

基于 RBFN 及模糊决策的多模型直接自适应控制

陈小红

钱积新

(同济大学 CIMS 研究中心·上海, 200092) (浙江大学工业控制技术研究所·杭州, 310027)

摘要: 继基于 RBF 网络的直接自适应控制研究与应用^[3-5]后, 针对强非线性及工作点变化的实际问题提出径向基函数网络(RBFN)多逆模型自适应控制策略. 对单输出对象给出一种简捷有效的控制策略, 随之开发出一个一般的基于模糊规则的多逆模型信息综合控制策略. 该策略既具多逆模型控制的高精度, 又具单一模型的整体性, 从根本上消除多个逆模型控制方法的切换振荡问题. 在 CSTR 仿真中对两种方法做出对比研究, 进一步证实各自优点.

关键词: RBFN; 模糊决策; 多模型; 自适应

Multi-Model Direct Adaptive Control Based on RBFN and Fuzzy Decision

Chen Xiaohong

(CIMS Research Center, Tongji University·Shanghai, 200092, P. R. China)

Qian Jixin

(Institute of Industrial Process Control, Zhejiang University·Hangzhou, 310027, P. R. China)

Abstract: Aiming at the practical plants with strong nonlinear characteristics or changing operating points, this paper proposes two multi-model adaptive control strategies based on RBF networks, continuing the work in papers^[3-5]. A simple multi-model control strategy for SISO and another control strategy based on fuzzy logic are developed. The latter has both the advantages of high quality of multi-model method and the smoothness of single model method. It eliminates the disadvantages that model switch brings about. Simulation results to CSTR demonstrate the above properties.

Key words: RBFN; fuzzy decision; multi-model; adaptive

1 引言(Introduction)

一个高度非线性的工业控制对象几乎在整个空间任一点上都具有不同性质. 例如, 飞行器动态特性随飞行高度和速度变化, 实际对象也会因某些传感器失效有几种工作模式等. 针对强非线性及工作点变化的实际问题, Saeks^[1]和 Vidyasagar^[2]等人于 1982 年提出同时镇定控制器的设计思想, 它来源于实际工程中多模型特征系统的稳定需要. 但目前对同时镇定问题的研究尚局限于非线性系统在不同操作点附近的线性化模型, 而且简单的问题往往不能得到简单的答案. 当系统模型数目大于 2 时, 同时镇定控制器的设计变得非常困难.

近年来神经网络作为强有力的非线性建模工具而大量应用于工业对象, 但对上述复杂对象仍存在困难. 首先, 由于一般总是在非线性控制对象工作点附近将其特性充分激励出, 再用神经网络模型描述, 这使得当实际工作点大幅变化、跳出训练域时, 基于该模型的控制器将不可靠; 另一方面, 在较大范围内训练网络会使网络变得非常庞大, 不仅增加运算量,

还可能出现数值病态问题; 此外, 对象强非线性区域处的特性很难精确描述, 造成在该区域内逼近效果不佳. 事实上, 即便得到精确模型, 这些区域的控制也往往非常复杂, 同样很难得到良好的控制效果.

本文在基于 RBFN 的直接自适应控制的研究和应用的基础上^[3-5], 提出径向基函数网络多逆模型直接自适应控制策略. 采用多个 RBF 神经网络逆模型构成不同工作区域上多个子控制器. 其中每个子模型都具非线性, 削减了线性化建模引起的模型误差, 且子模型数目没有限制. 同时, RBF 神经网络只涉及简单代数运算, 省却了一般非线性控制器算法中复杂的非线性积分或多次迭代等运算^[6].

由于神经网络多模型方法同样存在切换抖动问题, 问题产生的本质在于模型切换. 本文针对单输出对象提出简单的抖动消除方案, 又进一步引入模糊决策方法, 将多模型方法中各子模型联结成一个完整的模糊神经网络模型, 从根本上消除模型切换振荡. 对连续搅拌箱反应器(CSTR)的仿真结果证明加入模糊决策的控制策略既具有多模型的高精度, 又

消除了切换振荡问题;针对单输出对象的控制方法具有一定去抖动功能,算法简单,计算量小.

