

文章编号:1005-0523(2012)04-0029-06

基于BP算法的中密度纤维板热压机压力控制研究

王野平,陈文倩,江华荣

(同济大学机械与能源工程学院,上海 201804)

摘要:在中密度纤维板生产过程中,针对热压压力控制存在的大惯性、纯滞后和非线性问题,提出具体的解决方法。建立中密度纤维板热压机压力模型,运用基于BP(back propagation)神经网络的经典增量式PID控制方式,实现对热压过程的优化控制。通过仿真实验和结果分析得出:BP神经网络优化控制具有稳定性好、超调量少、震荡现象少等优势特点,改善了被控过程的动态性能和稳态性能,在提高系统抗干扰性能及参数时变的鲁棒性等方面优越于常规PID调节器。

关键词:中密度纤维板;热压;PID控制;BP神经网络

中图分类号:TH122

文献标志码:A

热压是纤维板制造的一道重要工序。对产品质量和产量起着决定性的作用。热压是指在热量和压力的联合作用下,板坯中的水分汽化、密度增加、胶粘剂固化、防水剂重新分布,原料中的各组分发生一系列物理化学变化,从而使纤维间产生各种结合力,形成符合质量要求的纤维板制品的过程^[1]。热压是生产工艺中的一道重要工序,直接决定着成品的内在性能和质量,并且对生产效率及成本控制有重要的影响。目前,国产设备多采用继电器等硬件实现的传统控制,或简单的微机控制,该热压过程均为在控制中不调整参数的预先设定值控制。在中密度纤维板的热压生产工艺过程中,系统的工艺状况复杂多变,控制参数多,具有大惯性、纯滞后、非线性的特点,单靠传统的过程控制策略难以获得令人满意的控制效果。因此,可以根据不同工况运用自整定参数的基于BP神经网络的PID控制,对于提高中密度纤维热压生产的产品质量具有非常重要的实践意义^[2]。本文主要对基于神经网络的PID智能控制方法进行研究和探讨,并应用于热压压力模型,将结果与传统PID控制进行比较。

1 影响中密度纤维板热压过程的主要因素

热压是中密度纤维板生产中最重要、最复杂的工序,对产品的质量和产量起着决定性的作用。在热压过程的诸多影响因素中,热压温度、热压压力和热压时间是热压过程中的3个基本因素,通常被称为“热压三要素”。热压温度一般为160~180℃,热压压力为7~10 MPa。中密度纤维板的板坯含水率在10%左右,一般采用二段热压曲线,高压段压力一般为3.5 MPa左右,低压段压力一般为1.5~2.0 MPa。①过高的压力,往往会影响到断面密度的分布,一般为表层密度大,芯层密度小,形成较大密度梯度。造成的主要原因是由于板坯表层直接接触热压板,较快地受热,水分快速干燥,胶粘剂提前固化,失去了弹性收缩;而芯层受热不足仍保持弹性,继续产生压缩阻力,使压缩量减少而密度降低,于是就形成了密度梯度,压力越高,压缩越快,密度梯度越大。②水分汽化、胶粘剂固化和纤维之间各种结合力的形成主要在低压段完成,对于低压段压力的制定,压力太高,造成水蒸汽排出困难,延长热压周期,控制不好易出现水迹,鼓泡的缺陷;压力过低,导热效率过低。所以,合理控制“热压三要素”是保证纤维板生产质量和产量的关键^[3]。在热压机

收稿日期:2012-06-20

作者简介:王野平(1963—),男,教授,主要研究方向为机械设计及制造、摩擦学、生物质燃料成型技术。

的压力控制系统中,通常要求稳态精度高,动态范围宽,升压速度快,避免过大的超调以及振荡。由于这些性能指标之间存在互相制约,采用常规的控制方法往往难以使系统很好地同时满足各项指标要求。本文采用基于BP神经网络的PID控制压力系统。在控制过程中,根据不同的压力偏差值和偏差变化,对PID中的3个参数: K_p , K_I , K_D (分别为比例参数、积分作用参数、微分作用参数)进行在线的自校正。

板坯压力 P 计算公式如下:

$$P = \frac{\pi d^2 m P_0 K}{4A} \quad (1)$$

式中: d 为热压机油缸直径, cm; m 为热压机油缸数量; A 为板坯面积, cm^2 ; P_0 为热压机表面压力, MPa; K 为压机损失系数, 一般取 0.9~0.92。

