

文章编号: 1000-8152(2011)11-1658-07

# 相空间压缩法实现混沌神经网络联想记忆

缪志强, 王耀南

(湖南大学 电气与信息工程学院, 湖南 长沙 410082)

**摘要:** 给出了利用相空间压缩法控制混沌神经网络, 使得网络能够收敛于存储的目标模式的充分条件和必要条件。通过数学分析, 得到了相空间压缩控制方法中对应参数的上下限; 并通过对仿真结果的分析, 提出了通过改变相空间压缩控制方法中对应的参数来实现混沌神经网络联想记忆的新方法。以上结果均通过仿真得到验证。

**关键词:** 混沌神经网络; 混沌控制; 相空间压缩; 联想记忆

中图分类号: TP183 文献标识码: A

## Realization of associative memory using chaotic neural network via phase space compression

MIAO Zhi-qiang, WANG Yao-nan

(College of Electrical and Information Engineering, Hunan University, Changsha Hunan 410082, China)

**Abstract:** We develop the necessary and sufficient conditions for a chaotic neural network to converge to the stored target patterns. The upper and lower limits of the corresponding parameters in the phase space compression control method are obtained. An associative memory scheme is proposed through the analysis of simulation results. The scheme is realized by changing the corresponding parameters in the phase space compression control method. These results are validated by simulations.

**Key words:** chaotic neural network; controlling chaos; phase space compression; associative memory

## 1 引言(Introduction)

混沌神经网络相比传统的Hopfield等网络而言, 具有更加丰富的动力学行为, 使得其在动态联想记忆<sup>[1,2]</sup>、组合优化<sup>[3~7]</sup>和信息处理<sup>[8]</sup>等领域有着极为广泛的应用前景。由混沌神经元组成的混沌神经网络<sup>[9]</sup>, 具有非周期的动态联想特性, 能够实现信息的存储和记忆, 然而, 记忆搜索过程不会收敛于任何一个平衡态, 而是非平衡地在存储模式间动态地“游走”<sup>[1,10]</sup>, 使得混沌神经网络的存储模式之间变得难以区分, 这样就限制了网络联想记忆功能的应用。为在神经网络中实现信息处理, 本文应对网络的混沌态进行控制, 以使得网络能够稳定在某一期望的存储模式上。这样, 控制混沌神经网络中的混沌变得十分必要<sup>[11]</sup>。

钉扎控制<sup>[11]</sup>、时延反馈控制和相空间压缩控制<sup>[12~14]</sup>相继被应用于混沌神经网络中的混沌控制。钉扎控制往往需要预先知道控制目标, 而时延反馈控制中的时滞参数及控制强度参数的选取较为复杂。相较于钉扎控制和时延反馈控制等仍建立在传统的反馈控制理论基础上的方法而言, 相空间压缩

控制法有着更加独特的控制机制, 相应的设计方法也较为简单。用相空间压缩法实现对混沌神经网络的控制的有效性已通过实践仿真, 得到充分的验证。然而, 对于混沌神经网络, 还没有人从理论上对这种控制方法的有效性进行解释。本文就试图解决这一问题。

## 2 混沌神经网络模型(Chaotic neural network model)

本文中的混沌神经网络采用由Aihara等人提出的模型<sup>[4]</sup>。此混沌神经网络模型由混沌神经元间的反馈时空耦合而成。第*i*个混沌神经元的动力学方程为:

$$x_i(t+1) = f(\eta_i(t+1) + \zeta_i(t+1)), \quad (1)$$

$$\eta_i(t+1) = k_f \eta_i(t) + \sum_{j=1}^N w_{ij} x_j(t), \quad (2)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a_i, \quad (3)$$

其中:  $x_i(t+1)$ 为神经元在*t+1*时间的输出,  $\eta_i(t+1)$ 和 $\zeta_i(t+1)$ 为神经元的内部状态, 分别为神经元的反馈输入项和神经元的不应性项,  $k_f$ 为反馈输

入衰减系数,  $k_r$  为不应性衰减系数,  $\alpha$  为不应性参数,  $\alpha_i$  为第  $i$  个神经元阈值,  $f(\cdot)$  为神经元作用函数, 取带陡度参数  $\varepsilon$  的 Sigmoid 函数,  $f(y) = 1/(1 + \exp(y/\varepsilon))$ ,  $w_{ij}$  为第  $i$  个神经元与第  $j$  个神经元间的连接权值, 在

