

# 时空混沌控制在联想记忆中的应用

余群明, 王耀南

(湖南大学电气与信息工程学院, 长沙 410082)

摘要: 本文提出了一种具有时空混沌控制的联想记忆网络. 实验结果表明: 具有目标信息的一部分知识的初始输入能在时空混沌的参数控制中成功地完成联想记忆, 根据提出的学习算法, 该网络的记忆搜索性能和记忆容量比 Hopfield 模型有较大改善. 同时发现联想记忆成功率与强化因子、样本数、信息率、学习阈值以及初始混沌参数有关.

关键词: 时空混沌控制; 联想记忆网络; 成功率; 强化因子; 学习阈值; 初始混沌参数

中图分类号: TP29 文献标识码: A 文章编号: 03722112 (2001) 05067804

## Spatiotemporal Chaos Control Applied in Associative Memory

YU Qunming, WANG Yaoan

(Institute of Electronic and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: An associative memory network with spatiotemporal chaos control is investigated in this paper. Experimental results show that initial input with the knowledge of only a part of the target information can successfully complete associative memory by spatiotemporal chaos parameter control. By means of our proposed algorithm, memory search performance and memory capacity possess more powerful improvement compared with the Hopfield model. Meanwhile we find that success rate of associative memory depends on reinforcement factor, sampling number, information quantity, training threshold value and initial chaos parameters.

Key words: spatiotemporal chaos control; associative memory network; success rate; reinforcement factor; training threshold value; initial chaos parameters

### 1 引言

最近在脑神经系统中, 从微观的神经元到宏观的脑电波, 理论和实验两方面都发现了混沌现象的存在<sup>[1,2]</sup>, 混沌动力在神经网络的信息处理中起着很重要的作用<sup>[3-5]</sup>. 例如: Tsuda 认为皮层的混沌对真实记忆和记忆搜索动态地联系很有用<sup>[6]</sup>; Aihara 等提出一种混沌自身地响应的混沌神经网络, 并认为混沌动力可用于神经网络的信息处理<sup>[7]</sup>; Toyoda<sup>[11]</sup>等提出一种混沌神经网络联想模型, 并指出该模型能非周期性地联想记忆模式; Nakamura<sup>[12]</sup>等认为凭借神经网络参数控制技术的联想记忆能逃离局部最小, 该方法要求全部目标信息中的内容. 为此, 本文提出一种具有混沌控制的联想记忆网络, 文中首先简要地介绍一下使用的混沌神经网络, 为了描述网络的混沌特性, 引入 Lyapunov 指数谱分析理论; 接着在此基础上重点讨论用于联想记忆的混沌控制方法, 为了快速回忆起目标模式, 在输出模式接近目标模式的一定程度时通过引入强化因子来增加神经元的激活率, 从而为下一步搜索作准备; 最后进行计算机仿真实验得到有关结果和结论.

### 2 混沌神经网络及 Lyapunov 指数谱分析

为了进行时空混沌控制, 本文采用 Aihara 提出的混沌神

经网络模型, 该模型由离散时间和连续空间方程定义为:

$$y_i(t+1) = k(t)y_i(t) + \sum_{j=1}^M w_{ij}x_j(t) - A(t)x_i(t) + a_i(t), \quad i = 1, 2, \dots, M \quad (1)$$

$$x_i(t+1) = f(y_i(t+1)) \quad (2)$$

其中:  $y_i(t)$  和  $x_i(t)$  分别为第  $i$  个神经元的内部状态和输出;  $M$  为网络中全部神经元数目;  $k(t)$  为记忆常量,  $0 \leq k(t) \leq 1$ , 它保证迭代的收敛性;  $A(t)$  为相对抑制常量,  $A(t) > 0$ , 它抑制神经元兴奋后的激活;  $w_{ij}$  为网络中第  $i$  个神经元与第  $j$  个神经元间的连接权值;  $a_i(t)$  为第  $i$  个神经元的外部输入;  $f(y)$  为转换函数, 取为  $s$  型函数, 即  $f(y) = \tanh(y/E)$ ,  $E$  为  $s$  型函数的确定参数.

