

文章编号: 1001- 2486(2008) 06- 0107- 07

# 基于 VFGPIR 联合特征的决策级加权融合检测方法\*

杨延光<sup>1</sup>, 周智敏<sup>1</sup>, 宋 千<sup>1</sup>, 初 宁<sup>1</sup>, 金小三<sup>2</sup>

(1. 国防科技大学 电子科学与工程学院, 湖南 长沙 410073; 2. 海军 705 厂, 广东 湛江 524016)

**摘要:** 车载前视地表成像雷达(VFGPIR)探测浅埋目标时面临虚警率过高问题, 可利用序列图像特征的联合检测解决这一问题。首先利用 Fisher 鉴别比(FDR)定量评估从单帧和序列图像中提取的单个特征的鉴别能力; 然后针对单个最优序列特征无法满足探测指标要求提出一种基于决策级加权融合的多特征联合检测方法; 最后利用接收机工作特性(ROC)曲线来验证所提方法的有效性。试验结果表明: 序列特征比单帧图像特征具有更好的鉴别能力; 所提方法性能优于单个最优序列特征、特征向量和多数票融合准则对应的检测结果, 有望满足实际探雷应用需求。

**关键词:** 地表穿透成像雷达; 地雷检测; 决策级融合; Fisher 鉴别比; 接收机工作特性曲线

中图分类号: TN914. 42 文献标识码: A

## A Decision-level Weighting Fusion Detection Method Based on the Joint Multi-features of VFGPIR

YANG Yarr guang<sup>1</sup>, ZHOU Zhi min<sup>1</sup>, SONG Qian<sup>1</sup>, CHU Ning<sup>1</sup>, JIN Xiao san<sup>2</sup>

(1. College of Electronic Science and Engineering, National Univ. of Defense Technology, Changsha 410073, China;

2. 705 Factory of Navy, Zhanjiang 524016, China)

**Abstract:** The vehicle mounted forward looking ground penetrating imaging radar (VFGPIR) is a feasible facility to detect shallow buried objects, but it faces a high false alarm rate. The combined detection, by using the sequence features, is proposed as the key to solve this problem. Firstly, we use the Fisher's discriminating ratio (FDR) to quantificationally evaluate the discriminating power of the individual feature component extracted from the single or serial images. Since the optimal individual sequence feature cannot satisfy the needs, a multi-features joint detection method based on the decision-level weighting fusion is presented in this paper. Finally, the receiver operating characteristic (ROC) curve is exploited to demonstrate the validity of the proposed method. Experimental results of the data show that the features extracted from the sequence images have better discriminating power, and the suggested method has a better detection performance than that of the optimal individual sequence feature, feature vector, and majority voting fusion rule. The approach is expected to satisfy the requirements of landmine detection in the practical application.

**Key words:** ground penetrating imaging radar (GPIR); landmine detection; decision-level fusion; Fisher's discriminant ratio (FDR); receiver operating characteristic (ROC) curve

大面积区域需要进行排雷及清除一颗怀疑地雷的代价要求探测设备具有较低的虚警率<sup>[1]</sup>。车载前视地表穿透成像雷达(Vehicle-mounted Forward looking Ground Penetrating Imaging Radar, VFGPIR)作为一种有效的探雷装备, 受低信杂比的限制在实用中面临虚警率过高的挑战<sup>[2]</sup>, 从VFGPIR序列图像中获取稳健、有效的特征成为提高目标检测性能的关键<sup>[3-7]</sup>。目前已有大量文献研究SAR图像中的目标特征。针对高波段SAR图像, 诸如形状、尺寸、扩展分形、分形维数、面积、峰值、峰值能量比、加权填充比、对比度、均值、标准偏差、频率和极化等特征广泛用于目标检测和鉴别<sup>[8-10]</sup>。针对GPR获取的低波段SAR图像, 文献[11-12]利用能量扩展比对其进行预筛选; 文献[13]利用尺寸、形状、对比度和纹理特征区分地雷和杂波; 文献[3]提出了基于强度、局部对比度和极化的10个特征以及21个模糊几何特征; 文献[4]基于全极化图像进一步研究了频域特征; 文献[5-7]利用时频分析提取地雷不同于杂波的特征。在分