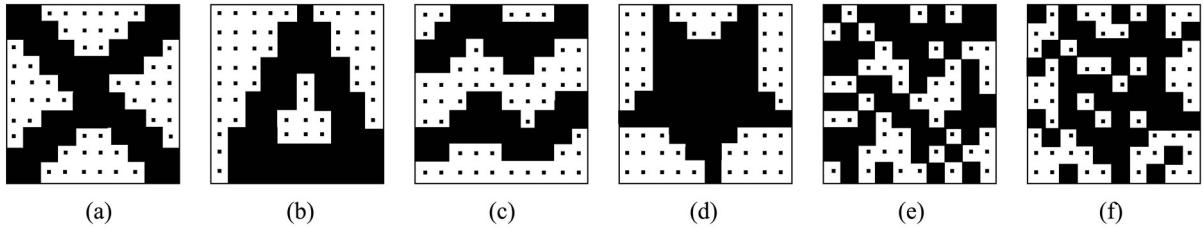


图 1 (a)~(d) 为 4 个存储模式, (e) 和 (f) 分别为 (c) 和 (d) 含 20% 噪声的模式, 记为  $X^5$  和  $X^6$

Fig. 1 (a)~(d) are four stored patterns, (e) and (f) are noisy patterns, generated with 20% noise from (c) and (d), noted  $X^5$  and  $X^6$

每一个模式由  $10 \times 10$  阵列组成, 分别用 100 个混沌神经元的输出状态来表示, 如果神经元为“兴奋”, 对应的点显示黑方块, 如果为“抑制”则显示为点“.”。混沌神经网络的输出与目标模式间的相似度由汉明距离定义:

$$H^p = \sum_{i=1}^{100} |x_i - X_i^p|. \quad (5)$$

汉明距离越小, 则网络的输出与目标模式间的相似度越大, 当汉明距离为零时, 则实现了对存储模式的联想记忆。

网络的动力学特性由网络的参数决定。当选取参数  $k_f = 0.2$ ,  $k_r = 0.95$ ,  $\alpha = 10$ ,  $\alpha_i = 2$  ( $i = 1, 2, \dots, 100$ ) 时, 神经网络显示为混沌动力学特性<sup>[1]</sup>。

为后面的分析方便起见, 本文将式(1)~(3)变换为如下形式:

$$x_i(t+1) = f(H_i(x(t)) + I_i(\zeta_i(t), x_i(t))), \quad (6)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a_i, \quad (7)$$

其中:

$$H_i(x(t)) = \sum_{j=1}^N w_{ij} x_j(t) + k_f x_i(t),$$

$$I_i(\zeta_i(t), x_i(t)) = \zeta_i(t+1) - k_f \zeta_i(t) = (k_r - k_f) \zeta_i(t) - \alpha x_i(t) + a_i.$$

$H_i(x(t))$  具有含自反馈的 Hopfield 网络的结构, 它具有使网络收敛于某一存储模式的效应, 是系统的稳定因子;  $I_i(\zeta_i(t), x_i(t))$  是具有自回归的不应反馈项, 它趋于使网络远离任意固定态, 是系统的不稳定因子; 正是由于稳定因子与不稳定因子的相互作用, 实现了神经网络的动态联想记忆。

### 3 相空间压缩法控制混沌神经网络(Controlling chaotic neural network based on phase space compression)

相空间压缩法即通过对混沌系统的轨道演化空间进行限制, 限制其相轨道在空间中的自由伸缩和扩张, 从而达到控制混沌的目的。对该系统进行轨道

图 1 中, 由图 1(a)~1(d) 表示的 4 个存储模式<sup>[1]</sup>, 分别记为  $X^1, X^2, X^3, X^4$ , 按外积求和学习算法决定:

$$w_{ij} = \frac{1}{4} \sum_{p=1}^4 (2X_i^p - 1)(2X_j^p - 1). \quad (4)$$

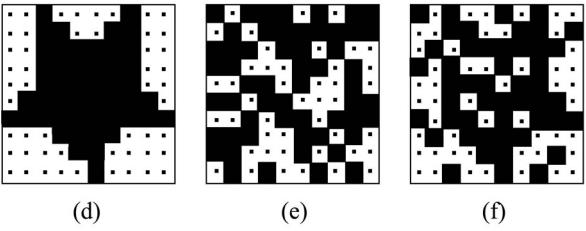


图 1 (a)~(d) 为 4 个存储模式, (e) 和 (f) 分别为 (c) 和 (d) 含 20% 噪声的模式, 记为  $X^5$  和  $X^6$

空间压缩有 3 条途径<sup>[11]</sup>: 一是只对反馈输入项  $\eta_i$  压缩; 二是只对不应项  $\zeta_i$  压缩; 三是对  $\eta_i$  和  $\zeta_i$  同时压缩。 $\zeta_i$  反映的是对混沌神经元自身性质的影响, 直接影响网络的输出, 而  $\eta_i$  反映的是混沌神经元相互连接之间的影响, 随着系统的运动和时间的推移才能影响到整个系统。因而对  $\zeta_i$  进行压缩比对  $\eta_i$  进行压缩有更好的控制效果。加了控制后的混沌神经网络模型可以用以下的方程来描述:

$$x_i(t+1) = f(\eta_i(t+1) + \zeta_i(t+1)), \quad (8)$$

$$\eta_i(t+1) = k_f \eta_i(t) + \sum_{j=1}^N w_{ij} x_j(t), \quad (9)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a_i, \quad (10)$$

$$\zeta_i(t+1) = \begin{cases} a, & \zeta_i(t+1) \leq a, \\ \zeta_i(t+1), & a \leq \zeta_i(t+1) \leq b, \\ b, & \zeta_i(t+1) \geq b. \end{cases} \quad (11)$$

将式(11)记为  $\zeta_i(t+1) = C[\zeta_i(t+1)]$ , 则

$$x_i(t+1) = f(H_i(x(t)) + I_i(\zeta_i(t), x_i(t))), \quad (12)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a_i, \quad (13)$$

其中:

$$H_i(x(t)) = \sum_{j=1}^N w_{ij} x_j(t) + k_f x_i(t),$$

$$I_i(\zeta_i(t), x_i(t)) = C[\zeta_i(t+1)] - k_f C[\zeta_i(t)].$$

一方面, 由于混沌运动的遍历性, 即使不对  $\zeta_i(t+1)$  进行压缩, 混沌神经网络仍然可以搜索到存储的目标模式或其逆模式, 只不过可能搜索过程耗时较长, 效率低; 另一方面, 由于混沌系统自身的结构不稳定性, 这些存储的目标模式(或其逆模式)又是不稳定的, 神经网络还是会运动到偏离目标模式的状态。所以, 对不稳定因子  $\zeta_i(t+1)$  进行压缩的目的, 一是减小系统的不稳定量, 使得系统能在一个较短的时间内, 就能遍历或运动到某一存储的目标模式; 另一个更重要的目的是, 通过对  $\zeta_i(t+1)$  进行压

缩,使得目标模式是稳定的.即一旦网络搜索到目标模式,以后的时间内,受限的不稳定因子 $\zeta_i(t+1)$ 对网络状态的影响应始终小于稳定因子对网络状态的影响,则网络最终将稳定到目标模式.基于以上讨论,本文得到应用相空间压缩法控制混沌神经网络,要使得目标模式稳定,受限的 $\zeta_i(t+1)$ 必须满足的充要条件:当网络搜索到目标模式(或其逆模式)时,受限的不稳定因子 $\zeta_i(t+1)$ 对网络状态的影响在以后的时间内应始终小于稳定因子对网络状态的影响.

要使得系统稳定,本文可以将以上条件中对稳定因子和不稳定因子间的约束类比于Logistic映射中的对驱动力和耗散力间的约束:驱动力应小于耗散力.驱动力使得系统远离平衡态,而耗散力使得系统趋于稳态.

只要将 $\zeta_i(t+1)$ 压缩的足够小,以上条件总会满足.然而,为从理论上分析 $\zeta_i(t+1)$ 应压缩的最小限度,以上条件是极为苛刻的,必须将以上限制弱化.当网络搜索到目标模式时,受限的不稳定因子 $\zeta_i(t+1)$ 对网络状态的影响在以后的时间内应始终小于稳定因子对网络状态的影响,则至少应该在网络稳定在目标态即终态时,以上条件满足.这样本文得到网络收敛于目标模式的一个必要条件:当网络在终态或稳态时,受限的不稳定因子 $\zeta_i(t+1)$ 对网络状态的影响小于稳定因子对网络状态的影响.

下面,本文将在以上分析的基础上,定量的讨论相空间压缩控制方法由式(11)表示的参数 $a$ 和 $b$ 应满足的条件.

#### 4 相空间压缩法参数的设计及电路实现(Parameters design and circuit implementation )

相空间压缩法控制混沌神经网络的关键在于参数 $a$ 和 $b$ 的设计:

$$\zeta_i(t+1) = \begin{cases} a, & \zeta_i(t+1) \leq a, \\ \zeta_i(t+1), & a \leq \zeta_i(t+1) \leq b, \\ b, & \zeta_i(t+1) \geq b. \end{cases}$$

根据第2部分中得到的充要条件,应对参数 $a$ 和 $b$ 做出了一定的限制.