方程(1)右边的第二项为常规 Hopfield 项, 方程(1)、(2)定义的模型在  $k(t) = A(t) = a_i(t) = 0$  的情况下变为 Hopfield 模型, 方程(1)中右边最后一项是对神经元的偏置, 方程(1)中右边第一项和第三项引入是为了在系统中产生混沌动力. 因此, 可以认为混沌神经网络模型是将混沌动力引入到 Hopfield 模型中, 作为 Hopfield 模型的自然扩展.

混沌神经网络的混沌特征由 Lyapunov 指数谱来度量, 由文献[8]可知:  $n$  维离散系统中存在  $n$  个 Lyapunov 指数  $K_i (i =$

1, 2, ..., n), 若其中最大的 Lyapunov 指数  $K_{max} > 0$ , 则该系统一定存在混沌.  $K_{max}$  计算式如下:

$$K_{max} = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=0}^{n-1} \ln |J_t| \quad (3)$$

这里  $J_t$  为  $t$  阶 Jacobian 矩阵.

$$J_t = \begin{bmatrix} \frac{\partial y_1(t+1)}{\partial y_1(t)} & \frac{\partial y_1(t+1)}{\partial y_2(t)} & \dots & \frac{\partial y_1(t+1)}{\partial y_M(t)} \\ \frac{\partial y_2(t+1)}{\partial y_1(t)} & \frac{\partial y_2(t+1)}{\partial y_2(t)} & \dots & \frac{\partial y_2(t+1)}{\partial y_M(t)} \\ \dots & \dots & \dots & \dots \\ \frac{\partial y_M(t+1)}{\partial y_1(t)} & \frac{\partial y_M(t+1)}{\partial y_2(t)} & \dots & \frac{\partial y_M(t+1)}{\partial y_M(t)} \end{bmatrix}$$

其中:  $\frac{\partial y_i(t+1)}{\partial y_j(t)} = \begin{cases} k(t) + (w_{ii} - A(t))fc(y_i(t)), & \text{当 } i=j \\ w_{ij}fc(y_j(t)), & \text{当 } i \neq j \end{cases}$

### 3 联想记忆的混沌控制方法

在讨论混沌控制方法之前, 有必要对混沌神经网络中的连接权值  $w_{ij}$  作一简要说明.

(1) 连接权值  $w_{ij}$  的确定 这里介绍一种用广义逆矩阵法来确定连接权值  $w_{ij}$  的方法.  $w_{ij}$  定义为:

$$w_{ij} = \frac{1}{N} \sum_{L=1}^N N_i^L N_j^{L+} \quad (4)$$

其中:  $N_i^L$  为第  $i$  个神经元在第  $L$  个记忆模式中的状态,  $N_i^L$  取  $\{1, 0\}$  中的一个,  $L = 1, 2, \dots, N, i = 1, 2, \dots, M; N$  为记忆模式数;  $N_j^{L+}$  为第  $j$  个神经元在第  $L$  个记忆模式中的伴随值 (Adjoint), 它满足  $\sum_{j=1}^M N_j^L N_j^{L+} = D_s$ ,  $D_s$  为 Kronecker 的  $D$  函数,  $D_s = \begin{cases} 1, & L = s \\ 0, & L \neq s \end{cases}$ . 有关广义逆矩阵法来设计权值  $w_{ij}$  详细内容参见文献 [9].

(2) 参数  $k(t)$ 、 $A(t)$  和  $a_i(t)$  的控制 混沌神经网络的混沌动力主要取决于网络参数  $k(t)$ 、 $A(t)$  和  $a_i(t)$ , 因此可以考虑通过控制网络参数  $k(t)$ 、 $A(t)$  和  $a_i(t)$  来达到对混沌神经网络中混沌行为的时空控制, 并将它应用于联想记忆中.

对正确的记住记忆模式有许多种方法, 这里采用输出模式和目标模式 (记忆模式) 中随机选中部分的一致性程度来产生控制信号的一种方法. 定义第  $L$  个记忆模式的控制信号  $B^L(t)$  为:

$$B^L(t) = \frac{1}{L} \sum_{i=1}^L f^L(t, Q_i) \quad (5)$$

式中:

$$f^L(t, Q_i) = \begin{cases} 1, & \text{当 } N_{Q_i} \neq x_{Q_i}(t) > 0 \text{ 时, 表示能正确回忆} \\ 0, & \text{其它, 表示不能正确回忆} \end{cases}$$

其中:  $L$  为第  $L$  个记忆模式中为产生控制量所取的样本数,  $L < M$ ;  $Q_i$  为 1 到  $M$  间随机分布的整数;  $x_{Q_i}(t)$ ,  $N_{Q_i}$  和  $M$  的含义同以上.

