

BP神经网络模型预测控制算法的仿真研究^①

程森林, 师超超

(重庆大学 自动化学院, 重庆 400044)

摘要: 为克服被控对象参数变化导致控制精度降低的问题, 研究了一种 BP 神经网络模型预测控制算法。借助最小二乘递推算法在线预测系统模型参数, 利用 BP 神经网络在线预测 PID 参数以控制被控对象。该算法基于模型预测, 首先在线性系统中验证其控制效果, 然后将非线性问题作线性处理, 采用 BP 神经网络模型预测 PID 控制器予以实现控制非线性系统。仿真曲线显示 BP 神经网络 PID 控制器用于线性系统可达到高精度控制要求; 对于非线性系统有自适应及逼近任意函数的能力。仿真研究表明, 该算法与传统 BP 神经网络 PID 控制器相比, 其自适应能力更强, 稳定性更好, 控制精度更高。

关键词: 模型预测; 最小二乘递推算法; BP 神经网络 PID 控制器

Simulation on Predictive Control Algorithm Based on BP Neural Network Model

CHENG Sen-Lin, SHI Chao-Chao

(College of Automation, Chongqing University, Chongqing 400044, China)

Abstract: To overcome the problem of lower control precision caused by parameters varying of the controlled object, the paper proposed a sort of predictive control algorithm based on BP neural network model. In the paper, it applies the predictive parameter of PID controller based on BP neural network on line to control the controlled object, and the system model parameter was on line predicted by means of least recursive squares algorithm. The algorithm would be based on model prediction. It first validates its control effect in the linear system, and then the non-linear problem would be treated as the linearity. The non-linear system would be controlled by use of predictive control algorithm based on BP neural network model. The simulation curves shows that it could achieve high control precision in the linear system to PID controller of BP neural network, and own the ability of adaptation and approaching arbitrary function. The simulation researches show that it is stronger in adaptation, better in stability, and higher in control precision compared with the traditional BP neural network PID controller.

Key words: model prediction; least recursive squares algorithm; PID controller of BP neural network

传统的 PID 控制参数整定后, 在整个控制过程中都是固定不变的, 而在实际系统中, 系统状态和参数时常变化, 致使传统的 PID 控制效果不明显^[1]。常规神经网络 PID 控制器对三个参数进行在线调整, 其方法是将神经网络用于 PID 控制器的设计或直接计算 PID 控制器的输出^[2], 该方法用系统预测值或其变化量计算系数修正值, 传统做法是采用符号函数代替系统系数修正值。为实现系数修正, 文中研究了 BP 神经

网络模型预测控制算法, 用该数学模型计算的预测输出取代实测值, 以提高系统控制效果^[3]。

在实际物理系统中, 严格意义上的线性系统只是近似的, 一般都是非线性的, 因此研究非线性系统的预测控制无论在理论上还是在实际应用中都具有重要意义^[4]。为了更好的跟踪非线性系统的动态过程, 在一定条件下, 非线性问题可作线性化处理, 据此文中提出将 BP 神经网络模型预测的 PID 控制器运用到非线性

① 收稿时间:2010-12-08;收到修改稿时间:2011-01-02

性系统中。

程:

1 非线性方程的线性化条件

图 1 是具有连续变化的非线性函数，可表示为：

$$y = f(x) \tag{1}$$

若取某一平衡状态为工作点。

如 A 点.: $y_0 = f(x_0)$ 当 $x = x_0 + \Delta x$ 时, $y = y_0 + \Delta y$, 如 B 点. 设函数 $y = f(x)$ 在 (x_0, y_0) 附近连续可导, 则可将函数在 (x_0, y_0) 附近展开成泰勒级数:

$$y = f(x) = f(x_0) + \left. \frac{dy}{dx} \right|_{x=x_0} (x - x_0) + \frac{1}{2!} \left. \frac{d^2y}{dx^2} \right|_{x=x_0} (x - x_0)^2 + \dots \tag{2}$$