由于 $f(y) = 1/(1 + \exp(y/\varepsilon))$ ,当 $\varepsilon \rightarrow 0$ 时,

$$f(y) = \begin{cases} 0, & y > 0, \\ 1, & y < 0. \end{cases}$$

考虑到函数 $f(\cdot)$ 的上述性质,则当 $|I_i(\zeta_i(t), x_i(t))| < |H_i(x(t))|$ 时,

$$\begin{aligned} x_i(t+1) &= f(H_i(x(t))) + I_i(\zeta_i(t), x_i(t)) = \\ &= f(H_i(x(t))). \end{aligned}$$

此时,网络的动力学行为完全由稳定因子 $H_i(x(t))$ 决定.根据充要条件,若网络在 $t_0$ 时刻运动到某一存

储的目标态,则对所有的神经元,下式应成立:

$$\begin{cases} |I_i(\zeta_i(t), x_i(t))| < |H_i(x(t))|, \\ 1 \leq i \leq N, t > t_0, p \in \{1, 2, 3, 4\}. \end{cases} \quad (14)$$

根据必要条件,当网络处于稳态时, $x(t) = X^p$ ,则上式变为:

$$\begin{cases} |I_i(\zeta_i(t), X_i^p)| < |H_i(X^p)|, \\ 1 \leq i \leq N, p \in \{1, 2, 3, 4\}. \end{cases} \quad (15)$$

式(15)与下式等价:

$$|I_i(\zeta_i(t), X_i^p)| < \min_{1 \leq i \leq N} |H_i(X^p)|, p \in \{1, 2, 3, 4\}. \quad (16)$$

由式(16)可知,对于不同的终态目标模式,参数 $L^p = \min_{1 \leq i \leq N} |H_i(x(t))|$ 是一个重要的指标.对于不同的终态目标模式或其逆模式参数

$$L^p = \min_{1 \leq i \leq N} |H_i(x(t))|$$

的计算结果如表1.

表 1 4个存储模式对应的参数 $L^p$

Table 1 The  $L^p$  parameters of four stored patterns

稳态模式	$X^1$	$X^2$	$X^3$	$X^4$
$L^p$	9	11	10	9

下面,本文的工作在于求解不等式:

$$|I_i(\zeta_i(t), X_i^p)| < \min_{1 \leq i \leq N} |H_i(X^p)|, p \in \{1, 2, 3, 4\},$$

其中:

$$\begin{aligned} I_i(\zeta_i(t), x_i(t)) &= C[\zeta_i(t+1)] - k_f C[\zeta_i(t)], \\ \zeta_i(t+1) &= k_r \zeta_i(t) - a X_i(t) + a_i. \end{aligned}$$

首先,本文给出以下结论:

当 $x(t)$ 稳定于 $X^p$ 时,受限后的( $\zeta_i(t)$ )也将最终收敛于边界点 $a$ 或 $b$ .

若 $X_i^p = 1$ ,则( $\zeta_i(t)$ )将收敛于点 $a$ ;

若 $X_i^p = 0$ ,则( $\zeta_i(t)$ )将收敛于点 $b$ .

证 当 $x(t)$ 稳定于 $X^p$ 时,

$$\zeta_i(t+1) = k_r \zeta_i(t) - a X_i^p + a_i.$$

1) 若 $X_i^p = 1$ ,则 $\zeta_i(t+1) = k_r \zeta_i(t) - 8$ .

当 $\zeta_i(t) > -160$ 时, $\zeta_i(t+1) < \zeta_i(t)$ 恒成立. ( $\zeta_i(t) > -160$ 这个条件很容易得到满足,只需 $a > -160$ 即可).此时 $\zeta_i(t)$ 随着时间递减,考虑到 $\zeta_i(t)$ 受限,最终 $\zeta_i(t)$ 将收敛于边界最小点 $a$ .

2) 若 $X_i^p = 0$ ,则 $\zeta_i(t+1) = k_r \zeta_i(t) + 2$ .

当 $\zeta_i(t) < 40$ 时, $\zeta_i(t+1) > \zeta_i(t)$ 恒成立( $\zeta_i(t) < 40$ 这个条件很容易得到满足,只需 $b < 40$ 即可).此时 $\zeta_i(t)$ 随着时间递增,考虑到 $\zeta_i(t)$ 受限,最终 $\zeta_i(t)$ 将收敛于边界最大点 $b$ .

