

文章编号: 1001-0920(2008)07-0735-06

基于核最优变换与聚类中心的雷达目标识别

赵峰, 张军英, 刘敬

(西安电子科技大学 计算机学院, 西安 710071)

摘要: 抽取有效鉴别特征是雷达一维高分辨距离像识别的关键。基于统计学习理论的核化原理, 提出一种新的鉴别特征提取方法——核最优变换与聚类中心算法。该算法通过非线性变换, 将数据映射到核空间, 在核空间执行最优变换与聚类中心算法, 能够提取一维距离像的稳健非线性鉴别特征。同时, 基于训练样本在核空间所张成的子空间的一组基, 给出一种快速计算方法, 提高了特征提取速度。基于微波暗室实测数据的实验表明了该方法的有效性。

关键词: 高分辨距离像; 核方法; 最优聚类中心; 最优变换

中图分类号: TN957

文献标识码: A

Radar target recognition based on kernel optimal transformation and cluster centers

ZHAO Feng, ZHANG Junying, LIU Jing

(School of Computer Science and Engineering, Xidian University, Xi'an 710071, China. Correspondent: ZHAO Feng, E-mail: zhaofeng1016@126.com)

Abstract: How to extract effective discriminant features is the key problem for radar automatic target recognition based on high resolution range profile (HRRP). A novel method for extracting discriminant features by using kernel methods, kernel optimal transformation and cluster centers algorithm (KOT-CC), is presented. In KOT-CC, all data are mapped to a kernel space via some nonlinear mapping, and the optimal transformation and cluster centers (OT-CC) is performed in the kernel space. KOT-CC is a powerful technique for extracting nonlinear discriminant features. A fast algorithm for KOT-CC is also proposed based on a basis of the sub-space which is spanned by the training samples mapped onto the kernel space, which can improve the efficiency of the feature extraction process. Experimental results using range profiles from microwave unreflected chamber show the effectiveness of the proposed algorithm.

Key words: High resolution range profile (HRRP); Kernel method; Optimal cluster centers; Optimal transformation

1 引言

高分辨距离像(HRRP)是目标散射点子回波在雷达射线上投影的向量和,可提供目标散射点的强度和位置信息,反映目标的形状和结构等特征。相对于雷达目标像,HRRP更容易获取,因而成为雷达自动目标识别领域的研究热点^[1-4]。但HRRP随目标姿态的变化会出现起伏、闪烁等现象,即所谓的目标姿态敏感性,使得同一目标在不同姿态角下,其HRRP可能相差甚远。因此,采用恰当方法提取稳健的鉴别特征——松弛方位敏感性,成为基于一维距离像识别目标的关键^[1-7]。

文献[5]提出一种鉴别特征提取算法——最优

变换与聚类中心算法(OT-CC),并成功地用于雷达目标识别。其基本思想是通过一个变换矩阵,即寻找一个子空间,使得变换后的每类数据分别聚集于预先指定的聚类中心,同时保持聚类中心之间尽可能分离,即在优先考虑异类之间差异性的基础上,保持同类数据间的趋同性。但该算法本质上属于线性算法,只能提取数据的线性特征,而不能提取其非线性特征。因此,采用该算法处理分布复杂的高分辨距离像时,容错能力受到一定限制,从而影响了识别效果。

本文基于统计学习理论的核学习算法^[8],在深入分析最优变换与聚类算法(OT-CC)的基础上,提

收稿日期: 2007-05-23; 修回日期: 2007-10-25.

基金项目: 国家自然科学基金项目(60574039,60371044); 国防预研项目(413070501).

作者简介: 赵峰(1974—),男,山东梁山人,博士,从事智能信息处理、雷达目标识别等研究; 张军英(1961—),女,西安人,教授,博士生导师,从事人工神经网络、智能信息处理等研究。

出一种新的非线性鉴别特征提取算法——核最优变换和聚类中心算法(KOT-CC).即通过一个非线性变换,将数据映射到高维核空间,然后采用OT-CC处理数据,实现原空间数据的非线性特征提取.实际计算则借助于“核函数”,即非线性变换的内积,保留在原空间进行;而复杂的非线性变换的具体形式则无需明确表示.

