

文章编号: 1001-0920(2006)07-0771-05

## 动态突触型 Hopfield 神经网络的动态特性研究

王直杰, 范 宏, 严 晨

(东华大学 信息科学与技术学院, 上海 200051)

**摘 要:** 提出一种基于动态突触的离散型 Hopfield 神经网络(DSDNN)模型, 给出了DSDNN 的连接权值的动态演化模型及其神经元的状态更新模型 证明了DSDNN 的平衡点与常规离散型 Hopfield 神经网络的平衡点具有一一对应的关系, 分析了平衡点的稳定性 最后通过仿真分析了DSDNN 的动态演化特性与其参数的关系

**关键词:** 动态突触; 神经网络; 平衡点

**中图分类号:** TP183 **文献标识码:** A

## Dynamics of Hopfield Neural Networks with Dynamic Synapses

WANG Zhi-jie, FAN Hong, YAN Chen

(College of Information Science and Technology, Donghua University, Shanghai 200051, China Correspondent: WANG Zhi-jie, E-mail: wangzj@dhu.edu.cn)

**Abstract:** A discrete Hopfield neural network model with dynamic synapses (DSDNN) is proposed. The model of the dynamical connection weight and the updating scheme of the states of neurons are given. It is proved that each equilibrium of DSDNN corresponds to one equilibrium of a traditional discrete Hopfield neural network, and each equilibrium of a traditional discrete Hopfield neural network corresponds to one of DSDNN. The stability of the equilibrium is analyzed. The relationship between the dynamic characteristic of the DSDNN and its parameters is also analyzed by simulation.

**Key words:** Dynamic synapses; Neural networks; Equilibrium

### 1 引 言

在人工神经网络的理论和应用的研究中, 大多假设神经元与神经元之间的连接权值是静态的。静态连接权假设当前神经元的状态对连接权值的影响是长时间效应, 即神经元的状态要在几小时或几天后才影响连接权值, 因此一旦连接权值学习确定后, 便认为权值是固定不变的。然而神经生理学的研究表明, 神经元与神经元之间信息传递的连接点——突触是动态的<sup>[1,2]</sup>。当前神经元的状态对权值的影响不仅具有长时间效应, 而且具有短时间效应<sup>[3]</sup>。即神经元的兴奋或抑制状态能立即反映突触的信息传递效率(权值)的变化, 具有秒级甚至毫秒级的时间效应, 因此权值是动态变化的。这种变化可能是增强突

触信息传递的, 也可能是抑制突触信息传递的<sup>[4]</sup>。

近年来, 结合动态突触的神经网络的联想记忆特性以及平衡点问题<sup>[5,6]</sup>引起人们的兴趣, 采用动态突触的神经网络的应用研究及其硬件实现问题<sup>[7,8]</sup>也开始兴起。例如动态突触应用于多维信号的聚类, 语音信号的分析 and 识别, 图象的预处理<sup>[9,10]</sup>等。本文研究具有动态突触的神经网络的平衡点分布、平衡点的稳定性及其动态特性。首先提出具有抑制型动态突触的离散型 Hopfield 神经网络(DSDNN)模型及其伴随神经网络模型, 并证明DSDNN 及其伴随神经网络模型具有一一对应的平衡点, 然后分析DSDNN 平衡点的稳定性, 最后通过仿真研究DSDNN 的动态演化特性与其参数的关系。

收稿日期: 2005-06-01; 修回日期: 2005-11-11

基金项目: 上海市优秀青年教师后备人员基金项目(03YQHB074)。

作者简介: 王直杰(1969—), 男, 浙江临海人, 副教授, 博士, 从事神经网络、模糊系统等研究; 范宏(1971—), 女, 辽宁大石桥人, 讲师, 博士生, 从事神经网络、模糊系统的研究。

## 2 具有抑制型动态突触的离散型 Hopfield 神经网络模型

由  $N$  个神经元相连组成的异步更新的离散型 Hopfield 神经网络可描述为<sup>[11,12]</sup>

$$x_i(t+1) = f \left[ \sum_{j=1}^i w_{ij}^c x_j(t+1) + \sum_{j=i+1}^N w_{ij}^c x_j(t) + I_i \right], \quad i = 1, 2, \dots, N; \quad (1)$$

$$x_i(t+1) = f(u) = \begin{cases} 1, & u > 0; \\ 0, & u < 0; \\ x_i(t), & u = 0 \end{cases} \quad (2)$$

