

汽油调合过程的神经内模优化控制*

陈捷

(深圳中兴通讯股份有限公司·深圳, 518004)

王宁 王树青

(浙江大学工业控制技术研究所·杭州, 310027)

摘要: 针对某炼油厂的管道汽油自动调合系统, 建立了汽油调合过程的神经网络模型, 在此基础上, 设计出汽油辛烷值的神经内模优化控制器. 仿真结果表明了对产品汽油辛烷值的在线闭环实时优化控制方案是可行的.

关键词: 汽油调合; 管道汽油自动调合系统; 神经网络; 内模控制; 非线性优化

Neuro-Internal Model Based Optimal Control for Gasoline Blending Processes

Chen Jie

(Zhongxing Telecom Limited·Shenzhen, 518004, P. R. China)

Wang Ning and Wang Shuqing

(Institute of Industrial Process Control, Zhejiang University·Hangzhou, 310027, P. R. China)

Abstract: In this paper, a static Double Parallel Feed Forward Neural Network combined with a linear dynamic model is proposed to model the gasoline pipe blending system of a refinery. And the optimal controller based on the neuro-internal model is designed to optimize and control the gasoline octane number on real time. Simulation control results on gasoline-blending process prove the effectiveness of this novel controller.

Key words: gasoline-blending; automatic gasoline pipe blending system; neural network; internal model control; nonlinear programming

1 引言 (Introduction)

汽油调合是指炼油厂通过合理利用现有的多种汽油组分, 按适当的配方(或比例)混合, 调配出所有指标都合乎要求的产品汽油. 其中一个最重要指标是辛烷值(RON). 由于汽油调合过程机理非常复杂, 各组分之间存在调合效应, 因而难以建立精确的调合模型, 使得对最终调合产品的辛烷值预测或计算变得十分困难. 而国内外通常采用的是按照离线优化的配方进行调合^[1~3], 这样难以保证产品的质量, 也无法达到实际最优调合.

本文采用神经网络的方法对汽油调合过程进行建模, 并由此提出汽油辛烷值的神经内模优化控制方案, 达到了在线优化调合的目标.

2 汽油调合神经网络模型的建立 (Neural network model of gasoline blending)

针对某大型炼油厂的汽油管道调合过程, 本文提出如图 1 所示的双并联前向神经网络结构来建立调合过程的静态模型. 该神经网络由一个具有隐层的三层前向网络 NN_1 和一个不含隐层的线性前向网络 NN_2 并联构成^[4]. 不含隐层的前向网络在实现

线性映射时非常快, 多层前向网络则能实现非线性映射, 因而这种神经网络具有快速的收敛特性以及良好的函数映射和表达能力.




图 1 双并联前向神经网络模型

Fig. 1 Double parallel feed forward neural network model

图 1 中 NN_1 和 NN_2 有相同的输入节点, 它们的输出节点之和 v 作为产品汽油的辛烷值. 输入节点 $x_i (i = 1, \dots, n)$ 则选择为每一路原料汽油的流量分数. NN_1 中的隐层节点数为 m . NN_1 隐节点的作用函数选择为 s 型函数

* 国家自然科学基金(69774023)资助项目.
本文于 1997 年 9 月 1 日收到, 1998 年 9 月 21 日收到修改稿.

$$f_s(x) = 1/(1 + e^{-x}). \quad (1)$$

网络采用 BP 学习算法修正权值 $w_{ij}, h_j, c_i (i = 1, \dots, n; j = 1, \dots, m)$.

由于参与调合的 n 路组分油的辛烷值 $a_i (i = 1, \dots, n)$ 通常是已知的或知道其大致范围, 因此可以充分利用这些信息, 在网络学习前, 将网络的权值 $c_i (i = 1, \dots, n)$ 的初值设置为对应的组分油辛烷值, 即

$$c_i(0) = a_i, \quad i = 1, \dots, n, \quad (2)$$

这样可以提高网络的学习收敛速度. 权值 w_{ij} 和 h_j 的初值可以取 $(-1, 1)$ 之间的随机数.

