

基于对角递归神经网络的粘度软测量模型

曹柳林 陶斌军

(北京化工大学信息科学与技术学院, 北京 100029)

摘 要: 采用对角动态递归神经网络, 基于生产过程的可测参数, 构造聚酯 (PET) 的粘度软测量模型, 实现 PET 粘度的在线估计。实验表明了方法的有效性和可行性。

关键词: 软测量; 对角递归神经网络; 聚酯; 粘度

中图分类号: O 643.36

引 言

在许多石化工业中, 存在一些重要的过程变量, 如产品组分、质量分数、转化率和聚合度等, 目前仍难以用仪表在线测量。这些变量与产品质量密切相关, 对实现直接质量控制具有重要的意义。为了对这类变量进行有效估计和控制, 软仪表技术近年来得到很快发展和应用^[1,2]。核心是建立上述变量(主导变量)与其它可测变量(辅助变量)间的数学模型, 用计算机软件实现, 实现主导变量的估计。依据建模方法的不同, 软测量分为基于机理分析、状态估计、回归分析的方法以及神经网络的方法等^[1,3]。神经网络不需要过程的先验知识, 学习和非线性映射的能力非常强, 因而成为解决软测量问题的理想选择。

人工神经网络是一种“黑箱子”建模工具。常用的前向神经网络, 如 BP、RBF 网络等, 虽然具有强有力的学习能力和非线性处理能力, 但却不能捕捉系统的动态特性, 使用这些网络构成的软仪表往往不能获得预期的效果。为处理时间序列建模和动态系统辨识等问题, 必须在网络中引入记忆功能。可以有两种方式, 一是通过延时单元把以前的输出存储在延时单元中, 把时间信号展成空间表示后再送给前向网络(外递归方式); 另一种是在网络的隐含和(或)输出单元引入自反馈回路, 使网络本身成为动态系统(内递归方式)。

连续化工动态系统的建模, 比较充分地研究了外递归方式的前向网络及应用。软仪表模型, 这种

方法并无太大的实用价值, 实际应用中, 不可能得到主导变量的反馈信号。因此选择一种本质动态(内递归)的神经网络, 是建立软仪表模型的迫切要求。

对角递归神经网络 DRNN (Diagonal Recurrent Neural Network) 是递归神经网络的一种^[4]。它既具有递归神经网络的特点, 又具有结构简单, 学习快速的优势。本文研究利用对角递归神经网络建立聚酯生产过程的粘度软测量模型, 为实现 PET 产品质量实时监测和在线控制提供可能。

1 工艺介绍

本研究工作是根据某石化公司化纤厂连续聚酯生产过程进行的。生产装置由二个酯交换釜和四个缩聚釜串联组成。原料对苯二甲酸二甲酯 (DMT) 和乙二醇 (EG) 及添加剂定量地供应到酯交换釜, 反应生成单体, 随后在缩聚工序中, 除掉 EG 进行缩聚反应, 生成特定聚合度的聚合体送往纺丝机。其中聚合熔体的粘度是产品质量的一个重要参数。由于第一、二缩聚釜没有在线粘度计, 软仪表工作主要是针对一、二釜的粘度预估进行的。网络学习的粘度数据由已经检验的机理模型得出。机理模型的输入均采用现场实际操作数据。

2 对角型递归神经网络^[5]

传统的递归神经网络是一种全连接的结构形式。它的隐含层及输出单元之间相互交换信息均含有自反馈单元。这种结构虽然提高了网络的动态映射能力, 同时也导致系统复杂, 学习缓慢, 收敛困难。对角递归神经网络 DRNN (图 1) 是全连接递归神经网络的一种简化。它与标准的前馈网络相比, 同样有输入、输出和隐含单元。不同之处是 DRNN 的

