

文章编号: 1009-038X(2000)06-0547-05

酵母流加发酵过程中模糊神经网络的优化

未作君, 苗志奇, 元英进

(天津大学化工学院生化工程系, 天津 300072)

摘要: 利用模糊神经网络构建了酵母流加发酵过程的网络模型. 通过建立优化子网络, 探讨了不同时刻的最佳底物浓度. 在模拟网络的基础上, 利用遗传算法对流加策略进行了优化研究.

关键词: 模糊神经网络; 酵母发酵; 优化; 流加发酵; 遗传算法

中图分类号: TQ929

文献标识码: A

Fuzzy Neural Network Optimization for Yeast Fed-Batch Process

WEI Zuo-jun, MIAO Zhi-qi, YUAN Ying-jin

(Biochemical Engineering Department, Tianjin University, Tianjin 300072)

Abstract: A fuzzy neural network was founded to simulate the process of yeast fed-batch fermentation. By making the optimal sub-network, the favorite substrate concentration during different periods was studied. On the basis of the analog network, the genetic algorithm is proposed to optimize the fed-batch strategy.

Key words: fuzzy neural network; yeast fermentation; optimization; fed-batch fermentation; genetic algorithm

流加发酵过程具有高度非线性、时变性和不确定性等特点, 且影响因素众多, 数据准确性较差, 因此建立可靠的模型显得非常困难. 要实现流加量的最优控制, 必须通过发酵过程的模拟、优化来获取. 人工神经网络作为一种全新的系统分析工具, 能够通过训练自适应来拟合系统行为, 因而在生物发酵过程中得到了广泛应用.

过程模拟中最常用的是 BP 网络, 但训练时间长, 预测精度难于估计. 而模糊神经网络作为一种新型网络, 实现了网络节点的功能分化, 改善了网络的局域性, 提高了网络训练速度与网络预测精度^[1]. 采用一种新型的模糊神经网络来模拟流加发酵过程. 在模拟网络基础上一方面引入优化子网

络, 进行最佳底物浓度的优化研究, 另一方面引入遗传算法, 探讨了最优的底物流加策略.

1 实验部分

数据取自本实验室酵母流加发酵实验. 采用 NBS 发酵罐, 工作体积为 5 L, 进行了酵母间歇与流加发酵实验. 实验装置如图 1 所示.

实验的最终目的是建立控制底物流加的模糊神经网络控制器, 以实现底物(葡萄糖)的自动流加, 获得最大量的酵母菌体. 作者建立了发酵过程的模糊神经网络模型, 进行过程优化, 为控制器的设计提供数据.

实验过程中, pH 值采用流加方式自动控制在

收稿日期: 2000-01-24; 修订日期: 2000-10-10.

基金项目: 国家自然科学基金项目资助课题(29476248); 国家教委“跨世纪优秀人才培养计划”基金项目资助课题

作者简介: 未作君(1975-), 男, 湖北武汉人, 生化工程博士研究生.

6.4±0.1附近, DO值采用自动调整搅拌转速调节, 维持DO值在80, 消除溶氧限制。

菌体密度采用721分光光度计测量, 糖浓度采用经典DNS法测量. 流量数值表征蠕动泵开停比。

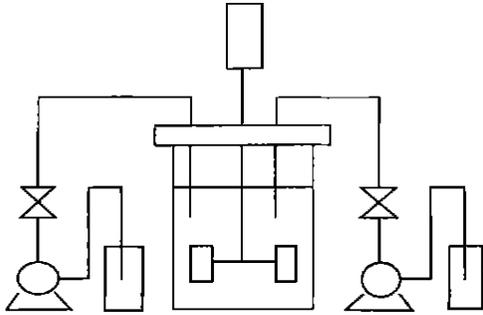


图1 酵母间歇和流加发酵实验装置

Fig. 1 The sketch map of batch and fed-batch fermentation system

2 模拟、优化系统模型

整个系统由模拟子网络(A)、优化(B)两个子网络与遗传算法(C)构成, 如图2所示. 模拟子网络作为发酵过程的数学模型, 即菌体生长的动力学模型; 以模拟子网络为基础, 优化子网络可以进行单变量优化, 获取培养基的最优组成曲线及最优接种量. 利用将模拟网络输出计算出评价函数数值, 遗传算法可以进行多阶段优化, 求取最优流加曲线。