另外,本文基于训练集在核空间的空间结构,用训练集在核空间中所张成的子空间的一组基线性地表示最优变换矩阵,给出KOT-CC的一种快速算法:FKOT-CC,使计算复杂度由原来的 $O(n^3)$ 降为 $O(r^3)$ (其中: n 表示训练样本个数, r 表示基的个数,一般情况下 $r \ll n$),特征提取速度显著提高.

2 最优变换和聚类中心

2.1 最优变换

设 x_{ij} (N 维列向量)表示第 i 类目标的第 j 个训练样本, $i = 1, 2, \dots, g; j = 1, 2, \dots, n_i$.其中: g 为类别数, n_i 为第 i 类目标的训练样本数.令 w_l ($l = 1, 2, \dots, g-1$)表示 R^N 中的列向量,作以下变换:

$$y_{ij} = Wx_{ij} + b. \quad (1)$$

其中: $W = (w_1, w_2, \dots, w_{g-1})^T$ 为 $(g-1) \times N$ 变换矩阵, b 为任一 $g-1$ 维列向量, y_{ij} 为 x_{ij} 经 W 变换后对应的子像.

设 u_i ($i = 1, 2, \dots, g$)为 $g-1$ 维列向量,则最优变换的目标就是寻求一个矩阵 W ,即 R^N 中 $g-1$ 个投影方向 w_i 以及列向量 b 满足

$$J(W, b) = \arg \min_{W, b} \sum_{i=1}^g \sum_{j=1}^{n_i} (u_i - y_{ij})^T (u_i - y_{ij}), \quad (2)$$

其中 W 称为最小平方误差准则下的最优变换矩阵.式(2)表明,经最优变换后,第 i 类数据的子像聚集于 u_i 的周围,所以称 u_i 为第 i 类目标在子像空间的聚类中心.结合式(1)和(2),有

$$\begin{cases} W = C_{VW} C_{WW}^{-1}, \\ b = \bar{u} - W\bar{x}. \end{cases} \quad (3)$$

其中

$$\begin{cases} \bar{u} = \frac{1}{n_1 + n_2 + \dots + n_g} \sum_{i=1}^g n_i u_i, \\ \bar{x} = \frac{1}{n_1 + n_2 + \dots + n_g} \sum_{i=1}^g \sum_{j=1}^{n_i} x_{ij}, \\ C_{VW} = \sum_{i=1}^g \sum_{j=1}^{n_i} (u_i - \bar{u})(x_{ij} - \bar{x})^T, \\ C_{WW} = \sum_{i=1}^g \sum_{j=1}^{n_i} (x_{ij} - \bar{x})(x_{ij} - \bar{x})^T. \end{cases} \quad (4)$$

2.2 最优聚类中心的选择

由2.1节知,每类训练样本经最优变换后,子像分别聚集于各自的聚类中心,减少了同类间的差异性.进一步,如果各聚类中心之间分离(距离)越大,则异类子像间的分离也相应越大,即选取最优聚类中心,可以加大异类的差异性.

不失一般性,令范数 $u_i = 1$ ($i = 1, 2, \dots, g$),即聚类中心位于子像空间的单位超球面上.显然,最优聚类中心应满足在各聚类中心之间的距离(夹角)相等的情况下,尽可能地分离.即最优聚类中心 u_i 应满足(详细推导过程见文献[5])

$$\begin{cases} \sum_{i=1}^g u_i = 0, \\ u_i, u_j = \frac{-1}{g-1}, \quad i \neq j, \\ u_i = 1. \end{cases} \quad (5)$$

根据式(5),最优聚类中心可按下列步骤选取:

$$\text{Step 1: } u_1 = (1, 0, \dots, 0)^T.$$

$$\text{Step 2: } u_2 = (a_{21}, a_{22}, 0, \dots, 0)^T,$$

其中 a_{21} 和 a_{22} 由条件 $u_2 = 1, u_1, u_2 = \frac{-1}{g-1}$ 确定.

$$\text{Step 3: } u_3 = (a_{31}, a_{32}, a_{33}, 0, \dots, 0)^T,$$

其中 a_{31}, a_{32}, a_{33} 由 $u_3 = 1, u_1, u_3 = u_2, u_3 = \frac{-1}{g-1}$ 确定.

Step 4: 重复以上过程,直到求得

$$u_{g-1} = (a_{g-1,1}, a_{g-1,2}, \dots, a_{g-1,g-1})^T.$$

Step 5: u_g 可由 $\sum_{i=1}^g u_i = 0$ 得到.

