

## 基于GSVD的核不相关判别子空间与雷达目标识别

刘华林<sup>①②</sup> 杨万麟<sup>①</sup>

<sup>①</sup>(电子科技大学电子工程学院 成都 610054)

<sup>②</sup>(中国兵器装备集团火控技术中心 成都 611731)

**摘要:** 该文提出了一种基于广义奇异值分解的核不相关判别子空间算法,并将其用于高分辨距离像雷达目标识别。新算法结合广义奇异值分解与核方法的优点,有效地解决了传统方法面临的矩阵奇异问题,同时进一步改善了目标的类可分性。其次,依据 Fisher 准则导出了距离像总散度矩阵零空间中不含有有用判别信息的结论。利用这一结论,可以在求解核不相关最优判别矢量之前对各散度矩阵进行预降维,以减小后续运算的计算复杂度。对3类飞机目标实测数据的识别结果表明了所提方法的有效性。

**关键词:** 雷达目标识别; 高分辨距离像; 核不相关判别子空间; 广义奇异值分解

中图分类号: TN957.54

文献标识码: A

文章编号: 1009-5896(2009)05-1095-04

## Radar Target Recognition Based on Kernel Uncorrelated Discriminant Subspace of GSVD

Liu Hua-lin<sup>①②</sup> Yang Wan-lin<sup>①</sup>

<sup>①</sup>(College of Electronic Engineering, UEST of China, Chengdu 610054, China)

<sup>②</sup>(Fire Control Technology Center of China South Industry Group Co., Chengdu 611731, China)

**Abstract:** A Kernel Uncorrelated Discriminant Subspace (KUDS) method based on Generalized Singular Value Decomposition (GSVD) for radar target recognition is proposed. The new method combines with the advantage of GSVD and kernel trick, which can effectively overcome the limitation of traditional linear methods in solving singular problem, but also improve the class separability further. In addition, a conclusion from Fisher's criterion that there exists no useful discriminative information in the null space of the range profile population scatter matrix is derived, which can be used to reduce the dimensionality of original scatter matrices as well as the computation complexity of the following operation of solving kernel optimal discriminant vectors. Experimental results based on three measured airplanes data confirm the effectiveness of the proposed method.

**Key words:** Radar target recognition; High Resolution Range Profile (HRRP); Kernel Uncorrelated Discriminant Subspace (KUDS); Generalized Singular Value Decomposition (GSVD)

### 1 引言

雷达目标识别是指从接收到的目标散射回波中提取目标的稳定特征和相关信息,对目标的类别、属性等作出判决。研究表明,高分辨距离像(HRRP)含有目标精细的几何结构信息,相对于二维或三维成像具有易于获取和处理的特点,对实现雷达目标识别具有十分重要的意义<sup>[1-4]</sup>。但HRRP敏感于目标姿态角的变化,常常给目标识别带来困难。因此,要解决好雷达HRRP目标识别的问题,如何提取稳健、有效的特征非常关键。

子空间法是一种经典的特征提取方法,在包括雷达HRRP目标识别等应用中都获得了良好的效果<sup>[2-4]</sup>。在模式识别理论中,为减少特征子空间的冗余信息,一般都希望所

提取的特征之间统计相关性越小越好,最好是不相关的。Jin等提出了统计不相关最优判别矢量集的概念,并给出了线性求解的方法<sup>[5,6]</sup>(即不相关判别分析, Uncorrelated Discriminant Analysis, UDA)。随后, Liang等基于核机器学习理论对UDA作了非线性推广,提出了核不相关判别分析<sup>[7]</sup>(KUDA)方法。实验结果表明, KUDA不仅有效地改善了目标的类可分性,同时提高了识别的稳健性。然而,它与UDA一样,求解 $L$ 个最优判别矢量必需计算 $L$ 个广义特征方程,显然,目标类别数较多时计算量也将会比较可观。此外,两者还可能面临奇异性的问题。

