

369-374

基于时间序列最大后验概率雷达目标识别*

周德全 刘国岁[✓] 孙光明 王蕴红
(南京理工大学电光学院, 南京, 210014)

TN951

摘要 首次讨论了高分辨率雷达一维距离像的特点, 提出了获取较稳定低维特征矢量的方法, 指出不同时刻获得的矢量集为多维时间序列. 将 Vassilios Petridis 等提出的用于时间序列分类分割算法推广到多维时间序列空间, 并对实测的一维距离像进行了识别. 初步的模拟结果表明, 该方法在雷达目标识别领域具有良好的应用前景.

关键词 一维距离像, 目标识别, 时间序列, 最大后验概率, 神经网络.

雷达

引言

现代雷达一般都工作在目标的高频区或光学区, 如合成孔径雷达(SAR)、逆合成孔径雷达(ISAR). 它们利用宽带信号获得目标散射中心在径向距离的一维分布, 即目标的一维距离像; 利用运动目标的多普勒信息获得目标散射中心在横向距离的一维分布, 即一维横向像; 利用距离多普勒联合成像技术可获得目标的二维像. ISAR 技术既可用于空间飞行目标的成像, 也可用于海上舰船目标的成像, 是目标分类识别的主要技术方向之一. 但这一技术的缺点也是明显的: (1) 处理一幅二维图像需要较长的相干积累时间; (2) 需要对目标作精确的、过程十分复杂的运动补偿; (3) 光学散射区的雷达图像不同于光学图像, 后者可以显示出目标的比较完整的轮廓形状, 而前者则表现为稀疏散射中心的分布, 这就给利用图像识别方法增加了困难. 因此, 除目标的二维成像外, 基于高分辨一维距离像和神经网络的雷达目标识别(RTI)也是当前国内外关注的热点课题^[1~3]. 如果直接将距离像各距离单元上的幅值(RCS)作为特征矢量提供给神经网络去学习、分类, 这种高维的样本必然会导致网络规模过大、学习速度太慢、易收敛至局部极小点, 且过多不必要的特征细节反而会影响网络的正确识别. 本文首先对一维距离像进行非相关平均、多分辨率分解及等距离间隔最大幅值下采样的预处理, 以获得较稳定的低维样本. 在不同时刻获得的多维特征矢量(样本)集可认为是一多维时间序列^[6]. 我们将文献[5]中的分割算法(partition algorithm)推广到多维时间序列空间, 并用我国第一部实验 ISAR 提供的外场实测数据对以上方法进行了验证.

1 一维距离像

发射机发射脉冲线性调频信号为

$$S_T(t) = a(t)e^{j2\pi(f_0 t + \frac{1}{2}kt^2)}. \quad (1)$$

* 国家教委博士点基金资助项目(编号 101208)
稿件收到日期 1996-06-24, 修改稿收到日期 1996-10-16

其中 $a(t) = \begin{cases} 1 & |T| \leq T/2 \\ 0 & \text{其它} \end{cases}$, f_0 为中心频率, T 为时宽, k 为调频斜率. 点目标的宽带回波信号经去斜率混频后, 为

$$S_0(t) = a(t - \tau_R) a(t - \tau_0) \exp[j2\pi(f_m t + \Phi)]. \quad (2)$$

其中

$$f_m = k(\tau_R - \tau_0) = 2R(R - R_0)/c, \quad (3)$$

$$\Phi = f_0 \tau_R + k(\tau_0^2 - \tau_R^2). \quad (4)$$

其中 $\tau_0 = 2R_0/c$, R_0 为目标的参考距离. τ_R 为点目标回波延迟, 当点目标距离为 R 时 $\tau_R = 2R/c$, 这里 c 为光速. 从式(3)可以看出混频器输出信号频率和点目标距离与参考距离之差成正比, 据此, 我们对混频器输出作采样, FFT 就可获得目标沿径向距离方向的散射强度(或称为雷达目标截面积)分布, 即一维距离像. 图 1 给出了由 ISAR 雷达实测数据所形成的雅克飞机的 100 个相邻回波的一维距离像. 图中 RCS 表示归一化的雷达目标反射强度, T 为距离像序号, R_i 为距离单元, 每一距离单元表示的实际长度为 37.5 cm.




