

(12) 302-306

基于多阶段分类的雷达目标识别*

涂志江 刘国岁

(南京理工大学电子工程与光电技术学院, 江苏, 南京, 210091)

TN957-1
TN957-523

摘要 讨论了用一种新的识别系统识别高分辨雷达距离像(HRRP), 它先在 K-L 变换对距离像进行特征压缩后, 用聚类分析进行识别或基于某个规则排除某些种类, 再对不能识别的模式, 用种类少时效果好的最佳鉴别准则对模式进行特征提取, 然后用模糊 ARTMAP 网络组进行分类, 实验表明该方法比常规的单分类器方法有更高的识别率。

关键词 雷达距离像, 模糊 ARTMAP, 聚类分析, 目标识别。

RANGE PROFILE IDENTIFICATION BASED ON MULTISTAGE CLASSIFICATION*

TU Zhi-Jiang LIU Guo-Sui

(Department of Electronic Engineering and Photoelectricity Technology, Nanjing University of Science and Technology, Nanjing, Jiangsu 210091, China)

Abstract A novel range profile identification system based on multiple classification was discussed. After feature compression with K-L transform, one can get a rough identification result by clustering or eliminate impossible candidates according to some rules. The remainder is identified by fuzzy ARTMAP neural network with the feature extraction of the optimal set based on the Fisher criterion. The experiment shows that this classifying method could be more effective than the single classifier method.

Key words radar range profile, fuzzy ARTMAP, clustering, target identification.

引言

高分辨雷达及其成像技术的出现,使得对雷达目标特性的刻画更为精细,对高分辨雷达的回波进行频谱分析,就获得一维距离像。雷达一维距离像以散射点模型为依据的,它与目标表面的物理结构特性密切相关,反映目标精密结构特性,从几何的角度看,它描述了目标的散射中心在径向的投影,从而含有目标的类别可分性信息;因此,以距离像作为目标特征进行雷达目标识别系统的设计引起广泛的重视。已有不少运用一维距离像识别飞机的工作^[1~2],但是这些工作都是采用单分类器,一次识别完成的,由于距离像预处理的特点,传统的单分类器的方法较难得到高的识别率,因此有必要考虑更复杂的识别系统来完成一维距离像的识别。

本文所提出的识别系统主要由两个识别阶段构

成,第一阶段只是对模式者大致的识别,第二阶段是对第一阶段不能识别的模式再进行识别。对某高分辨率雷达所得三类飞机数据的实验结果表明,本文讨论的系统识别能力远远优于单分类器一次识别的方法。本文主要工作有三个方面:(1)提出一种新的识别系统,可应用于传统的单分类器的方法效果差的领域;(2)提出了一种更好的利用最佳鉴别准则的方法;(3)给出了一种较为新颖的聚类分析方法。

1 系统的总体框架

系统的结构框图如图 1 所示;在预处理后,阶段 1 用常规的 K-L 变换对距离像进行特征压缩,并根据聚类结果对置信度高的类别得到直接的判决,对于可靠性低的类别,可将明显不相似的对象去除,为第二阶段的识别提供了一个较少的候选子集,这样更有利于提高识别的正确率;阶段 2 的最佳鉴别准则源于 Fisher

* 国家教委博士点基金(编号:101208)资助项目
稿件收到日期 1999-06-04,修改稿收到日期 2000-03-20

* The project supported by the Doctoral Fund of Higher Education of State Education Committee of China.
Received 1999-06-04, revised 2000-03-20




图1 系统框架

Fig.1 Architecture of the system

准则^[3],从识别能力来说是最好特征提取的方法之一,它在类别较少时、分类效果较类别较多时有较大提高^[4],因此在聚类分析的基础上,用最佳鉴别准则对较少种类进行特征提取和压缩,并用速度很快学习总是稳定的模糊自适应共振映射(ARTMAP)网络^[5],作为分类器对处理后的数据进行识别,可以得到更好的效果。

