

分区适应截值模型及其 在交通标志识别中的应用*

常胜江 申金媛 张延焯

(南开大学现代光学研究所, 天津 300071)

摘 要 针对 Hopfield 网络模型在存储模式不满足 0 和 1 状态均匀分布及数目对等的条件下存储容量及寻址能力下降的缺点, 提出并用光束方向编码光学实现了三值(1, 0, -1)互连的分区适应截值模型, 并把这一模型应用到交通标志的识别中, 结果表明该模型及光学系统有很好的稳定性。

关键词 神经网络, 互连权重, 分区适应截值, 正交化算法。

1 引 言

光学中通常采用的神经网络模型, 如 Hopfield 模型等, 对存储矢量有着较严格的要求, 即存储矢量所对应的每个神经元的状态[0(表示抑制)或1(表示兴奋)]需相对独立, 0 和 1 状态均匀分布且应有对等的数目, 而且存储矢量间的汉明(Hamming)距离不能太小。当存储矢量不满足上述要求时, 存储容量急剧下降且容易出现假态。然而, 实际的光学图像往往不具备神经网络模型所要求的理想像素分布, 因此限制了 Hopfield 网络模型的实际应用。为了对 0 或 1 数目不对等进行补偿, 人们提出了互补图像法^[1], 但这种方法在光学实现时牺牲了空间带宽积。另一种补偿方法是混沌编码法^[2], 这种编码方法是采用混沌发生器经多次叠代进行的, 缺点是编码方法十分烦琐且不能实时进行。为了克服假态的出现, Bruce^[3]提出了最邻近算法, 虽然避免了假态的出现, 但这种算法容易把非同类的模式归为一类, 产生误判。基本算法为赝逆算法的 H-K 模型^[4]避免了当存储模式不满足理想像素分布时出现假态导致存储容量下降的缺点。本文引入了与赝逆算法有同等效果但计算量小的正交化算法^[5, 6], 并针对光学无法实现高灰阶互连权重的弱点, 提出了分区适应截值算法, 对由正交化方法处理后得到的高动态范围的互连矩阵进行了二值化处理, 建立了三值互连的分区适应截值模型。这一模型克服了 Hopfield 模型在存储模式 0、1 状态分布不均匀及模式间汉明距离较小时, 出现假态导致存储容量急剧下降的缺点。同时, 针对光学系统难以表示负值的弱点, 本文提出了光束方向编码方法, 给出了存储模式为交通标志时的实验结果。结果表明, 该模型及光学系统有很好的稳定性。

* 国家攀登计划认知科学(神经网络)重大关键项目和国家自然科学基金资助。

收稿日期: 1995 年 11 月 24 日; 收到修改稿日期: 1996 年 4 月 4 日

2 正交化算法及适应截值模型

给定一组双极矢量 $V_i^{(m)}$ ($i = 1, 2, \dots, N$, $m = 1, 2, \dots, M$), $V_i^{(m)}$ 取值为 +1 或 -1, N 为网络的神经元数目, M 为存储的模式数目, 通过 Gram-Schmidt 正交化处理, 可以得到正交化的矢量 $V^{*(m)}$ [5]:

$$V^{*(m)} = V^{(m)} - \sum_{m_0=1}^{m-1} \left[\frac{V^{(m)} \cdot V^{*(m_0)}}{\|V^{*(m_0)}\|} \right] V^{*(m_0)} \quad (1)$$

这里 $[V^{(m)} \cdot V^{*(m_0)}]$ 表示两者的内积, $\|V^{*(m_0)}\|$ 为 $V^{*(m_0)}$ 的平方模。对于一个给定的矩阵 $T^{(m-1)}$, 由递推算法可得记忆矩阵 $T^{(m)}$ 为

$$T^{(m)} = \begin{cases} T^{(m-1)} + (1 - T^{(m-1)}) V^{(m)} \frac{V^{*(m)T}}{\|V^{*(m)}\|}, & \text{if } \|V^{*(m)}\| \neq 0 \\ T^{(m-1)} & \text{otherwise} \end{cases} \quad (2)$$