本文针对雷达HRRP目标识别的特点,首先依据Fisher准则导出了HRRP总散度矩阵的零空间中不含有有用判别信息的结论,然后以此为基础提出了一种基于广义奇异值分解(GSVD)的核不相关判别子空间算法(KUDS),仿真实验验证了算法的性能。

2008-04-07 收到, 2008-12-08 改回

国家自然科学基金(60372022)和新世纪优秀人才支持计划(NCET-05-0806)资助课题

## 2 核不相关辨别子空间特征提取算法

### 2.1 算法推导

设  $\{\mathbf{X} | \mathbf{x}_i, i = 1, \dots, N\} \in \mathcal{R}^{d \times N}$  为  $N$  幅  $d$  维 HRRP 组成的训练集,  $g$  为目标类别数,  $N_l$  为第  $l$  类目标的样本数, 满足  $N = N_1 + \dots + N_g$ . 先给定一非线性映射  $\Phi$ , 将  $\mathcal{R}^{d \times N}$  映射到高维特征空间  $F$ :

$$\Phi: \mathcal{R}^{d \times N} \rightarrow F, \mathbf{x} \rightarrow \Phi(\mathbf{x}) \quad (1)$$

定义特征空间  $F$  中的 Fisher 准则函数如下:

$$J_1(\mathbf{w}) = \arg \max_{\mathbf{w}} \frac{\mathbf{w}^T \mathbf{S}_b^{\Phi} \mathbf{w}}{\mathbf{w}^T \mathbf{S}_w^{\Phi} \mathbf{w}} \quad (2)$$

其中  $\mathbf{S}_b^{\Phi}$ ,  $\mathbf{S}_w^{\Phi}$  分别表示类间和类内散度矩阵, 另有总散度矩阵  $\mathbf{S}_t^{\Phi}$ , 满足  $\mathbf{S}_t^{\Phi} = \mathbf{S}_b^{\Phi} + \mathbf{S}_w^{\Phi}$ . 在数学意义上, 式(2)定义的最优化问题等效于广义特征方程  $\mathbf{S}_b^{\Phi} \mathbf{w} = \lambda \mathbf{S}_w^{\Phi} \mathbf{w}$ , 其每一个特征矢量均由  $F$  空间中所有的样本张成, 即:

$$\mathbf{w} = \sum_{i=1}^N \alpha_i \Phi(\mathbf{x}_i) = \mathbf{Q} \boldsymbol{\alpha} \quad (3)$$

其中  $\mathbf{Q} = (\Phi(\mathbf{x}_1), \dots, \Phi(\mathbf{x}_N))$ , 系数矢量  $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_N)^T$ .

选定核函数  $k(\mathbf{x}, \mathbf{y})$ , 计算核对称矩阵  $\mathbf{K} = (\mathbf{K}_{ij})_{i,j=1,\dots,N}$ , 其中  $\mathbf{K}_{ij} = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle = k(\mathbf{x}_i, \mathbf{x}_j)$  ( $\langle \cdot \rangle$  表示内积运算). 将式(3)代入式(2), 则 Fisher 最优准则转化为

$$J_2(\boldsymbol{\alpha}) = \arg \max_{\boldsymbol{\alpha}} \frac{\boldsymbol{\alpha}^T \mathbf{S}_b \boldsymbol{\alpha}}{\boldsymbol{\alpha}^T \mathbf{S}_w \boldsymbol{\alpha}} \quad (4)$$

相应地, 各散度矩阵分别变为

$$\mathbf{S}_b = \mathbf{H}_b \mathbf{H}_b^T, \mathbf{S}_w = \mathbf{H}_w \mathbf{H}_w^T, \mathbf{S}_t = \mathbf{H}_t \mathbf{H}_t^T \quad (5)$$