2 单输出对象多模型自适应控制策略 (Multi-model adaptive control strategy for single output plant)




图 1 基于RBF网络的非线性多模型自适应控制

Fig. 1 Nonlinear multi-model adaptive control based on RBFN

图 1 示出对象描述为两个子模型时的多模型控制系统结构. NN1 和 NN2 分别为对象在两个工作区间上的逆动态模型,在这里用作控制器和反馈环节^[3].

多模型控制策略设计如下:

- 离线辨识.

采用 RBFN 构造对象工作空间不同区段的逆动态模型作为控制器,即在不同工作区段上取代表性工作点激励对象,产生多组训练数据,离线训练各子逆模型(算法见[3]);

- 在线控制. 在线实施控制的每一步.

1) 用实际输入输出数据对上一步所采用的子逆模型控制器进行自适应权值修正. 这里采用加入 PID 修正的递推最小二乘算法 (PID-RLS)^[4] 实现这一任务;

2) 进行模型切换判断,选择对应于当前对象状态的逆模型作为该时刻的控制器,得到当前的控制输入. 转 1).

对于单输出系统,根据期望输出判断下一时刻系统处在哪个控制器控制域内,以此切换模型. 但由于神经网络模型的输出决定于系统所有当前状态,当状态值处在不同训练域时,这种判断规则使系统出现切换振荡与输出不确定. 为避免这些问题,本文提出以下方案:

1° 扩大训练域冗余,使相邻训练域相互重叠. 显然重叠域越大则模型越难精确;反之则过渡过程越易出现振荡或不稳定.

2° 在总的工作范围内离线训练一个网络模型作过渡用;在线控制过程中,每当判断控制器需要切换,先利用该模型进行控制以保证控制平稳过渡. 当系统输出完全落入某个控制器工作范围后,再切换

到相应控制器以保证控制精度.

3 多模型模糊自适应控制策略 (Multi-model fuzzy adaptive control strategy)

为简单起见,图 2 示出将对象模型描述为两个子模型的多模型模糊自适应控制策略.

对于多输出系统,多模型控制的关键问题在于模型区域划分和切换判断. 此时不能仅根据输出所在一维区域划分和判断. 由于 RBFN 是局域性网络,因此可以通过聚类方法划分样本空间进行子模型训练,并选择包容当前系统状态的子模型作为控制器. 但对跨模型区间的系统状态变化,上述方法仍存在切换引起的振荡、发散等一系列问题. 本文将所有子模型联接成一个完整的模糊神经网络模型,对任意模型输入,各个子模型都对输出以某种加权的方式有所贡献,权值与该输入同每个模型工作域的逼近程度或者说依赖程度相关,这就避免每个子模型单独隔离地使用,不仅具有多模型的高精度,而且具有单一模型的整体性.

以模糊分类方法实现上述思想. 对于一个输入样本,首先求其对各子模型工作空间的隶属度 μ ; 再令该样本通过每个子模型得到各自输出;后使各子模型输出与其隶属度之乘积相加得到网络输出,即对象控制输入. 在应用实际输入输出数据对模型进行在线修正时,采取类似的方法分配修正误差: 首先求出对象实际控制输入与各子模型反馈信号之差,将此误差量按照系统输入对各逆模型工作空间的隶属度分配到每个模型,并采用在线修正算法使各子模型进行在线学习.

3.1 几个关键问题 (Key problems)

- 隶属度求取.