在控制结构中, 网络的参数值是控制信号  $B^L(t)$  的函数, 其函数关系式为:

$$\begin{aligned} k(t) &= (1 - B^L(t))k(0) \\ A(t) &= (1 - B^L(t))A(0) \\ a_i(t) &= (1 - B^L(t))a_i(0) \end{aligned} \quad (6)$$

其中:  $k(0)$ 、 $A(0)$  和  $a_i(0)$  为网络初始混沌参数.

(3) 学习算法的选择 对方程 (1), 当  $k(0)$ 、 $A(0)$  和  $a_i(0)$  均接近零时, 系统从混沌神经网络模型向 Hopfield 模型转化. 因此, 这里定义的网络既有可能逃离具有混沌演变的“伪状态”, 又有象 Hopfield 模型一样联想目标模式的功能 (当网络的输出接近目标模式时).

神经元激活后抑制兴奋的参数  $A(t)$  的大小对当前神经网络模型的性能起着决定性的影响. 在回忆过程中为了成功地避开“伪状态”,  $A(t)$  必须相当大. 但同时太大的  $A(t)$  值, 系统有时不能逃离混沌态而达到 Hopfield 网络状态. 因此, 为了改善网络的记忆搜索能力, 需要采用一种有效的学习算法. 在搜索目标模式期间, 该算法修改外部输入值  $a_i(t)$ .

若  $B^L(t) \setminus Q$  则  $a_i(t) = (1 - B^L(t)) \# [a_i(0) + S N_i^L]$ ,  $i \in H$  (7) 其中:  $Q$  称为学习阈值,  $0 < Q < 1$ ;  $S$  称为学习过程中的强化因子;  $H$  为第  $L$  个记忆模式中所取样本的神经元集. 这样方程 (1) 可改写为:

$$y_i(t+1) = k(t)y_i(t) + \sum_{j=1}^M w_{ij}x_j(t) - [A(t)x_i(t) - S(t)N_i^L] + a_i(t), \quad i \in H \quad (8)$$

$$y_i(t+1) = k(t)y_i(t) + \sum_{j=1}^M w_{ij}x_j(t) - A(t)x_i(t) + a_i(t), \quad i \notin H \quad (9)$$

其中:  $S(t)$  定义为  $S(t) = S(1 - B^L(t))$ .

当神经元的输出状态接近目标模式一定程度时, 即  $B^L(t) \setminus Q$  该学习算法起作用, 它可以增加神经元的激活率, 能更容易、更快地使目标模式恢复. 这样, 一方面网络在目标模式的邻域处能更容易逃离混沌动力; 另一方面当输出状态远离目标模式时, 强化因子  $S$  的引入对网络动力没影响.

### 4 计算机仿真实验

实验的目标模式集为英文字母 A0 ~ H0, 如图 1. 即记忆模式数  $N = 8$ , 神经网络的结点数  $M = 100$ . 对目标模式随机地将若干单元取相反像素 (白色取反为黑色, 黑色取反为白色), 从而得到初始输入模式. 在本仿真实验中, 主要考虑强化因子和为产生控制量所取的样本数 (以下简称为样本数) 对联想记忆的影响、初始输入模式含目标模式的信息量 (以下简称为信息率) 和学习阈值对联想记忆的影响以及初始混沌参数  $k(0)$  和  $A(0)$  对联想记忆的影响这三个方面. 联想记忆的成功率定义为在不同初始输入模式下联想成功的试验次数与全部试验




图 1 实验的目标模式集

次数的比率. 实验中取 100 次试验, 每次试验的搜索次数为 100, 若搜索 100 次仍未联想到目标模式, 则认为联想不成功.