3 汽油管道调合过程的动态模型 (Dynamic model of gasoline blending process)

3.1 汽油管道调合系统 (Gasoline pipe blending system)

某炼油厂采用的汽油管道调合工艺过程原理图如图 2 所示. 四种原料油: 催化汽油、重整汽油、烷基化油和 MTBE 按不同比例流经管道调合器后直接调合出产品汽油.

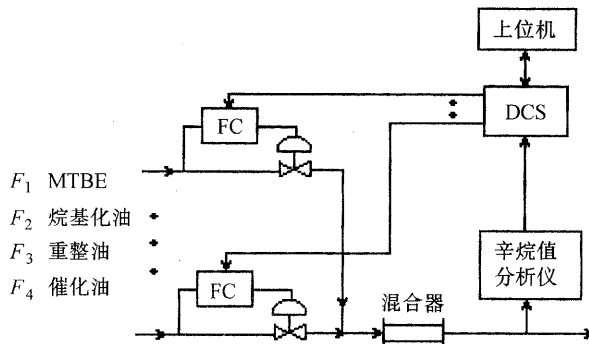


图 2 汽油管道调合系统工艺自控图

Fig. 2 Gasoline pipe blending system

图中, 上位机采用工业 PC 机, 进行静态建模与优化计算等工作. 下位机为小型的 DCS, 完成辛烷值和流量的闭环控制. 辛烷值分析仪采用 8154 型辛烷值在线分析仪, 在非校样期间内其数据输出周期约为 1.5 分钟.

3.2 广义调合对象的动态模型 (Dynamic model of generalized blending object)

把汽油组分在管道中的混合过程、调节阀特性以及辛烷值分析仪的测量特性作为一个广义受控对象, 通过分析辛烷值随流量变化的阶跃响应曲线, 可知调合过程具有大纯滞后及大惯性特点, 纯滞后和过渡过程均达十几分钟^[5]. 据此, 本文建立广义调合对象的非线性动态模型为

$$y_m(s) = f_{NN}(x_1(s), \dots, x_4(s)) \cdot \frac{e^{-\tau s}}{1 + T_s s}, \quad (3.1)$$

$$x_i(s) = F_i(s) / \sum F_i(s), \quad i = 1, \dots, 4. \quad (3.2)$$

即在静态神经网络模型的基础上串联一个一阶惯性加纯滞后的动态环节. 上式中 $f_{NN}(\cdot)$ 表示图 1 所示的汽油调合静态神经网络非线性模型, $F_i(s) (i = 1, \dots, 4)$ 为流量的拉氏变换.

4 调合过程的内模优化控制器 (Internal-model optimal control for blending process)

4.1 控制器结构及算法 (Structure and algorithm of the controller)

由于内模控制具有结构简单, 鲁棒性强等优点^[6], 基于前述的神经网络动态模型, 本文设计了如图 3 所示的神经内模优化控制器. 图中, r 为设定辛烷值, y_p 为测量辛烷值, y_m 为模型输出辛烷值. 模型 \tilde{P} 为(3)式表示的神经网络动态模型. 滤波器为

$$f(s) = \frac{1}{1 + \lambda s}. \quad (4)$$




图 3 神经内模优化控制器结构

Fig. 3 Structure of neuro-internal model based optimal controller

由于参加调合的原料汽油具有不同的价格系数, 为获得最大经济效益, 使调合汽油的成本最低, 优化控制器 C 设计为求解如下一个优化命题

$$\min_{F_i} J = \sum_{i=1}^4 P_i F_i \quad (5.1)$$

$$\text{s. t. } \sum_{i=1}^4 F_i = F_t, \quad (5.2)$$

$$F_l i \leq F_i \leq F_h i, \quad (5.3)$$

$$f'_{NN}(F_1, \dots, F_4) = r_e. \quad (5.4)$$

式中 J 为单位时间的调合成本, $P_i (i = 1, \dots, 4)$ 是原料汽油的价格系数, F_i 为参加调合的原料汽油的流量, $F_l i$ 和 $F_h i$ 分别为各路原料油流量的下限和上限, F_t 为调合汽油总流量. $f'_{NN}(\cdot)$ 为神经网络调合模型, 表示产品汽油辛烷值与原料汽油流量的非线性关系. 式中 r_e 为优化控制器的输入.