2 特征提取

2.1 识别模式的预处理

预处理在雷达距离像识别中是非常重要的环节,它的目的是在特征压缩前获得稳定的模式,从回波的特点考虑它涉及以下几个问题^[6]:(1)提高回波的信噪比,(2)归一化回波幅度,(3)距离对准。对上述问题,较为实用的方法是非相干平均,幅度归一化、富里叶变换取幅值^[7],并且因为实函数富里叶变换的对称性,可以取一半的幅值作为特征矢量。一维距离像在经过预处理后,特征矢量的主分量集中在零频附近,幅度的归一化使特征矢量的第一个分量最大且都为1,这样模式间的类似性很大,在经过聚类分析中,不可避免地存在重叠现象。图2是本文实验中所识别飞机的距离像经过预处理的图,其中Z轴为归一化幅度,X轴

为频率,Y轴为距离像序号。

2.2 K-L展开法

K-L展开法主要是由模式样本矢量的相关矩阵进行特征值分解,选择其中的主特征矢量构成主特征空间,然后将待识别的模式投影到此特征空间,形成维数压缩的压缩模式矢量,由于第一阶段只是进行大体识别,因此K-L展开法较最佳鉴别变换可进行更大程度的维数压缩。

样本集合 $\{x_i\}, i=1, 2, \dots, N$,其中 x_i 是 n 维矢量;设 m 为总体均值,我们可以定义K-L坐标系产生矩阵。

$$R = E\{(x - m)(x - m)^T\}, \quad (1)$$

对 R 进行特征值分解得:

$$R = \sum_{j=1}^r \lambda_j O_j O_j^T, \quad (2)$$

取其中 r 个大的特征值对应的特征矢量形成压缩变换矩阵 $O = (o_1, o_2, \dots, o_r)$,则

$$y = O^T x, \quad (3)$$

变换的结果是将一个 n 维向量 x 变为一个 r 维向量 y 。

2.1 最佳鉴别准则

最佳鉴别变换实际上就是找一个投影矩阵,使得经该投影矩阵变换后的模式样本,同类间的散度减小,不同类间的距离增大,投影矩阵的每一列向量由下列解得到:

(1) o_1 为使 $J(o)$ 达到最大值的单位向量。

(2) $o_i (2 \leq i \leq r)$ 解 $\max(J(o))$ 得到。

$$o_j^T o_i = 0, \quad \|o_j\| = 1, \quad j = 1, 2, \dots, j-1 \quad (4)$$

其中 $J(o) = \frac{o^T S_b o}{o^T S_t o}$, S_b 是样本的类间散布矩阵, $S_t =$




图2 距离像的预处理

Fig.2 Preprocessing of profiles

$\sum_{j=1}^n p(c_j)(m_j - m_0)(m_j - m_0)'$, S_0 是样本的总体散布矩阵, $S_i = E\{(x - m_{0i})(x - m_{0i})'\}$, 令投影矩阵 $O = (o_1, o_2, \dots, o_r)$, 则

$$y = O'x, \tag{5}$$

变换的结果就是将一个 n 维向量 x 变为一个 r 维向量 y , 这样就达到了特征压缩的目的. 矩阵 O 的具体解法见文献[7].

3 分类器

3.1 聚类分析

(1) 聚类

本文的聚类算法主要基于 K-均值聚类法, 所改进的是本算法能够自动的进行类的合并与分裂, 从而得到较为合理的聚类数, 具体步骤如下:

步骤 1: 随机选择 c 个样本初始的聚类中心 w_1, w_2, \dots, w_c .

步骤 2: 设总样本数为 N , 并设下列控制参数: K 为期望得到的聚类数; n 为一个聚类中的最少样本; J 为允许的迭代次数.

步骤 3:

(a) 将样本 x 按最小距离原则分配给某个聚类中心, $\eta = \arg \min_t \|x(t) - w_t(t)\|$.

(b) 重新计算各聚类中心, $W_\eta(t+1) = \frac{1}{N_\eta} \sum_{x \in \eta} x$, N_η 是第 η 个聚类中的样本数.