\* 收稿日期: 2008- 09- 06

基金项目: 国家部委重点资助项目

作者简介: 杨延光(1980-), 男, 博士生。

类之前需通过某种准则对单个特征的鉴别能力进行评估,以去除某些无效特征,提高检测性能和效率<sup>[2,5,14]</sup>。

地雷埋设环境的复杂性及探测的特殊性使得利用单一特征很难满足指标要求,问题的解决有赖于多种特征的综合运用。决策级融合以其易于实现、稳健和适应性好的优点而广泛用于多传感器数据融合<sup>[1,15]</sup>。文献[8]采用投票机制对多特征进行联合判决,假定各个特征均有效而未进行特征选择,且权值均为1,这与实际情况不符合;文献[9]采用序贯鉴别方法进行地雷检测,但对确定特征的次序和相应的门限要求很高,使用不当将导致检测性能的严重恶化。

本文提出一种基于加权融合的多特征联合检测方法。首先利用 Fisher 鉴别比(Fisher's Discriminant Ratio, FDR)定量评估单帧图像特征和序列图像特征的鉴别能力<sup>[9]</sup>;然后利用线性判别分析(Linear Discriminant Analysis, LDA)分类器对各个特征进行鉴别<sup>[2]</sup>;最后利用所选择的序列特征和由其构成特征向量的鉴别结果进行加权融合判决,分别将 FDR 和 Fisher 代价函数作为单个序列特征和特征向量鉴别结果对应的权值。该方法充分利用了单个特征的互补信息和特征向量的内部结构,可克服多数投票准则对做出正确判决的单个分类器数目的要求,且避免了  $N$  中取  $k$  准则对单个特征鉴别能力相等的前提假设<sup>[16]</sup>。

## 1 VFGPIR 图像中地雷目标特征提取

由于系统、信息处理和检测对象不同,特征亦不尽相同,因此本文仅从感兴趣区域(Region of Interest, ROI)中提取 10 个局部统计特征和 12 个图像几何特征。表 1 给出了它们的名称和表征的物理含义。

表 1 特征名称及其表征的物理含义

Tab. 1 Appellation of features and their physical meanings

特征类型	特征名称	特征描述
局部统计特征	峰值	ROI 中像素的最大值,假设目标能量普遍强于自然杂波能量
	目标对比度	潜在目标最大灰度值与其最小灰度值之比
	统计均值	潜在目标块像素的平均值,反映目标的平均能量
	标准差	潜在目标块像素强度起伏的度量值
	偏度	利用像素的三阶统计特性表征分布的形状
	峰度	利用像素的四阶统计特性表征分布的峭度和扁平度
	能量	ROI 分割后得到的潜在目标块的像素灰度值之和
	中值对比度	潜在目标块的灰度中值与背景的灰度中值之比
	前后对比度	潜在目标块的平均强度与背景区域平均强度的差与它们的和之比
	能量扩展比	潜在目标块的能量与周围背景杂波能量之比,定量衡量目标能量的集中程度
图像几何特征	面积	二元图像中潜在目标块内的像素总数
	周长	潜在目标块边缘像素点数,在一定程度上反映目标的面积和形状
	紧致度	目标面积与目标周长平方之比
	块长度	目标在距离向的像素点数,反映目标在距离向上的尺寸
	块宽度	目标在方位向的像素点数,反映目标在方位向上的尺寸
	面积覆盖比	潜在目标块的面积与长度和宽度之积的比,表征区域的形状
	轴比	潜在目标块的长度与宽度之比
	平均半径	潜在目标块边界上的点到质心的平均距离
	长轴长度	物体最小外接矩形的长
	短轴长度	物体最小外接矩形的宽
	离心率	短轴长/长轴长,度量一个区域与圆的相似程度
	扩展分形	度量局部结构函数在不同尺度上的变化