当变化量 $\Delta x = x - x_0$ 很小时, 可忽略高次项。则有:

$$\Delta y = y - y_0 \approx \left. \frac{dy}{dx} \right|_{x=x_0} \cdot \Delta x = K \cdot \Delta x \quad \text{其中: } K = \left. \frac{dy}{dx} \right|_{x=x_0} \tag{3}$$

在 (x_0, y_0) 邻域非线性方程 $y = f(x)$ 可用线性化的斜线代替。对具有两个自变量的非线性函数:

$$y = f(x_1, x_2) \tag{4}$$

可作同样的处理: 当 $\Delta x_1, \Delta x_2$ 很小时, 有

$$\Delta y = y - y_0 = K_1 \Delta x_1 + K_2 \Delta x_2 \tag{5}$$

其中, $K_1 = \left. \frac{\partial f}{\partial x_1} \right|_{x_{10}, x_{20}}$ 及 $K_2 = \left. \frac{\partial f}{\partial x_2} \right|_{x_{10}, x_{20}}$ 。

这种线性化方法对于存在本质非线性的系统是不能作线性化处理的。所谓本质非线性是系统在工作点处的非线性是不连续的, 因其泰勒级数不收敛^[5]。




图 1 线性化示意图

2 最小二乘递推预测算法

设被控对象动态过程的数学模型如式 (6)。

$$A(z^{-1})y(k) = B(z^{-1})u(k) + n(k) \tag{6}$$

式中 $y(k)$ 、 $u(k)$ 为系统输出和控制输入信号, $n(k)$ 为均值为零的独立同分布随机干扰, 由式 (6) 可得辨识方

$$y(k) = \varphi^T(k-1) \cdot \theta + n(k) \tag{7}$$

$$\varphi^T(k-1) = [-y(k-1), \dots, -y(k-n), u(k-1), \dots, u(k-n)]^T \tag{8}$$

$$\theta = [a_1, \dots, a_n, b_1, \dots, b_n]^T \tag{9}$$

因此用最小二乘法可在线估计出参数矢量 $\hat{\theta}_N$ 。

若增加一组新的观测值 $u(n+N+1), y(n+N+1)$, 则下一步预报输出可由式 (10) 计算^[6]。

$$\begin{aligned} P_N &= [\Phi_N^T \Phi_N]^{-1} \\ \hat{\theta}_N &= [\Phi_N^T \Phi_N]^{-1} \Phi_N^T Y_N \\ \hat{\theta}_{N+1} &= \hat{\theta}_N + G_{N+1} [y_{N+1} - \varphi_{N+1}^T \hat{\theta}_N] \end{aligned} \tag{10}$$

$$G_{N+1} = \frac{P_N \varphi_{N+1}^T}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}}$$

$$P_{N+1} = P_N - G_{N+1} \varphi_{N+1}^T P_N$$

式 (10) 是一个最小二乘递推算法, 首先得到 $\hat{\theta}_N, P_N, u_{N+1}, y_{N+1}$; 再计算 $\varphi_{N+1} \rightarrow \hat{\theta}_{N+1} \rightarrow P_{N+1} \rightarrow$, 由上述方法可预报下一步的输出如式 (11)。

$$\hat{y}(k+1) = \varphi^T(k) \cdot \theta \tag{11}$$

3 BP神经网络PID控制器

神经网络输出层节点个数为 3, 系统可测量数据有 $r_{in}(k), y_{out}(k), e(k)$, 加上在线调整系数 k , 其输入层节点个数选为 4。为使性能指标优化, BP 神经网络可采用 4-5-3 层次结构, 如图 2 所示。

