
短文

联想记忆的自强式学习控制¹⁾

许 力 蒋静坪 诸 静 朱炎新

(浙江大学电机系 杭州 310027)

摘要

在 ASE/ACE 模型中引入监督式学习的局部性网络作联想记忆机制，从而构造一种新的自强式学习控制器模型 RELCAM。仿真结果表明，使用该模型能显著改善学习和控制性能。

关键词：自强式学习，联想记忆，ASE/ACE 模型，RELCAM 模型。

1 引言

自强式学习 (Reinforcement Learning) 是在没有教师的示范而只有评论家的评判的情况下进行的学习控制。学习中获取的反馈信息只是对或错，而不是具体的误差信息。ASE/ACE 模型^[3] 是在文 [1, 2] 基础上发展起来的一种自强式学习控制器模型，其学习是一种完全独立的表格查询与修改过程，缺乏记忆的联想性。而“实现了联想记忆就等于实现了半个大脑^[6]”，因此，本文提出一种带联想记忆机制的自强式学习控制器模型 RELCAM (Reinforcement Learning with Associative Memory)，并对文献 [3] 介绍的倒立摆进行了在线学习控制的仿真研究。

2 ASE/ACE 模型的分析

ASE/ACE 模型由关联式搜索单元 ASE 和自适应评判单元 ACE 构成。ASE 的作用是确定控制信号 y ，而 ACE 则对自强信号 r 进行改善。ASE 和 ACE 各有 n 路输入通道，由系统状态 s 解码而成，且每一时刻只选一个，即 $x_i(t)$, $i=1, 2, \dots, n$ 。控制信号的确定和各通道权值修正的公式如下^[3]：

$$y = f \left[\sum_{i=1}^n w_i(t) x_i(t) + \text{noise}(t) \right], \quad (1)$$

$$p(t) = \sum_{i=1}^n v_i(t) x_i(t), \quad (2)$$

$$\hat{r}(t) = r(t) + \gamma p(t) - p(t-1), \quad (3)$$

$$w_i(t+1) = w_i(t) + \alpha \hat{r}(t) e_i(t), \quad (4)$$

1) 获国家自然科学基金资助课题。

本文于 1993 年 6 月 19 日收到

$$e_i(t+1) = \delta e_i(t) + (1 - \delta)y(t)x_i(t), \quad (5)$$

$$v_i(t+1) = v_i(t) + \beta \hat{r}(t)\bar{x}_i(t), \quad (6)$$

$$\bar{x}_i(t+1) = \lambda \bar{x}_i(t) + (1 - \lambda)\bar{x}_i(t). \quad (7)$$

其中 w_i 和 v_i 分别为 ASE 和 ACE 各通道的权值; \hat{r} 是经改善的自强信号; $\alpha, \beta, \gamma, \delta$ 和 λ 是有关系数; noise 是随机噪声.

显然, 各单元的输出几乎完全取决于被选通道的权值 (ASE 略受噪声的影响). 但是, 各权值的学习却是相互独立的, 只有那些曾被选中的通道的权值才会得到修正, 其它的则不变. 这样, 一旦碰到新情况, 即选中一个从未选中的通道, 就可能输出一个完全错误的控制信号, 导致系统运行的失败.

3 RELCAM 模型

以上分析表明, 应对权值进行联想记忆, 即任一通道权值的学习会同时影响另几路的权值, 其中包括未曾选中的通道. 这样, 系统在失败几次而稍具经验教训后, 即使碰到新情况, 也能联想出一个比较好的 (尽管可能不是最好的) 控制信号, 以保证系统能继续成功地运行和学习.

RELCAM 模型就是基于以上考虑提出的, 它由 ASE/ACE 模型和联想记忆机制 AM 构成, 如图 1 所示. 每个通道的权值通过一个子网络来记忆, 各子网络既独立又关联地组成一个监督式学习 (Supervised Learning) 的局部性网络. 全局性网络 (如 BP 网) 因其完全联结机制而较适合于对固定样本集的学习^[5]. 研究还表明, 直接将 BP 网用作 AM 是不合适的; 而局部性网络因其部分联结机制而较适合于实时控制^[5]. 在 RELCAM 模




图 1 RELCAM 模型

型中; AM 可采用 CMAC^[4] 或局部化的 BP 网 (LBP)^[8] 等局部性网络.

下面以 CMAC 为例说明 RELCAM 的工作原理. 系统状态 $s(t)$ 经解码选中通道 $x_i(t)$, 经杂凑映射 (Hashmapping)^[4] 选中 CMAC 记忆空间 A_p 中的 A^* 个记忆单元, 该 A^* 个单元中的信号之和即为本时刻本通道的权值, 相应于网络学习的教师信号分别由式 (4) 和 (6) 给出. 由于子网络间的关联性, 任何一个权值的一部分同时也是另几个通道权值的一部分. 因而, 没有一个通道的权值是完全独立的, 学习是联想式的.

控制信号的确定和权值的修正依旧采用式 (1)–(7).

