



# 自学习模糊逻辑推理网络及 模糊控制器的构成<sup>1)</sup>

张新学 王桂增 大町真一郎 阿曾弘具

(清华大学自动化系 北京 100084)

(日本东北大学工学部)

**摘要** 提出了一种自学习模糊逻辑推理网络和自学习模糊控制器的构成方法. 这种方法是把 RCE (Restricted Coulomb Energy) 模型进行扩展, 使其能够进行模糊逻辑推理, 并用于构成基于 RCE 模型的自学习模糊控制器 RLFC (RCE-based Learning Fuzzy Controller). 这种方法有以下特点: a) 学习速度快, 追加学习容易; b) 网络的信息处理工作单元的个数由自学习决定, 通用性好; c) 不存在局部极小点问题. 自学习模糊控制器 RLFC 可以直接把熟练者的操作知识转换成模糊控制规则, 自动构成模糊控制器. 数值仿真实验表明其效果良好.

**关键词** 自学习网络, 模糊控制, RCE 模型.

## FORMATION OF A LEARNING FUZZY LOGIC REASONING NETWORK AND A FUZZY CONTROLLER

ZHANG Xinxue WANG Guizeng

(Department of Automation, Tsinghua University, Beijing 100084)

Omachi Shin'ichiro Aso Hirotomoz

(Faculty of Engineering, Tohoku University, Japan)

**Abstract** This paper presents an RLFC (RCE-based learning fuzzy controller) which is capable of extracting expert knowledge automatically. The RLFC is an extended RCE (Restricted coulomb energy) model, hence it needs few iterations in learning and is easy for additional learning when control objects are changed. Moreover, the RLFC is capable of dealing with fuzzy sets and produces fuzzy control rules in a self-organizing way from operational patterns of experts. The effectiveness of RLFC is shown by numerical simulation results.

**Key words** Learning network, fuzzy control, RCE model.

1) 国家自然科学基金和留学生回国启动基金资助项目.

收稿日期 1998-02-18 收修改稿日期 1999-01-08

## 1 前言

近年来,不需要控制对象的精确数学模型的模糊控制方法已进入实用化阶段<sup>[1,2]</sup>,但是要把熟练者的操作经验转换成 if-then 型控制规则是比较困难的. 所以人们用神经网络的自学习功能,直接把熟练者的操作过程自动地转换成 if-then 型控制规则<sup>[3,4]</sup>. 但是神经网络的学习是用重复迭代方法,要使其收敛需要很长时间,且追加学习困难,缺乏通用性,存在局部极小点问题.

Cooper 氏提出了与神经网络不同的 RCE 模型<sup>[5]</sup>,本文把 RCE 方法扩展到能够进行模糊集合处理的领域,提出自学习模糊控制器 RLFC. RLFC 直接根据熟练者的操作模式,通过学习自动构成模糊控制器. 它具有学习速度快,追加学习容易;网络的工作单元的个数在学习过程中确定,通用性好;不存在局部极小点问题等特征.

## 2 自学习模糊逻辑推理网络及模糊控制器的构成方法

### 2.1 模糊控制

对于以  $n$  个输入  $x_1, x_2, \dots, x_n$  和 1 个输出  $\xi^i$  (控制量) 的模糊控制器,模糊控制规则如下所示:

$$L^i: \text{IF}(x_1, x_2, \dots, x_n) \text{ is } A^i \quad \text{THEN } \xi^i = f(x_1, x_2, \dots, x_n), \quad (1)$$

其中  $x_1, x_2, \dots, x_n$  为输入变量,  $A^i$  为模糊集合,  $\xi^i$  为控制器的输出. IF 的部分叫前件部, THEN 的部分叫后件部. 模糊集合  $A^i$  用于对输入向量  $X = (x_1, x_2, \dots, x_n)$  的隶属度的确定. 规则的前件部对于“ $X$  is  $A^i$ ”的隶属度用  $\omega^i(X)$  表示. 根据  $N$  个模糊规则对于输入向量  $X$  的模糊推理由下式计算出模糊控制器的输出(控制量):

$$\xi = \frac{\sum \omega^i(X) \xi^i}{\sum \omega^i(X)}, \quad i = 1, 2, \dots, N. \quad (2)$$

### 2.2 学习型模糊控制器的构成

RLFC 是经过自组织学习自动构成,如图1所示由6层网络构成. 其工作原理如下:

1) 第1层由  $n$  个输入单元组成,各输入为实数值,  $n$  个输入构成输入向量.