其中  $\mathbf{H}_b = (\mathbf{B}_{ij})_{i=1,\dots,N}$ ,  $\mathbf{H}_w = (\mathbf{W}_{ij})_{i,j=1,\dots,N}$ ,  $\mathbf{H}_t = (\mathbf{T}_{ij})_{i,j=1,\dots,N}$ , 且:

$$\mathbf{B}_{ij} = \sqrt{N_j} \left( \frac{1}{N_j} \sum_{p=1}^{N_j} k(\mathbf{x}_i, \mathbf{x}_p) - \frac{1}{N} \sum_{q=1}^N k(\mathbf{x}_i, \mathbf{x}_q) \right) \quad (6)$$

$$\mathbf{W}_{ij} = k(\mathbf{x}_i, \mathbf{x}_j) - \frac{1}{N_l} \sum_{q=1}^{N_l} k(\mathbf{x}_i, \mathbf{x}_q) \quad (7)$$

$$\mathbf{T}_{ij} = k(\mathbf{x}_i, \mathbf{x}_j) - \frac{1}{N} \sum_{q=1}^N k(\mathbf{x}_i, \mathbf{x}_q) \quad (8)$$

为求解核不相关最优辨别矢量, KUDS 在 Fisher 准则中引入了与 UDA 相同的正交条件, 即  $\boldsymbol{\alpha}_i^T \mathbf{S}_t \boldsymbol{\alpha}_j = \begin{cases} 0, & i \neq j \\ 1, & i = j \end{cases}$ ,

从而式(4)更新为

$$J_3(\boldsymbol{\alpha}) = \arg \max_{\boldsymbol{\alpha}} \frac{\boldsymbol{\alpha}^T \mathbf{S}_b \boldsymbol{\alpha}}{\boldsymbol{\alpha}^T \mathbf{S}_t \boldsymbol{\alpha}} \quad (9)$$

鉴于总散度矩阵  $\mathbf{S}_t$  在实际中可能出现奇异的问题, 这里先引入定理 1.

**定理 1**  $\mathbf{S}_t$  奇异时, 其零空间中不含有有用辨别信息.

**证明** 定义  $\mathbf{S}_t(0) = \{\boldsymbol{\xi} | \mathbf{S}_t \boldsymbol{\xi} = 0\}$  表示  $\mathbf{S}_t$  的零空间. 若用  $\Xi$  代替  $\mathbf{S}_t(0)$ , 则有:

$$\begin{aligned} & \Xi^T \mathbf{S}_t \Xi = 0 \\ \Leftrightarrow & \Xi^T (\mathbf{S}_b + \mathbf{S}_w) \Xi = 0 \\ \Leftrightarrow & \Xi^T \mathbf{S}_b \Xi + \Xi^T \mathbf{S}_w \Xi = 0 \\ \Leftrightarrow & \Xi^T \mathbf{S}_b \Xi = 0 \cap \Xi^T \mathbf{S}_w \Xi = 0 \end{aligned} \quad (10)$$

式(10)表明, 当  $\mathbf{S}_b$  和  $\mathbf{S}_w$  投影于  $\mathbf{S}_t$  的零空间时, 类间和类内散度将同时为零, 依据 Fisher 准则, 可知  $\mathbf{S}_t(0)$  中不含有有用的辨别信息. 这也就是说, 若将  $\mathbf{S}_b$  和  $\mathbf{S}_w$  投影于  $\mathbf{S}_t$  的非零空间, 可以在不损失有用辨别信息的前提下降低后续运算的处理维数.

