

神经网络模式识别系统 互连权重二值化研究*

李豫华 孙 颖 申金媛 张延忻

(南开大学现代光学研究所, 天津 300071)

摘 要 在增量算法的基础上, 利用截断(Clipping)方法和蒙特卡罗(Monte Carlo)算法, 对以四类飞行目标平面旋转投影作为学习样本的级联神经网络互连权重进行了二值优化处理, 并用非学习样本进行了容错性检验, 计算机模拟得到了满意的结果。

关键词 模式识别系统, 神经网络互连权重, 灰度阶, 二值化。

1 引 言

光学系统的快速、大信息量及高度并行性使得用光学方法实现神经网络的复杂互连和并行运算备受重视。因此, 近几年国内外都已做了大量工作。并在许多方面得到应用, 其中包括三维多目标的模式识别问题^[1-3]。用光学神经网络方法研究多目标旋转不变性分类识别, 要涉及到对神经网络的模型研究, 学习算法研究以及硬件实现技术。但这些研究又是互相关联的^[4-7]。例如在硬件实现方面, 由于光学测量精度的影响, 权重灰度阶过大则难以在光学硬件上实现, 而简单的压缩权重灰度阶又势必会影响到网络的互连精度与目标识别性能。虽然文献^[8-9]通过改进学习算法对网络的互连权重的灰度阶进行了有效的控制, 但由于仍是多灰度阶分布, 在光学实现上仍存在许多技术问题。因此在保证不影响网络识别精度的前提下, 研究网络互连权重的灰度阶二值化(即取值 $\pm 1, 0$)的方法可以使得光学实现大为简单。

除此之外, 由于神经网络互连权重的学习是一个反问题, 至今仍没有现成的解析方法。因此, 对于互连权重二值化处理可使得权重的优化过程大为简化。

基于这种思想, 本文对多目标分类识别的级联神经网络, 采用有限灰度阶的增量学习算法、截断方法和蒙特卡罗算法相结合的方式, 对四类飞行器的平面旋转投影目标进行了学习训练, 得到了网络互连权重二值化(即 $\pm 1, 0$)后仍具有良好识别性能的结果, 从而为更好的光学实现奠定了基础。这种二值化的学习算法也可推广到其他神经网络的应用场合。

2 神经网络结构及学习算法

2.1 神经网络结构和原理

* 本研究课题为国家自然科学基金和攀登计划所资助。

收稿日期: 1995 年 4 月 27 日; 收到修改稿日期: 1995 年 11 月 27 日




Fig. 1 The cascaded neural network

为减少学习的复杂性和避免陷入局域极小的困难^[6]，本文采取了级联神经网络模型，根据最大相似度分类识别原理，系统由四层三级连接而成，如图 1 所示。外界目标成象于输入层，即第一层 (P_1)，产生输入层神经元的状态分布 $X(i, j)$ (即输入模式，其中 $X(i, j) \in (0, 1)$, $i = 1, \dots, I; j = 1, \dots, J$)，其神经元的个数为 $N_1(N_1 = I \times J)$ 。输入层与第二层 (P_2) 是一个异联想网络，即第一级网络，它实现对输入模式的旋转不变性编码，其互连权重的二值优化处理是实现光学模式识别的关键所在。第二层的神经元个数 N_2 即为特征码的码长；第二层与第三层即构成第二级网络，它给出第一级的输出与存储模式特征码之间相似度的测量。第三层的神经元个数 N_3 即为目标分类的个数；第三层与输出层组成第三级网络，即胜者全取(WTA)网络^[10]，它完成对目标的分类及输出该分类目标的标准图象或异联想输出，其输出层的神经元个数为 N_4 。由于各级之间权重是相对独立的(即可分别计算各自的权重)，因此，权重的学习过程将大大简化。实际上，这里第二和第三级网络的互连权重都已知，所以只需计算第一级网络的互连权重即可。并且由于这是一个单层多重感知机网络，其输出每个神经元的互连权重为独立的，也可分别得到。因此这种级联结构神经网络可使得网络的学习过程大为简化。

2.2 学习算法

为实现第一级网络互连权重二值优化处理，首先采用有限灰度阶的增量算法^[8]来对第二层的每一个神经元(其期望输出为对应目标的不变性编码值)分别进行网络的权重学习。为了控制互连权重的灰度阶，引入了一个控制因子 a_c ， a_c 取 1, 2, 3 ... 等正整数。并且 a_c 从 1 开始，这样就可得到使第一级网络收敛并且具有有限灰度阶的互连矩阵 $U_n(i, j)$, $n = 1, \dots, N_2$ ，然后对它们作二值化处理。

