

基于多分类器融合的雷达高分辨距离像 目标识别与拒判新方法

张学峰¹ 王鹏辉¹ 冯博¹ 杜兰¹ 刘宏伟¹

摘要 由于雷达自动目标识别 (Radar automatic target recognition, RATR) 中库外目标的存在, 评价系统性能时应综合考虑其识别性能和拒判性能. 由此本文构造了一种将分类器的输出通过最近邻分类器 (Nearest neighbor, NN) 进行拒判和识别的“分类器-最近邻”系统, 并在拒判和识别两个阶段分别采用多分类器融合技术以提高 RATR 系统的拒判和识别综合性能. 此外, 文中定义了一种代价函数以衡量系统综合性能并为系统拒判工作点的选取提供依据. 进而, 采用局部法和全局法两种算法确定拒判器的工作点. 实测数据实验结果验证了本文方法的有效性, 两种工作点选取算法均能够显著提高识别系统的综合性能.

关键词 雷达自动目标识别, 多分类器融合, 库外样本拒判, 最优工作点选择

引用格式 张学峰, 王鹏辉, 冯博, 杜兰, 刘宏伟. 基于多分类器融合的雷达高分辨距离像目标识别与拒判新方法. 自动化学报, 2014, 40(2): 348–356

DOI 10.3724/SP.J.1004.2014.00348

A New Method to Improve Radar HRRP Recognition and Outlier Rejection Performances Based on Classifier Combination

ZHANG Xue-Feng¹ WANG Peng-Hui¹ FENG Bo¹ DU Lan¹ LIU Hong-Wei¹

Abstract Because of the presence of outlier samples, it is important to take both the recognition and rejection performances into account when evaluating a radar automatic target recognition (RATR) system. In this paper, we propose to utilize the nearest neighbor (NN) classifier with the inputs being the outputs of a classifier, referred to as “Classifier-NN” system, to identify outliers. In order to improve the performance, several “Classifier-NN” systems are combined. A cost function is defined to measure the recognition and rejection performance of the RATR system. Two algorithms are developed to select the optimal work point of each “Classifier-NN” system. Experimental results based on the measured HRRP dataset have validated the effectiveness of the proposed methods.

Key words Radar automatic target recognition (RATR), multiple classifiers combination, outlier rejection, optimal work point selection

Citation Zhang Xue-Feng, Wang Peng-Hui, Feng Bo, Du Lan, Liu Hong-Wei. A new method to improve radar HRRP recognition and outlier rejection performance based on classifier combination. *Acta Automatica Sinica*, 2014, 40(2): 348–356

雷达高分辨距离像 (High-resolution range profile, HRRP) 是目标沿雷达视线方向的投影, 它

包含了丰富的目标结构信息, 可以用来对目标进行识别. 相对于合成孔径雷达 (Synthetic aperture radar, SAR) 像和逆合成孔径雷达 (Inverse SAR, ISAR) 像而言, HRRP 具有易于获取和计算简单等优点. 因此在雷达自动目标识别领域得到了广泛的应用^[1–4].

雷达自动目标识别的对象主要是非合作目标, 因此需要建立大量的非合作目标的模板数据库. 然而, 目标的非合作性使得建立完备的数据库极其困难, 甚至不可能实现, 所以实际应用中的训练数据库往往都是不完备的. 此时如果有新类别的库外目标作为测试样本出现, 就要考虑拒判 (拒绝判别) 问题. 因此, 在雷达自动目标识别过程中, 要求分类器不但能够对库内的样本进行正确识别, 而且能够对库外目

收稿日期 2012-06-26 录用日期 2012-11-25
Manuscript received June 26, 2012; accepted November 25, 2012

国家自然科学基金 (61271024, 61201292, 61201283), 新世纪优秀人才支持计划 (NCET-09-0630), 全国优秀博士学位论文作者专项资金资助项目 (FANEDD-201156), 中央高校基本科研业务费专项资金资助 (Supported by National Natural Science Foundation of China (61271024, 61201292, 61201283), Program for New Century Excellent Talents in University (NCET-09-0630), the Foundation for the Author of National Excellent Doctoral Dissertation of China (FANEDD-201156), and the Fundamental Research Funds for the Central Universities)

本文责任编辑 韩崇昭

Recommended by Associate Editor HAN Chong-Zhao

1. 西安电子科技大学雷达信号处理国家重点实验室 西安 710071

1. National Key Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071

标实现拒判。

由于库外目标的 HRRP 样本难以获取, 无法直接利用库外样本训练分类器. 处理拒判问题通常有两种方法: 1) 将拒判看作两类目标 (即库内目标和库外目标) 的分类问题, 将所有库内目标样本看作一类目标, 然后利用支撑向量域描述 (Support vector domain description, SVDD)、一类支撑向量机 (One class support vector machine, OCSVM)、K-近邻 (K-nearest neighbors, KNN) 等单类别分类器方法进行拒判处理^[5-8]; 2) 在多类别分类器的基础上, 将分类器输出 (如后验概率、似然值、信任度等) 与预先设定的门限比较进行拒判^[4]. 第 1 种方法只考虑了每一个类别自身的信息, 对分类和拒判都有一定的局限性; 第 2 种方法虽然考虑了多个类别的信息, 但是分类界面不能形成紧致闭合的分类界面将样本包裹, 在拒判上有一定的局限性.