注1 随着类别数 g 的增加,由式(5)知,最优聚类中心之间的夹角逐渐逼近于 90° .综上所述,对于 g 类目标,按上述步骤为各类选定最优聚类中心,然后利用式(3)得到最优变换,进而可依据各类数据在最优变换下的子像为特征(见式(1)),采用一定的识别方法进行识别.

3 核最优变化与聚类中心

由式(1)可以看出,OT-CC只是一个线性变换,只能提取数据的线性鉴别特征,而对于非线性可分数据以及分布较为复杂的实测数据,其分类效果很不理想.本文基于核化原理,首先通过一个非线性映射将输入空间的数据映射到核空间,然后在核空间中执行OT-CC算法.将该算法简记为KOT-CC.下面给出详细的推导过程.

令 ϕ 表示原空间 R^N 到核空间 F 的一个非线性变换,即

$$x \in R^N \xrightarrow{\phi} \phi(x) \in F. \quad (6)$$

在核空间 F 中,用 $\phi(x_{ij})$ 取代 x_{ij} , 设 $W = (w_1, w_2, \dots, w_{g-1})^T$ 为 F 中的列向量 $w_l (l = 1, 2, \dots, g - 1)$ 所构成的矩阵,作如下变换:

$$y_{ij} = W\phi(x_{ij}) + b. \quad (7)$$

优化的目标函数形式上仍为

$$J(W, b) = \arg \min_{W, b} \left(\sum_{i=1}^g \sum_{j=1}^{n_i} (u_i - y_{ij})^T (u_i - y_{ij}) \right), \quad (8)$$

其中 u_i 为 $g - 1$ 维列向量.

由 Mercer 定理^[9], 式(8)的最优解 W 的每一个行向量 w_l^T , 必然落在所有训练样本 $\phi(x_i)$ 所张成的子空间中,即存在 $l = (a_1, a_2, \dots, a_n)^T$, 满足

$$w_l = \sum_{i=1}^n a_i \phi(x_i). \quad (9)$$

其中 x_i 为输入空间的第 i 个训练样本, n 为总训练样本个数. 将式(9)代入(7), 并在运算中用核函数表示向量的内积, 即 $k(x_i, x_j) = \phi(x_i)^T \phi(x_j)$, 可得

$$y_{ij} = Bk_{ij} + b. \quad (10)$$

其中 $B = (b_1, b_2, \dots, b_{g-1})^T$ 为 $(g - 1) \times n$ 矩阵, $k_{ij} = (k(x_1, x_{ij}), k(x_2, x_{ij}), \dots, k(x_n, x_{ij}))^T$. 此时, 式(8)的优化问题转化为

$$J(B, b) = \arg \min_{B, b} \left(\sum_{i=1}^g \sum_{j=1}^{n_i} (u_i - y_{ij})^T (u_i - y_{ij}) \right). \quad (11)$$

定义 $k_{ij} = (k(x_1, x_{ij}), k(x_2, x_{ij}), \dots, k(x_n, x_{ij}))^T$ 为核样本, 则式(10)和(11)与式(1)和(2)在形式上完全一样, 容易得到式(11)的最优解为

$$\begin{cases} B = K_{VW} K_{WW}^{-1}, \\ b = \bar{u} - B\bar{k}. \end{cases} \quad (12)$$

其中

$$\begin{cases} \bar{u} = \frac{1}{n_1 + n_2 + \dots + n_g} \sum_{i=1}^g n_i u_i, \\ \bar{k} = \frac{1}{n_1 + n_2 + \dots + n_g} \sum_{i=1}^g \sum_{j=1}^{n_i} k_{ij}, \\ K_{VW} = \sum_{i=1}^g \sum_{j=1}^{n_i} (u_i - \bar{u})(k_{ij} - \bar{k})^T, \\ K_{WW} = \sum_{i=1}^g \sum_{j=1}^{n_i} (k_{ij} - \bar{k})(k_{ij} - \bar{k})^T. \end{cases} \quad (13)$$

注2 式(12)需要对 K_{WW} 求逆运算, 为了保证可逆, 实际计算中采用正则化技术, 用 $\bar{K}_{WW} = K_{WW} + \mu I$ 取代 K_{WW} . 其中 μ 为一个较小的正数, I 为对应的单位矩阵. 对于式(3), 同样要作类似处理. 在本文实验中取 $\mu = 0.001$.