其中:  $x_i$  为第  $i$  个神经元的输出, 它只取 0 或 1 两种情况;  $I_i$  为第  $i$  个神经元的外部输入;  $\left[ \sum_{j=1}^i w_{ij}^c x_j(t+1) + \sum_{j=i+1}^N w_{ij}^c x_j(t) \right]$  为来自其他神经元的输入;  $w_{ij}$  为第  $j$  个神经元到第  $i$  个神经元的连接权值,  $w_{ij} = w_{ji}$ ,  $w_{ii} = 0$

在通常的神经网络模型中, 权值  $w_{ij}$  在网络的演化过程中保持不变 然而神经生理学的研究表明, 连接神经元与神经元之间的突触是动态变化的, 因此权值  $w_{ij}$  是动态变化的 当神经元  $i$  处于激活状态时, 传递信息的突触资源(如神经发射囊)发生了变化, 而这些资源的恢复需要一定的时间, 从而造成突触信息传递能力的变化

引入文献[5]的抑制型动态突触的模型, 描述具有抑制型动态突触的离散型 Hopfield 神经网络模型(DSDNN), 有

$$x_i(t+1) = f \left[ \sum_{j=1}^i w_{ij}(t+1)x_j(t+1) + \sum_{j=i+1}^N w_{ij}(t)x_j(t) + I_i \right], \quad (3)$$

$$w_{ij}(t) = w_{ij}^c r_j(t), \quad (4)$$

$$r_i(t+1) = r_i(t) + \frac{1-r_i(t)}{\tau} - U x_i(t) r_i(t). \quad (5)$$

其中: 动态权值  $w_{ij}(t)$  为两部分的乘积,  $w_{ij}^c$  为权值的静态部分, 其学习方法与通常的 Hopfield 网络的权值学习方法相同;  $r_i(t)$  为可用的突触资源,  $r_i(t) = 1$  表示所有的突触资源都可用;  $U x_i(t) r_i(t)$  表示当  $x_i(t) = 1$  时, 在每一时间步, 突触的可用资源  $r_i(t)$  将减少  $U r_i(t)$ ,  $0 < U < 1$ ; 同时突触的不可用资源  $(1 - r_i(t))$  将有  $\frac{1-r_i(t)}{\tau}$  恢复为可用,  $\tau > 1$

如式(3)所示, DSDNN 状态的更新采用异步更新的方式 根据式(5), 当  $x_i$  一直为 1 时,  $r_i(t)$  有一平

衡点  $r_i^* = \beta$  此时  $\frac{1-r_i^*}{\tau} = U x_i(t) \beta = U \beta$ , 因而

$$\beta = \frac{1}{1+U\tau} \quad (6)$$

根据式(3)~(6), 设计一个异步更新的常规离散 Hopfield 神经网络模型

$$x_i(t+1) = f \left[ \sum_{j=1}^i w_{ij}^c x_j(t+1) + \sum_{j=i+1}^N w_{ij}^c x_j(t) + \beta I_i \right] \quad (7)$$

由式(7)描述的神经网络称为式(3)~(5)描述的 DSDNN 的伴随神经网络

## 3 具有抑制型动态突触的离散型 Hopfield 神经网络的平衡点

设  $x^* = (x_1^*, x_2^*, \dots, x_N^*)$  为由式(7)确定的异步更新的常规离散型 Hopfield 神经网络的平衡点, 则

$$\begin{cases} \sum_{j=1}^N w_{ij}^c x_j^* + \beta I_i & 0, x_i^* = 1; \\ \sum_{j=1}^N w_{ij}^c x_j^* + \beta I_j & 0, x_i^* = 0; \end{cases} \quad i = 1, 2, \dots, N. \quad (8)$$

关于 DSDNN 的平衡点的性质, 有如下定理:

**定理 1** 设  $y^* = (x_1^*, x_2^*, \dots, x_N^*, r_1^*, r_2^*, \dots, r_N^*)$  为由式(3)~(5)确定的 DSDNN 的平衡点, 则

$$\begin{cases} \sum_{j=1}^N w_{ij}^c \beta x_j^* + I_i & 0, r_i^* = \beta, x_i^* = 1; \\ \sum_{j=1}^N w_{ij}^c \beta x_j^* + I_i & 0, r_i^* = 1, x_i^* = 0; \end{cases} \quad i = 1, 2, \dots, N. \quad (9)$$

证明 根据式(5), 有  $\frac{1-r_i^*}{\tau} - U x_i^* r_i^* = 0$ , 则

$$r_i^* = \begin{cases} \beta, & x_i^* = 1; \\ 1, & x_i^* = 0; \end{cases} \quad i = 1, 2, \dots, N. \quad (10)$$

根据式(3)和(4), 有  $x_i^* = f \left[ \sum_{j=1}^N w_{ij}^c r_j^* x_j^* + I_i \right]$ , 因而

$$x_i^* = f \left[ \sum_{j=1}^N w_{ij}^c \beta x_j^* + I_i \right] \text{ 所以 } \begin{cases} \sum_{j=1}^N w_{ij}^c \beta x_j^* + I_i & 0, x_i^* = 1; \\ \sum_{j=1}^N w_{ij}^c \beta x_j^* + I_i & 0, x_i^* = 0; \end{cases} \quad i = 1, 2, \dots, N. \quad (11)$$

根据式(10)和(11), 有式(9)成立

**引理 1** 设  $x^* = (x_1^*, x_2^*, \dots, x_N^*)$  为式(7)确定的 DSDNN 的伴随神经网络的平衡点, 则  $y^* = (x_1^*, x_2^*, \dots, x_N^*, r_1^*, r_2^*, \dots, r_N^*)$  为 DSDNN 的平衡

点, 其中  $r_i^*$  如式(10) 所示

证明 因为  $x^* = (x_1^*, x_2^*, \dots, x_N^*)$  为式(7) 确定的神经网络的平衡点, 所以式(8) 成立, 从而式(11) 成立 取  $r_i^*$  如式(10) 所示, 则

$$\begin{cases} \frac{1-r_i^*}{\tau} - U x_i^* r_i^* = \\ \left\{ \begin{array}{l} \frac{1-\beta}{\tau} - U \beta = 0, x_i^* = 1; \\ \frac{1-1}{\tau} - 0 = 0, x_i^* = 0; \end{array} \right. \\ i = 1, 2, \dots, N. \end{cases} \quad (12)$$

根据式(11) 和(12), 引理得证

引理 2 设  $y^* = (x_1^*, x_2^*, \dots, x_N^*, r_1^*, r_2^*, \dots, r_N^*)$  为 DSDNN 的平衡点, 则  $x^* = (x_1^*, x_2^*, \dots, x_N^*)$  为其伴随神经网络的平衡点

证明 因为  $y^* = (x_1^*, x_2^*, \dots, x_N^*, r_1^*, r_2^*, \dots, r_N^*)$  为 DSDNN 的平衡点, 根据定理 1, 有式(11) 成立, 所以  $x^* = (x_1^*, x_2^*, \dots, x_N^*)$  为其伴随神经网络的平衡点

定理 2 DSDNN 的平衡点  $y^*$  与式(7) 确定的伴随神经网络的平衡点  $x^*$  具有一一对应关系

证明由引理 1 和引理 2 显然易得 设

$$u_i(t+1) = \sum_{j=1}^i w_{ij}(t+1)x_j(t+1) + \sum_{j=i+1}^N w_{ij}(t)x_j(t) + I_i$$

为第  $i$  个神经元的输入, 则当  $y^* = (x_1^*, x_2^*, \dots, x_N^*, r_1^*, r_2^*, \dots, r_N^*)$  为 DSDNN 的平衡点时,  $z^* = (u_1^*, u_2^*, \dots, u_N^*, r_1^*, r_2^*, \dots, r_N^*)$  可表示 DSDNN 的平衡点