(c) 检查样本的隶属关系是否改变, 如改变则转回到步骤(a).

步骤 4: 删除只有很少样本的聚类中心.

步骤 5: 检查各聚类中心的彼此距离, 如果 $\|w_i - w_j\|^2 \leq \frac{\omega}{M_j} \sum_{l=1, l \neq j}^M \|w_l - w_j\|^2, i=1, 2, \dots, M, M$ 是目前的聚类数, 且 $0 < \omega \leq 1$, 则合并聚类 i 与 j , 并计算新的聚类中心 $w_{\omega\omega} = \frac{1}{N_i + N_j}(N_i w_i + N_j w_j)$, N_i 与 N_j 是第 i 和第 j 个聚类中的样本数.

步骤 6: 若这是最后一次迭代, 则程序中止.

步骤 7: 计算各聚类的标准偏差 $\delta_i = \frac{1}{N_i} \sum_{x \in i} \|x - w_i\|$ 及总的平均偏差 $\delta = \frac{1}{N} \sum_{i=1}^M N_i \delta_i$, 若满足 (a) $\delta_i > \delta$, 且 $N_i > 2(n+1)$; (b) $M \leq K$, 则将第 i 个聚类分裂为 $w_i^+ = w_i + k\delta_i$ 和 $w_i^- = w_i - k\delta_i$ 两个聚类, 其中 $0 < k < 1$.

步骤 8: 根据具体情况改变参数, 转向步骤 2 或不改变参数, 转向步骤 3.

(2) 分析

本文中聚类分析的目的主要有两个, 第一: 对可靠性高的类别得到直接的判决; 第二: 对于其它情况, 可将明显不相似的对象去除, 为第二阶段的识别提供一个较少的候选子集, 这不但大大提高了最佳鉴别准则的性能, 而且分类器的复杂性也大为减少. 例如, 就一个三类问题来说, 聚类后子类包含的类别结果如图 3 所示; 如 a, b, c 情况的子类, 可直接得到判决; 如 e, f, g 情况的子类, 将它们包含的候选类别送到第二阶段去识别, 具体步骤如下:

步骤 1: 利用事件发生的频率近似估计先验概率及类条件概率, 设训练样本集为 $\omega_1, \omega_2, \dots, \omega_c$, 总的训练样本集为 $\omega = \omega_1 \cup \omega_2 \cup \dots \cup \omega_c, N_i$ 是 ω_i 类的训练样本数, N 是总训练样本数, 则各类先验概率的估计值为

$$p(\omega_i) = \frac{N_i}{N}, \tag{6}$$

样本被聚成 K 个子类后, 样本空间被离散为 K 个区域 $R_j, j=1, 2, \dots, K$, 设 w_1, w_2, \dots, w_c 为其聚类中心, 样本被离散为几个有限值 w_j , 每个样本都可用离散值表示; 这样类条件概率 $p(x|\omega_i)$ 的估计就变成对 $p(w_j|\omega_i)$ 的估计, 而

$$p(w_j|\omega_i) = \frac{R_j \text{ 中属于 } \omega_i \text{ 的样本数}}{\omega_i \text{ 中的样本数}}, \tag{7}$$

显然 $\sum_{i=1}^c p(\omega_i) = 1, \sum_{j=1}^k p(w_j|\omega_i) = 1$.

步骤 2: 对于输入未知类别样本, 可利用贝叶斯公式计算后验概率进行判决, 当满足

$$p(\omega_i|x) = \max_{1 \leq i \leq c} p(\omega_i|x) \\ p(\omega_i|x) \geq \rho; \tag{8}$$

其中 ρ 是预先设定的置信概率, $0 < \rho \leq 1$; 则判决 $x \in \omega_i$.