最优聚类中心的选取, 仍然与 OT-CC 的选取方法一致(见 2.2 节). 下面给出 KOT-CC 的具体求解步骤:

Step1: 确定核函数 $k(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ 及相应的参数. 目前常用的核函数主要有: 1) 多项式核 $k(x, y) = (a x, y + b)^d$; 2) RBF核 $k(x, y) = \exp(-\|x - y\|^2 / (2\sigma^2))$; 3) Sigmoid核 $k(x, y) = \tanh(a x, y + b)$.

Step2: 按照 2.2 节的方式选定最优聚类中心.

Step3: 按式(12)求解最优变换矩阵 B 和 b .

Step4: 对于输入样本 x , 由式(10)得到其对应的核空间的子像

$$y = Bk_x + b, \quad (14)$$

其中 $k_x = (k(x_1, x), k(x_2, x), \dots, k(x_n, x))^T$. 进而可依据子像 y 为识别特征, 按一定的分类方法进行.

由 KOT-CC 的推导过程可知, 整个求解过程只用到变换的内积函数, 即核函数, 无需明确非线性变换 $\phi(\cdot)$, 这正是核化原理的巧妙所在.

4 KOT-CC 的快速算法

由式(12)知, KOT-CC 的计算复杂度为 $O(n^3)$, 对于大训练集数据而言, 计算很困难. 本文基于训练集在核空间的空间结构, 给出一种 KOT-CC 的快速算法——FKOT-CC.

4.1 FKOT-CC 的推导

由式(9)可以看出, 在核空间中, 所有训练样本 $\phi(x_i) (1 \leq i \leq n)$ 都参与变换矩阵 W 的表达. 事实上, 训练样本 $\phi(x_i) (i = 1, \dots, n)$ 在核空间所张成的子空间为 $\{\phi(x_i)\}_{1 \leq i \leq n}$, 其空间结构可由该子空间的一组基来捕获^[10]. 一般情况下, 基的个数 r 满足 $r \ll n$. 设 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{br})$ 为子空间 $\{\phi(x_i)\}_{1 \leq i \leq n}$ 的一组基, 则最优变换矩阵 W 的每一个行向量 w_i^T (见式(9)) 可由 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{br})$ 线性表示, 即

$$w_l = \sum_{i=1}^r t_{li} \phi(x_{bi}). \quad (15)$$

将式(15)代入(7), 并结合式(8)容易推导出: 对于任意输入数据 x , 最优变换为

$$y = \tilde{B}\tilde{k}_x + \tilde{b}. \quad (16)$$

其中 $\tilde{k}_x = (k(x_{b1}, x), k(x_{b2}, x), \dots, k(x_{br}, x))^T$, \tilde{B} 和 \tilde{b} 分别满足

$$\begin{cases} \tilde{B} = \bar{K}_{VW} \bar{K}_{WW}^{-1}, \\ \tilde{b} = \bar{u} - \tilde{B}\bar{k}. \end{cases} \quad (17)$$

式中

$$\left\{ \begin{aligned} \bar{u} &= \frac{1}{n_1 + n_2 + \dots + n_g} \sum_{i=1}^g n_i u_i, \\ \tilde{k} &= \frac{1}{n_1 + n_2 + \dots + n_g} \sum_{i=1}^g \sum_{j=1}^{n_i} \tilde{k}_{ij}, \\ \bar{K}_{VW} &= \sum_{i=1}^g \sum_{j=1}^{n_i} (u_i - \bar{u})(\tilde{k}_{ij} - \tilde{k})^T, \\ \bar{K}_{WW} &= \sum_{i=1}^g \sum_{j=1}^{n_i} (\tilde{k}_{ij} - \tilde{k})(\tilde{k}_{ij} - \tilde{k})^T, \\ \tilde{k}_{ij} &= (k(x_{b1}, x_{ij}), k(x_{b2}, x_{ij}), \dots, k(x_{br}, x_{ij}))^T. \end{aligned} \right. \quad (18)$$

由式(17)知,快速算法的计算复杂度为 $O(r^3)$,仅与子空间 $\{\phi(x_i)\}_{1 \leq i \leq n}$ 的基的个数有关,大大降低了KOT-CC的计算复杂度.更重要的是,测试阶段的特征提取速度也得到了显著的改善,这是因为FKOT-CC进行特征提取时,只需计算 r 个核函数(见式(16));而KOT-CC则需要计算 n 个核函数(见式(14)).