求解非线性规划问题有多种方法, 针对(5.1)~(5.4)式的优化问题, 可以结合罚函数法和梯度法, 首先借用罚函数把该有约束优化问题转化为无约束优化问题, 再用梯度法求解转化后的无约束优化问题.

从(5.1)~(5.4)式的优化问题可看出,在(5.4)式的约束下,优化控制器 C 等价于神经网络模型 $f_{NN}(\cdot)$ 的最优逆函数.即

$$F = f_{NN}^{-1}(r_e) |_{\min J}, \quad F = (F_1, \dots, F_4). \quad (6)$$

可见优化控制器 C 通过在线反复进行优化计算,求解优化问题 J 来实施控制作用.实现了辛烷值的闭环实时优化控制.

4.2 控制器的鲁棒稳定性 (Robust stability of the controller)

由于控制器 $C = f_{NN}^{-1} |_{\min J}$, 为便于分析,将图3的控制系统用图4的形式描述.其中

$$G_d(s) = \frac{e^{-\tau s}}{1 + Ts}. \quad (7)$$




图4 神经内模控制器的等价形式

Fig. 4 Equivalent form of neuro-internal model controller

将 $C \cdot P$ 视为广义对象,则 $G_d(s)$ 为广义标称对象的模型.设模型误差满足

$$\left| \frac{C \cdot P - G_d(j\omega)}{G_d} \right| \leq l_m(\omega). \quad (8)$$

可以推证该控制器能保证鲁棒稳定性的充分必要条件是^[6]

$$\| f \cdot G_d \cdot l_m \|_{\infty} = \sup_{\omega} | f \cdot G_d \cdot l_m(\omega) | < 1, \quad (9)$$

由(4),(9)式可知滤波器的设计应保证控制系统的鲁棒稳定.模型失配越严重,则 λ 应当越大,以满足(9)式,保证系统的稳定性.

该神经内模优化控制器具有以下特点:

1) 优化控制器 C 采用非线性规划算法求取神经网络的最优逆解,算法简便,易于实现,避免了一般的神经内模控制方法需建立被控对象逆动态的神经网络模型的复杂过程^[7].

2) 对于稳定的控制对象,当模型准确时,闭环控制系统稳定;当模型失配时,由于引入反馈滤波器 f ,增强了控制器的鲁棒性,滤波器参数 λ 越大,则控制器的鲁棒性越强.

3) 不管模型与对象是否失配,只要闭环系统稳定,则无稳态误差.且优化控制器 C 是在线进行优化计算,直至系统达到稳态,保证了稳态最优.

5 仿真结果 (Simulation results)

5.1 神经网络建模 (Neural network modeling)

某炼油厂高标号汽油由催化汽油、重整汽油、烷基化油和 MTBE 调合而成.设这四种油的辛烷值分别为 89,92,95 和 115,为便于仿真,设实际调合方程为^[3]

$$v = f_p(x_i) = 89x_1 + 92x_2 + 95x_3 + 115x_4 + 5x_1x_2 - 4x_1x_3 + 15x_1x_4 - 3x_2x_3 + 9x_2x_4 + 5x_3x_4. \quad (10)$$

用(10)式随机给出 (x_i, v) 的 50 组样本数据对,使用本文图 1 设计的神经网络对这组样本数据进行学习,经 100 步学习后,计算出的平方误差 $E = 0.017$.另随机取 50 组新输入样本,经(10)式计算结果与网络计算结果的误差如图 5 所示,可以看出网络的逼近精度在 0.2 个辛烷值以内.




