

文章编号: 1001-0920(2012)07-1042-05

## 基于神经网络的聚氯乙烯汽提过程自适应解耦控制

高淑芝<sup>1,2</sup>, 高宪文<sup>1</sup>, 王介生<sup>1</sup>, 杨 静<sup>1</sup>

(1. 东北大学 信息科学与工程学院, 沈阳 110819; 2. 沈阳化工大学 信息工程学院, 沈阳 110142)

**摘 要:** 聚氯乙烯汽提过程具有高度非线性和时变性的特点, 是一类复杂的非线性工业过程. 首先基于动态模糊神经网络建立了数据驱动的聚氯乙烯树脂(PVC)汽提过程的被控对象模型; 然后采用一种神经网络分散式解耦控制器对汽提过程进行解耦, 得到浆料流量-塔顶温度和蒸汽流量-塔底温度两个单变量系统; 最后采用 BP 神经网络 PID 控制器对系统进行控制. 仿真实验结果验证了所提出集成控制策略的有效性.

**关键词:** 聚氯乙烯汽提过程; 动态模糊神经网络; 解耦控制; 神经网络

中图分类号: TP273

文献标识码: A

## Adaptive decoupling control of PVC stripping process based on neural network

GAO Shu-zhi<sup>1,2</sup>, GAO Xian-wen<sup>1</sup>, WANG Jie-sheng<sup>1</sup>, YANG Jing<sup>1</sup>

(1. School of Information Science and Engineering, Northeastern University, Shenyang 110819, China; 2. College of Information Engineering, Shenyang University of Chemical Technology, Shenyang 110142, China. Correspondent: GAO Xian-wen, E-mail: gaoxianwen@ise.neu.edu.cn)

**Abstract:** Polyvinyl chloride(PVC) stripping process is a typical complicated non-linear industrial process with the characteristics of highly non-linear and time variety. Firstly, the controlled object model of the stripping process is established based on the data-driven dynamic fuzzy neural network(D-FNN) method. Then the decentralized neural network controller is adopted to decouple the stripping process into the two single-input-single-output(SISO) of slurry flux versus tower top temperature and steam flux versus tower bottom temperature. Finally, the BP neural network PID controller is used to control the decoupled SISO system. Simulation results show the effectiveness of the proposed integrated control strategy.

**Key words:** PVC stripping process; dynamic fuzzy neural network; decoupling control; neural network

### 1 引 言

聚氯乙烯树脂(PVC)是大宗基础化工原料, 目前脱除 PVC 浆料中多余的氯乙烯(VCM)单体方法中, 汽提工艺是非常有效的<sup>[1]</sup>. 目前针对 PVC 工业的控制研究大多在聚合、精馏等阶段, 如神经网络、模糊控制、专家系统和预测控制等先进控制技术得到了广泛应用. 基于神经网络的解耦和非线性自适应控制在 PVC 生产过程中得到广泛应用<sup>[2-5]</sup>. 文献[2]将 BP 神经网络解耦控制器应用于精馏塔温度控制, 仿真结果表明该算法具有较强的鲁棒性. [3]针对 PVC 沸腾床干燥过程, 基于人工神经网络, 建立了沸腾床能耗稳态优化模型, 设计了多变量状态反馈控制系统, 实现了床温的动态优化控制. [4]提出了一种针对精馏塔过程的基于神经网络的预测控制系统.

[5]设计了 BP 神经网络解耦控制器, 并将其应用于精馏塔温度控制, 取得了良好的鲁棒性和控制效果.

目前, 国内外缺乏对 PVC 生产中的汽提工艺过程进行先进控制方法的研究. 本文首先建立了聚氯乙烯汽提过程的动态模糊神经网络模型; 然后将神经网络解耦控制和 BP 神经网络 PID 控制相结合并应用于汽提过程的温度控制; 最后通过仿真实验验证了所提出算法的有效性.

### 2 聚氯乙烯汽提工艺过程

某化工集团采用的筛板穿流堰板式汽提塔, PVC 浆料的汽提工艺流程如图 1 所示. 聚合反应结束后, PVC 浆料由聚合釜通过进塔浆料泵打入汽提塔顶部, 但在进入汽提塔之前需要与塔底出来经过汽提

收稿日期: 2010-12-23; 修回日期: 2011-05-25.

