

文章编号:1001-9014(2011)01-0074-06

# 基于模糊函数特征优化的雷达辐射源个体识别

王磊, 姬红兵, 史亚

(西安电子科技大学 电子工程学院, 陕西 西安 710071)

**摘要:**对雷达辐射源信号进行模糊函数建模是一种有效的特征提取途径.通过对无意调制的雷达辐射源信号的模糊函数分析,提出了基于模糊函数子空间特征优化的个体识别方法.首先抽取模糊函数的“近零”频偏切片作为辐射源信号的主要特征,继而设计了切片串联策略构建了互补的特征子集对,从而分别利用典型相关分析和鉴别典型相关分析实现了切片特征的融合.理论分析和对实测数据的实验结果表明,所提算法不仅克服了现有的全平面核点排序法的计算问题,而且有效地融合了模糊函数各近零切片上的互补信息,在显著提高辐射源个体识别性能的同时,进一步消除了模糊函数特征的冗余性.

**关键词:**雷达辐射源识别;模糊函数;典型相关分析;鉴别典型相关分析;特征融合

**中图分类号:**TN957.51;TN974 **文献标识码:**A

## Feature optimization of ambiguity function for radar emitter recognition

WANG Lei, JI Hong-Bing, SHI Ya

(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

**Abstract:** Ambiguity function (AF) modeling of radar signals is a powerful approach to feature extraction and recognition of radar emitters. An AF subspace based optimization framework is proposed to identify radar emitters by exploring unintentional modulation on pulse (UMOP) features. First, near-zero Doppler cuts of AF were extracted as a preliminary feature subset. Then, two kinds of cut-concatenation schemes were designed to construct two different pairs of feature vectors with complementary information respectively, which will facilitate the subsequent feature fusion via canonical correlation analysis (CCA) or discriminative canonical correlation analysis (DCCA). Theoretical analysis and experimental results show that the proposed algorithms not only alleviate the calculation problem in the existing AF based method, but also improve the recognition performance considerably, due to the successful information fusion and redundancy reduction conducted in the AF subset.

**Key words:** radar emitter recognition; ambiguity function; canonical correlation analysis; discriminative canonical correlation analysis; feature fusion

**PACS:** 84.40.Xb

## 引言

雷达辐射源个体识别是电子情报侦察、电子支援措施和威胁告警等系统要解决的关键问题,也是现代电子对抗的前提和基础<sup>[1-3]</sup>.通过传感器接收未知雷达辐射源发射的信号,分析其个体特征,可以唯一地识别辐射源个体,从而确定雷达的技术水准.要想提高雷达辐射源识别系统的识别性能和鲁棒性,必须寻找稳定且有效的辐射源个体特征.

随着现代电子战的日益激烈,雷达信号的密度、

电磁环境的复杂程度都大幅度增加,传统的识别方法逐渐失去其有效性.更重要的是,实际中接收到的雷达脉冲数目通常较少,很难实现脉冲间累积.因此目前辐射源识别的研究重点在于如何提取雷达信号的有效脉内特征<sup>[1-6]</sup>,在此基础上实现辐射源个体识别. Gillespie 和 Atlas 最先将模糊函数应用于雷达辐射源识别<sup>[4,5]</sup>,并且利用 Fisher 鉴别比准则指导全平面核点的排序和优化,在美国海军实验室的仿真雷达数据上取得了较好的识别结果.然而本文指出,由于采用全平面特征优化策略,该方法不可避免地

收稿日期:2010-01-14,修回日期:2010-11-16

基金项目:国家自然科学基金(60871074)

作者简介:王磊(1979-),男,安徽池州人,博士研究生,主要研究领域为雷达信号处理,模式识别, E-mail: leiwang@mail.xidian.edu.cn.

Received date: 2010-01-14, revised date: 2010-11-16

具有计算量大且无法应用于大规模数据的缺点;而另一方面,核点排序法本质上是一种二值化的特征选择,其优化后的模糊函数特征仍然具有一定的冗余性.

针对这些局限性,本文提出一种基于模糊函数子空间特征优化的辐射源个体识别算法.该算法首先提取模糊函数的“近零”频偏切片(包括零切片)作为中间特征集,继而将这些切片分别组合成“近端”串联子集和“远端”串联子集,或者“偶数”串联子集和“奇数”串联子集,从而利用典型相关分析以及鉴别典型相关分析实现辐射源个体特征的优化.与传统方法相比,本文算法不仅避免了全平面特征优化带来的高计算量以及“内存溢出”问题,而且在低维的嵌入子空间内有效地挖掘了辐射源的个体特征,在消除特征冗余的同时进一步提高了识别性能.