图5 输入为新样本时的网络误差

Fig. 5 Network error for the new sample input

5.2 辛烷值的神经内模优化控制 (Neuro-internal model based optimal control of octane number)

设图 2 和图 3 中的实际调合过程 P 为如下形式

$$\begin{cases} x_i = F_i / \sum_{i=1}^4 F_i, & i = 1, \dots, 4, \\ y_p(s) = \frac{e^{-\tau s}}{1 + Ts} \cdot f_p(x_i). \end{cases} \quad (11)$$

式中 $T = 6\text{min}$, $\tau = 15\text{min}$, $f_p(\cdot)$ 如(10)式定义. F_1, F_2, F_3, F_4 分别为四路原料油即催化油、重整油、烷基化油和 MTBE 的流量.约束为

$$\begin{cases} 130 \leq F_1 \leq 150, & 0 \leq F_2 \leq 100, \\ 0 \leq F_3 \leq 50, & 0 \leq F_4 \leq 28, \\ \sum_{i=1}^4 F_i = 200. \end{cases} \quad (12)$$

目标函数

$$J = F_1 + 1.5F_2 + 2F_3 + 4F_4. \quad (13)$$

利用 5.1 节中训练好的神经网络模型,采用前述的神经内模优化控制方法进行辛烷值的闭环控制,控制周期为 2min,仿真试验如下:

1) 设定值跟踪试验.

(4)式的模型动态环节部分与对象(11)式中的

动态环节相同,滤波器参数 $\lambda = 3$. 设定值跟踪曲线和控制输出 F_i 曲线分别如图 6(a)和图 6(b)所示.

2) 对模型失配的鲁棒性试验.

对象的动态环节发生变化为 $T = 8\text{min}$, $\tau = 18\text{min}$. 而模型参数不变. 重复试验(1)中的过程. 对应滤波器参数 $\lambda = 1.2$ 和 $\lambda = 20$ 的响应曲线分别如




图 6(a) 无动态模型误差的跟踪曲线($\lambda=3$)
Fig. 6(a) Responses when no dynamic model errors ($\lambda=3$)




图 7(a) 存在动态模型误差的跟踪曲线($\lambda=1.2$)
Fig. 7(a) Responses when existing dynamic model errors ($\lambda=1.2$)




图 8(a) 存在动态模型误差的跟踪曲线($\lambda=20$)
Fig. 8(a) Responses when existing dynamic model errors ($\lambda=20$)

图 7,图 8 所示.

从 2 个试验中可以看出,虽然神经网络训练的精度并不高(在 0.2 个辛烷值以内),甚至在动态模型也存在较大的误差的情况下,本文设计的神经内模控制器仍然能够对辛烷值进行有效的控制,控制器对模型精度要求不高,具有很强的鲁棒性.




图 6(b) 控制流量输出
Fig. 6(b) Control output of flow




图 7(b) 控制流量输出
Fig. 7(b) Control output of flow




图 8(b) 控制流量输出
Fig. 8(b) Control output of flow

6 结论(Conclusion)

从仿真结果看,本文针对汽油调合过程提出的神经网络模型具有收敛速度快、所需样本少等特点. 基于该神经网络模型建立的内模优化控制器具有良好的控制品质,即使在神经网络模型训练精度不高及存在动态模型误差的情况下仍能进行有效的控制,无稳态误差. 控制器具有强鲁棒性,而且可通过在线调整滤波器的参数 λ , 来改善控制器的鲁棒性. 本文的工作实现了对汽油调合过程的闭环实时优化控制,为工业过程控制提出了一种先进控制方法.