基金项目: 国家自然科学基金重点项目(61034005); 教育部基本科研业务费研究生科研创新项目(N100604001).

作者简介: 高淑芝(1968-), 女, 博士生, 从事复杂工业过程智能建模与预测控制; 高宪文(1955-), 男, 教授, 博士生导师, 从事复杂工业过程的建模、智能控制与优化等研究.

后的浆料发生热交换, 随后进入汽提塔顶部. PVC 浆料经喷头均匀地洒向塔板, 浆料从第 1 层塔板沿塔板上的小孔自上而下流动. 低压蒸汽从汽提塔底部进入, 自下而上经塔板上的小孔上升, 在每层塔板上与下降的 PVC 浆料逆流接触, 进行传热和传质, 将残留在树脂颗粒表面及内部的氯乙烯解析出来. 蒸汽与解析出的氯乙烯气体从汽提塔顶部排出, 经塔顶冷凝器冷凝后, 进入冷凝水槽, 分离冷凝水并控制冷凝水槽液位, 将多余的冷凝水排放至离心母液水回收装置, 分离后的氯乙烯气体回收至氯乙烯气柜.

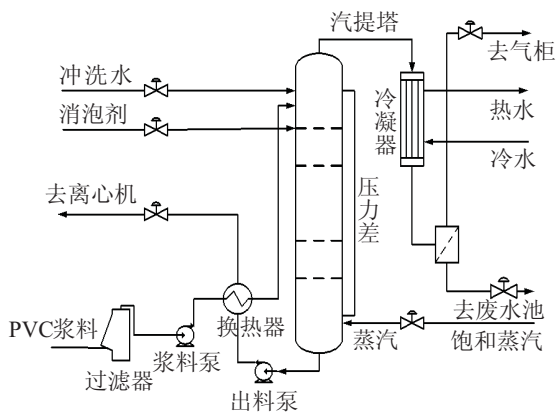


图 1 聚氯乙烯汽提工艺流程图

通过分析 PVC 汽提过程, 聚氯乙烯汽提过程具有较强的非线性及耦合特性. 影响 PVC 中氯乙烯单体脱除的主要因素是汽提塔塔顶温度和塔底温度, 其中最主要控制量为蒸汽流量和浆料流量. 由于缺乏有效的数学模型和变量之间的强耦合, 很难得到满意控制效果. 本文针对 PVC 汽提过程提出了基于神经网络技术的集成建模和混合智能控制策略.

### 3 基于神经网络的汽提过程智能解耦控制

#### 3.1 智能解耦控制系统的结构

基于神经网络的智能解耦控制策略的系统框图如图 2 所示. 控制系统由动态模糊神经网络建立被控对象(浆料流量-塔顶温度, 蒸汽流量-塔底温度), 两个神经网络开环解耦器 ND1 和 ND2 以及两个 BP 神经网络 NN1 和 NN2 由在线优化的 PID 控制器组成.

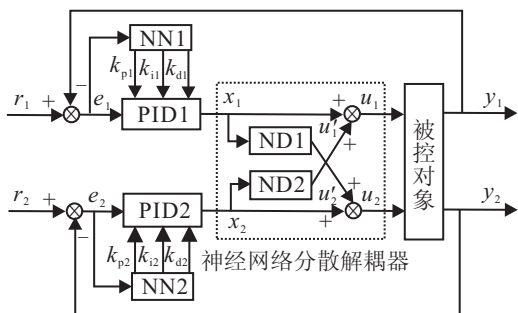


图 2 聚氯乙烯汽提过程解耦控制框图

图 2 中,  $r_i$  为系统输入,  $y_i$  为系统输出,  $x_i$  为控制器输出向量,  $u_i$  为神经网络解耦器输出向量,  $u'_i$  为控制输入向量,  $i = 1, 2$ . 汽提过程中智能解耦控制系统分为两个阶段:

1) 训练阶段: 此时神经网络 PID 控制器被断开, 系统处于开环训练状态. 首先训练神经解耦器 ND1, 保持 ND2 没有输入, 如果解耦成功, 则浆料流量-塔顶温度通道将不会有输出 ( $y_1 = 0$ ). 将  $y_1$  作为 ND1 训练的指标函数, 调整 ND1 各层连接权值; 同理, 用相同的方法训练 ND2. 此时, 整个汽提塔被控对象被解耦为浆料流量-塔顶温度和蒸汽流量-塔底温度两个 SISO 系统.