本文综合了以上两种方法, 将库内目标样本通过多类别分类器的输出向量作为库内样本的特征, 然后利用最近邻 (Nearest neighbors, NN) 分类器进行拒判, 称之为“分类器-最近邻”系统. 多分类器的输出表征了样本与库内各个类别的内在关系, 包含了更多的库内样本信息, 因而与传统方法相比, 分类器-最近邻系统在不损失分类性能的基础上更利于对库外样本进行拒判.

集成学习是机器学习的主要方向之一^[9], 并在实际问题中得到广泛的应用. 由于集成学习能够将多个学习机进行融合来提高整体的性能, 因此本文将应用于分类器-最近邻系统的识别和拒判阶段, 以充分发挥不同特征、不同分类器的优势, 从而提高整个 RATR 系统的识别和拒判性能. 集成学习包括两大类^[10]: 一类是非生成集成方法 (Non-generative ensemble method), 如投票法、加权投票法、加法准则、乘法准则、D-S 证据理论融合准则 (Dempster-Schafer combination rule) 和行为知识空间法 (Behavior-knowledge space method) 等多分类器融合方法^[9-13]; 另一类是生成集成方法 (Generative ensemble method), 如 Bagging、Boosting^[14] 等. 非生成集成方法是将一些设计好的学习机进行融合, 并不主动地去生成新的基学习器 (Base learner); 生成集成方法则将一组基学习器作用于基本的学习算法或者数据结构以主动提高学习器的多样性和准确性^[10]. 鉴于本文采用的特征及分类器均比较成熟, 因此只考虑采用多分类器融合技术, 对分类器和拒判器的输出直接进行融合. 由于所采用的分类输出尺度不同而且拒判器的输出为硬输出, 所以可以采用的融合方法有限, 本文选取了投票法、加权投票法以及行为知识空间法三种融合方法, 并在试验中进行了比较.

本文的主要安排如下: 第 1 节介绍了分类器-

最近邻系统并分析了其优越性. 第 2 节详细介绍了基于多分类器融合算法的目标识别拒判方法并且定义了一种代价函数来衡量系统的综合性能. 在此代价函数的基础上介绍了选取拒判器最优工作点的两种方法. 第 3 节中采用实测数据对本文的方法进行了实验, 验证了本文提出的拒判方法的优越性且两种工作点选取算法均能够显著提高识别系统的综合性能. 第 4 节进行了总结.

1 分类器-最近邻系统

RATR 对象的非合作性导致无法建立完整的目标模板库. 当样本库中不存在的未知样本出现时, 需要分类器系统将其检测出来, 然后进行后续处理. 图 1 给出了带有拒判功能的目标识别系统框图. 其中, 图 1 (a) 表示的是传统意义下的识别拒判系统框图. 其中分类器可以采用单类别分类器或具有软输出的多类别分类器, t 则是决定输入样本是否为库内样本的阈值 (分类器工作点); 图 1 (b) 是本文提出的分类器-最近邻识别拒判系统框图. 相比图 1 (a), 此系统采用 NN 分类器进行拒判, 之前阶段的分类器输出向量作为 NN 分类器的特征. 可以看出, 该系统兼具分类和拒判两种功能.

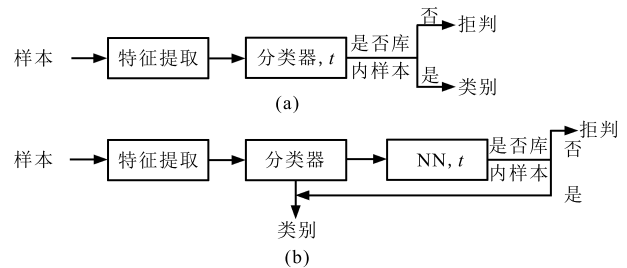


图 1 目标识别拒判系统框图 ((a) 传统意义下的框图; (b) 本文所采用的分类器-最近邻系统框图)

Fig. 1 Diagram of target recognition and rejection system ((a) Diagram of traditional system; (b) Diagram of classifier-NN system)

NN 分类器处理雷达目标识别中的拒判问题^[7]的基本思想为: 计算未知样本特征与已知库内训练样本特征间的欧氏距离, 然后将最小的距离值 d_{\min} 与预先设定的阈值 t 比较, 若 $d_{\min} \leq t$, 则将未知样本判为库内样本; 反之, 则将未知样本判为库外样本, 予以拒判.

图 1 (a) 的识别拒判系统将分类器输出与阈值比较来进行拒判操作, 只利用了库内每个子类别的信息. 单独利用 NN 分类器拒判方法也只利用了一个近邻样本的信息^[7]. 分类器-最近邻系统则弥补了这二者的不足. 多分类器的输出向量反映了未知样本与库内各类样本的“匹配程度”, 表征了样本与各类目标的关系, 包含了更多的库内样本信息. 因

而分类器-最近邻系统拥有更好的拒判效果. 后文将 NN 分类器称为 NN 拒判器以示与前端分类器的区别.

2 基于多分类器融合方法的雷达 HRRP 识别和拒判系统

由于目标的非合作性导致目标数据库不完备, 在 RATR 过程中所用的分类器应当既能够对库内的样本进行正确的识别, 又能够对库外目标实现拒判. 文献 [9-13] 证明通过对多个分类器的识别结果进行融合可以改善分类器的识别效果并提高分类系统的鲁棒性. 本节在前文提出的分类器-最近邻的识别拒判框架下, 定义了一种基于多分类器融合方法的雷达 HRRP 识别和拒判系统, 具体如图 2 所示.




