

基于模糊 RBF 神经网络的 PID 及其应用

欧阳磊, 黄友锐, 黄宜庆

(安徽理工大学电气与信息工程学院, 淮南 232001)

摘要: 针对传统的 PID 控制器参数固定而导致在控制中效果差的问题, 提出一种基于模糊 RBF 神经网络智能 PID 控制器的设计方法。该方法结合了模糊控制的推理能力强与神经网络学习能力强的特点, 将模糊控制与 RBF 神经网络相结合以在线调整 PID 控制器参数, 整定出一组适合于控制对象的 k_p, k_i, k_d 参数。将算法运用到电机控制系统的 PID 参数寻优中, 仿真结果表明基于此算法设计的 PID 控制器改善了电机控制系统的动态性能和稳定性。

关键词: 模糊控制; RBF 神经网络; PID 控制; 电机控制系统

PID Controller Based on Fuzzy RBF Neural Network and Its Application

OUYANG Lei, HUANG You-ru, HUANG Yi-qing

(School of Electronic and Information Engineering, Anhui University of Science and Technology, Huainan 232001)

【Abstract】 A kind of intelligent PID controller based on fuzzy RBF neural network is proposed to the problem that traditional PID controller is difficult to achieve good control effect because of the fixed parameters. This method includes the reasoning ability of fuzzy control and study ability of neural network. Fuzzy control and RBF neural network are applied in order to adjust the parameters of PID online to a group of k_p, k_i and k_d which is matching the plant best. Simultaneously the algorithm is applied to electro motor control system PID for parameter optimization. The simulation result shows that the PID controller greatly improves dynamic quality of electro control system.

【Key words】 fuzzy control; RBF neural network; PID control; electro motor control system

1 概述

PID 控制是一种很常用很普遍的控制方法, 在很多生产领域中都得到了广泛的应用^[1-2]。PID 控制器的关键在于对 3 个参数 k_p, k_i, k_d 的整定, 由于传统的 PID 控制器的 k_p, k_i, k_d 参数是固定的, 而现实系统中数学模型往往是非线性、时变的系统, 因此普通的 PID 控制器已不能满足其要求。

模糊控制^[3]是以模糊集合理论为基础的一种新兴的控制手段, 它是模糊系统理论和模糊技术与自动控制技术相结合的产物。模糊控制的核心就是利用模糊集合理论, 把人的控制策略的自然语言转化为计算机能够接受的算法语言所描述的控制算法, 这种方法不仅能实现控制, 而且能模拟人的思维方式对一些无法构造数学模型的被控对象进行有效的控制。它具有推理能力强的特点。

神经网络是一种模拟人的神经元对信息进行处理、存储和检索的理论结构。人的思维方式中信息处理是通过神经元之间同时相互作用的动态过程完成的。人工神经网络就是模拟人思维的这种方式。它是一个非线性动力学系统, 其特色在于信息的分布式存储和并行协同处理。虽然单个神经元的结构极其简单, 功能有限, 但大量神经元构成的网络系统所能实现的行为却是极其丰富多彩的。它的优点是自学能力和自适应能力强。

近年来, 模糊神经网络理论逐渐成为人们关注的热点^[4-9]。该文描述的模糊 RBF 神经网络正是运用模糊神经网络对 PID 3 个参数进行整定, 使系统达到了很好的控制效果, 具有明显的优点。

2 普通的 PID 控制器

普通的 PID 控制器的控制原理框图如图 1 所示。




图 1 PID 控制器原理图

在图 1 中, rin 是系统给定的输入; $yout$ 是整个系统的输出; e 是给定值 rin 与实际输出值 $yout$ 的偏差: $e=rin-yout$; 图中的比例环节、积分环节和微分环节将 e 通过线性组合构成控制量, u 是控制器的输出, 其控制规则为

$$u(t) = k_p \left(error(t) + \frac{1}{T_i} \int_0^t error(t) dt + \frac{T_D}{dt} derror(t) \right)$$