对于单帧图像,每个潜在目标只能提取一个 ROI,利用上述特征可获取单帧图像对应的特征向量  $v_F = [f_1 \cdots f_k \cdots f_K]$ ,  $k = 1, 2, \dots, K$ ,  $K$  为特征向量中所包含的特征数。VFGPIR 在行进探测过程中可获取

潜在目标在不同入射角和观测距离下的 ROI 序列图像  $g_l(x, y)$ ,  $l = 1, 2, \dots, L$ ,  $L$  为序列图像包含的帧数。利用 ROI 序列可形成一个特征矩阵  $V_F = [f_1 \dots f_k \dots f_K]$ , 其中每列为某个特征  $f_k$  在 ROI 序列中对应的  $L$  次观测样本形成的向量  $f_k$ , 每行为某个观测距离下得到的 ROI 提取的特征向量  $v_F^l$ , 上标  $l$  表明该 ROI 在序列中的索引号。本文利用 PCA 对多次观测样本形成的特征向量  $f_k$  进行特征提取和降维, 得到新的序列特征  $f_k^{\text{squnc}}$ 。则由 ROI 图像序列得到的序列特征  $f_k^{\text{squnc}}$  构成的特征矩阵为

$$V_{\text{feature}}^{\text{squnc}} = [f_1^{\text{squnc}} \dots f_k^{\text{squnc}} \dots f_K^{\text{squnc}}], \quad k = 1, 2, \dots, K \quad (1)$$

为便于和单帧图像特征比较, 仅取第一主分量对  $f_k$  进行变换, 使得到的序列特征为标量, 记为  $f_k^{\text{squnc}}$ 。

## 2 基于决策级加权融合的多特征联合检测

### 2.1 基于 FDR 的特征评估与选择

实际中各个特征的鉴别能力是不同的, 评价某种特征表征模式的好坏可通过分析各模式在其特征空间中的分布来实现<sup>[16]</sup>, 类内聚集程度越高, 类间距离越大的特征越好。文献[5]利用 FDR 作为准则函数对单个特征的鉴别能力进行评估, 对于两类问题, 第  $k$  个特征分量  $f_k$  的 FDR 为

$$J_{\text{FDR}}(f_k) = \frac{|\mu_1(f_k) - \mu_2(f_k)|^2}{\sigma_1^2(f_k) + \sigma_2^2(f_k)}, \quad k = 1, 2, \dots, K \quad (2)$$

其中,  $J_{\text{FDR}}(\bullet)$  为度量单个特征鉴别能力的准则函数,  $\mu_1(f_k)$  和  $\mu_2(f_k)$  分别为类 1 和类 2 的样本在第  $k$  个特征分量上的均值,  $\sigma_1^2(f_k)$  和  $\sigma_2^2(f_k)$  分别为相应的方差。对各个特征的  $J_{\text{FDR}}$  按照由大到小的顺序进行排序, 然后由训练数据获取一个阈值  $J_T$ , 保留  $J_{\text{FDR}} > J_T$  的特征。假设经过特征选择后保留  $N$  ( $N < K$ ) 个特征, 每个特征对应一个 LDA 分类器  $h(\mathbf{x})$ <sup>[5, 14]</sup>, 其定义为

$$h(\mathbf{x}) = \text{sgn}\left(\mathbf{W}^T \mathbf{x} + \omega_0\right) \quad (3)$$

其中  $\text{sgn}(\bullet)$  为符号操作,  $\mathbf{W}$  为投影矩阵,  $\mathbf{x}$  为待测试样本对应的归一化特征向量,  $\omega_0$  为阈值。为简化分类器的设计, 这里对各个特征空间均采用相同类型的 LDA 分类器。