图 2 基于多分类器融合方法的雷达 HRRP 识别和拒判系统

Fig. 2 Radar HRRP recognition and rejection system based on classifier combination

为了避免采用复杂的 HRRP 特征或分类器增加系统的复杂度, 文中采用几种简单的 HRRP 特征和分类器: 实 HRRP 的幅度特征配合使用最大相关分类器 (Maximum correlation classifier, MCC); 功率谱特征配合使用支持向量机 (Support vector machine, SVM)^[15] 分类器; 频谱幅度特征配合使用关联向量机 (Relevance vector machine, RVM)^[16] 分类器. 由此, 该融合系统将 MCC-NN、SVM-NN 以及 RVM-NN 三个子系统的拒判结果和识别结果分别进行融合. 通过融合可以利用不同特征以及不同分类器在对样本识别和拒判中的互补性, 并充分发挥各个分类器自身的优点, 整个系统的识别和拒判性能可以得到提高.

2.1 多分类器融合算法

在介绍整个系统之前, 本节先简单介绍一下融合拒判和融合识别两个阶段所用的融合方法: 投票法^[9-11]、加权投票法^[9-11] 以及行为知识空间法^[12].

1) 投票法

投票法是一种简单的融合方法, 基本原则是“少数服从多数”. 该方法的优点是不需要进行训练, 可直接根据分类器的输出进行融合判决. 但是, 它也存在一定的局限性. 首先, 它忽略了各个分类器之间性能的差异, 给予各个分类器输出同等地位; 其次, 容

易出现相同票数的情况, 需要拒判.

2) 加权投票法

相比于普通的投票法, 加权投票的方法考虑到不同分类器性能的差异, 给各分类器分配一个权值, 使得投票方法更为合理. 一般来说, 各分类器所分配的权值与其自身性能有关, 本文采用混淆矩阵计算权值矩阵.

设样本空间 P 中有 M 个类别, 采用 K 个分类器 e_k ($k = 1, 2, \dots, K$), 根据文献 [11] 中的加权投票算法可以得到各分类器在不同输出结果下的权值矩阵

$$W^k = \begin{bmatrix} p_{11}^k & p_{12}^k & \cdots & p_{1M}^k \\ p_{21}^k & p_{22}^k & \cdots & p_{2M}^k \\ \vdots & \vdots & \ddots & \vdots \\ p_{M1}^k & p_{M2}^k & \cdots & p_{MM}^k \end{bmatrix} \quad (1)$$

其中, p_{ij}^k 表示分类器将样本判为第 j 类而样本来自第 i 类的概率. 最终可得加权方案即判决函数为:

$$E(D) = \arg \max_i \sum_{k=1}^K p_{ij_k}^k, \quad i = 1, 2, \dots, M \quad (2)$$

其中, j_k 表示分类器 e_k 输出的类别号.

3) 行为知识空间法

前面介绍的两种方法是在各分类器相互独立的假设条件下得到的, 这里再引入一种对分类器之间独立性不做要求的融合方法, 即行为知识空间法. 该方法的具体内容是用一种所谓的行为知识空间来记录分类器集在样本上的决策行为. 空间由 K 维 (分类器个数) 决策矢量构成, 决策矢量中每一个元素代表一个分类器的决策 (类别号). 在训练过程中, 将每一类中具有相同分类器决策矢量的样本个数存入知识空间. 当要求对某个样本进行识别时, 就找出各个分类器给出的决策矢量在各个类别中的训练样本个数, 然后选取具有最多训练样本个数的类别作为样本类别.

2.2 衡量分类器综合性能的代价函数

整个融合系统中, NN 拒判器工作点的选取直接影响到分类器的拒判和识别性能. 因而需要定义合理的准则来选取适当的工作点使得系统的综合性能达到最优. 本节定义了一种代价函数来衡量分类器的识别拒判综合性能, 并将该代价函数作为选取系统工作点的标准. 在本小节中, 我们首先分别介绍衡量分类器识别性能和拒判性能的各项指标, 然后在此基础上定义代价函数.

本文用平均正确识别率 P_a 来衡量分类器的识别性能, 它表示正确检测到的库内目标的平均正确识别率, 其定义如下:

$$P_a = \frac{1}{M} \sum_{i=1}^M \frac{\text{正确识别为 } C_i \text{ 类的样本数目}}{\text{判别为 } C_i \text{ 类的库内样本数目}} \quad (3)$$

接收机工作特性 (Receiver operating characteristic, ROC) 曲线^[17] 常用来衡量分类器的拒判性能. ROC 曲线的横轴为虚警概率 P_f , 纵轴为检测概率 P_d . 其中, P_f 表示将库外样本误判为库内样本的概率, P_d 表示将库内样本正确判为库内样本的概率, 二者定义如下:

$$P_f = \frac{\text{库外样本判为库内样本的数目}}{\text{库外样本的数目}}$$

$$P_d = \frac{\text{库内样本判为库内样本的数目}}{\text{库内样本的数目}} \quad (4)$$

ROC 曲线上的每一个点代表分类器的一个工作点, 其横轴坐标和纵轴坐标分别为分类器在该工作点下的虚警概率和检测概率. 通常用 ROC 曲线下的面积 (Area under an ROC curve, AUC) 来表征分类器的拒判性能, 面积越大, 表明分类器的拒判性能越好.

分类器判别结果出现错误的情况有三种: 1) 混淆了库内目标的类别, 其概率为 $1 - P_a$; 2) 将库内目标误判为库外目标 (漏警), 其概率为 $1 - P_d$; 3) 将库外目标误判为库内目标 (虚警), 其概率为 P_f . 综合以上, 本文提出了如下的代价函数来定量地衡量分类器的综合性能:

$$CF = c_1(1 - P_a) + c_2(1 - P_d) + c_3P_f \quad (5)$$

其中, c_1, c_2, c_3 分别表示三类错误的代价.

