

基于矢量量化及 Hopfield 模型的 灰度级图像识别*

叶旭 李志能 陈抗生

(浙江大学信息电子系, 杭州 310027)

摘 要 提出了一种新的识别灰度级图像的方法, 该方法基于矢量量化的基本思想, 通过对图像的分割, 将灰度级图像映射成神经元仅取少数几种状态(低态)的 Hopfield 神经网络模型。理论和模拟实验证明: 这种低状态的 Hopfield 网络模型与传统灰度级图像识别模型相比, 不仅神经元的数目较少, 互连密度较低, 而且网络具有较好的联想能力。

关键词 联想存贮, 神经网络, 灰度级图像, 矢量量化。

1 引 言

1982 年 Hopfield 提出的二值 Hopfield 网络模型在光学图像处理、模式识别等领域一直引起人们极大的兴趣。所谓二值指每个神经元只能取二个状态: 0 或 1, 因此, 这种二值 Hopfield 网络在二值化图像的处理识别中有很大的应用前景。然而为了表示丰富多彩的真实世界需要采用多灰度级图像, 若仍采用二值化图像处理显然会丢失大量信息, 因此, 如何将 Hopfield 模型应用于灰度级图像识别一直是不少学者关注的课题。如 Taketa 等把 Q 值像点(Q 为灰度级, 若图像为 256 级灰度, 则 $Q = 256$) 通过几个二值神经元的编码来表示^[1], 这样所有的二值神经元直接构成一个二值 Hopfield 神经网络模型, 但这样也增加了神经元的数目, 从而增加了网络的空间连线密度。Zhang 等在此基础上提出了一个减少互连线的方案^[2], 但该方案增加了对突触连接权重计算的复杂性。另外, 也有许多人想到将 Q 级灰度图像映射到 Q 种状态的 Hopfield 模型, 这种直接将 Q 值 Hopfield 模型应用于灰度级图像识别的方法与上述几种方法相比, 此时的神经元个数及空间连线密度将大大减少, 但这种 Q 状态神经网络模型的存储容量与 Q 值的平方成反比, 即: $\alpha \propto 1/Q^{2[3]}$ 。因此, 对于 Q 值较大(高态)模型具有低的存储容量和低的联想能力, 从而难以实用于灰度层次丰富的图像。

上述方法的基本思想均是从“数”的角度出发, 如将某个数字用二元数的编码表示等。若从图像本身特点出发, 将图像分割成各子块, 每一子块对应一神经元, 不同特性子块用不同状态神经元表示, 相同特性子块用同一状态神经元表示。另外, 尽可能按一定方式寻址图像子块的共同特性以保存各图像子块对应的神经元只取少数的几个状态, 这样即可将一幅灰度

* 本研究受国家自然科学基金项目(No. 69703004)资助。

收稿日期: 1996-11-02; 收到修改稿日期: 1997-01-20

及图像映射成每一神经元仅取少数几种状态的 Hopfield 网络(也称低态 Hopfield)。

本文正是基于这种思想,在分割过程中结合图像编码中的矢量量化技术,建立了低态 Hopfield 网络模型,这种方法不仅避免了将 Q 值像点通过二进制编码构成二值 Hopfield 网络所造成的神经元数目增多、网络连接复杂,而且与直接采用 Q 状态 Hopfield 相比,增大了网络的联想能力,从而能识别灰度层次丰富的图像。

2 基于矢量量化的灰度级图像分解

矢量量化^[4]是一种有效的编码方法,从数学意义上说,矢量量化的过程就是从 K 维矢量空间 R^k 向 R^k 的有限子集 W 的映射,即:

$$Q: R^k \rightarrow W$$

其中 $W = \{w_i | i = 1, 2, \dots, P\}$, P 为 W 中矢量的个数。通信中,称 w_i 为码字, W 为码书。将一幅图像先分成若干个图像子块,每一图像子块视为一个输入矢量(矢量维数 K 为子块大小),按一定测量准则选择码书 W 中的某个最接近输入矢量的码字 w_i 来表示它,这即量化过程:然后用该码字在码书中的序号(地址)来代表这个码字 w_i ,并将其存贮或传输,这是矢量量化中的编码过程。因此,在通信中这种只传输矢量序号(地址)而不是矢量本身的方法,大大地降低了码率。近几年不少学者成功地将自组织特征映射(SOFM)神经网络应用于码书设计中,提出了更为有效的 SOFM 算法^[5]。