设  $\mathbf{S}_t$  的非零空间  $\mathbf{S}_t^+(0)$  为  $h = \text{rank}(\mathbf{S}_t)$  个非零特征值对应的特征矢量组成, 记为  $\mathbf{E} = [\mathbf{e}_1, \dots, \mathbf{e}_h]$ , 将  $\mathbf{S}_b$ ,  $\mathbf{S}_w$  投影于  $\mathbf{S}_t^+(0)$  可得:

$$\tilde{\mathbf{S}}_b = \mathbf{E}^T \mathbf{S}_b \mathbf{E} = \tilde{\mathbf{H}}_b \tilde{\mathbf{H}}_b^T \quad (11)$$

$$\tilde{\mathbf{S}}_w = \mathbf{E}^T \mathbf{S}_w \mathbf{E} = \tilde{\mathbf{H}}_w \tilde{\mathbf{H}}_w^T \quad (12)$$

其中  $\tilde{\mathbf{H}}_b = \mathbf{E}^T \mathbf{H}_b$ ,  $\tilde{\mathbf{H}}_w = \mathbf{E}^T \mathbf{H}_w$ .

依据上面两式, 式(9)等效的广义特征方程可转化为  $\tilde{\mathbf{S}}_b \boldsymbol{\alpha} = \lambda \tilde{\mathbf{S}}_w \boldsymbol{\alpha}$ . 但由于  $\tilde{\mathbf{S}}_w$  在小样本情况下往往奇异, 用传统的求逆方式无法求解. 因此, 这里引入伪逆, 并用广义奇异值分解 (GSVD) 来计算.

**定理 2** 广义奇异值分解<sup>[8]</sup>: 假定矩阵  $\mathbf{A} \in \mathcal{R}^{m \times n}$ ,  $\mathbf{B} \in \mathcal{R}^{p \times n}$ , 对于分块矩阵:

$$\mathbf{H} = \begin{bmatrix} \mathbf{A} \\ \mathbf{B} \end{bmatrix}, \quad t = \text{rank}(\mathbf{H})$$

存在正交矩阵  $\mathbf{U} \in \mathcal{R}^{m \times m}$ ,  $\mathbf{V} \in \mathcal{R}^{p \times p}$ ,  $\mathbf{W} \in \mathcal{R}^{t \times t}$ ,  $\mathbf{Q} \in \mathcal{R}^{m \times n}$ , 使得

$$\mathbf{U}^T \mathbf{A} \mathbf{Q} = \Sigma_A \begin{bmatrix} \mathbf{W}^T \mathbf{R}, & \mathbf{0} \\ \mathbf{0} & \mathbf{0}_{n-t} \end{bmatrix}, \quad \mathbf{V}^T \mathbf{B} \mathbf{Q} = \Sigma_B \begin{bmatrix} \mathbf{W}^T \mathbf{R}, & \mathbf{0} \\ \mathbf{0} & \mathbf{0}_{n-t} \end{bmatrix}$$

其中

$$\Sigma_A = \begin{bmatrix} \mathbf{I}_A & & \\ & \mathbf{D}_A & \\ & & \mathbf{0}_A \end{bmatrix} \in \mathcal{R}^{m \times t}, \quad \Sigma_B = \begin{bmatrix} \mathbf{I}_B & & \\ & \mathbf{D}_B & \\ & & \mathbf{0}_B \end{bmatrix} \in \mathcal{R}^{p \times t}$$

且  $\mathbf{R} \in \mathcal{R}^{t \times t}$  非奇异, 其奇异值等于矩阵  $\mathbf{H}$  的非零奇异值. 矩阵  $\mathbf{I}_A$  为  $r \times r$  的单位矩阵,  $\mathbf{I}_B$  为  $(t-r-s) \times (t-r-s)$  的单位矩阵, 其中  $r$  和  $s$  的值与所给数据有关,  $r = \text{rank}(\mathbf{H}) - \text{rank}(\mathbf{B})$ ,  $s = \text{rank}(\mathbf{A}) + \text{rank}(\mathbf{B}) - \text{rank}(\mathbf{H})$ ;  $\mathbf{0}_A$  和  $\mathbf{0}_B$  分别是  $(m-r-s) \times (t-r-s)$  和  $(p-t+r) \times r$  的零矩阵(但这两个零矩阵也有可能不存在, 即无任何行或任何列);  $\mathbf{D}_A = \text{diag}(\alpha_{r+1}, \alpha_{r+2}, \dots, \alpha_{r+s})$ ,  $\mathbf{D}_B = \text{diag}(\beta_{r+1}, \beta_{r+2}, \dots, \beta_{r+s})$ , 满足  $1 > \alpha_{r+1} \geq \alpha_{r+2} \geq \dots \geq \alpha_{r+s} > 0$ ,  $1 > \beta_{r+1} \geq \beta_{r+2} \geq \dots \geq \beta_{r+s} > 0$  以及  $\alpha_i^2 + \beta_i^2 = 1$ ,  $i = r+1, r+2, \dots, r+s$ .