图 1 雅克-42 飞机 100 个相邻回波距离像
Fig. 1 100 successive profiles of Yank-42




图 2 图 1 中距离像非相干平均后距离像
Fig. 2 Incoherent average profiles of Fig. 1

2 模式预处理及特征提取

2.1 距离像的非相干平均

由式(4)可知, 散射点相位对距离的变化很敏感, 会导致一维距离像很不稳定, 采用距离像非相干平均方法可部分解决这一问题^[2]. 这里, 我们将每相邻的 10 个距离像在距离对准的基础上进行非相干平均, 图 2 给出图 1 中距离像非相干平均的结果.

2.2 多分辨率分解

非相干平均在一定程度上解决了同一距离单元内不同散射点相位变化对距离像的影响, 但这些距离像包含了过多的目标局部细节, 实验表明, 如果直接将它送入网络学习, 识别效果并不理想. 如果能获得目标距离像的大致形状, 而又不丢失有关目标过多的特征信息, 那么就可以用较低维的特征矢量来表征目标. 信号的多分辨率分解^[4]可以较好的解决这一问题. 图 3 给出了实现这一分解的算法框图, 图中 H 为由尺度函数 $\varphi(x)$ 所确定的低通滤波器^[4], $\downarrow 2$ 为隔点下采样, G 是一传输函数为 $e^{-j\omega} H(\omega + \pi)$ 的高通滤波器. 图 4(b)、(c) 给出

了图 4(a) 雅克飞机平均一维距离像作为 $A_1 f$ 经图 3 两级分解后分别获得的 $1/2, 1/4$ 分辨率下的距离像, $A_{2^{-1}} f, A_{2^{-2}} f, A_{2^{-3}} f$ 保持了原距离像的大致轮廓但维数已大大降低. 图 4(a)、(b)、(c) 中 R 所表示的实际物理长度分别为 37.5、75、105 cm.

2.3 选征选取

为了进一步降低特征空间的维数, 我们对 $A_{-2} f$ 再作数据压缩. 具体步骤为: (1) 将 $A_{-2} f$ 归一化; (2) 将所有小于阈值(本文取 0.1)的点置为零(认为是噪声), 而所有大于阈值的点都作为目标的一部分; (3) 将目标对应的距离单元数作 n (由模拟结果知, $n > 6$, 增加 n 不但不能增加识别率而且会使网络规模扩大, 因此, 取 $n = 6$) 等分, 依次取出每一部分的最大值再加上归一化的目标长度(距离单元数)作为特征矢量. 取阈值为 0.1 主要是基于以下考虑: (1) 通过对实际目标一维像的观察未发现目标的部分(噪声)均在 0.1 以下; (2) 这一阈值即使切去部分目标也不会影响本文目标特征(强散射点及目标的相对长度)的选取. 由同一目标得到的不同时刻的 $n+1$ 维特征矢量可以看成 $n+1$ 维的时间序列 $\{X_t, t=1, 2, \dots\}$, 即

$$X_t = (x_t^1, x_t^2, \dots, x_t^{n+1})^T. \quad (5)$$

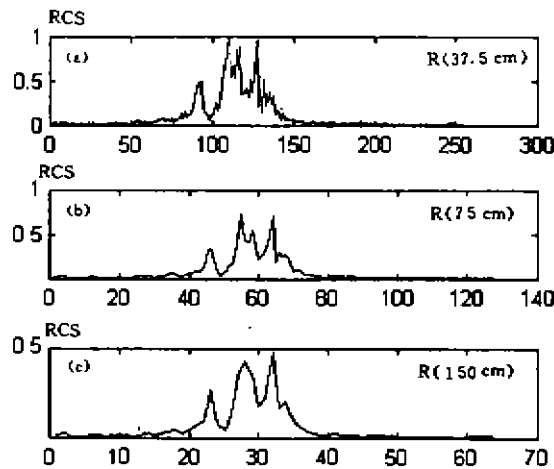


图 4 一维距离像两级多分辨率分解结果(低通滤波器 H 的输出)