步骤 3: 当未知类别样本落入不满足(8)的子类时, 将计算后验概率降序排列, 即




图 3 聚类结果
Fig. 3 Clustering results

$$\{p(\omega_i|x), i=1, \dots, c\} \rightarrow \left\{ \begin{array}{l} Pr_i(x), i=1, \dots, c | Pr_i(x) \geq Pr_{i+1}(x), \\ i=1, \dots, c-1 \end{array} \right\} \quad (9)$$

将满足下式与前 m 个 $Pr_i(x)$ 相对应的候选子集送入第二阶段进行识别, $1 < m < c$;

$$m = \min_{i \in [1, c]} \{i | Pr_{i+1}(x) - Pr_i(x) \geq P_i, i=1, \dots, c-1\}, \quad (10)$$

P_i 是阈值, $0 < P_i \leq 1$, 注意 m 是 x 及 P_i 的函数, 不同的子集情况不同.

步骤 4: 当未知类别样本落入不满足式(8)和式(10)的子类时, 即子类中的类别呈现均匀分布, 则送入第二阶段的候选子集包括所有的类别, 由于第二阶段采用的特征提取的方法和分类器均不同于第一阶段, 因此系统有可能作出正确判决.

步骤 3 之所以不用取前 m 个具有较大后验概率的类别作为第二阶段候选类别的方法, 因为在某种情况下, 淘汰掉正确类别的可能性将大为增加; 例如, 一个三类问题, 聚类后对于未知输入 x , 各后验概率为 $Pr_a(x)=0.5, Pr_b(x)=0.26, Pr_c(x)=0.24$, 很明显, 步骤 3 中只将 (a), (b) 作为第二阶段候选类别是很不可靠的. 下面, 我们分析步骤 3 淘汰正确类别的概率上限.

设 N 是总训练样本数, R 是满足步骤 3 条件的所有子集区域, n 是这些子集中的训练样本数, 则步骤 3 的淘汰正确类别概率上限的估计值为

$$e(P_i) \leq \frac{P}{N} \left(1 - \frac{1}{c}\right) (1 - P_i), \quad (11)$$

证明: 令 $r(P_i, x) = \sum_{i=m+1}^c Pr_i(x)$, 由图 4 可见

$$r(P_i, x) \leq \left(1 - \frac{m}{c}\right) (1 - m * P_i),$$

由于 $\sum_{i=1}^c Pr_i(x) = 1$, 令 $p(x)$ 为概率函数密度, 由于 $m > 1$, 所以

$$\begin{aligned} e(P_i) &= \int_R r(P_i, x) p(x) dx \leq \int_R \left(1 - \frac{m}{c}\right) (1 - m * P_i) p(x) dx \\ &< \int_R \left(1 - \frac{1}{c}\right) (1 - P_i) p(x) dx = \left(1 - \frac{1}{c}\right) (1 - P_i) \int_R p(x) dx \leq \frac{n}{N} \left(1 - \frac{1}{c}\right) (1 - P_i). \end{aligned}$$

3.2 ARTMAP 网络组

普通的神经网络, 无论是有导师还是无导师的, 都存在对过去模式样本的记忆和对新的模式样本的自适应学习问题, 如果网络的规模一定, 新输入的模式样本




图 4 计算错误概率
Fig. 4 Calculation of risk

将会对过去记忆的模式样本产生抵消和遗忘, 这样会影响网络的分类性能. 因此, 在很多时候都需要在不致使网络规模过大的同时, 最大程度地接收新的模式而较少地影响过去样本的记忆; ART 网络在此点上具有独特性, 它在适当地扩大网络规模的同时, 以较大的灵活性适应新输入的模式, 而且保持对过去的记忆.

将两个导师的模糊 ART 模型通过一个内部映射机联在一起, 就构成了有导师的 ARTMAP 模型. 模糊 ARTMAP 的结构图及输入、输出如图 5 所示. 如果 ART₁ 输出分类层激活的某个模式映射到 ART₂ 输出分类层对应的激活节点, 所实现的映射不符合要求, 则内部映射场发出匹配跟踪信号使 ART₂ 略微增加警戒参数 ρ_i , 从而降低网络的推广和信息压缩能力, 直到网络按有导师信号能正确学习所给定的输入输出映射关系为止, 模糊 ARTMAP 的算法见文献[5]. 特征矢量在经最佳鉴别变换输入网络前必须经下式使矢量分量在 0, 1 间.

$$a = k \cdot (y - v) \quad (12)$$

式(12)中 k 是常数, v 是常矢量.

