

# 基于人工神经网络的多路光学相关器相关峰的实时识别\*

余波 王汝笠 陈高峰 华铁均

(中国科学院上海技术物理研究所青年光电工程研究中心, 上海, 200083)

**A** **摘要** 提出一种应用人工神经网络根据多路光学相关器相关面输出图像识别目标的方法. 运用统计规律确定相关峰的位置, 不但把自相关峰作为目标特征, 还将互相关峰也引入了识别, 并通过神经网络实现相关峰复杂特征的抽取. 该方法能有效地排除目标背景干扰和器件性能波动的影响, 实现了对目标的实时识别.

**关键词** 神经网络, 多路光学相关器, 相关峰.

0437.4  
TP18

## 引言

近年来, 光学相关器的研究有了较大进展, 人们在光学系统小型化、滤波器优化设计技术和高帧速调制器等方面做了很多研究, 而对相关输出图像的自动分析没有引起足够的重视. 本文介绍了应用人工神经网络实现多路光学相关器相关峰实时识别的方法.

在多路相关器中, 由于各路匹配滤波器是处于同一系统中, 相互之间或多或少地存在干扰, 这就使各路相关峰的强度远赶不上在单路相关器中的强度, 不能用单路相关器中的阈值方法来区分相关峰和互相关峰. 而多路相关器并非多个单路相关器的简单组合, 多路带来了各路间的干扰, 但提供了利用互相关信息的可能性, 如果只孤立地识别各路, 实际上是牺牲了识别精度来换取识别数量. 为此, 我们采用同时使用多路相关信息的方法, 也就是当某一目标出现时, 不仅判断哪一路中出现了自相关峰, 还全局考虑到其它各路互相关峰的情况, 这种方法对特征的提取要求较高, 仅仅用一般的统计方法来确定不同目标的特征矢量是比较困难的. 另外, 由于受目标环境的影响, 相关峰的形状和强弱是变化的, 并且随着目标的移动而产生位移, 这就要求识别系统有较好的容错性能. 综合以上各种因素, 我们决定采用神经网络来对目标进行特征提取和识别.

## 1 BP神经网络模型

我们所采用的神经网络是比较成熟的3层BP神经网络模型, 神经元的非线性变换为

$$y_k^p = f(u_k) = \frac{1}{1 + e^{-u_k}} = \frac{1}{1 + e^{-\sum (w_{ij} z_j - \theta_k) / T^p}}, \quad (1)$$

权值修正公式为

$$w_{ij}(n+1) = w_{ij}(n_0) + \eta(n_0) \sum_p \delta_n^p X_i^p + \alpha \Delta w_{ij}(n_0). \quad (2)$$

\* 国防科工委预研基金资助项目, 编号 85A-I-128  
本文 1996 年 5 月 23 日收到, 修改稿 1996 年 10 月 7 日收到

对输出层:  $sq = jk$ ,

$$\delta_{jk}^P = (t_k^P - y_k^P) y_k^P (1 - y_k^P); \quad (3)$$

对隐层:  $sq = ij$ ,

$$\delta_{ij}^P = \sum_{k=0}^n \delta_{jk}^P w'_{jk} x_i^P (1 - x_i^P). \quad (4)$$

当  $\Delta E_E < 0$  时,

$$\eta(n_0 + 1) = \eta(n_0) \cdot \varphi, \quad \alpha = \alpha$$

当  $\Delta E_E > 0$  时

$$\eta(n_0 + 1) = \eta(n_0) \cdot \beta, \quad \alpha = 0 \quad (5)$$

其中  $\varphi > 1, \beta < 1, \Delta E(n_0) = E(n_0) - E(n_0 - 1)$ . 这里  $P$  为学习样本数,  $\delta_{sq}^P$  为各层的误差,  $\eta(n_0)$  为步长,  $w_{sq}(n_0)$  为连接权值,  $x_i^P$  为神经元状态,  $y_k^P$  为输出层神经元的输出,  $t_k^P$  为理想输出.

