文章编号:1009 – 038X(2000)05 – 0506 – 04

可用于灰度图象处理的并行自适应加权识别系统模型

葛洪伟, 朱建鸿
(无锡轻工大学信息与控制工程学院,江苏无锡 214036)

摘 要:提出了一种可用于灰度图象处理的并行自适应加权识别系统模型,从理论上对该模型作了相应的数学描述和分析,并给出了将系统应用于灰度图象边缘检测的实例.

关键词:模式识别;神经网络;灰度图象;边缘检测
中图分类号:TP391.41 文献标识码:A

A Parallel Adaptive Ram Weighted Recognition System Model which Can be Used to Process Grey-Level Image

GE Hong-wei, ZHU Jian-hong
(Wuxi University of Light Industry, Wuxi, 214036)

Abstract: In this paper, we propose a parallel adaptive ram weighted recognition system model which can be used to process grey-level image and present the description and analysis of the model in theory. One example of using this system to detect grey-level image edge has also been given.

Key words: pattern recognition; neural network; grey-level image; edge detection

传统的图象处理几乎都是基于算法,其信息处理和存贮都局限在冯·诺依曼机器上串行或局部并行实现,其实时性、适应性、通用性都较差,对现实环境中的图象无法进行自动、高速的处理.而图象处理的神经网络方法对信息采用大规模并行分布式处理技术,更接近于人的视觉模型,是研究图象高速处理的一个新颖而重要的途径.英国 Aleksander 教授领导的研究小组在 1985 年研制成功了一种基于 n 元原理、由可重构内容寻址 RAM 阵列实现的松散基于神经元网络的模式识别系统 WISARD.其成果受到英国学术界、工业界及国家安全部门的重视,并一直得到英国 ALVEY 计划资助.而采用 RAM 加权技术的自适应模式识别系统改进了上述系统,提高了系统的识别能力[1].由于受结构的限制,这些系统都要求输入二值图象,其它图象需经过二值化后才能提供给系统识别或处理,这种处理方式无疑损失了许多模式间用以相互区分的有用信息,导致系统的识别、处理能力下降.为扩大系统的应用范围,作者在加权识别系统的基础上,提出了一种可直接处理灰度图象的并行识别系统模型,并对该系统模型从理论上进行了描述和分析.这种并行加权系统,可以用常规 RAM 芯片实现,其实时性、通用性强,这是其它任何传统图象处理算法难以做到的.随着 RAM 芯片价格不断下跌,这种系统更具其工业前程.最后文中以边缘检测为例,验证了模型的可行性和有效性.

收稿日期:2000 – 01 – 24;修订日期:2000 – 05 – 29.
作者简介:葛洪伟(1967 –),男,上海人,工学硕士,讲师.
万方数据

1　加权自适应识别系统简介

加权自适应识别系统的逻辑结构如图 1 所示. 其输入模式是 $m_1 \times m_2$ 的二值数据阵列,该阵列可以是一幅图象、一个字符或其它类型的模式数据. 它被随机或确定地划分成 k 个子模式,每个子模式为 n 维,故称为 n 元子模式. 每个 n 元分别连接到具有 2^n 个存贮单元的 RAM 地址端. 这样, $k = m_1 \times m_2/n$ 个内容寻址的 RAM 部件就构成了一个分类器的存贮空间. 对于 M 类问题一般需要 M 个分类器与之对应. 它们的训练单独进行,而分类则同时进行.

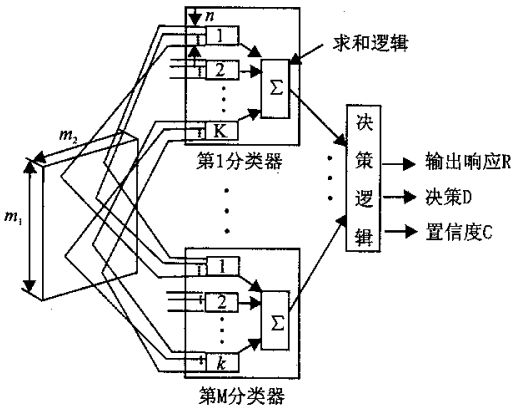


图 1　加权自适应识别系统的逻辑结构

Fig.1　Logical structure of weighted adaptive recognition system

在网络训练阶段,对一个分类器进行训练时,剩余空闲分类器的 RAM 附在被训练分类器上构成计数器,记录每个 n 元子模式的出现频率. 该分类器训练结束后,取适当的阈值,出现频率超出阈值的 n 元子模式将相应的 RAM 单元置为‘1’. 当一个模式类数据训练完毕后,再以同样的方式进行其它分类器的训练. 在分类阶段,各分类器 RAM 置为“读”状态,当未知模式输入系统时,各 n 元子模式同时寻址各分类器的 RAM,相应单元的内容被读出,每个分类器的所有 RAM 输出之和形成该分类器的响应. 决策逻辑根据各分类器的响应对未知模式进行分类,其分类决策采用最大响应决策原理. 有关该系统更为详细的介绍,包括其工作原理、理论描述、应用简例等请参见文献[1].