(1) 强化因子和样本数对联想记忆的影响

试验中设初始输入模式含目标模式 70% 的随机信息, 网络参数初值  $k(0) = 0.18$ ,  $A(0) = 0.16$ ,  $a_i(0) = 0.12$  (对所有神经元), 学习阈值  $Q = 0.15$ . 试验结果如表 1:

表 1 强化因子和样本数对联想成功率的影响

强化因子 样本数	0.13	0.14	0.15	0.16	0.18	1
40	/	30%	68%	80%	88%	92%
50	/	40%	91%	92%	95%	98%
60	4%	62%	94%	96%	97%	100%
80	5%	75%	99%	100%	100%	100%

从表中可以看出: 随着强化因子和样本数的增加, 联想记忆成功率明显提高.

(2) 信息率和学习阈值对联想记忆的影响

试验中设为产生控制量所取的样本数为 60, 网络参数初值  $k(0) = 0.18$ ,  $A(0) = 0.16$ ,  $a_i(0) = 0.12$ , 强化因子  $S = 0.18$ . 试验结果如下表 2.

表 2 信息率和学习阈值对联想记忆的影响

学习阈值 信息率	0.14	0.15	0.16	0.17	0.18
40%	96%	94%	92%	90%	60%
50%	86%	82%	74%	48%	/
70%	100%	100%	98%	64%	/
80%	98%	98%	98%	98%	40%

从表中可以看出: 随着学习阈值的减小和信息率的增加联想记忆成功率基本上在提高, 但在信息率为 50% 时联想记忆成功率有所下降. 这是因为在信息率大于 50% 时, 初始输入模式较靠近目标模式; 在信息率小于 50% 时, 初始输入模式较靠近目标模式的相反模式, 这两种情况均能较容易地成功联想, 而在信息率为 50% 时, 记忆搜索在模式空间中混沌地游荡, 不知道向哪个模式收敛, 因此造成信息率为 50% 时联想记忆成功率有所下降.

(3) 初始混沌参数  $k(0)$  和  $A(0)$  对联想记忆成功率的影响

试验中设初始输入模式含目标模式 70% 的随机信息, 为产生控制量所取的样本数为 60, 学习阈值  $Q = 0.16$ , 强化因子  $S = 0.18$ . 为了描述初始参数  $k(0)$  和  $A(0)$  的混沌动力, 我们在图 2 和图 3 绘出了不同网络初始混沌参数对应的 Lyapunov 指




图 2 (a) 不同网络初始混沌参数  $k(0)$  与联想成功率的关系图, 图中虚线表示 Hopfield 模型的联想成功率; (b) 不同网络初始混沌参数  $k(0)$  对应的 Lyapunov 指数曲线图, 另两个参数固定为  $A(0) = 0.16$ ,  $a_i(0) = 0.12$  (对所有神经元).

数谱曲线图; 同时为了观察初始混沌参数对联想记忆的影响, 不同网络初始混沌参数对应的联想记忆成功率也绘于图 2 和图 3.




图 3 (a) 不同网络初始混沌参数  $A(0)$  与联想成功率的关系图, 图中虚线表示 Hopfield 模型的联想成功率; (b) 不同网络初始混沌参数  $A(0)$  对应的 Lyapunov 指数曲线图, 另两个参数固定为  $k(0) = 0.18$ ,  $a_i(0) = 0.12$  (对所有神经元)

从图 2 和图 3 中可以看出: 网络的记忆搜索性能比 Hopfield 模型有较大改善, 联想成功率高的区域出现在那些网络初始混沌参数使系统为混沌 (正 Lyapunov 指数区域) 的地方. 但同时也发现正的 Lyapunov 指数并不一定保证联想的高成功率. 这是因为在记忆恢复过程中, 联想到目标模式的过程取决于控制参数的偏差, 当网络成功地联想到目标模式时, 该偏差从 0 到原始指定值之间变化, 因此只有初始混沌动力并不能足够保证网络的高联想成功率.

下面说明一下具有时空混沌控制的联想记忆网络的记忆容量问题. 所谓记忆容量是指在网络结构参数一定的条件下, 要保证联想功能的正确实现, 网络所能存储的最大样本数  $m$ . 记忆容量不仅与结点数  $n$  有关, 还与连接权值的设计有关, 适当地设计连接权值可以提高网络的记忆容量. 对 Hopfield 网, Hopfield<sup>[13]</sup> 提出了一个数量范围, 即  $m \in [0.15n, 0.15n @ 100 = 15]$ , 这就是说 Hopfield 网络能存储的最大样本数  $m = 15$ ; 而对于本文提出的这种网络, 其连接权值按广义逆矩阵法来设计, 根据文献[7]中的实验, 可得到在不同噪信比时其联想记忆成功率的统计结果如表 3.