图1 自学习模糊控制网络的结构

2) 第2层的单元  $S_2^k$  由自学习生成,与第1层所有单元  $S_1^i$  联结,与第3层的某个单元  $S_3^i$  联结. 第3层的单元  $S_3^i$  与第2层隶属于分类  $C^i$  的所有单元  $S_2^{ik}$  相联结,其中  $i$  表示分类序号,  $k$  表示  $i$  分类中的单元序号. 在学习过程中,单元  $S_2^{ik}$  根据学习规则生成.  $S_2^{ik}$  中保存有参考向量(中心)  $M_k^i = (m_{k1}^i, \dots, m_{kn}^i)$  和阈值(半径)  $r_k^i$ ,并按照下式计算输入向量  $X$  与参考向量  $M_k^i$  的距离  $d_k^i = \|X - M_k^i\|$ . 第2层的输出为:

$$Z_k^i = \begin{cases} 1, & d_k^i \leq r_k^i, \\ 0, & d_k^i > r_k^i. \end{cases}$$

3)第3层由  $N$  个单元构成,单元  $S_3^i$  的输出为:  $D_i = \begin{cases} 0, & Z_k^i = 1, \{k \in C^i\}, \\ \min_{k \in C^i} d_k^i, & \text{Otherwise.} \end{cases}$

4)第4层有  $N$  个单元,在学习时将  $\xi^i$  保存于  $S_4^i$  中.按下式进行计算,并输出  $\omega^i, \omega^i \xi^i$ .

$$W_j^i = \frac{D_j}{D_i + D_j}, (j \neq i), \quad W_i^i = 1,$$

$$\omega = \prod_{j=1}^N W_j^i. \quad (3)$$

5)第5层2个单元分别计算式(2)的分母和分子  $\omega = \sum \omega^i, \beta = \sum \omega^i \xi^i$ .

6)第6层为输出层,计算并输出  $\xi = \frac{\beta}{\omega}$ .

本文把 RCE 模型扩展到模糊信息处理领域,并构成自学习模糊控制器.以第2层属于分类  $C^i$  的单元  $S_2^{ik}$  中的  $M_k^i$  和  $r_k^i$  所确定的超球覆盖输入空间,输入空间被分割成若干个领域,其中某领域  $G(i)$  对应于模糊规则  $L^i$  的前件部的条件,领域  $G(i)$  上的模糊集合为  $A^i$ .不同分类的超球互不重叠.

当给网络输入一个输入向量  $X$ ,且该输入向量  $X$  被属于分类  $C^i$  第2层的单元所表示的超球所包含时,第3层的单元  $S_3^i$  的输出  $D_i = 0$ .  $S_3^i$  以外的单元  $S_3^j$  的输出  $D_j > 0$ .第4层的单元根据(3)式计算出  $\omega^i = 1, \omega^j = 0, (j \neq i)$ .当输入向量不属于第2层的超球时,第3层的单元输出为正数,第4层的单元  $S_4^i$  输出  $\omega^i$  为正小数.输入向量属于  $G(i)$  或  $G(j)$  的隶属度与其距离成反比.

### 2.3 学习与自组织

RLFC 中的第1层工作单元数与输入向量的维数相等,初始状态时第2层至第4层没有单元,在学习过程中根据学习规则生成或消除单元,自动组成网络.其动作过程如下:

1)当把学习用数据(输入向量  $X$  和属于分类  $C^i$  的输出  $T^i$ )输入网络进行学习时,若第3层与  $T^i$  相对应的单元不存在时,生成第3层单元  $S_3^i$  和第2层单元  $S_2^{ik}$ ,并把参考向量  $M_k^i = X$  登录在  $S_2^{ik}$ ,其阈值(超球半径)设为初始值  $r_k^i = r_d$  并使  $P_k^i = 1$  ( $P$  为范例数).  $S_2^{ik}$  单元与第1层所有的单元相联结,与第3层的单元  $S_3^i$  相联结(分类  $C^i = \{k\}$ ).同时生成第4层单元  $S_4^i$ ,并保存与该参考向量  $M_k^i$  相对应的控制量  $\xi^i$ .

