



XI'AN JIAOTONG UNIVERSITY

第三章 Hopfield神经网络

- 引言
- Hopfield人工神经网络的电路模型及其能量函数
- Hopfield人工神经网络A/D变换器
- Hopfield人工神经网络用于求解TSP
- Hopfield人工神经网络用于求解货流问题
- Hopfield人工神经网络用于联想记忆
- 双向联想记忆
- 小结

2004-8-8
《神经网络导论》——Hopfield神经网络
3-1



XI'AN JIAOTONG UNIVERSITY

§ 3.1 引言

1982年到1986年，美国物理学家Hopfield在美国科学院院刊上陆续发表了几篇论文，提出了反馈神经网络理论，报导了相应的研究成果，成为新一轮神经网络研究高潮的标志。因此，把这种单层反馈网络称为Hopfield网络。

下表是Hopfield网络和前向多层网络的简单比较。

	前向多层网络	Hopfield 网络
网络连接形式	不含反馈连接	包含反馈连接
输出输入关系	简单映射关系，不考虑滞后效应	要考虑输出输入间的延迟，要用差分或微分方程描述
学习算法	误差修正法（BP算法），收敛慢	Hebb 规则，收敛快
应用（功能）	分类、联想	分类、联想、优化计算
稳定性理论	分析简单	分析复杂

2004-8-8
《神经网络导论》——Hopfield神经网络
3-2



XI'AN JIAOTONG UNIVERSITY

§ 3.1 引言

Hopfield的主要贡献有：

- <1> 提出了利用能量函数研究反馈网络稳定状态的方法。
- <2> 给出了利用模拟电子线路实现反馈型人工神经网络的电路模型。
- <3> 成功求解了人工智能的典型难题——TSP问题。

以此为基础，人们对Hopfield网络进行了深入研究，主要有以下几个方面：寻找Hopfield网络的稳定性规律并进而研究其信息容量；提出各种改进的Hopfield网络模型；参照Hopfield电子线路模型研究人工神经网络的硬件实现方法；借助能量函数方法用Hopfield网络求解优化计算、组合数学、人工智能问题的多种实例。

本章主要讨论Hopfield人工神经网络的网络模型，以及其在优化计算、联想记忆方面的应用，并简单介绍Hopfield网络的稳定性问题。

2004-8-8
《神经网络导论》——Hopfield神经网络
3-3



XI'AN JIAOTONG UNIVERSITY

§ 3.2 Hopfield人工神经网络的电路模型及其能量函数

一、电路模型

Hopfield用模拟电子线路构造了反馈型人工神经网络的电路模型，如图3-1所示。电路中的基本元件如下：




图3-1 Hopfield神经网络电路模型

2004-8-8
《神经网络导论》——Hopfield神经网络
3-4

§ 3.2 Hopfield人工神经网络的电路模型及其能量函数

XI'AN JIAOTONG UNIVERSITY

1. 用具有正、反向输出的运算放大器模仿神经元的非线性函数关系。第 i 个神经元输出电压 V_i 与输入电压 u_i 之间的关系为S形函数，如图3-2所示。

$$V_i = f_i(u_i) = \frac{1}{2} \left[1 + \tanh\left(\frac{u_i}{u_0}\right) \right] = \frac{1}{1 + e^{-2u_i/u_0}}$$

u_0 是归一化基准值。当 $u_0 \rightarrow 0$ 时, f_i 成为硬限幅函数。

2. 输入电容 C_i 和电阻 R_i ，决定着电路的时间常数，它使放大器的输出相对于输入有一定的延时，这可以用来模仿神经元的动态特性。

3. 连接电导 w_{ij} ，是第 j 个神经元的输出和第 i 个神经元的输入之间的连接电导，

图3-2 神经元特性曲线

2004-8-8 《神经网络导论》——Hopfield神经网络 3-5

§ 3.2 Hopfield人工神经网络的电路模型及其能量函数

XI'AN JIAOTONG UNIVERSITY

它模仿神经元之间的突触作用。也可以用电阻 R_{ij} 来表示, $R_{ij} = 1/w_{ij}$ 。

4. 外加偏置电流 I_i ，模仿神经元的阈值作用。

图3-3是第 i 个神经元输入节点处元件的相互连接关系，显然，由KCL定律我们可得：

$$\sum_j w_{ij}(V_j - u_i) + I_i = C_i \frac{du_i}{dt} + \frac{u_i}{R_i}$$

令 $\frac{1}{R'_i} = \frac{1}{R_i} + \sum_j w_{ij}$

得 $C_i \frac{du_i}{dt} = \sum_j w_{ij} V_j + I_i - \frac{u_i}{R'_i}$

图3-3 神经元输入节点处的元件连接关系

2004-8-8 《神经网络导论》——Hopfield神经网络 3-6

§ 3.2 Hopfield人工神经网络的电路模型及其能量函数

XI'AN JIAOTONG UNIVERSITY

如果各神经元参数相同，并取 $R = R'_i, C = C_i = 1$ ：令 $\tau = RC$ 。则有：

$$\begin{cases} \frac{du_i}{dt} = -\frac{u_i}{\tau} + \sum_j w_{ij} V_j + I_i & i = 1, 2, \dots, N \\ V_i = f_i(u_i) \end{cases} \quad \dots \dots \text{EQ3.5}$$

N 个神经元的方程构成 N 元联立非线性微分方程组。给定一个初值，可以求出此方程组的解；如果方程组的解为一组确定值，则表明系统演变的最终结果将得到一个稳定状态。所以，具体应用时都需要研究它的稳定性，稳定状态存在的规律及性质。

➡

二、能量函数

Hopfield利用非线性动力学系统理论中的能量函数法（Liapunov第二方法）为网络建立了能量函数，借此研究反馈神经网络的稳定性，并利用此方法建立了求解优化问题的系统方程式。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-7

§ 3.2 Hopfield人工神经网络的电路模型及其能量函数

XI'AN JIAOTONG UNIVERSITY

$$E = -\frac{1}{2} \sum_{i \neq j} \sum_j w_{ij} V_i V_j + \sum_i \frac{1}{R'_i} \int_0^{V_i} f_i^{-1}(V) dV - \sum_i I_i V_i \quad \dots \dots \text{EQ3.6}$$

E 具有能量的量纲。

下面证明： E 对时间的导数为负值，且达到稳定状态时， E 取极小值。

使用复合微分 $\frac{dE}{dt} = \sum_i \frac{\partial E}{\partial V_i} \cdot \frac{dV_i}{dt}$

利用突触权重的对称性 $w_{ij} = w_{ji}$ ，可得

$$\frac{\partial E}{\partial V_i} = -\sum_j w_{ij} V_j + \frac{u_i}{R'_i} - I_i \quad \dots \dots \text{EQ3.8}$$

与EQ3.3 $C_i \frac{du_i}{dt} = \sum_j w_{ij} V_j + I_i - \frac{u_i}{R'_i}$ 比较，有 $\frac{\partial E}{\partial V_i} = -C_i \frac{du_i}{dt}$ 所以：

2004-8-8 《神经网络导论》——Hopfield神经网络 3-8

§ 3.2 Hopfield人工神经网络的电路模型及其能量函数




XIAN JIAOTONG UNIVERSITY

$$\begin{aligned} \frac{dE}{dt} &= -\sum_i C_i \frac{du_i}{dt} \cdot \frac{dV_i}{dt} \\ &= -\sum_i C_i \frac{du_i}{dV_i} \frac{dV_i}{dt} \cdot \frac{dV_i}{dt} \\ &= -\sum_i C_i \frac{du_i}{dV_i} \left(\frac{dV_i}{dt}\right)^2 \end{aligned}$$

其中 $C_i > 0$, $(dV_i/dt)^2 \geq 0$
 由右图, 可知 $du_i/dV_i > 0$ 。
 所以 $dE/dt \leq 0$,
 且当 $dV_i/dt = 0$ 时, $dE/dt = 0$ 。

以上结果说明, 随着时间的推移, 在状态空间中, 网络总是朝能量函数 E 减小的方向运动, 网络达到稳态时 E 取极小值。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-9