2　适于灰度图象处理的并行识别系统模型

2.1　系统结构

从上述介绍中可以看出,原加权系统仅适用于二值图象的识别和处理,为使系统具有灰度图象的识别和处理能力,现对原系统加以改造,使之具有图 2 所示的结构.

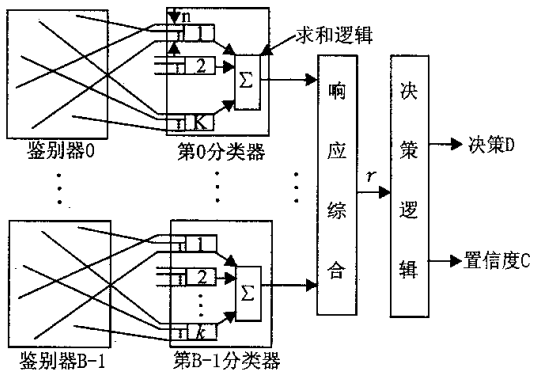


图 2　并行分布式灰度图象加权处理系统的模型

Fig. 2　Model of parallel distributed weighted system which was used to process grey-level image

对于一幅具有 2^B 个灰度级的图象,系统一般用 B 位二进制数来表示图象的象素点灰度. 可以很容易地将原图按位分解成 B 幅二值位平面图象,并且每幅二值图象对应于一个鉴别器. 用 B 个独立的鉴别器同时扫描这 B 幅二值图象,每个鉴别器分别对应于一个分类器网络,那么在任一位置处可同时得到 B 个分类器的响应值,然后根据这些响应值的加权和,就可以对输入模式作出判定,以达到灰度图象的识别或处理的目的. 这种分解灰度图象的方法无需算法,对存贮图象的 RAM 按位访问即可达到分解目的.

2.2　系统模型的理论描述和分析

假设系统的 B 个鉴别器均有 R 个元素,在处理灰度图象时,这 B 个鉴别器以同步的方式逐点扫描 B 幅二值位平面图象,令 W 为其中任一鉴别器,它的输入模式可用向量表示为 :$(p_1, p_2, \cdots, p_R)$. 其中 $p_i = 0$ 或 $1 (1 \le i \le R)$.

取每个子模式为 N 个元素,则子模式个数为 : $K = R/N$.

假设对 W 所对应的分类器网络所训练的样本模式集 $T = \{T_1, T_2, \cdots, T_M\}$, M 为训练模式的个数. 其中任一样本模式 T_i 可用向量表示为 :$(p_1^i, p_2^i, \cdots, p_R^i)$ $(1 \le i \le M)$.

T_i 被抽取成 K 个 N 元组,即 K 个 N 元子模式,各 N 元组的状态一起构成一个 N 元组状态集,可记为 :$\{S_1^i, S_2^i, \cdots, S_k^i\}$,其中 $S_j^i (1 \le j \le K)$ 是第 j 个 N 元组的状态.

对于训练模式集 T 来说,所有训练模式的第 h

万方数据

个 N 元组状态,构成了一个 N 元组状态集 S_h,$S_h = \{S_h^1, S_h^2, \cdots, S_h^\alpha\}$,其中 $1 \le h \le k$,$\alpha \le M$. 而每种状态出现的次数则构成向量 $\boldsymbol{C_h}$,$\boldsymbol{C_h} = (\boldsymbol{C_h^1}, \boldsymbol{C_h^2}, \cdots, \boldsymbol{C_h^\alpha})$.

在加权系统中,若对 RAM 置位的阈值为 σ,则有效状态集为 S_h'. 对于 S_h 中任一元素 S_h^β($1 \le \beta \le \alpha$),当且仅当 $C_h^\beta \ge \sigma$ 时,$S_h^\beta \in S_h$,显然 $S_h' \subseteq S_h$.