2 热压生产工艺

2.1 热压生产工艺曲线

热压过程干法中密度纤维板的热压压力主要用来克服板坯的热压过程中产生的摩擦力或者反弹力, 将板坯压缩到厚度规定的要求。实际热压过程中, 由于板坯含水率、产品厚度、幅面大小的不同, 所采用的热压曲线也不尽相同。通常在板坯含水率大于 5% 的情况下, 需要采用二段以上的加压曲线。如图 1 所示。

热压曲线的含义是当板坯装入各层热压板后发出闭合命令, 热压机快速闭合, 热压机闭合后快速加压, 接下来在一定压力范围内保压, 并使板坯达到要求的厚度, 热压机在开前, 先使压力慢慢卸下来, 压力降低到允许张开时的压力后, 热压机快速张开。




图1 热压生产工艺曲线
Fig.1 Hot pressing process curve

2.2 压力控制系统的构成及控制

液压压力控制系统可简化为由伺服阀和液压缸, 反馈压力传感器系统组成。液压泵提供油液压力, 系统通过引入压力负反馈, 与给定值比较, 得到偏差量, 通过 PLC 来控制伺服阀。

在中密度纤维板热压过程中, 严格控制压力大小是重要的生产环节, 目前应用最为广泛的方法是采用 PID 控制方式实现。该方法控制简单, 实现容易。但是, 压力系统是个复杂的系统, 不是一个固定的值, 而是在动态的变化, 这样传统的 PID 控制器很难进行动态跟踪, 达到理想的压力控制。本文将根据 BP 神经网络的辨识实时动态的改变 PID 参数, 使压力能够动态的跟踪变化, 实现实时控制。

3 基于BP神经网络的PID控制

BP(back propagation)神经网络即误差反向传播算法的学习过程, 由信息的正向传播和误差的反向传播两个过程组成。输入层各神经元负责接收来自外界输入信息, 并传递给中间层各神经元; 中间层是内部信息处理层, 负责信息变换, 根据信息变化能力的需求, 中间层可以设计为单隐层或者多隐层结构; 最后一个隐层传递到输出层各神经元的的信息, 经进一步处理后, 完成一次学习的正向传播处理过程, 由输出层向外界输出信息处理结果。当实际输出与期望输出不符时, 进入误差的反向传播阶段。误差通过输出层, 按误差梯度下降的方式修正各层权值, 向隐层、输入层逐层反传。周而复始的信息正向传播和误差反向传播过程, 是各层权值不断调整的过程, 也是神经网络学习训练的过程, 此过程一直进行到网络输出的误差减少到可以接受的程度, 或者预先设定的学习次数为止^[4]。

误差反向传播 BP 神经网络是一种有隐含层的多层前馈网络, 结构如图 2 所示。BP 神经网络具有 m 个输入节点 ($x_1 \sim x_m$), Q 个隐含层节点, l 个输出节点 ($y_1 \sim y_l$)。

基于BP神经网络的PID控制器结构如图3所示。




图2 BP神经网络结构图
Fig.2 BP neural network structure




图3 基于BP神经网络的PID控制器结构
Fig.3 Structure of BP-based PID controller

图3中 r 为给定输入, y 为系统输出, e 为误差, a_c/a_i 为调整参数。由图可以看出,BP神经网络是一个三层网络系统。基于BP神经网络的PID控制包括两个部分:①常规PID控制器:直接对被控对象过程闭环控制, $K_p K_i K_d$ 为在线整定式;②神经网络NN层:根据系统的运行状态,调节PID控制器的参数,以期达到某种性能指标的最优化。输出层神经元的输出状态对应于PID控制器的3个可调参数 K_p, K_i, K_d ,通过神经网络的自身学习、加权系数调整,从而使其稳定状态对应于某种最优控制律下的PID控制器参数^[5]。

其中,经典增量式数字PID控制算法为

$$U(K) = U(K-1) + K_p e(K) - e(K-1) + K_i e(K) + K_d (e(K) - 2e(K-1) + e(K-2)) \quad (2)$$

式中: K_p, K_i, K_d 为比例、积分、微分系数; $U(K)$ 为控制器输出; $e(K) = r(K) - y(K)$ (给定输入与系统输出的差值)。

由文献[6]可知隐含层节点数的选取通常用以下经验公式

$$Q = \sqrt{m+l} + a \quad (3)$$

式中: m 为输入节点数4; l 层为输出层,即为PID的3个参数输出,输出节点数目为3; a 为1~10之间的一个常数; Q 为隐含层节点数,根据公式(3)调整,定为5。

