

文章编号:1000-582X(2009)01-0105-06

焦炉集气管压力自适应预测解耦控制系统设计

张世峰,周建芳

(安徽工业大学 电气信息学院,安徽 马鞍山 243002)

摘要:针对焦炉集气管压力系统具有强耦合、强干扰、典型非线性、时滞等特点,在系统控制过程中将压力分段考虑,用基于 RBF 神经网络辨识的单神经元控制器和 PID 控制相结合的方法,保证集气管压力稳定在工艺要求的范围内;在总管控制级用 RBF 神经网络预测模型对鼓风机机前吸力的实际输出进行超前预测以克服鼓风机控制系统的时滞。仿真示例和应用结果都表明该方案具有理想的控制效果。

关键词:集气管压力;鼓风机系统;预测控制;解耦;神经网络控制

中图分类号:TP229

文献标志码:A

A radial basis function neural network based self-adapting predictive decoupling control system for gas collector pressure in coke ovens

ZHANG Shi-feng, ZHOU Jian-fang

(Department of Electrical Engineering & Information, Anhui University of Technology,
Ma'anshan 243002, P. R. China)

Abstract: Pressure is measured at different levels in the loop layer because self-adapting predictive decoupling control systems are strongly coupled, disturbed, and non-linear and there is a long time delay for gas collector pressure systems in coke ovens. By combing the traditional neural network control and proportional integral differential(PID) controllers based on radial basis function(RBF) neural network identification, the gas collector pressure is ensured to reach the desired technology range. The prediction model of an RBF neural network is used for advanced prediction of the actual output pressure to overcome delays in general gas collection. The simulation results and application indicate that the method can obtain ideal control results.

Key words: pressure of gas collectors; fan system; predictive control; decoupling; neural network control

在钢铁企业的炼焦生产过程中,焦炉集气管压力的稳定性与焦炉的正常生产和使用寿命密切相关。由于集气管压力系统是一个耦合严重、具有高度非线性、时变特性、扰动变化激烈且幅值大的多变量系统^[1],因此,难以用常规方法控制。近年来国内外对集气管压力控制问题在理论与实践方面进行了大量探索^[2],如文献[3]将遗传算法和模糊神经网络相结合,用遗传算法对模糊神经网络的结构和参数进行优

化,实现了焦炉集气管压力的单回路控制和解耦控制,具有一定的动态性;文献[4-6]采用模糊控制实现了单回路控制和组内、组间解耦;文献[7]采用补偿解耦算法实现了组内和组间解耦。由于集气管系统的复杂性,这些方法能起到一定的效果但是较难处理各种复杂的工况。针对焦炉集气管系统的结构和特点,采用将可变参数 PID 控制,单神经元 PID 控制、神经网络辨识^[8]、神经网络预测模型相结合的方法,设计

收稿日期:2008-07-20

基金项目:安徽省教育厅自然科学研究资助项目(KJ2008B104)

作者简介:张世峰(1959-),男,安徽工业大学副教授,硕士生导师,主要从事控制理论及应用和计算机控制技术等方面研究,(Tel)13805558903;(E-mail)zhangsf@ahut.edu.cn.

混合智能控制器,实现了 NNC 控制器参数的在线调整,并实现了被控对象的解耦,克服了系统的时滞,保证了集气管压力稳定在工艺要求的范围内。

1 控制问题描述

图 1 是某钢厂焦炉集气管系统的结构。该厂有 3#、4# 两座焦炉,每座焦炉都有 2 个集气管,集气管网不对称分布。集气管在组内汇总后,经组间汇总,再连通到鼓风机侧单集气管总管上,集气管总管很长,组间管道较长,组内管道相对较短。




图 1 集气管及鼓风机系统

集气管压力控制问题可以分解为两部分:焦炉集气管智能控制单元和鼓风机智能控制单元,如图 1 所示。各焦炉集气管通过调节集气管上的蝶阀开度保持集气管压力的稳定,通过相互协调解决它们之间耦合问题。鼓风机调速控制的主要目标是保证鼓风机吸力相对稳定,集气管压力控制系统是以压力 p_1 、 p_2 、 p_3 、 p_4 为被控量,以蝶阀角 α_1 、 α_2 、 α_3 、 α_4 为控制量,通过控制鼓风机转速调节总管吸力 p_5 (通常取压点在初冷器前)和调节集气管蝶阀的开度来达到控制压力 p_1 、 p_2 、 p_3 、 p_4 。正常时要求控制集气管压力在 120 Pa 左右,工艺要求上下波动一般不能超过 ± 20 Pa。