需要指出的是,本文主要针对辐射源信号无意调制特征的提取与优化,即限定在基本工作模式下,挖掘辐射源信号的脉内“指纹”特征,对型号、参数均相同的辐射源进行个体识别.而辐射源信号的(有意)调制识别或分选则不是本文的研究重点,读者可参阅文献[6].

## 1 模糊函数与核函数

信号  $x(t)$  的模糊函数可以视为其瞬时自相关函数关于时间  $t$  的 Fourier 反变换:

$$A(\tau, \nu) = \int_{-\infty}^{\infty} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{j2\pi\nu t} dt. \quad (1)$$

可见,模糊函数是时延  $\tau$  和频偏  $\nu$  的二维函数,能够度量信号及其自身经时延和频移后所得信号之间的相似性,因而通过不同“延迟”下的“匹配滤波输出”反映了信号内在的结构信息. Cohen 指出,信号的时频分布可以写成一般形式<sup>[7]</sup>:

$$P(t, f) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x\left(u + \frac{\tau}{2}\right) x^*\left(u - \frac{\tau}{2}\right) \varphi(\tau, \nu) e^{-j2\pi(t\nu + \tau f - u\nu)} du d\tau d\nu, \quad (2)$$

其中  $\varphi(\tau, \nu)$  称为核函数,它具有时、频移不变性.进一步,式(2)可以简写为:

$$P(t, f) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} A(\tau, \nu) \varphi(\tau, \nu) e^{-j2\pi(t\nu + \tau f)} d\nu d\tau. \quad (3)$$

具有这种形式的时频分布统称为 Cohen 类时频分布.改变核函数可以设计出不同的时频分布,例如核函数取 1,式(3)即退化成为 Wigner-Ville 分布.因此,核函数可视为模糊域的“滤波函数”,能够将

$A(\tau, \nu)$  中某些不需要的分量滤掉.对模糊函数的研究有助于优化基于时频分布的辐射源特征提取方法.

## 2 基于 FDR 核点排序的特征优化

Gillespie 和 Atlas 研究了模糊函数在雷达辐射源识别中的应用,提出了一种针对分类的核函数优化方法<sup>[4~5]</sup>.假设类别数为  $c$ ,第  $l$  ( $l = 1, \dots, c$ ) 类的信号数目为  $n_l$ ,  $A_{y_i^{(l)}}$  表示第  $l$  类第  $i$  个信号  $y_i^{(l)}$  的模糊函数,  $\bar{A}^{(l)}(\tau, \nu)$  表示第  $l$  类信号的平均模糊函数.该算法的核心思想是利用如下的 Fisher 鉴别比(FDR)准则进行全平面核点的排序:

$$FDR(\tau, \nu) = \frac{\sum_{l=1}^c \sum_{m=1}^c |\bar{A}^{(l)}(\tau, \nu) - \bar{A}^{(m)}(\tau, \nu)|^2}{\sum_{l=1}^c [\sigma^{(l)}(\tau, \nu)]^2}, \quad (4)$$

这里  $[\sigma^{(l)}(\tau, \nu)]^2 = \frac{1}{n_l} \sum_{i=1}^{n_l} |A_{y_i^{(l)}}(\tau, \nu)|^2 - |\bar{A}^{(l)}(\tau, \nu)|^2$ ,

表示第  $l$  类信号在模糊函数面上点  $(\tau, \nu)$  处的方差.对全平面核点进行 FDR 排序后,通过识别率反馈,寻找使得识别率最大的前  $K_{opt}$  个核点,从而实现对模糊函数平面的选择性加权.通过理论分析并结合实际应用,我们指出该方法存在以下突出的问题:

(1) 该方法需要在模糊函数全平面上进行核点排序,涉及到  $N \times L \times L$  矩阵的计算与存储( $N$  为训练样本个数,  $L$  为采样点数).实际获得的辐射源信号,  $N$  和  $L$  通常很大,会导致计算繁重甚至出现“内存溢出”问题.

(2) FDR 指导的核点优化实际上是对整个平面的模糊函数进行重新排序和位置加权的过,因此本质上是一种二值化的特征选择.从后面的实验分析可知,当模糊函数自身具有一定的规律性及连续性时,为了得到最优分类矢量,这样的特征选择不得不涵盖较多的核点,因此导致其优化后的特征仍然具有一定的冗余性.

(3) 为了通过识别率的反馈来确定最优核点,该方法采用了交叉验证.而实际应用中有类标的数据集通常规模较小且标记代价较高,交叉验证法的引入或压缩了训练集的空间,或导致了样本的重复训练,另一方面也增加了额外的特征优化时间.严格地说,该方法实际上需要训练集、反馈集以及测试集,这样的识别体系在工程应用中并不多见.