聚类分析得出候选子集被送入模糊 ARTMAP 网络进行识别, 网络的个数由候选子集的种类数决定, 当类别较多时, 网络的个数有可能会很大, 因此在这种情况下, 应适当调整 P_i , 使候选子集的种类在合理的范围内.

4 实验

本文所用数据由某研究所提供, 用 ISAR 雷达测得安-26, 奖状, 雅克-42 三类飞机. 所用的回波数据是混频后经采样得到, 每个脉冲冲作 256 点采样, 因此, 对原始数据进行谱分析所获取的一维距离像也由 256 点组成; 经预处理后, 特征矢量的维数为 128. 共得到 6000 个样本矢量集(每种各 2000), 用 3000(每种各 1000)个作为训练样本, 其余的为测试样本. 为了进一步说明本系统的效果, 我们用传统的方法作一次仿真.




图 5 模糊 ARTMAP 网络结构
Fig. 5 Fuzzy ARTMAP architecture

由于最佳鉴别准则识别效果优于 K-L 变换,因此,系统将由最佳鉴别变换和 ARTMAP 网络构成.经最佳鉴别变换后,特征矢量被压缩至 30 维,然后送入 ARTMAP 网络.

表 1 实验结果
Table 1 Experiment results

系 统	识 别 率 (%)		
	安-26	奖状	雅克-42
最佳鉴别准则 +ARTMAP 网络	88.4	74.6	84.7
聚类分析 +ARTMAP 网络	96.1	89.3	97.3

特征矢量送入本文所论述的系统后,经 K-L 变换特征矢量被压缩至 20 维,聚类分析后,共 1656 个样本被输入第二阶段;聚类分析得出三种候选子集 $\{1,2\}$ $\{1,3\}$ $\{2,3\}$,即 ARTMAP 网络的个数为 3,用最佳鉴别准则产生三种不同的投影坐标,按不同的候选子集用各自的投影坐标将输入第二阶段的样本压缩至 30 维,分别送入的三个 ARTMAP 网络,每个网络的训练样本为 2000 个(每种各 1000 个);表 1 为两次实验的结果.结果显示本文所论述的系统识别能力远远优于单分类器一次识别的方法.

REFERENCES

- [1] LI Hsue J, YANG Sheng-Hui. Using range profiles as feature vectors to identify aerospace objects, *IEEE Trans. on AP*, 1993, 41(3): 261-268
- [2] ZHAO Qun, BAO Zheng. Radar target recognition based on neural network. *Journal of Electronics* (赵群, 保铮. 基于神经网络的雷达目标识别, *电子科学学刊*), 1995, 17(6): 591-598
- [3] Foley D H, Sammon J W, Jr. An optimal set of discriminant vectors. *IEEE Trans. on Comput*, 1975, 24(3): 281-289
- [4] Huang Xiu-Wu. Feature extraction and recognition of human face image based on algebraic approach, Doctoral Dissertation, Nanjing University of Science and Technology (黄修武. 基于代数方法的人脸图像特征提取与识别, 博士学位论文, 南京理工大学), 1998, 74-77
- [5] Gail A C, Stephen G, John H R, et al. Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps, *IEEE Trans. on NN*, 1992, 3(5): 698-710
- [6] Anthony Zyweck. Radar target classification of commercial aircraft, *IEEE Trans. on AES*, 1996, 32(2): 741-748
- [7] LIU Ke, CHENG Yong-Qing, YANG Jing-Yu. An efficient algorithm for Foley-Sammon optimal set of discriminant vectors by algebraic method. *International Journal of Pattern Recognition and Artificial Intelligence*, 1992, 6(5): 817-829