

基于小波基神经网络 PID 的直流电机伺服控制

顾 洲¹, 鹿世化¹, 朱建忠², 王延维³

(1 南京师范大学 动力工程学院, 江苏 南京 210042 2 南京航空航天大学 自动化学院, 江苏 南京 210016
3. 江苏省标准化研究院, 江苏 南京 210029)

[摘要] 通过一种新颖的小波基神经网络对未知数学模型的对象进行在线辨识, 得到对象的数学模型——Jacobian 信息, 并提出了神经网络与模糊控制算法共同在线调整 PID 参数的方法, 从而实现电机位置的准确、快速、实时地跟踪. 通过仿真和实验表明: 使用该自适应控制方法, 能够对位置准确跟踪, 基本克服了一般神经网络控制对初始权值的依赖, 大大提高了对未知模型的辨识精度, 改善了系统的动态响应品质, 增强了系统的鲁棒性.

[关键词] 直流力矩电机, 小波神经网络, 辨识, 自适应 PID 控制

[中图分类号] TM 301.2 [文献标识码] A [文章编号] 1672-1292(2006)04-0017-04

DC Motor's Servo Controller Based on WNN PID

GU Zhou¹, LU Shihua¹, ZHU Jianzhong², WNAG Yanwei³

(1. School of Power Engineering, Nanjing Normal University, Nanjing 210042, China
2. School of Automatic Control, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China
3. Jiangsu Institute of Standardization, Nanjing 210029, China)

Abstract A novel topology network of WNN is introduced to identify on line the object of a certain unknown mathematical model and obtain the object's mathematical model—the Jacobian information. A method is suggested of PID parameters or adjusted on line by WNN and fuzzy arithmetic and thus realize the accurate, quick and real-time track. The sim together self tuning using is reported to track the motor's position precisely. The simulation and the experiment results show that the adaptive PID control method can be used to track accurately the position, and overcome the dependence of general neural network on initial weight and greatly increase the precision of identifying the unknown model and improve the control.

Key words DC motor, wavelet neural network(WNN), identification, adaptive PID control

0 引言

由于直流力矩电机存在非线性问题, 如电枢反应的非线性、转动惯量和电阻的变化等, 使得难以用一个精确的数学模型来描述直流电机的电磁关系^[1]. 由于采用传统的线性固定增益的 PID 控制需要精确地描述系统动态数学模型, 所以在运行过程中其参数发生变化或者受到外界扰动时, 其动态控制品质将会下降, 甚至影响系统的正常运行^[2]. 已有学者以 Sigmoid 函数的 BP 神经网络为基础用于直流电机的速度自校正控制, 但速度环属于一阶对象, 比较容易跟踪, 而且 BP 神经网络也存在以下缺点^[3]: 基函数非正交, 难以保证解的唯一性; 局域性差, 收敛速度慢; 难以确定逼近的分辨尺度等.

本文利用一种经过改进的小波基神经网络^[4], 获得电机精确的数学模型, 用于直流电机的 PID 自整定控制, 基本克服了以往神经网络对初始权值的依赖. 仿真结果表明: 小波基神经网络用于模型辨识其精度非常高; 用本文提出的方法其控制性能要优于传统的 PID 控制和一般神经网络控制.

1 控制系统的组成

系统的控制原理框图如图 1 所示. 码盘获得电机的位置信号 θ 通过 722 卡调理后进入工控机, 控制器

收稿日期: 2005-09-28
作者简介: 顾 洲(1973-), 讲师, 主要从事智能控制的教学与研究. E-mail: guzhou@mail@sohu.com

输出信号由工控机的 D/A 经过调理成为电机的 u_a 。由这两组信号构成小波神经网络辨识器的输入信号,通过辨识得到 $\partial\theta/\partial u$ 。PID 控制器参数由另外一个神经网络和模糊控制器进行在线调整,从而构成一个闭合的位置环跟踪控制。

