

基于 CPN 的模糊控制器系统设计及其应用研究*

葛 铭 李 平 孙 优 贤

(浙江大学工业控制技术研究所, 工业控制技术国家重点实验室·杭州, 310027)

摘要: 本文给出一种基于对向传播网络 CPN(counter propagation networks)的模糊控制器设计。该网络经训练后能得到模糊规则并且具有自学习功能, 在控制性能上较普通控制器有所改进。最后给出加压网前箱系统的应用实例。

关键词: 对向传播网络; 模糊控制器; 神经网络; 自学习

1 引言

模糊控制器在工业生产中有着其广泛的应用, 特别是对常规控制器难以控制的复杂和病态系统, 模糊控制有其独特的控制性能。然而, 由于模糊控制是一种基于知识的控制, 控制性能的好坏直接取决于知识量获得的多少。事实上由于人们对控制对象的了解往往是不全面甚至是微浅的, 所以模糊规则往往很不完善, 控制效果因而也有所降低。如果模糊控制具有学习机制, 能够不断地从被控对象中获得信息, 修正模糊规则, 这样控制效果就会大大改进。而这学习机制的产生, 完全可以利用神经网络。由于神经网络具有自学习机能, 经过一定的训练以后, 它能给出一个比较合理的模糊规则。而这规则并非一成不变, 它可以从实时控制中获得新的对象信息而加以修正。

2 基于 CPN 的模糊控制器

一般的模糊控制器由三部分组成: 模糊化(fuzzifier)、规则推理(if-then)、去模糊化(de-fuzzifier)。在这三部分中, 规则推理是最重要的一部分。对控制对象了解多少就体现在控制规则上, 规则制定的好坏直接影响到控制质量。

一个控制规则实际上就是一个映射, 模糊控制器的本质就是根据不同的输入变量激活相应的映射从而给出控制作用而达到控制目的。控制规则的制定一般依赖于经验, 然而经验并不能完全体现出对象的性质, 而且由于一些经验只能“意会不能言传”, 因而在经验的转换过程中, 一些信息会丢失掉, 规则最终也不能全部反映经验知识。最重要的是由于规则本身不能自动调节, 所以当对象或者环境发生变化时, 现有的规则可能会导致控制质量下降。

控制规则既然是一个映射, 那么就可以利用神经网络来逼近它, 并且由于神经网络本质上具有学习和记忆能力, 用它来表达控制规则是合适的。神经网络有许多, 典型的如 BP 网络, Hopfield 网络等, 这里给出一种新型神经网络 CPN(counter propagation networks)。CPN 是一种在功能上用作统计最优化和概率密度函数分析的网络, 由 Robert Hecht-Nielsen 提出, 通过组合 Kohonen 学习和 Grossberg 学习而得的一种新的网络结构。

众所周知, 人工神经网络所具有的一种信息处理能力是通过自组织完成对范例的映射学习, 如 BP 网络可以达到在 LSM 意义上最优的逼近。CPN 由自组织结构(Kohonen 结构)和 Grossberg 组合而成^[1,2], 包含两者的优点, 结构如图 1。一般 CPN 包含三层神经元, 输入层接

* 国家重点实验室基金资助项目。

本文于 1995 年 5 月 9 日收到, 1996 年 2 月 2 日收到修改稿。

受输入向量, Kohonen 层通过权矩阵 W 与输入层相连, 再经过权矩阵 K 连接输出层(grossberg).

CPN 网络的训练是无教师学习和有教师学习的综合, 无教师学习保证了网络可以不断接受信息而调整规则. 一般权矩阵 W 的调节采用无教师学习 LVQ 法(learning vector quantizer), 权矩阵 K 则采用 Out-star 法训练^[3]. 算法如下:

1) 输入向量标准化:

$$a_h^k = \frac{a_h^k}{\|A_k\|}, \quad h = 1, 2, \dots, n; \quad k = 1, 2, \dots, m;$$

2) 权阵列 W 取随机小值:

$$W_{ij} \in [0, 1], \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, p;$$

3) 权阵列标准化:

$$W_{ij} = \frac{W_{ij}}{\|W_i\|},$$

$$W_i = (W_{i1}, W_{i2}, \dots, W_{ip}), \quad i = 1, 2, \dots, n; j = 1, 2, \dots, p;$$

4) 对任一输入向量 $A_k, k = 1, 2, \dots, m$; 有:

a) 找出最接近向量 A_k 的权阵列 W_g , 满足

$$\|A_k - W_g\| = \min_{i=1}^p \|A_k - W_i\|;$$

b) 使 W_g 逐渐逼近 A_k .