设对象的逆由 M 个 RBFN 子模型实现. 网络输入对每个子模型的隶属度由它对该子模型中各 RBF 中心的隶属度决定. 设每个子模型的中心集合为 $M_i, i = 1, \dots, M$, 所有模型中心数目之和为 N , 输入 X 对每个中心 C_i 的隶属度记为 v_i , 令性能指标为

$$J = \sum_{i=1}^N v_i \|X - C_i\|^2. \quad (1)$$

满足

$$\sum_{i=1}^N v_i = 1, \quad v_i \in [0, 1].$$

对(1)式求最小,并令 $d_i = \|X - C_i\|^2$ 得:

$$v_i(X) = \begin{cases} \frac{1}{\sum_{j=1}^N \frac{d_i}{d_j}}, & \text{for } d_i \neq 0 \text{ and } X \notin \{C_1, \dots, C_N\}, \\ 0, & \text{for } d_i \neq 0 \text{ and } X \in \{C_1, \dots, C_N\}, \\ 1, & \text{for } d_i = 0 \text{ and } X = C_i, \end{cases} \quad (2)$$

这样网络输入 X 对第 l 个模型的隶属度为:

$$\mu_l = \sum_{i, C_i \in M_l} v_i. \quad (3)$$

• 控制输入求取.

令当前时刻输入通过各子模型得各自输出,再以该输入对每个子模型的隶属度作为权值,对各子模型的输出加权求和得到整个网络输出,即控制输入 u :

$$u = \sum_{l=1}^M \mu_l u_l. \quad (4)$$

u_l 为第 l 个子模型输出.

• 离线子模型整和.

离线训练中,用聚类后的各样本子集训练多个子模型,然后将各子模型联结成整体模型(图3),该网络输出为各子模型输出加权和,权 w_i 对应于样本输入对 RBFN i 控制区域的隶属度.进一步用所有样本对该整体模型训练.这时子模型 RBFN i 对应每一个样本的训练误差为:

$$e_i = (u - \tilde{u}) w_i. \quad (5)$$

u 为样本输出, \tilde{u} 为网络输出. RBFN i 以此修正其参数.

• 在线误差修正.

在线控制过程中(图2),每个子模型的修正同样通过其隶属度加权系数.对应子模型 NN i ,

$$e_i = [u - f_{NNi}(y, \cdot)] \times \mu_i. \quad (6)$$

其中, $f_{NNi}(\cdot)$ 为神经网络 NN i 的传递函数. u 为实际输入, μ_i 为输入对子模型 NN i 的隶属度.

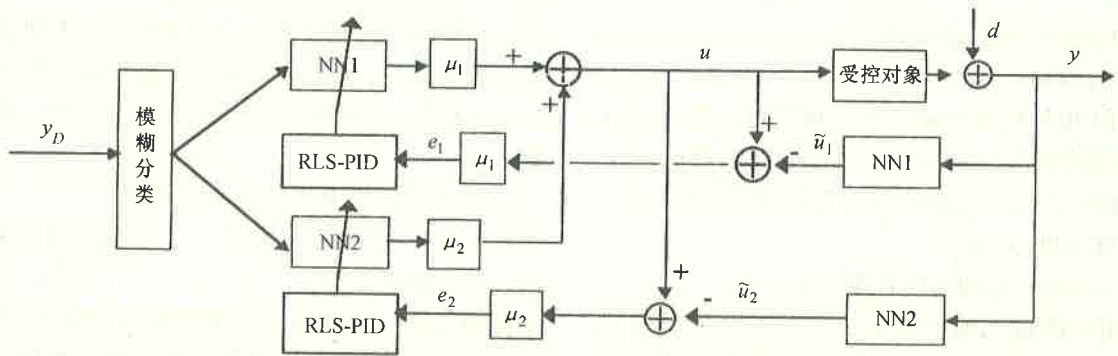


图2 加入模糊方法的非线性多模型自适应控制

Fig. 2 Nonlinear multi-model adaptive control with fuzzy decision

3.2 控制策略设计(Control strategy realization)

控制策略设计如下:

• 离线模型求取.

1) 根据具体问题确定聚类数目.采用 K-means 聚类算法对训练样本进行分类.

2) 用聚类后的样本子集分别训练神经网络,得到各个子模型.

3) 构造整体模型(图3),并用所有样本数据进一步训练该模型.

• 在线自适应控制策略.

1) 利用式(2),(3)求网络输入对每个子模型的隶属度,并计算对应于该输入的各子模型输出.

2) 利用(4)式求系统控制输入.