## 3 基于子空间特征优化的辐射源个体识别

### 3.1 辐射源信号的模糊函数分析

对辐射源个体识别而言,之所以能够区分型号、

参数均相同的辐射源,是由于实际中发射机自身存在相位噪声以及各类杂散输出,使得振荡器输出的信号产生了无意相位调制,从而导致在载频 $f_0$ 周围产生了边带效应,形成辐射源信号独特的“指纹”特征.由于无意调制的细微性和复杂性,一维的信号变换难以充分体现无意调制的细节特征.而模糊函数不仅具有自动的数据中心对齐效果以及对噪声的抑制作用,而且在时延和频偏的二维平面上,多角度地刻画了无意调制对发射信号载频的影响.为了简化模型推导,我们假设雷达辐射源发射的信号为单频实信号 $x(t) = u(t) \cos 2\pi f_0 t$ ,其中 $u(t) = \begin{cases} a, & t_0 \leq t \leq t_0 + T \\ 0, & \text{else} \end{cases}$ 为宽度为 $T$ 的矩形窗函数, $a$ 为大于零的常数.根据式(1),可以计算出该信号的模糊函数为:

$$A(\tau, \nu) = \frac{a^2(T-|\tau|)}{2} \cdot \cos 2\pi f_0 \tau \cdot e^{j\pi\nu(T+2t_0)} \cdot \frac{\sin[\pi\nu(T-|\tau|)]}{\pi\nu(T-|\tau|)} + \frac{a^2(T-|\tau|)}{4} \cdot e^{j\pi(\nu+2f_0)(T+2t_0)} \cdot \frac{\sin[\pi(\nu+2f_0)(T-|\tau|)]}{\pi(\nu+2f_0)(T-|\tau|)} + \frac{a^2(T-|\tau|)}{4} \cdot e^{j\pi(\nu-2f_0)(T+2t_0)} \cdot \frac{\sin[\pi(\nu-2f_0)(T-|\tau|)]}{\pi(\nu-2f_0)(T-|\tau|)} \quad (5)$$

为了方便后续的特征表示和分类,通常可取式(5)的模值构成模糊函数图.可见辐射源信号模糊函数图的主体由3个sinc函数构成,其能量主要集中在 $\nu \approx 0$ 和 $\nu \approx \pm 2f_0$ 附近.在这三个区域里,模糊函数能量主要沿时延轴方向分布,沿频偏方向则下降很快.在频偏为零处模糊函数图存在峰值,且在原点达到最大值.另一方面,由于无意调制的复杂性,沿时延轴方向的单个频偏切片难以充分表征用于分类的个性特征.因此我们考虑将频偏接近零(包括零)的少数几个模糊函数切片作为辐射源信号的主要特征集.这种特征近似不仅符合真实辐射源信号的模糊函数特性,而且大大降低了后续计算的复杂度.而舍弃高频偏 $\nu \approx \pm 2f_0$ 处的模糊函数能量则能避免载频不同对辐射源个体识别的主导作用,从而有利于挖掘无意调制造成的各辐射源信号模糊函数的细微差异.图1给出了一个实测雷达信号的波形图及其对应的模糊函数图.

得到有限个模糊函数近零切片后,便可以采用各种切片组合策略以实现基于子空间方法的特征融合与优化.根据式(5)可知,实信号的模糊函数围绕频偏为零的分界线具有上下平面的对称性,因此选择正频偏的切片即可.为了方便后续的切片描述,上述频偏均为对应于采样点数的“量化”频偏而非归一化频偏.