$V^{*(m)T}$ 表示 $V^{*(m)}$ 的转置矩阵, $T = T^{(M)}$ 是正交化记忆矩阵。初始记忆矩阵 $T^{(0)}$ 为零矩阵或单位矩阵。利用正交化模式间内积为零的关系, 从(2)式可以得到正交化互连权重为:

$$T_{ij} = \sum_{m=1}^M \frac{V_i^{(m)} V_j^{*(m)}}{\|V^{*(m)}\|} \quad (3)$$

当进行内容寻址时, 网络的迭代规则可写为

$$v_i(t+1) = \text{sgn} [T_{ij} v_j(t)] \quad (4)$$

此处存储模式采用单极(1, 0)形式, 在建立分区适应截值模型时, 先把单极存储矢量 $V^{(m)}$ 转换成双极形式 $V_b^{(m)} = 2V^{(m)} - 1$, 将 $V_b^{(m)}$ 代入(1)式进行正交化处理, 然后根据推导的公式(3)求解互连权重。虽然正交化方法能够提高网络的存储容量及寻址能力, 但它导致互连权重的动态范围加宽, 用光学方法实现其互连权重有很大的困难。因此, 互连权重的二值化是光学实现的关键问题, 作者曾采用 Clipped 模型(截值点为 0) [7] 及适应截值模型 [8] 的截值方法对由(3)式求得的互连权重进行了二值化处理, 得到的三值互连权重在存储模式不具备理想像素分布时网络性能改善不大。可见, 上述的截值方法失掉了互连权重中经正交化算法所提取的一些重要信息。对于神经网络来说, 外部的信息分布存储在网络的互连矩阵之中, 互连矩阵是外部信息在网络内部的表达形式。因此互连权重的最佳二值化处理应使互连中存储的信息量损失最少。从(4)式可以看出, 网络每一次迭代时互连子矩阵 $\{T_{ij}\} j = 1, 2, \dots, N$, 只与第 i 个神经元的下一个状态有关而与其他神经元的下一个状态没有关系, 此时这一互连子矩阵 $\{T_{ij}\} j = 1, 2, \dots, N$ 与其他互连子矩阵 $\{T_{xj}\} j = 1, 2, \dots, N, x \neq i$ 相对独立。因此可以对每个互连子矩阵单独进行截值处理。为此, 本文提出了以每个互连子矩阵中信息损失最少为原则的分区适应截值算法。方法如下:

设正数 m_i 是由(3)式得到的互连子矩阵 $\{T_{ij}\} j = 1, 2, \dots, N$ 的截值点, 截值后的互连子矩阵元为 W_{ij} , W_{ij} 满足下式:

$$W_{ij} = \begin{cases} m_i & T_{ij} > m_i \\ 0 & |T_{ij}| \leq m_i \\ -m_i & T_{ij} < -m_i \end{cases} \quad (5)$$

由截值引起的互连子矩阵元的误差为:

$$\Delta W_{ij} = T_{ij} - W_{ij} = \begin{cases} T_{ij} - m_{ij} & T_{ij} > m_i \\ T_{ij} & |T_{ij}| \leq m_i \\ T_{ij} + m_i & T_{ij} < -m_i \end{cases} \quad (6)$$

对于互连子矩阵中所有的矩阵元, 截值引起总的误差为:

$$\Delta W_i = \sum_{j=1}^N |\Delta W_{ij}| \quad (7)$$

使(7)式为最小的 m_i 点就是互连子矩阵 $\{T_{ij}\} j = 1, 2 \dots N$ 的最佳截断点。

由(5)式可以看出, 对互连子矩阵 $\{T_{ij}\} j = 1, 2 \dots N$ 截值后得到的互连子矩阵 $\{W_{ij}\} j = 1, 2 \dots N$ 只有 0 和 $\pm m_i$ 三个值, 由于 m_i 为正数, 且神经元的激活函数为符号函数[见(4)式], 进行内容寻址时从互连子矩阵 $\{W_{ij}\} j = 1, 2 \dots N$ 中提出 m_i 不影响第 i 个神经元的迭代结果, 此时 $\{W_{ij}\} j = 1, 2 \dots N$ 相当于三值(+1, 0, -1) 子矩阵。对其他子矩阵作同样的处理后, 可以得到与 T 相对应的三值互连矩阵 W 。从(7)式可见看出互连子矩阵的截值点与截值前的互连矩阵有着密切的关系, 而正交化互连矩阵又是存储模式在网络内部的表达形式, 因此上述的截值方法是对存储模式的适应截值方法, 由于截值过程是对每个互连子矩阵分别进行的, 截值过程最大程度地保留正交化方法所提取的信息。故把上述建立的三值互连模型叫作分区适应截值模型。