2 对象的在线网络辨识

2.1 WNNI 的网络结构

文献 [4] 已对小波神经网络作了阐述。本文的小波神经网络采用 3 层网络结构模型:如图 2 所示,输入节点为 3 个,隐含层节点数为 6 个(隐层节点及小波个数的选择对系统辨识的精度有一定的影响,并非隐层节点越多越好^[5]),输出为 1 个节点(i 为输入层节点数, j 为隐层节点数; w_j 为隐层到输出的权值; w_{in} 为输入到输出的权值)。

输入层:由 3 个神经元组成,其输入信号为:

$$\begin{aligned}x_1 &= u_a(k) \\x_2 &= \theta(k) = y(k) \\x_3 &= \theta(k-1) = y(k-1)\end{aligned}\tag{1}$$

输入层节点的输出为直接输出。

隐含层:由 6 个神经元组成,其作用函数为小波函数: $\phi(x) = \|x - c_{ij}\| \cdot e^{-\frac{\|x - c_{ij}\|^2}{2b_{ij}^2}}$, 所以, 隐层输出为:

$$O_{ij} = \sum_{i=1}^3 \|x_i - c_{ij}\| \cdot e^{-\frac{\|x_i - c_{ij}\|^2}{2b_{ij}^2}}$$

(2)

输出层:由一个神经元组成

$$\hat{y} = \sum_{j=1}^6 \omega_j O_{ij} + \sum_{i=1}^4 w_{ini} x_i \quad (\text{其中 } x_4 = 1 \text{ 为域值})$$

(3)

输出层不仅有隐层输出的作用, 还有输入层直接作用, 这有利于神经网络的辨识精度和泛性的提高^[4]。

2.2 对象的辨识

定义性能函数: $J_I = \frac{1}{2} [y(k) - \hat{y}(k)]^2$, 则神经网络的学习算法如下:

$$\Delta c_{ij} = \eta \frac{\partial J_I}{\partial c_{ij}} = \eta \frac{\partial J_I}{\partial \hat{y}} \cdot \sum_{j=1}^6 \omega_j \frac{\partial \hat{y}}{\partial O_{ij}} \cdot \frac{\partial O_{ij}}{\partial c_{ij}}$$

(4)

$$c_{ij}(k) = c_{ij}(k-1) + \Delta c_{ij}(k) + \alpha \cdot [c_{ij}(k-1) - c_{ij}(k-2)] + \beta \cdot [c_{ij}(k-2) - c_{ij}(k-3)]$$

式中, η 为网络的学习速率, α 为惯性系数, β 为次惯性系数。

同理可得到:

$$b_{ij}(k) = b_{ij}(k-1) + \Delta b_{ij}(k) + \alpha \cdot [b_{ij}(k-1) - b_{ij}(k-2)] + \beta \cdot [b_{ij}(k-2) - b_{ij}(k-3)]$$

(5)

$$w_{ini}(k) = w_{ini}(k-1) + \Delta w_{ini}(k) + \alpha \cdot [w_{ini}(k-1) - w_{ini}(k-2)] + \beta \cdot [w_{ini}(k-2) - w_{ini}(k-3)]$$

(6)

$$\omega_j(k) = \omega_j(k-1) + \Delta \omega_j(k) + \alpha \cdot [\omega_j(k-1) - \omega_j(k-2)] + \beta \cdot [\omega_j(k-2) - \omega_j(k-3)]$$

(7)

式 (5) ~ (7) 中, Δb_{ij} , Δw_{ini} , $\Delta \omega_j$ 分别为:

$$\Delta b_{ij} = \eta \frac{\partial J_I}{\partial b_{ij}}, \quad \Delta w_{ini} = \eta \frac{\partial J_I}{\partial w_{ini}}, \quad \Delta \omega_j = \eta \cdot \frac{\partial J_I}{\partial \omega_j}$$

(8)