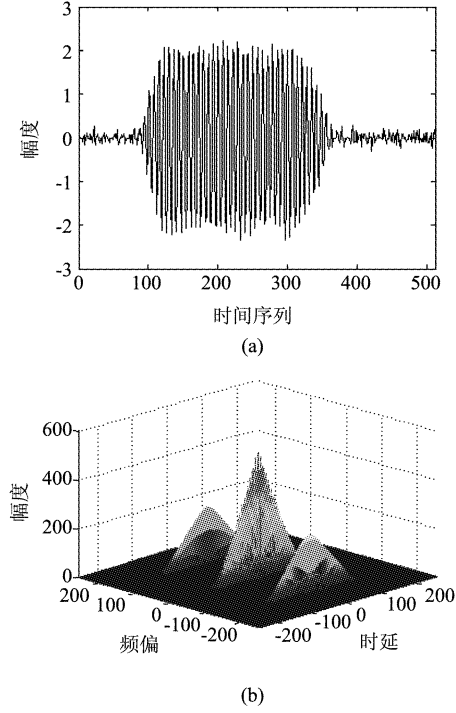


图1 (a)典型脉冲示意图 (b)对应的模糊函数图  
Fig. 1 (a) A typical signal (b) The corresponding AF

### 3.2 基于典型相关分析的切片特征融合

典型相关分析(CCA)<sup>[8,9]</sup>是一种对互补特征进行融合的子空间方法.给定 $N$ 对训练样本集 $\{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^N$ ,其中 $\mathbf{x}_i \in \mathbf{R}^p$ 和 $\mathbf{y}_i \in \mathbf{R}^q$ 是两组蕴含不同信息的特征矢量.记 $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N] \in \mathbf{R}^{p \times N}$ , $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_N] \in \mathbf{R}^{q \times N}$ ,且均已中心化,即 $E[\mathbf{X}] = E[\mathbf{Y}] = 0$ .记 $(\mathbf{x}, \mathbf{y})$ 为 $\{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^N$ 中任意一对样本,CCA的目的是分别为训练集 $\mathbf{X}$ 和 $\mathbf{Y}$ 寻找投影方向 $\mathbf{w}_x \in \mathbf{R}^p$ 与 $\mathbf{w}_y \in \mathbf{R}^q$ 使得随机变量 $x = \mathbf{w}_x^T \mathbf{x}$ 和 $y = \mathbf{w}_y^T \mathbf{y}$ 之间的相关性达到最大,即求解如下相关系数的最大值问题:

$$\rho_{cca} = \frac{\mathbf{w}_x^T \mathbf{C}_{xy} \mathbf{w}_y}{\sqrt{\mathbf{w}_x^T \mathbf{C}_{xx} \mathbf{w}_x \mathbf{w}_y^T \mathbf{C}_{yy} \mathbf{w}_y}} \quad (6)$$

其中, $\mathbf{C}_{xx} = \mathbf{X}\mathbf{X}^T \in \mathbf{R}^{p \times p}$ 与 $\mathbf{C}_{yy} = \mathbf{Y}\mathbf{Y}^T \in \mathbf{R}^{q \times q}$ 分别表示 $\mathbf{x}$ 与 $\mathbf{y}$ 的协方差矩阵, $\mathbf{C}_{xy} = \mathbf{X}\mathbf{Y}^T \in \mathbf{R}^{p \times q}$ 表示 $\mathbf{x}$ 与 $\mathbf{y}$ 之间的互协方差矩阵.式(6)中的相关系数 $\rho_{cca}$ 仅与 $\mathbf{w}_x$ 和 $\mathbf{w}_y$ 的方向有关,因此CCA优化如下目标函数:

$$\max_{\mathbf{w}_x, \mathbf{w}_y} \mathbf{w}_x^T \mathbf{C}_{xy} \mathbf{w}_y \quad s.t. \quad \mathbf{w}_x^T \mathbf{C}_{xx} \mathbf{w}_x = \mathbf{w}_y^T \mathbf{C}_{yy} \mathbf{w}_y = 1 \quad (7)$$

由拉格朗日乘子法,上述优化问题转化为如下广义特征方程问题:

$$\begin{cases} \mathbf{C}_{xy} \mathbf{C}_{yy}^{-1} \mathbf{C}_{yx} \mathbf{w}_x = \lambda^2 \mathbf{C}_{xx} \mathbf{w}_x \\ \mathbf{C}_{yx} \mathbf{C}_{xx}^{-1} \mathbf{C}_{xy} \mathbf{w}_y = \lambda^2 \mathbf{C}_{yy} \mathbf{w}_y \end{cases} \quad (8)$$

分别取前 $d$ 个最大的特征值对应的特征矢量构

成投影矩阵  $\mathbf{W}_x = [\mathbf{w}_{x1}, \dots, \mathbf{w}_{xd}] \in R^{p \times d}$  和  $\mathbf{W}_y = [\mathbf{w}_{y1}, \dots, \mathbf{w}_{yd}] \in R^{q \times d}$ , 这里  $d \leq r \leq \min(p, q)$ ,  $r = \text{rank}(C_{xy})$ .

对任意一对样本  $(\mathbf{x}, \mathbf{y})$  进行如下的特征融合:

$$\mathbf{z} = \begin{pmatrix} \mathbf{W}_x & \mathbf{0} \\ \mathbf{0} & \mathbf{W}_y \end{pmatrix}^T \begin{pmatrix} \mathbf{x} \\ \mathbf{y} \end{pmatrix}, \quad (9)$$

$\mathbf{z}$  为融合之后的特征向量, 其维数为  $2d$ . 同时, 为了克服实际中面临的高维小样本问题, 可先用 PCA 进行降维预处理, 以使得协方差矩阵非奇异.