显然, 错误 1) 反映了分类器的识别性能, 错误 2) 和错误 3) 反映了分类器的拒判性能. 本文假设识别错误与拒判错误的代价比为 $1 : \alpha$, 拒判错误中漏警和虚警的代价比为 $1 : \beta$, 即 $c_1/(c_2 + c_3) = 1/\alpha$, $c_2/c_3 = 1/\beta$, 则式 (5) 中的代价函数可改写为如下形式:

$$CF = \frac{1}{1 + \alpha} \left((1 - P_a) + \frac{\alpha}{1 + \beta} ((1 - P_d) + \beta P_f) \right) \quad (6)$$

其中, 常数因子 $1/(1 + \alpha)$, $1/(1 + \beta)$ 分别起到对总体代价因子和拒判代价因子归一化的作用. 分析可得, α 值越大表明对拒判性能的要求越高 (控制错误 2) 和错误 3)); β 值越大要求虚警概率尽可能低. 在具体的应用背景下, 可以调节 α 和 β 的取值来对不同的错误定义相应代价.

2.3 利用多分类器融合方法进行拒判和识别的步骤

图 2 给出了基于多分类器融合方法的识别和拒判系统的框图, 本小节将具体介绍其实施步骤. 将整个样本集分为三类: 训练集 1, 只包含各类库内目标

样本; 训练集 2, 同时包含库内目标样本和库外目标样本; 测试集, 同时包含库内目标样本和库外目标样本. 整个识别系统分为训练和测试两个阶段:

1) 训练阶段:

训练阶段共分为两步: a) 利用训练集 1 训练三个分类器; b) 利用训练集 2 确定 NN 拒判器的工作点 t , 并利用第 2.1 节多分类器融合算法求得分类器识别和拒判的权值以及行为知识空间 (投票法不需要进行训练). 具体步骤如下:

步骤 1. 训练分类器-最近邻系统, 按照第 2 节介绍分别提取三种特征并训练相应的分类器; 然后将训练集 1 的样本通过每个分类器的输出向量作为库内样本特征库.

步骤 2. 为了表述方便, 将 MCC-NN、SVM-NN 和 RVM-NN 三个子系统的标号记作 1, 2, 3. 对于每个子系统分别采取如下训练步骤:

步骤 2.1. 将训练集 2 中的样本通过第 i 个分类器-最近邻系统得到最小距离集 $\{d_{ij} | i = 1, 2, 3; j = 1, 2, \dots, N\}$, j 为样本标号, N 为训练集 2 中的样本数;

步骤 2.2. 确定第 i 个 NN 拒判器的工作点 t_i : 令 $t_i = d_{ik_i}$, $k_i = \arg \min_j CF_{ij}$, $j = 1, 2, \dots, N$, 其中 CF_{ij} 表示以 d_{ij} 为拒判阈值时的代价函数值, 也即选择使用代价函数值最小的工作点所对应的阈值;

步骤 2.3. 根据识别和拒判结果, 利用第 2.1 节多分类器融合算法, 分别记录其行为知识空间并计算加权矩阵;

步骤 2.4. 记录分类器的工作点和拒判、识别的权值以及行为知识空间.

由上面步骤可以看出, 每个分类器-最近邻系统的阈值是当自身的代价函数值最小时得到的, 本文称此方法为局部法.

2) 测试阶段:

测试阶段的流程如图 2 所示. 由图 2 可以看出, 本文算法可以将任务分配给多个处理单元实现并行处理以提高效率, 这也是多分类器融合的一个优势所在. 对于测试集中的任一样本 \mathbf{x} , 采取如下测试步骤:

步骤 1. 提取测试集内样本对应的实距离像、频谱幅度和功率谱三个特征;

步骤 2. 将提取的特征分别通过 MCC、SVM 和 RVM 三个分类器进行识别;

步骤 3. 将分类器的输出通过 NN 拒判器分别与阈值进行比较;

步骤 4. 利用多分类器融合算法, 通过权值矩阵或行为知识空间判定 \mathbf{x} 是否为库内目标;

步骤 5. 若样本 \mathbf{x} 为库内目标, 则采用多分类器融合算法判定其类别, 然后输出类别; 若为库外目

标, 则拒判。

2.4 全局最优的工作点

分类器-最近邻系统工作点的选择直接影响系统融合后的代价函数值。第 2.3 节中的局部法分别针对不同的分类器选取各自最优的工作点, 这种方法在训练阶段的计算复杂度较低, 但它不能保证融合后最终的代价函数最小。为了获取全“最优”的工作点组合, 本节提出了全局法。全局法通过三维(取决于分类器个数)搜索的方法, 确定融合后代价函数值最小时所有分类器-最近邻系统的工作点。全局法与局部法的区别主要在于分类器训练阶段的步骤 2, 其余训练阶段及测试阶段完全一致。全局法训练步骤 2 如下:

步骤 2.1. 将训练集 2 中一半的样本通过第 i 个分类器-最近邻系统得到最小距离集 $\{d_{ij}|i = 1, 2, 3; j = 1, 2, \dots, N\}$, j 为样本标号, N 为所用样本数;

步骤 2.2. 令三个分类器-最近邻系统工作点为 $[t_1 t_2 t_3] = [d_{1i} d_{2j} d_{3k}]$, $i, j, k = 1, 2, \dots, N$, 共有 N^3 个工作点组合;