为了加速神经网络的收敛,在该模型中采取了多种方法<sup>[1]</sup>:根据每次迭代后误差函数  $E_E$  的变化情况,合理调整下一次迭代的步长  $\eta$ ;为了防止振荡,引入一个动量因子  $\alpha, \alpha \Delta w_{sq}(n_0)$  是记忆上一个时刻权的修改方向,在  $n_0$  时刻的修改方向为  $(n_0 - 1)$  时刻方向与  $n_0$  时刻方向的组合;加入  $\gamma^P$  因子,在碰到局部最小或平坦区时误差函数有一定改变,使  $y_k^P$  迅速退出不灵敏区,这可避免大部分的局部最小值,使收敛速度变快.

在进行训练和识别时,神经网络的输入对应于相关面上相关点的亮度,每个输入的灰度值为  $0 \sim 255$ ,值的范围比较宽.由于激光源、CRT 和液晶光阀的瞬时波动性,相关点在一定的背景亮度下有一定的波动,在使用上述方法后,对保证神经网络收敛和提高收敛速度有比较好的效果.




图1 目标2的一个相关点对不同目标的灰度对比图和随时间变化曲线图  
Fig.1 The grayscale of the point selected for target 2 against different targets as a function of time

## 2 相关峰位置的确定

在实验中,各个目标的相关峰的灰度值作为神经网络的输入,自相关峰和相关峰的灰度值是判别目标的依据,相关峰的位置确定是非常关键的.在相关面上的某个位置是否出现了自相关峰取决于两个方面:一是当某一目标出现时,该点亮度出现峰值,而其他目标出现时,该点亮度较低,前后灰度差别越大越好;二是由于系统中某些器件的不稳定性和目标背景的变化,相关峰会受到影响,表现为相关峰形状的变化和一定程度的移动,这就要求所找的相关峰针对相应目标的各种变化情况越稳定越好.为满足这两个方面的要求,我们采取以下方法确定相关峰的位置.

首先,将  $N$  个目标的标准模板图像先后送入相关器,并用图像采集卡采下相应的  $N$ .

幅  $512 \times 512$  相关图像,经过一个固定时间间隔  $t$  后,将目标图像稍加变化,比如加入各种干扰噪声,再采集  $N_c$  幅相关面图像,如此反复,每间隔  $t$ ,采集  $N_c$  幅图像,重复  $N_t$  次共得到  $N_c \times N_t$  幅相关图像,对于同一时间段内的  $N_c$  幅图像中每一点灰度值求方差,对  $N_c$  个时间段的方差取均值,得到不同目标间的方差均值  $S_1$ ;然后,对每个目标的不同时间序列的  $N_t$  幅图像中每一点灰度值求方差,得到  $S_2$ .

$$\left. \begin{aligned} m_1^l(i, j) &= \sum_{k=1}^{N_c} f_{kl}(i, j) / N_c, \\ S_1(i, j) &= \sum_{l=1}^{N_t} \sum_{k=1}^{N_c} [f_{kl}(i, j) - m_1^l(i, j)]^2 / (N_c - 1) / N_t, \end{aligned} \right\} \quad (6)$$

$$\left. \begin{aligned} m_2^K(i, j) &= \sum_{l=1}^{N_t} f_{Kl}(i, j) / N_t, \\ S_2^K(i, j) &= \sum_{l=1}^{N_t} [f_{Kl}(i, j) - m_2^K(i, j)]^2 / (N_t - 1). \end{aligned} \right\} \quad (7)$$

其中  $f_{kl}(i, j)$  为第  $K$  个目标在采样时间  $l$  时所对应的相关面上坐标为  $(i, j)$  点的灰度值,  $0 \leq f_{kl}(i, j) \leq 255$ ,  $1 \leq l \leq N_t$ ,  $1 \leq K \leq N_c$ ,  $N_c$  为待识别目标数,  $N_t$  为采样次数,  $m_1$  和  $m_2$  为均值,  $S_1(i, j)$ 、 $S_2^K(i, j)$  为方差.