值得注意的是, CCA 只能用于两特征集的融合. 假设共得到感兴趣的  $2h$  个近零切片  $\{v=0, +1, \dots, +(2h-1)\}$ , 从零切片出发, 我们设计如下两种策略来组合辐射源信号的模糊函数各切片特征:

(1) “近端”切片  $\{v=0, +1, \dots, +(h-1)\}$  串联构成特征集  $\mathbf{x}$ , “远端”切片  $\{v=+h, +(h+1), \dots, +(2h-1)\}$  串联构成特征集  $\mathbf{y}$ , 这样的 CCA 融合方式记为 CCA1;

(2) “偶数”切片  $\{v=0, +2, \dots, +(2h-2)\}$  串联构成特征集  $\mathbf{x}$ , “奇数”切片  $\{v=+1, +3, \dots, +(2h-1)\}$  串联构成特征集  $\mathbf{y}$ , 这样的 CCA 融合方式记为 CCA2.

### 3.3 基于鉴别典型相关分析的切片特征融合

由于 CCA 是一种无监督的方法, 它仅仅关注两样本集的相关性, 而并未利用样本的类别信息, 因此我们引入鉴别典型相关分析 (DCCA) [10], 提出了基于 DCCA 的模糊函数切片融合策略, 以期充分利用训练样本的类别信息, 寻找能够同时考虑类间可分性最大化和类内相似性最小化的鉴别性典型变量. 数学上, DCCA 求解如下相关系数的最大值问题:

$$\rho_{dcca} = \frac{\mathbf{w}_x^T \tilde{\mathbf{C}}_{xy} \mathbf{w}_y}{\sqrt{\mathbf{w}_x^T \mathbf{C}_{xx} \mathbf{w}_x \cdot \mathbf{w}_y^T \mathbf{C}_{yy} \mathbf{w}_y}}, \quad (10)$$

其中,  $\tilde{\mathbf{C}}_{xy} = \mathbf{C}_w - \gamma \mathbf{C}_b$ ,  $\mathbf{C}_w$  和  $\mathbf{C}_b$  分别表示类内和类间相关矩阵,  $\gamma$  用来权衡  $\mathbf{C}_w$  和  $\mathbf{C}_b$  之间的比重. 为了便于表示  $\mathbf{C}_w$  和  $\mathbf{C}_b$ , 训练集  $\mathbf{X}$  和  $\mathbf{Y}$  重写如下:

$$\begin{aligned} \mathbf{X} &= [\mathbf{x}_1^{(1)}, \dots, \mathbf{x}_{n_1}^{(1)}, \dots, \mathbf{x}_1^{(c)}, \dots, \mathbf{x}_{n_c}^{(c)}] \\ \mathbf{Y} &= [\mathbf{y}_1^{(1)}, \dots, \mathbf{y}_{n_1}^{(1)}, \dots, \mathbf{y}_1^{(c)}, \dots, \mathbf{y}_{n_c}^{(c)}] \end{aligned}, \quad (11)$$

其中,  $c$  为类别数,  $n_i$  表示第  $i$  类的样本数,  $\mathbf{x}_j^{(i)}$  和  $\mathbf{y}_j^{(i)}$  分别表示  $\mathbf{X}$  和  $\mathbf{Y}$  中第  $i$  类的第  $j$  个样本, 则有:

$$\mathbf{C}_w = \sum_{i=1}^c \sum_{k=1}^{n_i} \sum_{l=1}^{n_i} \mathbf{x}_k^{(i)} \mathbf{y}_l^{(i)T} = \mathbf{X} \mathbf{D} \mathbf{Y}^T, \quad (12)$$

$$\begin{aligned} \mathbf{C}_b &= \sum_{i=1}^c \sum_{\substack{j=1 \\ j \neq i}}^c \sum_{k=1}^{n_i} \sum_{l=1}^{n_j} \mathbf{x}_k^{(i)} \mathbf{y}_l^{(j)T} \\ &= \sum_{i=1}^c \sum_{j=1}^c \sum_{k=1}^{n_i} \sum_{l=1}^{n_j} \mathbf{x}_k^{(i)} \mathbf{y}_l^{(j)T} - \sum_{i=1}^c \sum_{k=1}^{n_i} \sum_{l=1}^{n_i} \mathbf{x}_k^{(i)} \mathbf{y}_l^{(i)T} \\ &= -\mathbf{X} \mathbf{D} \mathbf{Y}^T, \end{aligned} \quad (13)$$