§ 3.2 Hopfield人工神经网络的电路模型及其能量函数



XIAN JIAOTONG UNIVERSITY

如果神经元非线性函数 f 是硬限幅函数, 则EQ3.6中的第二项 (积分项) 等于零。所以能量函数 E 的表达式可以简化为:

$$E = -\frac{1}{2} \sum_{i \neq j} \sum_j w_{ij} V_i V_j - \sum_i I_i V_i \quad \dots \dots \dots \text{EQ3.13}$$

其实, 在一般情况下, 当 f 为sigmoid函数时, 如果 V_i 的值接近于1或0, 那么它的变动对积分结果的影响也不大, 能量函数也可以近似为上式。

其矩阵形式为:

$$E = -\frac{1}{2} \mathbf{V}^T \mathbf{W} \mathbf{V} - \mathbf{V}^T \mathbf{I} \quad \dots \dots \dots \text{EQ3.14}$$

设神经元数目为 N , 那么式中 \mathbf{V} 是 N 维列向量, \mathbf{V}^T 是 \mathbf{V} 的转置, \mathbf{W} 是 $N \times N$ 的方阵, \mathbf{I} 也是 N 维列向量。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-10

§ 3.3 Hopfield神经网络A/D变换器



XIAN JIAOTONG UNIVERSITY

一、Tank与Hopfield神经网络A/D变换器

模拟量 x 数字量 V_i

9	1001
8	1000
⋮	⋮

右图为 Tank 和 Hopfield给出的神经网络A/D变换器的原理电路图。要求: 当网络稳定以后, 其输出 V_i 接近于0或1, 且与模拟量 x 满足如下关系:

2004-8-8 《神经网络导论》——Hopfield神经网络 3-11




图3-7 神经网络A/D变换器

§ 3.3 Hopfield神经网络A/D变换器



XIAN JIAOTONG UNIVERSITY

$$x \doteq \sum_{i=0}^3 2^i V_i \quad \dots \dots \dots \text{EQ3.25}$$

为了完成此A/D转换电路的设计, 需要根据要求建立Hopfield网络的能量函数, 并由此计算出网络的各突触电导值 w_{ij} 。

A. 因为要求电路的转换功能完成以后, 模拟量 x 与数字量 V_i 之间满足EQ3.25, 所以能量函数中应该包含下式:

$$\frac{1}{2} \left(x - \sum_{i=0}^3 2^i V_i \right)^2 \quad \dots \dots \dots \text{EQ3.26}$$

B. 要求输出 V_i 尽量靠近0或1。由于运放的输出是连续的, 为保证输出数字量, 能量函数中要附加下式:

$$-\frac{1}{2} \sum_{i=0}^3 (2^i)^2 V_i (V_i - 1) \quad \dots \dots \dots \text{EQ3.27}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-12

XI'AN JIAOTONG UNIVERSITY

§ 3.3 Hopfield神经网络A/D变换器

此式大于等于0，只有当 $V_i = 0$ 或 1 时取最小值0。其中系数的选择是为了保证突触连接电导矩阵 \mathbf{W} 的对角元素为0，即当 $j = i$ 时， $w_{ij} = 0$ 。


将EQ3.26与EQ3.27相加，整理并去除与变量 V_i 无关的项，可得如下的能量函数：

$$E = -\frac{1}{2} \sum_{j=0}^3 \sum_{i \neq j}^3 (-2^{i+j}) V_i V_j - \sum_{i=0}^3 (-2^{2i-1} + 2^i x) V_i \quad \dots \dots \text{EQ3.28}$$

将此式与“标准的”Hopfield能量函数表达式

$$E = -\frac{1}{2} \sum_{i \neq j} w_{ij} V_i V_j - \sum_i I_i V_i \quad \dots \dots \text{EQ3.13}$$

进行比较，可得电路中的电导值为： $w_{ij} = -2^{(i+j)}$

$$I_i = -2^{(2i-1)} + 2^i x$$


2004-8-8 《神经网络导论》——Hopfield神经网络 3-13

XI'AN JIAOTONG UNIVERSITY

§ 3.3 Hopfield神经网络A/D变换器

其中， w_{ij} 表示各突触的电导值，利用运放的反相输出可以实现式中的负号。神经元偏置电流表达式由两项组成，第一项表示参考电压源和运放输入之间连接的电导值，若参考电压为 $-1V$ ，则电导值为 $2^{(2i-1)}$ ；第二项表示模拟输入到各运放所经过的电导值，即 2^i 。显然这是一组归一化的电导值。

实际电路中还需要做以下修正：

- (1) 当运放输出电压为0至 V_{BB} 伏时，有

$$w_{ij} = -2^{(i+j)} / V_{BB}$$
- (2) 当参考电压源为 $-V_R$ 时，相应的一组电导值为：

$$2^{(2i-1)} / V_R$$
- (3) 当输入信号 x 的最大值为 V_H 时，相应的一组电导值为：

$$\frac{2^i}{V_H} = \frac{2^{4+i}}{16}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-14

XI'AN JIAOTONG UNIVERSITY

§ 3.3 Hopfield神经网络A/D变换器

神经网络A/D变换器的优点包括：(a) 由于它是并行工作的，所以比一般的串行A/D变换器速度快；(b) 比一般的并行A/D变换器结构简单，需要的运放少。

这种电路的缺点是存在迟滞 (hysteresis) 现象。






图3-8 正确工作情况下的A/D转换关系 图3-9 迟滞现象

2004-8-8 《神经网络导论》——Hopfield神经网络 3-15

XI'AN JIAOTONG UNIVERSITY

§ 3.3 Hopfield神经网络A/D变换器

出现迟滞现象的原因是：在给定的输入模拟量的情况下，该电路的能量函数存在多个极小值，其中只有一个是全局最小值，其余为局部极小值，当系统收敛到局部极小解时，就出现错误映射。

解决办法：

- (1) Tank与Hopfield指出，如果在每次变换之前先输入零，则可以避免(减小)迟滞现象。但电路复杂度增大，工作速度降低。
- (2) 利用非对称Hopfield人工神经网络。

张宁、郑君里，“非对称人工神经网络A/D变换器”，电路与系统学报，1991，2。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-16

§ 3.3 Hopfield神经网络A/D变换器

二、非对称Hopfield神经网络及相应的A/D变换器

(一) 非对称Hopfield网络结构

网络结构如右图所示。可以看到，网络结构有如下特点：高位输出只对低位输入有反馈，而低位输出对高位没有影响。网络的这个特点使得该网络总是稳定的，且不存在局部极小值。下面我们将证明这一点。

对神经元的要求：单调连续，权值 $T_{ij} \geq 0$ 。

图3 非对称Hopfield网络A/D变换器

2004-8-8《神经网络导论》——Hopfield神经网络3-17

§ 3.3 Hopfield神经网络A/D变换器

(二) 关于网络稳定性和唯一性的证明

证明中要用到如下的定理。

【定理】 考虑微分方程

$$y^{(n)} + a_1 y^{(n-1)} + \dots + a_{n-1} y^{(1)} + a_n y = \phi(t)$$

其中 a_1, a_2, \dots, a_n 为实常数， $a_n \neq 0$ ， $\phi(t)$ 为连续函数，若方程满足：

(a) $\lim_{t \rightarrow \infty} \phi(t) = b$;

(b) 微分方程的特征方程的根具有负实部，

那么它的所有解当 $t \rightarrow \infty$ 时，趋于 b/a_n 。

1. 稳定性

对于图示的网络来说，根据KCL，其运动方程为

$$C_i \frac{du_i}{dt} = - \sum_{j=i+1}^N T_{ij} V_j + I_i - \frac{u_i}{R_i} \dots \dots \dots (1)$$

2004-8-8《神经网络导论》——Hopfield神经网络3-18

§ 3.3 Hopfield神经网络A/D变换器

其中 $T_{ij} \geq 0, i = 1, 2, \dots, N$ 。

当 $i = N$ 时，有

$$C_N \frac{du_N}{dt} = I_N - \frac{u_N}{R_N} \dots \dots \dots (2)$$

由于 $R_N > 0, C_N > 0$ ，根据上述定理 ($a_n = \frac{1}{R_N}, b = I_N$) 有 $t \rightarrow \infty$ 时，(2)式的稳态解为

$$u_N^e = R_N I_N \quad \text{其中上标 } e \text{ 代表平衡状态。}$$

当 $i = N-1$ 时，有

$$C_{N-1} \frac{du_{N-1}}{dt} = -T_{N-1,N} V_N + I_{N-1} - \frac{u_{N-1}}{R_{N-1}} \dots \dots \dots (3)$$