$\Delta W_{hg} = \alpha(t)[a_h^k - W_{hg}], h = 1, 2, \dots, n; \alpha(t)$ 为一学习速率, 按经验可取为 $\alpha(t) = 1/t$ 或 $\alpha(t) = 0.2[1 - t/1000]$ ^[1]; 其中 ΔW_{hg} 为 W_{hg} 的改变量.

c) 对 W_g 进行标准化

$$W_{hg} = \frac{W_{hg}}{\|W_g\|}, \quad h = 1, 2, \dots, n;$$

d) 利用 Grossberg 层输出值 C_k 对权阵列 K 进行调整 $\Delta K_{gj} = -\beta(t)K_{gj} + \gamma b g C_j^k, j = 1, 2, \dots, q; \beta(t)$ 可以取为正数并随时间递降; $\gamma > 0$ 为控制学习速率; $b g = \sum_{h=1}^n W_{hg} a_h^k$,

5) 不断重复步骤 4) 直至满足给定要求, 即网络达到一个相对平稳状态.

在 CPN 学习以后, 就可以对网络输入信息进行处理: 若给定输入向量 X , 求出每一权向量与 X 的点积, 称点积最大的神经元为 C ; 其次, 求出第三层中每一神经元的输出 $Y_i, Y_i = K_{ij}$ (即与第二层中神经元连接的权值). 如果要优化 CPN 的性能, 可对输入向量归一化, 输入到 Kohonen 神经元的每一权值集也应作向量归一化处理. 根据 CPN 网络的结构和原理, 就可以利用它进行模糊规则的学习和更新.

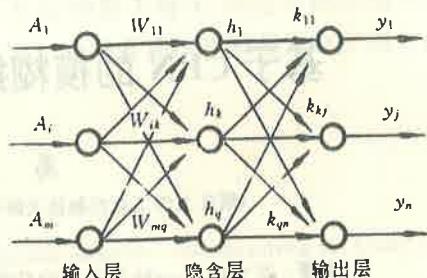


图 1 CPN 网络结构

表 1 控制规则表

		PB	PM	PS	ZE	NS	NM	NB	
		PN	NS	PS	NS	NS	NB	NM	NS
		PM	NS	PB	ZE	NM	ZE	NB	PB
		PS	PS	PB	NS	ZE	PS	NB	PM
		ZE	NM	NS	PB	NB	NM	ZE	PS
		NS	PS	PM	BM	NB	PS	NM	NS
		NM	NS	NS	PS	NS	PS	NB	PM
		NB	ZE	PM	NS	NB	PM	PS	NB

3 模糊规则的 CPN 实现

对于一模糊规则: $A_k, B_k \rightarrow C_k$ 来说在神经网络中可以把 A_k, B_k 分别看成一对输入向量, C_k 看成相应的输出向量. 不失一般性, 考虑一具体的模糊规则实现. 设输入向量 A, B 的维数为 7, 控制规则如表 1, 输出向量 C 的维数 13.

对于 CPN 网络, 中间(Kohonen 层)可以取为 8 个神经元, 而输入层则取 14(7+7)个神经元, 输出层则取为 13 个神经元.

神经网络的输入量的结构以如下形式表示

$$\text{Input} = [u_{NB}(a), u_{NM}(a), u_{NS}(a), u_{ZE}(a), u_{PS}(a), u_{PM}(a), u_{PB}(a); \\ u_{NB}(b), u_{NM}(b), u_{NS}(b), u_{ZE}(b), u_{PS}(b), u_{PM}(b), u_{PB}(b)].$$

其中 $u_x(a)$ 表示值 a 在模糊集 X 上的映射程度, $u(\cdot)$ 为隶属函数, 本例模糊隶属关系如图 2. 例如: A 为 PS, B 为 NM, 则 C 为 NB, 相应的在神经网络上输入向量为 $A = [0, 0, 0, 0, 1, 0, 0], B = [0, 1, 0, 0, 0, 0, 0]$; $C = [1, 0.5, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]$. 这样, 对于控制规则($PS, NB \rightarrow NB$) 就对应一数字化映射:

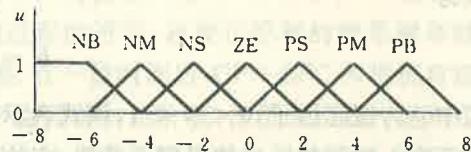


图 2 隶属函数

$[0, 0, 0, 0, 1, 0, 0; 0, 1, 0, 0, 0, 0, 0] \rightarrow [1, 0.5, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]$; 把控制表 1 都如上所示离散化后, 经过 CPN 网络的训练和学习就可得到一个连续的模糊规则映射. 这种经过训练以后的模糊规则对于那些新输入向量来说, 它与输出向量的准确度正比于输入向量与训练向量的距离, 也就是说对于规则($A_k, B_k \rightarrow C_k$), 若输入向量 A', B' 与 A_k, B_k 很接近, 则 C' 也接近于 C_k . 这一点正体现出了神经网络的泛化作用(generalizing).

当 CPN 学习完以后, 相应的权值也就固定了. 对于变化不大的控制对象, 该控制已能达到目的^[4]; 但对于时变较大的对象, 由于规则不能改变, 造成控制效果变差.

4 自组织 CPN 网络模糊控制器的实现

模糊神经网络控制器的跟踪能力较模糊控制器强, 相应的收敛程度也较前者好. 但是从 CPN 神经网络的构成过程来看, 有两个问题没有解决, 其一, CPN 网络的规则构成需要有控制对象的先验知识; 其二, 当控制对象发生变化时, CPN 神经网络模糊控制器的适应性较差. 为了解决这些问题, 提出了自组织 CPN 网络模糊控制器(CPN-SFC)

本节以单输入单输出(SISO)系统为例来研究 CPN-SFC 控制器, 对于该 SISO 系统有两个输入 E 和 ΔE 一个输出 U , 控制器的性能指标取某一 E 和 ΔE 的组合函数. 假定事先我们并不知道控制规则, 需要在控制中产生规则. 就 CPN 网络的权值结构来说, 就是需要在控制过程中调整权值得到规则. 整个自组织控制过程可以简单描述为: 当开始时, 网络得到一组输入信号 E 和 ΔE , 此时网络的控制规则是一些虚规则(随机赋值), 此时经过网络推理后得到一控制量 $U(t)$, 该控制量作用于被控系统得到一输出量 $y(t)$, 产生一误差 E 和误差速率 $\Delta E(E(t) - E(t-1))$. 根据 E 和 ΔE 得到性能函数值, 或从性能表中查询到相应的修正值 $R(t)$, 由此可得到输入输出数据对 $(E, \Delta E) \rightarrow (U(t - mT) + R(t))$, mT 为滞后时间. 将这数据对用 CPN 网络训练学习以后, 得到一组粗略的控制规则. 根据这组规则和新的输入产生控制量, 依上述步骤对相应的输入输出数据对进行训练和学习, 得到不断经过校正的模糊规则.

这里存在一个潜在的问题, 当控制过程不断产生新的数据对时, 累积的数据对会大大占用内存和降低运算速度, 最后造成数据溢出. 过多的历史数据会“淹没”新产生的数据, 当系统有所变化时, 控制器的鲁棒性会降低, 它的自组织功能也会受到很大的影响. 事实上, 在实际自组

织过程中也没有必要把所有的数据都累积起来,一者,在一段时间控制后,权值基本稳定,过多的学习不但浪费了时间,而且也可能会冲掉已有的权值;二者,由于系统可能是时变的,当前的数据才最能反映当前的系统的性况,太远的历史数据非但不能增加学习的效果,反而会由于过多的历史数据掩盖了系统的变化特性,使得控制器不能根据系统的变化作出相应的调整,我们可以对数据做一些必要的处理。一般来说,我们重视当前的数据,历史数据在起过相应的作用后就要慢慢的滤去。可以采用加遗忘因子的办法来处理该问题,也即 CPN 学习算法中的多模式训练集上的全局代价函数

$$E = \sum_{k=N+1}^{N+m} E_k$$

改为

$$E = \sum_{k=N+1}^{N+m} \rho^{N+m-k} E_k$$

式中 ρ 为遗忘因子, $0 < \rho < 1$, 该式表示对不同时间的输入输出数据对给以不同的加权值, E_k 表示在 k 时刻的给出的局部误差值, 它的遗忘系数为 ρ^{N+m-k} , 由于 ρ 范围为 $(0, 1)$, 所以当 k 逐步增大时 ρ^{N+m-k} 逐步变小, 作用在 E_k 上就表现为当前数据的影响最大, 越老的数据影响越小。但是加了遗忘因子后, 数据对并没有减少, 只是削弱了历史数据的影响, 为了控制数据量, 可以限定记忆数据, 神经网络学习的仅是一段时间内的数据。