网络输入层输入,上标(1)表示输入层:

$$O_j^{(1)} = x(j) \quad j = 1, 2, \dots, m \quad (4)$$

网络隐含层的输入 $n_i^{(2)}(K)$,输出 $O_i^{(2)}(K)$ 为式(5)。其中上标(2)表示隐含层, $w_{ij}^{(2)}$ 为可调整权系数。

$$\begin{cases} n_i^{(2)}(K) = \sum_{j=0}^m w_{ij}^{(2)} O_j^{(1)} \\ O_i^{(2)}(K) = f(n_i^{(2)}(K)) \end{cases} \quad i = (1, \dots, Q) \quad (5)$$

隐层神经元的活化函数取正负对称的sigmoid函数

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

网络输出层的输入输出为

$$\begin{cases} n_l^{(3)}(K) = \sum_{i=0}^Q w_{li}^{(3)} O_i^{(2)}(K) \\ O_l^{(3)}(K) = g(n_l^{(3)}(K)) \\ O_1^{(3)}(K) = K_p \\ O_2^{(3)}(K) = K_i \\ O_3^{(3)}(K) = K_d \end{cases} \quad l = 1, 2, 3 \quad (7)$$

输出层输出节点分别对应3个参数不能为负值,所以输出层神经元的活化函数取非负的sigmoid函数:

$$g(x) = \frac{1}{2}(1 + \tanh(x)) = \frac{e^x}{e^x + e^{-x}} \quad (8)$$

取性能指标函数 $E(K)$:

$$E(K) = \frac{1}{2}(r(K) - y(K))^2 \quad (9)$$

按照梯度下降法修正网络的权系数,即按 $E(K)$ 对加权系数的负梯度方向搜索调整,并附加一使搜索快速收敛全局极小的惯性项

$$\Delta w_{li}^{(3)}(K) = -\eta \frac{\partial E(K)}{\partial w_{li}^{(3)}(K)} + \alpha \Delta w_{li}^{(3)}(K-1) \quad (10)$$

式中: η 为学习速率; α 为惯性系数。

$$\begin{cases} \frac{\partial E(K)}{\partial w_{li}^{(3)}} = \frac{\partial E(K)}{\partial y(K)} \frac{\partial y(K)}{\partial U(K)} \frac{\partial U(K)}{\partial O_l^{(3)}(K)} \frac{\partial O_l^{(3)}(K)}{\partial n_l^{(3)}(K)} \frac{\partial n_l^{(3)}(K)}{\partial w_{li}^{(3)}(K)} \\ \frac{\partial n_l^{(3)}(K)}{\partial w_{li}^{(3)}(K)} = O_i^{(2)}(K) \end{cases} \quad (11)$$

由于 $\frac{\partial y(K)}{\partial U(K)}$ 未知,所以用近似符号函数 $\text{sgn}\left(\frac{\partial y(K)}{\partial U(K)}\right)$ 取代,由此带来计算不准确的影响可以通过调整学习速率 η 来补偿。

计算得

$$\begin{cases} \frac{\partial U(K)}{\partial O_1^{(3)}(K)} = e(K) - e(K-1) \\ \frac{\partial U(K)}{\partial O_2^{(3)}(K)} = e(K) \\ \frac{\partial U(K)}{\partial O_3^{(3)}(K)} = e(K) - 2e(K-1) + e(K-2) \end{cases} \quad (12)$$

分析可得网络输出层权的学习算法

$$\begin{cases} \Delta w_{li}^{(3)}(K) = \eta \delta_i^{(3)} O_l^{(2)}(K) + \alpha \Delta w_{li}^{(3)}(K-1) \\ \delta_i^{(3)} = e(K) \text{sgn}\left(\frac{\partial y(K)}{\partial U(K)}\right) \frac{\partial U(K)}{\partial O_l^{(3)}(K)} g'(n_l^{(3)}(K)) \end{cases} \quad (13)$$

同理隐含层权的学习算法

$$\begin{cases} \Delta w_{ij}^{(2)}(K) = \eta \delta_i^{(2)} O_j^{(1)}(K) + \alpha \Delta w_{ij}^{(2)}(K-1) \\ \delta_i^{(2)} = f'(n_i^{(2)}(K)) \sum_{L=1}^3 \delta_L^{(3)} w_{li}^{(3)}(K) \end{cases} \quad (14)$$

式中: $g'(\cdot) = g(x)(1 - g(x))$; $f'(\cdot) = (1 - f^2(x))/2$

控制算法的实现过程如下:

- 1) 确定BP神经网络的结构,给出各层初始权值,选定学习速率 η ,和惯性系数 α ,此时 $K=1$;
- 2) 采样后,计算时刻误差: $e(K) = r(K) - y(K)$;
- 3) 计算神经网络NN各层神经元的输入输出,NN输入层的输出即为PID控制器的3个可调参数, K_p , K_i , K_D ;