2)当第3层已有单元  $S_3^i$  时,第2层单元  $S_2^{ik}$  计算输入向量  $X$  与参考向量  $M_k^i$  的距离  $d_k^i$ ,若  $d_k^i$  小于其阈值  $r_k^i$ ,则  $Z_k^i = 1$  (称为兴奋),否则  $Z_k^i = 0$ .这里又分两种情况

a 第二层属于分类  $C^i$  的单元的动作如下:

属于分类  $C^i$  的第2层的单元  $S_2^{ik}$  对于输入向量  $X$  都不兴奋时 ( $Z_k^i = 0$ ),生成新的单元  $S_2^{ik'}$ ,  $M_{k'}^i = X, r_{k'}^i = r_d, P_{k'}^i = 1$  ( $C^i = C^i \cup \{k'\}$ );属于分类  $C^i$  的第2层的单元  $S_2^{ik}$  对于输入向量  $X$  兴奋时,仅使  $P_k^i$  增1.

b 第2层属于  $C^i$  以外的分类  $C^j$  的单元  $S_2^{ik}$  对于输入向量  $X$  兴奋时,其动作如下:若  $P_k^i \geq D$ ,半径  $r_k^i$  不变,仅把  $P_k^i$  减去  $D$ ;当  $D > P_k^i \geq 0$  时,若  $r_k^i < L$  ( $L$  为界限常数),则消除  $S_2^{ik}$  ( $C^j = C^j - \{k\}$ ).若  $r_k^i = L$ ,则缩小  $r_k^i$  使该单元不兴奋,并使  $P_k^i = 0$ .

参数  $D, L, r_d$  的最优化问题请参考文献[5].在本文中  $D = 7, L = 0.2r_d$ .超球半径  $r_d$  (阈值)的选择根据控制对象而定,选值过小,则生成的单元数增多,反之则修正阈值的频

度增高.

### 3 仿真实验

本文以非线性控制对象为例进行仿真实验

$$\ddot{y} = -10\dot{y} - 16y + \{-5\sin(0.5\pi u) + 16\}u,$$

模糊控制器输入为控制目标值  $y_d$  与控制对象的输出值  $y$  的误差  $e$  及其变化量  $\Delta e$ . 本文将输入空间表示成极坐标空间

$$R = \sqrt{e^2 + \Delta e^2}, \quad \theta = \cos^{-1} \frac{e}{R}.$$

本方法以输入向量  $(R, \theta)$  和控制器的输出  $\Delta u$  作为学习用数据. 模糊变量  $R, \theta$  构成一个极坐标输入空间. 仿真中, 将  $R$  分为5个模糊集合; 将  $\theta$  沿圆周八等分成8个模糊集合. 各模糊变量的模糊集合的隶属函数均设定为三角型. 与各领域  $i$  相对应的模糊控制器输出为  $\Delta u_i$ , 模糊控制规则为:  $L^i$ : IF  $(R, \theta)$  is  $A^i$  THEN  $\xi^i = \Delta u_i$ .

学习用数据由  $\langle (R, \theta), \Delta u_i, i \rangle$  组成. 其中  $(R, \theta)$  为输入向量,  $\Delta u_i$  为模糊控制器的输出,  $i$  为该输入数据所属的领域. 在此仿真实验中采用了360组学习用数据.

仿真结果分别如图2所示. 图2(a)表示用5种系统的控制目标值  $y_d(1, 0.8, 0.6, 0.4, 0.2)$  进行学习后的控制效果, 图2(b)表示以  $y_d$  为目标值进行学习后, 对未学习的控制目标值  $(0.8, 0.6, 0.4, 0.2)$  的控制效果. 由此得知, 对未学习的目标值也有良好的控制效果.