虽然, CPN 网络用于自组织模糊控制还有许多不尽如人意的地方, 如 CPN 网络的学习时间问题和网络结构的确定。但相比常规的自组织模糊控制有它独有的特点。对于传统的模糊控制来说, 规则数量的增加会造成控制算法复杂程度的提高, 以及规则合成时间的增加, 这些都是不利于在线控制的。而由于 CPN 网络的网状结构, 规则数的增加并不敏感, 规则数的增加只是变化了一些权值而已, 对于规则合成的时间也不会增长, 同时由于 CPN 网络的权值组合以加乘为主, 较之模糊合成规则更省时间。另外, 模糊化的过程也可以用神经网络来实现, 隶属函数的确定以前多用经验知识, 用神经网络来确定隶属函数并不是件难事, 它只要学习足够多的样本知识。实际上, 动态的改变隶属函数曲线也是自组织控制的一种方法, 隶属曲线的动态变化可以等效为“规则”的改变。这样用网络来实现模糊量与精确量的转化不但化的时间少而且具有更多的客观性。

为了说明 CPN-SFC 的控制效果, 在这里举出例子来进行讨论。

5 实例研究

由于 CPN 网络是有教师学习和无教师学习的结合, 因而对于避免学习过程中的局部极小点和提高学习速度都较之 BP 网络有了提高, 且加强了规则的延拓, 使控制范围增加。下面利用加压网前箱作为例子来研究。

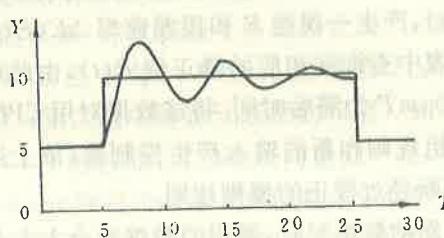


图 3 PID 控制

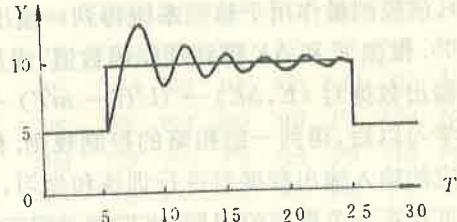


图 4 常规模糊控制(FLC)

在加压网前箱控制系统中^[5], 要求控制液位高度和总压以保持进料混和均匀和喷嘴流速

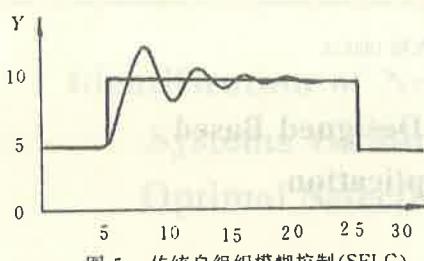


图 5 传统自组织模糊控制(SFLC)

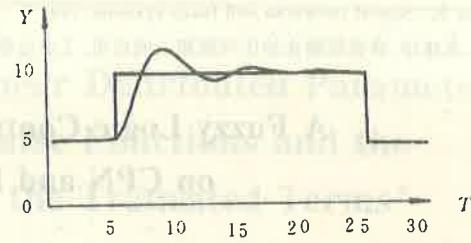


图 6 CPN 自组织模糊控制(CPN-SFC)