综上, 命题得证. 证毕.  
基于以上结论, 本文计算不等式(16), 得到对于不同的目标模式参数 $a$ 和 $b$ 最大范围的公式:

$$\begin{cases} a > -\frac{L^p}{1-k_f}, \\ b < \frac{L^p}{1-k_f}, \\ a < b. \end{cases} \quad (17)$$

由式(17)计算得参数 $a$ 和 $b$ 最大范围结果如表2所示.

表2 当稳态模式为存储模式之一时, 对应参数 $a$ 和 $b$ 的极值

Table 2 The extreme value of parameters  $a$  and  $b$  when steady state is one of the four stored patterns

稳态模式	$X^1$	$X^2$	$X^3$	$X^4$
$a$ 的最小值	-11.25	-13.75	-12.5	-11.25
$b$ 的最小值	11.25	13.75	12.5	11.25

下面本文将考虑相空间压缩法的电路实现问题. 考虑如下二极管双向限幅电路, 见图2. 显然, 可以用图2的双向限幅电路来实现对 $\zeta_i(t+1)$ 的限幅.

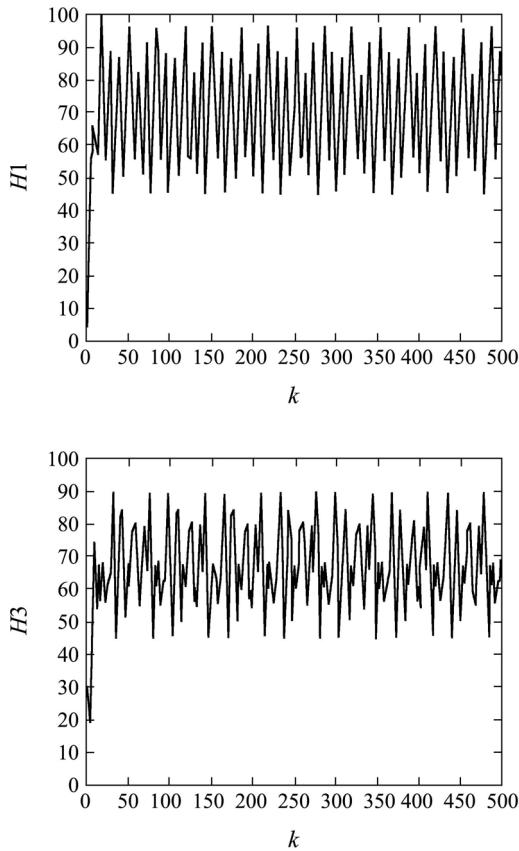


图3 当 $a = -13.75, b = 1$ 时, 网络输出与4个存储模式间的汉明距离

Fig. 3 The Hamming distances between the output pattern of the network and the four stored patterns, when  $a = -13.75$  and  $b = 1$