集气管压力系统是一个受多种因素影响的复杂系统,根据生产状况主要表现在以下几个方面^[9]:

1) 焦炉之间的相互耦合影响。两座焦炉共用一个鼓风机,而鼓风机对各个集气管的吸入管距离长短不等,管路又不对称,吸力分配不可能都合适。在机前吸力不变的情况下,任一焦炉压力的波动,都会影响其它焦炉压力的稳定。

2) 焦炉炉况对系统的影响。由于两座焦炉炉况不一样,装煤、推焦、炉门开启时间不同及煤气发生量的变化势必引起压力的波动。

3) 机后压力变化的影响。在鼓风机转速不变的情况下,机后设备的阻力发生变化或煤气用户的用量发生变化时,都会引起机后压力的变化,进而引起机前吸力的变化。在煤气发生量稳定的情况下,机后压力变化会引起集气管压力的强力波动。

2 焦炉集气管控制器的设计

由以上分析可知,焦炉集气管压力控制系统很

难建立精确的数学模型。传统的 PID 控制器在对一般的对象进行控制时,如果干扰较弱,系统指标要求较低的时候,是可以获得不错的控制效果,而且往往能达到相当的精度。但是,对于焦炉集气管压力控制系统,生产工艺对系统的超调有比较严格的限制,同时要求系统有相当的快速性。此时传统的 PID 就难以达到控制要求。在此,将压力分段考虑,当在推焦、加煤、平煤时或集气管的压力很高或者很低时,用变参数 PID 控制,来做到快速的调节阀门开度来脱离高压或者低压状态。当压力在正常范围波动时,由基于 RBF 网络辨识的单神经元 PID 控制器作为集气管压力单回路控制的控制器,在线调整控制系统参数,使系统避免出现等幅振荡和偏差不均且较大的状态,基于 RBF 网络辨识的单神经元 PID 控制器,其结构如图 2 所示。

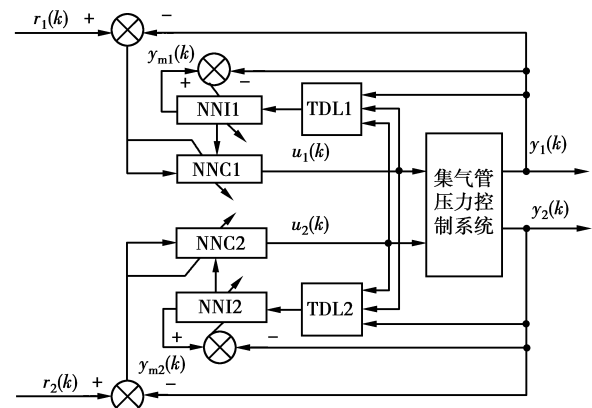


图 2 基于 RBF 网络的焦炉集气管 NNC 控制系统结构图

单神经元 PID 作为控制器,RBF 网络作为辨识器^[10-12],实现对被控对象的 Jacobian 信息辨识,其中不仅考虑到集气管之间的相互耦合影响,而且考虑到鼓风机系统对集气管系统的耦合影响。单神经元控制器的自适应功能是通过改变权重来实现的,学习规则就是调整权重的算法,它是单神经元控制器的核心。这里权系数的调整是按有监督的 delta 学习规则来实现的。

以 NNC1 为例,定义控制误差为

$$e_1(k) = r_1(k) - y_1(k). \quad (1)$$

单神经元控制器的输入为

$$\begin{cases} xc_1(k) = e_1(k); \\ xc_2(k) = e_1(k) - e_1(k-1); \\ xc_3(k) = e_1(k) - 2e_1(k-1) + e_1(k-2). \end{cases} \quad (2)$$

其控制算法和学习算法为

$$u_1(k) = u_1(k-1) + k \sum_{i=1}^3 \omega c_i(k) xc_i(k), \quad (3)$$

$$J_1 = \frac{1}{2} (rin_1(k) - y_1(k))^2, \quad (4)$$

$$\omega c_i(k) = \omega c_i(k-1) + \Delta \omega c_i(k),$$

$$\begin{aligned} \Delta \omega c_i(k) &= -\eta_i \frac{\partial J_1}{\partial \omega c_i} = -\eta_i \frac{\partial J_1}{\partial y_1} \cdot \frac{\partial y_1}{\partial u_1} \cdot \frac{\partial u_1}{\partial \omega c_i} \\ &= \eta_i e_1(k) \frac{\partial y_1}{\partial u_1} x c_i(k), \end{aligned} \quad (5)$$