### 2.2 多个特征鉴别结果的加权融合判决

传统分类器在进行鉴别时, 其目的是最大化分类间隔, 从而减小分类错误率; 而在地雷检测中, 由于将地雷误判为杂波和杂波误判为地雷的代价是不同的, 此时的最优分类面不仅仅是使分类间隔最大化, 而且需使得分类界面与地雷目标特征空间的距离最大化, 即最优分类面不再位于两类的中间, 而是靠近杂波空间, 以降低目标误判为杂波的风险。因此可将式(3)定义的分类器修正为软判决形式:

$$h_M(\mathbf{x}) = \mathbf{W}^T \mathbf{x} + \alpha \omega_0 \quad (4)$$

其中  $\alpha$  为常数, 对于给定的 LDA 分类器, 其值通常由某个特征对应的 ROC 曲线决定, 本文由训练数据给出的范围为 0.5~0.8。将每个特征经过分类器的输出映射为检测概率

$$p(f_k) = \begin{cases} 1, & h_M(f_k) \geq 0 \\ 0, & h_M(f_k) < 0 \end{cases} \quad (5)$$

对各特征的鉴别结果进行决策级融合判决可提高检测性能, 决策级融合具有多种准则<sup>[16]</sup>, 利用贝叶斯与奈曼-皮尔逊公式作为融合规则时, 均需具备概率密度的先验知识; 而一些“固定”的决策级融合规则却不需要对联合概率密度进行建模, 例如: (1) 与规则; (2) 或规则; (3) 多数票规则; (4)  $N$  中取  $k$  规则。因保留特征的鉴别能力各不相同, 应对其鉴别结果赋予不同的权重, 这里将该特征的 FDR 作为其鉴别结果的权重。为利用特征间的结构信息, 将所选择的特征分量构成特征向量进行鉴别, 并将该特征向量对应代价函数的度量值作为其权重。代价函数度量准则定义为<sup>[2]</sup>

$$J = \text{Trace}\left(\mathbf{S}_w^{-1} \mathbf{S}_b\right) \quad (6)$$

式中,  $\mathbf{S}_w$  为类内散度矩阵,  $\mathbf{S}_b$  为类间散度矩阵。则对所选择单个序列特征及其构成特征向量的鉴别结果进行加权融合得到的置信度为

$$P_d = \left[ w_0 p(x) + \sum_{k=1}^N w_k p(f_k) \right] / \sum_{k=0}^N w_k \quad (7)$$

其中,  $w_0 = J$ ,  $w_k = J_{\text{FDR}}(f_k)$  ( $k = 1, 2, \dots, N$ )。由训练数据可以确定  $P_d$  的门限  $P_T$ , 当  $P_d > P_T$  时, 将对应 ROI 序列的输出判为目标。图 1 给出了加权融合方法的流程图。

### 2.3 加权融合检测的性能分析

由式(7)可给出每个潜在目标的置信度, 由给定的门限  $P_T$  可以确定做出目标判决所需的最少分类器数目  $n$ 。下面分析采用加权融合进行联合检测的理论检测概率和虚警概率。各个特征鉴别能力的不同将导致其鉴别结果对应的检测概率和虚警概率不同, 令  $p_{d,k}$  和  $p_{f,k}$  分别为第  $k$  个特征鉴别结果对应的检测概率和虚警概率; 令  $P_D^{\text{Fusion}}$  和  $P_F^{\text{Fusion}}$  分别为融合判决对应的检测概率和虚警概率。根据二项式分布理论, 若总的分类器数目为  $N$ , 实际检测出目标的分类器数目为  $k$ , 要求检测出目标的最少分类器数目为  $n$ , 基于贝努利概率模型, 在  $N$  次检验中目标至少出现  $n$  次的概率为<sup>[17]</sup>

$$P_D^{\text{Fusion}} = \sum_{k=n}^N \left\{ \left[ \sum_{m=0}^{k-n} (-1)^m C_k^m \right] \left( \sum_{C_{k/N}} \prod_j p_{d,j} \right) \right\} \quad (8)$$