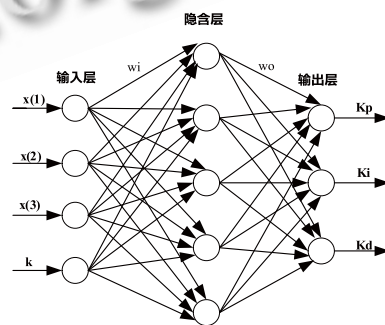


图 2 BP 神经网络结构图

设计节点输入如式 (12)。

$$\begin{aligned} O_j^{(1)} &= x(j) \quad (j=1,2,3) \\ O_4^{(1)} &= k=1 \end{aligned} \tag{12}$$

其中, $x(1)=r_{in}(k), x(2)=y_{out}(k), x(3)=e(k)$ 。

隐含层输入如式 (14)。

$$net_i^{(2)}(k) = \sum_{j=1}^4 \omega_{ij}^{(2)} O_j^{(1)}(k) \quad (14)$$

$$O_i^{(2)}(k) = f[net_i^{(2)}(k)] \quad (i=1,2,\dots,5)$$

输出层的输入输出如式(15)。

$$net_l^{(3)}(k) = \sum_{i=1}^6 \omega_{li}^{(3)} O_i^{(2)}(k) \quad (15)$$

$$O_l^{(3)}(k) = g[net_l^{(3)}(k)] \quad (l=1,2,3)$$

其中, $O_1^{(3)}(k) = Kp$, $O_2^{(3)}(k) = Ki$, $O_3^{(3)}(k) = Kd$ 。

性能指标函数如式(16)。

$$J = \frac{1}{2} (r_{in}(k+1) - y_{out}(k+1))^2 \quad (16)$$

按梯度下降法修正系统的权值, 可以得 BP 神经网络输出层的加权系数的修正公式如式(17)。

$$\Delta \omega_{li}^{(3)}(k+1) = \eta \delta_l^{(3)} O_i^{(2)}(k) + \alpha \Delta \omega_{li}^{(3)}(k) \quad (17)$$

其中,

$$\delta_l^{(3)} = e(k+1) \operatorname{sgn}\left(\frac{\partial y(k+1)}{\partial u}\right) \times \frac{\partial u(k)}{\partial O_l^{(3)}(k)} \times g'[net_l^{(3)}(k)] \quad (l=1,2,3)$$

同理可得隐含层加权系数的修正公式如式(18)。

$$\Delta \omega_{ij}^{(2)}(k+1) = \eta \delta_i^{(2)} O_j^{(1)}(k) + \alpha \Delta \omega_{ij}^{(2)}(k) \quad (18)$$

其中, $\delta_i^{(2)} = f'[net_i^{(2)}(k)] \sum_{l=1}^3 \delta_l^{(3)} \omega_{li}^{(3)}(k) \quad (i=1,2,\dots,5)$

其中 $f[x] = \tanh(x)$, $g[x] = (1/2)(1 + \tanh(x))$ 。

4 BP神经网络模型预测PID控制器设计

由式 (11) 可得:

$$\hat{\partial} y(k+1) / \partial u(k) = \hat{\theta}_{N+1}(n+1); \quad (19)$$

从而可实现用 $\hat{\partial} y(k+1) / \partial u(k)$ 代替 $\partial y(k+1) / \partial u(k)$ 符号函数^[3]。

因此基于 BP 神经网络模型预测的 PID 控制器系统的结构图如图 3 所示。




图 3 BP 神经网络模型预测 PID 控制器

5 仿真实验

阶跃信号应用在系统辨识仿真时, 可以使系统得

到较好的辨识结果, 但阶跃信号在工程应用不能完全反应系统的实际需要, 正弦信号可以弥补阶跃信号实际应用的不足, 文中选择正弦信号作为输入信号。

仿真过程分为两部分, 首先利用线性方程验证该算法辨识系统模型参数的准确性和 PID 控制系统的效果, 为算法应用于非线性差分方程提供理论支持; 然后再将该算法与传统的 BP 神经网络 PID 控制算法分别应用在线性差分方程。

实验过程如下:

1) 线性差分方程的选择: 线性函数的选择是基于差分方程转化为 S 和 Z 域后的传递函数后, 其阶跃响应有超调和放大的效果, 进而可以体现 PID 参数调整的作用。

构造线性差分方程:

$$y_{out}(k) = 0.9 \times y(k-1) - 0.4 \times y(k-2) + 1.4 \times u(k-1) - 0.8 \times u(k-2)$$

差分方程转化为 S 和 Z 域的传递函数后的阶跃响应 (Z 域的采样时间 $T=0.01$) 如图 4 所示, 仿真结果符合线性函数选择的要求。




图 4 阶跃响应仿真图

构造的线性函数系统实际参数为:

$a_1^0 = -0.9, a_2^0 = 0.4; b_1^0 = 1.4, b_2^0 = -0.8$; 当 $t_s = 0.001$, 正弦输入信号为 $r_{in}(k) = \sin(2 \times k \times \pi \times t_s), k = (1, 2, \dots, 2000)$

学习速率和惯性系数分别为 $\eta = 0.25, \alpha = 0.25$ 。

当 $t_s = 0.01$ 时, 正弦输入信号为

$r_{in}(k) = \sin(2 \times k \times \pi \times t_s), k = (1, 2, \dots, 1000)$, 学习速率和惯性系数分别为 $\eta = 0.01, \alpha = 0.25$ 。加权系数初始值取区间 $[-1, 1]$ 上的随机数。

由仿真图 5、图 6 可以看出在不同的采样的周期, BP 神经网络模型预测 PID 控制算法在线性系统取得了较好的控制效果, 系统具备很好的跟踪误差

能力。

2) 非线性函数的选择:

构造非线性被控对象差分方程^[7]:

$$y_{out}(k) = \frac{y(k-1)}{1 + y(k-1)^2} + u(k-1)^3; \text{ 对于差分方程的四}$$

个自变量分别取偏导数都是存在的, 方程式符合可线性化的条件。线性化采用阶数为 2 的预测模型来等价非线性差分方程, 正弦输入信号为 $r_{in}(k) = \sin(2 \times k \times \pi \times t_s)$, 加权系数初始值取区间[-1,1]上的随机数, 利用模型预测 BP 神经网络 PID 控制算法分别在 $t_{s1} = 0.005s, k = (1, 2, \dots, 1000)$, $\eta = 0.001$, $\alpha = 0.25$ 与 $t_{s2} = 0.01s, k = (1, 2, \dots, 1000)$ 两种情况下仿真实验。

由仿真图 7、图 8 可以看出在不同的采样的周期, 当 $t_s = 0.005s$ 时, 两种算法应用在非线性系统中系统都取得了较好跟踪误差的能力, 但采用 BP 神经网络 PID 模型预测控制算法系统波动较稳定性, 当 $t_s = 0.01s$ 时, 由仿真图 9、图 10 可以看出采用模型预测 BP 神经网络 PID 控制算法与传统 BP 神经网络 PID 控制算法相比系统稳定性更好。




图 5 $t_s = 0.001$ 时, 信号跟踪仿真图




图 6 $t_s = 0.01$ 时, 信号跟踪仿真图




图 7 $t_s = 0.005s$ 时, 预测控制跟踪仿真图




图 8 $t_s = 0.005s$ 时, 传统方法跟踪仿真图




图 9 $t_s = 0.01s$ 时, 预测控制跟踪仿真图




图 10 $t_s = 0.01s$ 时, 传统方法跟踪仿真图

6 仿真验证

上述采用最小二乘递推算算法对系统模型在线预测, 根据所得的预测模型与 BP 神经网络相结合可得到 PID 控制器的参数, 以此取代与传统用符号函数值等价的系数修正值, 仿真实验验证了 BP 神经网络模型预测 PID 控制器在线性与非线性系统中的控制效果。应用于线性系统中可以准确实时地在线辨识系统模型, 提高了系统跟踪误差的能力, 可满足系统高精度的控制要求; 应用于非线性系统中有很好的自适应及逼近任意函数的能力。

