

文章编号 :1009 - 038X( 2001 )01 - 0055 - 03

# 结合先验知识的神经网络在生化系统建模中的应用

阮 泉 , 吴铁军

( 浙江大学工业控制技术国家重点实验室 , 浙江杭州 310027 )

摘 要 :生化系统由于其高度的非线性 ,往往难以得到一个精确的数学模型 . 虽然许多学者为此做了很多工作 ,提出了各种模型 ,但这些模型的精确度和适应性还有待提高 . 而单纯用神经网络建立的模型由于其各种局限性 ,精确度也很难得到保证 . 将神经网络和先验模型结合而构成混合模型可以提高整个模型的精确度和泛化能力 . 本研究将动态递归神经网络和废水生化处理系统的先验模型结合 ,说明了结合先验模型的神经网络模型的优越性 .

关键词 :废水生化处理 ;先验知识 ;递归网络 ;神经网络

中图分类号 :TP183

文献标识码 :A

## Application of Combining Prior Knowledge and Neural Network in Biochemical Process Modeling

RUAN Quan , WU Tie-jun

( National Laboratory for Industrial Control Technology , Zhejiang University , Hangzhou 310027 , China )

**Abstract :** It is difficult to obtain an accurate model for a biochemical system because of its high nonlinear properties . Although a lot of work was done , it is hard to get a satisfying model in practice . Neural network is a good tool for complex nonlinear system modeling , but it has also some limitations . A method combining prior knowledge to a dynamic recurrent neural network is presented in this paper , to improve the precision and validity in the modeling of a biological wastewater treatment system . Computer simulation results have shown its effectiveness .

**Key words :** biological wastewater treatment ; prior knowledge ; recurrent network ; neural network

城市生活和工业废水处理一直是环境保护领域的一个重要的课题 . 生化方法 ,尤其是活性污泥法在这方面得到了广泛的应用<sup>[1]</sup> . 但由于生化系统固有的高度非线性和多种不确定性 ,难以得到一个精确的数学模型 ,使得依赖于被控对象模型的现代控制理论的各种综合方法在废水生化处理系统的实际运用中存在种种局限 ,从而增加了对城市废水处理生化反应实施自动控制的难度 .

神经网络以其强大的函数逼近能力受到了人们的关注 . 由于神经网络具有能以任意精度逼近任意非线性函数的特性 ,因此 ,常把神经网络作为复杂非线性系统的模型 . 神经网络模型的最大优势在于不需要知道被控对象的机理和其他细节 ,只需给定一组完备的系统输入输出数据对网络进行训练 . 但由于模型完全依赖于样本数据 ,缺乏实际过程的知识 ,而且目前网络的学习算法多为梯度寻优方

收稿日期 2000 - 01 - 20 ;修订日期 2000 - 09 - 16 .

作者简介 :阮泉 ( 1975 - ) 男 ,江苏溧阳人 ,硕士研究生 .

万方数据

法,它只能保证在已知数据点上的精确性,外推能力难以得到保证<sup>[2]</sup>.在实际应用中,由于技术和经济上的原因,往往只能得到十分有限的有关对象特性参数的测量数据,用这些有限数据训练出来的网络,其性能就更值得怀疑.

通常情况下,不管对象特性和机理如何复杂,我们对其往往并不是只知道一些测试数据,而是在一定程度上了解关于它的一些先验知识(数学模型或是经验判据).如何将先验知识和神经网络相结合成为近来颇受关注的一个课题.

本研究针对废水生物处理系统的生化反应模型提出了一种将先验模型和动态神经网络结合进行动态系统建模的方法.

1 废水生物处理生化反应模型

一般来说,采用生物处理法进行无害化处理废水,较其他方法相比是经济的,而且处理效率高,技术也比较成熟.活性污泥法作为生物处理方法的典型代表,在城市生活和工业废水的二级处理中占有重要的地位.废水的水质测量的重要指标之一是废水的生化耗氧量,即 BOD.所谓 BOD 是指水中的好氧菌在将水中的有机废物氧化分解的过程中消耗的水中的溶解氧的量.废水生物处理的基本思想就是利用微生物的新陈代谢作用将废水中危害环境的有害物质吸收转化掉,降低废水的 BOD.