第一级网络的互连权重的二值化处理方法是将由上述算法得到的有限灰度阶互连权重进行截断运算，即

$$G_n(i, j) = \begin{cases} + 1, & \text{当 } U_n(i, j) > 0 \\ 0, & \text{当 } U_n(i, j) = 0 \\ - 1, & \text{当 } U_n(i, j) < 0 \end{cases} \quad (1)$$

其中 $n = 1, \dots, N_2; i = 1, \dots, I; j = 1, \dots, J; IJ = N_1$ 。

这样得到的二值化互连权重会使得网络的识别性能变坏。为保证网络的识别精度，作者采用修改的蒙塔卡罗算法对所得到的二值化互连权重进行进一步的调整，其方法如下：

1) 用第 p 类目标的全部学习样本，对二值化互连中的第 n 个互连矩阵 $G_n(i, j)$ ，进行检验。可按下式计算网络编码偏离初值 $d_k^0(p, n)$ 。

$$d_k^0(p, n) = C_{pn}(\sum_{i,j} G_n(i, j) X_{pk}(i, j)) - T_2 \quad (2)$$

式中 T_2 为阈值， C_{pn} 为第 p 类目标的第 n 位特征码， $X_{pk}(i, j)$ 为第 p 类目标的第 k 个样本的输入神经元状态， $k = 1, \dots, M_p$ ， M_p 为该目标的样本数。

2) 对 N_3 个不同目标的全部样本重复上述检验，按下式确定第 n 位码的误判样本数的初值 M_n^0 。

$$M_n^0 = \sum_p \sum_{k=1}^{M_p} m_k^0(p, n) \quad (3)$$

$$\text{式中 } m_k^0(p, n) = \begin{cases} 0, & \text{当 } d_k^0(p, n) > 0 \text{ (即识别)} \\ = 1, & \text{当 } d_k^0(p, n) \leq 0 \text{ (即误判)} \end{cases} \quad (4)$$

3) 求第 n 位码对所有误判样本的误码初值 D_n^0 。

$$D_n^0 = \sum_p \sum_{k=1}^{M_p} m_k^0(p, n) * d_k^0(p, n) \quad (5)$$

显然, $D_n^0 \leq 0$, 若 D_n^0 趋向零, 则网络的目标识别趋向正确。

4) 将互连矩阵 $\{G_n(i, j)\}$ 中的任一非零矩阵元 $G_n(i, j)$, 用 $G'_n(i, j) = -G_n(i, j)$ 替代, 即符号变号。然后重复 1) 至 3)。分别由 (3) 式和 (5) 式求出该矩阵元改变符号后的误判样本总数 $M_n(i, j)$ 和误码值 $D_n(i, j)$, 然后恢复该矩阵元的原值。

5) 遍历权重矩阵 $G_n(i, j)$ 中的每一非零矩阵元, 重复步骤 4)。完成一个循环后, 将 $D_n(i, j)$ 与 D_n^0 比较, 从中选取差值 $[D_n(i, j) - D_n^0]$ 最大的 $D_n(i', j')$ 及相应的 $G_n(i', j')$, 用 $D_n(i', j')$ 替代 D_n^0 , 并将 $G_n(i', j')$ 改变符号。再回到 4) 直到 $M_n(i', j') = 0$ 为止, 即网络收敛。

6) 若完成一个上述循环后没有 $D_n(i, j) > D_n^0$ 的情况出现, 且 $M_n(i, j) \neq 0$, 则退出循环, 网络不能收敛, 必须从有限灰度阶的增量算法开始, 重新计算互连权重矩阵 $G_n(i, j)$, 然后再重复以上过程, 直到网络收敛为止。

7) 对 $n = 1, 2, \dots, N_2$ 所对应的权重矩阵 $G_n(i, j)$, 重复上述过程, 直到所有 N_2 位特征码的二值化互连矩阵全部收敛为止, 网络的优化结束。

3 网络的容错性与合理编码

由于输入目标样本旋转不变的相似度是以第一级网络的输出与特征码的内积为度量的, 因此在选择不同目标特征码时, 应以它们之间的海明(Hamming)距离达到最大程度为准则。本文所选择的特征码如表 1 所示可以看出除本身以外, 它们任意两组编码之间的海明距离都为 4, 且是正交的。