依据定理 2, 容易导出如下引理.

**引理 1** 定义矩阵:

$$\mathbf{Z} = \mathbf{Q} \begin{bmatrix} \mathbf{R}^{-1} \mathbf{W} & \mathbf{0} \\ \mathbf{0} & \mathbf{I} \end{bmatrix}$$

易知, 有下述性质成立:

$$(1) \mathbf{U}^T \mathbf{A} \mathbf{Z} = [\Sigma_A, \mathbf{0}], \quad \mathbf{V}^T \mathbf{B} \mathbf{Z} = [\Sigma_B, \mathbf{0}];$$

$$(2) \mathbf{Z}^T \mathbf{A}^T \mathbf{A} \mathbf{Z} = \begin{bmatrix} \Sigma_A^T \Sigma_A & \mathbf{0} \\ \mathbf{0} & \mathbf{I} \end{bmatrix} = \Lambda_A;$$

$$(3) \mathbf{Z}^T \mathbf{B}^T \mathbf{B} \mathbf{Z} = \begin{bmatrix} \Sigma_B^T \Sigma_B & \mathbf{0} \\ \mathbf{0} & \mathbf{I} \end{bmatrix} = \Lambda_B;$$

$$(4) \mathbf{Z}^T \mathbf{A}^T \mathbf{A} \mathbf{Z} + \mathbf{Z}^T \mathbf{B}^T \mathbf{B} \mathbf{Z} = \begin{bmatrix} \mathbf{I}_t & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}.$$

定理2和引理1的结论说明,由分块矩阵  $\mathbf{H} = \begin{bmatrix} \mathbf{A} \\ \mathbf{B} \end{bmatrix}$  的广义奇异值分解结果,可以构建一个新的矩阵  $\mathbf{Z} = \mathbf{Q} \begin{bmatrix} \mathbf{R}^{-1} \mathbf{W} & \mathbf{0} \\ \mathbf{0} & \mathbf{I} \end{bmatrix}$  实现对矩阵  $\mathbf{A}^T \mathbf{A}$ ,  $\mathbf{B}^T \mathbf{B}$  和  $\mathbf{A}^T \mathbf{A} + \mathbf{B}^T \mathbf{B}$  的瞬时对角化。KUDS 算法利用了上述结论,其基本实现思路是:

首先结合之前的推导建立分块矩阵  $\tilde{\mathbf{H}} = \begin{bmatrix} \tilde{\mathbf{H}}_b^T \\ \tilde{\mathbf{H}}_w^T \end{bmatrix}$ , 并对其进行

GSVD 运算,然后按引理1求解类似的矩阵  $\mathbf{Z}$ , 进而获得 KUDS 的一组统计不相关最优辨别矢量。

## 2.2 算法描述

结合2.1节的推导,及Howland和Park提出的一种GSVD简便计算方法<sup>[8]</sup>,下面给出KUDS算法的具体描述:

输入  $g$ 类目标的HRRP训练样本集  $\mathbf{X} \in \mathcal{R}^{d \times N}$ , 并选定核函数  $k(\mathbf{x}, \mathbf{y})$ 。

