消亡影响。该模型涉及对水稻生长的光合作用、呼吸作用、光合产物的分配、水分和土壤肥料等多个方面的模拟,但模型只有两个参数<sup>[6]</sup>。本研究中假定水分和土壤肥料都达到水稻分蘖的最佳条件。模型的模拟过程可参阅文献,本研究采用高亮之等的 RCSODS 模型进行拟合。3 个模型的参数都采用  $n$  维极值的复形调优法<sup>[12]</sup>求取。

1.2.3 模型的训练和测试 在模型应用时,通常需要一定数量的样本对网络进行训练和对训练后模型的模拟能力进行测试。神经网络模型通常采用交互验证(Cross validation)的策略进行训练和测试,即随机地把整个数据集分成两个部分,训练样本数和测试样本数的比例可为 1:1、2:1、3:1 等,前提条件是训练样本数要足以反映输入、输出变量之间的关系、测试样本数要能足以检验模型的模拟能力<sup>[13]</sup>。本研究中把数据随机按训练样本数和测试样本数“3:1(108:33)”的比例划分,该方法测试样本和训练样本的来源都是相同的。

为了研究模型的外推能力,研究还采用了另一种验证方法,即独立验证(Independent validation),按照该方法将来自宁乡、湘潭和华蓉的样本( $n=108$ )作为训练数据,将来自监利的样本( $n=36$ )作为试测数据。该方法测试样本和训练样本的来源是不同的,利用该方法可测试从来自宁乡、湘潭和华蓉数据中学习的原则,是否可应用于预测监利的水稻分蘖动态,即测试神经网络的外推能力。

1.2.4 模型的训练、仿真流程及实现 BP 网络的训练、仿真和作图采用 MATLAB 6.1 编程实现<sup>[11, 14]</sup>。调用 Neural Networks toolbox 中的函数模块完成 BP 网络的训练和仿真。网络训练的具体流程和原理可参考文献<sup>[11, 14]</sup>。水稻群体茎蘖消长的统计模型和基本动力学模型采用 C 语言编程进行求参、仿真。

为模型之间方便比较,本实验中的茎蘖数据都采用标准化进行处理,训练和模拟后进行还原,并计算实测值与模拟值间的相关系数及平均误差平方的平方根(root mean square error, RMSE)作为训练和模拟的标准<sup>[15]</sup>,由于神经网络训练和模拟的结果波动较大,本文报道训练数据和测试数据都最小的结果。

2 结果分析

2.1 单变量模型的训练及模拟

表 1 是 4 个单变量模型各数据集交互验证和独立验证的结果。表 1 的结果表明,在只受气象因子限制的情况下,用有效积温或移栽后返青天数作变量,预测水稻群体分蘖动态,4 个模型的 RMSE 值相似,表明神经网络模型与积温统计模型、基本动力学模型拟合能力相似。表 1 的结果也表明,不仅积温统计模型和基本动力学模型两种验证方式的 RMSE 结果相似,表明两个模型能够从来自宁乡、湘潭和华蓉数据中学习的原则,可应用于预测监利的水稻分蘖动态,即两个模型具有一定的外推能力,而且神经网络模型也有类似的结果,表明了神经网络模型也具有一定的外推能力。比较以积温为输入变量的两个模型和以移栽后天数为输入的两个模型,用有效积温作为输入变量积温统计模型和稍优于用移栽返青后天数的 BP 网络,可能由于有效积温与分蘖动态相关性更大。另外,积温-分蘖网络模型还是有轻微的过度吻合,因为独立验证的积温-分蘖网络模型要比交互验证的积温-分蘖网络模型测试数据的 RMSE 高 18.51%。

从图 1 中也可得到与表 1 相同的结果。图 1 中不同模型训练数据与模拟数据相混和,表明交互验证和独立验证的结果相似,也说明了神经网络模型与积温统计模型、基本动力学模型的模拟能力是相似的。

2.2 多变量的网络模型的训练与模拟

比较表 2 中复合分蘖模型与表 1 中的积温统计模型和基本动力学模型的 RMSE,可以看出复合分蘖模型比积温统计模型和基本动力学模型的模拟结果好。因为积温统计模型和基本动力学模型都只分别考虑一个因素对水稻分蘖的影响,而复合分蘖