其中,  $C_k^m = \frac{k!}{m!(k-m)!}$ , 为二项式分布系数,  $\sum_{C_{k/N}} \prod_j p_{d,j}$  表示  $k$  个检测概率的乘积之和在  $N$  次检验中所占的概率, 此时融合判决对应的虚警概率为

$$P_F^{\text{Fusion}} = \sum_{k=n}^N \left\{ \left[ \sum_{m=0}^{k-n} (-1)^m C_k^m \right] \left( \sum_{C_{k/N}} \prod_j p_{f,j} \right) \right\} \quad (9)$$

其中,  $\sum_{C_{k/N}} \prod_j p_{f,j}$  为  $k$  个虚警概率的乘积之和在  $N$  次检验中所占的概率。若  $N = 2n + 1$ , 且  $p_{d,k} \geq 0.5$ ,  $p_{f,k} \leq 0.5$  ( $k = 1, 2, \dots, N$ ), 总有下式成立:

$$\begin{cases} P_D^{\text{Fusion}} \geq \min\{p_{d,1}, p_{d,2}, \dots, p_{d,N}\} \\ P_F^{\text{Fusion}} \leq \max\{p_{f,1}, p_{f,2}, \dots, p_{f,N}\} \end{cases} \quad (10)$$

若分类器的输出是不相关的, 对多个特征鉴别结果进行决策级融合总可以提高检测性能。参数  $n$  的选取对检测概率和虚警概率之间的折衷极为重要。对于地雷检测, 既要确保目标不漏检, 又要求较低的虚警概率, 这要求分类器具有极低的错误率。假设每个分类器的错误率为  $p < 0.5$ , 采用简单的多数票准则, 则最终判决结果为错误的最大概率为

$$P_{\text{err}} = \sum_{k=\lfloor (N+1)/2 \rfloor}^N C_N^k p^k (1-p)^{N-k} \quad (11)$$

其中,  $\lfloor \cdot \rfloor$  表示取整。例如, 假设选择了  $N = 11$  个特征, 对应的每个分类器的错误率均小于 0.25, 则 6 个或者 6 个以上的分类器为错误的最大概率是 0.0343, 这比单个分类器的错误率要小得多。

### 3 试验结果与分析

本文利用的实测数据由国防科技大学研制的国内首个车载前视地表穿透成像雷达——VFPIR 探测系统获取, 该系统工作频段为 P 波段, 极化方式为圆极化。某次试验获取的数据集包含 100 个地雷样本和 343 个杂波样本, 样本所对应的探测区域为 3300m<sup>2</sup>。下面利用实测数据验证序列特征的有效性, 并利用接收机工作特性 (Receiver Operating Characteristic, ROC) 曲线来说明所提方法的有效性。

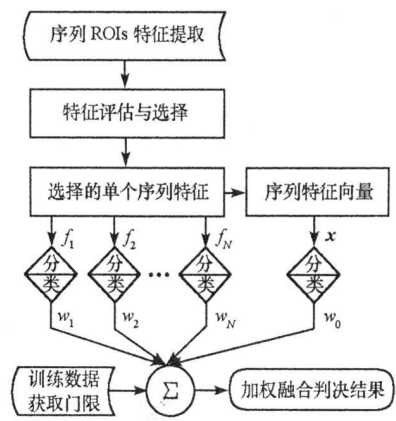


图 1 基于决策级加权融合的多特征联合检测流程图  
Fig. 1 Flow chart of multi-features joint detection based on decision-level weighting fusion

### 3.1 单帧图像特征和序列图像特征比较

图 2 给出了单帧图像和序列图像中面积覆盖比特征的比较。图中  $o$  和  $*$  分别表示地雷和自然杂波样本对应的特征。由图 2 可直观看出, 由序列图像获取的序列特征比单帧图像特征具有更好的鉴别能力, 即可更好地将目标和杂波区分开来。

