注:北京市自然科学基金资助项目(NO. 4162025)

摘要:针对水泥分解炉温度控制难题,利用某水泥厂实际生产的数据在 MATLAB 系统辨识工具箱 中辨识出了分解炉温度和分解炉喂煤量的一阶延时加滞后的系统模型。利用此模型,采用径向基 (RBF)神经网络监督控制算法对分解炉温度进行了控制。仿真结果表明,所用算法控制精度高。 在此基础上通过改变分解炉温度参考值,模拟不同工况,验证了此控制算法的有效性。与传统 PID 控制相比,所用算法在分解炉温度参考值发生改变后再次达到稳定的调节时间更短、响应更快。 关键词:水泥分解炉温度;建模;RBF 神经网络;监督控制 中图分类号:TP273 文献标识码:A 文章编号:1006-883×(2018)12-0025-08 收稿日期:2018-10-19

水泥分解炉温度的 RBF 神经网络监督控制

李东 艾红

北京信息科技大学自动化学院,北京 100192

一、引言

 水泥生产过程中,分解炉是预分解系统的核心 设备,其中涉及大量复杂的物理、化学反应过程, 并且伴有物料浓度、颗粒粒径的变化¹¹。分解炉温度 过高会引起第五级旋风筒内物料结皮堵塞,甚至烧坏 分解炉;温度过低将显著降低生料分解率,加重回转 窑负荷。因此,对分解炉温度的合理控制在实际生产 过程中非常重要。

模糊控制是模仿人脑推理决策基于模糊规则的控制^[2],因其可不依赖于被控对象的具体数学模型,无 需深入了解分解炉内各化学反应机理,控制器易于设 计等特点,在分解炉温度的控制中应用较广^[3-6]。在模 糊控制的基础上,王盛慧等^[7]采用了模糊控制与 PID 控制并联结合双作用的结构;李洪林等^[8]在这种结构 基础上采用了切换装置,先利用模糊控制粗调,再利 用 PID 精调;LiSW等^[9]采用了模糊控制调节 PID 的积分系数和微分系数,基于模糊规则的免疫控制调 节 PID 的比例系数的复合控制结构;李学军等^[10]采 用了三维模糊 PID 的串级结构。虽然模糊控制在分解 炉温度控制领域应用广泛,但模糊规则是模糊控制的 核心,模糊规则的制定需要专家经验,主观性较强, 当模糊规则划分数大,输入维数增加时,模糊规则表 将变得巨大而复杂。神经网络因其具有能逼近任意非 线性函数,较强的容错性和抗干扰等能力,被应用到 了分解炉温度控制中。刘彬等^[11]将 BP 神经网络应用 于分解炉温度控制中;乔景慧等^[12]提出了一种改进的 ELMAN 网络和模糊控制相切换的控制结构。

为了合理控制分解炉温度,利用实际生产数据, 在建立了被控对象的一阶滞后加延时的系统模型基础 上,采用 RBF 神经网络监督控制的算法进行了仿真研 究。仿真结果表明,所用 RBF 监督控制算法对分解炉 温度的控制精度高。系统稳定后,改变分解炉温度设 定值,所用算法控制效果依然较好。

二、系统分析与建模

1、分解炉系统分析

在新型干法水泥生产工业中,分解炉是预分解系 统的核心设备,它位于悬浮预热器和回转窑之间。分



解炉作为一种高温多相反应器,承担着烧成所需的约 60%的燃料燃烧和90%以上的碳酸钙分解任务,其 性能直接影响烧成系统的产量、质量及热耗、电耗。 图1所示是一种典型的按制造厂商命名的,由日本神 户制钢所研制的DD型分解炉结构。它包含还原区(I 区)、燃料裂解和燃烧区(II区)、主燃烧区(III区)、 完全燃烧区(IV区)4个部分。回转窑窑尾废气喷入 I区,与三次风及物料混合;燃料由2个分别装在II 区两侧的主喷嘴喷入,燃烧放热加速生料分解;生料 下落时,在I区咽喉部分的喷腾作用下迅速喷腾;在 IV区,生料和较粗燃料二次喷腾,充分燃料分解,随 后从出口出分解炉。