表 1 单变量模型各数据集观测数据与模拟数据的决定系数与 RMSE

Table 1  $R^2$  and RMSE for subsets of observed data and estimated data

| 神经网络类型<br>Type of neural networks                     | 验证类型<br>Validation type | 整个数据集的决<br>定系数 $R^2$ of whole<br>data subset | 测试数据集的<br>RMSE RMSE of<br>testing subset | 训练数据集的 RMSE<br>RMSE of training<br>subset | 模型参数数目<br>The number of<br>parameters in model |
|-------------------------------------------------------|-------------------------|----------------------------------------------|------------------------------------------|-------------------------------------------|------------------------------------------------|
| 积温统计模型<br>Degree-day statistical model                | CV<br>IV                | 0.7883<br>0.7768                             | 83.52<br>98.96                           | 89.03<br>84.5                             | 2                                              |
| 积温-分蘖网络模型<br>Degree-day-tillering NN                  | CV<br>LV                | 0.8028<br>0.7974                             | 78.54<br>98.41                           | 83.67<br>79.31                            | 8                                              |
| 基本动力学模型<br>Basical Dynamics Model                     | CV<br>LV                | 0.7552<br>0.7534                             | 84.52<br>83.10                           | 92.72<br>94.64                            | 7                                              |
| 移栽后天数-分蘖网络模型<br>Days after transplanting-tillering NN | CV<br>IV                | 0.755<br>0.7534                              | 88.86<br>84.60                           | 91.50<br>94.36                            | 8                                              |

CV 交互验证 Cross validation;IV 独立验证 Independent validation




图 1 不同单变量模型模拟的水稻分蘖(茎蘖数/m²)动态观测值与模拟值的相关分析图

Fig. 1 Correlation graphs between observed and estimated data of rice tillering dynamics (tillers/m²) by different models

(a) 交互验证的积温-分蘖网络模型 from cross-validated degree-days-tillering NN; (b) 独立验证的积温-分蘖网络模型 from independent-validated degree-days-tillering NN; (c) 交互验证的积温统计模型 from cross-validated degree-days statistical model; (d) 独立验证的积温统计模型 from independent-validated degree-days statistical model; (e) 交互验证的移栽后天数-分蘖网络模型 from cross-validated days after transplanting-tillering NN; (f) 独立验证的移栽后天数-分蘖网络模型 from independent-validated days after transplanting-tillering NN; (g) 交互验证的基本动力学模型 from cross-validated basic dynamic model; (h) 独立验证的基本动力学模型; 图中点代表训练数据, 圆圈代表测试数据 from independent-validated basic dynamic model. Points stand for the samples from training data, and circles for the samples from testing data



模型涉及影响水稻分蘖的多个生态过程,因而能更精确地模拟水稻分蘖动态,而且该模型只有两个参数,需要用于求取模型参数的样本数也小。另一方面,比较交互验证和独立验证的复合分蘖模型,可以看出独立验证的复合分蘖模型测试数据的 RMSE 比独立验证的复合分蘖模型测试数据的 RMSE 高 26.14%,表明复合分蘖模型也存在轻微的过度吻合。复合分蘖模型轻微的过度吻合可能主要来自于实验点特异条件对分蘖动态的影响。本研究中的复合分蘖模型中没有模拟对水稻分蘖影响较小的因素,如水分、土壤中肥料等对分蘖动态影响较小的模型,只模拟影响水稻分蘖的主要生态过程。模型的简化意味取系统的平均行为<sup>[3]</sup>。所以交互验证模型能从 4 个实验点的训练数据学习到四个点的特异条件来拟合四个点水稻分蘖动态;但是独立验证的模型只能从其它 3 个点学习到的原则,来拟合监利点的分蘖动态,因此轻微的过度吻合是不可避免的。比较图 1a 和图 1b 也可得出相同的结论。




图 2 不同多变量模型模拟的水稻分蘖(茎蘖数/m<sup>2</sup>)动态观测值与模拟值的相关分析图

Fig. 2 Correlation graphs between observed and estimated data of rice tillering dynamics (tillers/m<sup>2</sup>) by different models

(a) 交互验证的复合分蘖模型 from cross-validated composite model; (b) 独立验证的复合分蘖模型 from independent-validated composite model; (c) 交互验证的三变量网络模型 from cross-validated three-variables NN; (d) 独立验证的三变量网络模型。图中点代表训练数据,圆圈代表测试数据 from independent-validated three-variables NN. Points stand for the samples from training data, and circles for the samples from testing data

表 2 多变量模型各数据集观测数据与模拟数据的决定系数与 RMSE

Table 2 R<sup>2</sup> and RMSE for subsets of observed data and estimated data

| 分蘖模型<br>Tillering Models                                  | 验证类型<br>Validation type | 整个数据集的决<br>定系数 R <sup>2</sup> of whole<br>data subset | 测试数据集的<br>RMSE RMSE of<br>testing subset | 训练数据集的 RMSE<br>RMSE of training<br>subset | 模型参数数目<br>The number of<br>parameters in model |
|-----------------------------------------------------------|-------------------------|-------------------------------------------------------|------------------------------------------|-------------------------------------------|------------------------------------------------|
| 复合分蘖模型<br>Synthetical tillering Model                     | CV                      | 0.823                                                 | 69.66                                    | 80.21                                     | 2                                              |
|                                                           | IV                      | 0.82                                                  | 87.87                                    | 76.54                                     |                                                |
| 三变量分蘖动态网络模型<br>Tillering NN with three variables as input | CV                      | 0.864                                                 | 71.18                                    | 67.67                                     | 16                                             |
|                                                           | IV                      | 0.786                                                 | 127.81                                   | 67.97                                     |                                                |