由于 $V_N = g(u_N)$ ，其中 $g(\bullet)$ 是神经元功能函数，且 $g(u)$ 是单调连续的。

2004-8-8《神经网络导论》——Hopfield神经网络3-19

§ 3.3 Hopfield神经网络A/D变换器

所以： $\lim_{t \rightarrow \infty} V_N = g(u_N^e)$

根据上述定理，有

$$\lim_{t \rightarrow \infty} u_{N-1} = -R_{N-1} T_{N-1,N} g(u_N^e) + R_{N-1} I_{N-1}$$

同理可证，对 $i = 1, 2, \dots, N$ ，方程(1)的稳态解为

$$u_i^e = -R_i \sum_{j=i+1}^N T_{ij} g(u_j^e) + R_i I_i \dots \dots \dots (4)$$

可见方程(1)的解当 $t \rightarrow \infty$ 时是稳定的，且与初始条件无关。

2. 唯一性

当方程(1)达到稳定时， $C_i \frac{du_i}{dt} = 0$ ，那么从方程(1)显然可以得到其平衡状态的解为：

$$\frac{u_i^e}{R_i} = - \sum_{j=i+1}^N T_{ij} g(u_j^e) + I_i \dots \dots \dots (5)$$

2004-8-8《神经网络导论》——Hopfield神经网络3-20



XI'AN JIAOTONG UNIVERSITY

§ 3.3 Hopfield神经网络A/D变换器

由于 I_i 对于某一具体输入是确定的，因此方程(1)的解是唯一的。比较(4)、(5)两式，可见两者是一致的，所以由方程(1)所描述的网络的解是唯一的，且解的吸引域为整个空间。

(三) 非对称Hopfield网络的优点

1. 不存在局部极小点问题；2. 该系统总是稳定的。

(四) 在A/D变换中的应用

为了用这个网络实现A/D变换，必须在网络输出与模拟输入之间建立一定的关系，使这些输出能代表模拟输入的值。设图中运放的输出高电平为 A 伏，低电平为 B 伏，模拟输入的动态范围为 C 伏，那么网络输出 V_j 应满足：

$$\frac{2^N-1}{C}x - 0.5 \leq \sum_{j=1}^N (V_j - B) \frac{2^{j-1}}{K} \leq \frac{2^N-1}{C}x + 0.5 \quad \dots\dots\dots (6)$$

其中 $K = A - B$ ， N 为A/D变换器的位数，展开(6)式

2004-8-8 《神经网络导论》——Hopfield神经网络 3-21



XI'AN JIAOTONG UNIVERSITY

§ 3.3 Hopfield神经网络A/D变换器

$$\frac{2^N-1}{C}x - 0.5 \leq \sum_{j=1}^{i-1} (V_j - B) \frac{2^{j-1}}{K} + (V_i - B) \frac{2^{i-1}}{K} + \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K} \leq \frac{2^N-1}{C}x + 0.5$$

$$\frac{2^N-1}{C}x - 0.5 - \sum_{j=1}^{i-1} (V_j - B) \frac{2^{j-1}}{K} \leq (V_i - B) \frac{2^{i-1}}{K} + \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K} \leq \frac{2^N-1}{C}x + 0.5$$

因为 $\sum_{j=1}^{i-1} (V_j - B) \frac{2^{j-1}}{K} \leq \sum_{j=1}^{i-1} 2^{j-1} = 2^{i-1} - 1$ ，所以

$$\frac{2^N-1}{C}x + 0.5 - 2^{i-1} - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K} \leq (V_i - B) \frac{2^{i-1}}{K} \quad \dots\dots\dots (7)$$

$$\leq \frac{2^N-1}{C}x + 0.5 - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K}$$

定义如下决策函数：

2004-8-8 《神经网络导论》——Hopfield神经网络 3-22



XI'AN JIAOTONG UNIVERSITY

§ 3.3 Hopfield神经网络A/D变换器

$$u_{ii} = \frac{2^N-1}{C}x + 0.5 - 2^{i-1} - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K} \quad \dots\dots\dots (8)$$

V_i 和决策函数有如下关系。当 $V_i = A$ 时，根据(7)式的右半不等式，有

$$\frac{2^N-1}{C}x + 0.5 - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K} \geq (V_i - B) \frac{2^{i-1}}{K} = 2^{i-1}$$

$$\Rightarrow \frac{2^N-1}{C}x + 0.5 - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K} - 2^{i-1} \geq 0 \Rightarrow u_{ii} \geq 0$$

当 $V_i = B$ 时，根据(7)式的左半不等式，有

$$\frac{2^N-1}{C}x + 0.5 - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K} - 2^{i-1} \leq 0 \Rightarrow u_{ii} \leq 0$$

所以有 $\begin{cases} \text{当 } V_i = A \text{ 时, } u_{ii} \geq 0 \\ \text{当 } V_i = B \text{ 时, } u_{ii} \leq 0 \end{cases}$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-23



XI'AN JIAOTONG UNIVERSITY

§ 3.3 Hopfield神经网络A/D变换器

反过来，当 $u_{ii} > 0$ 时，有

$$0 < u_{ii} = \frac{2^N-1}{C}x + 0.5 - 2^{i-1} - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K}$$

$$= \frac{2^N-1}{C}x - 0.5 + 1 - 2^{i-1} - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K}$$

$$\leq \sum_{j=1}^i (V_j - B) \frac{2^{j-1}}{K} + 1 - 2^{i-1} - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K}$$

$$= \sum_{j=1}^{i-1} (V_j - B) \frac{2^{j-1}}{K} + 1 - 2^{i-1} + (V_i - B) \frac{2^{i-1}}{K}$$

$$\leq 2^{i-1} - 1 + 1 - 2^{i-1} + (V_i - B) \frac{2^{i-1}}{K} \Rightarrow V_i = A$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-24

§ 3.3 Hopfield神经网络A/D变换器

而当 $u_{ii} < 0$ 时, 有

$$0 > u_{ii} = \frac{2^N - 1}{C} x + 0.5 - 2^{i-1} - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K}$$

$$\geq \sum_{j=1}^N (V_j - B) \frac{2^{j-1}}{K} - 2^{i-1} - \sum_{j=i+1}^N (V_j - B) \frac{2^{j-1}}{K}$$

$$= \sum_{j=1}^{i-1} (V_j - B) \frac{2^{j-1}}{K} + (V_i - B) \frac{2^{i-1}}{K} - 2^{i-1}$$

$$\geq (V_i - B) \frac{2^{i-1}}{K} - 2^{i-1} \Rightarrow V_i = B$$

所以有 $\begin{cases} \text{当 } u_{ii} > 0 \text{ 时, } V_i = A \\ \text{当 } u_{ii} < 0 \text{ 时, } V_i = B \end{cases}$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-25

§ 3.3 Hopfield神经网络A/D变换器

由此可见, u_{ii} 与 V_i 的对应关系和 u_i 与 V_i 的对应关系是一致的。因此决策函数 u_{ii} 就决定了A/D变换器第 i 位取值所应遵循的规则, 也就确定了网络方程的稳定解。根据这一点就可以导出相应的网络参数。

网络的稳态解为

$$u_i^e / R_i = - \sum_{j=i+1}^N T_{ij} g(u_j^e) + I_i$$

比较可得:

$$\begin{cases} T_{ij} = 2^{j-1} / K & j = i+1, \dots, N \\ I_i = \frac{2^N - 1}{C} x + 0.5 - 2^{i-1} + \frac{B}{K} (2^N - 2^i) & i = 1, 2, \dots, N \end{cases}$$

由式中的 I_i 可以确定:

$$K_i = \frac{2^N - 1}{C} \quad L_i = 0.5 - 2^{i-1} + \frac{B}{K} (2^N - 2^i) \quad i = 1, 2, \dots, N$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-26