步骤 2.3. 在每个工作点组下, 根据识别和拒判结果, 利用第 2.1 节多分类器算法, 分别记录其行为知识空间并计算加权矩阵;

步骤 2.4. 对于每个工作点组合, 按照第 2.3 节局部法测试阶段步骤, 对训练集 2 的另一半样本进行拒判和识别, 进一步求得 N^3 个代价函数值;

步骤 2.5. 记录代价函数取值最小时对应的三个分类器的工作点、识别和拒判的权值以及行为知识空间。

由上面步骤可以看出, 对于每个工作点组都要分别计算各子系统的拒判和识别时的权值, 然后对分类器输出进行融合, 最后计算代价函数, 这样整个训练过程计算复杂度将大大增加。因此有必要减小训练样本个数 N 的值。然而利用分类器的混淆矩阵进行加权是一种统计意义上的加权, 为了得到准确的识别性能矩阵, 训练阶段的步骤 2 中需要使用大量的训练样本。为缓解这一矛盾, 本文在搜索最优工作点组时, 要求每个子系统的待选工作点应满足以下约束条件:

$$P_d \geq 90\% \text{ 且 } P_f \leq 20\% \quad (7)$$

然后, 在每个子系统得到的待选工作点中抽取 N' 个工作点, 由此来降低计算复杂度。

从上面的分析可知, 训练过程中全局法最终的代价要小于局部法, 适当的训练后在测试阶段可以得到更优的结果。然而也应当看到, 局部法在计算复杂度和分类器扩展性方面有其独特优势。在训练阶段, 局部法中各分类器相互独立, 可以通过并行运算

来提高训练的效率; 而全局法由于要考虑整个系统的代价函数, 所以只能通过三维搜索的方法来搜索三个分类器-最近邻系统的最优工作点。此外, 当分类器个数增加时, 局部法中只需单独训练新增的分类器, 而全局法则需要对所有的分类器全部重新训练。在实际工程中, 两者都有其相应的应用价值。

在寻找局部法和全局法中拒判器的阈值时, 采用交叉验证法能够获取更加稳健参数。然而, 由于雷达 HRRP 数据通常具有较高的维度且具有姿态敏感性^[18], 不同姿态下 HRRP 差异很大, 而实际获取的训练样本往往很有限, 因此基于 HRRP 的目标识别属于典型的小样本学习问题^[15, 19]。交叉验证法需要将有限的训练样本再划分成若干块, 这就使得 HRRP 识别中的“维数灾难”问题更加突出。另外, 交叉验证法需要提前给定一组备选的参数。本文 NN 拒判器的备选阈值为最小距离集合 $\{d_{ij}|i = 1, 2, 3; j = 1, 2, \dots, N\}$ 。采用交叉验证法时, 如果每次试验选用不同的备选阈值, 显然不合适; 然而采用相同的备选集, 则又会出现不同的阈值下检测和虚警概率相同的情况, 不易进行比较。因此本文未采用交叉验证法选取最优阈值。

3 实验

3.1 数据介绍

本节选用国内某研究所 ISAR 雷达测量的 3 类飞机数据^[1-2, 5, 7, 13] 作为库内样本, 然后人工生成库外样本进行仿真实验。ISAR 雷达工作在 C 波段, 信号带宽为 400 MHz。实验飞机有三类, “An-26”为中小型螺旋桨飞机, “Cessna”为小型喷气式飞机, “Yark-42”为中大型喷气式飞机。三类飞机的航迹在地平面上的投影如图 3 所示。

在训练分类器的工作点以及测试系统的性能时需要用到大量的库外样本。本文采用文献 [5, 7] 中提到的方法人工产生库外样本。该文献中认为, 理论上可以假设库外样本是在全空间均匀分布, 但由于 HRRP 通常具有很高的维度, 要生成高维空间内完全均匀分布的样本是很困难的。事实上, 常用的方法是产生有限数量的样本来代表库外样本。本文中采用了文献 [5, 7] 中提出的方法 2, 将样本每一维分布的区间范围扩大两倍, 作为库外样本在该维上均匀分布的范围。

为了检验本文方法的推广性能, 将三类飞机的 HRRP 数据分段, 并分别选取不同的数据段作为库内样本的训练和测试数据, 其中, “Yark-42”的第 2、5 段, “An-26”的第 5、6 段, “Cessna”的第 6、7 段数据作为训练集 1, 其他段数据作为训练集 2 以及测试集中的库内样本。训练集 2 中包含 30 000 个库内样本(每类飞机各 10 000 个)和 30 000 个库外样本。

测试集中包含 5 200 个库内样本和 20 000 个库外样本. 训练集 2 和测试集所含库内样本不同.

