

文章编号:1000-6893(2009)12-2380-07

两向二维最大子类散度差鉴别分析及其在SAR目标识别中的应用

胡利平, 刘宏伟, 尹奎英, 吴顺君

(西安电子科技大学 雷达信号处理国家重点实验室, 陕西 西安 710071)

Two-directional Two-dimensional Maximum Clustering-based Scatter Discriminant Analysis and Its Application to SAR Target Recognition

Hu Liping, Liu Hongwei, Yin Kuiying, Wu Shunjun

(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

摘要: 针对 Fisher 线性判决分析(FLDA)在图像识别应用中遇到的小样本问题, 提出了两向二维最大子类散度差($(2D)^2$ MCSD)鉴别分析的图像特征提取方法。首先找到每类数据的子类划分, 再根据这些子类构造基于二维图像矩阵的子类间和子类内散布矩阵, 最后用子类间与子类内散布之差作为鉴别准则求取投影矢量。该方法可以处理多模分布问题, 从根本上避免了矩阵求逆和小样本问题, 加快了特征抽取的速度, 且同时对图像行和列进行压缩, 克服了二维最大子类散度差(2DMCSD)鉴别分析和另一种形式的2DMCSD(Alternate 2DMCSD)的特征维数较大的问题。基于美国运动和静止目标获取与识别(MSTAR)公共数据库提供的实测数据的实验结果表明: 本文方法的性能优于现有的子空间方法; 与 2DMCSD 和 Alternate 2DMCSD 相比, 可大大降低特征维数、提高识别性能。

关键词: 目标识别; 合成孔径雷达; 子类判决分析; 最大散度差; Fisher 线性判决分析

中图分类号: TN959.1⁺7 **文献标识码:** A

Abstract: To solve the small sample size (SSS) problem of Fisher linear discriminant analysis (FLDA) when it is applied to image recognition tasks, a novel image feature extraction technique is proposed which is called two-directional two-dimensional maximum clustering-based scatter difference ($(2D)^2$ MCSD) discriminant analysis. In this method, the possible clusters for each class are first found, and then the between-cluster and within-cluster scatter matrices are constructed from the 2D image matrices based on these clusters. Finally, projection vectors are sought by taking the difference of between-class scatter and within-class scatter as the discriminant criterion. Thus the method can not only deal with multimodal distribution problems but also avoid inverse matrix calculation and SSS problems, and increase the efficiency of feature extraction. Moreover, the $(2D)^2$ MCSD compresses image rows and columns simultaneously, thus overcoming the problem of too many features of 2DMCSD and Alternate 2DMCSD. Experiments on a moving and stationary target acquisition and recognition (MSTAR) public database demonstrate that the $(2D)^2$ MCSD is more efficient than some existing subspace methods. Furthermore, compared with 2DMCSD and Alternate 2DMCSD, $(2D)^2$ MCSD achieves higher recognition rates with much less memory requirements.

Key words: target recognition; synthetic aperture radar; clustering-based discriminant analysis; maximum scatter difference (MSD); Fisher linear discriminant analysis(FLDA)

Fisher 线性判决分析(Fisher Linear Discriminant Analysis, FLDA)是一种有效的特征提取方法, 它通过最大化投影后样本的类间散布与类内散布之比寻找最优的投影矢量。然而, 它在用于图像特征提取时, 类内散布矩阵通常不可逆, 即小样本问题(样本维数远大于样本个数)。目前许多方法^[1-5]用于解决该问题。其中, 文献[1]和

文献[2]首先用主分量分析(Principal Component Analysis, PCA)进行降维, 以保证类内散布矩阵可逆, 然后再做 FLDA。而在 PCA 中会丢失一些有用的可分性信息。文献[3]~文献[5]提出了最大散度差(Maximum Scatter Difference, MSD)判决分析, 它通过最大化投影后样本的类间与类内散布矩阵之差来求解投影轴, 避免了矩阵求逆, 从根本上避免 FLDA 的小样本问题, 大大加快了特征抽取的速度。