CV 交互验证 Cross validation; IV 独立验证 Independent validation

神经网络的主要优点是能采用神经元之间相互作用来模拟影响作物生长各因子的复杂相互作用,因此无需用复杂的数学式来描述因子间的相互作用,就能对输入的多变量样本进行训练和模拟<sup>[13]</sup>。三变量的网络模型采用训练样本的有效积温、累计日辐射量和移栽返青后天数-分蘖数据样本训练网络,由于网络考虑的因素较多,接近实际情况,但同时也是由于神经网络的结构转为 3-4-1,网络增加了两个神经元,结构变大,网络参数增加(表 2),导致网络的学习能力增加所致。比较三变量分蘖网络模型与表 1 中的两个模型,独立验证的三变量分蘖网络模型要比独立验证的积温-分蘖统计模型、移栽后天数-分蘖统计模型相应训练数据和测试数据的 RMSE 低,表明三变量分蘖网络模型的拟合能力要比积温-分蘖统计模型、移栽后天数-分蘖统计模型好。另一方面,独立验证的三变量分蘖网络模型测试数据的 RMSE 比交互验证的三变量分蘖网络模型测试数据的 RMSE 增加了 79.56%。表明采用三变量分蘖网络模型来预测水稻分蘖动态时,过度吻合严重。当神经网络的输入变量增加时,网络的神经元和网络的参数也相应增加(表 2),网络相应所要求的训练样本数也大大增加,导致网络模型的过度吻合,所以使用神经网络时,应充分考虑网络大小与训练样本数之间的关系。根据已经的研究经验,训练数据的样本数应是神经网络参数数目的 5-10 倍<sup>[10]</sup>。但三变量分蘖网络模型训练数据是网络的参数 6.75 倍,尚不足满足网络模型的要求,克服过度吻合的问题。

3 讨论

本研究中,交互验证的神经网络模型都比相应的算法模型如积温统计模型、复合分蘖模型等的拟合能力好,这可能主要是因为神经网络模型比相应的算法模型参数要多<sup>[16]</sup>。较少的模型参数是算法模型的优点,因为较少的模型参数只需要少量的样本来求取参数,这大大地增加了算法模型的可应用性<sup>[16]</sup>。因此,考虑到算法模型只有较少的模型参数,本研究中积温统计模型、



复合分蘖模型的拟合能力是较高的。另外,从本研究可看出,神经网络模型在进行作物模拟研究时,显示了以下优点:(1)方法简单,无需建立各种复杂的数学模型。用一种模型就可拟合作物生长的多个生理生态过程,而且拟合效果也和统计模型、动力学模型等大致相同。这就给作物模拟研究的科学工作者提供了一个“傻瓜相机”,无需复杂的数学建模知识,用已有的实验训练网络模型,就可以用于仿真实验。(2)经过训练的人工神经网络存贮了专家知识、经验和推理机制,特别适合于受多因素影响,且各因素之间的关系不清楚的作物生长发育过程进行模拟。

神经网络模型主要依赖训练数据集的内部结构,而不是基于所模拟生态过程的理解,因此通常认为神经网络模型是不具有外推能力的经验性模型<sup>[2,3]</sup>。在本研究中,采用交互验证和独立验证的方法,比较了神经网络模型和几种相应的算法模型对水稻分蘖动态拟合能力的研究表明:神经网络模型和算法模型一样,具有一定的外推能力。但是神经网络模型与算法模型比较有更多的参数,因此需要大量的样本来获取具有外推能力的训练结果和测试网络模型的拟合能力。较少的样本数来训练神经网络容易使网络模型对训练数据产生过度吻合,如本研究中的三变量分蘖网络模型。本研究中的积温-分蘖网络模型、移栽后天数-分蘖网络模型的训练样本数是神经网络参数数目的 13.5 倍,三变量分蘖网络模型的神经网络参数数目的 6.75 倍,因此,具有外推能力的神经网络模型的最少训练样本数应大于 6.75 倍于神经网络参数数目,小于 13.5 倍于神经网络参数数目。因此在应用神经网络模型时,应当尽可能采用较小的网络结构;如果神经网络模型包括大量的输入变量时,可考虑采用主成分分析、对应分析等技术对输入变量进行信息综合<sup>[11]</sup>,一方面可综合训练数据的大部分信息,另一方面可减少输入神经元而相应地减少网络模型的参数。当训练样本不足时,最好只用神经网络模型对同一系统的情况进行模拟,即交互验证;应谨慎使用神经网络模型进行外推<sup>[17]</sup>。神经网络模型需要大量的训练样本来保证其参数不致于过度吻合,这也妨碍了神经网络模型的广泛应用。