§ 3.4 Hopfield网络用于求解TSP

一、TSP命题

TSP是Travelling Salesman Problem的缩写, 中文称为“旅行商问题”, 它是一个经典的人工智能难题。

TSP命题是: 设有 N 个城市A、B、C..., 它们之间的距离分别为 d_{AB} 、 d_{AC} 、... d_{BC} ...。问题是寻找一条闭合路径, 此路径经过每个城市且只经过一次, 最后返回起始城市, 要求路径的长度最短。

如图3-4是 $N = 10$ 时的一种可能路径。其路径长度为

$$d = d_{AJ} + d_{JC} + d_{CB} + \dots + d_{EA}$$

不难求得, 对于给定的 N 可能存在的路径




图3-4 10个城市的TSP路径示意

2004-8-8 《神经网络导论》——Hopfield神经网络 3-27

§ 3.4 Hopfield网络用于求解TSP

数为 $\frac{1}{2}(N-1)!$ 。如果按照传统的方法, 先计算出所有可能路径的长度然后再搜索最优路径, 那么随着 N 的增大, 计算量将急剧增大。

实际应用中, 这类问题往往不需要得到严格的最优解, 近似最优、准最优的解也是可以接受的。例如, 图3-4中的路径也许就是准最优的。

二、求解TSP的网络模型

1. TSP状态与结果的表示

如果用行表示城市, 用列表示步数, 那么我们就可以用表3-1所示的矩阵来表示TSP的状态与结果。例如, 表中的矩阵表示的路径顺序是CAEBD, 路径总长度为

$$d = d_{CA} + d_{AE} + d_{EB} + d_{BD} + d_{DC}$$

	1	2	3	4	5
A	0	1	0	0	0
B	0	0	0	1	0
C	1	0	0	0	0
D	0	0	0	0	1
E	0	0	1	0	0

2004-8-8 《神经网络导论》——Hopfield神经网络 3-28

XI'AN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

这种矩阵称为置换矩阵 (permutation matrix)，它具有以下特点：

- (1) 每行只有一个“1”，其余元素为“0”；
- (2) 每列只有一个“1”，其余元素为“0”；
- (3) 全部元素中“1”的总和为 N 。

2. 网络模型

这样，我们就可以用 $N \times N$ 个神经元组成Hopfield神经网络，当网络达到稳定状态时，各神经元的状态对应置换矩阵的各元素值（“1”或“0”）。各城市间的距离 d_{AB} 、 d_{AC} 、...等作为一组约束信息确定神经元之间的连接强度 w_{ij} 。我们期望网络演变的最终结果给出最优解，即网络给出的置换矩阵所对应的路径是最短路径。

为了便于和置换矩阵对应，神经元的输出电压用双下标表示，如 V_{xi} ，其中第一个下标 X 代表城市名（如A，B等），第二个下标 i 代表路径顺序（如1，2等）。相应地，放大器的输入电压也用双下标表示，记为 u_{xi} 。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-29

XI'AN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

为了完成网络电路的设计，需要求出其中的连接电导和偏置电流。因此，我们要根据优化目标构造能量函数，所建立的能量函数应该满足以下两方面的要求：(1) 网络稳定时，也即能量函数达到最小值时，神经元的输出符合置换矩阵的形式；(2) 网络稳定时，置换矩阵对应的路径最短。

为满足(1)，能量函数中应包括下式：

$$\frac{\alpha}{2} \sum_X \sum_i \sum_{j \neq i} V_{xi} V_{xj} + \frac{\beta}{2} \sum_X \sum_{Y \neq X} \sum_{i \neq j} V_{xi} V_{yj} + \frac{\gamma}{2} \left(\sum_X \sum_i V_{xi} - N \right)^2 \quad \dots \text{EQ3.17}$$

式中的 α 、 β 、 γ 为实系数。其中第一项是置换矩阵所有各行每行内各元素两两交叉相乘（不包括自乘）的各种组合，此项是为了保证使置换矩阵的各行中1的个数不大于“1”；第二项是为了保证使置换矩阵的各列中“1”的个数不大于1；第三项是为了保证置换矩阵中共有 N 个“1”。当EQ3.17取最小值0时，网络的输出符合置换矩阵形式，其所代表的路径是一条“合法”路径。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-30

XI'AN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

为了满足(2)，能量函数应包含下式

$$\frac{\lambda}{2} \sum_X \sum_{Y \neq X} \sum_i d_{XY} V_{xi} (V_{Y,i+1} + V_{Y,i-1}) \quad \dots \text{EQ3.18}$$

上式表示的是某条“合法”路径的长度，我们希望它越小越好。要注意的是，上式中的下标按“模 N ” 规律确定，即 $V_{Y,N+j} = V_{Y,j}$ 。

将上两式结合，得到能量函数表达式为：

$$E = \frac{\alpha}{2} \sum_X \sum_i \sum_{j \neq i} V_{xi} V_{xj} + \frac{\beta}{2} \sum_X \sum_{Y \neq X} \sum_{i \neq j} V_{xi} V_{yj} + \frac{\gamma}{2} \left(\sum_X \sum_i V_{xi} - N \right)^2 + \frac{\lambda}{2} \sum_X \sum_{Y \neq X} \sum_i d_{XY} V_{xi} (V_{Y,i+1} + V_{Y,i-1}) \quad \dots \text{EQ3.19}$$

把此式和“标准的”Hopfield神经网络能量函数（EQ3.13）相比较，就可以求得连接权值和阈值。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-31

XI'AN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

$$E = -\frac{1}{2} \sum_{i \neq j} \sum_j w_{ij} V_i V_j - \sum_i I_i V_i \quad \dots \text{EQ3.13}$$

为了方便比较，我们把“标准”能量函数改写为双下标的形式：

$$E = -\frac{1}{2} \sum_X \sum_i \sum_Y \sum_j w_{xi,yj} V_{xi} V_{yj} - \sum_X \sum_i I_{xi} V_{xi} \quad \dots \text{EQ3.14}$$

为了清楚地表示比较结果，引用如下符号：

$$\delta_{ij} = \begin{cases} 1 & (i = j) \\ 0 & (i \neq j) \end{cases} \quad \dots \text{EQ3.20}$$

通过比较，我们可以得到：

$$w_{xi,yj} = -\alpha \delta_{xy} (1 - \delta_{ij}) - \beta \delta_{ij} (1 - \delta_{xy}) - \gamma - \lambda d_{xy} (\delta_{j,i+1} + \delta_{j,i-1}) \quad \dots \text{EQ3.21}$$

$$I_{xi} = N \gamma \quad \dots \text{EQ3.22}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-32



XIAN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

下面导出描述TSP网络的状态方程式，由EQ3.9，并令 $C = C_i$ ，有

$$-\frac{\partial E}{\partial V_i} = C \frac{du_i}{dt}$$

考虑到神经元非线性函数不一定是硬限幅函数，需要在能量函数表达式中增加 $f_i^{-1}(V)$ 函数积分项，最后求得：

$$\left. \begin{aligned} \frac{du_{xi}}{dt} &= -\frac{u_{xi}}{\tau} - \alpha \sum_{j \neq i} V_{xj} - \beta \sum_{Y \neq X} V_{Yi} - \gamma \left(\sum_X \sum_i V_{Xi} - N \right) \\ &\quad - \lambda \sum_{Y \neq X} d_{XY} (V_{Y,i+1} + V_{Y,i-1}) \\ V_{xi} &= f(u_{xi}) = \frac{1}{2} \left[1 + \tanh \left(\frac{u_{xi}}{u_0} \right) \right] \end{aligned} \right\} \dots \dots \text{EQ3.23}$$

这是 $N \times N$ 个神经元状态方程式的通用表达式。为求TSP的优化结果，需要求解 $N \times N$ 个非线性一阶联立微分方程组。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-33



XIAN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

三、仿真实验

Hopfield给出了TSP的计算机仿真实例。实验中参数选择如下：

$$N = 10 \quad \tau = 1 \quad u_0 = 0.02$$

$$\alpha = \beta = 500 \quad \gamma = 200 \quad \lambda = 500$$

初始条件为： $u_{xi} = u_{00} + \delta u_{xi}$ ，
 u_{00} 满足 $t = 0$ 时， $\sum_X \sum_i V_{Xi} = 10$ 以利于收敛；
 $-0.1u_0 \leq \delta u_{xi} \leq 0.1u_0$ 为随机噪声。