2) 控制阶段: 采用 NN1 和 NN2 在线优化 PID 控制器参数来对两个 SISO 系统进行闭环控制.

#### 3.2 基于动态模糊神经网络的汽提过程建模

建立了以蒸汽流量和浆料流量为输入, 分别以塔顶温度和塔底温度为输出的基于动态模糊神经网络<sup>[6-9]</sup>的汽提过程模型. 这里主要介绍其学习算法.

1) 规则产生准则.

误差判据可以描述如下: 对于第  $i$  个观测数据 ( $X_i, t_i$ ),  $X_i$  为输入向量,  $t_i$  为期望输出, 设  $y_i$  为 D-FNN 现有结构的全部输出. 定义

$$\|e_i\| = \|t_i - y_i\|, \tag{1}$$

如果  $\|e_i\| > k_e$ , 则考虑增加一条新的规则, 这里的  $k_e$  值是根据 D-FNN 期望的精度选定的.

2) 可容纳边界.

一个高斯函数具有良好的局部特性, 其输出随着与中心距离的增加而单调递减. 当输入变量的隶属函数采用高斯函数描述时, 整个输入空间由一系列的高斯隶属函数划分. 如果一个新的样本位于某个存在的高斯函数覆盖范围(可容纳边界内), 则新样本可以用存在的高斯函数代表, 而无须 D-FNN 产生新的高斯单元.

可容纳边界判据: 对于第  $i$  个观测数据 ( $X_i, t_i$ ), 计算输入值  $X_i$  与现有的 RBF 单元的中心  $C_j$  直接的距离

$$d_i(j) = \|X_i - C_j\|, \tag{2}$$

其中  $u$  是现有的模糊规则或者 RBF 单元的数量. 找出

$$d_{\min} = \arg \min(d_i(j)), \tag{3}$$

如果  $d_{\min} > k_d$ , 则要考虑增加一条新的模糊规则; 否则, 观测数据  $X_i$  可以由现有的最近的 RBF 单元表示. 这里  $k_d$  是可容纳边界的有效半径.

3) 分级学习思想.

分级学习的主要思想是每个 RBF 单元的可容纳

边界不是固定的而是根据如下方式动态调节的: 起初, 可容纳的边界设置较大, 以实现全局学习; 但随着不断学习, 边界逐渐减小, 因此开始局部学习. 根据分级学习思想, 文献 [10] 提出了一种简单的方法, 即基于单调递减函数, 逐渐减少每个 RBF 单元的有效半径和误差指数. 即上文中的  $k_e$  和  $k_d$  不是常数, 而是由下式确定的:

$$k_e = \max[e_{\max} \times \beta^i, e_{\min}], \quad (4)$$

$$k_d = \max[d_{\max} \times \gamma^i, d_{\min}]. \quad (5)$$

式中:  $e_{\max}$  为预先定义好的最大误差,  $e_{\min}$  为期望的 D-FNN 精度,  $\beta(0 < \beta < 1)$  为收敛常数,  $d_{\max}$  为输入空间的最大长度,  $d_{\min}$  为输入空间的最小长度,  $\gamma(0 < \gamma < 1)$  为衰减常数.

分级学习思想的关键是首先确定产生输出误差大而又没有被现有模糊规则覆盖的位置, 这个阶段也称为粗学习; 当  $k_e$  和  $k_d$  分别达到  $e_{\min}$  和  $d_{\min}$  时, 这个阶段的学习便称为细学习.

4) 前提参数分配.