4.2 子空间基的确定

因为非线性变换 ϕ 是以隐式形式出现的,无法直接明确地知道 $\phi(x_i)$,所以 $\{\phi(x_i)\}_{1 \leq i \leq n}$ 的基不能显式给出.本文从向量间的线性相关性理论考虑,给出子空间 $\{\phi(x_i)\}_{1 \leq i \leq n}$ 一组基的确定方法.

定理1 $x_{b1}, x_{b2}, \dots, x_{bs}$ 表示 s 个训练样本,则 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs})$ 线性无关 $\Leftrightarrow \det(K_{ss}) \neq 0$,其中 $K_{ss} = (k(x_{bi}, x_{bj}))_{1 \leq i, j \leq s}$.

证明 令 $A = (\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs}))$,则 $K_{ss} = A^T A$,易证 $\text{rank}(K_{ss}) = \text{rank}(A)$.又 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs})$ 线性无关 $\Leftrightarrow \text{rank}(A) = s$,即 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs})$ 线性无关 $\Leftrightarrow \text{rank}(K_{ss}) = s$,亦即 $\det(K_{ss}) \neq 0$.

定理2 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs})$ 线性无关, x 为任一新样本,则 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs}), \phi(x)$ 线性无关 $\Leftrightarrow k_{xx} - k_{sx}^T K_{ss}^{-1} k_{sx} \neq 0$.其中: $k_{xx} = k(x, x)$, $k_{sx} = (k(x_{b1}, x), k(x_{b2}, x), \dots, k(x_{bs}, x))^T$, $K_{ss} = (k(x_{bi}, x_{bj}))_{1 \leq i, j \leq s}$.

证明 令 K_{s+1} 表示 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs}), \phi(x)$ 的核矩阵,则

$$\det(K_{s+1}) = \begin{vmatrix} K_{ss} & k_{sx} \\ k_{sx}^T & k_{xx} \end{vmatrix} = \begin{vmatrix} K_{ss} & k_{sx} \\ 0 & k_{xx} - k_{sx}^T K_{ss}^{-1} k_{sx} \end{vmatrix}.$$

因 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs})$ 线性无关,故 $\det(K_{ss}) \neq 0$.因此 $\det(K_{s+1}) \neq 0 \Leftrightarrow k_{xx} - k_{sx}^T K_{ss}^{-1} k_{sx} \neq 0$,即 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs}), \phi(x)$ 线性无关 $\Leftrightarrow k_{xx} - k_{sx}^T K_{ss}^{-1} k_{sx} \neq 0$.

基于上述定理,可采用如下迭代算法寻找 $\{\phi(x_i)\}$ 的一组基:

假设利用 $t(t \leq N)$ 个样本 $\{x_i\}_{i=1}^t$ 完成训练,得到子空间 $\{\phi(x_i)\}_{i=1}^t$ 的一组基 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bt})$.对于新的样本 x ,依据定理2判定 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bt}), \phi(x)$ 是否线性无关.如果无关,则令 $\phi(x_{b,s+1}) = \phi(x)$,构成一个新的线性无关组 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bt}), \phi(x_{b,s+1})$.当遍历所有训练样本时,所求得的线性无关组 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{br})$ 即为子空间 $\{\phi(x_i)\}_{1 \leq i \leq n}$ 的一组基.

但应注意到:利用定理2进行无关性判别时,需对 s 阶矩阵 K_{ss} 求逆.随着迭代次数的加大, s 可能逐渐增大,求逆的运算量很大.因此,利用分块矩阵的性质,本文给出一种简化算法,将求逆运算变为乘法运算,计算代价将有所减小.