利用数值计算方法对此微分方程组求解，经过若干次迭代即可求得各神经元的最终状态。给定不同的 δu_{xi} ，就可能得到不同的最终状态，其中有一些可能是最优的，另一些可能是准最优的。图3-6是两种可能的解。




图3-6 两种可能的解

2004-8-8 《神经网络导论》——Hopfield神经网络 3-34



XIAN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

关于仿真实验的几点讨论：

1. u_0 的选择对计算结果有较大的影响。太小的 u_0 将使优化路径过于粗略，所得结果与最优状态相差较远。而太大的 u_0 则使最终的 V_{xi} 难以接近1或0，即难以得到正确的置换矩阵形式。
2. 系数 $\alpha, \beta, \gamma, \lambda$ 的选择也很重要，其中 λ 的选择更为重要。
3. 实验结果表明，选择20组不同的 δu_{xi} 进行实验，其中大部分结果收敛于接近最优的路径，包括最优路径。对于 $N = 10$ ，共有181440条路径，所以这种算法改善计算效率为： $20/181440 \approx 10^{-5}$ 。

四、Hopfield网络求解TSP的意义、存在的问题及影响

利用Hopfield网络求解TSP的成功引起了人们极大的兴趣，但也存在着一些问题。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-35



XIAN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

1. 可以得到最优或接近最优的解，与人脑分析这种问题的特点相似。
2. 借助计算机进行仿真，只能证实这一方法的可行性，不一定能改善计算速度。
3. 如果用硬件实现，则解题时间仅是运放过渡特性时间常数的量级，非常快。而目前硬件实现的进展不顺利。
4. 按照Hopfield提出的方法计算TSP时，收敛效果并不好。已有很多文章从不同角度对此方法进行了改进。
5. Hopfield网络的构成原理既不同于数字计算机，也不同于传统的模拟计算机，它在结构原理和功能效果方面更接近人脑的特征。在解决TSP以外的许多优化问题中都取得了一定的进展，提供了一种解决优化问题的新思路，表现出了引人注目的潜在能力。
6. TSP属于NP难题，Hopfield网络求解TSP的方法对众多NP问题的研究有一定的启发。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-36

XIAN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

五、NP理论简介

在研究算法时，需要研究算法的“时间复杂性”与“空间复杂性”。在研究算法时间复杂性的过程中逐步形成了NP理论，它已成为组合数学研究领域中的重要组成部分。

假定计算对象的规模为 N ，那么算法所需的时间将随 N 的增加而增大，其增长规律可能有以下几种类型：

- (1) 对数型： $\log N$
- (2) 多项式型： N, N^2, N^3, \dots
- (3) 指数型： $2^N, 3^N, 4^N, \dots$
- (4) 阶乘型： $N!$

如 $T(N) = 8N^3 + 5N + 6$ ，算法的时间复杂性为 $O(N^3)$ ，其中 $O(\cdot)$ 表示取数量级。而FFT算法的时间复杂性为 $O(N \log_2 N)$ 。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-37

XIAN JIAOTONG UNIVERSITY

§ 3.4 Hopfield网络用于求解TSP

通常认为算法的时间复杂性存在多项式界时，计算时间是可以接受的，如果超出多项式界，那么计算时间将随 N 的增大而急剧增长，则该算法在实际应用中很难被接受。一般情况下有如下结论：

$$O(\log N) < O(N) < O(N \log N) < O(N^2) < \dots < O(2^N) < O(3^N) < \dots < O(N!)$$

NP理论指出：如果算法的时间复杂性存在多项式界(Polynomial bounded)，则称为P类。如FFT算法。有许多问题，其算法的时间复杂度肯定超出多项式界，如求一个图的所有树。此外，还有许多问题未能证明它超出多项式界，但又未找到有效算法，称之为“非确定型多项式(Nondeterministic Polynomial)问题”，简称NP问题。当然，这不是NP问题的严格定义。

NP理论不期望寻找NP问题的具体算法，而是着重证明这类问题相互等价性，即证明它们的困难程度相当，如果其中一个问题获得多项式解法，则此类问题全部获得解决。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-38

XIAN JIAOTONG UNIVERSITY

§ 3.5 Hopfield网络用于求解货流问题

一、以二值状态实现数字编码的几种方式

在某些优化计算中，输出结果需要连续取值。这可以利用连续时间连续幅度工作下的运放来实现，也可以用二值数据编码来实现。

1. 二进制

是一种一对一的映射，无冗余，虽然节省神经元的数目，但容错性较差。

$$N_d = \sum_{k=1}^q 2^{k-1} V_k \quad \dots \dots \dots \text{EQ3.47}$$

如 $5 \Rightarrow 101$ $7 \Rightarrow 111$

2. 简单求和制

是一种一对多的映射，和二进制相比，表示相同的数字需要更多的神经元，但容错性好。

$$N_d = \sum_{i=1}^q V_i \quad \dots \dots \dots \text{EQ3.48}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-39

XIAN JIAOTONG UNIVERSITY

§ 3.5 Hopfield网络用于求解货流问题

如 $5 \Rightarrow 1010111, 0011111, 1101011, \dots$ $7 \Rightarrow 1111111$

3. 分组求和加权制

是上述两种方案的折衷。把 q bit分成 K 组，每组 M bit, $q = KM$ 。

每组内使用简单求和制，各组之间使用 $M+1$ 进制的加权求和制。

$$N_d = \sum_{k=1}^K \left[(M+1)^{k-1} \sum_{i=1}^M V_{(k-1)M+i} \right] \quad \dots \dots \dots \text{EQ3.46}$$

例如： $q = 6, K = 2, M = 3$ 则

$$100100 = 4^1 \times (1+0+0) + 4^0 \times (1+0+0) = 5$$

$5 \Rightarrow 100001, 001100, 010010, \dots$

当 $M = 1, K = q$ 时，即每组只有一位，相当于不分组，可得二进制表达式EQ3.47；而当 $M = q, K = 1$ 时，即只分一组，此时可得简单求和制的表达式EQ3.48。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-40

§ 3.5 Hopfield网络用于求解货流问题

XI'AN JIAOTONG UNIVERSITY

二、货流问题描述

货流问题 (Hitchcock Problem) 又称为运输问题。

设有 m 个货源 $x = 1, 2, \dots, m$, 每个源储存的 (可供应的) 物资量为 S_x 。有 n 个用户 $y = 1, 2, \dots, n$, 每个用户需要的物资量为 D_y 。从源 x 到用户 y 运送单位物资量的消耗费用为 C_{xy} 。在以上条件下, 确定一组从 x 到 y 运送物资的流量 f_{xy} , 使其满足供销平衡且总的消耗费用最小。

可以用数学语言描述如下:

$$\min \left[\sum_{x=1}^m \sum_{y=1}^n C_{xy} f_{xy} \right] \dots\dots\dots \text{EQ3.49}$$

$$\sum_{y=1}^n f_{xy} = S_x \quad x = 1, 2, \dots, m \quad \dots\dots\dots \text{EQ3.50}$$

$$\sum_{x=1}^m f_{xy} = D_y \quad y = 1, 2, \dots, n \quad \dots\dots\dots \text{EQ3.51}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-41

§ 3.5 Hopfield网络用于求解货流问题

XI'AN JIAOTONG UNIVERSITY

图3-11是 $m = 4, n = 5$ 情况下的供销关系示意图。

假定已知消耗矩阵如下表:

$x \backslash y$	1	2	3	4	5
1	5	1	7	3	3
2	2	3	6	9	5
3	6	4	8	1	4
4	3	2	2	2	4

经分析计算可以得到如下的流量矩阵:

	D_1	D_2	D_3	D_4	D_5
S_1	5	0	5	0	0
S_2	3	2	1	0	0
S_3	4	0	0	0	2
S_4	6	0	1	3	0




图3-11 货流问题供销关系

2004-8-8 《神经网络导论》——Hopfield神经网络 3-42

§ 3.5 Hopfield网络用于求解货流问题

XI'AN JIAOTONG UNIVERSITY

问题是: 如何用人工神经网络来求解这一问题?