本文提出的灰度级图像分解正是基于上述矢量量化的基本思想。假定某灰度级图像大小为 $N \times N$,灰度级为 Q ,将该图像按顺序分成各子块,每一子块大小为 $M \times M$,则共可分成 $(N/M) \times (N/M)$ 个子块。采用矢量量化的方法,根据 SOFM 算法用各图像子块作为输入矢量(矢量维数为 $M \times M$)训练码书,令码书大小为 P ,代表码书中有 P 个码字,即可用 P 个矢量表征 $\frac{N}{M} \times \frac{N}{M}$ 个子块,具体方法如下:对任意输入矢量(图像子块 x_j)都可在一定测量准则(矢量差的范数最小)下,在码书中选择出最接近输入矢量的码字 w_{i^*} (最佳码字),即:

$$d_{i^*} = \|x_j - w_{i^*}\| = \min_{1 \leq i \leq P} \|x_j - w_i\| \quad (1)$$

令其序号为 u ,则 $u = i^*$ 。为了便于叙述,图像子块与码字序号对应关系可简写成:

$$u = f[x_j] \quad (2)$$

其中, $f[\]$ 为综合(1)式的图像子块与码书中码字的序号映射操作:

$$u \in [1, 2, \dots, P] \quad \text{且} \quad j = 1, 2, \dots, N^2/M^2。$$

这样,就可用码书中 P 个序号的组合来表征一幅图像,从而完成图像分解过程。

现若把每一图像子块视为一神经元,则神经元状态可取 P 种。当然,从编码的观点看, P 的取值与传输码率 γ 、子块大小 $M \times M$ 等有关,即 $\gamma = \log_2 P / (M \times M)^{[4]}$ 。如取图像大小为 20×20 ,子块为 2×2 ,若传输码率 $\gamma = 0.5 \text{ bit/pixel}$,则 $P = 4$ 。这样大小为 $N \times N$ 的灰度级图像可映射成 $(N/M) \times (N/M)$ 个神经元,每个神经元具有 P 种状态的 Hopfield 网络。

3 灰度级图像识别的 Hopfield 网络模型

上一节讨论了采用矢量量化的方法将灰度级图像映射成 Hopfield 网络,其中每一神经元具有少数几种状态,而这种多值 Hopfield 网络实质上是二值 Hopfield 网络的推广,为了便于分析比较,下面先简单介绍多值 Hopfield 网络模型。

3.1 多状态 Hopfield 模型

假定网络共有 P 种状态, 则每一神经元的状态 $s_i \in \{\delta_1, \delta_2, \dots, \delta_p\}$, 其中, $\delta_u = 2u - P - 1$, ($u = 1, 2, \dots, P$)。如 $P = 4$, 则状态取 $\{-3, -1, 1, 3\}$ 。对于这种 P 状态的网络, 若采用 Hebb 学习规则, 则存储 G 个模式的网络互连权重 T_{ij} 的学习过程可描述为:

$$\begin{cases} T_{ij} = \frac{1}{\beta^2} \sum_{\mu} s_i^{\mu} s_j^{\mu}, & i \neq j \\ T_{ij} = 0, & i = j \end{cases} \quad (1 \leq i, j \leq N) \quad (3)$$

式中 s_i^{μ} 表示网络第 μ 个存储模式中第 i 个神经元的状态, 其中 $\mu = 1, 2, \dots, G$, G 为存储模式数, N 为神经元个数,

且
$$\beta = \left[\frac{N}{P} \sum_{k=1}^P (\delta_k)^2 \right]^{\frac{1}{2}}$$

例如, $P = 2$, $\delta_1 = -1$, $\delta_2 = 1$, 则 $\beta = \sqrt{N}$, 此时(3)式简化为:

$$T_{ij} = \frac{1}{N} \sum_{\mu} s_i^{\mu} s_j^{\mu}, \quad (1 \leq i, j \leq N)$$

此式即为众所周知的二值 Hopfield 网络的互连权值表达式。同样, 在网络的恢复过程中, 每个神经元按下式迭代:

$$\begin{aligned} S_i(t+1) &= \text{step}[h_i(t)] \\ h_i(t) &= \sum_{j=1}^N T_{ij} S_j(t) \end{aligned} \quad (1 \leq i \leq N) \quad (4)$$