图2 仿真结果

### 4 结束语

本文提出了高速的模糊集合处理学习方法, 并用于自学习模糊控制器. 对于同样问题用人工神经网络学习方法<sup>[2,3]</sup>时, 学习的迭代次数为五千次以上, 而用 RLFC 的学习方法仅需2次迭代. 人工神经网络的学习是改变加权系数的过程, 追加学习时, 必须对全部数据重新学习, 而 RFLN 仅对追加学习数据进行补充学习就可以了, 所以追加学习容易. 这种方法不是采用迭代求误差极小的方法, 所以不存在局部极小点问题. RLFC 可以从熟练者操作现场数据直接经过学习获得模糊控制规则, 并自动构成模糊控制器. 数值仿真实验表明这种方法效果良好.

**致谢** 向对本研究提出过宝贵意见的日本北陆先端科学技术大学院大学堀口进教授表示

感谢.

## 参 考 文 献

- 1 菅野道夫. ファジイ制御, 日本日刊新聞社, 1988
- 2 古橋武. ニューラルネットワークによるファジイ制御. 日本システム/制御/情報. 1994, **38**(11): 607—612
- 3 Kong S G, Kosko B. Adaptive fuzzy systems for backing up a truck and trailer. *IEEE Trans. Networks*, 1992, **5**(3): 211—223
- 4 Reilly D, Cooper L, Elbaum C. A neural model for category learning. *Biol Cybern.* 1982, **45**(1): 35—41
- 5 岡本義則. 環境の激しい變化に適應する神經回路網モデル. 日本電子情報通信學會論文誌, J73-D- I : 1990, 1186—1191

**张新学** 1954年生, 男. 博士后、副教授. 研究领域为高等控制系统, 模糊学习网络等.

**王桂增** 1942年生, 男. 教授、博士生导师. 研究领域为高等过程控制和动态系统故障诊断等.

## 书 讯

由南京航空航天大学自动控制系教授、博士生导师姜长生等同志编著的《系统理论与鲁棒控制》一书已于1998年8月由航空工业出版社出版.

该书比较系统地总结了自60年代至90年代发展起来的近、现代控制理论的主要内容. 分两大部分: 第一部分为系统理论的基础部分, 包括时域和频域中的控制理论、方法和设计, 特别花较多的篇幅论述了用输出反馈实现特征配置、同时配置极点的解耦控制以及鲁棒跟踪等; 第二部分论述了鲁棒控制理论和方法, 其中有: 时域中的鲁棒控制(摄动系统的鲁棒稳定性, 区间系统的鲁棒稳定, 鲁棒极点配置, 带观测器系统的鲁棒性), 频域中的鲁棒控制(区间多项式的稳定性、系统的奇异值分析设计), 时域中的  $H_\infty$  控制(系统的  $H_\infty$  范数, 状态反馈和输出反馈的  $H_\infty$  控制,  $H_\infty$  滤波等), 频域中的  $H_\infty$  控制(鲁棒稳定问题的定理, Youla 参数化问题, 最优 Hankel 范数逼近, 模型匹配问题的解法), 鲁棒控制的间隙拓扑方法. 最后较全面系统地介绍了与鲁棒控制密切相关的矩阵方程和线性矩阵不等式的求解. 全书两部分内容有机结合, 密切联系, 前后呼应, 构成一个系统的整体. 读者通过本书的阅读可以从理论到方法掌握系统理论和鲁棒控制的概貌和主要结果, 并由此进入鲁棒控制领域的研究. 全书内容丰富, 论述由浅入深, 并用丰富的例题解释理论的应用, 达到深入浅出的效果. 同时书中还配有大量习题, 语言通俗易懂, 读者只要具备矩阵理论和经典控制的知识, 就可阅读全书. 另外, 全书所有标题均配有英文翻译便于读者熟悉专业词汇, 有利于阅读英文书刊.

本书适合控制类专业研究生作教材, 也可供相关专业高年级大学生、研究生参考. 也适合高校青年教师和广大科技工作者参考.

全书共103万字, 648页, 分十二章, 定价每册65元, 邮购者请汇款至南京航空航天大学自控系资料室张恂收, 邮编210016, 支票、信汇, 请汇至“南京航空航天大学(三系)066390149000354, 交行御分”, 并通知张恂即可. 邮购一律免收邮费.