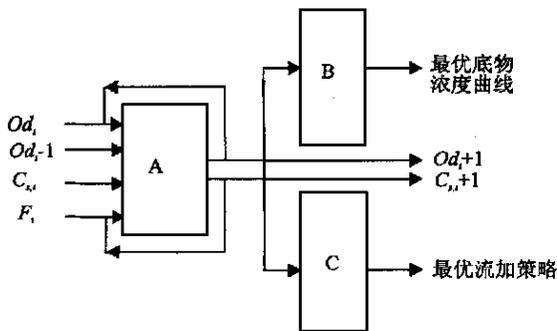


图2 酵母发酵模拟、优化系统结构图

Fig. 2 The structure of yeast fermentation simulation and optimization system

2.1 用于流加发酵过程模拟的模拟子网络

作者采用一种新型模糊-神经网络作为模拟网络. 该网络特点如下:

1) 将模糊语言词层与规则层合并, 为自由调整模糊子空间数目提供了可能。

2) 采用均匀设计的方法进行模糊子空间设计, 使模糊空间在整个输入空间上均匀分布, 以提高子空间的代表性。

3) 采用并联BP子网络结构, 以改善网络的区域性, 提高网络训练速度; 增加网络定量计算能力, 提高预测精度。

采用窗口网络形式, 当前时刻与前一时刻的菌体密度同时作为网络输入, 网络的模糊推理^[5]过程可用向量式表示如下:

$$\text{if } x \in A_i \text{ then } y = f_i(x) \quad i=1, 2, \dots, L \quad (1)$$

为了进一步说明该模糊神经网络的结构, 现将网络结构绘于图3. 从图中可以看出, 整个网络的主网分为4层, 分别为图中的A、B、E、F层, 其中A层为输入层, B层为模糊分类层, E层为加和层, F层为输出层. 图中G为子网, 子网分为两层. 子网中C层为子网隐含层, D层为子网输出层. 同上所述, 子网的个数与图中B层的节点数目相同, 图中的B层与C层的节点数目可由用户自行设定。

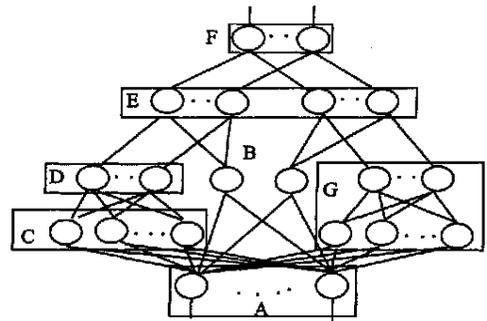


图3 可调整模糊-神经网络结构

Fig. 3 The topology of adjustable fuzzy-neural network

当输入信号进入网络后, 首先进入模糊分类层, 分类层输出信号表示的是该输入对当前节点所代表的子空间的隶属度. 隶属度作为一种导向信号, 决定了各子空间所对应的BP子网络的激活抑制程度。

由于实验中消除了pH、DO的影响, 因而在模型输入输出变量中不再出现. 考虑到菌体生长较底物吸收的时间常数大得多, 采用循环式窗口网络形式, 将上一时刻的菌体密度引入作为网络输入变量. 网络输入输出变量如表1所示. 网络参数如表2所示。

表1 系统输入输出变量的选取

Tab. 1 The input and output variables of the system

状态参数	操作参数	I/O
Od_{t-1}		I
Od_t		I
F_t		I
$C_{g,t}$		I
	Od_{t+1}	O
	$C_{g,t+1}$	O

表 2 网络具体结构

Tab. 2 The topology of network and node transformation function

网络层	节点数目	转换函数
网络输入层	4	线性函数
分类层	4	高斯函数
子网隐含层	6×4	双曲正切函数
子网输出层	2×4	双曲正切函数
网络输出层	2	线性函数

2.2 用于最佳底物浓度优化的优化子网络

优化子网络采用两层的对应线性联结网络, 如图 4 所示. 优化目标选为下一个时刻的酵母密度. 优化子网络的权重分为优化初始权重、固定权重、优化权重 3 类: 依靠优化权重的调节实现过程优化.