表 3 不同噪信比时网络的联想记忆成功率统计结果

噪信比	0.105	0.110	0.115	0.120	0.125	0.130	0.135	0.140
网络的联想记忆成功率	100%	100%	100%	98%	92%	75%	58%	26%

从表 3 可以看出: 在噪信比为 0.125 时, 网络的联想记忆成功率仍高达 92%, 这说明该网络模型的联想记忆容量与 Hopfield 网相比有明显的提高.

5 结论

本文提出了一种具有混沌控制的联想记忆网络, 实验仿真结果表明: 具有目标信息的一部分知识的初始输入能在时空混沌的参数控制中成功地完成联想记忆, 凭借提出的学习算法, 网络的记忆搜索性能和记忆容量与 Hopfield 模型相比均有很大改善, 同时得到如下结论:

(1) 随着强化因子和样本数的增加, 联想成功率明显提高.

(2) 随着学习阈值的减小和信息率的增加联想记忆成功率基本上在提高, 但在信息率为 50% 时联想记忆成功率有所

下降.

(3) 联想成功率高的区域出现在网络初始混沌参数使系统为混沌的地方, 但正的 Lyapunov 指数并不一定保证联想的高成功率.

因此上述结果暗示着在神经网络中适当地应用柔性混沌动力可能避免局部最小问题, 本文提出的联想记忆网络在图像压缩和编码数据通信等神经网络的实际应用中由部分信息来恢复图像是很有用的.

#### 参考文献:

- [ 1 ] Aihara K. et al. Periodic and nonperiodic responses of a periodically forced Hodgkin-Huxley oscillator [ J ]. J. Theor. Biol. , 1984, 10: 249-269.
- [ 2 ] Parisi G. Asymmetric neural networks and the process of learning [ J ]. J. Phy. A. , 1986, 19: L675- L680.
- [ 3 ] Nicolis J. S. Chaos and information processing [ M ]. Singapore: World, 1991.
- [ 4 ] Yao Y, Freeman W. J. Model of biological pattern recognition with spatially chaotic dynamics [ J ]. Neural Networks, 1990, 3: 153- 170.
- [ 5 ] Nara S, et al. Memory search using complex dynamics in a recurrent neural network model [ J ]. Neural Networks, 1993, 6: 963- 973.
- [ 6 ] Tsuda I. Dynamics link of memory-chaotic memory map in one equilibrium neural networks [ J ]. Neural Networks, 1992, 5: 313- 326.
- [ 7 ] Aihara K, et al. Chaotic neural networks [ J ]. Phys. Lett. A. , 1990, 144: 334- 340.
- [ 8 ] 王东生, 曹磊. 混沌、分形及其应用 [ M ]. 合肥: 中国科学技术大学出版社, 1995.

- [ 9 ] 余群明, 王耀南. 联想记忆神经网络的连接权值设计方法研究 [ J ]. 模式识别与人工智能.
- [ 10 ] 王耀南. 计算智能信息处理技术及其应用 [ M ]. 长沙: 湖南大学出版社, 1999.
- [ 11 ] Toyoda, M. , et al. Chaotic neural networks [ A ]. Proceedings of SICE. 89 [ C ], 1989: 1323- 1325.
- [ 12 ] Nakamura, T. , et al. Retrieval of spatio-temporal sequence in asynchronous neural network [ J ]. Physical Review A, 1990, 41: 3346- 3351.
- [ 13 ] 孙增圻等编著. 智能控制理论与技术 [ M ]. 清华大学出版社, 1997.

#### 作者简介:



余群明 1966 年生, 现为湖南大学电气与信息工程系博士研究生. 主要从事神经网络、混沌理论及智能机器人等方面的研究.



王耀南 1957 年生, 博士后, 现为湖南大学电气与信息工程系教授, 博士生导师. 主要研究领域为工业自动化、人工智能、智能控制、智能机器人视觉、神经网络及模糊控制等.