当一条模糊规则产生后, 需解决的问题是如何确定它的参数. RBF 单元宽度对系统的泛化性能至关重要, 如果这个宽度小于邻近输入距离(即 RBF 单元没有重叠), 则模糊神经网络的泛化能力很差, 但如果宽度太大, 则 RBF 单元容易饱和. 因此, 新产生的规则的初始参数应按如下方式进行分配:

$$C_i = X_i, \quad (6)$$

$$\sigma_i = k \times d_{\min}, \quad (7)$$

式中  $k(k > 1)$  为重叠因子.

需注意的是, 当第 1 个观测数据  $(X_1, t_1)$  得到后, 此时的 D-FNN 还没有建立起来, 因此, 这个数据将被选为第 1 条模糊规则:  $C_1 = X_1, \sigma_1 = \sigma_0$ , 其中  $\sigma_0$  是预先设定的常数. 另外, 只有当  $\|e_i\| > k_e, d_{\min} > k_d$  时, 才需要增加一条模糊规则.

5) 结果参数确定.

根据上述提到的规则产生准则, 假定  $n$  个观测数据产生了  $u$  个模糊规则,  $N$  个节点的输出可写成矩阵形式为

$$\psi = \begin{bmatrix} \psi_{11} & \cdots & \psi_{1n} \\ \vdots & \ddots & \vdots \\ \psi_{u1} & \cdots & \psi_{un} \end{bmatrix}. \quad (8)$$

于是, 对于任意输入  $X_j(x_{1j}, x_{2j}, \dots, x_{rj})$ , 系统的输出  $y_j$  也可写为如下紧凑形式:

$$W \Psi = Y. \quad (9)$$

假定理想输出为  $T = (t_1, t_2, \dots, t_n) \in \mathbb{R}^n$ , 则目标是: 给定  $\Psi \in \mathbb{R}^{(r+1)u \times n}$  和  $T \in \mathbb{R}^n$  之间的关系为

$$Y = W \times \Psi, \quad (10)$$

$$\tilde{E} = \|T - Y\|, \quad (11)$$

寻找一个最优的系数向量

$$W^* \times \Psi = T, \quad (12)$$

最优的  $W^*$  具有如下形式:

$$W^* = T(\Psi^T \Psi)^{-1} \Psi^T. \quad (13)$$

3.3 神经网络开环解耦算法

3.3.1 神经网络开环解耦器的结构

神经网络开环解耦器是由两个不同的动态时延 TDNN 神经网络 ND1 和 ND2 组成的. 这里以 ND1 为例进行分析, 其结构如图 3 所示.




图 3 神经网络解耦器结构

神经解耦器可采用 1 个 3 层神经网络, 神经网络的激励函数可采用双曲正切函数<sup>[11-12]</sup>. 每个网络有 1 个输入端和 1 个输出端, 解耦器输出可表示为

$$u_2'(k) = f_1(x_1(k), x_1(k-1), \dots, x_1(k-n_1), u_2'(k-1), u_2'(k-2), \dots, u_2'(k-m_2)). \quad (14)$$

式中:  $u$  为神经网络解耦器输出;  $k$  为采样次数;  $m_2$  和  $n_1$  为正整数, 可根据被控过程的阶次近似确定.

3.3.2 训练算法

对于图 3 所示的神经网络解耦器, 理论上应取期望输出作为其性能指标函数, 但神经网络期望输出是未知的, 因此, 本文将神经解耦器与被控对象看作一个广义对象, 这样, 神经网络的训练便可用系统输出作为指标函数, 即 ND1 的指标函数为

$$J_1 = \frac{1}{2} \sum_{K=0}^N [y_2(k)]^2. \quad (15)$$

本文采用如下所示的权值学习算法训练 BP 神经网络<sup>[13]</sup>:

$$\Delta w(k) = -\eta \frac{\partial J}{\partial w} + \alpha * \Delta w(k-1). \quad (16)$$

式中:  $\eta$  为学习速率,  $\alpha$  为动量系数,  $w$  为对应神经网络的权值,  $N$  为训练所用的样本数. 将指标函数对权值求导, 为方便讨论, 略去下标, 得

$$\Delta w(k) = -\eta \sum y \frac{\partial y}{\partial u'} \frac{\partial u'}{\partial w} + \alpha * \Delta w(k-1), \quad (17)$$

式中  $w$  和  $\Delta w$  分别为权值和权值的改变量.