定理3 设线性无关组 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{bs})$ 对应的核矩阵为 K_{ss} ; $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{b(s-1)})$ 对应的核矩阵为 $K_{(s-1)(s-1)}$.令

$$\begin{aligned} &= (k(x_{b1}, x_{bs}), k(x_{b2}, x_{bs}), \dots, k(x_{b(s-1)}, x_{bs}))^T, \\ &= k(x_{bs}, x_{bs}), D = K_{(s-1)(s-1)}^{-1}, \end{aligned}$$

则

$$K_{ss}^{-1} = \frac{1}{-{}^T D} \begin{bmatrix} (-{}^T D) D + D {}^T D & -D \\ -{}^T D & 1 \end{bmatrix}. \quad (19)$$

由逆矩阵的定义易验证上式成立.根据定理3,对 s 阶矩阵的求逆运算便转化为对 $s-1$ 阶矩阵的求逆运算,依次下去,求逆运算变为乘法运算.结合定理2,可很方便地寻求子空间 $\{\phi(x_i)\}_{1 \leq i \leq M}$ 的一组基 $\phi(x_{b1}), \phi(x_{b2}), \dots, \phi(x_{br})$.具体算法步骤如下:

Step1: 初始化.在训练集 $X = \{x_1, x_2, \dots, x_n\}$ 中任选一样本 x ,满足 $k(x, x) \neq 0$.令 $S = \{x\}$, $D = \{x\}$, $G = 1/k(x, x)$, $t = 1$.

Step2: 如果 $t = N$,则输出 D ,终止程序;否则进入下一步.

Step3: 在 $S = X - S$ 中任选一样本 x^* ,令 $S = S \cup \{x^*\}$, $t = t + 1$;并验证下式是否成立:

$$k_{tt} - k_{st}^T G k_{st} = 0. \quad (20)$$

其中: $\bar{x}_i \in D$, $(k_{st})_i = k(\bar{x}_i, x^*)$, $k_{tt} = k(x^*, x^*)$.

Step4: 若式(20)成立,则返回Step2;否则令

$$D = D \cup \{x^*\},$$

$$G =$$

$$\frac{1}{k_{tt} - k_{st}^T G k_{st}} \begin{bmatrix} (k_{tt} - k_{st}^T G k_{st}) G + G k_{st} k_{st}^T G & -G k_{st} \\ -k_{st}^T G & 1 \end{bmatrix},$$

返回Step2.

程序终止时,集合 D 中的向量经非线性变换 ϕ 后,即为子空间 $\{\phi(x_i)\}_{1 \leq i \leq M}$ 的一组基.需要说明的是,考虑到实际的计算误差,采用式(20)进行线性无关性判别时,采用 $k_{tt} - k_{st}^T G k_{st} \neq 0$ 取代式(20),其

中 是一个小的正数,在本文实验中 $\epsilon = 0.01$.

4.3 FKOT-CC 的求解步骤

结合上面的推导,可给出 FKOT-CC 的求解步骤如下:

- Step1: 确定核函数 $k(x_i, x_j) = \phi(x_i), \phi(x_j)$ 及相应的参数;
- Step2: 按照 2.2 节的方式选定最优聚类中心;
- Step3: 选择子空间 $\{\phi(x_i)\}_{1 \leq i \leq M}$ 的一组基(参见 4.2 节);
- Step4: 按式(17) 求解最优变换矩阵 \tilde{B} 和 \tilde{b} ;
- Step5: 对于输入样本 x ,由式(16) 得到其对应的核空间的子像 y .

5 计算性能分析

在训练阶段,OT-CC 的计算量主要体现在对一个 N 阶矩阵求逆运算(见式(3)),计算复杂度为 $O(N^3)$,其中 N 表示数据的维数. KO T-CC 的计算复杂度为 $O(n^3)$ (见式(12)),与训练样本数目 n 有关,而与数据维数 N 无关,对于高维小样本问题比较有效,但对于大训练数据集,其计算量将增大. 而 FKOT-CC 却可以很好地解决这个问题. 因为 FKOT-CC 的计算量为 $O(r^3)$ (见式(17)),其中 r 为训练样本在特征空间所张成子空间基的个数,尽管 r 与 n 有关,但一般情况下 $r \ll n$,特别是 n 越大,训练数据间的相关性越强, r 与 n 的差别也越大. 因此 FKOT-CC 不仅适用于高维小样本分类问题,而且同样适合大训练集分类问题.

在测试阶段,OT-CC 只是一个简单的矩阵乘法运算(见式(1)),特征提取速度较快;KO T-CC 则需要计算 n 个核函数(见式(14)),当 n 较大时,运算时间较长;而 FKOT-CC 的特征提取速度却较 KO T-CC 有显著改善,只需 r 个核函数运算(见式(16)).