Table 1. The targets' encoding

target	Cp1	Cp2	Cp3	Cp4	Cp5	Cp6	Cp7	Cp8
bomber plane	+ 1	+ 1	+ 1	+ 1	- 1	- 1	- 1	- 1
fighter plane	+ 1	- 1	- 1	+ 1	+ 1	+ 1	- 1	- 1
transport plane	- 1	+ 1	- 1	+ 1	+ 1	- 1	+ 1	- 1
rocket	- 1	- 1	- 1	- 1	- 1	- 1	- 1	- 1

其中: $p = 1, \dots, 4$ 为目标数。

4 计算机模拟及结果

本文对四类飞行目标(轰炸机、战斗机、运输机、火箭, 如图 2 所示)进行了计算机模拟, 其互连权重矩阵的二值化是由上述算法学习得到的。所选训练样本为每种飞行目标取 36 个面内旋转投影图象, 每个投影图象的象元数为 $N_1 = 20 \times 20$, 相邻两个投影图象之间的旋转角度为 10° 。四




Fig. 2 Four kinds of targets and training sets

类飞行目标共取 144 个投影图象作为学习样本。另取与学习样本旋转角度相差 5° 的投影图象共 144 个作为检验样本。在网络互连矩阵为二值化的条件下其计算机模拟结果如下:

- 1) 对于学习过的 144 个训练样本, 通过第一级网络即能全部正确判断目标的类型。
- 2) 对于非训练的 144 个检验样本, 虽通过第一级网络有 45 个出现误码, 但通过第二级、第三级网络的容错判断, 最后只有 6 个错误判断目标类别, 网络的正确识别率可达到 95.83%。

结 论 本文提出了一种利用增量算法、截断方法和蒙塔·卡罗算法相结合的方式, 对用于多目标分类识别的四层三级神经网络互连权重进行二值优化处理的新方法, 它克服了由于光学测量精度低造成的网络实现的困难, 从而为最后的光学实时实现奠定了可靠的基础。这一方法亦可推广应用于其他级联网络要求有二值互联的场合。

参 考 文 献

- [1] D. Casasent, Unified synthetic discrimination function computation formulation. *Appl. Opt.*, 1984, **23** (10): 1620~ 1627
- [2] G. F. Schils, D. W. Sweeney, An optical processor for recognition of 3-D targets viewed from any direction. *J. Opt. Soc. Am. A*, 1988, **5**(8): 1309~ 1321
- [3] Abdul Ahad S. Awwal, Gregory J. Power, Object tracking by an optoelectronic inner product complex neural network. *Opt. Eng.*, 1993, **32**(11): 2782~ 2787
- [4] K. Fukushima, Neural network model for selective attention in visual pattern recognition and associative recall. *Appl. Opt.*, 1987, **26**(23): 4985~ 4992
- [5] Yin Shizhuo, Cheng Lu, Mu Guoguang, 3-D target recognition by using serial-code-filters. *Optik*, 1989, **82**(4): 129~ 131
- [6] Zhang YanXin, Gao Chengqun, Huang Wuqun *et. al.*, A cascaded model of neural networks suitable for optical implementation. *Opt. Comp. and Proc.*, 1992, **2**(1): 3~ 8
- [7] Jayanta Basak, *et. al.*, A connectionist model for category perception: theory and implementation. *IEEE Trans. N. N.*, 1993, **4**(2): 257~ 269
- [8] 孙 颖, 李豫华, 张延忻等, 目标边缘增强对神经网络性能的改进. *红外与毫米波学报*, 1995, **14**(1): 67~ 70
- [9] 张延忻, 申金媛, 黄五群等, 三种 WTA 神经网络模型的模拟与分析. *模式识别与人工智能*, 1991, **5**(1): 1~ 7

Study on Binary Interconnection Weight of a Cascaded Neural Network for Pattern Recognition System

Li Yuhua Sun Ying Shen Jinyuan Zhang Yanxin

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

(Received 27 April 1995; revised 27 November 1995)

Abstract In this paper, based on the increment algorithm, the clipping learning method and Monto Carlo algorithm were used in optimization of a cascaded neural network. As a result, binary interconnection weights were obtained. The error-tolerance of the neural network was tested by non-learning sets. Computer simulation indicated that the results were satisfactory.

Key words pattern recognition system, interconnection weight, gray-levels, binary.