稳定。对于本对象给出四种不同控制方案(PID 控制, 常规模糊控制(FLC), 传统自组织模糊控制(SFLC), CPN 自组织模糊控制(CNP-SFC))得到的控制结果, 如图 3~6 所示。从控制过程看, 开始两种自组织控制器的控制效果并不理想, 出现较大的振荡和超调, 相比之下, 常规模糊控制器(FLC)的控制效果似乎好一些。但是随着控制过程的进行, 自校正控制的效果越来越好, 两种自校正控制比较起来, CPN-SFC 收敛更快一些。在一段时间后, CPN-SFC 和传统自组织模糊控制(SFLC)控制质量优于 FLC。这主要是由于在控制初始阶段, 自组织控制的规则还未完全形成, 许多控制规则开始甚至可能是错误的, 因而造成输出振荡和很大的超调。而 FLC 由于已经有了一组比较完全的规则, 因而能够在一定程度上控好对象。当过程进行了一段时间, CPN-SFC 和 SFLC 得到了足够多的学习样本以后, 它的控制规则逐渐完善, 因而控制效果越来越好。由于本对象具有较严重的非线性, 因此 PID 控制效果不好, 而从图中可以看出, CPN-SFC 的控制效果好得多, 而另二种模糊控制器 FLC 和 SFLC 控制质量也不高。

6 结 论

本文以 CPN 网络为基础设计了一种神经模糊控制器, 与传统的模糊控制器相比在模糊推理、模糊量与实际量的转换等方面都有了相应的改进。在此基础上, 给出了神经模糊自组织控制器(CPN-SFC)的设计方法。由于 CPN 网络的并行结构和它的自学习能力, 使得该控制器在处理一些时滞、非线性系统时有较好的的控制质量。与传统的模糊自组织控制器(SFLC)相比, CPN-SFC 不仅在规则的修改上远比 SFLC 简单并且解决了模糊自组织控制中的规则数急剧增多的问题, 同时在对规则合成等的计算时间较 SFLC 大大缩短。

作为一种自组织控制器, CPN-SFC 还存在着一些不够完善的地方。比如在自组织控制中关键的性能指标函数的设计和规则的修改量还没有比较一般的方法, 需要针对具体对象具体考虑, 在一定程度上还需要经验知识。同时 CPN 算法在学习速度和收敛性都有待提高。

对于实时控制来说, 速度确实是个很重要的因素。神经网络以其独有的并行结构使它的运行速度的大步提高有了潜在的基础。对于一些系统, 我们可以在进行离线的学习和训练之后, 给出一个初始的网络权值组合。然后把控制器以硬件形式实现, 由于目前以数字形式实现神经网络的并行计算还有待研究, 一般都以模拟形式实现。这样进行的在线控制由于利用了网络的并行结构, 它的处理速度可以达到很高的地步, 这对于快速反应系统来说, 尤其有用。

参 考 文 献

- 1 Patrick, K. S. . Artificial neural networks. Springer, 1989
- 2 Nielsen, H. . Counterpropagation Network. Proceedings of the IEE First International Conference on Neural Networks, 1987, 2; 19-32
- 3 Kohonen, T. . Automatic formation of topological maps in a self-organizing systems. Proceedings of the 2nd Conference on Image Analysis, 1981, 214-220

- 4 Kosko, B., Neural networks and fuzzy systems. 1992
 5 葛铭,葛建华.容错控制在加压网前箱上的应用.工业过程模型化及控制 1992,5

A Fuzzy Logic Controller Designed Based on CPN and Its Application

GE Ming, LI Ping and SUN Youxian

(Institute of Industrial Process Control, Zhejiang University • Hangzhou, 310027, PRC)

Abstract: This paper presents a control strategy that enhances fuzzy controller with self-learning capability for achieving prescribed control objectives with the use of artificial neural network. The neural network, termed CPN(counter propagation networks), is trained to establish fuzzy associations between the input and output fuzzy subsets. The fuzzy logic controller based on CPN can refine the fuzzy if-then rules if human experts are not all available and it also improves the system property such as the robustness and fault-tolerance. The air cushion headbox system is employed as a test-bed to demonstrate the effectiveness of the proposed control scheme.

Key words: CPN; fuzzy logic controller; neural network; self-learning

本文作者简介

葛 铭 1971 年生. 分别于 1992 年和 1995 年在浙江大学获学士和硕士学位. 目前在浙江大学工业控制研究所攻读博士学位. 主要研究兴趣为模糊控制, 人工智能控制及鲁棒控制.

李 平 1954 年生. 1978 年考入浙江大学化工系, 1988 年获博士学位, 1988 年至 1990 年在浙江大学流体传动与控制博士后流动站工作, 出站后在浙江大学工业控制研究所工作. 主要研究兴趣为工业过程模型化, 鲁棒控制, 模糊控制及人工智能控制.

孙优贤 见本刊 1997 年第 1 期第 41 页.