为了应用 BP 算法, 需要知道偏导数  $\partial y / \partial u$ . 如果已知偏导数的符号, 则将其记为  $\text{sign}(\partial y / \partial u)$ , 通过调

整学习速率, 可使

$$\eta' = \eta \left| \frac{\partial y}{\partial u'} \right|. \quad (18)$$

因此式(17)可改写为

$$\Delta w(k) = -\eta' \text{sign} \left( \frac{\partial y}{\partial u'} \right) \sum y \frac{\partial u'}{\partial w} + \alpha * \Delta w(k-1). \quad (19)$$

在实际工业生产中, 有许多被控过程具有单调上升或单调下降的特性, 也就是说,  $y$  是关于  $u'$  的单调上升或单调下降函数. 当  $y$  关于  $u'$  是单调上升时,  $\text{sign}(\partial y / \partial u) = 1$  或  $-1$ .

每个 TDNN 神经网络权值的训练可采用如上权值更新公式独立地进行训练学习, 于是原 TITO 系统被解耦为两个 SISO 非线性系统; 然后分别对每个 SISO 系统进行控制器的设计.

## 4 仿真验证

### 4.1 汽提过程的动态模糊神经网络建模

采集能反映 PVC 汽提过程特性的 280 组样本数据来训练 D-FNN 模型, 其中 80 组数据作为测试样本来检验辨识效果. 以汽提塔塔顶温度为例, 针对测试数据的辨识结果如图 4 所示, 可以看出汽提塔温度实际值与预测值拟合较好, 能满足过程优化控制的要求.




图 4 塔顶温度的 D-FNN 建模仿真结果(测试样本)


### 4.2 汽提过程的神经网络解耦控制

为了验证基于神经网络的智能解耦控制策略的有效性, 将其应用于动态模糊神经网络对象模型, 进行了以下仿真. 首先设定各神经网络结构和训练算法参数: ND1 和 ND2 的结构为 5-4-1 结构, 动量系数  $\eta_{ND} = 0.005$ , 学习率  $\alpha_{ND} = 0.9$ ; NN1 和 NN2 采用 3-5-3 结构, 惯性项  $\eta_{NN} = 0.25$ , 学习率  $\alpha_{NN} = 0.05$ .


根据聚氯乙烯汽提工艺实际过程, 汽提塔的塔顶温度最佳值为  $85^\circ\text{C}$ , 因此仿真中塔顶温度的给定值信号为  $85^\circ\text{C}$ , 但该温度不能超过  $110^\circ\text{C}$ , 否则会使聚氯乙烯树脂发生分解变质, 因此  $y_1$  的上限值为  $110^\circ\text{C}$ ; 而汽提塔的塔底温度最佳值为  $107^\circ\text{C}$ ,  $y_2$  的上限值为  $113^\circ\text{C}$ . 根据实际汽提过程中可能出现的情况, 仿真中主要考虑以下几种情况:

1) 不加任何扰动, 测试塔顶温度和塔底温度的跟

踪效果. 从仿真结果(图 5)中可以看出, 控制系统可以及时跟踪输入变化, 系统具有较高的响应性能.



(a) 塔顶温度阶跃响应曲线




(b) 塔底温度阶跃响应曲线


图 5 不加扰动时的仿真结果

2) 在塔顶温度的设定值部分加入一个幅值为 5 的随机扰动信号, 仿真结果如图 6 所示. 通过加入塔顶温度扰动来测试系统的解耦效果, 从图 6 中可以看出, 神经网络构造的解耦器改善了控制系统性能, 两个回路之间的相互影响得到了有效控制.

从以上仿真结果可得出以下结论: 1) 系统跟踪性能良好, 能够适应设定值的变化, 响应时间等参数令人满意; 2) 浆料流量-塔顶温度和蒸汽流量-塔底温



(a) 塔顶温度随机扰动响应曲线



(b) 塔底温度输出曲线

图 6 加入塔顶温度扰动的仿真结果

度之间的耦合度得到了明显降低,基本达了解耦效果;3)系统对外来扰动具有一定鲁棒性,并且能够克服扰动对塔顶温度与塔底温度的影响.