式(5)中, $\partial y_1(k)/\partial u_1(k)$ 为被控对象的 Jacobian 信息, 可通过 RBF 网络的辨识获得。

$\eta_i (i=1, 2, 3)$ 分别为积分、比例、微分的学习速率, k 为神经元的比例系数, $k > 0$ 。 k 值的选择非常重要。 k 越大, 则快速性越好, 但超调量大, 甚至可能使得系统不稳定; k 值选择过小, 会使系统的快速性变差。

单神经元 PID 控制器在压力波动大或系统等幅振荡时, 根据从 RBF 神经网络辨识器获得的梯度调整所需的 Jacobian 信息在线对参数 $\omega c_i(k)$ 进行整定, 使系统获得对应于某种最优控制律下的 PID 参数。 这样, 可加快收敛速度, 做到快速的调节阀门开度, 使系统脱离高压或者低压状态, 避免输出振荡而影响系统的稳定性。 从而适应了系统运行状态的实时变化, 保证集气管压力稳定在工艺要求的范围内; 同时, 由于并联的 RBF 神经网络辨识器的输入包含了其他通道中的控制器的输出信息, 这样辨识器的辨识信息同时包含了其他通道对其耦合影响^[13-14], 进而实现了 2 个焦炉集气管的解耦以及集气管与鼓风机之间的解耦。

3 鼓风机液力耦合器控制器的设计

鼓风机的吸力的变化会引起 4 个集气管压力的波动, 并且转速的微量变化会引起集气管压力很大的波动, 经过多个调节周期才能稳定下来, 因此采取以保集气管压力为主, 同时兼顾尽量降低鼓风机转速的非定值调节方案, 鼓风机转速的调节量由基于 RBF 网络的单神经元 PID 控制器计算给出。

鼓风机机前吸力因为初冷器的原因, 从鼓风机转速变化到机前吸力变化有明显时滞的特性。 基于 RBF 网络建立的自适应预测单神经元 PID 控制器, 是结合递推多步预测算法和自适应单神经元 PID 控制器构成的, 其结构图如图 3 所示。 控制方案可分为两部分: 第一部分是最优预测的设计。 首先, 用 RBF 网络依据过去的输入序列和输出序列及当前的输入来预测被控对象的未来输出值。 RBF 神经网络预测模型可以不知道被控对象的参数, 也不要控制对象的参数恒定, 它会根据所得到的信息在线调整预测模型的结构, 使其与被控对象模型尽可能地接近。 最后将预测值与期望值的偏差形成反馈作 NNC 的输入, 从而消除时变时滞对控制系统输出的影响。 第二部分是基于 RBF 网络的自适应单神经元 PID 控制器的设计。 通过 RBF 网络的学习在线整定 NNC 的参数。




图 3 基于 RBF 网络的自适应预测 NNC 控制器

3.1 基于 RBF 网络的递推多步预测模型

对于大滞后系统, 因为当前施加的控制作用需要很长时间才能在输出中反映出来, 因此, 需选择一个合适的当前控制作用, 使系统未来的输出结果满足期望要求。 可见, 克服滞后系统的影响依赖于对系统输出的预测。

RBF 网络是一种非常有效的局部逼近神经网络, 它广泛用于函数逼近、自适应滤波等领域。 以 RBF 网络作为被控对象的单步预测模型^[15], 其结构是三层网络: 输入层、隐含层和输出层。 假设每层的节点数分别为 p 、 h 和 L 。 网络的输入向量为 $\mathbf{x} = [x_1, x_2, \dots, x_p]^T$, 输出向量为 $\mathbf{y} = [y_1, y_2, \dots, y_L]^T$ 。

RBF 网络中径向基的形式有很多种, 选取高斯基函数作为隐含层的激发函数

$$h_i(\mathbf{x}) = \exp\left[-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\sigma_i^2}\right], \quad i=1, 2, \dots, h, \quad (6)$$

其中, \mathbf{c}_i 为隐含层第 i 个神经元的中心; σ_i 为相应节点的高斯基函数尺度因子。 网络的输出为

$$y_j = \sum_{i=1}^h \omega_{ij} h_i(\mathbf{x}), \quad j=1, 2, \dots, L, \quad (7)$$