2、系统建模

分解炉的温度因各个水泥厂的生产线的条件、所 用技术、燃料的品质、测温点及测温技术等因素的不 同而不同,但为了保证合理生产,一般控制在 800℃ ~900℃之间。对分解炉温度的影响因素有分解炉喂 煤量、三次风量、生料喂量等,其中,最主要的影响 因素是分解炉的喂煤量。为了建立分解炉温度与分解 炉喂煤量之间的对应关系,利用某水泥厂一条日产 3500 t 的水泥生产线实测的生产数据,在 MATLAB 系 统辨识工具箱中对模型进行了辨识。辨识采用了 1410 组原始生产数据构成建模数据集,采样周期设置为 0.01 s。对于分解炉温度与分解炉喂煤量之间的关系, 一般可以近似为一阶惯性加滞后的模型^[13]。建模所用 的 1410 组原始生产数据如图 2 所示。图 2 中横坐标采 样值 k 表示建模所用组数,纵坐标表示建模所用输入 信号分解炉喂煤量和输出信号分解炉温度。部分原始 数据如表 1 所示。辨识所得的分解炉温度与分解炉喂 煤量之间的传递函数为:

$$G(s) = \frac{92.1308}{0.79016s + 1} e^{-0.00489s} \tag{1}$$



表1部分原始生产数据

序号	输入变量	输出变量
	分解炉喂煤量(t/h)	分解炉温度(℃)
1	8.7552	825.9761
2	8.7468	825.5563
3	9.1437	818.3764
4	9.3456	817.9146
5	8.7922	824.6326
6	8.7468	827.3618
7	9.1059	825.9761
8	9.1136	825.9761
9	9.1583	825.0944
10	8.8076	830.0069

为了验证所建模型的有效性,重新选取了200组 实际生产原始数据构成模型检验数据集。部分测试数 据如表2所示。

表2模型检验所用原始生产数据

序号	输入变量	输出变量
	分解炉喂煤量(t/h)	分解炉温度(℃)
1	9.4273	843.0230
2	8.9417	840.3778
3	8.9193	838.1105
4	9.3455	848.0195
5	9.4504	851.5884
6	9.1513	844.4085
7	9.6600	845.2903
8	9.7494	852.4702
9	9.2554	848.4393
10	9.4273	843.0230

将所建模型的输出值与相应条件下的实际生产真 实值进行对比,并计算他们之间的差值,分别绘制图形, 仿真结果如图 3 所示。可以看出,模型输出值与实际 生产真实值能较好地吻合。图 4 绘制的是实际生产真 实值与模型输出之间的差值,可以看出,两者之间的 差值基本上处于 [-10,10]的范围内,对于超过 800 ℃ 的分解炉温度来说,误差范围小于 2 %,绝大部分处 于 1 % 的范围内,表明所建模型是有效的。

三、神经网络监督控制策略

文中采用 RBF 神经网络的监督控制算法。控制系统的结构如图 5 所示。

图 5 中 r(k) 代表分解炉的设定值; u_n(k) 代表 RBF 神经网络的输出控制量; u_p(k) 代表 PID 控制器的输出 控制量; u(k) 代表作用于被控对象的输入,即分解炉 喂煤量; y(k) 代表在控制量作用下的系统输出,即分 解炉温度; e(k) 代表分解炉设定值与系统输出值之差。 其中,在监督控制作用下:

(2)

$$u(k)=u_p(k)+u_n(k)$$

e(k)=r(k)-y(k)

(3)

RBF 神经网络控制器实际上是一个前馈控制器, 它建立的是被控对象的逆模型。RBF 神经网络控制器 通过对 PID 控制器的输出进行学习,调整网络权值, 使反馈控制器的输出 *u_p(k)* 逐渐趋于 0,从而在控制中 逐步占主导地位,并最终取消反馈控制器的作用。当







系统出现扰动,或者改变了设定值 r(k) 时,反馈控制器又重新工作,这种前馈加反馈的监督控制方法可以 有效的保证控制系统的稳定性和鲁棒性。

RBF 神经网络的结构如图 6 所示。在文中, RBF 网络采用(3×4×1)的结构,即输入层神经元节点数 *i*=3,中间隐含层节点数 *j=*4,输出层节点数为1。