人工神经网络是一门新兴的技术,特别近年来在农业生态研究发展较快,它的以上优点使它在作物模拟研究中有广泛的前景,另一方面,在这些网络模型中,有很多未成熟和尚待完善的地方,网络技术也期待农业研究去完善它们。对数学建模不熟悉的农业研究人员,人工神经网络可以替代数学建模进行仿真实验;对于精通数学建模的研究人员来说,它至少是一种补充和可作为比较的非线性数据处理方法。

#### References:

- [1] Yang J P, Wang Z Q. Crop growth simulation model and its application. *Chinese Journal of Applied Ecology*, 1999, **10**(4):501~505.
- [2] Schultz A, Wieland R. The use of neural networks in agroecological modeling. *Computers and electronics in agriculture*, 1997, **18**,73~90.
- [3] Schultz A., Wieland R, Lutze G.. Neural networks in agroecological modeling-stylish application or help tool? *Computers and electronics in agriculture*, 20002, **9**, 73~97.
- [4] Wang, Y N. *Computational intelligent information Processing: Technology and Applications*. Changsha: Press of Hunan University, 1998. 155~200.
- [5] Hu, S R, Yu S B, Dai K. *An introduction of artificial neural networks*. Changsha: Press of National Defensive Technology University, 1993, 10~135.
- [6] Huang Y, Gao L Z, Jing Z Q. Simulation model of tillering Dynamics of rice community. *Chinese Journal of Ecology*, 1994, **13**(4):27~32.
- [7] Zou Y B, Tang Q C, Hu C Q, et al. Dynamic simulation for rice growth and yield II. The comparison and application of rice tillering statistical models. *Crop Research*, 1991, **5**(4):18~22.
- [8] Jiang D L. The model of relations of rice tillering to light and temperature conditions. *Acta Botanica Sinica*, 1982, **24**(3):247~251.
- [9] Wang F Y, Huang P S. Study on basic dynamic model for stem and tiller growth and population classification in Rice. *Scientia Agricultura Sinica*, 1997, **30**(1):57~64.
- [10] Goh A T, Back-propagation neural networks for modeling complex systems. *Artificial intelligence in engineering*, 1995, **9**, 143~151.
- [11] Demuth H, Beale M. *Neural Network Toolbox*. For Use with MATLAB. The MathWorks, Inc, Natick, 2001. 31~120.
- [12] Xu S L. *Collection of C programs in common use, The 2<sup>nd</sup> edition*. Qinghua University Press, Beijing, 1996. 258~261.
- [13] Lek S, Guégan J F. Artificial neural networks as a tool in ecological modeling, an introduction. *Ecological Modelling*, 1999, **120**, 65~73.
- [14] Lou S T, Shi Y. *Artificial neural network—The systematical analysis and design based on MATLAB*. Xi'an University of electronic technology, Xi'an, China, 1999. 11~128.
- [15] Marsili-Libelli S. Parameter estimation of ecological models. *Ecological Modelling*, 1992, **62**, 233~258.
- [16] Van Wijk M T, Bouten W, Verstraten J M. Comparison of different modeling strategies for simulating gas exchange of a Douglas-fir forest. *Ecological Modelling*, 2002, **158**:63~81.
- [17] Borner I, Comstock C R. Combining expert systems and neural networks for learning site-specific conditions. *Computer and electronics in Agriculture*, 1997, **19**:37-53.

#### 参考文献:

- [1] 杨京平,王兆骞.作物生长模拟模型及其应用.应用生态学报,1999, **10**(4):501~505.
- [4] 王耀南.计算机智能信息处理技术及其应用.长沙:湖南大学出版社,1998,55~200.
- [5] 胡守仁,余少波,戴葵.神经网络导论.长沙:国防科技大学出版社,1993,10~35.
- [6] 黄耀,高亮之,金之庆.水稻群体分蘖动态的计算机模拟模型.生态学杂志,1994, **13**(4):27~32.
- [7] 邹应斌,唐秋澄,胡昌启,等.水稻苗情动态计算机模拟 II.水稻叶蘖生长的统计模式及应用.作物研究,1991, **5**(4):18~22.
- [8] 蒋德隆.水稻分蘖与光、温条件的统计模式.植物学报,1982, **24**(3):247~251.
- [9] 王夫玉,黄丕生.水稻群体茎蘖消长模型及群体分类研究.中国农业科学,1997, **30**(1):57~64.
- [12] 徐士良主编.C常用计算机程序集,第2版.北京:清华大学出版社,1996.258~261.
- [14] 楼顺天,施阳编著.基于 MATLAB 的系统分析与设计——神经网络.西安:西安电子科技大学出版社,1999.11~128.