优化子网络的输出信号及其调整可表示如式 (2) ~ (6) 所示:

$$\Delta O_i = \Delta W_i * \text{const} \quad (2)$$

$$O_i = W_i * \text{const} + V_i \quad (3)$$

$$W_i^{t+1} = W_i^t + \Delta W_i \quad (4)$$

$$O_i^{t+1} = O_i^t + \Delta W_i * \text{const} \quad (5)$$

$$\Delta W_i^{t+1} = \alpha * \Delta W_i^{t-1} - (1 - \alpha - \beta) * \frac{\partial (y - \hat{y})}{\partial W_i} + \beta * \Delta W_i^t \quad (6)$$

在实际应用中, 优化子网络与模拟子网络合二为一, 结合成一个复合网络, 以完成整个优化过程. 因此整个复合网络的运行可分为训练、预测、优化 3 个阶段, 前两个阶段由模拟网络单独完成. 在优化阶段, 固定模拟网络中的所有权重, 利用优化算法调整优化权重, 实现优化过程. 优化子网络结构图见图 4.

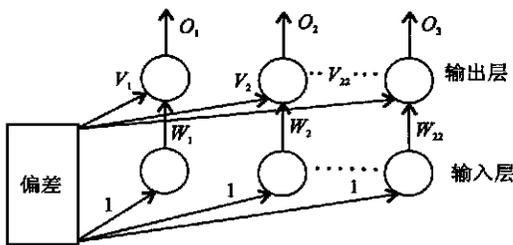


图 4 优化子网络结构图

Fig. 4 The topology of optimization sub-network

引入优化子网络的一个优点是可以训练算法作为优化算法, 减少了编程工作量. 与常规优化算法不同, 训练算法需要训练样本. 上述优化子网络的特殊结构恰好可提供这个样本. 优化初始权重提供优化子网络的输入信号, 输出信号定为优化目标

的期望值. 训练算法调整优化子网络的优化权重, 进而改变模拟网络的输入信号, 使整个复合网络的输出信号向着优化期望值靠近. 当复合网络的输出信号不再变化时, 优化过程终止. 此时对应的模拟网络输入信号即为最优输入信号, 对应模拟网络输出信号为过程最优值.

2.3 用于流加策略优化的遗传算法

利用循环网络作为模拟网络, 所以流加量优化问题成为一个多阶段动态规划问题. 因此采用优化网络求取的各时刻最优流加量对于整个发酵过程来说并不是最优流加策略.

由于采用网络模型进行过程模拟, 难于给出显式的状态方程. 因此难于利用动态规划的基本方程求解. 作者将多阶段优化问题转化为多变量优化问题求解. 这种转化必然导致优化变量维数的增加. 在众多的多变量优化方法中, 遗传算法在解决高维优化问题、避免局部最优值及优化速度方面具有相当优势.

遗传算法是生物进化的模拟算法. 生物进化的物质基础是基因重组与基因突变, 外在动力是环境的自然选择, 优胜劣汰. 遗传算法是通过数据点的重组与突变, 产生新的数据点. 同时引入淘汰机制, 删除与优化目标相违背的数据点, 实现数据的优胜劣汰.

遗传算法的目的是寻找最优的流加策略. 具体由以下几步构成:

- 1) 随机的产生一定数量的优化起始点. 每一个数据点都由发酵期内各时刻的流加量构成.
- 2) 确定优选概率函数和突变概率.
- 3) 将各优化起始点作为模拟子网络的各时刻的流加量输入网络, 求取 2 d 后相应的网络输出值.
- 4) 利用网络输出值计算优选概率, 模拟网络输出值越大, 优选概率值越大.
- 5) 按照优选概率随机地从现有的数据点中取出两个数据点, 优选概率高的数据点被选中的可能性大.

$$\{F_1^1, F_2^1, \dots, F_6^1, F_7^1, \dots, F_{12}^1\} + \{F_1^2, F_2^2, \dots, F_6^2, F_7^2, \dots, F_{12}^2\} \rightarrow \begin{cases} \{F_1^1, F_2^1, \dots, F_6^1, F_7^2, \dots, F_{12}^2\} \\ \{F_1^2, F_2^2, \dots, F_6^2, F_7^1, \dots, F_{12}^1\} \end{cases} \quad (7)$$
- 6) 将选中的两个数据点进行类似基因重组的数据重组. 形成两个新的数据点. 加入到原有数据点中.
- 7) 按突变概率决定现有数据点是否发生基因突变, 若发生则随机取一数据点, 随机变更任一坐标值.

$$\{F_1^i, F_2^i, \dots, F_{12}^i\} \rightarrow \{F_1^i, \dots, F_{i-1}^i, \alpha \times F_i^i, F_{i+1}^i, \dots, F_{12}^i\} \quad (8)$$

