

用 Hopfield 网络实现二元串码滤波器*

刘 颖 路明哲 张建明 方志良 刘福来 母国光

(南开大学现代光学研究所, 天津, 300071)

摘要 根据 Hopfield 神经网络的优化功能设计二元串码滤波器. 对于识别同样数目的物体, 本方法所需要的滤波器数目较少, 且容错能力较强. 对适当的编码方法识别准确率可达 100%.

关键词 串码滤波器, 二元串码滤波器, 综合鉴别函数, 模式识别, 特征码.

引言

人工神经网络的主要应用之一为信号处理与模式识别. 随着光学模式识别研究的不断深入, 涉及的课题和目标日趋复杂化. 具有空间任意方向旋转不变性的三维目标模式识别及多目标识别便成为人们关注的复杂课题. 近年来, 人们提出了几种用单个滤波器来识别一组投影图像及多个图像的方法^[1~3], 综合鉴别函数 (SDF) 方法就是其中引人注目的一种^[1]. 多幅投影图像或多目标图像包含有大量的信息, 用一个滤波器往往不能解决这样复杂的问题. Schils 和 Sweeney 提出用一组滤波器 (称为锁栓滤波器 LAT)^[4]可以成功地识别多个目标及旋转目标, 但 LAT 滤波器设计和制作方法较复杂. 与 LAT 滤波器相比, 串码滤波器 (SCFs)^[5]不仅便于综合, 而且所需滤波器数目可大大减少.

本文提出用 Hopfield 网络异步迭代完成二元串码滤波器 (BSCF) 的优化设计, 对 26 个英文字母进行学习和识别. 计算机模拟结果表明, 该方法与一般的串码滤波器相比, 所需滤波器数目更少, 容错能力更强, 分类识别准确率可达 100%.

1 Hopfield 模型

设给定的一组存贮矢量为 $V_i^{(m)}$, $i=1, 2, \dots, N$; $m=1, 2, \dots, M$. N 为网络中神经元数目, M 为存贮矢量数. 网络的突触矩阵为

$$T_{ij} = \sum_m V_i^{(m)} V_j^{(m)}, \quad i \neq j \\ T_{ii} = 0. \quad (1)$$

* 国家自然科学基金资助项目

本文 1993 年 9 月 13 日收到, 修改稿 1994 年 1 月 12 日收到

神经元的演化方程为

$$V_i = \begin{cases} 1, & \sum T_{ij} V_j > U_i \\ 0, & \text{其它} \end{cases} \quad (2)$$

U_i 为系统的阈值，一般取 $U_i = 0$ 。在 Hopfield 模型中，能量函数的表达式为

$$E(m) = -\frac{1}{2} \left\{ \sum_i \sum_j T_{ij} V_i^{(m)} V_j^{(m)} - U_i V_j^{(m)} \right\}. \quad (3)$$

可证明，网络按式 (2) 进行演化的过程是网络能量函数单调下降的过程。对一个优化问题，如它的能量函数可写成式 (3) 的形式，就可利用 Hopfield 模型的神经网络进行优化。

2 串码滤波器的二元优化

串码滤波器采用多个滤波器对各个输入图像进行编码，根据编码的不同来判断输入目标的种类。设有多个目标物体 $f_i(x, y)$, $i=1, 2, \dots, N$, 要设计一组串码滤波器 $\{g_k\}$ ($k=1, 2, \dots, K$)，使 f_i 与 g_k 的内积为一常数，即

$$(f_i \cdot g_k) = C_{ik}, \quad i = 1, 2, \dots, N; k = 1, 2, \dots, K \quad (4)$$

每一个滤波器 g_k 可由综合鉴别函数方法求得，为

$$g_k = \sum_{i=1}^N a_{ik} f_i, \quad (5)$$

所以有

$$(f_i \cdot g_k) = \sum_{i=1}^N a_{ik} (f_i \cdot f_i) = C_{ik}, \quad k = 1, 2, \dots, K \quad (6)$$

