

文章编号: 1001-0920(2002)01-0092-04

CMAC 网络建模在非线性预测控制中的应用

何剑春, 王慧燕

(浙江大学 电气工程学院, 浙江 杭州, 310027)

摘要: CMAC 是一种具有线性结构、算法简单的局部化设计网络。将 CMAC 网络应用到具体非线性系统的预测控制研究中。对一类 CSTR 系统的仿真结果表明, 该预测控制策略响应快且容易实现, 具有较强的鲁棒性, 对于改善非线性预测控制性能不失为一种有益的尝试。

关键词: CMAC 网络; 非线性预测控制; CSTR 系统; hash 编码

中图分类号: O 231

文献标识码: A

Application of CMAC neural network to nonlinear predictive control

HE Jian-chun, WANG Hui-yan

(College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: The local structure of CMAC results in faster learning of nonlinear functions. A CMAC-based predictive control method is put forward to control nonlinear systems. Simulation results of a CSTR system predictive controller show that the method has a quick response speed and good robustness, so it is helpful to improve the capabilities of nonlinear predictive controller.

Key words: CMAC neural network; nonlinear predictive control; CSTR system; hash coding

1 引言

预测控制是一类基于模型的闭环优化控制算法, 已成为过程控制的主要途径之一。预测控制器的设计在很大程度上依赖于描述过程动态特性的预测模型。对于一般意义的非线性系统, 采用近似的线性模型由于偏差大而难以达到优化控制的目标, 而直接采用非线性模型进行优化又存在着本质上的困难。

20 世纪 80 年代中期出现的神经网络, 在非线性领域显示出强大的实力, 已广泛用于动态非线性

过程的建模。但 BP 网络由于其全局化设计特点而导致学习缓慢, 且存在局部极值问题, 一般只适合于对固定样本集的学习; 局部化设计的网络则由于其输出在任何时刻只与部分权值(即某子网络)相关, 有较快的学习速度, 较适合于实时控制。

CMAC 是一种典型的局部逼近网络, 具有线性结构, 算法简单, 有一定泛化能力, 已成功地应用于机器人控制、模糊控制、非线性时间序列分析等领域。本文在充分利用系统辨识模型的基础上, 将 CMAC 网络作为预测模型用于 CSTR 系统的控制, 实现了一类非线性系统预测控制。

收稿日期: 2000-09-18; 修回日期: 2001-04-23

作者简介: 何剑春(1973—), 男, 浙江诸暨人, 博士生, 从事非线性预测控制、IC-CAD 研究; 王慧燕(1975—), 女, 山东招远人, 博士生, 从事智能控制、图像处理研究。

2 CSTR 系统

CSTR系统是聚合反应工业中广泛使用的重要系统,具有很强的非线性。CSTR 系统的系统结构如图 1 所示,其动态过程可用方程描述为

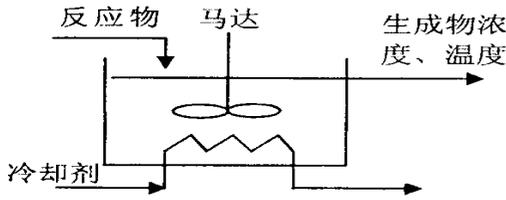


图 1 CSTR 系统结构

$$V \frac{dC_A}{dt} = F(C_{Af} - C_A) - V k_0 \exp\left[-\frac{E}{R_g T_r}\right] C_A \quad (1)$$

$$V \rho C_p \frac{dT_r}{dt} = F \rho C_p (T_f - T_r) - V(-\Delta H) k_0 \times \exp\left[-\frac{E}{R_g T_r}\right] C_A - UA_h (T_r - T_c) \quad (2)$$

式中, C_A 和 T_r 分别为反应物的浓度和温度, T_c 是冷却剂温度。引入如下参数

$$\phi = \frac{E}{R_g T_{f0}}, \quad B_h = \frac{(-\Delta H) C_{Af0}}{\rho C_p T_{f0}}$$

$$D_\alpha = \frac{k_0 e^{-\phi}}{F_0}, \quad \beta = \frac{UA_h}{F_0 \rho C_p}$$