3 数值分析

3.1 存储模式为随机模式

利用数值模拟的方法, 采用多组随机存储模式, 对上述的分区适应截值模型进行了计算机模拟。网络的性能由内容寻址时的出错率描述, 出错率定义为:

$$q = 1 - \frac{[(2V - 1), (2V' - 1)]}{N} \quad (8)$$

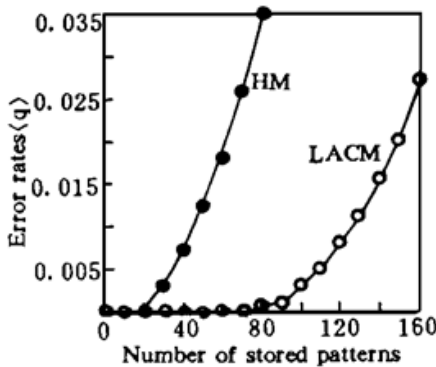


Fig. 1 Curves of average error rate $\langle q \rangle$ via M for locally adaptive clipped model (LACM) and Hopfield model (HM) respectively for $N = 1024$

V 为存储矢量, V' 为寻址矢量(存储模式本身或含有噪声的存储模式)经迭代稳定后的输出矢量, $[(2V - 1), (2V' - 1)]$ 表示两矢量的内积。对于大量随机矢量计算可得平均出错率 $\langle q \rangle$ 。定义 $\langle q \rangle < 0.015$ 时最大的 $\alpha = M/N$ 作为该网络的存储容量, 记为 α 。图 1 示出 $N = 1024$ 时分区适应截值模型(LACM)和 Hopfield(HM)模型的平均出错率 $\langle q \rangle$ 与 M 的关系曲线。从图可以看出, 分区适应截值模型的存储容量可达 $\alpha = 136/1024 = 0.13$, 而 Hopfield 模型的存储容量仅为 $\alpha = 57/1024 = 0.056$ 。可见分区适应截值模型的存储容量大大高于多灰度互连的 Hopfield 模型。在模拟中还发现, 网络基本一次迭代就能收敛到稳定的吸引子上。

3.2 交通标志为存储模式

随机模式基本都具有较理想的 0, 1 状态分布, 因而当以随机模式作为存储模式时, 网络有较理想的存储容量及寻址能力, 但现实中的模式(如光学中的图像)往往并不具备随机模式的特点, 因此研究网络在非理想存储模式下的性能具有更广泛的意义。本文以交通标志作为存储模式对分区适应截值模型进行了计算机模拟, 并与 Hopfield 模型、正交化 Clipped 模型

(截值点 $m_i = m = 0$) 及适应截值模型(把整个互连矩阵作为一个整体进行适应截值)进行了比较分析。选择交通标志作为存储模式的意义在于汽车自动驾驶中交通标志的识别是一个必须解决的问题。所用的交通标志图是用手持扫描仪对原始图像扫描进入计算机后,进行图像转换得到的规模为 32×32 个像素的二值(0, 1) 图像,如图 2(a) 所示。可见这些模式的 0、1 (黑白) 分布极不均匀,数目也不对等,且模式间的汉明距离很近(最小的汉明距离为 61)。图 2(b) 为以图 2(a) 中的 34 个交通标志作为寻址模式时,分区适应截值模型的输出的结果,此时输出模式的出错率 $\langle q \rangle = 0.0143$, 满足 $\langle q \rangle < 0.015$ 的定义。相应的存储容量为 $\alpha = M/N = 34/1024 = 0.033$, 与随机模式时的存储容量 $\alpha = 0.13$ 相比下降了 77%。当存储模式多于 34 个时,网络迭代收敛后出错率上升但不产生假态,也就是说分区适应截值模型避免了假态的出现。当以上述交通标志作为存储模式时, Hopfield 网络模型的存储容量很低,仅能存下二个模式,此时存储容量仅为 $\alpha = 0.00195$, 当存储模式多于二个时,假态出现,如图 3 所示。与随机模式时的存储容量 $\alpha = 0.057$ 相比下降了 97%。为了同其他三值互连模型进行比较,表 1 列出了几种不同截值模型在存储交通标志时存储容量的比较结果,从中可以看出,在非理想存储模式情况下,分区适应截值模型比其他的截值模型有更好的性能。




