

PID 神经元网络对强耦合带时延多变量系统的解耦控制

舒怀林

(广州大学维修工程技术学部·广州, 510091)

摘要: 提出了一种新的神经网络——PID 神经元网络, 它是由比例元、积分元和微分元构成的多层神经网络, 它可以用于控制强耦合带时延多变量系统, 并使系统具有良好的动态和静态性能。

关键词: 神经网络; PID 控制; 带时延系统; 多变量系统; 解耦控制

1 引言

多变量系统控制的目的是使系统的每个被控变量只按其给定值变化, 使其不受或少受其它给定值的影响, 并且具备较好的动态和静态性能, 即实现解耦控制。传统控制方法在进行带时延多变量系统的控制时, 需要预先得知对象参数, 再分别设计补偿器、解耦器和控制器。由于强耦合多变量系统的参数测量不易, 补偿器、解耦器和控制器的设计、实现和协调困难, 因此传统控制方法难以对强耦合带时延多变量系统进行有效的控制。

本文建立了一种新的神经网络——PID 神经元网络, 来进行强耦合带时延多变量系统的控制, 这与用神经网络辅助选取或修改 PID 控制器的参数^{[1]~[5]}有本质的区别。PID 神经元网络是一种前向多层神经网络, 它参照 PID 规律选取隐含层神经元的输入输出函数, 使它们分别成为具有比例、积分和微分处理功能的比例元、积分元和微分元; 它还参照 PID 规律确定网络的连接权初值, 使系统初始状态稳定, 且使网络的学习收敛速度快。应用 PID 神经网络控制器时, 不需要测量或辨识对象的内部结构和参数。PID 神经元网络通过在线测量的系统给定值和输出值, 通过自主学习, 调整网络权值, 并行同时完成系统解耦控制工作, 使强耦合带时延多变量系统具有良好的动态和静态性能。

2 PID 神经元网络多变量控制系统结构

设多变量被控对象为 n 输入 n 输出的 n 变量系统, PID 神经元网络控制器即为 $2n \times 3n \times n$ 结构, 图 1 为一个二变量的 PID 神经元网络控制系统。由图 1 可知, PID 神经元网络是一个三层网络, 包括 n 个并列的相同子网络。各个子网络的输入层至隐层是相互独立的, 其输入层有两个神经元, 分别接受一个被控变量的给定值和实际值。每个子网络的隐层有三个神经元, 分别为比例元、积分元和微分元, 它们的输入-输出函数分别为比例、积分和微分函数。各个子网络在隐层至输出层相互交叉相连, 输出层完成控制规律的综合, 形成多变量对象的控制输入。




图1 二变量PID神经网络控制系统

3 PID 神经网络的计算方法

PID 神经网络的计算方法与其它前向神经网络类似,包括前向算法和反传算法.

3.1 前向算法

在任意采样时刻 k , PID 神经网络的前向计算公式如下:

1) 输入层.

输入层神经元的输入输出函数为

$$x_{si}(k) = u_{si}(k). \quad (1)$$

上式中, u_{si} 为输入层神经元的输入值, x_{si} 为输入层神经元的输出值, s 为并列子网的序号, $i = 1, 2; s = 1, 2, \dots, n$.

2) 隐含层.

隐含层各单元输入总值的计算公式相同,均为

$$u'_{sj}(k) = \sum_{i=1}^2 w_{sij} x_{si}(k). \quad (2)$$

比例元的输入输出函数为

$$x'_{s1}(k) = \begin{cases} 1, & x'_{s1}(k) > 1, \\ u'_{s1}(k), & -1 \leq x'_{s1}(k) \leq 1, \\ -1, & x'_{s1}(k) < -1. \end{cases} \quad (3)$$

积分元的输入输出函数为

$$x'_{s2}(k) = \begin{cases} 1, & x'_{s2}(k) > 1, \\ x'_{s2}(k-1) + u'_{s2}(k), & -1 \leq x'_{s2}(k) \leq 1, \\ -1, & x'_{s2}(k) < -1. \end{cases} \quad (4)$$

微分元的输入输出函数为

$$x'_{s3}(k) = \begin{cases} 1, & x'_{s3}(k) > 1, \\ u'_{s3}(k) - u'_{s3}(k-1), & -1 < x'_{s3}(k) < 1, \\ -1, & x'_{s3}(k) < -1. \end{cases} \quad (5)$$

以上各式中 u'_{sj} 为隐层神经元的输入值, x'_{sj} 为隐层神经元的输出值, w_{sij} 为各子网输入层至隐含层的连接权值, $j = 1, 2, 3; s = 1, 2, \dots, n$.