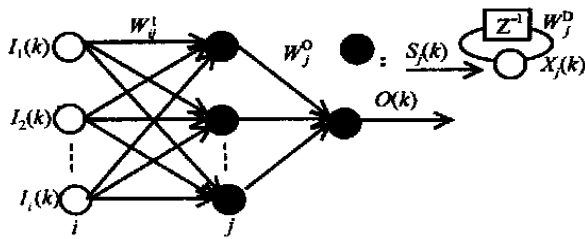


图 1 对角递归神经网络结构

Fig. 1 Structure of diagonal recurrent network

隐含单元具有自反馈。DRNN 的动态映射和记忆功能正是通过递归神经元在内部的反馈回路捕捉系统的动态特性来实现的。相对于全连接的 RNN,隐含单元之间不存在相互的信息交换,模型获得了极大地简化,学习的快速性得到保证。DRNN 的输入和输出表达式如下:

$$O(k) = \sum_j W_j^O X_j(k), X_j(k) = f(S_j(k))$$

$$S_j(k) = W_j^D X_j(k-1) + \sum_i W_{ij} I_i(k)$$

其中, $I_i(k)$ 是 DRNN 的第 i 个输入函数。 $S_j(k)$ 是第 j 个递归神经元的输入总和函数。 $X_j(k)$ 是第 j 个递归神经元的输出函数。 $O(k)$ 是 DRNN 的输出函数。 W^I, W^D, W^O , 分别为输入、递归和输出层权值向量。激励函数 $f(S_i(k))$ 取典型的 Sigmoid 函数(双曲函数)。各层结点权重的修正量:

$$\frac{\partial O(k)}{\partial W_j^O} = X_j(k) \quad (1)$$

$$\frac{\partial O(k)}{\partial W_j^D} = W_j^O P_j(k) \quad (2)$$

$$\frac{\partial O(k)}{\partial W_{ij}^I} = W_j^O Q_{ij}(k) \quad (3)$$

其中:

$$Q_{ij}(k) = \frac{\partial X_i(k)}{\partial W_j^D} = f(S_j) (I_j(k) +$$

$$W_j^D Q_{ij}(k-1)) \quad (4)$$

$$P_j(k) = \frac{\partial X_j(k)}{\partial W_j^D} = f(S_j) (X_j(k-1) +$$

$$W_j^D P_j(k-1)) \quad (5)$$

权值的修正采用梯度法进行:

$$W(n+1) = W(n) + \left[\frac{\partial E}{\partial W} \right] + W(n) \quad (6)$$

是动量因子。引入动量因子并在修改权重时考虑前一次修改量是为了增加收敛速度并避免振荡。

方程(1)~(6)式构成了 DRNN 的动态反向传播算法。考虑到快速和收敛稳定的共同要求,根

据 Lyapunov 稳定判据,可推导出网络各层权值的最佳学习速率:

$$0 < \eta < \frac{2}{h}; 0 < \alpha < \frac{2}{h} \left[\frac{1}{W_{\max}^O} \right]^2$$

$$0 < \alpha < \frac{2}{(h+n)} \left[\frac{1}{W_{\max}^O I_{\max}} \right]^2$$

其中, h 为隐含结点个数, n 为输入结点个数。 η, α, η' 分别为输出层、递归层和输入层的权值学习速率,并且有:

$$W_{\max}^O = k_{\max} (j_{\max} | W_j^O(k) |)$$

$$I_{\max} = k_{\max} [I_i(k)]_{\max}$$

k 为迭代的次数, j 代表当前输出结点。

3 构造基于 DRNN 的粘度软仪表

3.1 首釜粘度估计

选择第一缩聚釜的粘度作为研究对象。影响第一釜产物粘度的操作参数有进料温度,进料流量,反应温度,反应釜液位及真空度等。为了寻求与粘度相关性较大的参数作为网络的输入,可采用相关分析等统计方法。同时,还要从反应机理出发,选择出与主导变量动态特性相近的可测变量。在对系统进行机理分析结合相关分析之后,确定了 6 个输入变量:进料泵速 v_1 ,进料温度 t_0 ,反应温度 t_1 ,出料泵速 v_2 、液位高度 h 和真空度 p_0 。网络的结构为 $N_{6,20,1}^3$ (3 层,6 个输入,20 个隐含结点,1 个输出)。利用 600 组样本进行离线学习,另选 500 组数据用于验证。利用平均误差和最大误差作为性能评判标准。统计结果如表 1。图 2 为网络输出和期望输出的粘度曲线。