(1)计算散度矩阵  $\mathbf{S}_b$ ,  $\mathbf{S}_w$  及相应的分解矩阵  $\mathbf{H}_b \in \mathcal{R}^{N \times g}$  和  $\mathbf{H}_w \in \mathcal{R}^{N \times N}$ , 参见式(6)和式(7);

(2)计算  $h = \text{rank}(\mathbf{S}_t)$ , 依据定理1, 获得总散度矩阵的非零子空间  $\mathbf{E} = [\mathbf{e}_1, \dots, \mathbf{e}_h]$ , 并将  $\mathbf{S}_b$  和  $\mathbf{S}_w$  分别投影于其中, 参见式(11)和式(12);

(3)建立矩阵  $\tilde{\mathbf{H}} = \begin{bmatrix} \tilde{\mathbf{H}}_b^T \\ \tilde{\mathbf{H}}_w^T \end{bmatrix} \in \mathcal{R}^{(g+N) \times h}$ , 并进行奇异值分解

$$\tilde{\mathbf{H}} = \mathbf{P} \begin{bmatrix} \Sigma & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \mathbf{Q}^T;$$

(4)令  $t = \text{rank}(\tilde{\mathbf{H}})$ , 取  $\mathbf{P}$  的前  $g$  ( $g$  为类别数)行  $t$  列, 并进行奇异值分解  $\mathbf{P}(1:g, 1:t) = \mathbf{U} \Lambda \mathbf{V}^T$ ;

(5)计算矩阵  $\tilde{\mathbf{Z}} = \mathbf{Q} \begin{bmatrix} \Sigma^{-1} \mathbf{V} & \mathbf{0} \\ \mathbf{0} & \mathbf{I} \end{bmatrix}$ , 取  $\tilde{\mathbf{Z}}$  的前  $r$  ( $r \leq g-1$ )

列矢量构成矩阵  $\tilde{\mathbf{Z}}_r$ , 则式(9)所定义的最优化准则解集为  $\mathbf{M} = \mathbf{E} \tilde{\mathbf{Z}}_r$ 。

输出 计算  $\mathbf{G} = \mathbf{Q} \mathbf{M} = \mathbf{Q} \mathbf{E} \tilde{\mathbf{Z}}_r$ ,  $\mathbf{G}$  即为构成 KUDS 的统计不相关最优辨别矢量集, 参见式(3)。

任选一幅训练或测试 HRRP 样本  $\mathbf{z}$ , 计算其在 KUDS 中的投影:

$$\mathbf{y} = \mathbf{G}^T \Phi(\mathbf{z}) = \tilde{\mathbf{Z}}_r^T \mathbf{E}^T \mathbf{Q}^T \Phi(\mathbf{z}) = \tilde{\mathbf{Z}}_r^T \mathbf{E}^T \mathbf{K}_{tz} \quad (13)$$

其中  $\mathbf{K}_{tz} = \mathbf{Q}^T \Phi(\mathbf{z}) = [k(\mathbf{x}_1, \mathbf{z}), \dots, k(\mathbf{x}_N, \mathbf{z})]^T$ 。

## 3 基于核不相关辨别子空间的目标分类

对  $g (\geq 2)$  类目标, 先按2.2节描述的 KUDS 算法获取统计不相关最优辨别矢量集  $\mathbf{G}$ , 然后依据式(13)将各目标的

训练样本投影于  $\mathbf{G}$  中, 取每类目标训练样本子像的平均作为库模板矢量, 构建总模板库为  $\{\bar{\mathbf{y}}_1, \bar{\mathbf{y}}_2, \dots, \bar{\mathbf{y}}_g\}$ 。

对任一幅测试 HRRP 样本  $\mathbf{x}_t$ , 先按式(13)得到其在  $\mathbf{G}$  中的投影子像  $\mathbf{y}_t$ , 然后计算其与各库模板矢量之间的 Euclidean 距离:

$$d_i = \|\mathbf{y}_t - \bar{\mathbf{y}}_i\|, \quad i = 1, 2, \dots, g \quad (14)$$