参考文献(References)

- 1 任军,李兵.汽油调合的目标规划方法.石油炼制与化工,1994,(25):24-28
- 2 张星.汽油的辛烷值调合特性及调合方案的优化.石油炼制,1988,(10):26-32
- 3 William E M. Optimum blending gives best pool octane. Oil & Gas J., 1986, 63(8):63-66
- 4 何明一.神经计算原理·语言·设计·应用.西安:西安电子科技大学出版社,1992
- 5 陈捷.神经控制理论及工业应用研究.[博士学位论文].杭州:浙江大学,1996

进行负荷预测的特殊复杂性,本系统的实验结果已达到了实际的设计指标.这一研究为解决一般的经济预测问题提供了一类全新的智能化方法.

参考文献(References)

- 1 Box G E P and Jenkins G M. Time Series Analysis: Forecasting and Control. Holden-Day Inc., 1976
- 2 汪日康等编著. 计算机决策支持系统. 上海:上海科学普及出版社, 1993
- 3 刘晨晖. 电力系统负荷预报理论与方法. 哈尔滨:哈尔滨工业大学出版社, 1987
- 4 辛开远等. 电力系统短期负荷预报的几种方法. 电力情报, 1993 (3):9-14
- 5 侯志俭等. 电力系统短期负荷预报的几种改进手段. 电力系统自动化, 1996, 20(7):27-31
- 6 张昊, 吴捷. 通用的集成电力调度自动化系统. 中国电力, 1997, 30 (3):16-19
- 7 Pedrycz W. Fuzzy Control and Fuzzy System. New York: Res. Stud. Press, 1993
- 8 Wang L X. Adaptive Fuzzy System and Control-Design and Stability Analysis. New York: PTR Prentice-Hall, 1994
- 9 Liu K et al. Comparison of very short-term load forecasting techniques. IEEE Trans. on Power Systems, 1996, 11(2):877-882
- 10 赵振宇, 徐用懋. 模糊理论和神经网络的基础与应用. 北京, 广西:清华大学出版社 & 广西科学技术出版社, 1996

本文作者简介

郁滨 1964年生. 1986年毕业于上海交通大学电子工程系, 1994年获华南理工大学自动控制理论及应用专业硕士学位, 1999年华南理工大学控制理论与控制工程专业博士毕业. 主要研究方向为专家系统, 模糊控制理论与应用, 工业自动化技术等.

张昊 1969年生. 1991年毕业于国防科技大学自动控制专业, 1994年获华南理工大学生物电子学硕士学位, 1997年获华南理工大学自动控制理论及应用专业博士学位, 现为广东省科学院自动化工程研制中心助理研究员. 主要研究方向为智能控制理论与应用, 电力系统自动化以及工业自动化工程等.

钟慕良 女. 1936年生. 华南理工大学自动控制工程系教授, 长期从事机电一体化及现代控制方法的研究.

毛宗源 见本刊1999年第1期第20页.

周其节 见本刊1999年第1期第42页.

(上接第535页)

- 6 Morari M and Zafiriou E. Robust Process Control. Prentice-Hall, Englewood Cliffs, N. J., 1989
- 7 Hunt K J, Sbarbaro D, Zbikowski R and Gawthrop P J. Neural networks for control systems—A survey. Automatica, 1992, 28(6):1083-1112

本文作者简介

陈捷 1968年生. 分别于1989年和1992年在华中理工大学自动控制工程系获学士及硕士学位, 1996年获浙江大学工业自动化专业博士学位, 1998年西南交通大学博士后出站. 现就职于深圳中兴通

讯股份有限公司.

王宁 1961年生. 1992年在华中理工大学获工业自动化专业博士学位, 1994年浙江大学博士后出站, 现为浙江大学副研究员, 发表了数十篇神经控制方面的论文. 主要从事神经控制, 专家智能控制, 控制理论及工业过程优化控制等方面的研究.

王树青 1939年生. 1964年毕业于浙江大学, 现为浙江大学教授, 博士生导师及工业控制技术国家重点实验室主任. 主要从事智能控制, 控制理论及工业生产过程模型化与优化控制, 计算机控制和集成生产系统等方面的研究.