6 实验分析

本文采用的是 5 类缩比模型飞机 :B-52 ,歼-6 ,

歼-7 ,B-1B ,B-2 微波暗室转台数据. 5 类缩比模型飞机及转台数据的主要参数说明详见文献[11]. 原始数据采用步进频率方式在微波暗室测得. 目标的方位角变化范围为 $0^\circ \sim 155^\circ$,俯仰角为 5° ,平均方位角采样间隔为 0.43° . 该数据是 101 维的,样本数分别为 322,311,451,65,256. 实验中,采用等间隔从每类中选取一半作为训练数据,其余作为测试数据.

实验中,采用本文方法 KO T-CC/ FKOT-CC 以及 OT-CC 进行特征提取,将所得到的子像作为识别对象,采用最小距离法进行识别,以讨论本文方法的性能. 最小距离法是指:以每类训练样本的子像的平均作为识别模板,则模板库为 $(\bar{y}_1, \bar{y}_2, \dots, \bar{y}_g)$;对于待测样本 x , 设其对应的子像为 y , 若 $i = \arg \min_{k=1,2,\dots,g} |y - \bar{y}_k|$, 则 y 属于第 i 类.

为了直观地观察 KO T-CC/ FKOT-CC 以及 OT-CC 的特征提取效果,首先对 B-52, 歼-6 和 歼-7 这 3 类飞机数据进行特征提取(之所以选择 3 类数据,是因为运用 KO T-CC/ FKOT-CC/ OT-CC 提取数据的特征,其子像维数 = 数据类别数目 - 1). 图 1 为 3 类飞机的测试数据子像的空间散布图. 其中:“ Δ ”、“ ∇ ”、“ $+$ ”分别表示 B-52, 歼-6, 歼-7 飞机的子像. 实验中 KO T-CC/ FKOT-CC 所选取的核函数为 $\epsilon = 0.1$ 的 RBF.

由图 1 可以看出,OT-CC 的各类子像间存在混叠现象;而 KO T-CC/ FKOT-CC 的各类子像则比较聚集,类间界面较为清晰,说明 KO T-CC/ FKOT-CC 能够提取可分性较强的鉴别特征;而 FKOT-CC 与 KO T-CC 相比,二者的子像散布图相似,说明 FKOT-CC 与 KO T-CC 所提取的鉴别特征基本一致,其中微小的差别主要是由计算误差所引起的.

表 1 给出了 KO T-CC/ FKOT-CC/ OT-CC 对 5 类飞机的识别结果. 实验中 KO T-CC/ FKOT-CC 所选取的核函数为 $\epsilon = 0.1$ 的 RBF. 表 1 中的识别速度

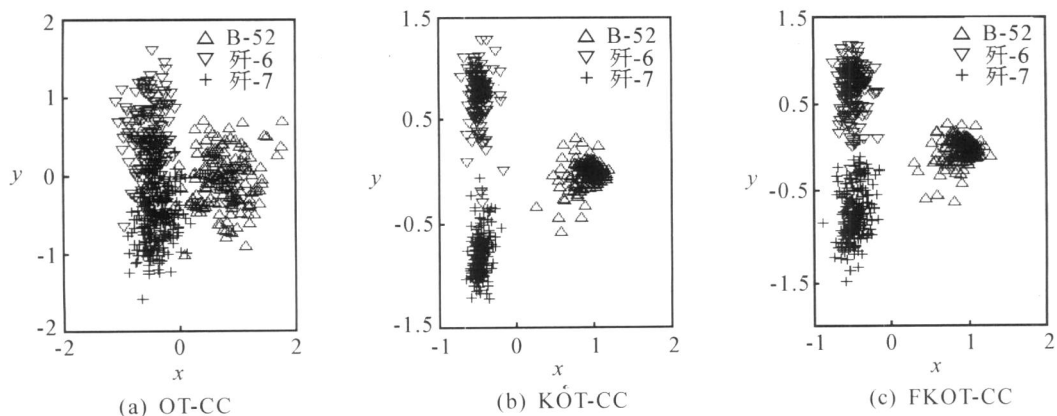


图 1 暗室数据的子像散布图

表1 各种方法的识别结果

飞机类型	OT-CC	KOT-CC	FKOT-CC
B-52	0.92	1	1
歼6	0.88	0.99	0.96
歼7	0.9	0.99	0.98
B-1B	0.97	0.99	0.99
B-2	0.98	1	0.99
平均识别率	0.93	0.99	0.985
识别速度/s	0.023	17.3	10

是指文中所选择的所有测试样本在同样的实验平台下10次实验的平均时间。

就识别效果而言, KOT-CC/ FKOT-CC 识别率明显高于 OT-CC, 说明 KOT-CC/ FKOT-CC 能够提取稳健的鉴别特征. 而 FKOT-CC 与 KOT-CC 的识别率几乎相同, 说明 FKOT-CC 与 KOT-CC 的识别性能相当.