这里先不考虑物体的旋转，因为我们的目的是要识别 26 个字母，即分类数目相对较多，所以暂不对滤波器提出过高要求。

设有 M 类物体 $f(m)$ ($m=1, 2, \dots, M$)，每一类物体各有一套特征码 $\{C_{mn}\}$ ($n=1, 2, \dots, N$, N 为物体编码的位数，同时也是滤波器的个数)， C_{mn} 的取值只能是 +1 或 -1。那么，我们期望能量函数

$$E = \sum_n \sum_m \{C_{mn} - \theta_{mn}[f(m) \cdot g(n)]\}^2 \quad (7)$$

最小，其中 $\theta_{mn}(\cdot)$ 是取阈操作，“.” 表示内积， $f(m)$ 与 $g(n)$ 均为 $L \times L$ 的二元二维矢量。这样，就要求优化后的滤波器 $g(n)$ 满足以下要求：当编码 C_{mn} 为 +1 时， $f(m)$ 与 $g(n)$ 的内积尽量接近一个期望值 NA ；当编码 C_{mn} 为 -1 时 $f(m)$ 与 $g(n)$ 的内积则尽量接近另一个期望值 NI 。也就是：当 $C_{mn}=+1$ 时， $[f(m) \cdot g(n)] \in [NA-\Delta_1, NA+\Delta_1]$ ；当 $C_{mn}=-1$ 时， $[f(m) \cdot g(n)] \in [NI-\Delta_2, NI+\Delta_2]$ 。这里 Δ_1 、 Δ_2 均为大于零的常数，且 $NA-\Delta_1 > NI+\Delta_2$ ，取 $\Delta_1=\Delta_2=\Delta$ 。

为了提高系统的容错能力和抗干扰能力, 我们需尽可能拉大 C_{mn} 取 +1 和 -1 的阈值差距, 即 NA 要尽可能大于 NI , 且 Δ 为尽可能小的正数。因此, 能量函数应写为

$$E = \sum_n \sum_m [NM(n, m) - f(m) \cdot g(n)]^2, \quad (8)$$

其中

$$NM(n, m) = \begin{cases} NA, & \text{当 } C_{mn} = +1 \text{ 时} \\ NI, & \text{当 } C_{mn} = -1 \text{ 时} \end{cases} \quad (9)$$

式(8)还可写为

$$E = \sum_n \sum_m [NM(n, m) - \sum_{x, y} f_m(x, y)g_n(x, y)]^2,$$

其中 $f_m(x, y)$ 和 $g_n(x, y)$ 分别为二维矢量 $f(m)$ 和 $g(n)$ 的一个分量, 这里 $x, y = 1, 2, \dots, L$. 就有

$$\begin{aligned} E &= \sum_n \sum_m \left[NM(n, m) - \sum_{x_1, y_1} f_m(x_1, y_1)g_n(x_1, y_1) \right] \\ &\quad \left[NM(n, m) - \sum_{x_2, y_2} f_m(x_2, y_2)g_n(x_2, y_2) \right] \\ &= \sum_n \sum_m \left\{ NM^2(n, m) - 2NM(n, m) \left[\sum_{x_1, y_1} f_m(x_1, y_1)g_n(x_1, y_1) \right. \right. \\ &\quad \left. \left. + \sum_{x_1, y_1} \sum_{x_2, y_2} f_m(x_1, y_1)f_m(x_2, y_2)g_n(x_1, y_1)g_n(x_2, y_2) \right] \right\}. \end{aligned} \quad (10)$$

当把二维矢量 $g_n(x, y)$ 作为输入矢量进行优化时, 与式(3)比较, 得到互连权重

$$W(i, j, k, l) = \sum_{n, m} f_m(i, j)f_m(k, l), \quad (11)$$

阈值

$$Th(i, j) = 2 \sum_{m, n} NM(n, m)f_m(i, j). \quad (12)$$

这里将式(10)中的 x_1, y_1, x_2, y_2 分别换成了 i, j, k, l .