下面讨论平衡点  $z^* = (u_1^*, u_2^*, \dots, u_N^*, r_1^*, r_2^*, \dots, r_N^*)$  的稳定性问题

引理 3 设  $z^* = (u_1^*, u_2^*, \dots, u_N^*, r_1^*, r_2^*, \dots, r_N^*)$  为 DSDNN 的平衡点,  $\forall i, u_i^* \neq 0$  如果  $u_i(k) = u_i^*, k = 1, 2, \dots, M$ , 则对任一初始状态  $r_i(1) \in (0, 1]$ , 有

$$\begin{aligned} |r_i(k) - r_i^*| &< |r_i(k-1) - r_i^*|, \\ k &= 2, 3, \dots, M. \end{aligned} \quad (13)$$

且  $\lim_M |r_i(M) - r_i^*| = 0$

证明 如果  $u_i^* < 0$ , 则  $x_i^* = 0, r_i^* = 1$  根据式(5), 有

$$r_i(k) = r_i(k-1) + \frac{1-r_i(k-1)}{\tau}$$

由于  $\tau > 1$ , 显然有式(13) 成立

如果  $u_i^* > 0$ , 则由式(6) 有

$$r_i^* = \frac{1}{1+\tau}, x_i^* = 1$$

下面分两种情况讨论:

第 1 种情况:  $u_i^* > 0, r_i(k-1) > \frac{1}{1+\tau}$

因为  $r_i(k-1) > \frac{1}{1+\tau}$ , 所以

$$\frac{1-r_i(k+1)}{\tau} - U r_i(k-1) < 0 \quad (14)$$

由于  $x_i^* = 1$ , 根据式(5), 有

$$r_i(k) = r_i(k-1) + \frac{1-r_i(k-1)}{\tau} - U r_i(k-1)$$

若  $r_i(k) - r_i^* > 0$ , 则

$$\begin{aligned} |r_i(k) - r_i^*| &= r_i(k-1) + \frac{1-r_i(k-1)}{\tau} - \\ &U r_i(k-1) - r_i^* \end{aligned}$$

根据式(14), 有  $|r_i(k) - r_i^*| < r_i(k-1) - r_i^*$ , 因而式(13) 成立

若  $r_i(k) - r_i^* < 0$ , 则

$$\begin{aligned} |r_i(k) - r_i^*| &= \\ &r_i(k-1) - \frac{1-r_i(k-1)}{\tau} + \\ &U r_i(k-1) + r_i^* \end{aligned} \quad (15)$$

因为  $r_i(k-1) > \frac{1}{1+\tau}, r_i^* = \frac{1}{1+\tau}$ , 所以

$$\begin{aligned} 2(r_i^* - r_i(k-1)) &< \\ \frac{1-r_i(k-1)}{\tau} - U r_i(k-1) \end{aligned}$$

因而

$$\begin{aligned} -r_i(k-1) - \frac{1-r_i(k-1)}{\tau} + \\ U r_i(k-1) + r_i^* < r_i(k-1) - r_i^* \end{aligned}$$

根据式(15), 有式(13) 成立

第 2 种情况:  $u_i^* > 0, r_i(k-1) < \frac{1}{1+\tau}$

类似于第 1 种情况的计算, 可知式(13) 成立 根据式(5), 显然  $\lim_k r_i(k) = r_i^*$ , 故  $\lim_M |r_i(M) - r_i^*| = 0$  因而引理得证

定理 3 设  $z^* = (u_1^*, u_2^*, \dots, u_N^*, r_1^*, r_2^*, \dots, r_N^*)$  为 DSDNN 的平衡点,  $\forall i, u_i^* \neq 0$ , 则  $\exists \delta > 0$ , 当  $z(t_0) - z^* < \delta$  时,  $\lim_t z(t) - z^* = 0$

证明 取

$$\begin{aligned} \delta_1 &= \min_{i \in \{1, 2, \dots, N\}} (|u_i^*|), \delta_2 = \max_{i, j \in \{1, 2, \dots, N\}} (|w_{ij}^c|), \\ \delta_3 &= \max_{i=1}^N |x_i^*|, \delta = \min(\frac{\delta_1}{\delta_2 \delta_3}, \delta_1) \end{aligned}$$

因为  $\delta = \min(\frac{\delta_1}{\delta_2 \delta_3}, \delta_1)$ , 所以

$$|u_i(t_0) - u_i^*| \quad z(t_0) - z^* <$$

$\delta \quad \delta_1 \quad |u_i^*|$   
 从而  $\forall i, \text{sign}(u_i(t_0)) = \text{sign}(u_i^*)$ , 因此  $\forall i, x_i(t_0) = x_i^*$ .