FLDA 只有在单模分布假设下(每类样本的

协方差矩阵相同而均值不同)才能达到最优,然而当每类样本服从多模分布(不同类别的样本的均值很接近)时,FLDA 的性能就会大大恶化。且 FLDA 得到的特征维数至多为类别数减 1,这对于多类识别问题来说是不够的。为此,文献[6]和文献[7]提出子类判决分析(Clustering-based Discriminant Analysis, CDA),首先找到每类目标可能的子类,然后基于这些子类采用类似 FLDA 准则求解投影矢量,使得投影后异类目标的子类之间距离最大且子类类内的散布最小。由于 CDA 假设每类目标服从多模分布,可在一定程度上缓解 FLDA 的线性和奇异性问题,且得到的特征维数为子类总数减 1(大于类别数减 1)。然而,CDA 在用于图像特征提取时,需要将二维图像矩阵转化为一维向量,这使得特征提取要在高维向量空间中进行,会大大增加计算负担。为此,B. Ma 等^[8]提出了二维子类判决分析(Two-dimensional CDA, 2DCDA),它一方面可以处理多模分布问题,另一方面直接基于二维图像矩阵(这点与二维主分量分析(2DPCA)^[9]和二维线性判决分析(2DLDA)^[10]类似)来构造子类散布矩阵。然而在 2DCDA 中,需要计算子类类内散布矩阵的逆。为了避免计算逆矩阵或逆矩阵不存在的问题,本文首先给出一种新的图像特征提取方法,二维最大子类散度差鉴别分析(Two-dimensional Maximum Clustering-based Scatter Difference, 2DMCSD),它结合了 MSD 和 2DCDA 两种方法的思想。2DMCSD 只沿行方向压缩图像,类似地,给出其另一种形式(称之为 Alternate 2DMCSD),它只沿列方向压缩图像。因此它们需要较多的特征系数,这会增加内存需求量和识别时间。为了解决这一问题,提出两向二维最大子类散度差(Two-directional 2DMCSD, (2D)²MCSD)鉴别分析,它同时对图像行和列进行压缩,可大大降低特征维数,进而有效降低存储量和识别时间。

1 MSD 判决分析

给定 c 类 M 个训练样本向量 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M$,且 $\mathbf{x}_i \in \mathbf{R}^d$ ($i=1, 2, \dots, M$)。则类间、类内散布矩阵定义为

$$\left. \begin{aligned} \mathbf{S}_b &= \frac{1}{M} \sum_{i=1}^c M_i (\mathbf{m}_i - \mathbf{m}_0)(\mathbf{m}_i - \mathbf{m}_0)^T \in \mathbf{R}^{d \times d} \\ \mathbf{S}_w &= \frac{1}{M} \sum_{i=1}^c \sum_{j=1}^{M_i} (\mathbf{x}_i^j - \mathbf{m}_i)(\mathbf{x}_i^j - \mathbf{m}_i)^T \in \mathbf{R}^{d \times d} \end{aligned} \right\} \quad (1)$$

式中: M_i 为第 i 类的样本个数; \mathbf{x}_i^j 为第 i 类的第 j 个样本; \mathbf{m}_i 为第 i 类的均值; \mathbf{m}_0 为所有训练样本的均值。求取最优投影矢量时,FLDA 是最大化投影后样本的类间与类内散布之比,而 MSD 则是最大化投影后样本的类间与类内散布之差,即

$$J_{MSD}(\mathbf{v}) = \arg \max_{\mathbf{v}} (\mathbf{v}^T \mathbf{S}_b \mathbf{v} - \mathbf{v}^T \mathbf{S}_w \mathbf{v}) \quad (2)$$