$S_1(i, j)$  对应于前文提到的第一个方面,这个值越大则该点对目标的分离度越高,这里  $S_1(i, j)$  的作用不仅仅在于提取目标的自相关峰,与  $S_2^K(i, j)$  一起保证该点针对目标  $K$  出现尽量高的峰值,还能使该点当其他各目标出现时,也就是对其他目标出现互相关峰时,也有尽量大的差别,这就使互相关峰也能较好地介入识别,神经网络不但能对自相关峰抽取特征,也能在互相关时抽取有用信息.  $S_2^K(i, j)$  对应于第二个方面,这个值越小越好,表明该峰相对于时间变化和背景干扰有更好的稳定性.于是,  $S^K(i, j) = S_1(i, j) + \alpha S_2^K(i, j)$ , 将  $S^K(i, j)$  值由大到小排列,从最前面选取  $N_r$  个点作为识别该目标  $K$  的相关点,  $\alpha$  的选取很关键,如果系统的稳定性较好,则  $\alpha$  可取小值,以使神经网络更容易区分目标,否则,应加大  $\alpha$ , 以提高对系统稳定性要求所占的比重.我们一般取  $\alpha = 1.2 \sim 1.5$ . 对每个目标均重复这项工作,这可以得到针对每个目标的相关点.所有目标的相关点的坐标值存入一坐标文件中,以供采样程序使用.图 1 是针对某一目标采用以上方法得到的一个相关点的情况.

### 3 实验系统及其结果分析

#### 3.1 实验系统

在我们的实验系统中,目标图像经 CRT 送入小型多路光学相关器<sup>[3,4]</sup>,经相关运算后,相关结果由 CCD 采集,因为是原理性样机,我们将 CCD 采集的相关面图像送入 CA53 图像采集卡,采下的数据以二维图像形式由计算机进行处理和识别.在找峰期间,由 586 计算机对数据进行处理,找出的位置坐标存入一坐标文件.从实际计算结果可以看到,每个目标的相关峰的分布都比较集中在各自匹配滤波器的位置,这和光学相关器的理论设计原理是一致的.图 2 为经计算获得的某个目标的自相关分布情况.图 2(a)的目标图像输入相关器后,和图 2(b)左下角匹配滤波器相关,在图 2(c)的方框区域中产生了自相关峰.




图 2 经计算获得某飞机目标的自相关峰在相关面上的分布示意图  
 (a) 目标图像, (b) 制作匹配滤波器的二值图, (c) 目标送入相关器后得到的相关面图像  
 Fig 2. The position of the self-correlation peaks located by our algorithm  
 (a) the target, (b) the matching filter, (c) the output of the optical correlator

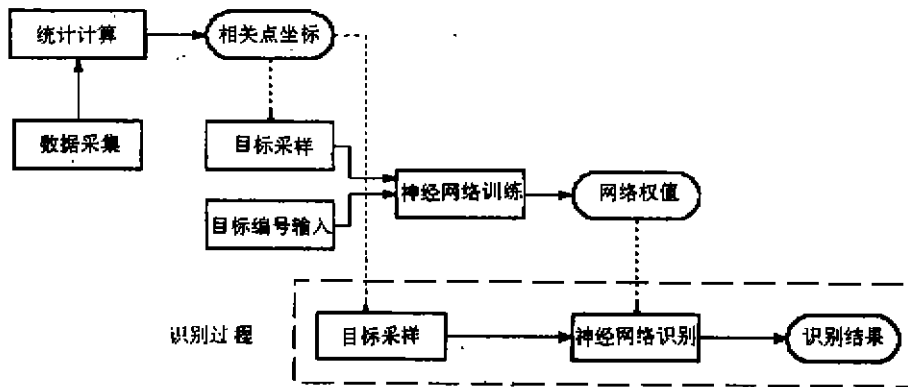


图 3 系统工作原理流程图  
 Fig 3. Diagram of operation of the system

以相关面左上角为坐标原点,把各相关点的坐标依次保存在坐标文件中,文件格式为一系列坐标对,如(132 65),(255 378),(401 23)…,采样程序就是根据坐标文件中的坐标值把相关面上相应点的灰度值取下来.相关点的总数量等于目标数量和对应每个目标的相关点数  $N_r$  的乘积,相关点数太少,不足以区分目标,太多会增加神经网络的计算量,影响识别的实时性能.我们取每个目标 4 个相关点,即  $N_r=4$ .