3) 输出层.

各个输出层神经元的输入为隐含层全部神经元的输出值的加权总和,

$$u''_h(k) = \sum_{s=1}^n \sum_{j=1}^3 w'_{sjh} x'_{sj}(k). \quad (6)$$

输出神经元的输入输出函数为

$$x''_h(k) = \begin{cases} 1, & x''_h(k) > 1, \\ u''_h(k), & -1 \leq x''_h(k) \leq 1, \\ -1, & x''_h(k) < -1. \end{cases} \quad (7)$$

上两式中, u''_h 为输出层神经元的输入值, x''_h 为输出层神经元的输出值, w'_{sjh} 为隐含层至输出层的连接权值. $h = 1, 2, \dots, n$, 为输出层神经元序号. 当网络用于控制时, 其输出值还应乘上对对象输入最大值和最小值相对应的系数.

3.2 反传算法

PID 神经网络控制属于无教师的直接自学习控制,反传算法将 PID 神经网络和多变量对象看作一个具有更多层次的网络,多变量对象是这个网络的最后一层(或几层),是未知的.这个广义网络采用误差后向传播的批学习算法,学习的目标是使

$$J = \sum_{p=1}^n E_p = \frac{1}{m} \sum_{p=1}^n \sum_{k=1}^m [r_p(k) - y_p(k)]^2 = \frac{1}{m} \sum_{p=1}^n \sum_{k=1}^m e_p^2(k) \quad (8)$$

为最小.式中 m 为每批采样点数, n 为被控变量个数.

按梯度法调节 PID 神经网络权值,经 n_0 步训练和学习后的权值分别由以下各式确定.

1) 隐含层至输出层.

隐含层至输出层的权值迭代公式为

$$w'_{sjh}(n_0 + 1) = w'_{sjh}(n_0) - \eta'_{sjh} \frac{\partial J}{\partial w'_{sjh}}. \quad (9)$$

由于多变量对象的输出和输入之间存在耦合作用,上式中

$$\frac{\partial J}{\partial w'_{sjh}} = \sum_{p=1}^n \frac{\partial J}{\partial E_p} \frac{\partial E_p}{\partial y_p} \frac{\partial y_p}{\partial v_h} \frac{\partial v_h}{\partial x''_h} \frac{\partial x''_h}{\partial u''_h} \frac{\partial u''_h}{\partial w'_{sjh}}, \quad (10)$$

由于对象参数的未知,式(10)中的 $\frac{\partial y_p}{\partial v_h}$ 项不能直接计算.而由式(10)可知, $\frac{\partial y_p}{\partial v_h}$ 项仅为其中的一个相乘因子,其正负决定收敛的方向,其大小只决定收敛的速度.因此,改用 y_p 和 v_h 的相对变化量的符号函数

$$\operatorname{sgn} \frac{y_p(k+1) - y_p(k)}{v_h(k) - v_h(k-1)}, \quad (11)$$

近似替代 $\frac{\partial y_p}{\partial v_h}$ 项.再由式(7)和式(8),可得

$$\begin{aligned} \frac{\partial J}{\partial w'_{sjh}} &= -\frac{2}{m} \sum_{p=1}^n \sum_{k=1}^m [r_p(k) - y_p(k)] \operatorname{sgn} \frac{y_p(k+1) - y_p(k)}{v_h(k) - v_h(k-1)} x'_{sj}(k) \\ &= -\frac{1}{m} \sum_{p=1}^n \sum_{k=1}^m \delta'_{hp}(k) x'_{sj}(k). \end{aligned} \quad (12)$$

2) 输入层至隐含层.