其中, ω_{ij} 为网络传输的权值。

对于大滞后系统, 离散模型可表示为

$$\begin{aligned} \mathbf{y}(k) &= f[\mathbf{y}(k-1), \dots, \mathbf{y}(k-n), \\ &u(k-d), \dots, u(k-d-m)], \end{aligned} \quad (8)$$

其中: $u(k)$ 为控制量; $\mathbf{y}(k)$ 为过程控制量的输出; d 为滞后拍数; $f(\cdot)$ 为线性或非线形函数。 其 RBF 模型描述为^[16]

$$\begin{aligned} \mathbf{y}_m(k) &= f[\mathbf{y}(k-1), \dots, \mathbf{y}(k-n), \\ &u(k-d), \dots, u(k-d-m)]. \end{aligned} \quad (9)$$

则 RBF 网络的预测模型为

$$\begin{aligned} \mathbf{y}_m(k+1) &= f[\mathbf{y}(k), \mathbf{y}(k-1), \dots, \mathbf{y}(k-n+1), \\ &u(k-d+1), \dots, u(k-d-m+1)]. \end{aligned} \quad (10)$$

考虑到多步预测模型中, 部分未来时刻的控制量并不影响部分未来时刻的输出量, 基于上述单步预测模型, 采用递推算算法构成多步预测模型, 从而 d 步超前预测模型的表达式为

$$\begin{aligned} \mathbf{y}_m(k+d) &= f[\mathbf{y}(k-1+d), \dots, \mathbf{y}(k-n+d), \\ &u(k), \dots, u(k-m)], \end{aligned} \quad (11)$$

由于 k 时刻, $\mathbf{y}(k-1+d)$, $\mathbf{y}(k-n+d)$ 是未来的输出值, 无法测得, 所以使用预测模型的预测值 $\mathbf{y}_m(k-1+d)$, $\mathbf{y}_m(k-n+d)$ 来代替, 所以得表达式如下

$$\mathbf{y}_m(k+d) = f[\mathbf{y}_m(k-1+d), \dots, \mathbf{y}_m(k-n+d), u(k), \dots, u(k-m)]. \quad (12)$$

其递推多步模型结构如图 4 所示。由此可以看出如果以系统 k 时刻式(12)右边各变量作为 RBF 网络的输入,以 $\mathbf{y}_m(k+d)$ 作为输出,以 $J = \frac{1}{2} [\mathbf{y}(k) - \mathbf{y}_m(k)]^2$ 作为性能指标,来训练 RBF 网络,当 J 满足误差要求时,便可得到基于 RBF 网络的对象模型与 d 步输出预测 $\mathbf{y}_m(k+d)$ 。

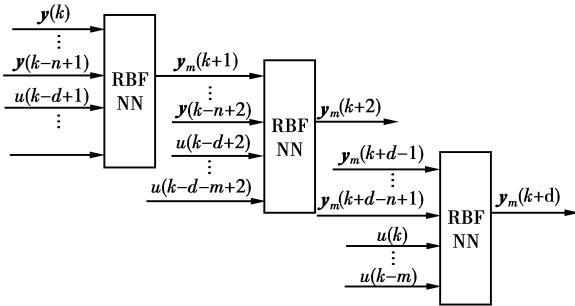


图 4 基于 RBF 网络的递推多步预测模型结构图

上述预测模型是离线建立的,在线控制时,若单步预测模型失配,可能存在误差累积,或当系统存在干扰等因素时,会导致预测输出存在偏差,因此有必要进行在线校正,以提高预测的准确性。这里采取直接校正的方法,校正后的系统多步预测值为

$$\mathbf{y}_p(k+d) = \mathbf{y}_m(k+d) + [\mathbf{y}(k) - \mathbf{y}_m(k)], \quad (13)$$

式(13)中, $\mathbf{y}_p(k+d)$ 是经过校正后的系统多步预测值, $\mathbf{y}(k)$ 为过程对象的输出量, $\mathbf{y}_m(k)$ 为系统预测模型的输出。