采用离散非同步 Hopfield 模型的演化过程, 就可以对滤波器 $g(n)$ 进行优化设计, 使其能量函数不断降低, 直至达到局域最小。

3 特征码的选取

神经网络对串码滤波器是一个一个分别进行优化设计的, 无需考虑特征码的正交性及 +1 和 -1 的等几率性。我们的目标是识别 26 个英文字母 (见图 1), 使用 5 个滤波器 (即 $N=5$) 就足够了。

特征码的选取要考虑到 26 个英文字母互相之间形状上的特点以及彼此之间的相似与差异程度。例如：对于左边有一“竖”的字母（如 D、E、F、H、L、M、N、P、R、U 等），可令其 $C_{m1} = 1$ ；对于右边有一“竖”的字母（如 H、M、N、U 等），可令其 $C_{m5} = 1$ ；对于形状相似的字母（如 O 和 Q、E 和 F），就要求其特征码不同的位数不能相对较多。我们选取的特征码见表 1。在计算机模拟过程中，我们发现特征码的选取对优化后滤波器的容量、容错能力等均有影响，所以选取合适的特征码是很重要的一个环节。

表 1 特征码的选取及实际输出

Table 1 The characteristic codes and the real outputs

字母	特征码 C_{mn}					实际相关输出值 $f \cdot g$					实际输出特征码 C'_{mn}				
	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5
A	-1	-1	1	-1	1	16	14	50	16	52	-1	-1	1	-1	1
B	1	1	1	-1	1	57	47	47	21	47	1	1	1	-1	1
C	1	1	-1	1	1	44	44	20	50	46	1	1	-1	1	1
D	1	1	-1	1	-1	52	58	16	54	18	1	1	-1	1	-1
E	1	1	1	1	-1	58	50	52	54	18	1	1	1	1	-1
F	1	-1	1	1	-1	56	18	52	54	18	1	-1	1	1	-1
G	1	-1	1	1	1	46	30	42	56	58	1	-1	1	1	1
H	1	-1	1	-1	1	56	12	46	16	50	1	-1	1	-1	1
I	-1	1	1	1	-1	20	46	48	50	12	-1	1	1	1	-1
J	-1	-1	-1	1	-1	12	20	30	58	16	-1	-1	-1	1	-1
K	1	-1	1	-1	-1	52	20	52	18	18	1	-1	1	-1	-1
L	1	1	-1	-1	-1	51	49	19	15	17	1	1	-1	-1	-1
M	1	-1	-1	-1	1	54	14	24	22	54	1	-1	-1	-1	1
N	1	-1	-1	1	1	57	15	19	43	57	1	-1	-1	1	1
O	-1	1	-1	1	1	20	48	16	52	50	-1	1	-1	1	1
P	1	-1	-1	1	-1	52	16	22	40	20	1	-1	-1	1	-1
Q	-1	1	1	1	1	27	51	45	51	55	-1	1	1	1	1
R	1	-1	-1	-1	-1	50	24	26	24	18	1	-1	-1	-1	-1
S	-1	-1	-1	1	1	20	20	26	52	52	-1	-1	-1	1	1
T	-1	-1	-1	1	-1	12	16	46	54	12	-1	-1	1	1	-1
U	1	1	-1	-1	1	50	56	22	24	52	1	1	-1	-1	1
V	-1	1	-1	-1	-1	18	48	12	18	24	-1	1	-1	-1	-1
W	-1	-1	-1	-1	1	16	18	16	16	46	-1	-1	-1	-1	1
X	-1	-1	-1	-1	-1	14	16	18	14	16	-1	-1	-1	-1	-1
Y	-1	-1	1	-1	-1	15	11	41	17	19	-1	-1	1	-1	-1
Z	-1	1	-1	1	-1	16	54	18	50	16	-1	1	-1	1	-1

4 计算机模拟及结果

目标物体是 26 个 16×16 分量为 0, 1 的二维矢量（图 1），分别表示 26 个字母， $g(n)$ ($n=1, 2, \dots, 5$) 的初值是随机产生的 +1 和 -1 等几率的 16×16 的矢量。 NA 、 NI 的取值与待测目标有关，这里 NA 、 NI 、 Δ 分别取为 55、15、15。

如前文所述，利用 Hopfield 网络对 5 个滤波器分别进行优化设计。迭代次数一般约

为 $(L \times L)/4$. 我们发现, 滤波器采用不同的初始值, 有可能得到更好的二元滤波器, 这表明这个更好的解更接近于全部解空间的最佳解, 或者说, 这个更好的解对应的稳定态更接近于网络的全局最小.