8) 计算新数据点的网络输出与优选概率。

9) 按照优选概率随机地选出与新增数据点数目相同的数据点, 然后删除这些数据点, 以维持数据点个数的恒定。

10) 返回3)重复执行, 指导找到满意的优化点和优化值为止。

其中步骤4、5实现基因重组功能, 步骤6、7实现基因突变功能, 步骤7实现自然选择功能。

3 结果与讨论

3.1 实验结果

实验中随着糖质量浓度的变化, 菌体生长速度随之发生变化。在间歇操作中, 糖浓度不断下降, 由于糖的缺乏, 菌体对数期较短。相反在流加操作中, 底物可以随时加入以补充消耗量, 糖浓度在一个较长的时间内保持稳定, 菌体的对数生长期时间较长。两种不同操作的葡萄糖与菌体的时变曲线如图5、6所示。

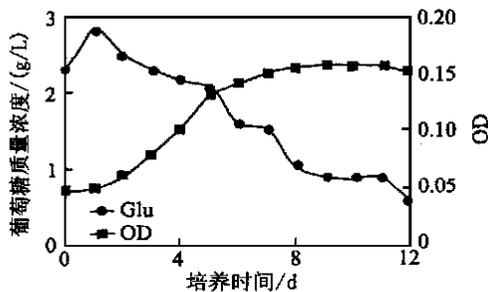


图5 间歇发酵过程时变曲线

Fig. 5 The dynamic curve of glucose concentration and yeast density in batch fermentation

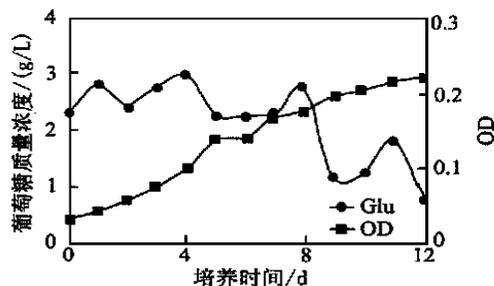


图6 流加发酵过程时变曲线

Fig. 6 The dynamic curve of glucose concentration and yeast density in fed batch fermentation

3.2 模拟结果

当网络训练误差达到1%, 取未经网络训练的几组数据进行预测, 在给定的过程初值与流加条件下, 进行网络循环计算, 预测葡萄糖浓度和酵母菌

菌体密度的时变曲线, 预测曲线与实验实测曲线对照结果绘于图7、8。从中可看出预测结果显示了较高的预测精度, 完全可以满足模拟、预测的需要。

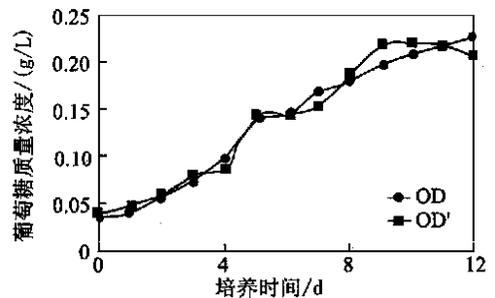


图7 葡萄糖质量浓度的网络预测曲线与实测曲线的比较

Fig. 7 The comparison of predicted model and experimental curves of glucose concentration

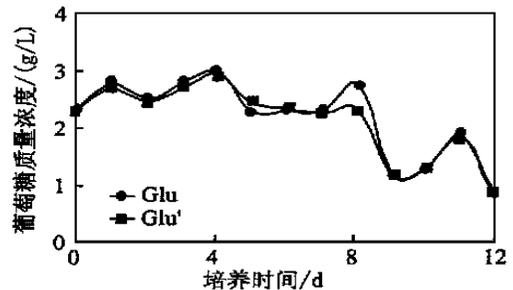


图8 菌体浓度的网络预测曲线与实测曲线的比较

Fig. 8 The comparison of predicted model and experimental curves of yeast density

3.2.1 单变量优化与最优的底物浓度曲线

在进行优化时, 若规定优化权重中只有一个可调, 而固定其余优化权重, 则此时的优化称为单变量优化。研究该可调优化权重变化时, 模拟网络输出信号的变化, 可了解对应的过程影响因素对下一时刻过程状态的贡献。OD初值的分析结果如图9所示。