微生物作为一种生命体,其行为受到种群、数量、温度、pH 等众多因素的影响,表现出极强的非线性,很难建立一个精确的模型进行描述.本研究所用的模型是在环境工程学界广泛认同的劳伦斯——麦卡蒂模式的基础上,针对污水的完全混合处理系统,并在以下两个假设的前提下得到的:1) 进水中的基质均为溶解性的,也不含微生物群体;2) 二次沉淀池内无微生物活动,也无污泥积累,固液分离良好.该模型可用以下两个方程描述<sup>[3]</sup>:

$$\frac{dX}{dt} = [Y_T \cdot \frac{k \cdot X \cdot S}{K_s + S} - K_d \cdot X] - \frac{Q_w \cdot X}{V}$$
$$\frac{dS}{dt} = \frac{Q(S_0 - S)}{V} - \frac{k \cdot X \cdot S}{K_s + S}$$

其中:  $X$  是污泥质量浓度 (mg/L);  $S_0$ 、 $S$  分别是进水和出水的底物 (BOD) 质量浓度 (mg/L);  $Y_T$  是细菌的产率;  $k$  是单位细菌的底物利用速度;  $K_d$  是细菌的自然死亡率;  $K_s$  是饱和常数;  $Q$ 、 $Q_w$  分别进水、污泥排放的流量 (m<sup>3</sup>/d);  $V$  是曝气池有效容积 (m<sup>3</sup>),其中参数  $K_d$  和  $K_s$  是方程中的未知量.

2 递归神经网络

递归神经网络是一种具有反馈连接的网络,这种网络具有更复杂的动力学特性,可以更好地反映包含在输入模式中的动态时间特性,因此适合于对动态系统建模.

递归神经网络的一个显著特征是它的节点形式,一个节点通常包含一个非线性动态方程,如下式所示:

$$T_i \frac{dy_i}{dt} = -y_i + f_i(\sum_j w_{ij} y_j) + I_i$$

其中  $y_i$  为第  $i$  个神经元的活性值,  $w_{ij}$  为第  $j$  个神经元到第  $i$  个神经元的连接权值,  $I_i$  为外部输入,  $f_i$  为非线性激发函数(通常是 sigmoid 函数).递归神经网络的另一个特征是它的拓扑结构,任意两个节点之间都可以存在前馈和反馈的连接,节点的输出也可以反馈到自身的输入端.针对递归神经网络, Almeida, Pineda, Werbos, Pearlmutter, Sato, Robinson 和 Williams 等提出了各种动态的学习算法<sup>[4]</sup>.

本研究中采用的是一种简化的对角型递归神经网络<sup>[5]</sup>,其结构如图 1 所示.其中:  $I_i(k)$  为神经网络的输入,  $O_p(k)$  为神经网络的输出;  $W_{ji}^I$  为第  $i$  输入到隐层第  $j$  个神经元的连接权;  $W_{pj}^O$  为隐层第  $j$  个神经元到第  $p$  个输出的连接权;  $W_{jj}^D$  为隐层第  $j$  个神经元内部连接权;  $S_j(k)$  为隐层第  $j$  个神经元的输入和;  $X_j(k)$  为隐层第  $j$  个神经元的输出.




图 1 对角型递归神经网络

Fig.1 Diagonal recurrent neural network

该递归神经网络的动态方程可表示为:

$$\begin{cases} O_p(k) = \sum_j W_{pj}^O X_j(k), X_j(k) = f_j(S_j(k)) \\ S_j(k) = W_{jj}^D X_j(k-1) + \sum_i W_{ji}^I I_i(k) \end{cases}$$

设

$$e_p(k) = y_p(k) - O_p(k), E(k) = \frac{1}{2} \sum_p e_p^2(k)$$

其中  $y_p(k)$  为对象的输出,  $O_p(k)$  为递归神经网络的输出.该网络可采用如下的学习算法:

1)  $W_{pj}^O(k+1) = W_{pj}^O(k) - \eta \frac{\partial E(k)}{\partial W_{pj}^O} = W_{pj}^O(k) + \eta e(k) X_j(k);$

2)  $W_j^D(k+1) = W_j^D(k) - \eta \frac{\partial E(k)}{\partial W_j^D} = W_j^D(k) + \eta \sum_p e_p(k) W_{pj}^O P_j(k);$