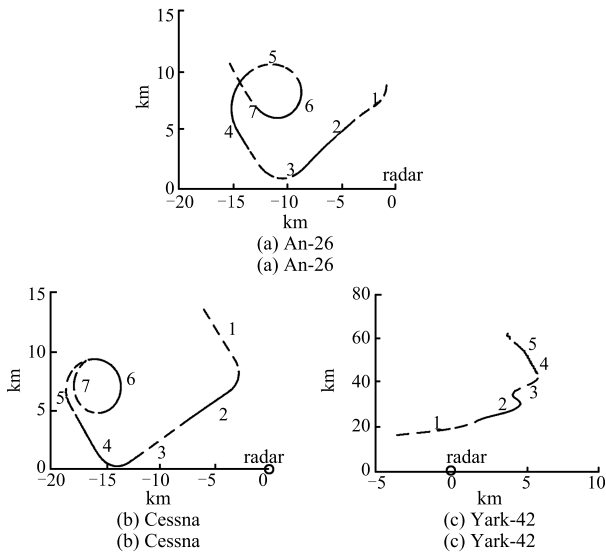


图 3 三类飞机的航迹在地平面上投影图
Fig.3 Projections of target trajectories onto the ground plane

3.2 实验结果分析

实验 1. 分类器-最近邻拒判器性能分析

本实验对三种特征下本文提出的分类器-最近邻拒判器与 NN^[7]、SVDD^[8]、OCSVM^[6] 以及 AGC^[20] 四种分类器作为拒判器的拒判性能进行了比较. 实验中采用训练集 1 中的样本训练分类器及拒判器, 然后用对训练集 2 的样本进行拒判实验. 由于在高斯核函数 ($k(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2/\sigma)$) 下 SVDD 与 OCSVM 是等价的^[6], 所以在实验过程中

OCSVM 采用多项式核函数 ($k(\mathbf{x}, \mathbf{y}) = (\mathbf{x}^T \mathbf{y} + 1)^d$). 此外, 实验中分别计算了各种拒判器在多种参数取值条件下的 AUC 值, 并从中挑选各自最优的结果如表 1 所示. 由于 HRRP 幅度特征呈多模态分布, 简单的一类分类器作为拒判器效果很差; 在功率谱特征下分类器-最近邻法 AUC 值略低于 AGC 法, 但仍高于其他方法; 在频谱幅度特征下分类器-最近邻法具有较高优势. 该实验结果表明了分类器-最近邻系统进行拒判时, 具有比传统拒判方法更好的效果.

实验 2. 采用局部法进行识别拒判实验

代价函数 (6) 中存在 α 和 β 两个参数, 在实际应用中可以根据实际的工程需要来确定两个常数的值. 本实验在假设虚警和漏警代价相同的情况下, 研究识别性能与拒判性能代价比的变化对识别系统性能的影响. 具体做法是: 固定 $\beta = 1$, 同时将 α 的取值从 0.5 变化到 2, 变化步长为 0.1. 设定好参数后分别按照第 3.3 节介绍的局部法训练和测试方法进行实验. 图 4 给出了采用加权投票融合算法时的实验结果. 图 4(a)~4(c) 给出了 α 取不同值时, 三个分类器-最近邻子系统和 CC-NN 系统 (表示融合后的识别拒判系统) 的代价函数中的三个因子: 平均识别率 P_a 、检测概率 P_d 和虚警概率 P_f 的值; 图 4(d) 比较了三个子系统和融合系统的代价函数值. 表 2 比较了几组 α 典型取值下最优的单个分类器与采用局部法时三种融合方法得到的代价函数值.

由图 4(a)~4(c) 可以看出三个分类器-最近邻系统各具优势: MCC-NN 表现了更好的识别性能; SVM-NN 表现了更好的检测性能; RVM-NN 在保持高检测概率的情况下仍很好地控制了虚警概率. 通过加权投票融合, CC-NN 系统在代价函数的各个

表 1 三种特征下不同方法得到的 AUC 值比较

Table 1 Comparison of AUC values obtained by different methods

AUC	NN	SVDD	OCSVM	AGC	分类器-最近邻
HRRP 幅	0.351	0.316	0.324	0.942	0.982
功率谱	0.989	0.971	0.972	0.996	0.993
频谱幅度	0.884	0.994	0.993	0.967	0.998

表 2 最优单系统与局部法结果比较

Table 2 Comparison of local method and optimal individual system

方法	$\alpha = 0.5$	$\alpha = 1.0$	$\alpha = 1.5$	$\alpha = 2.0$
RVM-NN	0.0726	0.0594	0.0515	0.0461
投票法	0.0637	0.0529	0.0466	0.0422
加权投票法	0.0636	0.0528	0.0464	0.0420
行为知识空间法	0.0524	0.0475	0.0448	0.0425

参数上保持较好的水平. 如图 4(d) 所示, CC-NN 系统代价函数值低于任何一个子系统的代价函数值. 计算可得, 与最优的单系统 (RVM-NN) 相比, 三种方法融合后的代价函数值分别降低了 8.6%~12.2%、8.9%~12.4% 和 7.9%~27.8%. 由于只用了三个子系统, 两种投票方法之间差异不大. 由此可见, 在识别和拒判阶段采用多分类器融合技术可以有效地提高 RATR 系统的综合性能.