实际采样时,每当一个目标图像摄入相关器,就采一次相关面上各相关点的灰度值,随后由键盘输入该目标的编码,编码为 0 和 1 的二进制值,将灰度值和编码写入采样文件,然后换一个目标,重复上面的采集和编码输入工作,直到所有的目标都采样完毕.以下是采样文件中的两行:

```
123 223 50 112 90 123 180 210 51 78 102 221 79 181 137 212 121 89 78 142 91...1010,
78 102 221 79 181 137 201 90 94 130 123 223 50 112 90 123 180 210 51 78 102...1011.
```

其中每一行的最后 4 个数字为目标编码,编码的位数取决于所需识别目标的个数,取 4 位二

进值可以标识 16 个目标,每行中前面的数字为相关点的灰度值,个数取决于目标的数量和每个目标对应相关点的数量,如果有 9 个目标,每个目标 4 个相关点,则每行应有  $9 \times 4 = 36$  个灰度值,其中 4 个为自相关峰值,32 个为互相关峰值.采样文件的行数是目标数量和每个目标采样次数的乘积,每个目标至少采样一次.

神经网络训练程序读取采样文件进行训练,在我们的系统中,输入神经元为 36 个,输出神经元为 4 个,隐神经元为 20 个.训练程序把采样文件中每行的前 36 个数据作为神经网络的输入,后 4 个数据作为理想输出,进行有教师的训练,直到神经网络的输出总误差收敛于  $10^{-6}$ .训练好的神经网络权值存入权值文件,供识别程序使用.

识别程序可对目标进行实时识别,在识别前由坐标文件调入坐标值,用权值文件重建神经网络,识别时实时采集相关峰灰度值,送入神经网络进行计算,在神经网络的输出端即可得到相应的目标编码,完成对目标的识别.

整个系统工作流程如图 3 所示.

### 3.2 实验结果分析

该系统虽然在找峰和训练时有较大的计算量,但特征提取工作都在训练神经网络时已完成,而且特征和相关点的位置一般不会变化.在识别时,只须一个采样时间 30ms 和 3 层神经网络的计算时间 3ms.对 9 个加有干扰的静止目标已有百分之百的识别率.在对运动目标的识别中,目标的尺寸和旋转角度变化的影响由相关器的光学相关部分解决,该系统的识别要能跟上目标运动的变化,而提高识别速度的主要瓶颈在图像采集卡,所使用的 CA53 图像采集卡将响应时间限制在 30ms 以上.在实际系统中采用光电子集成器件和神经网络芯片后,该系统能达到大于每秒 100 帧图像相关的运算速度.

另外,对神经网络输出的分析也比较重要,该神经网络的输出是连续模拟量,须变成 0 和 1 值,精度控制太高,会降低容错性能,太低会引起误判.另外,输出神经元数不能太少,为不可识别的情况留出一定空间.

## 4 结论

在该识别系统中,我们使用统计方法和神经网络相结合,对多路光学相关器相关面输出的数据进行自动分析,最终实现了光相关系统相关峰的实时识别.在我们的系统中,神经网络的使用和互相关峰引入识别是关键,这使由多路相关引起的各种不稳定因素的影响得到最大程度的减小,并且大大简化了特征提取工作.该系统可以比较容易地转换为硬件,从速度上完全可以满足实时识别的要求.

### 参考文献

- 1 张立明.人工神经网络的模型及其应用,上海:复旦大学出版社,1992
- 2 徐建华.图像处理与分析,北京:科学出版社,1992
- 3 Wang R L, Hua T J, Qin W F, et al. *SPIE*. 1996, 2752:173
- 4 王汝笠,华铁均,王君,等.红外与毫米波学报,12(1):21
- 5 Chao Tien-Hsin, Stoner W W. *Applied Optics*, 1993, 3(22):160
- 6 Booth J J. *SPIE* 1995, 2490:108

## REAL-TIME RECOGNITION OF THE CORRELATION PEAKS OF MULTI-CHANNEL OPTICAL CORRELATOR USING NEURAL NETWORK \*

Yu Bo Wang Ruli Chen Gaofeng Hua Tiejun

*(Optoelectronic Engineering Research Center, Shanghai Institute of Technical  
Physics, Chinese Academy of Sciences, Shanghai 200083, China)*

**Abstract** A method using neural network to recognize targets according to the output of the multichannel optical correlator was proposed. The position of the correlation peaks was found through statistical rules. Not only the self-correlation peaks but also the cross-correlation peaks were used to be the features of the targets and the complex feature extraction was realized through neural network. The proposed method can effectively exclude the effects of the target background interference and the fluctuation of the device performance so as to realize a real-time target recognition.

**Key words** neural network, multichannel optical correlator, correlation peak.

---

\* The project supported by the preliminary research foundation of State Commission of Science, Technology and Industry for National Defence.