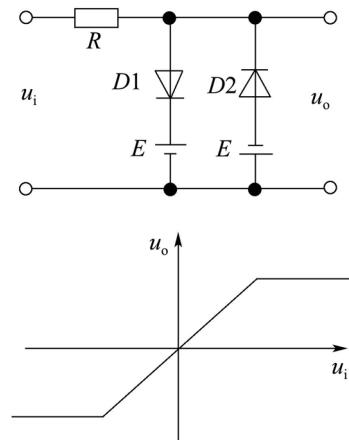


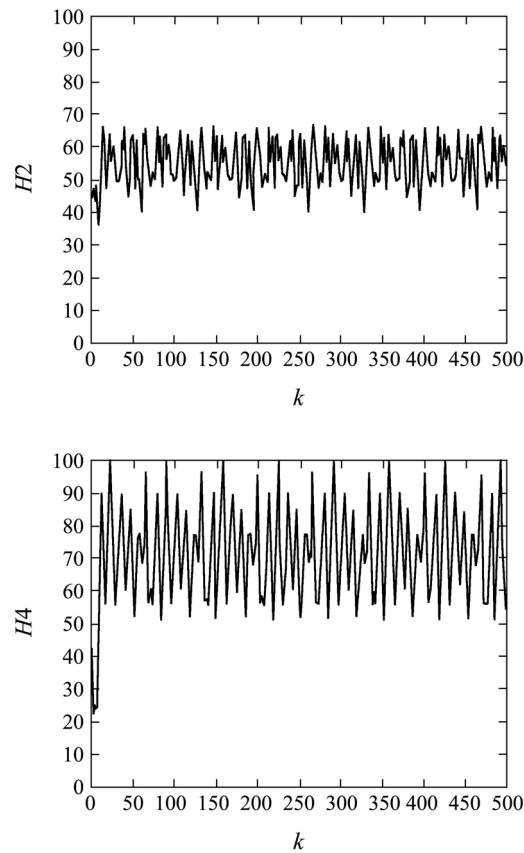
图2 双向限幅电路及其传输特性

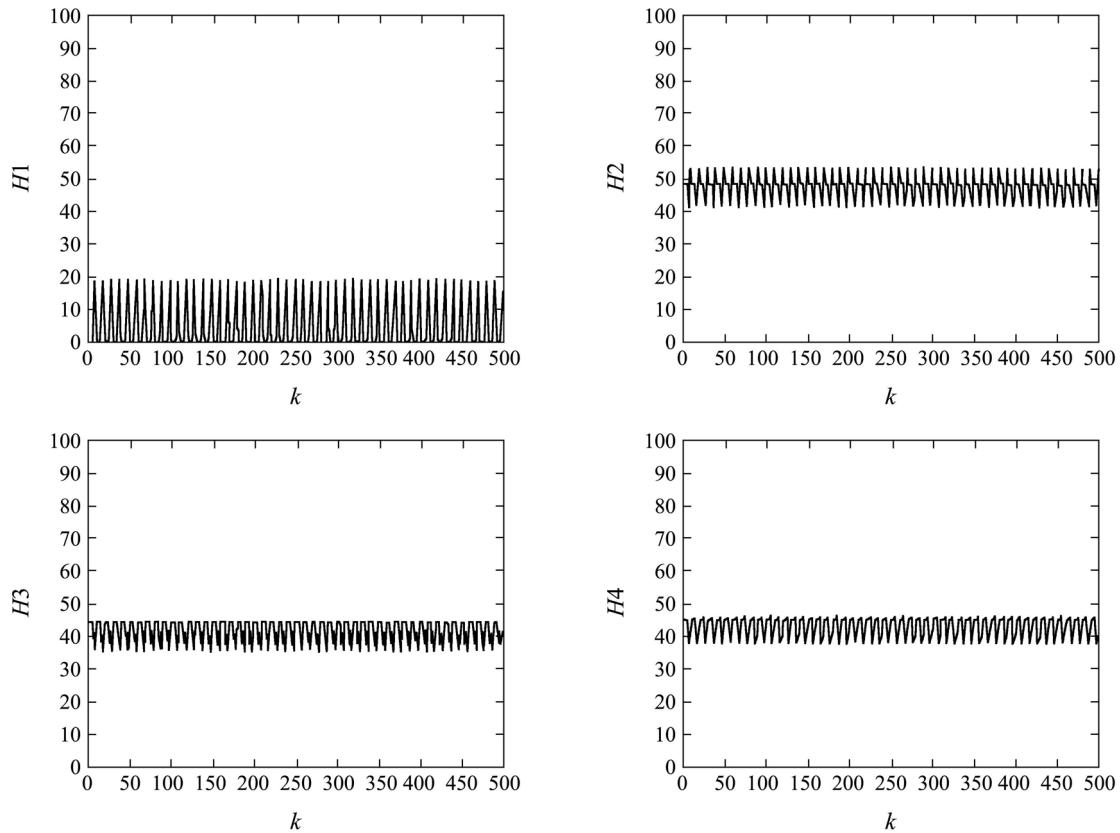
Fig. 2 A two-way limiter circuit and its transmission characteristics

表2表明, 一旦 $a \leq -13.75$ 或 $b \geq 13.75$ , 网络将不再收敛于目标模式或其逆模式. 图3和图4的仿真结果证明了以上结论的正确性.

## 5 仿真结果及其分析(The simulating results and its analysis )

下面本文将在满足以上对 $a$ 和 $b$ 大小的限制条件下, 选取一些 $a$ 和 $b$ 的不同取值, 进行仿真, 并对其结果进行分析, 见表3~15.



图4 当 $a = -1, b = 13.75$ 时, 网络输出与4个存储模式间的汉明距离Fig. 4 The Hamming distances between the output pattern of the network and the four stored patterns, when  $a = -1, b = 13.75$ 表3 当 $a = -13, b = 13$ 时, 网络输出Table 3 The output pattern of the network  
when  $a = -13, b = 13$ 

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^2$	$X^2$	不收敛	$X^2$	$X^2$	$X^2$

表4 当 $a = -12.5, b = 13$ 时, 网络输出Table 4 The output pattern of the network  
when  $a = -12.5, b = 13$ 

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^2$	$X^2$	$X^2$	$X^2$	$X^2$	$X^2$

表5 当 $a = -13, b = 12.5$ 时, 网络输出Table 5 The output pattern of the network  
when  $a = -13, b = 12.5$ 