式中, F_0, C_{Af0} 和 T_{f0} 分别为进料流率、进料组分和温度的某一确定参考值。相关的一些无因式化变量定义如下

$$t = \frac{t F_0}{V}, \quad x_1 = \frac{C_{Af0} - C_A}{C_{Af0}}$$

$$x_2 = \frac{T_r - T_{f0}}{T_{f0}}, \quad u = \frac{T_c - T_{f0}}{T_{f0}} \phi$$

式中 T_c 为温度的某一确定参考值。于是, CSTR 动态方程可无因式化为

$$\dot{x}_1 = x_1 + D_\alpha (1 - x_1) \exp\left[\frac{x_2}{1 + x_2/2} \phi\right] \quad (3)$$

$$\dot{x}_2 = x_2 + B_h D_\alpha (1 - x_1) \times \exp\left[\frac{x_2}{1 + x_2/2} \phi\right] + \beta (u - x_2) \quad (4)$$

式中, x_1 和 x_2 分别为无因式化后的反应物浓度和温度, u 为无因式化后的冷却剂温度。

3 基于 CMAC 的预测控制策略

3.1 CMAC 网络原理

CMAC 网络是一种典型的局部逼近网络, 它由一个固定的非线性输入层和一个可调的线性输出层组成, 通过多种映射实现联想记忆, 其一般结构如图 2 所示。CMAC 能实现无教师学习, 并且学习速度快, 可以处理不确定性知识, 因而在智能控制中占有重要的地位。

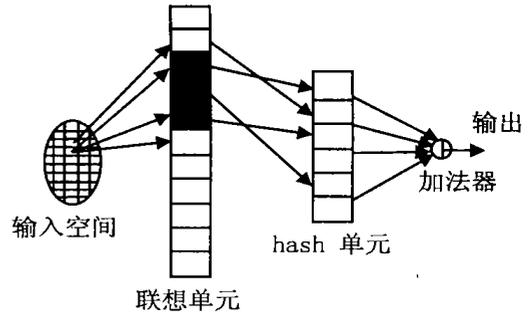


图 2 CMAC 的一般结构

设 $X \subset R^d$ 为 CMAC 输入空间, X_d 为对应的离散输入空间。CMAC 的实现过程可简述为: 由 X_d 中的每一输入点 x_i 激活存储于记忆空间 A 中一组 A^* 个联想强度(即连接权值), 它们的代数之和即为对应的输出。

在大输入空间情况下, 联想单元数是巨大的。为节省存储空间, Albus^[1] 提出了 hash 编码方法: 将 A 映射到一个较小的空间 A_p , 即联想强度存于一组数量大大少于联想单元数的 hash 单元, 联想单元中只存 hash 单元的散列地址编码。

CMAC 的训练是一个不断修正误差的迭代过程。设 V_i 为对应于某个输入状态 x_i 的观测值, $f(x_i)$ 是相应的 CMAC 响应值, 则 x_i 对应的 A^* 个记忆单元的内容可按式

$$\Delta W = \beta (V_i - f(x_i)) / A^* \quad (5)$$

进行修正。其中, ΔW 是相应的修正量, β 为训练因子。由于实际使用的记忆空间 A_p 远远小于输入空间 X_d , 因此碰撞是不可避免的。当然, 要求 CMAC 每个响应值都相当精确是不现实的, 但只要信号变化足够平滑, CMAC 的训练就一定收敛。

3.2 基于 CMAC 的预测控制策略

3.2.1 建模及反馈校正

为了利用 CMAC 网络学习 CSTR 系统, 需要将 CSTR 的输出反馈到 CMAC 的输入中。非线性 ARMA 模型的一般表达式为

$$y(t) = f(y(t-1), \dots, y(t-n), u(t-1), \dots, u(t-m)) + d(t) \quad (6)$$

其中, u 和 y 分别表示控制输入和过程输出, d 为过程扰动, f 表示非线性函数, m 和 n 分别为过程输入

和输出的阶次。将 CMAC 网络作为预测模型, $t + N_1$ 时刻的输出预测值 $\hat{y}(t + N_1)$ 可递推确定为

$$y(t + i) = f(y(t + i - 1), \dots, \hat{y}(t + i - n), u(t + i - 1), \dots, u(t + i - m)) + \hat{d}(t + i) \quad (7)$$

$$\hat{d}(t + i) = \hat{d}(t) = y(t) - f(y(t - 1), \dots, y(t - n), u(t - 1), \dots, u(t - m)) \quad (8)$$

$$u(t + j) = u_e \quad (9)$$

其中, $i = 1, 2, \dots, N_1, j = 0, 1, \dots, N_1 - 1, \hat{y}$ 表示过程的输出预测值, y 表示当前及过去的过程输出, $u(t + j)$ 为预测控制序列, \hat{d} 为扰动预测值, N_1 为预测时域, u_e 为常数。