就识别速度而言, 尽管 OT-CC 的识别速度最快, 但其代价却是较低的识别率. 另外在本实验中, 训练样本个数 $n = 703$, 而基的个数 $r = 435$, 所以 FKOT-CC 的识别速度较 KOT-CC 有显著提高. 可见, 对于识别率与实时性要求较高的雷达目标识别而言, FKOT-CC 不失为一种好的选择.

7 结 论

基于核化原理, 在分析 OT-CC 算法的基础上, 本文给出一种新的非线性鉴别特征提取方法——KOT-CC; 同时, 基于核空间中训练样本所张成的子空间的结构, 设计了 KOT-CC 的快速算法——FKOT-CC, 用于提取 HRRP 的稳健鉴别特征. 基于暗室实测数据的比较分析表明, FKOT-CC 能够提取稳健的鉴别特征, 而且计算量较小, 特征提取速度快. 另外, KOT-CC/ FKOT-CC 同样适用于其他领域的识别问题, 特别是本文快速算法的设计思想, 完全可以推广至其他核算法的简化问题. 有待进一步研究的问题是: KOT-CC/ FKOT-CC 算法中, 各类所对应的聚类中心间的夹角相等, 当雷达目标较多时(如群目标), 各目标的聚类中心夹角变小, 识别效果不太理想, 此时可考虑“一对多”或“一对一”的解决方案.

参考文献(References)

[1] Xing M D, Bao Z, Pei B N. Properties of high-

resolution range profiles[J]. *Optical Engineering*, 2002, 41(2): 493-504.

[2] Kim K T, Seo D K, Kim H T. Efficient radar target recognition using the MUSIC algorithm and invariant features[J]. *IEEE Trans on Antennas Propagation*, 2002, 50(3): 325-337.

[3] Willis C. Aircraft recognition using high-resolution radar range profiles[C]. *Signal Processing, Sensor Fusion, and Target Recognition*. Orlando: The Int Society for Optical Engineering, 2003: 200-209.

[4] Du L, Liu H W, Bao Z. Radar HRRP target recognition based on higher order spectra[J]. *IEEE Trans on Signal Process*, 2005, 53(7): 2359-2368.

[5] 周代英, 沈晓峰, 杨万麟. 基于最优变换和聚类中心的雷达目标识别[J]. *电波科学学报*, 2002, 17(3): 233-236.

(Zhou D Y, Sheng X F, Yang W L. Radar target imaging recognition based on optimal transformation and cluster centers[J]. *Chinese J of Radio Science*, 2002, 17(3): 233-236.)

[6] Novak L M, Owirka G J. Radar target recognition using an eigen-image approach[C]. *IEEE Int Radar Conf*. Alexandria, 1994: 129-131.

[7] Liu B Y, Yang W L. Radar target recognition using canonical transformation to extract features[J]. *Proc of SPIE*, 1998, 3545(1): 368-671.

[8] Muller K B, Mika S, Ratsch G, et al. An introduction to kernel-based learning algorithms[J]. *IEEE Trans on Neural Networks*, 2001, 12(2): 181-201.

[9] 边肇祺, 张学工. 模式识别[M]. 北京: 清华大学出版社, 1999.

(Bian Z Q, Zhang X G. *Pattern recognition* [M]. Beijing: Tsinghua University Press, 1999.)

[10] Baudat G, Anouar F. Kernel-based methods and function approximation[C]. *Proc of the Int Joint Conf on Neural Networks*. Piscataway: Institute of Electrical and Electronics Engineers Inc, 2001: 1244-1249.

[11] 时宇, 张贤达. Gabor 原子网络法在雷达目标高分辨距离像识别中的应用[J]. *清华大学学报*, 2001, 41(9): 98-101.

(Shi Y, Zhang X D. Gabor-atom network based target recognition using high-resolution radar range profiles[J]. *J of Tsinghua University*, 2001, 41(9): 98-101.)