当  $i = 1$  时, 有

$$|u_1(t_0 + 1) - u_1^*| = \left| \sum_{j=1}^N w_{1j}^c (r_j(t_0) - r_j^*) x_j^* \right|,$$

因而

$$\left| \sum_{j=1}^N w_{1j}^c \delta x_j^* \right| \leq \sum_{j=1}^N |\delta_2 \delta x_j^*| = \delta \delta_2 \delta_3 \quad (16)$$

因为  $\delta = \min(\frac{\delta_1}{\delta_2 \delta_3}, \delta_1)$ , 所以

$$\delta \delta_2 \delta_3 \frac{\delta_1}{\delta_2 \delta_3} \delta_2 \delta_3 = \delta_1 \quad (17)$$

因此

$$|u_1(t_0 + 1) - u_1^*| \leq \delta_1 |u_1^*| \quad (18)$$

从而  $\text{sign}(u_1(t_0 + 1)) = \text{sign}(u_1^*)$ , 故  $x_1(t_0 + 1) = x_1^*$ .

设  $i = p - 1, x_i(t_0 + 1) = x_i^*$ , 当  $i = p$  时, 有

$$|u_p(t_0 + 1) - u_p^*| = \left| \sum_{j=1}^p w_{pj}^c (r_j(t_0 + 1) - r_j^*) x_j^* \right| + \left| \sum_{j=p+1}^N w_{pj}^c (r_j(t_0) - r_j^*) x_j^* \right|$$

根据引理 3, 有

$$\left| u_p(t_0 + 1) - u_p^* \right| \leq \sum_{j=1}^p |w_{pj}^c (r_j(t_0) - r_j^*) x_j^*|$$

类似于式(16) ~ (18) 的计算, 可得  $x_p(t_0 + 1) = x_p^*$ . 所以

$$\forall i, x_i(t_0 + 1) = x_i^* \quad (19)$$

下面计算  $x_i(t_0 + 2)$ . 当  $i = 1$  时, 有

$$|u_1(t_0 + 2) - u_1^*| = \left| \sum_{j=1}^N w_{1j}^c r_j(t_0 + 1) x_j(t_0 + 1) + I_1 - \sum_{j=1}^N w_{1j}^c r_j^* x_j^* - I_1 \right|$$

根据式(19), 有

$$|u_1(t_0 + 2) - u_1^*| = \left| \sum_{j=1}^N w_{1j}^c (r_j(t_0 + 1) - r_j^*) x_j^* \right| \quad (20)$$

根据引理 3, 有

$$\left| u_1(t_0 + 2) - u_1^* \right| \leq \sum_{j=1}^N |w_{1j}^c (r_j(t_0) - r_j^*) x_j^*| \quad (21)$$

由式(16)和(17)得  $|u_1(t_0 + 2) - u_1^*| \leq \delta_1$

$|u_1^*|$  所以  $\text{sign}(u_1(t_0 + 2)) = \text{sign}(u_1^*)$ . 因而  $x_1(t_0 + 2) = x_1^*$ .

设  $i = p - 1, x_i(t_0 + 2) = x_i^*$ , 当  $i = p$  时, 有

$$|u_p(t_0 + 2) - u_p^*| = \left| \sum_{j=1}^p w_{pj}^c (r_j(t_0 + 2) - r_j^*) x_j^* \right| + \left| \sum_{j=p+1}^N w_{pj}^c (r_j(t_0 + 1) - r_j^*) x_j^* \right|$$

由引理 3 得

$$\left| u_p(t_0 + 2) - u_p^* \right| \leq \sum_{j=1}^p |w_{pj}^c (r_j(t_0 + 1) - r_j^*) x_j^*|$$

类似于式(20)和(21)的计算, 可得  $x_p(t_0 + 2) = x_p^*$ . 所以  $\forall i, x_i(t_0 + 2) = x_i^*$ .