Fig. 4 Decomposition results at the resolutions $1/2, 1/4$

(each gives the output of the lowpass filter H) of a profile

3 分割算法

3.1 时间序列的最大后验概率分类




图 3 多分辨率分解框图

Fig. 3 Block diagram of multiresolution signal decomposition

设有目标 $Z = \theta_k \in \{\theta_1, \dots, \theta_K\}$ 的先验概率 P_0^k 为

$$P_0^k = P(Z = \theta_k / t = 0), \quad k = 1, 2, \dots, K \quad (6)$$

如无先验知识,可取 $P_0^k = 1/K$ ($k = 1, 2, \dots, K$),再引进条件后验概率

$$P_t^k(x_1, \dots, x_t) = P(Z = \theta_k / x_1, \dots, x_t), \quad k = 1, 2, \dots, K, t = 1, 2, \dots \quad (7)$$

P_t^k 值反映了 t 时刻对时间序列 $\{x_1, \dots, x_t\}$ 由 θ_k 产生的置信度.有理由选取最大的 P_t^k 所对应的 θ_k 作为对目标的估计 \hat{Z}_t ,

$$\hat{Z}_t = \arg \max_{\text{all } \theta_k} P_t^k. \quad (8)$$

3.2 分割算法

分割算法(PA)可用来不断更新对 P_t^k 的估算.算法如下^[5]:对 $k = 1, 2, \dots, K$,有

$$P_0^k = P(Z = \theta_k / t = 0); \quad (9)$$

对 $t = 0, 1, 2, \dots$ 及 $k = 1, 2, \dots, K$,有

$$P_{t+1}^k = \frac{P(x_{t+1}/x_1, \dots, x_t, Z = \theta_k) \cdot P_t^k}{\sum_{j=1}^K P(x_{t+1}/x_1, \dots, x_t, Z = \theta_j) \cdot P_t^j}, \quad (10)$$

$$\hat{X}_{t+1}^k = f(x_1, \dots, x_t; \theta_k), \quad (11)$$

$$P(x_{t+1}/x_1, \dots, x_t; \theta_k) = \frac{1}{\sqrt{2\pi\sigma_k}} \exp\left(-\frac{|x_{t+1} - \hat{X}_{t+1}^k|^2}{2\sigma_k^2}\right), \quad (12)$$

$$\hat{Z} = \arg \max_{\text{all } \theta_k} P_t^k. \quad (13)$$

\hat{x}_{t+1}^k 为与每个 θ_k 相对应预报器 k 在 t 时刻的预报值, σ_k 为 k 预报器预报误差的标准值.

以上算法是针对一维时间序列,对于本文的多维时间序列,利用这一算法的主要障碍是如何确定预报误差,我们定义这一误差为 $X_{t+1} - \hat{X}_{t+1}^k$ 的 2 范数:

$$\|X_{t+1} - \hat{X}_{t+1}^k\| = (X_{t+1} - \hat{X}_{t+1}^k)^T (X_{t+1} - \hat{X}_{t+1}^k). \quad (14)$$

只要将式(12)改写为

$$P(X_{t+1}/X_1, \dots, X_t; \theta_k) = \frac{1}{\sqrt{2\pi\sigma_k}} \exp\left(-\frac{\|X_{t+1} - \hat{X}_{t+1}^k\|^2}{2\sigma_k^2}\right), \quad (15)$$

就可将这一算法推广到多维时间序列.

3.3 算法的神经网络实现

PA 算法可以用如图 5 所示的分级(hierarchical)、组件(modular)、递归(recurrent)神经网络实现.网络的底层是 K 个与雷达目标相对应的预报器.本文选用递推神经网络^[7]实现预报,预报器的阶数选为 2,预报器的训练离线(off-line)完成.顶层网络基于各种预报器的预报值完成后验概率的估计,并利用最大后验概率准则完成对目标的识别.

整个算法的实施步骤归纳如下:(1)为每一可能出现的目标建立一预报器,并用相应目标的时间序列来训练预报器.(2)对 $t = 1, 2, \dots$ 所有预报器并行实施预报,并计算每一模型的预报误差.(3)用这一预报误差来更新相应目标的后验概率.(4)利用最大后验概率准