3) 由(6)式求出每个子模型误差,采用 PID-RLS 算法^[5]对各个子逆模型进行修正.

4) 转 1) .




图3 整体模型

Fig. 3 The whole model

4 仿真实例(Simulation)

考虑如图4所示 pH CSTR 系统,控制变量是连续搅拌箱反应器 pH 值动态响应.搅拌箱有两个输入,即氢氧化钠溶液和醋乙酸溶液. J. Saint-Domat

等^[7]推导出反应箱中 pH 值的动态模型.




图 4 pH CSTR
Fig. 4 pH CSTR

具体描述如下:

物料平衡算式:

$$F_1 C_1 - (F_1 + F_2) \xi = V \frac{d\xi}{dt}, \quad (7)$$

钠离子平衡算式:

$$F_2 C_2 - (F_1 + F_2) \xi = V \frac{d\xi}{dt}, \quad (8)$$

HAC 离解平衡算式:

$$\frac{[AC^-][H^+]}{[HAC]} = K_a, \quad (9)$$

水离解平衡算式:

$$[H^+][OH^-] = K_w, \quad (10)$$

电平衡方程式:

$$\xi + [H^+] = [OH^-] + [AC^-], \quad (11)$$

其中

$$\xi = [HAC] + [AC^-]. \quad (12)$$

所考虑的 CSTR 参数同文^[7]. 为充分激励对象的特性, 用伪随机信号 (PRBS) 作为控制变量 F_2 输入系统, 得到训练数据. F_2 的值选在 460 到 560 (1/min) 之间随机波动, 得到 pH 值在 5.8 到 11.8 之间的输出. pH CSTR 在 pH = 7 附近具有很强的非线性特性, 稳态 pH 对基本流量的增益变化因子为 2.8, 用一个模型来完全描述 CSTR 系统的非线性非常困难. J. Saint-Domat 在用 BP 网络对其构造预测控制器时遇到了同样的问题. 由于模型不精确, 使得控制过程中动态性能较差. 可见, 模型在对象非线性很强区域内的精确化是一个很困难又很关键的问题.

4.1 单输出对象多模型控制策略的控制结果 (Control results by control strategy for single output plants)

为精确描述 pH = 7 附近的动态特性, 将工作空间在输出域分为:

- a) pH = 5.8 ~ 6.4; 对应于 NN1.
- b) pH = 6.2 ~ 10; 对应于 NN2.

c) pH = 9 ~ 11.8; 对应于 NN3.

这种划分将非线性最强的部分, 即 pH = 7.0 附近的特性独立出来用 NN2 描述. 且训练域相互重叠. 据此训练 3 个子模型, 再按图 1 构造控制系统.

为明晰地研究加入总体模型和模型重叠的作用, 令系统跟踪曲线:

$$y(i+1) = 8.6 + 0.9(\sin(2\pi i/100) + 2\sin(2\pi i/250)). \quad (13)$$

其中 $\tilde{y}(i+1)$ 为 $(i+1)$ 时刻期望的 pH 值. 图 5 示出基于训练域重叠很小的多模型控制器控制结果. 此时系统振荡很大, 无法跟踪要求的响应曲线; 图 6 示出训练域适当重叠 (采用上述划分数据) 的控制结果, 控制过程中不加入总体模型. 图 7 示出加入总体模型后的控制效果. 可见, 神经网络模型相互重叠以及加入总体模型协调之后, 系统对模型切换并不敏感, 而更多地受子模型精度影响.




图 5 非重叠模型的控制
Fig. 5 Control with non-overlapped model




图 6 重叠但未加入总体模型
Fig. 6 Control with overlapped model

4.2 多模型模糊自适应控制策略控制结果 (Control results by multi-model fuzzy adaptive control)

为与 4.1 节的模型切换方案进行比较, 仍采用 CSTR 系统作为控制对象.