通过不断调整学习可得到对象的 Jacobian 信息:

$$\partial y / \partial u \approx \partial \hat{y} / \partial u = \frac{\partial}{\partial x_1} \left[\sum O'_{ij} \omega_j + x_1 w_{ini} \right]$$

(9)

$$\text{式中, } O'_{ij} = f(x_i) = \|x_i - c_{ij}\| \cdot e^{-\frac{\|x_i - c_{ij}\|^2}{2b_{ij}^2}} \Big|_{i=1}.$$




图 1 系统结构框图




图 2 网络结构图

3 控制器的在线调整

3.1 控制器结构

设

$$\text{error}(k) = \text{rin}(k) - y(k) \tag{10}$$

式中, $\text{rin}(k) = \theta_{\text{ref}}(k)$, $y(k) = \theta(k)$. 控制器采用单神经元结构, 如图 3 所示. 其输入为:

$$\begin{aligned} x_{c1} &= \text{error}(k) - \text{error}(k-1) \\ x_{c2} &= \text{error}(k) - 2\text{error}(k-1) + \text{error}(k-2) \\ x_{c3} &= \text{error}(k) \end{aligned} \tag{11}$$

控制器的输出 $u(k)$ 为:

$$u(k) = K_p(k) \cdot x_{c1} + K_d(k) \cdot x_{c2} + K_i(k) \cdot x_{c3} \tag{12}$$

式中, K_p, K_d, K_i 为单神经元的调整权.

3.2 性能指标

已有很多文献介绍控制器的性能指标为 $J_c = \frac{1}{2} \text{error}(k)^2$, 但由于该控制器属于感知器类型是线性的, 所以在程序设计上一般都加了硬限幅, 这种控制方法势必影响控制性能. 在本文中, 根据最优控制理论^[6], 定义 NNC 的性能指标函数为: $J_c = \frac{1}{2} \text{error}(k)^2 + \frac{1}{2} u(k)^2$, 则:

$$\begin{aligned} \Delta K_p &= \eta_{K_{pe}} \cdot \text{error} \cdot \frac{\partial y}{\partial u} \cdot \frac{\partial u}{\partial K_p} - \eta_{K_{pu}} \cdot u \cdot \frac{\partial u}{\partial K_p} \\ \Delta K_d &= \eta_{K_{de}} \cdot \text{error} \cdot \frac{\partial y}{\partial u} \cdot \frac{\partial u}{\partial K_d} - \eta_{K_{du}} \cdot u \cdot \frac{\partial u}{\partial K_d} \\ \Delta K_i &= \eta_{K_{ie}} \cdot \text{error} \cdot \frac{\partial y}{\partial u} \cdot \frac{\partial u}{\partial K_i} - \eta_{K_{iu}} \cdot u \cdot \frac{\partial u}{\partial K_i} \end{aligned} \tag{13}$$

式中, $\eta_{K_{pe}}, \eta_{K_{de}}, \eta_{K_{ie}}$ 分别为比例、微分、积分误差影响因子; $\eta_{K_{pu}}, \eta_{K_{du}}, \eta_{K_{iu}}$ 分别为比例、微分、积分控制器输出影响因子.

4 仿真研究

以 WH22A 三轴电动仿真转台中轴直流力矩电机为例, 其技术参数为: $R_a = 6.67 \Omega$, 反电势系数 $K_e = 68.4 \text{ V} \cdot \text{s/rad}$, 电动机转矩系数 $K_m = 6.44 \text{ N} \cdot \text{m/A}$, B_m 是电动机和负载折合到电动机轴上的粘性摩擦系数, 较小可忽略不计, 电动机和负载折合到电动机轴上的粘性转动惯量 $J_m = 4.02 \text{ kg} \cdot \text{m}^2$, 电枢电流产生的

$$\text{电磁转矩 } T_m = \frac{R_a J_m}{K_m K_e + B_m R_a} \approx 0.062 \text{ s} \cdot \text{rad}$$