或写成传函形式:

$$G(s) = \frac{U(s)}{E(s)} = k_p \left(1 + \frac{1}{T_i s} + T_D s \right)$$

在该文的系统仿真中, 使用的是一种增量式 PID 的控制算法:

$$u(k-1) = k_p \left(error(k-1) + k_i \sum_{j=0}^k error(j) + k_d (error(k) - error(k-1)) \right)$$

作者简介: 欧阳磊(1984 -), 男, 硕士, 主研方向: 智能控制; 黄友锐, 博士后; 黄宜庆, 硕士

收稿日期: 2008-06-25 **E-mail:** ylou@aust.edu.cn

3 模糊 RBF 神经网络 PID 控制器

3.1 模糊 RBF 神经网络 PID 控制器的原理框图

模糊 RBF 神经网络 PID 控制器的原理框图如图 2 所示。




图 2 模糊 RBF 神经网络结构

在图 2 中, r 是系统的给定信号; y_{out} 是系统的输出; e 是给定输入跟实际输出的误差; u 是 PID 控制器的输出; 模糊 RBF 神经网络输出为 kp , ki 和 kd 3 个参数, 输入至 PID 控制器。

在原 PID 控制器的基础上, 利用模糊神经网络, 以系统实际输出和系统误差为输入, 整合出一组适合的 PID 参数, 并通过网络自身的学习功能, 不断优化其参数, 达到提高系统控制性能的目的。

3.2 模糊 RBF 神经网络的结构

神经网络将系统误差 e 和系统实际输出 y_{out} 作为输入, 整合输出一组合适的 kp , ki 和 kd 参数, 提高 PID 控制器的控制性能。

该模糊神经网络为 4 层, 如图 3 所示。第 1 层为输入层, 有 2 个节点; 第 2 层为模糊化层, 为 6 个节点; 第 3 层为模糊推理层, 也为 6 个节点; 第 4 层为输出层, 输出 3 个节点, 即 kp , ki 和 kd 3 个参数。




图 3 模糊 RBF 神经网络结构

下面为各层的具体描述, 其中, $f_n(x)$ 为各层的活化函数; n 为层数, 在这里 n 为 1~4。

(1) 输入层。该层有 2 个节点, 分别是误差和系统的输出反馈, 该层将输入的误差 e 和实际系统输出 y_{out} 作为输出送给下层。这层的输入为 x_1 和 x_2 , 其中, $x_1=e$, $x_2=y_{out}$; 活化函数为 $f_1(x)=x$ 。因此该层的输出为 x_1 和 x_2 。

(2) 模糊化层。该层有 6 个节点, 分别将 2 个输入划分为 6 个模糊集, 目的是把 2 个输入 e 和 y_{out} 进行模糊化: 利用 1 个隶属度函数分别计算出 2 个输入属于 6 个模糊集合的程度。本层的输入为 $x_1=e$, $x_2=y_{out}$, 活化函数即为该隶属度函数。因此, 输出为

$$f_2(i, j) = \exp\left\{-\frac{[f_1(i) - c_{ij}]^2}{(b_{ij})^2}\right\}$$

其中, $i=1, 2$; $j=1, 2, 3, 4, 5, 6$ 。 c_{ij} 和 b_{ij} 分别为高斯函数的第 i 个输入变量的第 j 个模糊集合的隶属函数的均差和标准差。

(3) 模糊推理层。该层同样有 6 个节点, 它们各代表了一种模糊规则, 作用是将 2 个输入所对应的模糊量经过两两匹

配达到点火强度。也就是说, 将上层中 2 个输入的模糊量经过两两相乘, 得到这一层的输出值。因此, 本层的活化函数, 即输出为

$$f_3(j) = \prod_{i=1}^N f_2(i, j), \quad N = \prod_{i=1}^n n_i$$

(4) 输出层。这一层要输出的就是 PID 控制器的 3 个参数, 输出当然是 3 个。这里有一个第 3 层跟本层的连接权矩阵 w , 它是一个 36 行 3 列的矩阵。本层的输出值就是将该矩阵以矩阵乘的方式, 乘以第 3 层的输出。因此, 本层的输出为

$$kp = w \cdot f_3 = \sum_{j=1}^N w(1, j) \cdot f_3(j), \quad ki = w \cdot f_3 = \sum_{j=1}^N w(2, j) \cdot f_3(j),$$