其中, $\text{step}[\]$ 为阶梯函数, 作为多状态阈值过程。

3.2 算法实现

本节讨论灰度级图像识别的算法实现。首先, 基于矢量量化的思想, 将待存储的 G 个模式图像均分解成相同大小的子块, 采用自组织特征映射算法(SOFM)经过训练产生一个共用的大小为 P 的码书, 根据(1)式的最小失真原则, 在码书中为各模式图像中的每一子块分配一个最佳码字 w_i^* , 并用该码字在码书中的序号 u (即 i^*) 来表征该图像子块, 如(2)式所示, 这即灰度级图像的分解。然后, 将每一图像子块用一神经元代表, 每一神经元的状态(δ_u) 与该图像子块所分配的序号(u) 的对应关系为, $\delta_u = 2u - P - 1$, 其中 $1 \leq u \leq P$ 。所以码书大小




Fig. 1 The mapping from image to Hopfield network

为 P 亦表明神经元的状态为 P 种, 从而实现将灰度图像映射到 P 状态的 Hopfield 网络, 存储 G 个模式的网络权重的学习过程如(3)式所示。图 1 为图像的分解、映射示意图, 即该图像模式中第 i 个图像子块对应码书中第 u 个码字, 网络中第 i 个神经元, 其状态为 δ_u 。

理论证明, 基于 Hebb 学习规则的全并行多值神经网络, 其按 Lyapunov 形式定义的能量函数: $E = -\frac{1}{2} \sum_i \sum_j T_{ij} s_i s_j$ 总是向局部能量最小点运行, 所以对于一定的吸引域范围内的输入带噪声的图像, 经过上述分析过程转变成网络输入模式, 并按(4)式迭代后, 网络可恢复出原来的存储模式, 最后由下式得出欲识别的图像。

$$R = \sum_{j=1}^N f^{-1}(u_j)$$

其中, u_j 表示第 j 个神经元的状态序号, $f^{-1}()$ 为对应(2) 式的逆映射, 即由第 j 个神经元对应的状态序号 u 通过码书找出相应的图像子块 x_j , 求和(\sum) 运算是将图像子块合并: R 为识别后图像。具体算法框图如图 2 所示。

下面将本文提出的灰度级 (Q) 图像的 P 状态(低态) Hopfield 网络与二值 Hopfield 网络及 Q 值网络作一比较, 如表 1 所列。其中, 假定待处理的灰度级图像大小为 $N \times N$, 网络存储模式数目为 G 。另外, 表中的二值 Hopfield 网络是指每一像点的灰度值用二进制数编码, 每一位对应一个二元神经元。因此对于灰度级为 Q 的图像, 用这种方式的二进制编码, 每一像素最多可用 $\log_2 Q$ 个二值神经元表示, 这样所有的二值神经元直接构成一个二值 Hopfield 神经网络模型; Q 值 Hopfield 网络是指灰度级为 Q 的图像直接映射成神经元状态为 Q 的网络, 即实现图像像素与网络神经元的一一对应, 每一神经元的状态由对应像素的灰度值决定; 而对于本文提出的低态 Hopfield, 在表 1 中假定图像子块大小为 4×4 , 码书大小为 P (一般 $P \ll Q$)。故由表 1 中各项可看出, 二值 Hopfield 网络所需神经元个数最多, 网络互连密度最高, 而本文建立的模型其神经元个数及网络互连密度均大大减小, 并且它的吸引域, 即网络容错能力比 Q 值 Hopfield 网络也有了很大的改善。




Fig. 2 Block diagram of the algorithm

Table 1. Comparison of the ability of three model

	number of neuron	states of neuron	interconnection weight	basin of attraction
2 Hopfield	$(N \times N) \log_2 Q$	2	$[(N \times N) \log_2 Q]^2$	big
Q Hopfield	$N \times N$	Q	$(N \times N)^2$	small
(P) Hopfield	$N/4 \times N/4$	P	$(N/4 \times N/4)^2$	mid

3.3 可编程光电混合系统模型

鉴于光的快速并行处理能力及电的灵巧运算能力, 采用可编程光电混合方法模拟所建立的灰度级图像识别模型是非常理想的。综上所述, 本文提出的灰度级图像识别算法是基于 Kohonen 自组织特征映射及 Hopfield 混合神经网络模型。自组织特征映射算法用以设计矢量量化中的码书, 其学习过程采用电的方式由计算机编程实现; 而低态 Hopfield 网络可采用光




Fig. 3 Optical arrangement of the Hopfield network

电混合方法实现, 经计算机学习后的网络互连权值显示于监视器, 采用透射式彩色液晶电视显示输入模式, 由监视器显示的网络互连权值经平面微透镜阵列成像在透射式彩色液晶电视上, 这样在网络互连权值和输入模式间就建立了全互连, 再通过透射式彩色液晶电视和网络互连权值之间的透镜的求和作用可实现: $\sum_{j=1}^N T_{ij} s_j(t)$, 并由透镜成像在 CCD 上, CCD 采集到的图像信号送入计算机进行阈值(阶梯)处理, 再将结果送入透射式彩色液晶电视, 此过程循环往复, 直到检索出原来的理想模式。微透镜光路系统原理如图 3 所示。