其中, 矩阵  $\mathbf{D}$  称为鉴别矩阵, 定义为:

$$\mathbf{D} = \begin{bmatrix} \mathbf{1}_{n_1 \times n_1} & & \\ & \ddots & \\ & & \mathbf{1}_{n_c \times n_c} \end{bmatrix} \in R^{N \times N}. \quad (14)$$

因此,  $\tilde{\mathbf{C}}_{xy} = (1 + \gamma) \mathbf{X} \mathbf{D} \mathbf{Y}^T$ . 对于式 (10) 的优化问题,  $\gamma$  的影响可以忽略. 令  $\hat{\mathbf{C}}_{xy} = \mathbf{X} \mathbf{D} \mathbf{Y}^T$ , 则 DCCA 优化如下目标函数:

$$\max_{\mathbf{w}_x, \mathbf{w}_y} \mathbf{w}_x^T \hat{\mathbf{C}}_{xy} \mathbf{w}_y \quad s. t. \quad \mathbf{w}_x^T \mathbf{C}_{xx} \mathbf{w}_x = \mathbf{w}_y^T \mathbf{C}_{yy} \mathbf{w}_y = 1. \quad (15)$$

由式 (14) 知  $\text{rank}(\mathbf{D}) = c$ . 设  $r = \text{rank}(\hat{\mathbf{C}}_{xy})$ , 则  $r \leq \min(p, q)$  且  $r \leq c$ . DCCA 的求解方法同 CCA. 与上节基于 CCA 的切片融合类似, 根据不同的切片组合策略, 分别得到 DCCA1 和 DCCA2 两种融合方式.

对于训练集和测试集, 利用 CCA 或 DCCA 得到各自优化特征后, 即可采用常规分类器进行分类.

## 4 实验结果与分析

利用实测的雷达辐射源信号来验证所提算法的有效性. 该数据包含 30 个辐射源个体, 每个个体有 100 个脉冲信号, 数据长度为 511 点; 所有脉冲的载频和脉宽参数基本一致, 数字接收机的采样率为 500MHz. 对于本文方法, 在得到各辐射源信号的 AF 模值后, 抽取 0 至 +9 共 10 个“近零”切片作为中间特征集, 切片组合策略如前所述.

实验一: 该实验比较基于 CCA 和 DCCA 的切片特征融合方法与单个切片法、频谱法、功率谱法以及时域包络法在辐射源识别中的性能. 分别随机选取每类样本的 20%、40%、60% 和 80% 作为训练集, 剩余样本构成测试集. 分类时分别采用最近邻分类器 (NN) 和支持向量机分类器 (SVM), 实验结果由 50 次平均得到. 考虑到切片串联组合形成的特征子集高达 2555 维, 首先通过 PCA 将每个特征子集的维数降为 100 维 (保留了约 99.79% 的能量), 继而进行基于 CCA 和 DCCA 的特征优化. CCA 取所有的 100 对典型变量, DCCA 取所有的 30 对典型变量. 各种方法的识别结果如表 1 所示, 其中最优和次优的结果加粗表示.

表 1 对实测雷达辐射源数据的分类正确率 (%) 比较

Table 1 Comparison of classification accuracy (%) for real radar data

	20% 训练		40% 训练		60% 训练		80% 训练	
	NN	SVM	NN	SVM	NN	SVM	NN	SVM
$v=0$	46.33	66.73	53.35	76.08	57.24	80.52	59.92	83.15
$v=+1$	62.84	77.66	68.41	84.27	71.25	87.34	73.38	89.07
$v=+2$	74.99	80.35	78.52	84.78	80.14	87.23	81.11	88.41
$v=+3$	79.22	84.82	81.94	87.62	83.79	89.28	84.85	90.58
$v=+4$	79.89	86.86	83.63	89.68	85.48	91.51	86.46	92.06
$v=+5$	77.28	85.10	80.92	87.79	82.80	89.12	84.19	89.94
$v=+6$	72.03	81.84	75.66	85.09	77.74	86.68	78.46	87.34
$v=+7$	67.62	77.33	70.90	81.31	72.65	83.30	73.68	84.17
$v=+8$	56.67	69.75	60.97	74.38	63.39	76.40	64.33	77.56
$v=+9$	41.04	58.30	45.33	64.76	47.32	67.04	48.55	69.25
CCA1	82.93	92.65	86.83	95.00	88.96	96.03	89.97	96.29
CCA2	85.58	93.56	89.33	95.54	91.18	96.57	92.54	96.81
DCCA1	93.70	<b>94.82</b>	95.43	<b>96.30</b>	96.17	<b>96.98</b>	96.45	<b>97.03</b>
DCCA2	94.22	<b>94.90</b>	95.61	<b>96.31</b>	96.34	<b>96.81</b>	96.69	<b>97.01</b>
频谱	74.45	87.59	78.56	90.05	80.33	91.39	81.67	91.98
功率谱	56.24	77.66	61.65	84.07	64.42	86.90	66.45	88.22
包络	35.64	43.51	39.47	48.39	41.75	50.88	43.36	52.36