$$kd = w \cdot f_3 = \sum_{j=1}^N w(3, j) \cdot f_3(j)$$

3.3 模糊神经网络的学习算法

由于系统都是时变、非线性的, 因此神经网络需要随时调整权值, 即随时对 w 进行优化。因此, 需要对神经网络进行在线调整。在这里, 用 delta 规则对神经网络参数进行修正。则输出层的权值为

$$w_j(k) = w_j(k-1) + \Delta w_j(k) + \partial [w_j(k-1) - w_j(k-2)]$$

其中, ∂ 为学习动量因子; k 为迭代步骤。学习算法的关键就是计算 $\Delta w_j(k)$, 学习方法如下:

$$\Delta w_j(k) = -\eta \cdot \frac{\partial E}{\partial w_j} = \eta \cdot [r_m(k) - y_{out}(k)] \times \frac{\partial y_{out}}{\partial \Delta u} \times xc(j) f_3(j)$$

其中, η 为学习速率; w_j 就是输出节点与上一层各节点的连接权, $j=1, 2, \dots, N$ 。

利用上述学习算法, 使得性能指标函数 $E = \frac{1}{2} [r_m(k) - y_{out}(k)]^2$ 最优。式中的 $r_m(k)$ 和 $y_{out}(k)$ 分别表示网络的理想输出和实际输出。

4 直流电动机数学模型的建立

电枢控制直流电动机简化后的微分方程为

$$T_m \frac{dw_m(t)}{dt} + w_m(t) = K_1 U_a(t) - K_2 M_c(t) \quad (1)$$

电动机控制电压到转速的传递函数的模型为

$$\frac{\Omega(s)}{U(s)} = \frac{1/C_e}{T_m s + 1} \quad (2)$$

电机从控制电压到角位移的传递函数模型为

$$\frac{\theta(s)}{U(s)} = \frac{1/C_e}{s(T_m s + 1)} \quad (3)$$

$$T_m = \frac{R \cdot J_m}{R \cdot F_m + C_m \cdot C_e} \quad (4)$$

其中, Ω 为电动机的转速; U 为电动机的控制电压; $1/C_e$ 为速度常数; T_m 为机械时间常数。

5 数例仿真

试验电机模型中参数取值如下:

电机电感 $La = 0.24 \text{ mH}$, 转动惯量 $J_m = 1.1 \times 10^{-6} \text{ kg} \cdot \text{m}^2$, 电机电阻 $R_a = 2.32 \Omega$, 粘滞摩擦系数 $F_m = 2.2 \times 10^{-4} \text{ kg} \cdot \text{m}^2 \cdot \text{s}^{-1}$, 电动机的转矩常数 $C_m = 0.023 \text{ 2Nm} \cdot \text{A}^{-1}$, 电动势常数 $C_e = pN_a / 60a = 9.00$ 。

建立电机的连续传递函数模型:

$$G(s) = \frac{\theta(s)}{U(s)} = \frac{1/C_e}{s(T_m s + 1)} = \frac{43}{s(0.005s + 1)}$$

图 4 为普通 PID 控制器和模糊 RBF 神经网络 PID 在电机控制系统中的仿真结果。图 5 为该网络对 PID 参数的在线整

定图。




图4 2种不同方法的电机控制系统PID控制曲线的比较




图5 模糊神经网络对PID参数的在线整定图

(上接第 230 页)

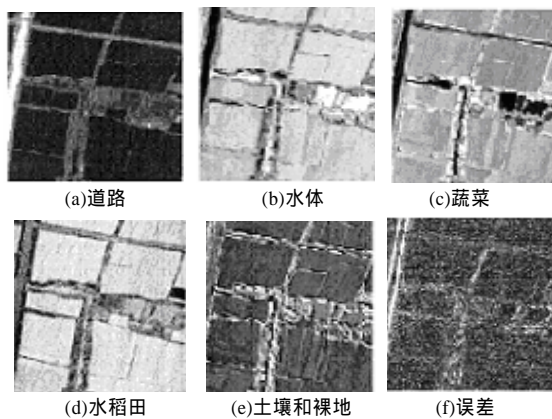


图5 分解的组分及误差影像

由于没有地面实测的定量数据,因此很难定量评价该方法估计的组分情况,本文以光谱重构的误差影像作为评价分解精度的指标,并通过对比文献[6]中迭代误差分解方法(IEA)来说明NMF的分解效果。表1是它们统计的一些结果。