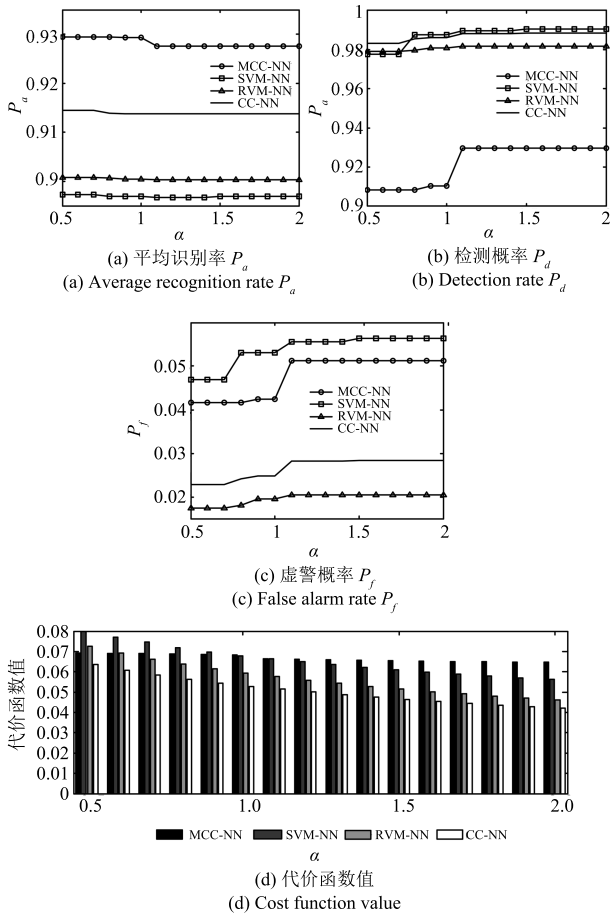


图 4 采用加权投票准则时局部法实验结果
Fig. 4 Results obtained by local method when using weighted voting method

实验 3. 采用全局法进行识别拒判实验

本实验采用全局法选择分类器-最近邻系统的工作点, 参数设置与实验 2 一致. 图 5 给出了在加权投票融合算法下, 三个分类器-最近邻系统以及融合后分类器在不同 α 下得到的代价函数值. 表 3 比较了几组 α 典型取值下最优的单个分类器与采用全局法时三种融合方法得到的代价函数值. 由表 3 计算可得, 与最优的单系统 (RVM-NN) 代价函数值相比, 三种方法融合后的代价函数值分别降低了 10.1%~12.9%, 13.1%~13.7% 和 29.5%~33.1%. 由此可见, 全局法可以更加有效地提高 RATR 系统的综合性能.

图 6 给出了局部法和全局法在加权投票融合准则下三个子系统与融合系统代价函数值比较. 三个




图 5 全局法代价函数值

Fig. 5 Cost function values obtained by global method when using weighted voting method




图 6 采用加权投票法时局部法与全局法代价函数值比较
Fig. 6 Comparison of local method and global method when using weighted voting method

表 3 最优单系统与全局法结果比较

Table 3 Comparison of global method and optimal individual system

方法	$\alpha = 0.5$	$\alpha = 1.0$	$\alpha = 1.5$	$\alpha = 2.0$
RVM-NN	0.0726	0.0594	0.0515	0.0461
投票法	0.0632	0.0523	0.0459	0.0415
加权投票法	0.0626	0.0514	0.0446	0.0401
行为知识空间法	0.0486	0.0407	0.0358	0.0326


子系统采用全局法得到工作点时, 子系统本身代价函数值并没有达到最小, 然而融合后全局法可以得到比局部法更小的代价函数值. 比较表 2 和表 3, 三种融合方法下采用全局法比采用局部法代价函数值分别降低了 0.8%~1.7%, 1.5%~4.8% 和 7.3%~24.35%, 其中行为知识空间法在实验中效果最佳. 可见, 全局法是在保证融合后代价函数值最小的条件下, 选择各个子系统的工作点, 它不但充分发挥了单个分类器-最近邻系统的优势, 而且与局部法相比扩大了融合分类器的优势.

4 结论

本文利用加权投票算法对多个分类器-最近邻系统的拒判和识别结果进行融合, 从而充分发挥各分类器自身的优势, 提高识别系统的综合性能. 为了衡量分类器的综合性能以及选择分类器-最近邻系统的工作点, 本文综合分类器的三个性能指标定义了一个代价函数, 并提出了两种算法来确定各个分类器-最近邻系统的工作点. 通过实测数据集仿真实验, 验证了利用多分类器融合方法可以得到比单个分类器更优的性能. 而且, 本文算法在测试阶段可以将任务分配给多个处理单元实现并行处理以提高效率. 因此本文算法是一种有效地提高雷达 HRRP 拒判和识别效果的方法.

