

文章编号 :1009 - 038X(2000)05 - 0491 - 04

微生物生长过程中菌体浓度的软测量

汪永生 , 邵惠鹤

(上海交通大学自动化研究所 ,上海 200030)

摘 要 :菌体浓度是微生物生长过程中关键的质量指标.作者利用 RBF 神经网络建立了微生物生长过程中菌体浓度的软测量模型,探讨了软测量模型的动态校正方法,通过仿真验证了该方法的有效性.

关键词 :微生物生长过程 ; 菌体浓度 ; 软测量 ; 动态校正

中图分类号 :Q93 - 31

文献标识码 :A

Soft Sensor for Thalli Concentration in Microbial Fermentation Process

WANG Yong-sheng , SHAO Hui-he

(Institute of Automation , Shanghai Jiao Tong University , Shanghai 200030)

Abstract : Thalli concentration is a key quality index in microbial growth process. In this paper , an RBF neural network was used as a soft sensor model to estimate the thalli concentration in this process , and discussed the on-line tuning method for the soft sensor model. A simulation was made to prove this soft sensor method.

Key words : Microbial growth process ; thalli concentration ; soft sensor ; on-line tuning

菌体浓度是微生物生长过程中一个关键的质量指标,但在实际生产中却缺乏比较有效的在线测量手段.软测量技术可以有效解决包括产品质量在内的关键性生产参数等无法在线实时测量的问题,目前在过程工业中已经有了比较广泛的应用^[1].

微生物生长过程中菌体浓度的软测量是个十分典型的非线性系统建模的问题.非线性动态系统建模与线性系统建模相比有许多难点:模型的结构和阶次很难确定;如果采用线性的模型结构来逼近系统的非线性特性,在许多情况下精度不能满足要求;如果采用多线性模型来近似一个非线性系统,将使建模过程非常复杂,而且难以确定线性模型之间的关系;如果采用非线性的模型结构,常规的系

统建模方法将无法确定出非线性模型结构的参数,难以应用许多成熟的线性系统建模方法.

作者利用 RBF 神经网络建立非参数模型以解决微生物生长过程中菌体浓度的软测量问题.利用模型产生仿真数据,利用仿真数据建立 RBF 神经网络软测量模型,通过与模型数据和线性建模的比较说明了这种软测量模型的有效性.

1 问题的提出

考虑微生物发酵过程,可用用 2 个微分方程表示为:

收稿日期 :1999 - 12 - 23 ;修订日期 :2000 - 06 - 15.

作者简介 :汪永生(1972 -)男,上海人,博士研究生.

万方数据

$$\left. \begin{aligned} \frac{dM}{dt} &= \frac{aMS}{S+b} - MU \\ \frac{dS}{dt} &= -\frac{caMS}{S+b} + (S_{in} - S)U \end{aligned} \right\} \quad (1)$$

上式的各参数的含义为： M 过程微生物浓度； S 过程培养基浓度； U 稀释率； a 最大生长率； b 饱和参数； c 收率因子； t 时间； S_{in} 入口培养基浓度

M 、 S 为系统的状态变量， U 为系统输入， a 、 b 、 c 为系统参数， S_{in} 为常数。假定 S 可以在离散的时间点上观测，则

$$y(k) = S(t_k) + \varepsilon_k, k = 1, 2, 3, \dots \quad (2)$$

其中 ε_k 为测量噪声采样周期为 0.5 参数为 $a = 0.55$ ， $b = 0.15$ ， $c = 2$ ， $S_{in} = 0.8$ 。

以稳态工作点 $U = 0.38$ 为中心，用伪随机信号作为系统的输入序列，经过系统输出采样和输入输出组合，得到一系列的系统状态和输入输出数据对 $\{M_k, S_k, U_k\}$ 。

在微生物实际生长过程中， S 值一般是可以实时得到的，而 M 是无法进行实时检测的，只能在较长的周期内通过实验室化验得到。而 M 的值关系到一些高级实时控制策略的正确有效实施，因此需要建立软测量模型，通过 S 、 U 对 M 进行实时估计。由于该系统是动态系统，所以要考虑系统的动态特性。

RBF 神经网络本质上是实现输入—输出的静态映射，当它用于动态建模时必须把系统的动态信息送给它，然后才能够利用它的静态映射功能实现动态映射。动态输入包含了过程的当前输入、历史输入和输出，由 TDL(Tapped Delay Line)，即多分头延时系统来实现。TDL 输出输出矢量由输入信号的延时构成。加入 TDL 部分后 RBF 神经网络就可以对系统的动态特性进行建模。

2 软测量模型的建立与多步校正

2.1 模型建立

利用上述系统状态参数和输入输出参数数据对，构成学习样本数据 $\{I_k, O_k\}$ (实际应用中，学习样本数据为现场采集的数据)，其中

$$\begin{cases} I_k = [M(k-1), M(k-2), M(k-3), \\ S(k), S(k-1), S(k-2), S(k-3), \\ U(k), U(k-1), U(k-2)]^T \\ O_k = M(k) \end{cases} \quad (3)$$