表 1 统计分析结果

Table 1 Results of statistical analysis						
样本类型	首釜		二釜方法 1		二釜方法 2	
	训练	验证	训练	验证	训练	验证
样本个数	600	500	500	400	450	400
平均误差	0.000 6	0.001 8	0.014 6	0.012 2	0.005 7	0.007 3
最大误差	0.019 6	0.019 6	0.042	0.054	0.022 8	0.039 5

从统计数据和检验曲线可见,训练好的神经网络具有良好的动态特性。其预估精度能够满足实际聚酯生产过程的质量监测和控制的要求。

3.2 第二釜粘度估计

影响第二釜粘度的参数与第一釜基本一致,还要考虑第一釜参数的影响。第一釜的状态必然影响

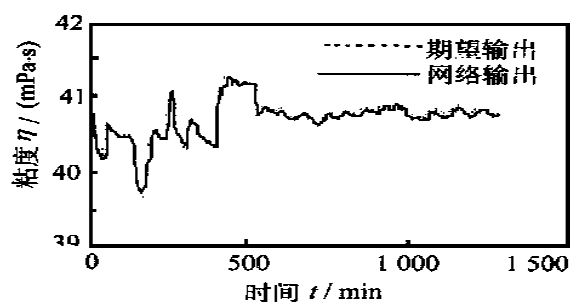


图2 软测量模型检验曲线

Fig. 2 Testing curves of soft sensing model

第二釜的产物粘度。为此,设计了两种解决方法。

3.2.1 方法1 对第二釜而言,第一釜的粘度是该釜反应情况的综合体现。没有第一釜粘度的实测数据,选择第一釜的输出泵速、反应温度、真空度和液位作为神经网络的部分输入,另一部分的输入为第二釜的液位高度 h_1 、真空度 p_1 、输出泵速 v_2 和反应温度 t_2 。网络结构为 $N_{8,20,1}^3$ 。训练和验证结果统计见表1。图3为上述模型输出和期望输出的对比曲线。

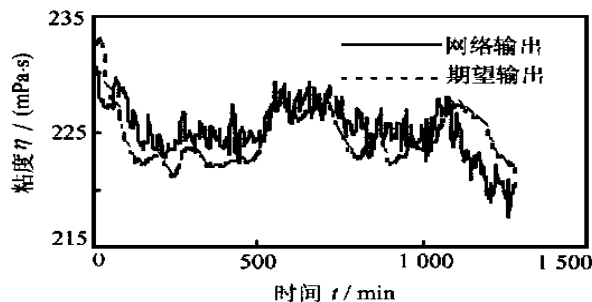


图3 软测量模型检验曲线

Fig. 3 Testing curves of soft sensing model

验证的数据统计结果表明网络的性能可以接受,但从验证曲线分析可见,太多的输入加重了网络的学习负担,引入了过多的噪声。这种方法有待改进。

3.2.2 方法2 为了进一步提高网络的建模精度,设计了串联型的DRNN系统(图4)。第一个网络的输入和结构同3.1所述,其网络输出粘度 η_1 送到第二个网络,再加上原二釜参数,构成第二个网络的输入,输出第二釜粘度 η_2 ,结构定为 $N_{5,15,1}^3$ 。这样的安排减轻了单一网络的学习负担,有利于提高建模精度。