三、用Hopfield网络求解货流问题

流量矩阵中的每个元素值以 q 个神经元的状态按数字编码 (分组加权求和) 的方式表示, 因此求解货流问题需要的神经元个数 $N = qmn$ 。我们用三个下标 x, y, j 确定神经元的位置, 其中 xy 表示流量矩阵中的元素序号, 而 j 表示神经元在该元素的 q 个位置中的序号。如下表所示:

	$y = 1$	$y = 2$...	$y = n$
	j	j	...	j
$x = 1$	$q \dots 2 \ 1$	$q \dots 2 \ 1$		$q \dots 2 \ 1$
$x = 2$				
\vdots				
$x = m$				

$V_{2,1,2}$ $f_{1,2}$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-43

§ 3.5 Hopfield网络用于求解货流问题


XI'AN JIAOTONG UNIVERSITY

引用EQ3.46, 用分组求和加权法表示流量 f_{xy} :

$$f_{xy} = \sum_{k=1}^K \left[(M+1)^{k-1} \sum_{i=1}^M V_{xy,(k-1)M+i} \right] \dots\dots\dots \text{EQ3.52}$$

由于矩阵元素是用分组求和加权制表示的, 所以下标 $j = (k-1)M + i$ 。下面我们根据优化目标构造能量函数。

(1) 神经元的输出要尽量接近0或1, 即二值化, 能量函数应包括:

$$-\frac{A}{2} \sum_{x=1}^m \sum_{y=1}^n \sum_{k=1}^K \sum_{i=1}^M (M+1)^{k-1} [1 - 2V_{xy,(k-1)M+i}]^2$$


借用函数 $-(1-2V)^2$ ($0 \leq V \leq 1$) 来满足这个要求

(2) 供货量约束

所有用户对某一源的需求应为源的供货量。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-44

XIAN JIAOTONG UNIVERSITY

§ 3.5 Hopfield网络用于求解货流问题

$$\frac{B}{2} \sum_{x=1}^m \left[S_x - \sum_{y=1}^n \sum_{k=1}^K \sum_{i=1}^M (M+1)^{k-1} V_{xy,(k-1)M+i} \right]^2$$

(3) 需求量约束，所有货源对某一用户的供货量等于这个用户的需求量。

$$\frac{C}{2} \sum_{y=1}^n \left[D_y - \sum_{x=1}^m \sum_{k=1}^K \sum_{i=1}^M (M+1)^{k-1} V_{xy,(k-1)M+i} \right]^2$$

(4) 消耗费用最小约束。

$$\frac{D}{2} \left[\sum_{x=1}^m \sum_{y=1}^n \sum_{k=1}^K \sum_{i=1}^M C_{xy} (M+1)^k V_{xy,(k-1)M+i} \right]^2$$

由于消耗费用恒为正值，所以上式中的平方可以去掉。以上四项相加，即为完整的能量函数，它与“标准”的Hopfield能量函数（EQ3.13）比较，就可以得到网络中的连接权值（电导）和阈值（偏置电流）。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-45

XIAN JIAOTONG UNIVERSITY

§ 3.5 Hopfield网络用于求解货流问题

为了方便比较，将EQ3.13式改写为与本问题相同的形式：

$$E = -\frac{1}{2} \sum_{x=1}^m \sum_{y=1}^n \sum_{k=1}^K \sum_{i=1}^M \sum_{x'=1}^m \sum_{y'=1}^n \sum_{k'=1}^K \sum_{i'=1}^M w_{xy,(k-1)M+i;x'y',(k'-1)M+i'} V_{xy,(k-1)M+i} V_{x'y',(k'-1)M+i'}$$

$$- \sum_{x=1}^m \sum_{y=1}^n \sum_{k=1}^K \sum_{i=1}^M V_{xy,(k-1)M+i} \cdot I_{xy,(k-1)M+i}$$

借助上一节定义的 δ_{ij} 符号，通过比较可得：

$$w_{xy,(k-1)M+i;x'y',(k'-1)M+i'} = 4A(M+1)^{k-1} \delta_{xx'} \delta_{yy'} \delta_{kk'} \delta_{ii'}$$

$$-B(M+1)^{k+k'-2} \delta_{xx'} - C(M+1)^{k+k'-2} \delta_{yy'} \dots \dots \text{EQ3.55}$$

$$-D(M+1)^{k+k'-2} C_{xy} C_{x'y'}$$

$$I_{xy,(k-1)M+i} = -2A(M+1)^{k-1} + B(M+1)^{k-1} S_x + C(M+1)^{k-1} D_y \text{EQ3.56}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-46

XIAN JIAOTONG UNIVERSITY

§ 3.5 Hopfield网络用于求解货流问题

如果令 $M=1, K=q$ ，那么可以得到二进制编码方式的连接权和阈值：

$$w_{xyk;x'y'k'} = 4A2^{k-1} \delta_{xx'} \delta_{yy'} \delta_{kk'} \dots \dots \text{EQ3.58}$$

$$-B2^{k+k'-2} \delta_{xx'} - C2^{k+k'-2} \delta_{yy'} - D2^{k+k'-2} C_{xy} C_{x'y'}$$

$$I_{xyk} = -A2^k + B2^{k-1} S_x + C2^{k-1} D_y \dots \dots \text{EQ3.59}$$

如果令 $M=q, K=1$ ，那么就可以得到简单求和制编码方式的连接权和阈值：

$$w_{xyi;x'y'i'} = 4A \delta_{xx'} \delta_{yy'} \delta_{ii'} \dots \dots \text{EQ3.60}$$

$$-B \delta_{xx'} - C \delta_{yy'} - DC_{xy} C_{x'y'} \dots \dots \text{EQ3.61}$$

$$I_{xyi} = -2A + BS_x + CD_y$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-47

XIAN JIAOTONG UNIVERSITY

§ 3.6 Hopfield网络用于联想记忆

Hopfield网络除用于优化计算外，也可以用于联想记忆或分类。在上一章，我们曾讨论过用前向多层神经网络实现异联想，和分类的情况类似，异联想可以用一种映射关系来描述。 $X^{(s)} \rightarrow Y^{(s)}, X^{(s)} + \Delta X^{(s)} \rightarrow Y^{(s)}$

本节我们以印刷体字符识别为例，讨论Hopfield网络用于联想记忆的原理、学习和识别的算法步骤。

待识别的8个标准字符如图3-12所示。

样本数 $M=8$ ，每个字符用120个黑白像素（ 12×10 ）表示。我们可以用列矢量 X 来描述字符。

$$\left. \begin{aligned} X &= [x_0 \ x_1 \ \dots \ x_{N-1}]^T \\ X &\in \{-1, 1\}^N \end{aligned} \right\} \dots \dots \text{EQ3.62}$$


图3-12 8个标准字符

其中， $N=120$ 为矢量维数。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-48

XIAN JIAOTONG UNIVERSITY

§ 3.6 Hopfield网络用于联想记忆

网络模型如图3-13所示。利用标准样本对网络进行训练（学习），可以求得网络的突触权重连接矩阵 \mathbf{W} ，从而使网络可以完成联想记忆的功能。

图3-13 Hopfield网络模型

2004-8-8 《神经网络导论》——Hopfield神经网络 3-49

XIAN JIAOTONG UNIVERSITY

§ 3.6 Hopfield网络用于联想记忆

算法步骤如下：

- ① 利用Hebb规则学习，求 w

$$w_{ij} = \begin{cases} \sum_{s=0}^{M-1} x_i^{(s)} x_j^{(s)}, & i \neq j \\ 0, & i = j \end{cases} \quad 0 \leq \begin{Bmatrix} i \\ j \end{Bmatrix} \leq N-1 \quad \dots \text{EQ3.63}$$

- ② 利用未知输入样本初始化

$$y_i(0) = x_i \quad 0 \leq i \leq N-1 \quad \dots \text{EQ3.64}$$

其中 $y_i(t)$ 表示节点 i 在 t 时刻的输出； $x_i \in \{-1, 1\}$ 是输入信号的 i 元素。

- ③ 运算、迭代至收敛

$$y_i(t+1) = f \left[\sum_{j=0}^{N-1} w_{ij} y_j(t) \right], \quad 0 \leq i \leq N-1 \quad \dots \text{EQ3.65}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-50

XIAN JIAOTONG UNIVERSITY

§ 3.6 Hopfield网络用于联想记忆

其中， $f[\cdot]$ 是神经元非线性函数。重复上述计算过程，直至 $y_i(t+k)$ 不再改变。最终，节点的输出描述了未知输入与样本的最佳匹配。

- ④ 返回②，可以再输入一个未知样本。

以上算法可以用**矩阵形式**表示如下：

$$\mathbf{W} = \sum_{s=0}^{M-1} (\mathbf{X}_s \mathbf{X}_s^T - \mathbf{I}) \quad \dots \text{EQ3.66}$$

$$\mathbf{Y}(0) = \mathbf{X} \quad \dots \text{EQ3.67}$$

$$\mathbf{Y}(t+1) = f[\mathbf{W}\mathbf{Y}(t)] \quad \dots \text{EQ3.68}$$

其中， \mathbf{I} 为单位阵。

More...