令 U 为任一测试模式,它的第 j($0 \le j \le B-1$)个位平面模式和鉴别器 W 相对应. 该子模式可表示为($p_{j1}, p_{j2}, \cdots, p_{jR}$),和该模式相对应的各 N 元组的状态所构成的状态集可记为 $\{S_{j1}, S_{j2}, \cdots, S_{jk}\}$,鉴别器 W 所对应的网络对子模式 j 的响应值所构成的向量可表示为:($A_{j1}, A_{j2}, \cdots, A_{jk}$),其中

$$A_{jh} = \begin{cases} 1 & \text{若 } S_{jh} \in S_h' \\ 0 & \text{若 } S_j h \notin S_h \end{cases} \quad (1 \le h \le k).$$

由此得该子网络对子模式 j 的绝对响应值

$$A^j = \sum_{i=1}^{k} A_{ji}.$$

在灰度图象处理系统中,各二值子图象对系统决策所提供的有效信息是有差异的,通过对各子网的响应值进行加权处理,可以更有效地扩大系统对输入模式整体响应间的差距,提高系统的分类、处理能力. 在这种方式下,系统对测试模式 U 的总的绝对响应为

$$A^{U} = \sum_{j=0}^{B-1} \omega_j \cdot \sum_{i=1}^{k} A_{ji},$$

其中 ω_j 为加权系数.

当 U 和训练模式完全相同,每个分类器的响应值均为 K 时,总的绝对响应为最大:

$$A_{\max}^{U} = K \sum_{j=0}^{B-1} \omega_j$$

由此可以定义总的相对响应值 R^U 为

$$R^U = \sum_{j=0}^{B-1} \omega_j \cdot \left(\sum_{i=1}^{k} A_{ji}\right) / K \sum_{j=0}^{B-1} \omega_j \qquad (1)$$

从理论上讲,R^U 是可以预测的. 一般而言,系统中各子网络均训练相同的模式集,下面就在这种方式下,分单训练模式和多训练模式两种情形讨论 R^U 的计算.

1) 单训练模式情形

记训练模式为 T_1,其 N 元组状态集记为 S,$S = \{S_1, S_2, \cdots, S_k\}$.

当 $\sigma = 1$ 时,假设测试模式 U 的第 j 个位平面子模式的 N 元组状态集为 S^j,则绝对响应值 A^j 实际上就是 S 和 S^j 中具有相同状态 N 元组的个数.

记 T_1 和子模式 j 重迭部分的象素(即具有相同值的象素)占整个模式象素 R 的比例为 D_{j1}($0 \le D_{j1} \le 1$),D_{j1} 可称作 T_1 和子模式 j 的相对相似重迭度. 这样 RD_{j1} 即为 T_1 和子模式 j 中具有相同值的象素的个数,对于任一随机采样的 N 元组,所有 N 个象素均在重叠区域的概率为 D_{j1}^N(假设采样是独立的). 因此 T_1 和子模式 j 的相同 N 元组状态个数最可能为 KD_{j1}^N,即 $A^j = KD_{j1}^N$,而此时系统总的相对响应值 R^U:

$$R^U = \left(\sum_{j=0}^{B-1} \omega_j \cdot D_{j1}^N\right) / \sum_{j=0}^{B-1} \omega_j \qquad (2)$$

2) 多训练模式情形

设训练模式集 $T = \{T_1, T_2, \cdots, T_M\}$,$\sigma = 1$

定义 T 中任一模式 T_i($1 \le i \le M$)和测试模式 U 的第 j($0 \le j \le B-1$)个位平面子模式的相对相似重迭度为 D_{ji},则 D_{ji}^N 为任一 N 元组的所有 N 个象素均在 T_i 和子模式 j 的重迭区域的概率.

由于 T 中各个模式是非独立的,所以必须避免 T 中模式和 U 的重迭区域的多次计算. 定义($D_{jp} \cdot D_{jq} \cdot D_{jr} \cdots$)为训练模式 T_p、T_q、$T_r \cdots$ 和子模式 j 的公共相对相似重迭度. 那么($D_{jp} \cdot D_{jq} \cdot D_{jr} \cdots$)^N 即为任一 N 元组的所有 N 个象素均在此公共重迭区内的概率,由此系统对 U 的相对响应为

$$R^U = \left(\sum_{j=0}^{B-1} \omega_j \cdot \sum_{i=1}^{M} (-1)^{i+1} \cdot P_{ji}\right) / \sum_{j=0}^{B-1} \omega_j$$

其中 P_j^i 为 T 中第 i 个训练模式和子模式 j 的公共相对相似重迭度,可表示为

$$P_{ji} = \sum \left(\prod_{k=1}^{i} D_{ja_k}\right)^N \quad \forall \ \{a_1, a_2, \cdots, a_i \mid 1 \le a_x \le M, 1 \le x \le i\}.$$

2.3 系统模型用于灰度图象处理的实例

2.3.1 理论分析方法 以灰度图象的边缘检测为例介绍该系统的应用. 由于灰度图象中越高的位平面所包含的图象信息越重要,所以本例中取 $\omega_j = 2^j$($0 \le j \le B-1$),以体现出各位平面的重要性,此时根据(1)式,系统总的相对响应值为

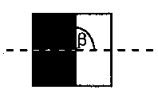
$$R^U = \left(\sum_{j=0}^{B-1} 2_j \cdot \sum_{i=1}^{k} A_{ji}\right) / (k(2^B - 1))$$