4 仿真结果

为了验证 RELCAM 模型, 采用文献 [3] 介绍的倒立摆的数学模型和参数值在 SUN 工作站上进行在线学习控制的仿真研究. 系统状态 s 取为 $[x, \dot{x}, \theta, \dot{\theta}]^T$, 其中 x 和 θ 分别为位移和偏角. ASE 和 ACE 各有 162 个输入通道. 当 θ 超出 $[-12^\circ, 12^\circ]$, 或者 x 超出 $[-2.4m, 2.4m]$ 的范围时, 尝试 (Trial) 失败. 以不失败地运动 8 万步 (相当于实际时间 26'40'', 步长为 0.02 秒) 为一次成功的尝试, 每次运行 (Run) 从零初值开始, 即 $w(0)$ 、 $v(0)$ 和 $s(0)$ 都为零, 到成功的尝试结束. 每次尝试的初值 $s(0)$ 为零, $w(0)$ 和 $v(0)$ 为本次运行中的上次尝试失败时的数值. 不同运行的差别在于随机数“种子”的不同.

联想记忆机制有两个主要参数, A_p 和 A^* . 在 CMAC 中, A_p 是整个网络记忆空间的大小, 而 A^* 则为各子网络中记忆单元的个数; 在 LBP 中, A_p 表示整个网络的隐单元总数, 而 A^* 则为各子网络的隐单元数. A_p 与 A^* 没有严格限制, 其典型取值为 $A_p \geq 100A^*$ ^[4]. 而研究表明应满足 $A_p \approx 10A^*$ 的关系^[7], 当 (A_p, A^*) 取为 $(50, 5)$, $(100, 10)$ 和 $(300, 30)$ 等多种组合, 均能很好地工作. 本文统一选取 $A_p = 100$ 和 $A^* = 10$.

对 ASE/ACE, ASE/ACE + CMAC 和 ASE/ACE + LBP 三种情况各作 6 次运行, 并对成功尝试中的下列指标进行统计: (1) 尝试成功的最快时刻 T_s ; (2) 尝试成功的平均时刻 T_{sm} ; (3) 偏角均方根的平均值 θ_{sm} ; (4) 最大偏角 θ_{\max} ; (5) 最大偏角的平均值 θ_{mm} .

表 1 6 次运行的统计

模 型	T_s (次)	T_{sm} (次)	θ_{sm} (度)	θ_{\max} (度)	θ_{mm} (度)
ASE/ACE	21	49.83	2.5895	11.2223	7.1734
ASE/ACE + CMAC	6	7	2.2878	6.4668	5.0178
ASE/ACE + LBP	5	7	2.1984	5.4431	4.9262

从表 1 统计结果可以看到, 联想记忆机制的引入, 使尝试成功前的失败次数和偏差明显减少; 同时, 记忆空间也可减小, 如采用 CMAC, 记忆单元总数从原来的 324 (即 162×2) 减少到 200 (即 100×2). 这一特点, 在状态空间较大而输入通道较多时显得尤其重要.

5 结论

在自强式学习控制中引入联想记忆机制，不仅可缩小记忆空间，更能显著地改善系统的学习控制性能。此外，自强式与监督式学习并非完全独立的，两者的有机结合，对改善复杂非线性系统的学习和控制性能是大有益处的。

参 考 文 献

- [1] Barto A G, Sutton R S, Brouwer P S. Associative search network: A reinforcement learning associative memory. *Biol. Cybern.*, 1981, **40**: 201—211.
- [2] Barto A G, Sutton R S. Landmark learning: An illustration of associative search. *Biol. Cybern.*, 1981, **42**: 1—8.
- [3] Barto A G, Sutton R S, Anderson C W. Neuronlike adaptive elements that can solve difficult learning control problems. *IEEE Trans. Syst., Man., Cybern.*, 1983, **SMC-13**(5): 834—846.
- [4] Albus J S. A new approach to the manipulator control: The cerebellar model articulation controller (CMAC). *Trans. ASME, J. Dynamic Syst. Meas. Contr.*, 1975, **97**: 220—227.
- [5] Werbos P J. Neurocontrol and elastic fuzzy logic: Capabilities, concepts and Applications. *IEEE Trans. Industr. Electronics*, 1993, **40**(2): 170—180.
- [6] 中野馨[日], 卫作人. 联想记忆工程. 国防工业出版社, 1992.
- [7] 许力, 蒋静坪. CSTR 系统的基于 CMAC 神经元网络的学习控制研究. 控制与决策, 1992, **7**(2): 131—136.
- [8] 许力. 一种局部化的反向传播网络. 控制与决策, 1995, **10**(2): 148—152.

REINFORCEMENT LEARNING CONTROL WITH ASSOCIATIVE MEMORY

XU LI JIANG JINGPING ZHU JING ZHU YANXIN

(Department of Electrical Engineering, Zhejiang University, Hangzhou 310027)

ABSTRACT

The supervised learning local nets are employed in the ASE/ACE model as the associative memory to construct a novel reinforcement learning controller model called RELCAM, simulation results show that the learning ability and control performance can be improved by using this model.

Key words: Reinforcement learning, associative memory, ASE/ACE model, RELCAM model.