## 5 结 论

以聚氯乙烯汽提过程为被控对象,建立了汽提过程的动态模糊神经网络被控对象模型,提出一种将神经网络解耦控制和BP神经网络PID控制相结合的策略,并将其应用于汽提过程的温度控制.仿真结果验证了所提出的聚氯乙烯汽提塔集成控制策略的有效性.

## 参考文献(References)

- [1] 惠正纲. 汽提技术在PVC生产中的应用[J]. 聚氯乙烯, 2007, 7(2): 8-12.  
(Hui Z G. The application of stripping technology in the production of PVC[J]. Polyvinyl Chloride, 2007, 7(2): 8-12.)
- [2] Liu H. Design of multivariable fuzzy-neural network decoupling controller[J]. Control and Decision, 2006, 21(5): 593-596.
- [3] 肖卫国, 王志明, 郭艳芬, 等. PVC沸腾床干燥过程优化控制系统[J]. 化工自动化及仪表, 1994, 21(5): 12-15.  
(Xiao W G, Wang Z M, Guo Y F, et al. PVC boiling bed drying process optimization control system[J]. Automation and Instruments in Chemical Industry, 1994, 21(5): 12-15.)
- [4] Khairiyah Mohd Yusof, Boo Chin Eng, Hong Mei Kwee, et al. Formulation of model predictive control algorithm for nonlinear processes[R]. Skudai: University of Technology Malaysia Press, 2006: 47-71.
- [5] Deng X S, Wang X Z. Incremental learning of dynamic fuzzy neural networks for accurate system modeling[J]. Fuzzy Sets and Systems, 2009, 160(7): 972-987.
- [6] Juang C F, Hsieh C D. A locally recurrent fuzzy neural network with support vector regression for dynamic-system modeling[J]. IEEE Trans on Fuzzy Systems, 2010, 18(2): 261-273.
- [7] Subasi Abdulhamit. Automatic detection of epileptic seizure using dynamic fuzzy neural networks[J]. Expert Systems with Applications, 2006, 31(2): 320-328.
- [8] Adeli H, Jiang X M. Dynamic fuzzy wavelet neural network model for structural system identification[J]. J of Structural Engineering, 2006, 132(1): 102-110.
- [9] Juang C F. A TSK-type recurrent fuzzy network for dynamic systems processing by neural network and genetic algorithms[J]. IEEE Trans on Fuzzy Systems, 2002, 10(2): 155-170.
- [10] Lee C H, Teng C C. Identification and control of dynamic systems using recurrent fuzzy neural networks[J]. IEEE Trans on Fuzzy Systems, 2000, 8(4): 349-366.
- [11] Sadeghi B H M. A BP-neural network predictor model for plastic injection molding process[J]. J of Materials Processing Technology, 2000, 103(3): 411-416.
- [12] Xiao Z, Ye S J, Zhong B, et al. BP neural network with rough set for short term load forecasting[J]. Expert Systems with Applications, 2009, 36(1): 273-279.
- [13] Yi J Q, Wang Q, Zhao D B, et al. BP neural network prediction-based variable-period sampling approach for networked control systems[J]. Applied Mathematics and Computation, 2007, 185(2): 976-988.
- [11] 陆文星, 梁昌勇, 丁勇. 一种基于证据距离的客观权重确定方法[J]. 中国管理科学, 2008, 16(6): 95-99.  
(Lu W X, Liang C Y, Ding Y. A method determining the objective weights of experts based on evidence distance[J]. Chinese J of Management Science, 2008, 16(6): 95-99.)
- [12] 刘思峰, 袁文峰, 盛克勤. 一种新型多目标智能加权灰靶决策模型[J]. 控制与决策, 2010, 25(8): 1160-1163.  
(Liu S F, Yuan W F, Sheng K Q. Multi-attribute intelligent grey target decision model[J]. Control and Decision, 2010, 25(8): 1160-1163.)
- [13] 徐泽水. 直觉模糊信息集成理论及应用[M]. 北京: 科学出版社, 2008.  
(Xu Z S. Theory of aggregating intuitionistic fuzzy information and application[M]. Beijing: Science Press, 2008.)

(上接第1041页)