3.2.2 系统维数的确定

系统维数是系统的结构表征。一般常用经验法确定: 取不同的参数建立多个模型, 根据精度及复杂度决定合适的系统维数。仿真中对 CSTR 系统采用上述方法进行建模。权衡精度和学习速度, 发现当 $n = m = 3$ 时比较合适。

3.2.3 参考轨迹

参考轨迹取以下常用形式

$$y_d(k + 1) = \alpha y_d(k) + (1 - \alpha) y_r \quad (10)$$

其中柔化因子

$$\alpha = \exp(-T_s/\tau), \quad 0 < \alpha < 1$$

τ 为参考轨迹常数, y_r 为设定轨迹。

3.2.4 控制率推导

取如下性能指标

$$J = \sum_{i=d}^{N_1} [y_r(k + i) - \hat{y}(k + i)]^2 \times \sum_{j=1}^{N_u} \lambda [\Delta u(k + j - 1)]^2 \quad (11)$$

其中, $y_r(k)$ 为设定值, N_u 为控制时域。定义控制增量 $\Delta u = [\Delta u(k), \dots, \Delta u(k + N_u - 1)]^T$, 在每一采样时刻, 利用梯度下降法可得

$$\Delta u = -\mu \delta J_u \quad (12)$$

式中 μ 为优化步长, 并且

$$\delta J_u = -\delta y_u e + \lambda \Delta u$$

δy_u 为灵敏度导数(详见文献[3]), λ 和 e 分别为

$$\lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{N_u}) \quad (13)$$

$$e = [y_r(k + d) - \hat{y}(k + d), \dots, y_r(k + N_1) - \hat{y}(k + N_1)] \quad (14)$$

由式(12), (14)得^[3]

$$\Delta u = (I + \mu \lambda)^{-1} \mu \delta y_u e \quad (15)$$

3.2.5 算法步骤

根据以上推导, 基于 CMAC 网络的预测控制算法可归纳为:

- 1) 首先给定预测时域 N_1 , 控制时域 N_u , 优化步长 μ 等参数, 利用样本数据对网络进行离线训练;
- 2) 实时检测系统输出 $y(k)$, 利用系统输入输出的历史信息及 CMAC 的递推预测, 形成 CMAC 的最新样本;
- 3) 由 CMAC 求得系统的预测输出 $\hat{y}(k + i), i = 1, 2, \dots, N_1$;
- 4) 比较预测输出与参考轨迹, 得到误差向量 e , 同时计算灵敏度导数 δy_u ;
- 5) 计算控制增量 Δu , 将控制增量 $u(k) = u(k - 1) + \Delta u(1)$ 付之实施;
- 6) 若设定控制时间到, 则程序结束; 否则, 返回 2)。

4 仿真研究

设某 CSTR 过程的参数为

$$D\alpha = 0.072, \quad \Phi = 20.0$$

$$B_h = 8.0, \quad \beta = 0.3$$

过程的控制目标是用冷剂的流量 u 控制反应物温度 x_2 。操作变量的约束为 $-0.65 \leq u(t) \leq 0.65$ 。取采

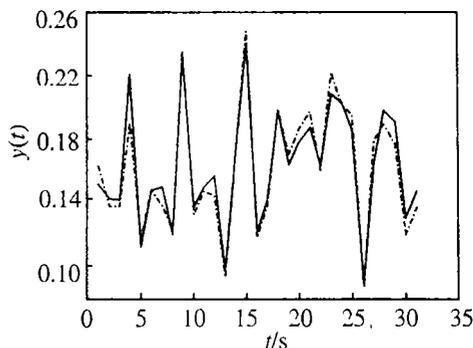


图 3 样本测试输出比较

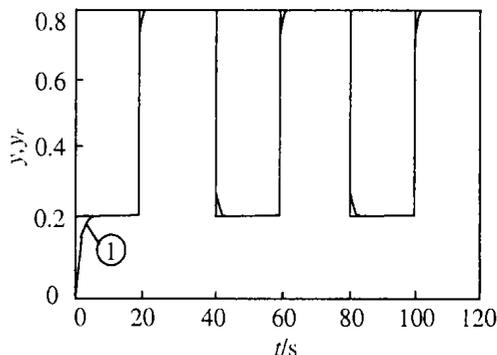


图 4 控制系统输出跟踪

样周期为 $T_s = 0.5 \text{ s}$, 当控制量为 $[-0.5, 0.5]$ 的随机数时, 系统的输出与 CMAC 模型的输出比较如图 3 所示(虚线为 CMAC 输出)。