Fig. 2 Traffic sign as stored pattern (a) 34 traffic signs (b) recalled results



Fig. 3 The performance of Hopfield model when 3 traffic signs being as stored patterns. (a) 3 stored patterns (b) recalled patterns

Table 1. Performances of 3 neural networks model

model	spurious state	oscillating state	number of stored pattern
locally adaptive clipped model	no	no	34
orthogonalized Clipped model	yes	yes	2
adaptive clipped model	no	no	5

4 光学实现

针对光学无法表示负值的缺点, 作者提出了光束方向编码方法来实现双极互连权重的加权求和运算。实验装置如图 4 所示。




Fig. 4 Experimental setup

计算机取阈后送入开关阵列进行下一次迭代。

实验中所用的透镜阵列是由我们自己设计加工的, 主要参数为:

规模: 32×32 ; 外形尺寸: $48.64 \text{ mm} \times 48.64 \text{ mm}$;

每个小透镜尺寸: $1.52 \text{ mm} \times 1.52 \text{ mm}$; 焦距 $f = 20.00 \text{ mm}$ 。

由于市场没有现成的产品, 系统中所用的开关阵列是 MGL(s)-8032B 超扭曲液晶阵列图形显示器经改装而成的; 改装后的主要参数为:

开关单元数: 32×32 ; 响应时间: $< 100 \text{ ms}$

单元尺寸: $0.5 \text{ mm} \times 0.5 \text{ mm}$; 工作方式: 透射、电寻址

帧率: $> 25 \text{ frame/s}$; 对比度: $1:50$ 。

本文采用的光束方向编码原理是这样的: 精细调节反射镜 M_2 和半透半反镜 H_2 , 使经正模板和负模板的两路平行光在反射镜 M_3 上成为两个光点(位于两路光重合时在 M_3 形成的光点的两侧), 然后调节正模板和负模板(位置及角度)使它们的像重合于透镜阵列的前焦面上(P_1 面), 并使每一互连子矩阵与透镜阵列对应的小透镜精确对位。由透镜阵列和透镜 L_3 组成的 $4f$ 系统把 P_1 面上的每一互连子矩阵成像于开关阵列上并与开关阵列上的输入模式进行加权求和运算。由于采用的是平行光, 虽然正模板和负模板中的每个互连子矩阵的像在开关阵列上是重合的, 但两路光的方向不同, 经后面的成像透镜 L_4 后在 CCD 形成 $2 \times 32 \times 32$ 个光点, 水平方向上相邻的两个点分别对应于正和负互连子矩阵与输入模式内积的结果, 进行 A/D 转换后由计算机对两光点进行相减取阈。

在本实验中, 选择了 24 个交通标志作为存储模式(如图 5 所示), 按适应截值模型的方法可得其互连权重。由于存储模式为二维矢量, 对应的互连权重变为四维矩阵, 可按图 6 所示互连矩阵的排列方法把四维互连矩阵变成二维形式。采用电子扫描仪把互连模板制作在铬板上, 因此有很高的精度。

考虑到对位精度的要求, 制作互连模板时互连子矩阵要比透镜阵列中小透镜的尺寸小一些。表 2 分别给出了计算机模拟结果和相应的光学实验结果, 从中可以看出, 光学实验结果与计算机模拟结果基本一致, 只是实验上输出模式的出错率比计算机模拟结果要高, 寻址能力略有下降。分析其原因, 主要是光学系统的硬件误差引起的^[9]。同时, 表 2 显示出黑白像素分布均匀、数目对等的模式(第 11、12、13、14、15、16 和 17)有较强的寻址能力, 可见存

平行光经半透半反镜(H_1)分成两路分别照明互连权重的正、负模板($IWM+$, $IWM-$), 在第二块半透半反镜(H_2)处合光, 经由透镜 L_1 和 L_2 组成的 $4f$ 系统(互连权重正、负模板放在透镜 L_1 的前焦面上)后把正、负互连模板成像在透镜阵列(Lenslet array)的前焦面上(P_1 面)。由透镜阵列与透镜 L_3 组成的第二个 $4f$ 系统把每个互连子矩阵成像到开关阵列(LCSA)上, 与并关阵列上输入的模式作加权求和运算, 运算的结果由透镜 L_4 会聚到 CCD 上, 经计