若满足  $c = \arg \min_i \{d_i\}$ , 则判定  $\mathbf{x}_t$  属于第  $c$  类目标。

## 4 仿真实验与分析

### 4.1 实验数据

本文实验采用C波段ISAR雷达对空中3种飞机(An-26、Jiang和Yark-42)录取的HRRP数据。根据飞行轨迹的不同, 每种飞机均记录了7段数据。表1给出了实验所用雷达及3种飞机目标的部分参数。

表1 ISAR 雷达及3类实测飞机目标的部分参数

雷达参数	中心频率		信号带宽
	5520MHz		400MHz
飞机类型	机长(m)	机宽(m)	机高(m)
An-26	23.80	29.20	8.58
Jiang	14.39	15.90	4.57
Yark-42	36.38	34.88	9.83

实验之前, 先对各目标的 HRRP 数据作如下预处理:

(1)归一化。将每幅 HRRP 的模归一化为 1, 降低其对幅度的敏感性。

(2)距离对准。利用 Fourier 变换的平移不变性, 对 HRRP 作 Fourier 变换以对齐。同时, 依据实数 Fourier 变换的共轭对称性, 取每幅像变换后的一半作为识别输入矢量。

### 4.2 实验结果

实验中, 训练样本和测试样本从不同的数据段内选取: 首先按“隔二取一”的方式从 An-26 的第 2, 第 4 段, Jiang 的第 2, 第 7 段和 Yark-42 的第 2, 第 5 段中抽取共 522 幅 HRRP 作为训练数据, 然后从各目标余下的数据段中分别选出一段, 同样按“隔二取一”的方式抽取共 261 幅 HRRP 作为测试数据。

**实验 1** 考察了高斯核函数  $k(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2 / \sigma)$  ( $\sigma > 0$ ) 中的  $\sigma$  因子对识别率的影响。取 KUDS 最优投影子空间维数为 2。为便于比较, 此处引入了几种经典的核方法, 包括 Liang 等提出的核不相关辨别分析(KUDA)、广义辨别分析<sup>[9]</sup>(GDA)及核主分量分析<sup>[10]</sup>(KPCA), 结果如图 1 所示。

可见, 当参数  $\sigma$  在 0.1~1.5 的范围内变化时(每隔 0.1 做一次试验, 共 15 次), KUDA 受  $\sigma$  变化的影响比较明显, 其平均识别率曲线波动较大, 最高值与最低值相差达 28.42%。而与之相反, KUDS, GDA 和 KPCA 受  $\sigma$  变化的影响较小,

体现出了良好的稳健性。就识别率而言, KUDS 各次试验的平均结果为 93.21%, 略逊于 GDA 的 93.93%, 但远远优于 KPCA 的 80.35%。

**实验 2** 考察了 KUDS 的最优投影子空间维数对目标识别率的影响(采用高斯核函数, 参数  $\sigma$  取值为 0.5)。如图 2 所示, 易知 KUDS 的平均识别率在子空间维数取 2 时达到最大值 94.53%, 此后其识别率随着子空间维数的增长总体上呈下降趋势。上述实验结果与文献[6]中理论与实验分析所获得的结论相吻合, 即对  $g$  类模式识别问题, 可抽取的最有效辨别特征为  $g-1$  个。




图 1 参数  $\sigma$  变化对识别率的影响




图 2 KUDS 平均识别率与子空间维数的关系

**实验 3** 比较了 KUDS 和 UDA 的识别性能(KUDS 采用高斯核函数, 参数  $\sigma$  取值为 0.5, 同时两方法子空间维数均取 2)。如表 2 所示, KUDS 的识别率明显优于 UDA, 平均识别率超出后者达 17.91%。另一方面, KUDS 对 3 类飞机目标识别率的最大值与最小值之间相差仅约 5.97%, 相比 UDA 的 20.90%, 其波动幅度要小得多, 这些都充分体现了核非线性方法对目标类可分性的改善作用。