References


- Du L, Wang P H, Liu H W, Pan M, Chen F, Bao Z. Bayesian spatiotemporal multitask learning for radar HRRP target recognition. *IEEE Transactions on Signal Processing*, 2011, **59**(7): 3182-3196
- Shi L, Wang P H, Liu H W, Xu L, Bao Z. Radar HRRP statistical recognition with local factor analysis by automatic Bayesian Ying-Yang harmony learning. *IEEE Transactions on Signal Processing*, 2011, **59**(2): 610-617
- Zhang Yu-Xi, Wang Xiao-Dan, Yao Xu, Bi Kai. HRRP recognition for polarization radar based on Bagging-SVM dynamic ensemble. *Systems Engineering and Electronics*, 2012, **34**(7): 1366-1371
(张玉玺, 王晓丹, 姚旭, 毕凯. 基于 Bagging-SVM 动态集成的多极化 HRRP 识别. 系统工程与电子技术, 2012, **34**(7): 1366-1371)
- Pilcher C M, Khotanzad A. Maritime ATR using classifier combination and high resolution range profile. *IEEE Transactions on Aerospace and Electronic Systems*, 2011, **47**(4): 2558-2573
- Chai Jing, Liu Hong-Wei, Bao Zheng. New method for improving the performance of radar HRRP recognition and rejection. *Journal of Xidian University (Natural Science)*, 2009, **36**(2): 233-239
(柴晶, 刘宏伟, 保铮. 一种提高雷达 HRRP 识别和拒判性能的新方法. 西安电子科技大学学报(自然科学版), 2009, **36**(2): 233-239)
- Tohmé M, Lengellé R. Maximum margin one class support vector machines for multiclass problems. *Pattern Recognition Letters*, 2011, **32**(13): 1652-1658
- Chai Jing, Liu Hong-Wei, Bao Zheng. Application of a weighted KNN classifier for HRRP out-of-database target rejection. *Systems Engineering and Electronics*, 2010, **32**(4): 718-723
(柴晶, 刘宏伟, 保铮. 加权 KNN 分类器在 HRRP 库外目标拒判中的应用. 系统工程与电子技术, 2010, **32**(4): 718-723)
- Pan Zhi-Song, Chen Bin, Miao Zhi-Min, Ni Gui-Qiang. Overview of study on one-class classifiers. *Acta Electronica Sinica*, 2009, **37**(11): 2496-2503
(潘志松, 陈斌, 缪志敏, 倪桂强. One-Class 分类器研究. 电子学报, 2009, **37**(11): 2496-2503)
- Kittler J, Hatef M, Duin R P W, Matas J. On combining classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, **20**(3): 226-239
- Valentini G, Masulli F. Ensembles of learning machines. In: Proceedings of the 13th Italian Workshop on Neural Nets. London, UK: Springer-Verlag, 2002. 3-22
- Xu L, Krzyzak A, Suen C Y. Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, Man, and Cybernetics*, 1992, **22**(3): 418-435
- Huang Y S, Suen C Y. A method of combining multiple experts for the recognition of unconstrained handwritten numerals. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1995, **17**(1): 90-94
- Cao Xiang-Hai, Liu Hong-Wei, Wu Shun-Jun. Utilization of multiple polarization data and multiple features for radar target identification. *Systems Engineering and Electronics*, 2008, **30**(2): 261-264
(曹向海, 刘宏伟, 吴顺君. 多极化多特征融合的雷达目标识别研究. 系统工程与电子技术, 2008, **30**(2): 261-264)
- Dietterich T G. An experimental comparison of three methods for constructing ensembles of decision trees: bagging, boosting, and randomization. *Machine Learning*, 2000, **40**(2): 139-157
- Bishop C M. *Pattern Recognition and Machine Learning*. New York: Springer Science + Business Media, LLC, 2006. 33-38
- Carin L, Dobeck G J. Relevance vector machine feature selection and classification for underwater targets. In: Proceedings of the 2003 Oceans Conference. San Diego, USA: IEEE, 2003. 1110-1110
- Fawcett T. An introduction to ROC analysis. *Pattern Recognition Letters*, 2006, **27**(8): 861-874
- Bao Zheng, Xing Meng-Dao, Wang Tong. *Radar Imaging Technology*. Beijing: Publishing House of Electronics Industry, 2005. 30-39
(保铮, 邢孟道, 王彤. 雷达成像技术. 北京: 电子工业出版社, 2005. 30-39)
- Schmid N A, O'Sullivan J A. Thresholding method for dimensionality reduction in recognition systems. *IEEE Transactions on Information Theory*, 2001, **47**(7): 2903-2920
- Jacobs S P, O'Sullivan J A. Automatic target recognition using sequences of high resolution radar range profiles. *IEEE Transactions on Aerospace and Electronic System*, 2000, **36**(2): 364-381



张学峰 西安电子科技大学雷达信号处理国家重点实验室博士研究生. 2009 年获西安电子科技大学电子工程学院学士学位. 主要研究方向为雷达自动目标识别. E-mail: zxf0913@163.com

(**ZHANG Xue-Feng** Ph. D. candidate at the National Key Laboratory of Radar Signal Processing, Xidian University.

He received his bachelor degree from Xidian University in 2009. His main research interest is radar target recognition.)




王鹏辉 西安电子科技大学雷达信号处理国家重点实验室讲师. 主要研究方向为雷达信号处理和雷达自动目标识别.

E-mail: wangpenghui@mail.xidian.edu.cn

(**WANG Peng-Hui** Lecturer at the National Key Laboratory of Radar Signal Processing, Xidian University.

His research interest covers radar signal processing and radar automatic target recognition.)



冯博 西安电子科技大学雷达信号处理国家重点实验室博士研究生. 2009 年获西安电子科技大学电子工程学院学士学位. 主要研究方向为雷达自动目标识别. E-mail: ivyleague007@126.com

(**FENG Bo** Ph. D. candidate at the National Key Laboratory of Radar Signal Processing, Xidian University. He

received his bachelor degree from Xidian University in 2009. His main research interest is radar target recognition.)



杜兰 西安电子科技大学电子工程学院教授. 2007 年获西安电子科技大学信息与通信工程专业博士学位. 主要研究方向为统计信号处理, 雷达信号处理, 机器学习及其在雷达目标检测与识别方面的应用. 本文通信作者.

E-mail: dulan@mail.xidian.edu.cn

(**DU Lan** Professor at the College of Electrical Engineering, Xidian University. She received her Ph. D. degree in information and communication engineering from Xidian University in 2007. Her research interest covers statistical signal processing, radar signal processing, and machine learning with application to radar target recognition. Corresponding author of this paper.)



刘宏伟 西安电子科技大学电子工程学院教授, 雷达信号处理国家重点实验室主任. 主要研究方向为雷达信号处理, MIMO 雷达, 雷达目标识别, 自适应信号处理, 认知雷达.

E-mail: hwliu@xidian.edu.cn

(**LIU Hong-Wei** Professor at the College of Electrical Engineering, Xidian University, director of the National Key Laboratory of Radar Signal Processing. His research interest covers radar signal processing, MIMO radar, radar target recognition, adaptive signal processing, and cognitive radar.)