Fig. 5 24 traffic signs as stored patterns




Fig. 6 Partition of a 4D interconnection matrix into an array of 2D submatrices

储模式对网络的性能是有一定影响的。

Table 2. results of computer simulation and optical implement

stored pattern as addressing pattern	number of pattern		1	2	3	4	5	6	7	8	9	10	11	12
	error bits of output pattern	computer samulation	1	0	1	0	1	1	3	1	1	3	0	0
		optical result	3	1	3	1	2	2	5	3	3	5	0	0
noise version of stored pattern as addressing pattern	ability of antinoise (error bits/N)	computer samulation	5%	5%	5%	6.5%	5%	5%	4%	4%	5%	4%	15%	15%
		optical result	4.6%	4.8%	4.6%	6%	4.5%	4.5%	3.5%	3.5%	4.8%	3.5%	15%	15%
stored pattern as addressing pattern	number of pattern		13	14	15	16	17	18	19	20	21	22	23	24
	error bits of output pattern	computer samulation	2	1	0	3	0	1	0	0	3	0	0	1
		optical result	4	1	0	5	0	3	2	2	5	2	1	1
noise version of stored pattern as addressing pattern	ability of antinoise (error bits/N)	computer samulation	8.5%	10%	15%	8%	15%	5%	5%	5%	4%	8%	5.5%	5%
		optical result	8%	9.8%	15%	7.5%	15%	4.6%	4.5%	4.5%	3.5%	7.5%	5%	4.7%

结 论 针对交通标志的特点，作者提出了以互连权重中信息损失最少为原则的分区适应截值方法，这一方法所建立的模型具有大的存储容量及较强的寻址能力，克服了当存储模式 0、1 数目不对等、分布不均匀及模式间汉明距离较小时，一些模型容易出现假态导致存储容量下降的缺点。由于分区适应截值模型的互连权重只有 -1, 0, +1 三个值，因此更易于光学实现，是一种理想的光学神经网络模型。

参 考 文 献

- [1] P. Mu, F. Yu., Encoding method for the implementation of the vector complementary extended Hopfield neural network model. *Optik.*, 1994, **96**(2): 65~ 68
- [2] G. Parodi, S. Ridella, R. Zunino, Using chaos to generate keys for associative noise-like coding memories. *Neural Network*, 1993, **6**(2): 559~ 572
- [3] Bruce. L. Montgomery, B. V. K. Vijaya Kumar, Evaluation of the use of the Hopfield neural network

- model as a nearest-neighbor algorithm. *Appl. Opt.*, 1986, **25**(20): 3759~ 3766
- [4] Brian Telfer, David P. Casasent, Ho-Kashyap optical associative processors. *Appl. Opt.*, 1990, **29**(8): 1191~ 1202
- [5] Huang Wu-Qun, A study on orthogonalized Hopfield model of neural network. CCAST-WL Workshop Series: 1994, **36**: 46~ 57
- [6] T. Lu, S. D. Wu, X. Xu *et al.*, Two-dimensional programmable optical neural network. *Appl. Opt.*, 1989, **26**(22): 4908~ 4913
- [7] N. H. Farhat, D. Psaltis, Optical implementation of the Hopfield model. *Appl. Opt.*, 1985, **24**(2): 1469~ 1475
- [8] 常胜江, 申金媛, 张延焯 基于正交代算法的三值互连神经网络模型. 光学学报, 1996, **16**(8): 1126~ 1132
- [9] 杨建文, 高胜泉, 光学神经网络中硬件误差对性能影响的分析. 光学学报, 1995, **15**(12): 1689~ 1696

Locally Adaptive Clipped Model and Its Application in of Traffic Sign Recognition

Chang Shengjiang Shen Jinyuan Zhang Yanxin

(*Institute of Modern Optics, Nankai University, Tianjin 300071*)

(Received 24 November 1995; revised 4 April 1995)

Abstract The storage capacity and addressability of Hopfield model decline greatly when stored patterns are not of independence and equal number of 1, 0 state. To remove this drawback, an neural networks of locally adaptive clipped model is proposed and realized with encoding method of beam direction. This model is also applied to the recognition of traffic sign. The experimental results show that locally adaptive clipped model and the optical system performs well.

Key words neural networks, interconnection weights, locally adaptive clipping, orthogonal algorithm.