网络训练和验证的结果统计见表1。图5为上述模型输出和期望输出的对比曲线。

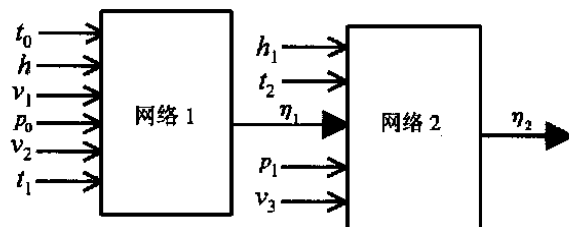


图4 串联DRNN结构图

Fig. 4 Structure of cascaded DRNN

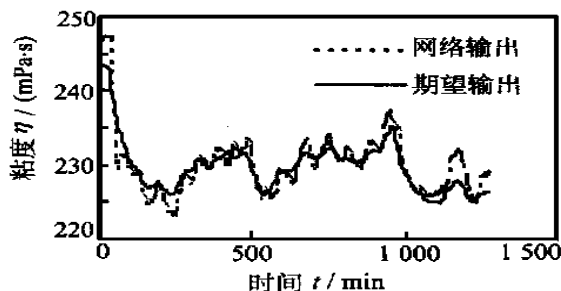


图5 软测量模型检验曲线

Fig. 5 Testing curves of soft sensing model

结果表明,串联型DRNN模型相对于方法1构成的网络,从训练和验证方面显示出更好的效果。

4 讨论和结论

本文利用对角递归神经网络,结合实际生产过程的操作数据,建立了聚酯粘度预估的软仪表模型。从表1的数字统计可见,网络进行验证时,首釜粘度预估的平均误差达到0.18%;第二釜利用串联型的网络,平均误差达到0.73%。这样的精度对于成分分析仪表而言,是完全可以接受的。这表明,利用DRNN软仪表实现聚酯粘度的在线测量是可行的。与利用静态的BP网络模型比较,基于DRNN的软测量模型表现出更好的动态性能,从跟踪能力和预估精度上都有较大改善。但是,从首釜和第二釜的实验结果比较可以看出,随着系统复杂性,如阶次、非线性程度的增加,DRNN的动态映射能力有所下降。与全连接的RNN比较,DRNN正是通过简化网络结构,以舍弃记忆空间和记忆能力的方式,获取网络的快速收敛性能的。如何增加网络输出结点与其它结点间的动态连接,同时保证网络的稳定性和快速收敛性,将是这类递归神经网络研究的课题。

(下转第76页)

度、加强 PC 通信管理与电话线本身通信管理。

参 考 文 献

- [1] 张洪润,蓝清华. 单片机应用技术教程. 北京:清华大学出版社,1999. 41 ~ 96

- [2] 范红梅. Windows 操作系统下的串并行仪器接口开发. 国外电子测量技术,2000(3):24 ~ 26
[3] Campbell J. 串行通信 C 程序员指南. 北京:清华大学出版社,1995. 45 ~ 62

Remote data communication of monitor system of environment

FENG Xiu-li HAN Jian-guo

(Institute of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: In this paper, software and hardware design and realization of environmental monitoring system are introduced on the basis of Modem and telephone wire. The specific actualization method of remote data communication is also discussed. This system has the advantages such as abundant interface types, strong ability of anti-noise and large store space. Besides, it is suitable for the data acquisition system that is new-old crossed and type complex. This system has been used in the environment protection of Beijing suburb successfully.

Key words: modem; waste water monitoring system; software and hardware; remote data communication

(上接第 72 页)

参 考 文 献

- [1] 于静江,周春晖. 过程控制中的软测量技术. 控制理论与应用,1996;13(2):137 ~ 142
[2] 曹柳林,江 弘,陈 红. 利用神经元网络实现门尼粘

度的预估. 北京化工大学学报,1997,24(4):60 ~ 64

- [3] 王旭东,邵惠鹤. 基于神经网络的通用软测量技术. 自动化学报,1998,24(5):702 ~ 706
[4] Ku C C, Lee K Y. Diagonal recurrent neural networks for dynamic systems control. IEEE Transactions on Neural Networks, Jan. 1995,16(1):144 ~ 156

Soft sensing model of viscosity based on diagonal recurrent network

CAO Liu-lin TAO Bin-jun

(College of Information Science and technology, Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: A diagonal recurrent network combined with measurable parameters is applied to construct soft sensing model to implement the online estimation of viscosity of poly(ethylene terephthalate). Experiments show the feasibility and effectiveness of the method.

Key words: soft sensing; diagonal recurrent network; PET; viscosity