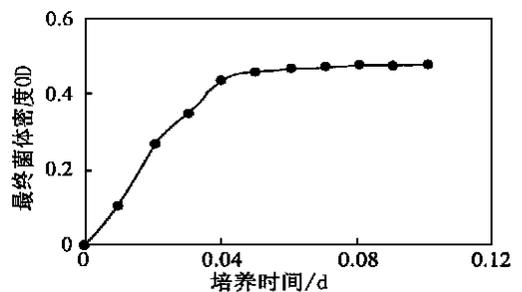


图9 接种量对2 d后菌体密度的影响

Fig. 9 The effects of inoculation amount on yeast density after two days

从图中可看出初始接种量越大, 2 d后菌体密度越高。当接种量超过OD值0.04后, 接种量与最

终菌体密度近似无关, 因此最优接种量应为曲线拐点值. 固定流加量为 0, 设定糖浓度为唯一可调变量, 可得到最优底物浓度曲线, 如图 10 所示.

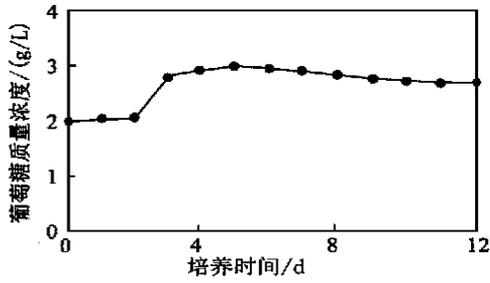


图 10 最优葡萄糖浓度的时变曲线

Fig. 10 The optimized curve of glucose concentration

3.2.2 最优流加策略优化结果 由于考虑了多阶段动态规划问题, 多变量遗传算法所得到的最优流加曲线为全局最优流加策略, 可作为模糊神经网络控制器的训练数据. 在利用单变量优化的最优初始糖质量浓度为初糖质量浓度, 进行遗传算法优化, 最优流加策略如图 11 所示.

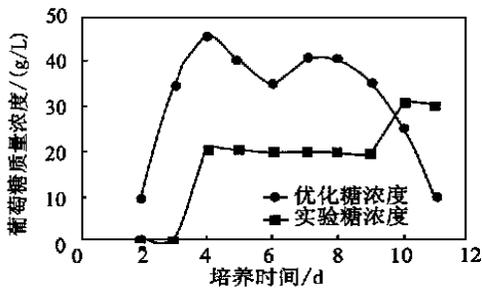


图 11 最优流加策略与实验流加策略

Fig. 11 The comparison of optimized and experimental fed batch strategy

在发酵过程中, 葡萄糖作为碳源消耗. 只有不断的流加葡萄糖, 才能将发酵液中葡萄糖质量浓度保持在最适水平. 从优化结果可以看出, 在适应期与稳定期, 由于碳源消耗量较少, 无需补加, 所以流加量为零. 在对数生长期, 碳源消耗量较大, 所以出现较大的流加量, 而且在对数期的前半段对氮源需求旺盛, 后期需求相对减少. 按照优化后的流加量进行流加, 实验流加策略与最优流加策略下的菌体生长曲线对照如图 12 所示, 结果显示优化后菌体产量出现了相当大的提高.

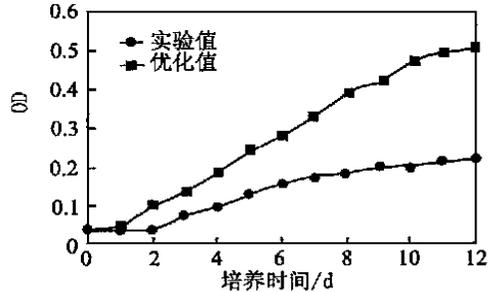


图 12 最优菌体生长曲线与实测曲线

Fig. 12 The comparison of optimized and experimental yeast growth

4 结 论

模糊神经网络应用于发酵过程的模拟、优化方面, 较经典方法具有相当优势. 特别是优化子网络的引入, 利用训练算法进行优化, 提供了一种全新的优化思路. 遗传算法的引入解决了多阶段动态规划的困难. 作者将神经网络用于因素分析与最优流加策略的获取, 取得了满意结果.

参考文献

[1] 元英进, 苗志奇, 秦家庆等. 一种用于谷氨酸生产流动加操作过程预测的模糊-神经网络[J]. 化工学报, 1997, 48: 553 ~ 559.

(责任编辑: 朱明 李春丽)