若取预测时域为 3, 控制时域为 3, 参考轨迹常数为 $\tau = 0.2$, CMAC 的参数选择为 $\beta = 0.1$, $A^* = 32$, $A_p = 800$, 并设定系统控制目标是将反应物的浓度由 0.2 上升到 0.8, 再由 0.8 降为 0.2 的方波, 则过程的预测控制跟踪曲线如图 4 所示。图中曲线 ① 为非线性对象仿真输出曲线。实验采用 C 语言编写程序, 运行结果在 MATLAB 环境下绘制图形。可见, 基于 CMAC 的预测控制器表现出良好的控制性能。

5 结 论

本文针对非线性预测控制实现上的困难, 提出一种基于 CMAC 的预测控制策略, 结合非线性优化方法, 实现了对具有一般意义的非线性系统的多步预测控制。仿真结果表明, 系统的收敛速度与控制效

果都有很大改观, 并且控制策略具有较好的稳定性和鲁棒性, 是实现非线性系统预测控制的一种有效途径。

算法实现的难点在于 CMAC 网络的结构和参数的选取。其中, hash 单元数的多少关系着碰撞发生的概率和学习速度, 泛化能力则取决于 A^* 的大小, 而学习因子的大小对过程的在线性能影响很大。仿真中这些因素需要综合考虑。

参考文献(References):

- [1] Albus J S. A new approach to manipulator control: The cerebellar model articulation controller (CMAC) [J]. IEEE Trans ASME, 1975, 97(3): 220-227.
- [2] Albus J S. Data storage in the cerebellar model articulation controller (CMAC) [J]. IEEE Trans ASME, 1975, 97(3): 228-233.
- [3] 王伟. 广义预测控制理论及应用[M]. 北京: 科学出版社, 1998.

(上接第 88 页)

5 结 论

本文采用模糊预测算法实现新一代大射电望远镜馈源轨迹跟踪自适应控制。文中给出了模糊预测器和模糊预测控制器的设计, 并采用 BP 算法实现在线修正以达到自适应控制。通过大射电望远镜悬索-馈源系统的时变大滞后二阶系统的数值仿真, 证明模糊预测控制算法可以满足馈源轨迹跟踪精度要求, 为新一代大射电望远镜国际合作项目的工程实现奠定了基础。

参考文献(References):

- [1] Duan B Y. A new design project of the line feed structure for large spherical radio telescope and its nonlinear

dynamic analysis[J]. Mechatronics, 1999, 9(1): 53-64.

- [2] Su Y X, Duan B Y. The mechanical design and kinematics accuracy analysis of a fine tuning stable platform for the large spherical radio telescope[J]. Mechatronics, 2000, 10(7): 819-834.
- [3] 张阿卜. 利用 BP 算法的一种自适应模糊预测控制器[J]. 控制理论与应用(Control Theory and Appl), 1999, 16(2): 105-108.
- [4] 王立新. 自适应模糊系统与控制——设计与稳定性分析[M]. 北京: 国防工业出版社, 1995.
- [5] 苏玉鑫, 段宝岩. 大射电望远镜馈源轨迹跟踪自适应控制[J]. 控制理论与应用(Control Theory and Appl), 2002, 19(1).

(上接第 91 页)

参考文献(References):

- [1] R M Sanner, J J E Slotine. Gaussian networks for direct adaptive control[J]. IEEE Trans on Neural Networks, 1992, 11(3): 837-863.
- [2] Young H Kim, Frank L Lewis, Chaouki T Abdallah. A

dynamic recurrent neural-network-based adaptive observer for a class of nonlinear systems[J]. Automatica, 1997, 33(8): 1539-1543.

- [3] 高为炳. 变结构控制理论基础[M]. 北京: 中国科学技术出版社, 1990.