类似于  $x_i(t_0 + 2)$  的计算, 则得  $x_i(t_0 + 3) = x_i^*, x_i(t_0 + 4) = x_i^*, \dots$  所以

$$\lim_t z(t) = z^* \quad \lim_{i=1}^N \sqrt{(1 + N \delta_2^2) [r_i(t - 1) - r_i^*]^2}$$

根据引理 3,  $\lim_t |r_i(t) - r_i^*| = 0$ , 所以  $\lim_t z(t) = z^* = 0$  因而定理得证

定理 3 表明, 当所有神经元处于平衡点时, 输入都不为 0, 此平衡点是渐近稳定的

### 4 仿真分析

从任一初始状态出发的异步更新的常规离散型 Hopfield 神经网络, 将沿着能量函数下降的方向演化到某一平衡点<sup>[11, 12]</sup>. 定理 2 表明, DSDNN 的平衡点与常规离散型 Hopfield 神经网络的平衡点具有一一对应关系. 那么从任一初始状态出发的 DSDNN 能否演化到平衡点? 本文通过仿真对此进行研究

为使仿真结果更具一般性, 设 DSDNN 的静态权值  $w_{ij}^c$  和外部输入  $I_i$  随机分布, 并设  $w_{ij}^c$  均匀分布于  $[-C_w, C_w]$ ,  $I_i$  均匀分布于  $[0, C_I]$ , 其中  $C_w$  和  $C_I$  为大于 0 的常数. 每次仿真的初始状态是随机的(神经元和突触的状态都是随机的), 如果仿真步数超过 5 000 仍没有演化到平衡点, 则停止本次仿真. DSDNN 的参数有  $C_w, C_I, \tau, U$  以及神经元的数量  $N$ , 本文分 3 种情况研究 DSDNN 的演化特性与这些参数的关系

#### 4.1 DSDNN 的演化特性与神经元数量 N 的关系

表 1 显示的是当参数  $C_w, C_I, \tau, U$  固定时, DSDNN 的演化特性与  $N$  的关系. 设置  $C_w = 0.5, C_I = 0.25, \tau = 30, U = 0.3$ . 表 1 中的数据是对每一  $N$  值作 100 次仿真, DSDNN 演化到平衡点的次数. 从



表中可以看出, 当  $N$  较小时, DSDNN 能演化到平衡点; 随着  $N$  的增大, DSDNN 变得越来越难以演化到平衡点

表 1 DSDNN 演化到平衡点的次数与神经元数量  $N$  的关系

$N$	20	40	60	80	100	120	140
演化到平衡点的次数	100	85	82	78	31	12	5

#### 4.2 DSDNN 的演化特性与 $C_w$ 和 $C_l$ 的关系

表 2 显示的是当  $C_w = 0.5, N = 100, \tau = 30, U = 0.3$  时, DSDNN 的演化特性与  $C_l$  的关系; 表 3 显示的是当  $C_l = 0.25, N = 100, \tau = 30, U = 0.3$  时, DSDNN 的演化特性与  $C_w$  的关系。表中的每一数据都是作 100 次仿真, DSDNN 演化到平衡点的次数。从表中数据可以看出, 当  $C_w$  较小而  $C_l$  较大时, DSDNN 容易演化到平衡点。

表 2 DSDNN 演化到平衡点的次数与参数  $C_l$  的关系

$C_l$	1	0.7	0.5	0.4	0.3	0.2	0.1
演化到平衡点的次数	98	62	56	52	32	31	34

表 3 DSDNN 演化到平衡点的次数与参数  $C_w$  的关系

$C_w$	0.1	0.2	0.3	0.4	0.5	1.0	1.5
演化到平衡点的次数	96	67	45	38	33	36	32

#### 4.3 DSDNN 的演化特性与 $\tau$ 和 $U$ 的关系

表 4 显示的是当  $\tau = 30, N = 100, C_l = 0.25, C_w = 0.5$  时, DSDNN 的演化特性与  $U$  的关系; 表 5 显示的是当  $U = 0.3, N = 100, C_l = 0.25, C_w = 0.5$  时, DSDNN 的演化特性与  $\tau$  的关系。表中的每一数据都是作 100 次仿真, DSDNN 演化到平衡点的次数。从表中数据可以看出, 当参数  $\tau$  和  $U$  较小时, DSDNN 容易演化到平衡点。