在图 6 中, RBF 神经网络的输入层输入矩阵为 X=[r(k) y(k-1) u(k-1)]^T,即神经网络的输入层三个节点 分别输入当前时刻的设定值 r(k),上一时刻的系统输出 值 y(k-1),上一时刻的系统输入值 u(k-1)。RBF 网络的 中间层径向基向量 $H=[h_1 \ h_2 \ h_3 \ h_4]^{T}$,其中 $h_j(j=1,2,3,4)$ 为高斯基函数,即:

$$h_j = e^{\left(-\frac{\left\|X - C_j\right\|^2}{2b_j^2}\right)}, j = 1, 2, 3, 4$$
(4)

其中, C_j 一隐含层第 j 个节点的中心向量, $C_j = [c_{j1} c_{j2} c_{j3}]^T$, (j=1, 2, 3, 4);

∥•∥一矩阵的 2- 范数;

 b_j 一隐含层节点 j 的基宽参数, $b_j > 0$ 。

RBF 网络输入层到隐含层的权值都为 1, 隐含层 到输出层的权向量为:

$$\boldsymbol{W} = [\boldsymbol{\omega}_1 \ \boldsymbol{\omega}_2 \ \boldsymbol{\omega}_3 \ \boldsymbol{\omega}_4]^{\mathrm{T}}$$
(5)

其中, ω₁, ω₂, ω₃, ω₄一输出层节点与4个隐含层节点之间的连接权值。

RBF 网络的输出为:

$$u_n(k) = \omega_1 h_1 + \omega_2 h_2 + \omega_3 h_3 + \omega_4 h_4 \tag{6}$$

控制律 *u*(*k*) 如式(2) 所示,其中 PID 控制器的 输出值 *u_o(k*) 采用下式计算:

$$u_p(k) = k_p e(k) + k_i \sum_{j=0}^k e(j)T_s + k_d \frac{e(k) - e(k-1)}{T_s}$$
(7)

e(k)、e(k-1)一第k和第(k-1)时刻所得的偏差值。 依据神经网络监督控制原理,为使神经网络控制 器占主导地位,神经网络的参数调整性能指标函数设 定为:

$$E(k) = \frac{1}{2} (u_n(k) - u(k))^2$$
(8)

采用梯度下降法对网络进行调整,网络的隐含层 与输出层之间的权值调整为:

$$\Delta \omega_{j}(k) = -\eta \frac{\partial E(k)}{\partial \omega_{j}(k)} = \eta (u_{n}(k) - u(k)) \frac{\partial u_{p}(k)}{\partial \omega_{j}(k)} \quad (9)$$

其中, η-学习速率, η∈[0,1];

 Δ 一增量;

ω_j(k) 一*k* 时刻隐含层第*j*个节点与输出层节点 之间的网络连接权值。

近似取值:

$$\frac{\partial u_p(k)}{\partial \omega_j(k)} \approx \frac{\partial u_n(k)}{\partial \omega_j(k)} \tag{10}$$

由此所产生的不精确性可以通过权值调节来补偿。将 (10)式代入到(9)式中得到:

 $\Delta \omega_j(k) = \eta(u_n(k) - u(k))h_j(k) \tag{11}$

权值调整公式为:

$$W(k) = W(k-1) + \Delta W(k) + \alpha (W(k-1) - W(k-2))$$
(12)

其中, α-动量因子, α∈[0,1]。

神经网络的隐含层节点基宽参数和中心向量的迭 代求取过程中均采用了上面公式(10)所述的近似处理。 迭代算法如下:

$$\Delta b_j(k) = -\eta \frac{\partial E(k)}{\partial b_j(k)} = \eta(u_n(k) - u(k)) \frac{\partial u_p(k)}{\partial b_j(k)} = \eta(u_n(k) - u(k)) \omega_j(k) h_j(k) \frac{\left\| \mathbf{X} - C_j \right\|^2}{b_j^3(k)}$$
(13)

 $b_{j}(k) = b_{j}(k-1) + \Delta b_{j}(k) + \alpha(b_{j}(k-1) - b_{j}(k-2))$ (14)