如果输入样本没有噪声，即输入的是标准样本，运算将一次迭代成功，输出 \mathbf{Y} 等于输入 \mathbf{X} 。如果输入样本含有噪声，即输入 $\mathbf{X} + \Delta\mathbf{X}$ ，那么需要经过若干次迭代，最终收敛后使 \mathbf{Y} 与某个样本 \mathbf{X} 一致。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-51

XIAN JIAOTONG UNIVERSITY

§ 3.6 Hopfield网络用于联想记忆

在仿真实验中，把样本“3”的25%的元素随机取反，经过6次迭代，最后输出收敛于标准样本“3”。

为实现联想记忆功能，我们希望网络最终收敛至预期的标准样本，即希望通过训练使样本成为网络的稳定状态。然而，稳定状态出现的规律十分复杂。

- (1) 给定一组样本，经训练得到 w ，网络将对应有一组稳定状态。除此之外，还可能有多余的稳定状态，称为伪稳定状态。
- (2) 并非任何一组样本经训练后都可以构成一组稳定状态。
- (3) 给定一个加噪的样本，最终不一定收敛到与其汉明距离最近的标准样本。
- (4) 各样本之间的汉明距离分布对联想记忆功能的正确实现有重要影响。若样本之间相互正交（汉明距离是输入矢量维数的一半），效果最好。
- (5) N 一定时， M 越小越好。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-52



XIAN JIAOTONG UNIVERSITY

§ 3.7 双向联想记忆

双向联想记忆, Bidirectional Associative Memory(BAM), 是一种异联想, 它可以存储两组矢量。

$\mathbf{A} = [a_0, a_1, \dots, a_{N-1}]^T$ $\mathbf{A} \in \{-1, 1\}^N$ 表示 N 维矢量,
 $\mathbf{B} = [b_0, b_1, \dots, b_{P-1}]^T$ $\mathbf{B} \in \{-1, 1\}^P$ 表示 P 维矢量。
 各 M 个矢量构成 M 对矢量 $(\mathbf{A}_s, \mathbf{B}_s)$, $s = 0, 1, \dots, M-1$ 。

双向联想记忆可以

$$\left. \begin{matrix} \mathbf{A} \Rightarrow \mathbf{B} \\ \mathbf{B} \Rightarrow \mathbf{A} \end{matrix} \right\} \mathbf{A} \Leftrightarrow \mathbf{B}$$

当有噪声或缺损时, 联想功能可使样本对复原。

利用人工神经网络实现BAM有多种结构形式, 这里只介绍最基本的一种, Kosko型BAM网络, 其网络模型如图3-16所示。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-53



XIAN JIAOTONG UNIVERSITY

§ 3.7 双向联想记忆

\mathbf{W} 为正向传输 $\mathbf{B} \Rightarrow \mathbf{A}$ 的突触权重连接矩阵; \mathbf{W}^T 是反向传输的权重连接矩阵。

当输入任意矢量时, 网络要经过若干次迭代运算演变至稳定状态。下面通过与自联想记忆的对比来说明网络的演变过程。




图3-16 双向联想记忆网络模型

<p>自联想</p> $\mathbf{W}\mathbf{Y}(t) \rightarrow \mathbf{Y}(t+1)$ $\mathbf{W}\mathbf{Y}(t+1) \rightarrow \mathbf{Y}(t+2)$ \vdots $\dots \rightarrow \mathbf{Y}(t+k)$ 迭代直至收敛、稳定	<p>双向联想</p> $\mathbf{W}\mathbf{B}(t) \rightarrow \mathbf{A}(t+1)$ $\mathbf{W}^T\mathbf{A}(t+1) \rightarrow \mathbf{B}(t+2)$ \vdots $\mathbf{W}\mathbf{B}(t+2) \rightarrow \mathbf{A}(t+3)$ \vdots 直至 \mathbf{A} 、 \mathbf{B} 均为稳定状态
---	--

2004-8-8 《神经网络导论》——Hopfield神经网络 3-54



XIAN JIAOTONG UNIVERSITY

§ 3.7 双向联想记忆

网络的学习(训练)按Hebb规则。

假设给定 M 个样本对: $(\mathbf{A}_0, \mathbf{B}_0), (\mathbf{A}_1, \mathbf{B}_1) \dots (\mathbf{A}_{M-1}, \mathbf{B}_{M-1})$ 。则

$$\mathbf{W} = \sum_{s=0}^{M-1} \mathbf{A}_s \mathbf{B}_s^T; \quad \mathbf{W}^T = \sum_{s=0}^{M-1} \mathbf{B}_s \mathbf{A}_s^T \quad \dots \dots \dots \text{EQ3.95}$$

如果BAM网络神经元的阈值等于零, 那么称为齐次BAM网络。定义齐次BAM网络的能量函数为

$$E(\mathbf{A}, \mathbf{B}) = -\frac{1}{2} \mathbf{A}^T \mathbf{W} \mathbf{B} - \frac{1}{2} \mathbf{B}^T \mathbf{W}^T \mathbf{A} \quad \dots \dots \dots \text{EQ3.97}$$

因为

$$\mathbf{B}^T \mathbf{W}^T \mathbf{A} = \mathbf{B}^T (\mathbf{A}^T \mathbf{W})^T = (\mathbf{A}^T \mathbf{W} \mathbf{B})^T = \mathbf{A}^T \mathbf{W} \mathbf{B}$$

所以

$$E(\mathbf{A}, \mathbf{B}) = -\mathbf{A}^T \mathbf{W} \mathbf{B} \quad \dots \dots \dots \text{EQ3.99}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-55



XIAN JIAOTONG UNIVERSITY

§ 3.7 双向联想记忆

对非齐次BAM网络, 其能量函数定义为:

$$E(\mathbf{A}, \mathbf{B}) = -\mathbf{A}^T \mathbf{W} \mathbf{B} + \mathbf{A}^T \boldsymbol{\theta} + \mathbf{B}^T \boldsymbol{\mu} \quad \dots \dots \dots \text{EQ3.100}$$

其中 $\boldsymbol{\theta} = (\theta_0, \theta_1, \dots, \theta_{N-1})^T$, θ_i 为 \mathbf{A} 的第 i 个元素 a_i 对应的阈值。
 $\boldsymbol{\mu} = (\mu_0, \mu_1, \dots, \mu_{P-1})^T$, μ_j 为 \mathbf{B} 的第 j 个元素 b_j 对应的阈值。

若神经元非线性函数 f 为硬限幅特性, 以 sgn 表示, 则描述BAM动态特性的差分方程式如下:

正向传输 ($\mathbf{B} \Rightarrow \mathbf{A}$):

$$a_i(t+1) = \begin{cases} \text{sgn} \left[\sum_{j=0}^{P-1} w_{ij} b_j(t) - \theta_i \right] & \text{当 } \sum_{j=0}^{P-1} w_{ij} b_j(t) - \theta_i \neq 0 \text{ 时} \\ a_i(t) & \text{当 } \sum_{j=0}^{P-1} w_{ij} b_j(t) - \theta_i = 0 \text{ 时} \end{cases} \quad \text{EQ3.101}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-56