目标识别时, 将待识别物分别与优化后的二元串码滤波器作内积, 取阈后得到特征码输出, 对 26 个字母识别的结果见表 1. 实际的输出码与原特征码完全相同, 可见用神经网络优化设计得到的二元串码滤波器性能优越.

另外, 我们还对这组二元滤波器进行了加噪声及缺损字符测试. 我们注意到, 即使是相同的随机噪声百分比(或字母缺损部分占该字母的百分比), 对不同的噪声分布(或不同的缺损部位), 字符的正确识别率不尽相同. 当每个字符有 5% 的随机噪声(图 2(a))时, 平均有 90.4% 的字符能被正确识别, 即它们的 5 个输出码均为原特征码. 若我们定义

$$\text{码的正确识别率} = \frac{\text{正确输出的码的个数}}{\text{输出码的总个数}(= 5 \times 26)}, \quad (13)$$

那么, 对于随机噪声为 5% 的情况, 码的正确识别率为 98.1%. 当每个字符有 10% 的随机噪声(图 2(b))时, 平均有 73.1% 的字符能被正确识别, 码的正确识别率为 92.3%. 字符缺损 5% 和 10% (图 3) 时, 字符的正确识别率及码的正确识别率分别与字符加 5% 及 10% 的噪声时的值相同. 这里, 字符的正确识别率不很高的原因在于我们没有将缺损字符和有噪声字符作为训练样本进行学习, 因为我们的目标是使滤波器能识别 26 个英文字母.

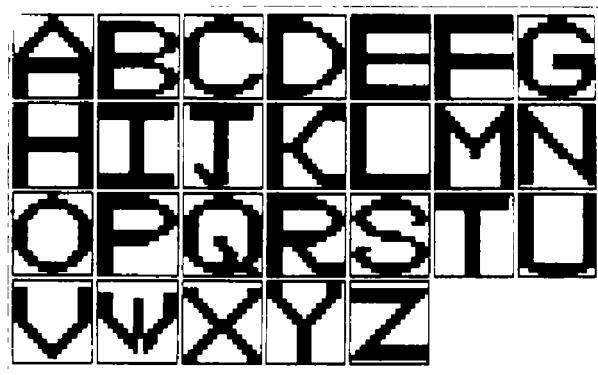


图 1 26 个英文字母, 每个含 16×16 个像素
Fig. 1 The 26 English letters, each with 16×16 pixels