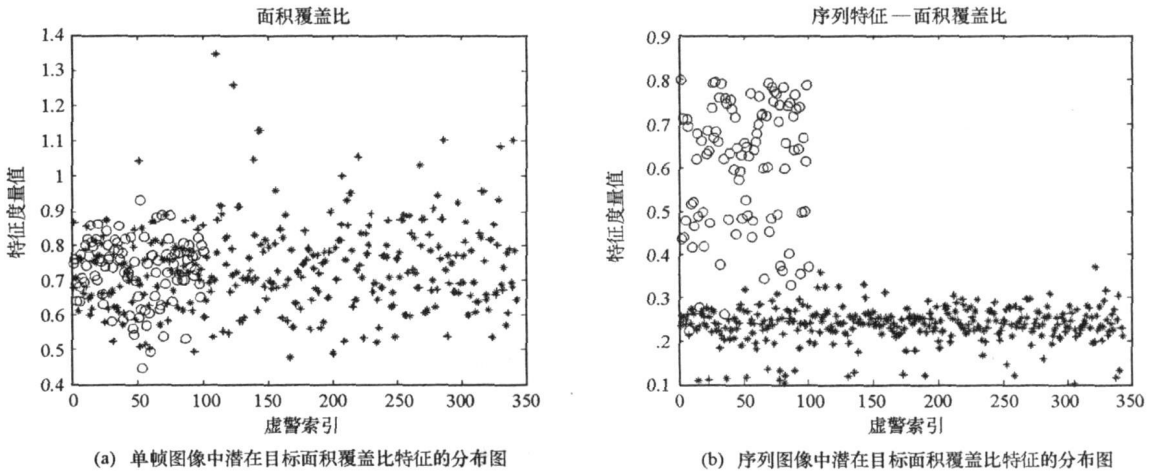


图 2 单帧图像和序列图像中潜在目标面积覆盖比特征的比较

Fig. 2 Comparisons of area coverage feature of potential targets in the single and sequence images

为定量分析单帧图像特征和序列图像特征及其各个特征分量的鉴别能力, 图 3 给出了它们各自的  $FDR$  曲线。由图 3 可知, 序列特征的  $FDR$  均大于对应的单帧图像特征, 因此序列特征的鉴别能力均优于与之对应的单帧图像特征, 且其  $FDR$  越大, 鉴别能力越强。可设定一个门限  $J_T$ , 将  $FDR$  大于门限的特征保留, 同时将保留的序列特征形成特征向量, 并计算其代价函数  $J$ , 作为特征向量的权重。




图 3 单帧图像特征和序列图像特征及其各个特征分量的  $FDR$  比较

Fig. 3 FDR comparisons of the individual feature in the single and sequence images

因单帧图像特征的可分性较差, 下面的分析仅考虑由序列图像中提取的序列特征。

### 3.2 单个序列特征的 LDA 分类结果

每次从 100 个目标样本中随机选取 70 个, 从 343 个杂波样本中随机选取 243 个作为训练样本, 剩余的 30 个目标样本和 100 个杂波样本作为测试样本。不妨假设目标和杂波均匀分布于探测区域, 则测试样本对应的等效探测区域面积为  $(30 + 100) / (100 + 343) \times 3300 \approx 968 m^2$ 。每次利用训练样本对式 (3) 对应的 LDA 分类器进行训练, 然后对测试样本进行鉴别, 利用 100 次的平均结果作为最终的检测性能。表 2 给出了序列特征中各个特征分量的平均检测概率和虚警概率。

表2 序列特征的各个特征分量的平均检测结果

Tab.2 Average detection results of the individual feature component in the sequence feature

# 特征索引	# 1	# 2	# 3	# 4	# 5	# 6	# 7	# 8	# 9	# 10	# 11
序列图 $\bar{P}_d$	0.532	0.871	0.542	0.513	0.806	0.811	0.598	0.829	0.853	0.743	0.860
像特征 $\bar{P}_f$	0.035	0.000	0.036	0.034	0.029	0.049	0.040	0.004	0.000	0.021	0.000
# 特征索引	# 12	# 13	# 14	# 15	# 16	# 17	# 18	# 19	# 20	# 21	# 22
序列图 $\bar{P}_d$	0.860	0.840	0.861	0.838	0.863	0.802	0.852	0.732	0.780	0.753	0.868
像特征 $\bar{P}_f$	0.012	0.003	0.000	0.005	0.000	0.000	0.000	0.101	0.134	0.071	0.000