3.2 基于 RBF 网络的自适应预测 NNC 控制器

为了使系统的响应能够平滑的达到期望值,对输入信号进行滤波处理。滤波器采用一阶形式,即

$$y_r(k+1) = (1-\alpha)r(k) + \alpha y_r(k), \quad (14)$$

其中: $r(k)$ 为阶跃输入信号, $y_r(k)$ 为滤波处理后的期望值, α 为滤波系数 ($0 < \alpha < 1$)。

基于 RBF 网络的自适应预测的单神经元 PID 控制器的结构图如图 3 所示。其控制算法和学习算法都和集气管的控制器相同,只是控制误差为

$$e(k) = y_r(k+d) - y_p(k+d). \quad (15)$$

单神经元控制器的输入为

$$\begin{cases} \mathbf{x}_{c1}(k) = e(k); \\ \mathbf{x}_{c2}(k) = e(k) - e(k-1); \\ \mathbf{x}_{c3}(k) = e(k) - 2e(k-1) + e(k-2). \end{cases} \quad (16)$$

其控制算法和学习算法为

$$u(k) = u(k-1) + k \sum_{j=1}^3 \omega c_j(k) \mathbf{x}_{c_j}(k), \quad (17)$$

其中 $u(k)$ 为液力耦合器执行机构的控制输出值。

$$J = \frac{1}{2} [\mathbf{y}_r(k+d) - \mathbf{y}(k+d)]^2, \quad (18)$$

$$\omega c_j(k) = \omega c_j(k-1) + \Delta \omega c_j(k),$$

$$\begin{aligned} \Delta \omega c_j(k) &= -\eta_j \frac{\partial J}{\partial \omega c_j} \\ &= -\eta_j \frac{\partial J}{\partial y(k+d)} \cdot \frac{\partial y(k+d)}{\partial u} \cdot \frac{\partial u}{\partial \omega c_j} \\ &= \eta_j e(k) \frac{\partial y(k+d)}{\partial u} \omega c_j(k), \end{aligned} \quad (19)$$

其中, $\partial y(k+d) / \partial u(k)$ 是未知的,常规控制方法中一般用符号函数 $\text{sgn}[\partial y(k+d) / \partial u(k)]$ 代替,但这样会影响控制精度。若采用最优估计量 $y_p(k+d)$ 取代 $y(k+d)$,可明显改善控制效果,这里仍采用上面提及的多步预测模型的结构和参数,在线调整网络的输出 $y_p(k+d)$,从而获得准确的灵敏度信息 $\partial y(k+d) / \partial u(k)$ 。这样不必考虑模型本身的特性,便可得到良好的控制效果,同时简化了控制器的设计。在线控制时,只需要对多步递推预测的输出进行修正,自适应调整 NNC 控制器的 3 个参数即可,从而满足控制系统实时性的要求。

4 仿真示例

设有二变量耦合非线性时滞时变被控对象

$$\begin{cases} y_1(k) = \frac{a(k) \cdot y_1(k-1)}{1 + y_1(k-1)^2} + u_1(k-1) + 0.2u_2(k-2); \\ y_2(k) = \frac{a(k) \cdot y_2(k-1)}{1 + y_2(k-1)^2} + 0.8u_2(k-1) + 0.7u_1(k-2), \end{cases}$$

系数 $a(k)$ 是慢时变的, $a(k) = 1.2(1 - 0.8e^{-0.01k})$ 。

系统参考输入信号为


$$\begin{cases} r_1(k) = 1; \\ r_2(k) = 0. \end{cases}$$

仿真时,采样周期取为 1 s, NNC 控制器参数的学习速率取 $\eta_i = 0.01$,控制器 3 个参数取值范围取 $[-10, 10]$ 初始值。分别采用上述变参数 PID 和基于 RBF 辨识的 NNC 控制器相结合的方法对上述的被控对象进行仿真,经过 600 个采样周期后的 MATLAB 仿真结果如图 5 所示。其中图 5(a) 表示没有加干扰时 $y_1(k)$ 和 $y_2(k)$ 的仿真曲线输出,图 5(b) 表示在被控对象 $y_1(k)$ 上加了一个 $R = 0.1$ 干扰时的仿真曲线输出。


由仿真结果可以看出:1) 在最初 100 个采样周期,由于辨识器模型刚刚建立,辨识信息不够准确, PID 参数的调整还不能很好的适应输入信号的变化,解耦控制不太理想;2) 经过 100 个采样周期的学习后, RBF 神经网络辨识器就能精确的辨识系统模型,系统响应快,解耦控制效果较好;3) 随着学习的增加,辨识精度进一步提高,辨识信息较准确地反映了系统的运行状态,解耦控制相当理想。