由该实验结果,我们可以得到以下结论:

(1) 作为无意调制最直接的体现,频谱特征具有较稳定的辐射源个体识别性能,功率谱次之,而时域包络特征已经失效,识别效果很差.

(2) 模糊函数各个切片特征的个体表征能力不尽相同,这进一步证明了各个切片包含信息的差异性和互补性.其中,+4 频偏切片具有最好的识别结果,且与频谱特征的识别能力相当.但一方面,对于不同的数据集,最优切片的位置并不相同,实际中需要经验地选取;而另一方面,和频谱特征一样,这种一维的信息表征仍具有一定的不完备性.

(3) 基于 CCA 和 DCCA 的融合方法不仅避免了切片寻优的过程,并且能够兼顾到各个切片所“贡献”的不同信息.它们通过切片融合的方式实现了模糊函数近零局部平面内的互补信息最大化,具有明显高于频谱法或最优切片法的识别性能.尤其是 DCCA 方法,由于加入了样本的类别信息,因此更大程度地挖掘了辐射源个体之间的可分辨特征.

(4) 从分类器的角度来看,SVM 分类器普遍优于 NN 分类器,但是可以看到,在 DCCA 特征融合之后,NN 与 SVM 的分类结果相当,表明 DCCA 优化后的特征非常紧凑,即使采用最简单的 NN 分类器也能达到满意的识别效果.

(5) 两种切片组合策略没有显著的优劣之分,实际应用中选取任意一种组合方式即可.

实验二:该实验进一步考察本文方法的特征优




图 2 FDR 准则下的核点选择  
Fig. 2 Kernel point selection via FDR criterion




图 3 本文方法识别结果随特征维数的变化趋势  
Fig. 3 Recognition accuracy versus the number of features for the proposed methods

化性能.为了能同时比较基于 FDR 的全平面优化法<sup>[4-5]</sup>,这里只选取每类样本的 20% 和 40% 作训练集,并且将 AF 平面沿时延轴和频偏轴下采样为  $257 \times 257$  大小.同时为了公平比较,本文方法中的各切片也下采样为 257 维.实验使用 SVM 分类器,各方法的最优识别率及其对应维数如表 2 所示.特别地,对于 FDR 核点排序法,我们通过 5 重交叉验证来选取最优的核点数目,其分类器反馈的识别率随核点数目的变化趋势如图 2 所示.图 3 则给出 CCA1 和 DCCA1 的最终识别结果与特征维数(所选典型变量的个数)之间的关系.

表 2 FDR 方法与本文方法优化性能对比  
Table 2 Comparison of FDR and the proposed methods

	20% 训练		40% 训练	
	识别率 (%)	维数	识别率 (%)	维数
FDR <sup>[4,5]</sup>	93.00	2620	95.72	3200
CCA1	92.79	196	95.44	186
CCA2	92.63	198	95.17	194
DCCA1	<b>95.54</b>	44	<b>96.39</b>	50
DCCA2	95.29	42	96.11	54

可以看到,作为时延-频偏二维信息的优化方法,基于 FDR 准则的模糊函数全平面优化法的性能要显著高于信号的一维变换法(如频谱法)。但是 FDR 方法需要选取较多核点,在上述两种训练集下,只有当核点数目接近 3000 点时,其识别性能才会逐渐趋于稳定。这意味着基于 FDR 准则优化后的特征维数过高,会给后续的分类带来很大的运算负担,难以满足工程应用的实时性要求。这也进一步印证了前文分析,即除了全平面优化的计算瓶颈外,采用二值化特征选择策略的 FDR 方法会导致两个新问题:1)最优核点数过高且依赖于数据,优化后的特征仍具有一定的冗余性;2)需要额外的反馈集和费时的交叉验证来确定最优核点数,增加了特征优化的代价。