注:  $\bar{P}_d$  和  $\bar{P}_f$  分别为序列图像特征对应的平均检测概率和平均虚警概率。

表2与图3的结果具有较好的一致性,即  $FDR$  大的特征具有较好的鉴别能力。若系统探测指标为检测概率大于99%,虚警率小于0.02个/ $m^2$ ,由潜在目标对应的探测区域面积( $968m^2$ ),可计算出最多允许有  $(968-30) \times 0.02 = 18.76$ (个)虚假目标,对应这里的最大虚警概率约为0.19。应尽量选择检测概率高且虚警概率低的特征,结合图3和表2,这里选择特征索引#2、#5、#6、#8、#9、#10、#11、#12、#13、#14、#15、#16、#17、#18、#21和#22对应的序列特征,并将其形成特征向量。

### 3.3 基于 ROC 曲线的性能比较

图4给出了以上选择的16个序列特征各自的ROC曲线。#16序列特征具有最好的鉴别能力,在虚警概率为0.19时,检测概率为97%,但仍无法满足上述给定的探测指标要求。因此考虑决策级融合方法,如简单的多数票融合准则和本文提出的决策级加权融合判决准则(简称本文方法)。

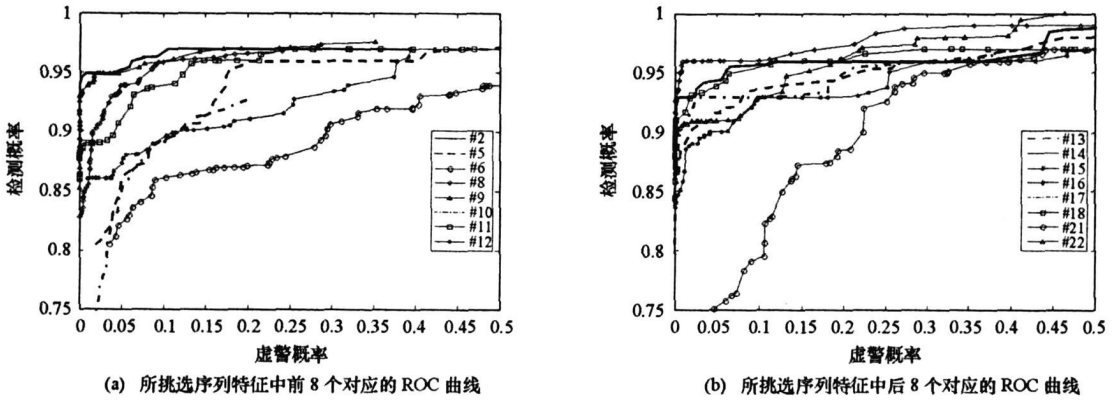


图4 单个序列特征对应的 ROC 曲线

Fig.4 ROC curves of the individual sequence features

对于挑选出的16个序列特征,它们的  $FDR$  之和约为62.5,由它们形成的特征向量对应的代价函数度量值为  $J = 5.18$ ,则17个分类器对应的权值之和为67.68。当其中9个具有较大权重的分类器给出正确分类时,它们权重之和占总权重的比约为0.68,已满足多数票准则;而此时的多数票融合准则要求至少有12个特征对应的分类器给出正确分类。图5给出了最具鉴别能力的单个序列特征、特征向量、多数票融合准则和本文方法对应ROC曲线的比较。本文方法充分利用了多个特征之间的相关性和冗余性,具有最好的检测性能,且可满足探测指标要求。理论分析和实测数据试验结果的一致性进一步验证了本文方法的有效性。