O_k 为过程的待估状态输出， I_k 为系统的动态输入作为 RBF 神经网络的输入。从仿真数据对中取出一部分作为学习样本，通过学习可得到权系数，

从而建立起过程的 RBF 神经网络预测模型。

RBF 神经网络的学习方法采用 OLS 法——正交最小二乘法，可以根据样本数据的分布特性确定网络结构、规模和连接权值等参数^[2]。

2.2 动态校正

为获得充分反映系统动态特性的样本，系统的激励信号采用伪随机信号，但对实际系统而言，这种做法有时是不允许的。因为，在现场中获得的采样数据在输入空间的分布是有限的。因此，过程的动态信息不可能在一次建模中得以完全记忆。这就要求模型在应用中不断校正，以跟踪过程的实际输出。一般的做法是首先在稳态工作点附近建立过程的模型，然后在应用中校正模型。何时校正及如何校正正是校正问题需要解决的两个方面。

2.3 校正样本的确定

对在线校正，由于模型与其它系统共同工作，不能也不该每一个输出都进行校正。当模型的输出与过程的实际输出偏差大于校正阈值时，就把该样本作为校正样本，对模型的参数进行校正。校正阈值的大小取决于应用环境对模型精度的要求。

校正数据的格式要符合初始建模时的样本格式，体现在：输入维数及每一维所代表的物理变量应一致；时刻上的一致，即过程 k 时刻的输出要与 $k-1$ 时刻的输入配对。

2.4 模型多步校正策略

校正动态模型实际上是校正 RBF 中的部分权系数。设 RBF 的输入标准化空间为 $A = A_1 \times A_2 \times \dots \times A_n$ ，对预先确定的校正样本 $\{I_k, O_k\}$ 。根据校正样本的分布，有 2 种情况：

1) 若校正样本在原模型输入空间内，则以原模型的权值为初值，通过学习校正样本，修正这些权值，实现模型输入—输出特性的局部校正。

记校正样本在校正前的模型输出误差为 e_k ，如果学习后的误差目标 $\vec{e}_k = 0$ ，将存在很大的缺陷：当校正样本不精确(指在该输入点，样本不能精确反映过程的动态信息)时，通过校正不但没有提高模型的精度，反而破坏初始模型。在校正样本的精度不能保证的前提下，使学习后的误差目标不为零，而是为校正前误差的一部分，即 $\vec{e}_k = e_k / \xi$ ， ξ 称为校正率。这样可使样本多次校正权系数，这就是多步校正策略。校正率的大小反映了对校正样本的“信任”程度， $\xi = 1$ ，信任度最高，认为样本十分精确。实际应用中可根据具体过程确定。

2) 若校正样本不在原模型输入空间内，校正步骤如下：

当 $I_{k,j} \notin A_j$,把 A_j 进行扩展为 $\tilde{A}_j$,使得 $I_{k,j} \in \tilde{A}_j$;

按建模时的学习算法学习校正样本 ,修正网络权值.

3 仿 真

利用模型 1 和模型 2 生成 2 000 组过程仿真数据^[3] ,过程输入采用伪随机信号.图 1 为稀释率伪

随机输入信号曲线.图 2 为培养基浓度响应曲线 ,图 3 为微生物浓度生长曲线.把 2 000 组数据分成两部分 ,每部分为 1 000 组.利用第一部分建立软测量模型 ,第二部分作为检验样本 ,用于检验模型的精度.为了说明 RBF 神经网络建立软测量模型的有效性 ,利用样本数据建立了线性估计模型 ,并对估计误差进行比较.图 4(a)(b)分别为 RBF 神经网络估计误差曲线和线性建模估计误差曲线.




图 1 伪随机稀释率

Fig.1 Psendo-random dilution ratio




图 2 过程培养基质量浓度

Fig.2 Process nutrient medium concentration




图 3 过程微生物质量浓度

Fig.3 Process microbe concentration




图 4 软测量估计误差与线性模型估计误差的比较

4 结 论

基于 RBF 的非线性动态系统建模可用于过程变量的监视、控制和故障诊断等. RBF 可用于非线性动态系统建模, 而且易于在线校正, 算法简单, 只需在原模型权值的基础上, 学习校正样本, 校正速

度快, 可方便地在线消除由于样本精度不高、在模型(RBF)输入空间的分布不均所带来的预测误差. 多步校正策略在一起程度上防止精度不高的校正样本污染模型, 甚至破坏模型. 当然, 为有效降低样本精度不够所带来的较大的模型误差, 可在建模前和校正前采用数据处理的方法处理样本数据, 去除样本中的随机误差和显著误差.

参考文献

- [1] GERG M. Consider Soft Sensor[J]. **Chemical Engineering Progress** , 1997 (1) : 66 ~ 70.
- [2] 王旭东, 邵惠鹤. 基于神经网络的通用软测量技术[J]. 自动化学报, 1998, 24 (5) : 702 ~ 706.
- [3] ZHANG Qing-hua. Using wavelet network in nonparametric estimation[J]. **IEEE trans** , 1997, 8 (2) : 227 ~ 236.