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^2$	$X^2$	$X^2$	$X^2$	$X^2$	$X^2$

表6 当 $a = -12.5, b = 12$ 时, 网络输出Table 6 The output pattern of the network  
when  $a = -12.5, b = 12$ 

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^2$	$X^2$	$X^2$	$X^2$	$X^2$	$X^2$

表7 当 $a = -12, b = 12$ 时, 网络输出Table 7 The output pattern of the network  
when  $a = -12, b = 12$ 

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	不收敛	不收敛	不收敛	不收敛	$X^2$	不收敛

表8 当 $a = -11, b = 11.5$ 时, 网络输出Table 8 The output pattern of the network  
when  $a = -11, b = 11.5$ 

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$-X^1$	$X^2$	$X^3$	$-X^1$	$-X^2$	$X^3$

表9 当 $a = -11, b = 11$ 时, 网络输出Table 9 The output pattern of the network  
when  $a = -11, b = 11$ 

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$-X^1$	$X^2$	$X^3$	$-X^1$	$-X^2$	$X^3$

表10 当 $a = -10, b = 10$ 时, 网络输出Table 10 The output pattern of the network  
when  $a = -10, b = 10$ 

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$-X^1$	$X^2$	$X^3$	$-X^1$	$-X^2$	$X^3$

表 11 当  $a = -9.5, b = 9.5$  时, 网络输出  
Table 11 The output pattern of the network  
when  $a = -9.5, b = 9.5$

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^1$	$X^2$	$X^3$	$X^4$	$-X^2$	$X^1$

表 12 当  $a = -9, b = 9$  时, 网络输出  
Table 12 The output pattern of the network  
when  $a = -9, b = 9$

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^1$	$X^2$	$X^3$	$X^4$	$-X^2$	$X^1$

表 13 当  $a = -8, b = 8$  时, 网络输出  
Table 13 The output pattern of the network  
when  $a = -8, b = 8$

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^1$	$X^2$	$X^3$	$X^4$	$-X^2$	$X^4$

表 14 当  $a = -7, b = 7$  时, 网络输出  
Table 14 The output pattern of the network  
when  $a = -7, b = 7$

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^1$	$X^2$	$X^3$	$X^4$	$-X^2$	$X^4$

表 15 当  $a = -6, b = 6$  时, 网络输出  
Table 15 The output pattern of the network  
when  $a = -6, b = 6$

初始模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^5$	$X^6$
稳态模式	$X^1$	$X^2$	$X^3$	$X^4$	$X^3$	$X^4$

表5~7表明,  $a \leq -12, b \geq 12$  时, 网络要么不收敛, 收敛的话, 只会收敛到模式  $X^2$ . 这是因为模式  $X^2$  的参数  $L^p$  最大, 当  $a$  和  $b$  的绝对值取值较大时, 使得只有终态模式为  $X^2$  时, 网络收敛的条件才会满足.

表8~15表明, 网络收敛的终态模式是由两个因素参数  $a$  和  $b$  及初始模式与存储模式间的汉明距离共同决定的. 表8~10表明,  $a \leq -10, b \geq 10$  时, 参数  $a$  和  $b$  起着主导作用, 无论初始模式与某一存储模式间的汉明距离有多小, 即便是为零, 网络也不会收敛到这一存储模式.

只有当  $a$  和  $b$  的绝对值充分小时, 网络才会收敛于与初始模式间汉明距离最小的存储模式或其逆模式上.

观察以上仿真结果, 本文还发现, 随着参数  $a$  和  $b$  变化, 模式  $X^6$  可以收敛到存储模式  $X^1, X^2, X^3, X^4$  中的每一个模式. 这样就为利用混沌神经网络进行参数与存储模式间的匹配, 从而实现联想记忆功能提供了一种可能. 本文还发现, 初始模式为  $X^6$  时, 参数  $a$  和  $b$  绝对值取值的大小与待联想模式的参数  $L^p = \min_{1 \leq i \leq N} |H_i(x(t))|$  是正相关的, 相应的结果如表16所示.

表 16 当初始模式为  $X^6$  时, 网络的稳态输出对应的参数  
Table 16 The corresponding parameters of the steady output pattern of the network when initial pattern is  $X^6$

稳态模式	$X^2$	$X^3$	$X^1$	$X^4$
参数 $L^p$	11	10	9	9
$a$ 取值	-13	-10	-9	-8
$b$ 取值	13	10	9	8

这样本文提出如下图所示的利用混沌神经网络进行参数与存储模式匹配的模型, 如图4所示, 其中  $A^1, A^2, A^3, A^4$  分别为与存储模式  $X^1, X^2, X^3, X^4$  对应的参数组的取值.

