

# 谷氨酸发酵过程的神经网络模拟预测模型

蔡煜东<sup>1</sup> 陈常庆<sup>2</sup> 周斌<sup>2</sup>

(中国科学院上海冶金研究所 上海 200050)<sup>1</sup>

(中国科学院上海生物工程研究中心 上海 200233)<sup>2</sup>

人工神经网络是八十年代迅速兴起的一门非线性科学, 它力图模拟人脑的一些基本特性, 如自组织性、自适应性和容错性能等, 已在模式识别、数据处理和自动化控制等方面得到了初步应用, 取得了很好的效果<sup>[1]</sup>。

本文根据上海某味精厂某发酵罐的一批批报数据, 利用人工神经网络的一典型模型—“反向传播”模型, 初步尝试了神经网络模拟预测方法的效果, 有关这方面的研究工作尚未见报道。

## 1 材料和方法

### 1.1 数据来源

本文所用数据来自上海某味精厂某发酵罐的一批批报数据。

### 1.2 人工神经网络模型—“反向传播”模型

“反向传播”模型的结构和学习算法可参阅。文献 [1]

## 2 结果与讨论

### 2.1 B-P 模型应用于谷氨酸发酵过程模拟预测

尽管谷氨酸发酵过程中状态变量有十几个, 但对预测而言, 最重要的变量取三个就够了, 它们是: 菌体浓度  $X$ 、基质浓度  $S$  和产物浓度  $P$ 。由于长菌过程在 18 小时已基本完成, 因此, 用 18 小时前的数据建立神经网络模型。分别建立预测菌体浓度  $X$  的网络模型 I, 基质浓度  $S$  的神经网络模型 II, 产物浓度  $P$  的神经网络模型 III。

2.1.1 菌体浓度  $X$  的神经网络预测模型 I: 以长菌过程的 15 个样本 (1 小时作 1 次记录, 一次记录为 1 个样本, 0、1、6 和 7 小时的记录不全, 未用, 下同) 作为神经网络的“学习”教材, 以时间  $t$  作为输入, 浓度  $X$  作为输出, 神经网络的隐蔽层含 5 个神经元。网络的收敛误差达  $10^{-4}$ 。经过学习, 神经网络能较为精确地拟合这些样本, 其最大相对误差不超过 1.14% (表 1), 建立了菌体生长过程复杂的非线性模型。

为了考验所建立的模型, 对 19 小时至 25 小时的菌体生长过程 (即未参加训练的 6 个样本, 22 小时的数据不全, 未用, 下同), 由已掌握了知识信息的神经网络对其进行预测, 由表 2 可见, 其最大相

表 1 神经网络拟合结果<sup>\*</sup>

总时间 $t$ (小时)	菌体浓度 $X$ (实测)	菌体浓度 $X$ (拟合)
2.0	0.32	0.322886
3.0	0.35	0.346122
4.0	0.36	0.360125
5.0	0.4	0.400005
8.0	0.74	0.739854
9.0	0.78	0.780420
10.0	0.82	0.819232
11.0	0.85	0.850817
12.0	0.86	0.861635
13.0	0.87	0.865377
14.0	0.87	0.872922
15.0	0.89	0.888842
16.0	0.9	0.897805
17.0	0.9	0.899702
18.0	0.9	0.900000

表 2 神经网络预测结果<sup>\*</sup>

总时间 $t$ (小时)	菌体浓度 $X$ (实测)	菌体浓度 $X$ (预测)
19.0	0.9	0.900051
20.0	0.9	0.900051
21.0	0.9	0.900052
23.0	0.9	0.900052
24.0	0.9	0.900052
25.0	0.9	0.900052

本文于 1994 年 9 月 17 日收到。

对误差不超过 0.0058%，可见，神经网络模型的预测精度较高。

表 3 神经网络拟合、预测结果<sup>\*</sup>

拟合：	总时间	菌体	产物	基质浓度	基质浓度
	$t$ (小时)	浓度 $X$	浓度 $P$	$S$ (实测)	$S$ (拟合)
	2.0	0.32	0.15	12.20	12.153863
	3.0	0.35	0.1	12.20	12.137078
	4.0	0.36	0.03	12.1	12.103787
	5.0	0.4	0.11	12.1	12.060780
	8.0	0.74	0.22	11.1	11.228970
	9.0	0.78	0.4	10.6	10.763846
	10.0	0.82	0.69	10.3	10.113513
	11.0	0.85	0.88	10.0	9.886224
	12.0	0.86	1.11	9.0	9.030878
	13.0	0.87	1.44	8.5	8.490358
	14.0	0.87	1.84	8.0	8.014496
	15.0	0.89	2.04	7.3	7.375034
	16.0	0.9	2.32	6.8	6.820084
	17.0	0.9	2.53	6.3	6.427772
	18.0	0.9	2.86	5.85	5.947618
预测：	总时间	菌体	产物	基质浓度	基质浓度
	$t$ (小时)	浓度 $X$	浓度 $P$	$S$ (实测)	$S$ (拟合)
	19.0	0.9	3.19	5.45	5.157246
	20.0	0.9	3.36	5.10	4.973957
	21.0	0.9	3.62	4.6	4.325464
	23.0	0.9	4.01	3.93	3.713037
	24.0	0.9	4.24	3.64	3.418308
	25.0	0.9	4.62	2.8	2.914689