表 4 DSDNN 演化到平衡点的次数与参数  $U$  的关系

$U$	0.1	0.15	0.2	0.25	0.3	0.4	0.5
演化到平衡点的次数	95	84	59	40	29	32	35

表 5 DSDNN 演化到平衡点的次数与参数  $\tau$  的关系

$\tau$	10	15	20	25	30	35	40
演化到平衡点的次数	98	71	42	45	36	34	26

## 5 结 论

绝大多数神经网络模型都假设连接权值是静态的, 即当权值学习结束后, 在网络的演化或使用中权值是固定不变的。然而神经生理学研究表明, 连接权值是动态变化的。因此研究具有动态权值的神经网络的动态特性成为这类网络的重要基础。本文提出一种基于动态突触的离散 Hopfield 模型 (DSDNN), 证明了 DSDNN 与常规的离散 Hopfield

模型具有一一对应的平衡点, 并分析了平衡点的稳定性。仿真结果表明, 当 DSDNN 的神经元数目较少, 或神经元连接强度较弱而输入较强, 或参数  $\tau$  和  $U$  较小时, DSDNN 比较容易演化到平衡点。

## 参考文献 (References)

- [1] Markram H, Tsodyks M. Redistribution of Synaptic Efficacy between Neocortical Pyramidal Neurons [J]. *Nature*, 1996, 382: 807-810.
- [2] Abbott L F, Varela J A, Sen K, et al. Synaptic Depression and Cortical Gain Control [J]. *Science*, 1997, 275: 220-224.
- [3] Amari S, Albert A M, Costas P. A Model Synapse That Incorporates Properties of Short- and Long-term Synaptic Plasticity [J]. *Neural Networks*, 2003, 16(8): 1161-1177.
- [4] Kistler W M. Short-term Synaptic Plasticity and Network Behavior [J]. *Neural Computation*, 1999, 11(7): 1579-1594.
- [5] Pantic L, Torres J J, Kappen H J, et al. Associative Memory with Dynamic Synapses [J]. *Neural Computation*, 2002, 14(12): 2903-2923.
- [6] Bibitchkov D, Hermann J M, Geisel T. Pattern Storage and Processing in Attractor Networks with Short-time Synaptic Dynamics [J]. *Neural Computation in Neural Systems*, 2002, 13(1): 115-129.
- [7] Liu S C. Analog VLSI Circuits for Short-term Dynamic Synapses [J]. *Eurasip J on Applied Signal Processing*, 2003, (7): 620-628.
- [8] Kanazawa Y, Asai T, Ikebe M, et al. A Novel CMOS Circuit for Depressing Synapse and Its Application to Contrast-invariant Pattern Classification and Synchrony Detection [J]. *Int J of Robotics and Automation*, 2004, 19(4): 206-212.
- [9] Nager C, Storck J, Geco G. Speech Recognition with Spiking Neurons and Dynamic Synapses: A Model Motivated by the Human Auditory Pathway [J]. *Neurocomputing*, 2002, 44-46: 937-942.
- [10] Mehrtash N, Jung D, Klar H. Image Preprocessing with Dynamic Synapses [J]. *Neural Computing and Applications*, 2003, 12(1): 33-41.
- [11] Aiyer S V B, Niranjan M, Fallside F. A Theoretical investigation into the Performance of the Hopfield Model [J]. *IEEE Trans on Neural Networks*, 1990, 1(2): 204-215.
- [12] Hopfield J J, Tank D W. Neural Computation of Decisions in Optimization Problems [J]. *Biological Cybernetics*, 1985, 52(3): 141-152.