XI'AN JIAOTONG UNIVERSITY

§ 3.7 双向联想记忆

反向传输 ($\mathbf{A} \Rightarrow \mathbf{B}$):

$$b_j(t+2) = \begin{cases} \text{sgn} \left[\sum_{i=0}^{N-1} w_{ij} a_i(t+1) - \mu_j \right] & \text{当 } \sum_{i=0}^{N-1} w_{ij} a_i(t+1) - \mu_j \neq 0 \text{ 时} \\ b_j(t+1) & \text{当 } \sum_{i=0}^{N-1} w_{ij} a_i(t+1) - \mu_j = 0 \text{ 时} \end{cases} \quad \text{EQ3.102}$$

下面我们证明, 网络在演变过程中能量函数 E 递减, 即 $\Delta E < 0$ 。

设 a_i 发生变化, 由于其取值为 -1 或 1 , 所以 Δa_i 的取值为 $-2, 2$ 两种情况。为书写简便, 下面的推导省去时序变量。

由EQ3.100可得:

$$\Delta E = -(\Delta \mathbf{A}^T) \mathbf{W} \mathbf{B} + (\Delta \mathbf{A}^T) \boldsymbol{\theta} = -(\Delta \mathbf{A}^T) (\mathbf{W} \mathbf{B} - \boldsymbol{\theta}) \quad \text{More...}$$

$$= -\sum_{i=0}^{N-1} (\Delta a_i) \left(\sum_{j=0}^{P-1} w_{ij} b_j - \theta_i \right) \quad \text{EQ3.103}$$

2004-8-8 《神经网络导论》——Hopfield神经网络 3-57



XI'AN JIAOTONG UNIVERSITY

§ 3.7 双向联想记忆

如果 $\Delta a_i = -2$, 即 a_i 从 1 变为 -1 , 由EQ3.101可知必有

$$\sum_{j=0}^{P-1} w_{ij} b_j - \theta_i < 0 \quad \text{故有 } \Delta E < 0。$$

如果 $\Delta a_i = 2$, 即 a_i 从 -1 变为 1 , 由EQ3.101可知必有

$$\sum_{j=0}^{P-1} w_{ij} b_j - \theta_i > 0 \quad \text{故有 } \Delta E < 0。$$

联系

第二次实验
双向联想记忆BAM
地址: <http://home.xjtu.edu.cn/teacher/zhangjg>

2004-8-8 《神经网络导论》——Hopfield神经网络 3-58



XI'AN JIAOTONG UNIVERSITY

§ 3.8 本章小结

本章我们讨论了Hopfield网络的电路模型及其能量函数。在此基础上介绍了Hopfield网络A/D变换器及非对称网络的A/D变换器; 讨论了用Hopfield网络求解TSP问题及货流问题, 这些都是Hopfield网络的典型应用。最后, 介绍了Hopfield网络在联想记忆方面的应用。

Hopfield网络的几个主要特点:

- (1) Hopfield网络是一个复杂的动力学系统, 稳定性分析成为不可避免困难问题, 这不同于前向网络, 它是一种输入到输出的映射模型。
- (2) Hopfield网络的学习(训练)主要采用Hebb规则, 收敛速度较前向网络快得多。
- (3) Hopfield网络可以用于优化计算和联想记忆, 两者实际上是对偶的。在优化计算方面, 由于Hopfield网络较成功地求解了NPH问题, 因此人们对它寄予厚望。

2004-8-8 《神经网络导论》——Hopfield神经网络 3-59



XI'AN JIAOTONG UNIVERSITY

附录A. EQ3.28的推导

$$E = \frac{1}{2} \left(x - \sum_{i=0}^3 2^i V_i \right)^2 - \frac{1}{2} \sum_{i=0}^3 2^{2i} V_i (V_i - 1)$$

$$= \frac{1}{2} x^2 - x \sum_{i=0}^3 2^i V_i + \frac{1}{2} \left(\sum_{i=0}^3 2^i V_i \right)^2 - \frac{1}{2} \sum_{i=0}^3 2^{2i} V_i^2 + \frac{1}{2} \sum_{i=0}^3 2^{2i} V_i$$

$$= -\sum_{i=0}^3 (2^i x - 2^{2i-1}) V_i + \frac{1}{2} \left(\sum_{i=0}^3 2^i V_i \right) \left(\sum_{j=0}^3 2^j V_j \right) - \frac{1}{2} \sum_{i=0}^3 2^{2i} V_i^2$$

$$= \frac{1}{2} \sum_{j=0}^3 \sum_{i=0, i \neq j}^3 2^{(i+j)} V_i V_j - \sum_{i=0}^3 (2^i x - 2^{2i-1}) V_i$$

Return

2005-6-2 《神经网络导论》——第三章附录 3A-60

XIAN JIAOTONG UNIVERSITY

附录B. 对TSP双下标的说明

$$w_{X_i, Y_j} = -\alpha \delta_{XY} (1 - \delta_{ij}) - \beta \delta_{ij} (1 - \delta_{XY}) - \gamma - \lambda d_{XY} (\delta_{j, i+1} + \delta_{j, i-1})$$

$$w_{A2, A1} = -\alpha - \gamma$$

$$w_{B1, A1} = -\beta - \gamma$$

$$w_{B2, A1} = -\gamma - \lambda d_{AB}$$

$$w_{C3, A1} = -\gamma$$

Return

2005-6-2 《神经网络导论》——第三章附录 3A-61

XIAN JIAOTONG UNIVERSITY

附录C. 对自联想记忆的说明

假设现在输入的是标准样本 \mathbf{X}_0 ，那么

$$\begin{aligned} \mathbf{Y} &= \text{sgn}(\mathbf{W}\mathbf{X}_0) \\ &= \text{sgn}\left[\left(\sum_{s=0}^{M-1} \mathbf{X}_s \mathbf{X}_s^T - \mathbf{I}\right)\mathbf{X}_0\right] \\ &= \text{sgn}\left[\sum_{s=0}^{M-1} \mathbf{X}_s \mathbf{X}_s^T \mathbf{X}_0 - \mathbf{M}\mathbf{X}_0\right] \\ &= \text{sgn}\left[\mathbf{X}_0 \mathbf{X}_0^T \mathbf{X}_0 + \sum_{s=1}^{M-1} \mathbf{X}_s \mathbf{X}_s^T \mathbf{X}_0 - \mathbf{M}\mathbf{X}_0\right] \\ &= \text{sgn}\left[120\mathbf{X}_0 + \sum_{s=1}^7 \mathbf{X}_s \mathbf{X}_s^T \mathbf{X}_0 - 8\mathbf{X}_0\right] \\ &= \text{sgn}\left[112\mathbf{X}_0 + \sum_{s=1}^7 \mathbf{X}_s \mathbf{X}_s^T \mathbf{X}_0\right] \end{aligned}$$

Return

2005-6-2 《神经网络导论》——第三章附录 3A-62

XIAN JIAOTONG UNIVERSITY

附录D. 对双向联想记忆能量变化的说明

设从 t 时刻到 $t+1$ 时刻，系统由 \mathbf{B} 联想 \mathbf{A} ，则

$$E(t) = -\mathbf{A}^T(t)\mathbf{W}\mathbf{B}(t) + \mathbf{A}^T(t)\boldsymbol{\theta} + \mathbf{B}^T(t)\boldsymbol{\mu}$$

$$E(t+1) = -\mathbf{A}^T(t+1)\mathbf{W}\mathbf{B}(t+1) + \mathbf{A}^T(t+1)\boldsymbol{\theta} + \mathbf{B}^T(t+1)\boldsymbol{\mu}$$

已知 $\mathbf{B}(t+1) = \mathbf{B}(t)$ ，令 $\Delta\mathbf{A} = \mathbf{A}(t+1) - \mathbf{A}(t)$ 可得：

$$\begin{aligned} \Delta E &= E(t+1) - E(t) \\ &= -[\mathbf{A}^T(t+1) - \mathbf{A}^T(t)]\mathbf{W}\mathbf{B} + [\mathbf{A}^T(t+1) - \mathbf{A}^T(t)]\boldsymbol{\theta} \\ &= -\Delta\mathbf{A}^T\mathbf{W}\mathbf{B} + \Delta\mathbf{A}^T\boldsymbol{\theta} \end{aligned}$$

Return

2005-6-2 《神经网络导论》——第三章附录 3A-63