设定值曲线为:

$$\text{rin}(t) = 120 \times \begin{cases} \sin(2t) + \sin(3t) & 0 < t < 1\text{s} \\ 2.6t - 2.6 & 1 < t < 1.5\text{s} \\ -2.6t + 5.2 & 1.5 < t < 2\text{s} \\ 0 & 2 < t < 2.5\text{s} \\ 1 & 2.5 < t < 3\text{s} \end{cases} \tag{14}$$

按上述算法进行仿真, 得到的曲线经常是发散的或者有很大的静差, 见图 4 中的点画线. 经过大量的仿真实验发现: 这是因为在调节过程中 K_i 过小或过大不收敛造成的, 显然这种控制器不能满足需要, 因此对 K_i 的调整要进行改进, 作者使用了模糊算法. 模糊输入为 error 和 Δerror , 输出为 K_i . 其输入输出三维规则曲线如图 5 所示. 经过改进后跟踪效果明显提高, 辨识精度达到 10^{-4} 数量级. PID 参数调节曲线如图 6 所示, 跟踪曲线如图 4 中的实线. 从跟踪效果图可以看出, 该控制器能够很好地跟踪不同频率的正弦波、三角波、阶跃响应, 其在调节时间、超调以及在适应性上明显优于和纯 PID, 如图 4 所示. 为了进一步测试其鲁棒性, 使系统跟踪 30 rad 的阶跃信号, 在 1 s 时开始加大电机的负载转矩, 从图 7 中可以看出系统很快跟踪上设定




图 3 网络结构图

值,可见其鲁棒性是比较高的.




图 4 跟踪曲线图




图 5 模糊规则 3D 图




图 6 改进后的 PID 曲线图




图 7 扰动曲线

5 结束语

由于小波参数的在线调整,使得网络的初始权值对系统稳定性的影响不大,本文在仿真实验中,初始权值设为随机数,经过多次的仿真实验证明,每次都能较好的跟踪设定值.另外 α 、 β 和 η 对网络的影响已有文献[7]做了介绍,这里不赘述.仿真结果表明:该控制方法具有适应性强、超调小、调节时间短、鲁棒性强等特点.

[参考文献] (References)

[1] 高钟毓. 机电控制工程[M]. 北京: 清华大学出版社, 2002
GAO Zhongyu Mechanical Control Engineering[M]. Beijing Tsinghua University Press 2002 (in Chinese)
[2] 曹先庆,朱建光,唐任远. 基于模糊神经网络的永磁同步电动机矢量控制系统[J]. 中国电机工程学报, 2006(1): 137- 141.
CAO Xianqing ZHU Jianguang, TANG Renyuan Vector controlled permanent magnet synchronous motor drive with adaptive fuzzy neural network controller[J]. Proceedings of the CSEE, 2006(1): 137- 141. (in Chinese)
[3] Q Shourong, WANG Dongfeng, PU Han, et al Grey prediction based RBF neural self tuning PID control for tuning process [C] // Proceedings of the Third International Conference on Machine Learning and Cybernetics Shanghai 2004
[4] ZHANG Q, BENVENISTE A. Wavelet networks[J]. Neural Networks 1992 3(6): 889- 898
[5] OUSSAR Y, RIVALS I, PERSONNAZ L, et al Training wavelet networks for nonlinear dynamic input/output modeling[J]. Neurocomputing 1998 20(8): 173- 188
[6] 胡寿松,王执铨,胡维礼. 最优控制理论与系统[M]. 2版. 北京: 科学出版社, 2005
HU Shousong WANG zhiquan, HU weili The Theory and System of Optimum Control[M]. 2nd ed Beijing Science Press 2005 (in Chinese)
[7] 易继锴,侯媛彬. 智能控制技术[M]. 北京: 北京工业大学出版社, 2004
YI Jikai HOU Yuanbin Intelligence Control[M]. Beijing Beijing University of Technology Press 2004 (in Chinese)

[责任编辑: 严海琳]