表 2 KUDS 和 UDA 对 3 类飞机目标的识别率比较(%)

	UDA	KUDS
An-26	65.67	92.54
Jiang	86.57	92.54
Yark-42	77.61	98.51
平均识别率	76.62	94.53

## 5 结束语

本文结合广义奇异值分解与核方法的优点, 提出了一种核不相关辨别子空间雷达 HRRP 目标识别算法。在 3 类飞机实测回波数据的基础上, 与 KUDA, GDA, KPCA 和 UDA 等方法进行了对比实验研究, 并考察了径向基核函数参数  $\sigma$  值及最优投影子空间维数变化对新算法分类性能的影响。实验结果表明, 所提方法不仅有效地改善了目标的类可分性, 同时进一步增强了方法的稳健性。

## 参考文献

- [1] 袁莉, 刘宏伟, 保铮. 雷达高分辨距离像分类器的参数自适应学习算法[J]. 电子与信息学报, 2008, 30(1): 198-202.  
Yuan L, Liu H W, and Bao Z. Adaptive learning of classifier parameters for radar high range resolution profiles recognition[J]. *Journal of Electronics & Information Technology*, 2008, 30(1): 198-202.
- [2] 周代英, 杨万麟. 雷达目标一维距离像识别中的最优因式分析子空间法[J]. 电子与信息学报, 2007, 29(10): 2341-2345.  
Zhou D Y and Yang W L. Recognition of radar target based on optimal factor analysis subspace using range profile[J]. *Journal of Electronics & Information Technology*, 2007, 29(10): 2341-2345.
- [3] 刘华林, 杨万麟. 基于 QR 分解的广义判别分析用于雷达目标识别[J]. 红外与毫米波学报, 2007, 26(3): 205-208.  
Liu H L and Yang W L. Radar target recognition based on generalized discriminant analysis of QR decomposition[J]. *J. Infrared Millim. Waves*, 2007, 26(3): 205-208.
- [4] Yu X L, Wang X G, and Liu B Y. A direct kernel uncorrelated discriminant analysis algorithm[J]. *IEEE Signal Processing Letters*, 2007, 14(10): 742-745.
- [5] Jin Z, Yang J Y, and Hu Z S, et al. Face recognition based on the uncorrelated discriminant transformation[J]. *Pattern Recognition*, 2001, 34(7): 1405-1416.
- [6] 杨静宇, 金忠, 胡钟山. 具有统计不相关性的最佳鉴别特征空间的维数定理[J]. 计算机学报, 2003, 26(1): 110-115.  
Yang J Y, Jin Z, and Hu Z S. A theorem on dimensionality of the uncorrelated optimal discriminant features space[J]. *Chinese Journal of Computers*, 2003, 26(1): 110-115.
- [7] Liang Z Z and Shi P F. Uncorrelated discriminant vectors using a kernel method[J]. *Pattern Recognition*, 2005, 38(1): 307-310.
- [8] Howland P and Park H. Generalizing discriminant analysis using the generalized singular value decomposition[J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2004, 26(8): 995-1006.
- [9] Baudat G and Anouar F. Generalized discriminant analysis using a kernel approach[J]. *Neural Computation*, 2000, 12(10): 2385-2404.
- [10] Schölkopf B, Smola A, and Müller K. Nonlinear component analysis as a kernel eigenvalue problem[J]. *Neural Computation*, 1998, 10(5): 1299-1319.

刘华林: 男, 1977 年生, 博士, 工程师, 研究方向为雷达信号处理与目标识别。

杨万麟: 男, 1945 年生, 教授, 博士生导师, 研究方向为大阵列微波成像、雷达信号处理与目标识别。