现假设只训练一个模式,该模式如图 3 所示,也就是说 B 个分类器均训练左边为黑(灰度级为 0),右边为白(灰度级为 $2^B - 1$)的模式,而输入的测试模式为无灰度变化的模式(灰度变化梯度角 $\theta = 0°$),此时,$D_{j1} = 0.5$ ($0 \le j \le B-1$),根据(2)式可得 $R_{\theta=0°}^U = (0.5)^N$. 当输入的测试模式和训练模式相同,即 $\theta = 90°$ 时,$D_{j1} = 1$ ($0 \le j \le B-1$),此时,$R_{\theta=90°}^U = 1$,$\theta = 90°$ 和 $\theta = 0°$ 时的相对响应值之比 $P_{90°/0°}^N = R_{\theta=90°}^U / R_{\theta=0°}^U = 2^N$. 如果输入的测试模式如图 4 所示,即灰度变化梯度角 $\theta = 45°$ 时的模式,此

万方数据

时

$$D_{j1}=\begin{cases}0.5 & \text{当 } 0\le j\le B-1\\ 1 & \text{当 } j=B-1\end{cases}$$



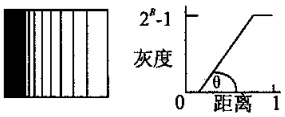


图 3　训练模式　　图 4　测试模式

Fig.3　Training pattern　　Fig.4　test pattern

由此,根据(2)式可得

$$R^{U}_{\theta=45^\circ}=[\sum_{j=0}^{B-2}2^j\cdot(0.5)^N+2^{B-1}]/2^B-1=$$
$$[(0.5)^N(2^{B-1}-1)+2^{B-1}]/(2^{B-1})>$$
$$(0.5)^N(0.5-2^{-B})+0.5$$

显然,$\theta=45^\circ$和$\theta=0^\circ$时的相对响应值之比 $P^N_{45^\circ/0^\circ}>0.5+2^{N-1}-0.5^B>2^{N-1}$.

系统在实际应用中,$N\ge4$,此时 $P^N_{90^\circ/0^\circ}$和$P^N_{45^\circ/0^\circ}$均有较大的值.

采用类似的计算方法,不难推算出,当 θ 为其它值时,$P^N_{\theta/0^\circ}$也大于 1,这就说明系统对灰度变化梯度不为 0°的边缘模式的响应值大于对无边缘模式的响应.通过选取适当的阈值,系统就可以检测出不同灰度变化梯度角的边缘.

以上讨论了训练一个模式的情形,实际应用中,可训练图 3 中 $\beta=45^\circ\times j$ $(0\le j\le7)$时的 8 个模式或 $\beta=22.5^\circ\times j$ $(0\le j\le15)$时的 16 个模式,以检测出各个方向的边缘.另外,当训练模式集较大时,RAM 置位阈值 σ 一般应大于 1.

2.3.2　实验结果　实验所处理的图象为 256×256 的 4 值图象,如图 5 所示,共 2 幅,下图为上图加入随机噪声的图象.SOBEL 算子处理的结果如图 6 所示.

新系统模型的仿真软件已开发成功,本实验即在该仿真软件包上完成.实验时,取 $R=8\times8$,$N=4$,$\sigma=2$,两个分类器网络均训练 $\beta=22.5^\circ\times j$ $(0\le j\le15)$的 16 个模式,分类阈值取 0.12,实验结果如图 7 所示.由结果图象可以看出,系统较好地检测出了不同方向、不同灰度变化梯度角的边缘,特别是那些灰度变化快的边缘.另外和 SOBEL 算子处理的图象相比,本系统体现出较好的抗噪能力.



图 5　输入图象

Fig.5　Input image



图 6　SOBEL 算子处理的结果

Fig.6　SOBEL operator on input image

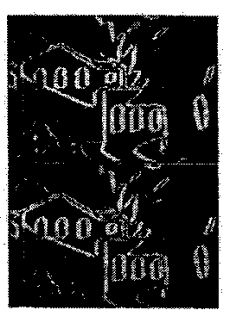


图 7　新系统的处理结果

Fig.7　New system applied to input image

参考文献

[1] 葛洪伟.采用 RAM 加权技术的自适应模式识别系统[J].无锡轻工大学学报,1999(1):82~86.

[2] ALEKSANDER I, THOMAS W V, BOWDEN P A, WISARD Radical Step Forward in Image Recognition[J]. **Sensor Review**, 1984,4(3):120~124

[3] ALEKSANDER I, MORTON H. An Introduction to Neural Computing[J]. **Chapman and Hall**, 1992:70~90.

[4] 王意洁.人工神经网络的分布并行处理[J].计算机学报,1997,(9):806~811.

(责任编辑:秦和平)

万方数据