2.1.2 基质浓度  $S$  的神经网络模型 I：在谷氨酸发酵过程中，基质（主要成分为葡萄糖）的消耗可大致划分为长菌消耗（与  $X$  相关）和产酸消耗（与  $P$  相关）两大部分。虽然菌体呼吸也要消耗大量的基质，但可将其归结在长菌消耗之内。与 I 中类似，以长菌过程的 15 个样本作为训练集，以时间  $t$ 、菌体浓度  $X$ 、产物浓度  $P$  作为输入，基质浓度  $S$  作为输出，隐蔽层含 18 个神经元。训练结束后，训练集的收敛度达 0.15%，其最大拟合相对误差不超过 1.85%，见表 3。

对 18 小时后的过程的预测从表 3 可知，神经网络模型的模拟精度较高，最大相对误差不超过 5.8%。

2.1.3 产物浓度  $P$  的神经网络模型 II：与 I 中类似，亦以长菌过程的 15 个样本作为学习集，以时间  $t$ 、菌体浓度  $X$ 、基质浓度  $S$  作为输入，产物浓度  $P$  作为输出，隐蔽层含 18 个神经元。训练结束后，训练集的收敛度达 0.14%，其最大拟合相

表 4 神经网络拟合、预测结果<sup>\*</sup>

拟合：	总时间	菌体	基质	产物浓度	产物浓度
	$t$ (小时)	浓度 $X$	浓度 $S$	$P$ (实测)	$P$ (拟合)
	2.0	0.32	12.20	0.15	0.143140
	3.0	0.35	12.20	0.1	0.096813
	4.0	0.36	12.1	0.03	0.028067
	5.0	0.4	12.1	0.11	0.105534
	8.0	0.74	11.1	0.22	0.228703
	9.0	0.78	10.6	0.4	0.414252
	10.0	0.82	10.3	0.69	0.698431
	11.0	0.85	10.0	0.88	0.891074
	12.0	0.86	9.0	1.11	1.145868
	13.0	0.87	8.5	1.44	1.397667
	14.0	0.87	8.0	1.84	1.886025
	15.0	0.89	7.3	2.04	1.997096
	16.0	0.9	6.8	2.32	2.292498
	17.0	0.9	6.3	2.53	2.532733
	18.0	0.9	5.85	2.86	2.798983

\* 表 1—4 中  $X$ 、 $S$  单位： $\times 10 \text{ mg/ml}$ ， $P$  单位： $\text{mg/ml}$

对误差不超过 5.0%，对 18 小时后的过程的预测最大相对误差不超过 6.8%，见表 4。

## 2.2 神经网络的容错能力

神经网络模型中，知识信息采取分布式存储，个别单元损坏不会引起错误，因此用神经网络进行预报识别容错能力强，可靠性高。本研究中，不失一般性，以模型Ⅱ为例，将神经网络的最后一个隐节点（隐蔽层第 11 个神经元）删去，所得到的神经网络模型记为模型 B，原来的模型记为模型 A，对“未知”样本的预测见表 5。

## 2.3 预测速度快

训练好的神经网络在对“未知”样本进行预报时仅需作少量的加法和乘法，因此预报速度快。如果做成专用硬件或用并行机进行数据处理则速度更快。

综上所述，随着人工神经网络理论的进一步发展，可望开辟发酵过程预测的新途径。

表 4 续

预测: $t$	总时间 (小时)	菌体 浓度 X	基质 浓度 S	产物浓度 $P$ (实测)	产物浓度 $P$ (预测)
	19.0	0.9	5.45	3.19	3.067416
	20.0	0.9	5.10	3.36	3.134266
	21.0	0.9	4.6	3.62	3.415113
	23.0	0.9	3.93	4.01	4.130710
	24.0	0.9	3.64	4.24	4.371865
	25.0	0.9	2.8	4.62	4.646616

表 5 个别神经元损坏对网络性能的影响

神经网络 B 的预测结果	神经网络 A 的预测结果
5.138334	5.157246
4.937378	4.973957
4.303247	4.325464
3.683783	3.713037
3.383278	3.418308
2.883278	2.914689

## 参 考 文 献

- (1) 尹红风, 戴汝为. 模式识别与人工智能, 1990, 3 (1) : 1.
- (2) 高以成等. 信息与控制, 1985, 2 (1) : 1.
- (3) R. Hecht-Nielsen "Theory of the Backpropagation Neural Network", Int. J. Conf. on Neural Network, Washington D. C. June 1989.
- (4) Lippmann R P. "An introduction to computing with Neural Network", IEEE ASSP Magazine, 1987, 4—22.
- (5) 叶开明等, 生物工程学报, 1993, 9 (3) : 61.

## The Neural Network Model for Predicting the Process of Fermentation

Cai Yudong<sup>1</sup> Chen Changqing<sup>2</sup> Zhou Bin<sup>2</sup>

(Shanghai Institute of Metallurgy, Academia sinica, Shanghai 2000050)<sup>1</sup>

(Shanghai Research Centre of Biotechnology, Shanghai 200233)<sup>2</sup>

**Abstract** The back-propagation model which is one of the typical artificial neural network models was applied to establish the mathematical model for simulation and predication of process of glutamic acid fermentation on the basis of the data of fermenter (No. 1501) in one glutamic factory. The results indicated that the performance of the network is good, and therefore it might be referred as an effective assistant technique for simulation and predication of process of fermentation.

**Key words** Glutamic acid, artificial neural network, process of fermentation, back-propagation model