- 4) 计算PID的控制输出 $U(K)$;
- 5) 进行神经网络学习,在线调整权系数 $w_{ij}^{(1)}(K)$, $w_{li}^{(2)}(K)$, 实现PID控制参数的自适应调整;
- 6) $K=K+1$, 返回到1)^[7]。

4 仿真及结果

由文献[8]可知道,压机过程传递函数可看作二阶系统加纯延迟,传递函数 $G(S)$ 为

$$G(S) = \frac{e^{-\tau s}}{(s+1)(\tau s+1)} \quad (15)$$

式中: $e^{-\tau s}$ 为二阶系数加纯延迟; τ 为延迟时间,在此取 0.5 s; s 为复变单位。

将传递函数转化为差分方程: $y(K) = -den(2)y_1 - den(3)y_2 + num(2)U_1 + num(3)U_2$; 首先利用 matlab 中的 `tf(num,den)` 来建立被控对象传递函数。通过 `c2d(sys,ts,'z')` 把传递函数离散化,最后利用 `[num,den]=tfdata(dsys,'v')` 提取离散化后的分子,分母^[9]。

得到

$$y(K) = 1.997y_1 - 0.997y_2 + 1.0e - 0060.9990U_6 \quad (16)$$

通过软件 matlab 编写程序的方式进行仿真,给定信号为阶跃信号: $r(K)=1$ 。图 4 和 5 给出了系统阶跃响应结果曲线。




图 4 常规 PID 阶跃响应曲线

Fig.4 Step response curve of conventional PID control




图 5 基于 BP 神经网络的 PID 阶跃响应曲线

Fig.5 Step response curve of PID control based on BP




图 6 参数自整定曲线

Fig.6 Self tuning curve of parameters

比较图 4 和图 5 可知,在压机加压过程中,与经典 PID 控制相比,基于 BP 神经网络的参数自整定 PID 控制方式响应快,不存在超调震荡,稳定性好。由图 6 可知:利用 BP 神经网络的自学习功能和非线性函数的逼近能力,遵从优化指标,控制系统在线地调整 PID 的控制参数,使之适应被控对象参数以及结构的变化。实现了参数自适应学习,自整定过程。

参考文献:

- [1] 华毓坤. 人造板工艺学[M]. 北京:中国林业出版社,2002:57.
- [2] 曾钦志. 中密度纤维板热压时间的模糊控制[J]. 木材工业,2001,15(4):15.
- [3] 王宁,孙丽萍. 中密度纤维板热压机压力模糊控制研究[J]. 机电产品开发与创新,2010,23(1):129.
- [4] 孟良. 基于BP神经网络的罩式炉炉温PID预测控制策略[D]. 太原:太原理工大学,2009:40.
- [5] 徐利云. 基于BP神经网络的PID控制器在温控系统中的研究与应用[D]. 济南:山东大学,2010:24-26.
- [6] CHEN T, CHEN H, LIU R W. Approximation capability in $c(r)$ by multilayer feedforward networks and related problems [J]. IEEE transactions on Neural Networks, 1995, 6(1):25-30.
- [7] 刘金锟. 先进PID控制及其MATLAB仿真[M]. 北京:电子工业出版社,2002:96-100.
- [8] 史春朝. BP神经网络算法的改进及其在PID控制中的应用研究[D]. 天津:天津大学,2006:46.
- [9] 李庆奎,吕志平,葛智杰. 基于模糊综合评判的智能行程时间预测算法[J]. 华东交通大学学报,2012,29(2):7-9.

A Study on BP-based Pressure Control for Medium-density Fiberboard Hot Press

Wang Yeping, Chen Wenqian, Jiang Huarong

(College of Mechanical Engineering, Tongji University, Shanghai 201804, China)

Abstract: In order to solve such problems as big inertia, pure time-delay and nonlinearity in hot pressing pressure control during the medium-density fiberboard production process, this paper proposes a feasible approach, including establishing the pressure model for medium-density fiberboard hot press and applying PID control based on BP neural network to realize the optimization control in hot pressing process. The simulation experiments and results analysis find out that the optimization control based on BP neural network has more advantages, such as strong stability, fewer overshoot and turbulence reduction. With improved stability and dynamic performance, the proposed BP-PID controller can thus yield better performance in system stability and robustness than conventional PID controllers.

Key words: medium-density fiberboard; hot pressing; PID control; BP neural network