表1 2种方法分解误差影像统计值的比较

方法	最小值	最大值	平均值	方差
IEA	0.000 0	11.331 6	0.309 4	0.258 4
NMF	0.000 0	1.320 5	0.075 5	0.118 3

表1的统计结果表明NMF的平均值和方差都较IEA方法计算的值为小,说明NMF混合像元的分解精度相对较高。

5 结束语

本文提出了一种端元约束的非负矩阵分解方法来自动反

6 结束语

本文描述了一种将模糊理论和神经网络相结合,并利用其调整PID 3个参数的控制方法,使PID控制系统达到很好的控制性能,解决了普通PID控制器在控制时变、非线性系统中所出现的问题。将此算法运用到电机控制系统的PID参数寻优中,从上面的仿真结果中不难发现,模糊RBF神经网络PID的控制性能明显优于普通的PID控制器,改善了电机控制系统的动态性能。

参考文献

- [1] 陶永华. 新型PID控制及其应用[M]. 北京: 机械工业出版社, 2005.
- [2] 刘金琨. 先进PID控制及其MATLAB仿真[M]. 北京: 电子工业出版社, 2003.
- [3] 杨大勇, 李鸣. 模糊PID控制在过程控制装置上的应用[J]. 微计算机信息, 2007, 23(10): 20-23.
- [4] 张好, 荣盘祥. 一种基于模糊神经网络的PID控制器[J]. 哈尔滨理工大学学报, 2005, 10(6): 63-65.
- [5] 宋北光. 模糊神经网络自适应PID在烟草复烤系统中的应用[J]. 河南科学, 2006, 24(6): 899-901.
- [6] 肖敏. 模糊神经网络PID控制在焊缝跟踪中的应用[J]. 微计算机信息, 2006, 22(9): 68-70.
- [7] 李英顺等. 基于模糊神经网络的PID温度控制系统[J]. 鞍山钢铁学院学报, 2002, 25(6): 408-411.
- [8] 刘文军, 牛昱光. 基于模糊神经网络的参数自整定PID控制系统设计[J]. 太原理工大学学报, 2006, 37(3): 298-301.
- [9] 江善和, 申东日. 一种基于模糊神经网络的自适应PID智能控制[J]. 安庆师范学院学报, 2004, 10(2): 1-4.

演高光谱混合像元组分解精度的信息。通过罚函数的形式加入了端元光谱差距最大化约束,利用最大后验概率的方法求出了限制性非负矩阵分解的迭代算法。利用PHI数据测试了该方法的效果,结果表明该方法获取的端元光谱比较合理,且混合像元分解精度较高。由于设计法函数有很大的灵活性,而本文使用的是修正的端元约束条件,因此,有可能存在更好的约束条件。今后将考虑其他形式的约束来提高混合像元的分解精度。

参考文献

- [1] Lee D D, Seung H S. Learning the Parts of Objects by Non-negative Matrix Factorization[J]. Nature, 1999, 401(6755): 788-791.
- [2] Guillamet D, Vitria J, Schiele B. Introducing a Weighted Non-negative Matrix Factorization for Image Classification[J]. Pattern Recognition Letters, 2003, 24(14): 2447-2454.
- [3] Paura V P, Piper J, Plemmons R J. Nonnegative Matrix Factorization for Spectral Data Analysis[J]. Linear Algebra and Its Applications, 2006, 52(1): 29-47.
- [4] Hoyer P O. Non-negative Matrix Factorization with Sparseness Constraints[J]. Journal of Machine Learning Research, 2004, 37(5): 1457-1469.
- [5] Pascual-Montano A, Carazo J, Kochi K, et al. Nonsmooth Nonnegative Matrix Factorization[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2006, 28(3): 403-415.
- [6] 吴波, 张良培, 李平湘. 高光谱端元自动提取的迭代分解方法[J]. 遥感学报, 2005, 9(3): 286-293.