首先以样本输出为基准, 取聚类数为 3, 采用 K-means 聚类算法对样本分类, 分类结果表明 pH = 7 附近强非线性部分样本成为单独一类. 然后用所得样本子集分别训练 3 个 RBFN 子逆模型, 然后如图 3




图7 重叠并加入总体模型

Fig. 7 Control with overlapped model and the whole model

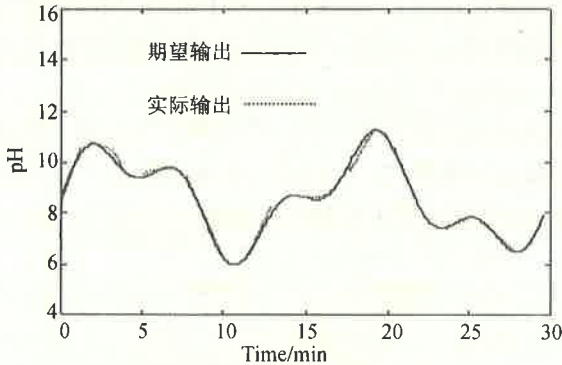


图8 模糊自适应控制

Fig. 8 Fuzzy adaptive control

构造并训练总体模型,结束离线建模过程.接下来如图2构造控制系统,并采用3.2节在线自适应控制策略仿真实时控制.

图8示出系统跟踪平滑曲线结果.可见,采用模糊自适应控制策略后,整个控制效果大大改善,系统输出不受模型切换影响,且控制精度进一步提高.

5 结论(Conclusion)

理论上神经网络可以实现对任意给定学习样本的拟合,而且可达任意精度.但是实际工业对象常常具有严重的非线性,利用一个神经网络达到很好的拟合非常困难.即使能够实现也使网络庞大,学习时间变长,运算复杂性增高,而性能反而变差.本文提出基于径向基函数网络和模糊方法的多模型自适应控

制策略.为避免切换抖动问题,对于单输出对象给出简单易行的模型切换方案;基于模糊规则得到的一般性自适应控制方案则不仅具有多逆模型控制的高精度,而且兼有单一模型的整体性,从根本上解决切换振荡问题.文中的仿真结果进一步证明上述优点.

参考文献(References)

- 1 Saeks R and Marraay J. Fractional representation algebraic geometry and the simultaneous stabilization problem. *IEEE Trans. Automat. Contr.*, 1982, 27(10): 895 - 903
- 2 Vidysagar M and Viswanadham N. Algebraic design techniques for reliable stabilization. *IEEE Trans. Automat. Contr.*, 1982, 27(10): 1085 - 1095
- 3 Chen Xiaohong, Gao Feng and Qian Jixin. Adaptive control based on RBF networks. 35th IEEE Conf. Decision and Control, Japan, 1996, 3810 - 3815
- 4 陈小红, 高峰, 钱积新. 基于径向基函数网络的自适应控制和一种新的权值在线调节算法. *控制理论与应用*, 1996, 13(增刊1): 42 - 44
- 5 陈小红, 高峰, 钱积新, 孙优贤. 基于RBFN的精髓塔自适应控制. *控制理论与应用*, 1998, 15(2): 226 - 231
- 6 Hidalgo P M and Brosilow C B. Nonlinear model predictive control of styrene polymerization at unstable operating points. *Chem. Eng.*, 1990, 4(5): 481 - 494
- 7 Sain-Donat J, Bhat N and McAvoy T J. Neural net based model predictive control. *Int. J. Control*, 1991, 54(6): 1453 - 1468

本文作者简介

陈小红 1969年生. 1990年毕业于西安交通大学机械系, 获工学学士学位, 1993年于浙江大学流体控制技术国家重点实验室获工学硕士学位, 1997年于浙江大学工业控制技术国家重点实验室获工学博士学位. 现在同济大学 CIMS 研究中心做博士后研究. 主要研究方向为神经网络, 工业过程控制, 模糊决策, CIMS.

钱积新 1939年生. 1962年毕业于清华大学电机系, 现任浙江大学工业自动化国家工业研究中心常务副主任, 中国自动化学会应用委员会常务委员. 长期以来主要从事复杂工业过程的建模, 控制与优化的研究工作.