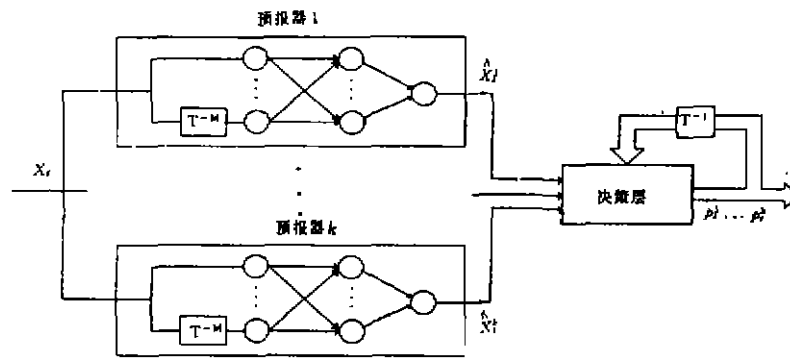


图 5 分割神经网络结构图
Fig. 5 Sketch of partition network architecture

则实现对目标的识别。

4 计算机模拟结果

用我国第一部 ISAR 外场实测数据对以上方法进行了验证,分别从过航雅克-42(d922.dat2)、安-26(d507.dat4)、奖状(d715.dat4)飞机宽带数据中抽取 4000 个相邻的回波,经模拟预处理后分别获得了 3 个长度为 400 的时间序列,用每个序列的前 100 个来训练相应的预报器,然后按照雅克、安-26、奖状飞机的次序将 3 个时间序列放在一起,形成一长度为 1200 的时间序列,将此序列送入图 5 所示的网络中识别,表 1 给出了各机种的识别率,图 6 给出了各机种的后验概率,从表 1 及图 6 可以看出以上方法不仅具有较高的识别率,且识别置信度也很高。

表 1 3 类目标的识别率
Table 1 Recognition rate of three kinds of radar targets

| 机型 | 雅克-42 | 安-26 | 奖状 |
|-----|--------|--------|--------|
| 识别率 | 96.23% | 99.75% | 98.24% |




图 6 三类目标的后验概率
Fig. 6 Posterior probability of three kinds of targets

5 结论

为了获取目标较稳定的低维特征矢量,对原始一维距离像作非相干平均、多分辨率分解及等距离间隔内最大值下采样的模式预处理,同一目标依次获取的低维特征矢量为—多维时间序列,将文献[5]提出的用于时间序列分类的分割算法推广到多维时间序列空间,并用

这一方法成功的实现了对高分辨率雷达目标的识别. 将目标回波看成时间序列, 并利用时间序列后验概率实现对目标分类的方法尚不多见. 初步的模拟结果表明这一方法在雷达目标识别领域有良好的应用前景.

REFERENCES

- 1 黄德双, 保铮. 电子科学学刊(HUANG D S, BAO Z. *Journal of Electronics*), 1995, 17(1): 26~33
- 2 赵群, 保铮, 叶伟. 电子科学学刊(ZHAO Q, BAO Z, YE W. *Journal of Electronics*), 1995, 17(6): 591~598
- 3 Eric T K, Steven K R, et al. *SPIE*, 1993, 1985: 256~265
- 4 Stephane G M. *IEEE Tran. on PAMI*, 1989, 11(7): 674~693
- 5 Vassilios Petridis, Athanasios Kehagias. *IEEE Tran. on NN*, 1996, 7(1): 73~86
- 6 Haykin S, Cong D. *IEEE Trans. on NN*, 1991, 2(6): 589~600
- 7 Williams R J, David Z. *Neural Computation*, 1989, 1: 270~280

RADAR TARGET RECOGNITION OF MAXIMUM POSTERIOR PROBABILITY BASED ON TIME-SERIES*

ZHOU De-Quan LIU Guo-Sui SUB Guan-Min WANG Yun-Hong

(Department of Electrical Engineering, Nanjing University of
Science and Technology, Nanjing, Jiansu 210014, China)

Abstract The characteristics of HRR profiles were analyzed firstly. An approach of obtaining stationary feature vectors was proposed. Partition algorithm presented by Vassilios Petridis, which was used to classify time-series, was modified to satisfy multidimensional time-series. Modified partition algorithm was applied to recognize HRR targets. Primary simulation results show that approaches discussed above have good prospects in the field of radar targets recognition.

Key words range profiles, target recognition, time-series, maximum posterior probability, neural network.

* The project supported by the Doctoral Fund of Higher Education of State Education Committee of China
Received 1996-06-24, revised 1996-10-16