本实验室已完成基于图 3 的 16 种颜色的联想识别^[6], 将每一神经元的状态赋予一种颜色, 鉴于颜色具有稳定性好、可运算的特点, 因此, 这种方法可推广到一般的多状态的光电实现, 对于本文建立的低态 Hopfield 网络, 若通过自组织特征映射算法分解、映射后的图像子块对应的神经元中的每一种状态也用一种颜色表示, 同样可采用图 3 的装置, 通过颜色运算正确反映神经元状态之间的运算关系, 以避免光学方法实现负值运算的困难, 最终实现低态 Hopfield 网络对灰度级的图像的联想识别。

4 模拟实验结果

在 SGI 工作站对灰度级图像进行了联想识别, 图 4(a) 为 4 幅灰度级存贮图像(灰度级为




Fig. 4 The simulation results on SGI

60), 每幅图像均由 20×20 像素组成。采用本文提出的灰度级图像识别技术, 将各输入图像分割成 2×2 图像子块, 并进行基于自组织特征映射算法的矢量量化, 通过训练得到一个共用的码书, 其大小 $P = 4$ 。训练图像施加 10% 的随机噪声即可获得如图 4(b) 所示的图像, 将图 4(b) 作为网络待识别的输入图像, 根据图 2 所示的算法框图运行最后可得图 4(c) 所示的恢复图像。由图可见, 本文提出的灰度级图像识别方法对于施加 10% 噪声的输入图像有很好的识别能力。

结 论 目前基于 Hopfield 网络的灰度级图像识别技术难以实用, 主要因为单纯用二进制方式增加网络的复杂性, 而直接采用 Q 值(Q 代表灰度级) Hopfield 网络大大降低网络的联想能力。本文针对这一矛盾, 提出的基于矢量量化的 Hopfield 网络灰度级图像识别方法, 不仅神经元数目减小, 网络互连密度降低, 且与直接采用 Q 值 Hopfield 网络相比, 因为神经元仅取少数几种状态, 故网络联想能力大大提高。模拟实验结果证明了这种方法的可行性。

参 考 文 献

- [1] M. Taketa, J. W. Goodman, Neural networks for computation number: representations and programming complexity. *Appl. Opt.*, 1986, **25**(17): 3033~ 3046
- [2] W. Zhang, K. Ltoh, J. Tanida, Hopfield model with multistate neurons and its optoelectronic implementation. *Appl. Opt.*, 1991, **30**(2): 195~ 200
- [3] T. Stiefvater, K. R. Muller, A finite-size scaling investigation for Q -state Hopfield models: storage

capacity and basins of attraction. *J. Phys. (A)*, 1992, **25**(22) : 5919~ 5929

[4] 姚庆栋, 毕厚杰, 王兆华等, 图像编码基础 1. 杭州, 浙江大学出版社, 1992 : 388~ 392

[5] A. K. Krishnamurthy, Neural networks for vector quantization of speech and images. *IEEE J. Select. Areas Commun.*, 1990, **8**(8) : 1449~ 1456

[6] 黄达诠, 黄海云, 多状态、多阈值神经网络模型的光电混合实现. 光学学报, 1996, **16**(6) : 772~ 776

Gray Image Recognition Based on Vector Quantization and Hopfield Network Model

Ye Xujun Li Zhineng Chen Kangsheng

(*Information and Electronic Department, Zhejiang University, Hangzhou 310027*)

(Received 2 November 1996; revised 20 January 1997)

Abstract A new kind of gray-level image recognition method is presented. By the image segmentation based on the vector quantization, the gray-level image can be mapped into an Hopfield network, each neuron has several states. The performance of this model is compared with that of the traditional model. It is concluded that the new one not only has a smaller number of neurons and interconnections. but also has better error correction capabilities.

Key words associative memory, neural network, gray-image, vector quantization.

勘 误

发表在光学学报 1997 年 17 卷 11 期 1599 页的“水窗波段同轴 X 射线全息成像及其数字重现”一文中最末一行的“横向分辨率优于 2 nm”应为“横向分辨率优于 2 μm ”, 特此勘误, 并致以歉意。

作者: 陈建文

1997. 11. 27