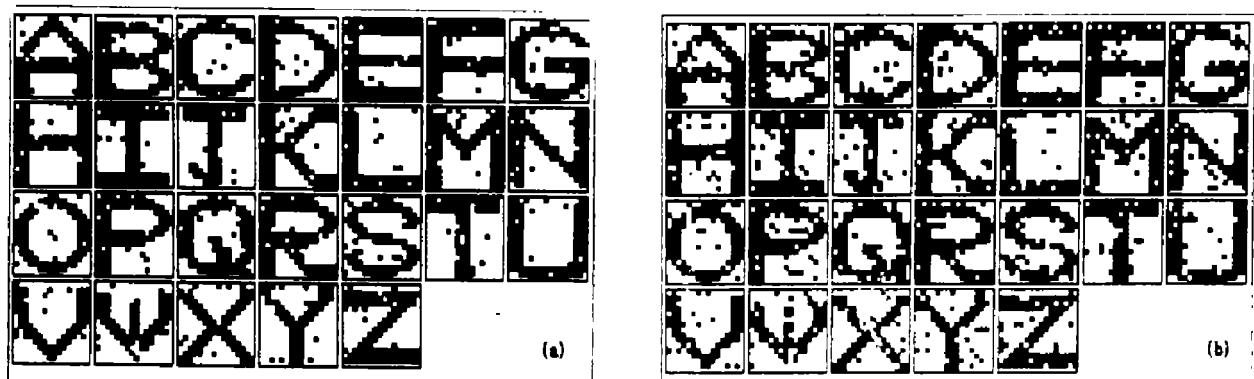


图 2 加随机噪声的字母, (a) 5% 的噪声, (b) 10% 的噪声
Fig. 2 Letters with 5% (a) and 10% (b) random noise

5 结论

本文提出一种利用 Hopfield 神经网络的优化功能来设计二元串码滤波器的方法. 该

方法基于对滤波器进行全方位优化设计, 所需滤波器数目少, 容错能力强, 易于用光学方法实现。

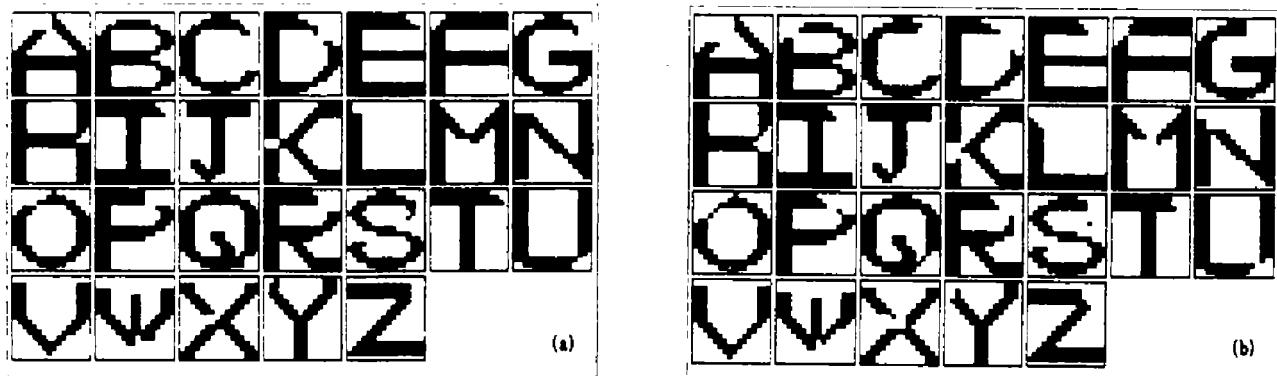


图3 缺损字母, (a)5% 的缺损, (b) 10% 的缺损
Fig. 3 Letters with 5% (a) and 10% (b) incompletely

参考文献

- 1 Casasent D. *Appl. Opt.*, 1984, **23**(10):1620~1627
- 2 Braunecker B, Hauck R, Lohnman A W. *Appl. Opt.*, 1979, **18**(16):2746~2752
- 3 Caulfield H J. *Appl. Opt.*, 1980, **19**(23):3877~3879
- 4 Schils G F, Sweeney D W. *J. Opt. Soc. Am.*, 1988, **A5**(8):1309~1321
- 5 Yin Shizhuo, Cheng Lu, Mu Guoguang. *Optik*, 1989, **82**(4):129~131

DESIGN OF BINARY SERIAL-CODED-FILTERS BY USING HOPFIELD MODEL*

Liu Ying Lu Mingzhe Zhang Jianming
Fang Zhiliang Liu Fulai Mu Guoguang

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

Abstract Binary serial-coded-filters (BSCFs) were designed based on the optimization functions of the Hopfield model. Less filters are needed to carry out the same recognition task, compared with other methods. The error-tolerant capacity is also very strong. All target objects can be correctly recognized when the characteristic codes are properly chosen.

Key words serial-coded filter, binary-serial-coded-filter, synthetic discriminant function, pattern recognition, characteristic code.

*The project supported by the National Natural Science Foundation of China