28 传感器世界 2018.12 Vol.24 NO.12 Total 282

$$\Delta c_{ji}(k) = -\eta \frac{\partial E(k)}{\partial c_{ji}(k)} = \eta(u_n(k) - u(k)) \frac{\partial u_p(k)}{\partial c_{ji}(k)} =$$

$$\eta(u_n(k) - u(k)) \omega_j(k) h_j(k) \frac{x_i(k) - c_{ji}(k)}{b_j^2(k)}$$
(15)
$$c_{ij}(k) = c_{ij}(k-1) + \Delta c_{ij}(k) + \alpha(c_{ij}(k-1) - c_{ij}(k-2))$$
(16)

四、仿真分析

利用所建立的分解炉温度与分解炉喂煤量之间的 模型,应用上述 RBF 神经网络控制算法在 MATLAB 中进行了仿真。仿真中对所建立的一阶滞后加延时的 系统模型进行了离散化处理,采样周期 *T_s*=0.001 s。模 型离散化后的表达式为:

y(k) = -den(2)*y(k-1) + num(1)*u(k-d) + num(2)*u(k-1-d)(17)

其中, den(2)、num(1)、num(2) 一在采样周期 T_s下模 型离散化后的对应分母、分子多项式系数;

d — 在采样周期 *T_s*下的输入延时步数,模型延时=0.00489s,采样周期 *T_s*=0.001 s,有:

 $d = \frac{0.00489}{T_s} = 4.89 \approx 5$

在仿真中,前面所述的控制策略中总的控制量 u(k)和 RBF 神经网络控制器的输入层节点中的输入 u(k-1)均需延时 d个步长。在仿真中,考虑到实际的 工业生产背景,控制量 u(k) 表示的是分解炉喂煤量, 不可能无限大,必须在一定的范围之内,这就要求在 控制器的设计过程中,参数的设计必须要合理,设 置 u(k) 在一个合理的空间。为了合理利用资源, 提高 生产效率,减少资源浪费,保护环境的原则,在仿真 程序中对控制器的总输出 u(k) 进行了范围设限。根据 水泥厂生产工人的实际经验,分解炉喂煤量 u(k) 一般 ≤10,因此在仿真程序中当控制器总的输出值 u(k)≥10 时, u(k)=10。为了防止参数调试过程中参数设置不 合理或系统失控,在程序中当控制器的总输出 u(k)≤ -10时, u(k)=-10。根据实际生产, 仿真中的设定值 r(k)=845, 之后进一步模拟多工况下的控制效果时, 根 据实际生产 r(k) 的设置为:

$$r(k) = \begin{cases} 845 & 0 \le t < 25\\ 865 & 25 \le t < 40\\ 830 & 40 \le t \le 60 \end{cases}$$
(18)

其中, *t* 一仿真的时间, *t=k*T_s*。 仿真中各参数值如表 3 所示。

表3仿真参数变量信息

参数变量名	参数变量值
采样周期 T _s	0.001 s
仿真总步长 k	60000
输入延时步长 d	5
神经网络输入初始向量 X	$\begin{bmatrix} 0 & 0 & 0 \end{bmatrix}^{\mathrm{T}}$
神经网络基宽初始向量 B	$\begin{bmatrix} 1 & 1 & 1 & 1 \end{bmatrix}^{\mathrm{T}}$
神经网络中心初始矩阵 C	$\begin{bmatrix} -2 & -1 & 1 & 2 \\ -2 & -1 & 1 & 2 \\ 7 & 8 & 9 & 10 \end{bmatrix}$
神经网络初始权值向量 W	rands(4,1)
神经网络输入层节点数 i	3
神经网络隐含层节点数 j	4
神经网络输出层节点数	1
学习率 η	0.91
动量因子 α	0.05
PID 参数值	k_p =0.0157 k_i =0.0353 k_d =0

当设定值 r(k)=845 不变时的仿真结果如图 7~ 图 9 所示。

图 7 中的实线表示分解炉温度的设定值 r(t),虚 线表示 RBF 监督控制的系统输出分解炉温度值 y(t), 8 s~20 s 之间的局部放大效果如图 7 中的小图所示。很 明显可以看出当系统稳定后,RBF 监督控制的系统输 出分解炉温度值与设定值能够很好地吻合,稳态误差 趋近于 0,能够达到很高的控制精度。超调量为:

$$\sigma\% = \frac{y(t_p) - y(\infty)}{y(\infty)} \times 100\%$$
⁽¹⁹⁾

其中, $y(t_p)$ 一响应的最大偏离量;

y(∞)一响应的终值。

经计算,所设计的控制系统的超调量为:

出现了平顶,造成在这一时间段系统响应曲线处于最 大偏离量的原因是上文中提到的采用控制器总的控制 输出 u(k) 进行了受限,导致控制器的总输出在这一段 时间内一直停留在 u(k) 的上限值。当 u(k) 不受限时的 仿真结果表明,系统响应的输出曲线没有图7中的平 顶现象,并且系统的调节时间极大地缩短,但是超调 量也显著增大,并且控制器的总输出值 u(k) 非常大, 考虑实际生产背景 u(k) 表示分解炉喂煤量, 它不可能 是不受限时的那么大的值,对u(k)设限具有实际意义, 并且在文中下面将要叙述的当系统稳定工作一段时间 后,因生产需要,工况发生改变,设定值 r(k)发生合 理范围内的变动时, u(k) 受限和不受限系统达到新的 稳态所需的调节时间和超调量几乎一样。因此, 所采 用的控制器的总输出值 u(k) 受限的思想, 虽然开始时 调节时间较大,但更符合工业生产实际情况,具有很 强的实际工业生产意义。

图 8 是设定值 r(k)=845 固定不变时,设定值 r(k) 与系统输出 y(k) 之间的差值曲线。可以看出,系统稳 定后的稳态误差趋近于 0,验证了所用 RBF 监督控 制算法的有效性,且控制精度很高。图 8 中的小图是 10 s~20 s 的局部放大效果。

图 9 是设定值不变工况下的控制器输出曲线。 其中, un(t) 表示的是 RBF 神经网络控制器的输出; up(t) 表示的是 PID 控制器的输出; u(t) 为监督控制总 的控制器输出。从图中可以看出,神经网络控制器通 过对 PID 控制器的学习,使得 PID 的控制器输出逐 渐趋于 0,并最终在总的控制当中占据主导地位。如 前所述,考虑实际工业生产背景,控制器的输出被控 制在一个合理的范围内。控制器总的输出 u(t) 的曲线 在 10 s 内有一段时间的平顶,表明在这段时间内控制 器的总输出一直处于最大上限值,这与前面所述系统 响应曲线的情形相符合。系统稳定后的控制器总输出 u(t)=9.1717,对应的实际物理意义为分解炉喂煤量, 单位为吨每小时(t/h)。控制器的输出符合实际情况, 具有很强的实际应用意义。

在此基础上进一步研究了当系统稳定后,因实际 生产需要,实际工况发生变化,分解炉的温度设定值 r(t)按照(18)式所述的变化时,在所建模型和控制策







略下的控制效果。仿真结果表明,当设定值 r(t) 发生 改变后, 文中所用 RBF 监督控制算法依然能够对系统 进行很好地控制。与传统 PID 控制进行对比(PID 参 数与前文所述值相同),仿真结果如图10所示。图 10 中的红色实线为设定值, 蓝色实线为 RBF 监督控制, 绿色实线为传统 PID 控制。结果表明,虽然在初始调 节阶段传统 PID 控制的系统响应曲线先从最大偏离量 处开始下降,但 RBF 监督控制的系统响应曲线下降趋 势更快。当系统达到稳定后,r(t)的值发生改变,系 统达到新的稳态, RBF 监督控制所用调节时间比传统 PID 短,响应速度比传统 PID 快。r(t) 的值发生改变后, 虽然从之前的状态调节到新的稳态过程中, RBF 监督 控制的超调比传统 PID 大,但 RBF 监督控制的超调量 很小,此过程中的最大偏离量也处于分解炉的正常工 作温度范围(不宜超过1000℃),因此,所用控制算 法与传统 PID 控制相比具有较大优势。

五、结论

水泥分解炉的温度对物料在预分解系统中预烧具 有很大影响。利用实际生产数据,建立了分解炉喂煤 量与分解炉温度的一阶滞后加延时的模型,应用此模 型采用 RBF 监督控制的算法进行了仿真研究。监督控 制实际上实现的是 RBF 神经网络前馈控制、PID 反馈