图5 4种不同方法对应 ROC 曲线的比较

Fig.5 Comparisons of ROC curves for four different methods

## 4 结束语

由 VFGPIR 的序列 ROI 中可提取大量特征,首先利用 FDR 定量评估单帧图像和序列图像特征的鉴别能力,得出了序列特征具有更好鉴别力的结论;然后提出了一种基于决策级加权融合的多特征联合检测方法,通过融合多个序列特征及其构成的特征向量的鉴别结果来提高最终的检测性能;最后比较了该方法与单个最优序列特征、特征向量及多数票融合准则对应的 ROC 曲线,进一步验证了所提方法的有效性。直接由单个特征评估选择的分量形成的特征向量是次优的,有待于对最优子集选择进行研究。

## 参考文献:

- [1] Gunatilaka A H, Baertlein B A. Feature level and Decision level Fusion of Noncoincidentally Sampled Sensors for Land Mine Detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(6): 577-589.
- [2] Sun Y, Li J. Landmine Detection Using Forward looking Ground Penetrating Radar[C]//Proc. of SPIE, 2005, 5794: 1089-1097.
- [3] Wang T, Sjahputera O, Keller J M, et al. Feature Analysis for Forward looking Landmine Detection Using GPR[C]//Proc. of SPIE, 2005, 5794: 1233-1244.
- [4] Wang T, Keller J M, Gader P D, et al. Frequency Subband Processing and Feature Analysis of Forward looking Ground penetrating Radar Signals for Land mine Detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(3): 718-729.
- [5] Sun Y, Li J. Time frequency Analysis for Plastic Landmine Detection via Forward looking Ground Penetrating Radar[J]. IEE Proc. Radar Sonar Navig., 2003, 150(4): 253-261.
- [6] Jin T, Zhou Z, Chang W, et al. Target Feature Extraction Using Time-frequency Representation in Synthetic Aperture Radar[C]//Proc. of SPIE, 2005, 6043: 371-379.
- [7] Gaunard G C, Nguyen L H. Detection of Land mines Using Ultrawideband Radar Data and Time frequency Signal Analysis[J]. IEE Proc. Radar Sonar Navig., 2004, 151(5): 307-316.
- [8] 高贵, 蒋咏梅, 张琦, 等. 基于多特征联合的高分辨率 SAR 图像机动目标快速获取[J]. 电子学报, 2006, 34(9): 1663-1667.
- [9] 李禹, 计科峰, 粟毅, 等. 一种新的高分辨率 SAR 图像目标自动鉴别方法[J]. 国防科技大学学报, 2007, 29(3): 81-84.
- [10] Novak L M, Halversen S D, Owirka G L, et al. Effects of Polarization and Resolution on SAR ATR[J]. IEEE Transactions on Aerospace and Electronic Systems, 1997, 33(1): 102-115.
- [11] Dong Y, Runkle P R, Carin L, et al. Multi aspect Detection of Surface and Shallow-buried Unexploded Ordnance via Ultrawideband Synthetic Aperture Radar[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(6): 1259-1270.
- [12] Carin L, Geng N, McClure M, et al. Wide area Detection of Land Mines and Unexploded Ordnance[M]. Institute of Physics Publishing Ltd., UK, 2002: 575-609.
- [13] Mudigonda N R, Kacelenga R, Palmer D. Detection and Classification of Land Mine Targets in Ground Penetrating Radar Images[C]//Proc. of SPIE, 2002, 4742: 390-400.
- [14] Sun Y, Li J. Adaptive Learning Approach to Landmine Detection[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(3): 973-985.
- [15] Liao Y, Nolte L W, Collins L. Optimal Multisensor Decision Fusion of Mine Detection Algorithms[C]//Proceedings of SPIE, 2003, 5089: 1252-1260.
- [16] Webb A R, 王萍, 杨培龙, 等. 统计模式识别[M]. 第二版. 北京: 电子工业出版社, 2004.
- [17] Liang H, Ni G. Analysis of Target Detection Probability in Sequence Image[C]//Proc. of SPIE Infrared Technology and Applications, 2000, 4130: 791-799.