其中

$P_j(k) = \frac{\partial X_j(k)}{\partial W_j^D} = f'[S_j(k)] \cdot [X_j(k-1) + W_j^D P_j(k-1)], P_j(0) = 0.$

3)  $W_{ji}^I(k+1) = W_{ji}^I(k) - \eta \frac{\partial E(k)}{\partial W_{ji}^I} = W_{ji}^I(k) + \eta \sum_p e_p(k) W_{pj}^O Q_{ji}(k).$

其中

$Q_{ji}(k) = \frac{\partial X_j(k)}{\partial W_{ji}^I} = f'[S_j(k)] \cdot [I_j(k) + W_j^D Q_{ji}(k-1)], Q_{ji}(0) = 0.$

$\eta$  为学习速率.

### 3 结合先验模型的神经网络模型结构

在某些情况下我们可以得到实际系统的一个先验模型,这个模型在一定程度上反映了系统的特性,加上神经网络的补偿和修正,可以得到一个更精确的模型.

神经网络和先验模型结合的方式主要有串联、并联和混合型<sup>[6,7]</sup>.在串联结构中,神经网络的作用主要是:1)对模型中难于测量的参数进行软测量.2)对测量值进行非线性滤波.3)对变量的测量值作非线性的映射.4)对模型作非线性补偿.并联型结构中,神经网络也用于对对象的建模.模型中引入选择器,在样本高密度空间,可以用神经网络输出作为系统输出,在样本低密度空间则以先验模型的输出为输出.混合型一般是以已有模型为框架,对已有模型中难于建模的部分参数,用神经网络进行建模.先验模型的引入大大提高了神经网络的泛化能力,减少了训练所需的数据量.

本研究用的是一种并联型的结构,与上面提到的并联型结构不同的是该模型利用先验模型和神经网络输出的和作为系统的输出,神经网络根据先

验模型的输出和样本数据的误差加以训练,以补偿先验模型的输出误差.该系统的结构如图 2 所示.





图 2 并联的混合模型结构  
Fig.2 Parallel hybrid model structure

### 4 仿真结果与讨论

仿真实验中,选取  $k = 1.5, K_d = 0.05, K_s = 0.044, Y_T = 0.55$  作为真实模型,  $k = 1.2, K_d = 0.035, K_s = 0.03, Y_T = 0.5$  作为先验模型,通过神经网络的修正得到图 3 所示曲线.



其中 c 和 d 为真实模型的 BOD 变化曲线和污泥浓度变化曲线, a 和 f 为先验模型的 BOD 变化曲线和污泥浓度变化曲线, b 和 e 为神经网络修正后的曲线.

图 3 仿真结果

Fig.3 Simulation result

先验模型和神经网络相结合对于提高整个模型的精度有很大的帮助.尤其在应用中,由于存在温度及其它各种不确定因素,先验模型的精度更难以得到保证,此时将先验模型和神经网络相结合的作用将会更加明显,如果神经网络采用实时的训练算法,还可以在线地对神经网络作不断的调整,提高模型对不断变化的外界环境的适应性.

### 参考文献:

[1] 秦麟源. 废水生物处理 [M]. 上海: 同济大学出版社, 1989.  
万方数据

( 上接第 57 页 )

- [ 2 ] 孙洁.神经网络泛化理化和模型嵌入方法研究[ D ].杭州 浙江大学 ,1999.
- [ 3 ] 彭永臻 ,王永贞 ,王淑莹.活性污泥的多变量最优控制 I、II、III[ J ].环境科学学报 ,1998 ,18 :1 ~ 2.
- [ 4 ] YANG YOU , MICHAEL NIKOLAOU. Dynamic process modeling with recurrent neural networks[ J ]. **AICHE JOURNAL** , 1993 , 39 ( 10 ) :1654 ~ 1667.
- [ 5 ] 李明忠 ,王福利.基于递归神经网络的一类非线性无模型系统的自适应控制[ J ]. 控制与决策 ,1997 ,12( 1 ) :64 ~ 67.
- [ 6 ] 谭立.内嵌先验模型的神经网络及其在过程建模中的应用[ D ].杭州 浙江大学 ,1998.
- [ 7 ] MUKUL AGARWAL. Combining neural and conventional paradigms for modeling , prediction and control[ J ]. **International Journal of Systems Science** , 1997 , 28( 1 ) :65 ~ 81.

( 责任编辑 :李春丽 )