控制的复合控制。RBF 神经网络控制实现的是被控对 象的逆模型。仿真结果表明,这种 RBF 监督控制算法 对分解炉温度的控制精度高。系统稳定后,当设定值 r(t)发生改变,与传统 PID 控制相比,所用 RBF 监督 控制在保障精度的基础上具有更快的响应速度和更短 的调节时间。所设计的控制器的输出考虑了工业生产 实际情况,具有很高的应用价值。

参考文献

[1] 田文富,李丽霞.水泥熟料煅烧过程与操作 [M].北京:中国建材工业出版社,2015.

[2] Ghazale M, Gholam A R A, Vahid A. A Novel Phase I Fuzzy Profile Monitoring Approach based on Fuzzy Change Point Analysis[J]. Applied Soft Computing, 2018, 71: 488-504.

[3] 姚维, 孟濬, 颜文俊, 等. 水泥回转窑分解炉温度的模糊控制 [J]. 自动化仪表, 2001, 22(02): 37-39.

[4] 冯丽辉, 吕智愚, 董乃飞, 等. 水泥分解炉出口温度的多变 量模糊控制 [J]. 控制工程, 2014, 21(03): 374-377.

[5] 张艳梅,冯丽辉.新型干法水泥分解炉出口温度的多变量 模糊控制 [J].工业仪表与自化装置,2011(01):77-80.

[6] 袁铸钢, 狄小峰, 申涛. 模糊控制及其在水泥分解炉的应用 [J]. 济南大学学报 (自然科学版), 2006, 20(01): 58-61.

[7] 王盛慧,王子峰,姜长泓. 模糊 PID 水泥分解炉温度控制 [J]. 长春工业大学学报,2016,37(03):252-255.

[8] 李洪林. 模糊控制技术在分解炉温度控制中的应用 [J]. 水 泥工程, 2014(03): 61-62.

[9] Li S W, Li B, Li C R. The study of temperature control of cement decomposition furnace on the basis of fuzzy immune self-adaptive PID control method[C]//Third International Conference on Information Science and Technology. Yangzhou: IEEE, 2013: 86-90.

[10] 李学军,周元,宾光富,等.基于三维模糊 PID 控制策略的水泥分解炉温度控制系统研究 [J].电子测量与仪器学报,2009,23(10):37-42.

[11] 刘彬,刘晓琳.水泥分解炉温度控制系统设计 [J]. 控制工程, 2004, 11(01): 63-65.

[12] 乔景慧, 柴天佑.改进 ELMAN 网络的 Q 学习温度切换控制 [J]. 控制理论与应用, 2015, 32(07): 955-962.

[13] 蒋妍妍, 李洪林. 基于变论域模糊 PID 的分 解炉温度控制研究 [J]. 测控技术, 2014, 33(10): 72-75.

Temperature Monitoring and Control in Cement Calciners Based on RBF Neural Network

LI Dong, AI Hong

(School of Automation, Beijing Information Science and Technology University, Beijing 100192, China)

Absrtact: Aiming at the problem of temperature control of cement decomposing furnace, the system model of the first-order delay and lag of the decomposition furnace temperature and the feed quantity of the calciner is identified by using the data from the actual production of a cement plant in the MATLAB System Identification Toolbox. Using this model, the temperature of the calciner is controlled by radial basis function (RBF) neural network monitoring and control algorithm. The simulation results show that the algorithm has high control accuracy. On this basis, the effectiveness of the control algorithm is validated by changing the temperature reference value of the calciner and simulating different working conditions. Compared with the traditional PID control algorithm, the temperature reference value of the calciner is changed to a more stable regulation time and quicker response.

Key words: cement decomposition furnace temperature; modeling; RBF neural network; supervision and control

作者简介

李东:北京信息科技大学自动化学院,硕士研究生, 研究方向为智能控制。 通讯地址:北京市海淀区北京信息科技大学小营校区 自动化学院 邮编:100192 邮箱:2496341966@qq.com 艾红:北京信息科技大学自动化学院,教授,研究方 向为故障检测诊断与控制。