在鼓风机系统仿真实验中,设被控对象为

$$\mathbf{y}(k) = \frac{b(k) \cdot \mathbf{y}(k-1) + u(k-1)}{1 + \mathbf{y}(k-1)^2},$$



(a)没加干扰时 y_1, y_2 的仿真曲线



(b)加干扰时 y_1, y_2 的仿真曲线

图 5 变参数 PID 和基于 RBFNN 辨识的 NNC 的输出响应

式中, $b(k)=0.6(1-0.8\exp(-0.2k))$, 系统参考输入信号分别为: $r(k)=1.0$ 和 $r(k)=0.9$ 。

仿真时, 采样周期取为 1 s, 滤波系数为 $\alpha=0.2$ 。采用带预测模型的神经网络 NNC 控制器对上述的被控对象进行仿真, 经过 600 个采样周期后的 MATLAB 仿真结果如图 6 所示。




图 6 被控对象的输出仿真图

图 6 中系统参考输入信号为 $r(k)=1.0$ 时是没加干扰时带预模型的 NNC 神经网络控制系统的仿真曲线。系统参考输入信号为 $r(k)=0.9$ 时是在 $t=300$ s 时加了一个 $R=-0.5$ 的干扰的仿真曲线。

从仿真结果可以看出, 基于 RBF 网络建立的自

适应预测单神经元 PID 控制器, 参数整定便利, 控制算法简单, 易于实现。通过递推多步预测算法预测系统的超前输出, 在吸力波动时, 使液力耦合器提前动作, 明显改善了滞后系统的控制品质, 并且具有一定的自适应性和鲁棒性。

5 讨论

采用上述设计方案对某钢厂焦炉集气管压力及鼓风机系统进行控制系统设计, 由北京和利时的 DCS 完成系统的软硬件实现, 工业现场共有二套鼓风机组, 电机功率均为 1 250 kW, 机组由液力耦合器改变鼓风机转速来调节初冷器前吸力, 两座焦炉, 其集气管压力变化曲线如图 7 所示(3#4#集气管压力曲线略)。




图 7 1#2#集气管压力变化曲线

集气管压力设定值为 120 Pa, 其中焦炉集气管压力 110~130 Pa 的采样占全部采样的 85%, 100~110 Pa 和 130~140 Pa 的压力采样占全部采样的 15%。当焦炉开盖、关盖、以及外送压力、煤气流量等因素引起集气管压力波动时, 系统能迅速调节集气管蝶阀开度使压力在 15 s 内达到稳定, 保证压力稳定在工艺要求波动范围内。有效地增强了系统的鲁棒性。

图 8 所示是智能 PID 控制在加煤推焦工况时 1 号焦炉集气管压力、2 号焦炉集气管压力以及初冷器前吸力的变化曲线, 集气管压力设定值为 120 Pa。初冷器前吸力设定值为一区间值, 根据工况的变化、两集气管压力的高低及蝶阀的开度在 $-0.6\sim-0.75$ 之间自动调节。从趋势图可以看出集气管压力的变化状况较好地满足了工艺要求。实际应用结果表明, 机前吸力波动很小, 集气管压力基本能控制在 120 ± 20 Pa, 在推焦、加煤等扰动情况下, 压力能在很短的时间内恢复正常。




图 8 智能控制下加煤推焦工况下压力和吸力的趋势图

6 结 论

将对单神经元 PID 控制、神经网络辨识、神经网络预测模型相结合的智能控制方案应用于集气管和鼓风机的控制系统。然后对该控制方案的控制效果进行了仿真,仿真结果该控制方案计算量小、跟踪时间短、网络收敛精度高,PID 参数很好的适应了环境的变化,解耦控制效果较好;该控制方案具有简单、易行、可靠、抗干扰能力强等优点,在对控制对象的数学模型难以确定的情况下,运用该控制方案能得到令人满意的效果。该控制方案可适用于其它类似的工业对象。

参考文献:

- [1] 吴晓苏,张中明. 焦炉集气管压力工业过程控制的研究[J]. 煤炭转化,2007,30(1):27-30.
WU XIAO-SU, ZHANG ZHONG-MING. Study on industrial process control of gas-collector pressure of coke furnace[J]. Coal Conversion, 2007,30(1):27-30.
- [2] CHAICHENKO V I, LAVROV K G. Pressure stabilization of direct coke oven gas in the gas collectors of coke batteries [J]. Coke & Chemistry (USSR), 2001,64 (7): 72-76.
- [3] 刘佳霓. 焦炉集气管压力模糊神经网络控制系统[J]. 中南民族大学学报:自然科学版,2004,23(3):54-56.
LIU JIA-NI. Fuzzy neural network pressure control system in air-collecting pipe of cookery[J]. Journal of South-Central University for Nationalities: Nature Science Edition, 2004,23(3):54-56.
- [4] 孙伟,杨东平. 焦炉集气管压力系统智能控制策略[J]. 中国矿业大学学报,2000,29(5):503-505.
SUN WEI, YANG DONG-PING. Intelligent control for pressure system of gas collecting pipe of coke oven[J]. Journal of China University of Mining & Technology, 2000, 29(5): 503-505.
- [5] 何成燕,吴敏. 集气管压力自适应模糊解耦控制系统的设计[J]. 计算机测量与控制,2006,(11):1477-1479.
HE CHENG-YAN, WU MIN. Adaptive fuzzy decoupling control system of gas collector pressure [J]. Computer Measurement & Control, 2006(11):1477-1479.
- [6] 李春华. 焦炉集气管压力多变量模糊控制系统[J]. 煤炭学报,2001,(2):195-198.
LI CHUN-HUA. Multi-variable fuzzy control system of gas collector pressure in coke oven[J]. Journal of China Coal Society, 2001(2):195-198.
- [7] 刘晓强,郝容. 补偿解耦算法在集气管压力控制中的应用[J]. 中国矿业大学学报,2000, 29(2):215-218.
LIU XIAO-QIANG, HAO RONG. Application of decouple arithmetic in collector pressure[J]. Journal of China University of Mining & Technology, 2000, 29(2): 215-218.
- [8] 刘金琨. 先进 PID 控制及其 MATLAB 仿真[M]. 北京:电子工业出版社,2003.
- [9] 舒雄鹰. 双焦炉集气管压力智能控制系统[J]. 自动化与仪表,2003,(1):39-41.
SHU XIONG-YING. Intelligent control system of double gas collector pressure in coke oven [J]. Automation and Instrument, 2003(1):39-41.
- [10] 李绍铭,刘寅虎. 基于改进型 RBF 神经网络多变量系统的 PID 控制[J]. 重庆大学学报:自然科学版, 2007, 30(2):53-57.
LI SHAO-MING, LIU YING-HU. PID control for multi-variable system based on ameliorative RBF neural networks[J]. Journal of Chongqing University: Natural Science Edition, 2007, 30(2):53-57.
- [11] CASTRO L N, ZUBEN F J. Automatic determination of radial basis functions: an immunity-based approach [J]. International Journal of Neural System, 2001, 11 (6): 523-535.
- [12] 翟东海,李力,靳蕃. 模糊神经网络用于非线性系统模型辨识[J]. 电子科技大学学报,2004,33(5):577-581.
ZHAI DONG-HAI, LI LI, JIN FAN. Application of fuzzy neural network in non-linear system identification [J]. Journal of Electronic and Technology University, 2004, 33(5):577-581.
- [13] 周国雄,赖旭芝,曹卫华,等. 焦炉集气管压力智能解耦控制系统的应用[J]. 中南大学学报:自然科学版, 2006(3):558-561.
ZHOU GUO-XIONG, LAI XU-ZHI, CAO WEI-HUA, et al. Application of intelligent decoupling control system for coke-oven collector pressure [J]. Journal of cent South university: Science and Technology, 2006, 37(3):558-561.
- [14] 薛昊洋,刘红军. 基于 BP 神经网络的多变量 PID 解耦控制[J]. 仪器仪表标准化与计量,2005(6):7-9.
XUE HAO-YANG, LIU HONG-JUN. Decoupling control of multivariable PID based on BPNN [J]. Standardization and Measurement of Instrumentation, 2005(6):7-9.
- [15] YANG C, WU M, SHEN D, et al. Hybrid intelligent control of gas collectors of coke ovens [J]. Control Engineering Practice, 2001,9 (7):725-733.
- [16] 胡灵燕,辛勇,等. 带预测模型的神经网络 PID 控制器[J]. 南昌大学学报:工科版,2001, 23(3):63-68.
HU LING-YAN, XIN YONG, et al. Neural networks PID controller by predictive model [J]. Journal of Nanchang University: Natural Science Edition, 2001,23(3): 63-68.

(编辑 侯 湘)