输入层至隐含层的权值迭代公式为

$$w_{sij}(n_0 + 1) = w_{sij}(n_0) - \eta_{sij} \frac{\partial J}{\partial w_{sij}}. \quad (13)$$

其中

$$\frac{\partial J}{\partial w_{sij}} = \sum_{p=1}^n \left[\frac{\partial J}{\partial E_p} \frac{\partial E_p}{\partial y_p} \left(\sum_{h=1}^n \frac{\partial y_p}{\partial v_h} \frac{\partial v_h}{\partial w_{sij}} \right) \right], \quad (14)$$

而

$$\frac{\partial v_h}{\partial w_{sij}} = \frac{\partial v_h}{\partial x''_h} \frac{\partial x''_h}{\partial u''_h} \frac{\partial u''_h}{\partial x'_{sj}} \frac{\partial x'_{sj}}{\partial u'_{sj}} \frac{\partial u'_{sj}}{\partial w_{sij}}. \quad (15)$$

由于上式中的 $\frac{\partial x'_{sj}}{\partial u'_{sj}}$ 也仅为一个相乘因子,其正负决定收敛的方向,其大小只决定收敛的速度,因此用 x'_{sj} 和 u'_{sj} 相对变化量的符号函数

$$\operatorname{sgn} \frac{x'_{sj}(k) - x'_{sj}(k-1)}{u'_{sj}(k) - u'_{sj}(k-1)}, \quad (16)$$

近似代替 $\frac{\partial x'_{sj}}{\partial u'_{sj}}$.再由式(1)~式(8)、式(11)和式(12),可得

$$\begin{aligned}\frac{\partial J}{\partial w_{sj}} &= -\frac{1}{m} \sum_{p=1}^n \sum_{h=1}^n \sum_{k=1}^m \delta'_{hp}(k) w'_{sjh} \operatorname{sgn} \frac{x'_{sj}(k) - x'_{sj}(k-1)}{u'_{sj}(k) - u'_{sj}(k-1)} x_{si}(k) \\ &= -\frac{1}{m} \sum_{p=1}^n \sum_{h=1}^n \sum_{k=1}^m \delta'_{jh}(k) x_{si}(k).\end{aligned}\quad (17)$$

由以上算法可知, PID 神经网络在进行多变量系统控制时, 不需要被控对象的内部数学模型, 也不需要辨识对象的数学模型。

3.3 PID 神经网络权重初值的确定

神经网络的连接权初值直接关系到学习收敛速度和收敛的方向, PID 神经网络按 PID 控制规律的特点确定权重初值. 选取网络的输入层至隐含层的权重初值, 使其满足 $(r, y) \rightarrow e$ 映射的要求; 选取网络隐含层至输出层的权重初值, 使系统初始工作的稳定裕量较大, 避免出现大超调和振荡。

4 PID 神经网络解耦控制机理

PID 神经网络的解耦控制能力来自它的任意非线性映射特性. 在进行训练和学习时, 它本身并不知道完成的任务是解耦或是控制, 它只是根据目标函数(式(8))的要求, 完成包含被控对象在内的系统输入到系统输出的映射. 因此, 只要训练样本中包括了解耦控制的要求, PID 神经网络就可以按学习算法逐步调整连接权, 使系统解耦控制性能达到最佳状态. 解耦是为了控制, 解耦是手段, 控制是目的, 二者相辅相成, 紧密相关. PID 神经网络将解耦和控制融为一体, 符合控制系统的根本要求。

定义 称 $\sigma(x): \mathbb{R} \rightarrow \mathbb{R}$ 是一广义 Sigmoidal 函数, 若 $\lim_{x \rightarrow \infty} \sigma(x)$ 和 $\lim_{x \rightarrow -\infty} \sigma(x)$ 存在, 且满足

$$\lim_{x \rightarrow \infty} \sigma(x) = 1, \quad \lim_{x \rightarrow -\infty} \sigma(x) = -1. \quad (18)$$

由式(3)~(7)可知, PID 神经网络中的神经元具有上下限幅的输入输出特性, 经坐标平移后属于广义 Sigmoidal 函数的范畴。

对于由具有 Sigmoidal 函数特性神经元组成的前向神经网络, 其映射能力已有大量的文献进行了研究和证明, 本文不在此详述. 由于 PID 神经网络也是由具有广义 Sigmoidal 函数特性的处理单元组成的多层前向神经网络, 其映射能力保证了其解耦控制能力。