参考文献

- 1 Zhao GQ. Design nerve network controller of D.C motor without brush. Journal of Liaoning Technical University Publisher, 2004. 76-78.
- 2 He JA, Da ZH. Simulation of BP Neural PID Controller, Journal of Gansu Lianhe University (Natural Sciences), 2005,

(下转第 180 页)

器件而专门开发的一种使用方便的开发平台,它支持ADI公司所有系列的DSP处理器,包括Blackfin系列。VisualDSP++通过图形窗口的方式与用户进行信息交换;采用直观的、易于使用的用户界面,针对处理器进行操作;集成了两大部分:集成的开发环境(IDE)和调试器(Debugger),提供了更强大的程序开发和调试功能。VisualDSP++具有灵活的管理体系,为处理器应用程序和项目的开发提供了一整套工具。VisualDSP++包含生成和管理处理器项目必须的所有工具。

4.2 系统工作流程

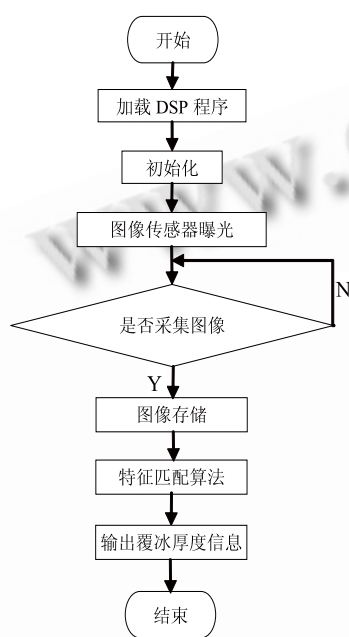


图5 系统流程图

系统流程图如图5所示。系统上电后,首先DSP加载FLASH中存储的程序,执行完初始化指令后,DSP通过I2C总线初始化MT9V032,使其工作在SLAVE模式。然后DSP通过外部总线接口对CPLD进行读写,使CPLD以一定的时序采集图像并通过DSP的PPI接口存入SDRAM。

5 结语

本文提出一种基于DSP与CPLD结构的图像采集和处理的方法,针对复杂背景下输电线路覆冰厚度的检测,采用线搜索算法对图像进行处理,为输电线路覆冰监测提供了新的依据。

参考文献

- 1 胡毅.输电线路运行故障的分析与防治.高电压技术,2007,33(3):1-8.
- 2 黄新波,孙钦东,程荣贵,等.导线覆冰的力学分析与覆冰在线监测系统.电力系统自动化,2007,31(14):98-101.
- 3 Rafael C.Gonzalez.数字图像处理.第2版.中文版.北京:电子工业出版社,2003.
- 4 周灿梅,陆佳政,向永嘉,黎福海,等.基于线搜索算法的输电线路覆冰厚度检测.仪表技术与传感器,2010,8:44-46.
- 5 Gao XQ, Peng TA. Line Detection Algorithm Based on Error Propagation. Proc. of the 26th Chinese Control Conference, 2007.493-496.
- 6 Chan TS, Yip RKK. Line detection algorithm. Pattern Recognition, 1996,2:126-130.

(上接第103页)

- 19(2):31-34.
- 3 陶永华,尹怡欣,葛芦生.新型PID控制及其应用.北京:机械工业出版社,1998.
- 4 Hilhorst RA, Van Amerongen J, et al. A supervisor for control of modeswitch processes. Automatica, 1994,30(8):1319-1331.
- 5 高国燊,余文杰,等.自动控制原理.广州:华南理工大学出版

社,2005.

- 6 李鹏波,胡德文,等.系统辨识基础.北京:中国水利水电出版社,2006.
- 7 Park SB, Park CH. Adaptive system identification using multilayer neural network and Gaussian potential function networks. The 1996 IEEE Int'l Conf on Neural Networks. Piscataway: IEEE, 1996,4:2261-2266.