基于 CCA 的切片特征融合法与 FDR 全平面核点排序法的识别率相当,但是要注意到 CCA 本身是一种无监督的特征融合方法,且较之 FDR 法,其优化后的最优分类特征的特征维数要显著降低。这一方面说明了提取模糊函数近零区域信息要比采用全平面信息更有优势;另一方面表明,融合了各近零切片间互补信息的典型相关分析有效地消除了模糊函数的冗余性。更进一步,由于引入了类别信息,DCCA 不仅压缩了辐射源个体的共性特征,而且放大了互相区别的个性差异,在更低维的嵌入子空间内达到了最优的识别性能。在实际中,我们可以固定选取等于类别数的  $c$  对典型变量作为 DCCA 融合后的特征,在保证实时性的同时还能获得满意的识别结果。

## 5 结语

雷达辐射源个体识别是当前电子对抗中的难题之一,要求能够区分型号、参数均相同的不同辐射源个体。为此,本文提出了一种基于模糊函数子空间优化的辐射源信号特征提取与个体识别框架,其优势在于:1)采用模糊函数的近零频偏切片集合而不是全平面作为初步特征集,既保留了模糊函数的二维有用信息,又解决了传统方法的计算和数据存储问题;2)提出了切片融合的概念,设计了近端串 VS 远端串、偶数串 VS 奇数串这两种切片组合策略,从而

构建了互补的特征子集对,实现了模糊函数自身特征的有效融合;3)提出了基于 CCA 和 DCCA 的模糊函数特征优化方法,在保持较高识别性能的同时还显著降低了特征维数,进一步消除了模糊函数的冗余性并提高了分类效率,有利于工程应用。值得注意的是,典型相关分析主要针对两组特征集的融合,因此利用 Multiset CCA<sup>[11]</sup>实现模糊函数各切片特征的直接融合将是我们的下一阶段的研究重点。

## REFERENCES

- [1] LI De-zhi, ZHU Li, WANG Qian. Study on Signature of Radar Countermeasures Target [J]. *Ship Electronic Engineering* (李德智, 祝利, 王倩. 雷达对抗目标信号特征研究. *舰船电子工程*), 2010, **30**(4): 28—32.
- [2] HAN Chun-liang, ZHANG Xin-ru, CHEN Yue-long. A Novel Radar Radiation Source Recognition Method on the Sea-Battlefield [J]. *Electronic Warfare* (韩春亮, 张新如, 陈悦龙. 一种新的海战场雷达辐射源识别方法. *电子对抗*), 2009, **124**: 12—16.
- [3] LIU Qing-yun, LU Fei-fei, and ZHU Wei-qiang, *et al.* Feasibility analysis of emitter identification based on emitter fine features [J]. *Aerospace Electronic Warfare* (刘庆云, 陆飞飞, 朱伟强, 等. 辐射源细微特征用于个体识别的可行性分析. *航天电子对抗*), 2008, **24**(2): 40—42.
- [4] Gillespie B W, Atlas L E. Optimization of Time and Frequency Resolution for Radar Transmitter Identification [C]. ICASSP 1999: 1341—1344.
- [5] Gillespie B W, Atlas L E. Optimizing Time-Frequency Kernels for Classification [J]. *IEEE Transactions on Signal Processing*, 2001, **49**(3): 485—496.
- [6] ZHU Ming, JIN Wei-Dong, PU Yun-Wei, *et al.* Feature Extraction of Radar Emitter Signals Based on Gaussian Chirplet Atoms [J]. *Journal of Infrared and Millimeter Waves* (朱明, 金炜东, 普运伟, 等. 基于 Chirplet 原子的雷达辐射源信号特征提取. *红外与毫米波学报*), 2007, **26**(4): 302—306.
- [7] Cohen L. Time-frequency distributions—a review [C]. Proc. IEEE, 1989, **77**(7): 941—981.
- [8] Hotelling H. Relations between two sets of variates [J]. *Biometrika*, 1936, **28**: 312—377.
- [9] Sun Q S, Zeng S G, Liu Y, *et al.* A new method of feature fusion and its application in image recognition [J]. *Pattern Recognition*, 2005, **38**(12): 2437—2448.
- [10] Sun T K, Chen S C, Jin Z, *et al.* Kernelized discriminative canonical correlation analysis [C]. ICWAPR 2007: 1283—1287.
- [11] Via J, Santamaria I, Perez J. A learning algorithm for adaptive canonical correlation analysis of several data sets [J]. *Neural Networks*, 2007, **20**(1): 139—152.

(上接 14 页)

- [11] Richardson A J, Wiegand C L. Distinguishing vegetation from soil background information [J]. *Photogramm. Eng. Remote Sens*, 1977, **43**(12): 1541—1552.
- [12] Ghulam A, Qin Q, Teyip T, *et al.* Modified perpendicular

drought index (MPDI): a real-time drought monitoring drought [J]. *ISPRS-J. Photogramm. Remote Sens*, 2007, **62**: 150—164.