5 PID 神经网络强耦合带时延多变量控制的系统仿真

为了验证 PID 神经网络的解耦控制能力, 作者进行了大量的仿真研究, 以下为一个仿真实例. 设一个带时延的强耦合二变量非线性对象由以下方程描述:

$$\begin{cases} y_1(k+1) = \frac{1}{1+y_1^2(k)} [0.8y_1(k) + v_1(k-2) + 0.2v_2(k-3)], \\ y_2(k+1) = \frac{1}{1+y_2^2(k)} [0.9y_2(k) + 0.3v_1(k-3) + v_2(k-2)]. \end{cases} \quad (19)$$


式中 $y_i(z), v_i(z); i=1, 2$, 分别为对象输入量和输出量的 z 变换. 可以证明, 这是一个强耦合的非线性带时延二变量对象。

给定输入激励为

$$R_{10} = \begin{bmatrix} r_1(k) \\ r_2(k) \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \quad R_{01} = \begin{bmatrix} r_1(k) \\ r_2(k) \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}. \quad (20)$$

由于 R_{10} 和 R_{01} 是两种典型的阶跃输入, 如果系统对 R_{10} 和 R_{01} 都有良好的响应, 必然满足其他类型输入的响应要求。

用 PID 神经网络构成控制系统, 先将 R_{10} 和 R_{01}



分别送入系统,对网络进行训练,学习步长 $\eta = 0.01$,每批的采样点数 $m = 200$. 网络学习 100 步后,系统对 R_{10} 和 R_{01} 响应如图 2(a)、(b) 所示. 再采用输入函数

$$R_{1s} = \begin{bmatrix} r_1(k) \\ r_2(k) \end{bmatrix} = \begin{bmatrix} 0.2(k) + 0.8(k - c) \\ 0.5(k) + 0.2\sin(0.05k) \end{bmatrix}, \quad (21)$$

检验系统的性能. 如果取采样点数 $m = 400$, 取上式中 $c = 200$, 系统对 R_{1s} 的响应如图 2(c) 所示.

由以上结果可知,系统已经实现了解耦控制,而且具有良好的动态和静态性能.

6 结 论

对于带时延的强耦合非线性多变量对象,PID 神经网络在未知对象参数的情况下,通过训练和学习,可以实现系统的解耦控制,使系统变量之间的相互耦合作用基本消除,系统的响应速度快、超调小、无静差.

PID 神经网络将 PID 控制规律融入多层前向神经网络,它的显著特点是:网络结构简单和规范,便于实现;网络结构和权重初值按 PID 控制规律确定,系统稳定,参数收敛迅速,学习时间短;网络具有内在的动态性能,自适应能力强,胜任强耦合带时延多变量系统的实时控制.




图 2 PID神经网络控制带时延非线性二变量对象的响应曲线

参 考 文 献

- 1 Chen, C. L. and Chang, F. Y.. Design and analysis of neural/fuzzy variable structural PID control systems. IEE Proc. Control Theory and Applications, 1996, 143(2): 200-208
- 2 李卓, 萧德云, 何世忠. 基于神经网络的模糊自适应 PID 控制方法. 控制与决策, 1996, 11(3): 340-345
- 3 谭永红. 基于 BP 神经网络的自适应控制. 控制理论与应用, 1994, 12(1): 84-87
- 4 夏红, 王慧, 李平. PID 自适应控制. 自动化仪表, 1996, 11(4): 41-43
- 5 王耀南, 蔡自兴. 基于神经网络的智能 PID 控制及应用. 信息与控制, 1994, 23(3): 185-189

PID Neural Network for Decoupling Control of Strong Coupling Multivariable Time-Delay Systems

SHU Huailin

(Technical Faculty of Maintenance Engineering, Guangzhou University • Guangzhou, 510091, PRC)

Abstract: A new kind of neural network—PID neural network is given in this paper. It is a multi-layered network and consists of proportional (P) neural units, integral (I) neural units and derivative (D) neural unit. It can be used to control the strong coupling time-delay multivariable systems and the control systems have perfect dynamic and static performances.

Key words: neural network; PID control; time-delay system; multivariable system; decoupling control

本文作者简介

舒怀林 1954 年生. 1982 年本科毕业于西安交通大学, 1989 年毕业于西安矿业学院, 获硕士学位, 1997 年毕业于华中理工大学, 获博士学位. 现在广州大学维修工程技术学部任教. 专业和研究方向为自动控制和神经网络的理论及应用.