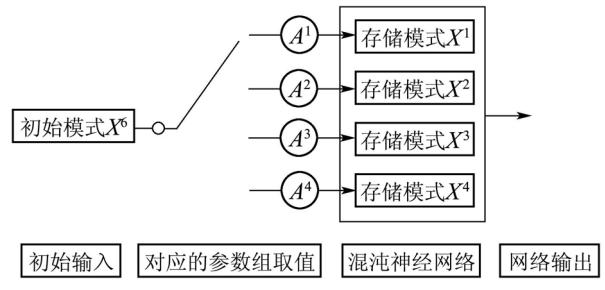


图 5 混沌神经网络实现参数与存储模式匹配模型

Fig. 5 Pattern matching using chaotic neural network

## 6 结论(Conclusion)

相空间压缩控制方法简单易行, 物理含义明确, 而且不需要预先知道控制目标. 本文通过逻辑推理和数学论证, 得到了相空间压缩控制方法中对应参数的上下限, 使得参数的选取更具指导性. 并通过对仿真结果的分析, 提出了通过改变相空间压缩控制方法中对应的参数来实现混沌神经网络联想记忆的新方法.

## 参考文献(References):

- [1] ADACHI M, AIHARA K. Associative dynamics in a chaotic neural network[J]. *Neural Networks*, 1997, 10(1): 83 – 98.
- [2] HERNANDEZ E D M, SANDMANN H, ARAUJO G. Context dependent pattern recognition — a framework for hybrid architectures

- bridging chaotic neural networks based on recursive processing elements and symbolic information[C] //Proceedings of International Joint Conference on Neural Networks. New York: IEEE, 2009: 663 – 670.
- [3] AIHARA K. Chaos engineering and its application to parallel distributed processing with chaotic neural networks[J]. *Proceedings of the IEEE*, 2002, 90(5): 919 – 930.
- [4] CHEN L N, AIHARA K. Chaotic simulated annealing by a neural network model with transient chaos[J]. *Neural Networks*, 1995, 8(6): 915 – 930.
- [5] KWOK T, SMITH K A. Experimental analysis of chaotic neural network models for combinatorial optimization under a unifying framework[J]. *Neural Networks*, 2000, 13(7): 731 – 744.
- [6] MIRZAEI A, SAFABAKHSH R. Optimal matching by the transiently chaotic neural network[J]. *Applied Soft Computing*, 2009, 9(3): 863 – 873.
- [7] 徐耀群, 孙明. Shannon小波混沌神经网络及其TSP(城市旅行商)问题的求解[J]. 控制理论与应用, 2008, 25(3): 574 – 577.  
(XU Yaoqun, SUN Ming. Shannon wavelet chaotic neural network and its solution to TSP(traveling salesman problem)[J]. *Control Theory & Applications*, 2008, 25(3): 574 – 577.)
- [8] ISHII S, FUKUMIZU K, WATANABE S. A network of chaotic elements for information processing[J]. *Neural Networks*, 1996, 9(1): 25 – 40.
- [9] AIHARA K, TAKABE T, TOYODA M. Chaotic neural networks[J]. *Physics Letters A*, 1990, 144(6/7): 333 – 340.
- [10] ADACHI M, AIHARA K, KQTANI M. An analysis of associative dynamics in a chaotic neural network with external stimulation[C] //Proceedings of International Joint Conference on Neural Networks. New York: IEEE, 1993: 409 – 412.
- [11] HE G G, CAO Z T, PING Z, et al. Controlling chaos in a chaotic neural network[J]. *Neural Networks*, 2003, 16(8): 1195 – 1200.
- [12] HE G G, CAO Z T, CHEN H P, et al. Controlling chaos in a neural network based on the phase space constraint[J]. *International Journal of Modern Physics B*, 2003, 17(22/24): 4209 – 4214.
- [13] HE G G, SHRIMALI M D, AIHARA K. Threshold control of chaotic neural network[J]. *Neural Networks*, 2008, 21 (2/3): 114 – 121.
- [14] ZHANG X, SHEN K. Controlling spatiotemporal chaos via phase space compression[J]. *Physical Review E*, 2001, 63(4): 1 – 6.

### 作者简介:

缪志强 (1989—), 男, 研究方向为混沌控制、混沌神经网络, E-mail: miaozhiqiang33@126.com;

王耀南 (1957—), 男, 教授, 博士生导师, 研究方向为智能控制理论、与机器视觉应用等, E-mail: yaonan@hnu.cn.