则最优的投影矢量 \mathbf{v} 为矩阵 $\mathbf{S}_b - \mathbf{S}_w$ 的最大特征值对应的特征向量。然而,对于多类识别问题,仅仅一个投影方向是不够的。取矩阵 $\mathbf{S}_b - \mathbf{S}_w$ 的前 q ($q \leq c-1$) 个较大特征值对应的特征向量 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_q$ 组成投影矩阵。与 FLDA 相比,MSD 不必计算 \mathbf{S}_w^{-1} ,这样不仅避免了 \mathbf{S}_w 不可逆的情况,还提高了特征抽取的效率。

2 2DCDA 判决分析

给定 c 类 M 个训练图像 $\mathbf{I}_1, \mathbf{I}_2, \dots, \mathbf{I}_M$,且 $\mathbf{I}_i \in \mathbf{R}^{n \times n}$ ($i=1, 2, \dots, M$)。每类样本的子类划分如下:第 j 类有 d_j 个子类,第 j 类的第 i 个子类有 $N^{j,i}$ 个样本, $\mathbf{I}_k^{j,i}$ 表示第 j 类的第 i 个子类中的第 k 个样本, $\bar{\mathbf{I}}^{j,i}$ 为第 j 类的第 i 个子类的训练图像的均值, $\bar{\mathbf{I}}$ 表示所有训练图像的均值。

基于上述的子类划分,2DCDA 通过最大化式(3)的准则函数寻找最优的投影矢量 \mathbf{w} 。

$$J_{2DCDA}(\mathbf{w}) = \arg \max_{\mathbf{w}} \frac{\text{tr}(\mathbf{P}_B)}{\text{tr}(\mathbf{P}_W)} \quad (3)$$

式中: \mathbf{P}_B 和 \mathbf{P}_W 分别为投影后样本 $\mathbf{y}_i = \mathbf{I}_i \mathbf{w}$ ($i=1, 2, \dots, M$) 的子类类间、子类类内散布矩阵,定义如下:

$$\left. \begin{aligned} \mathbf{P}_B &= \sum_{j=1}^{c-1} \sum_{l=j+1}^c \sum_{i=1}^{d_j} \sum_{h=1}^{d_l} p_{j,i} p_{l,h} (\bar{\mathbf{y}}^{j,i} - \bar{\mathbf{y}}^{l,h}) \cdot \\ &\quad (\bar{\mathbf{y}}^{j,i} - \bar{\mathbf{y}}^{l,h})^T = \\ &\quad \sum_{j=1}^{c-1} \sum_{l=j+1}^c \sum_{i=1}^{d_j} \sum_{h=1}^{d_l} p_{j,i} p_{l,h} (\bar{\mathbf{I}}^{j,i} - \bar{\mathbf{I}}^{l,h}) \cdot \\ &\quad \mathbf{w} \mathbf{w}^T (\bar{\mathbf{I}}^{j,i} - \bar{\mathbf{I}}^{l,h})^T \\ \mathbf{P}_W &= \sum_{j=1}^c \sum_{i=1}^{d_j} \sum_{k=1}^{N_{j,i}} (\mathbf{y}_k^{j,i} - \bar{\mathbf{y}}^{j,i})(\mathbf{y}_k^{j,i} - \bar{\mathbf{y}}^{j,i})^T = \\ &\quad \sum_{j=1}^c \sum_{i=1}^{d_j} \sum_{k=1}^{N_{j,i}} (\mathbf{I}_k^{j,i} - \bar{\mathbf{I}}^{j,i}) \mathbf{w} \mathbf{w}^T (\mathbf{I}_k^{j,i} - \bar{\mathbf{I}}^{j,i})^T \end{aligned} \right\}$$

于是,有 $\text{tr}(\mathbf{P}_B) = \mathbf{w}^T \mathbf{C}_B \mathbf{w}$ 和 $\text{tr}(\mathbf{P}_W) = \mathbf{w}^T \mathbf{C}_W \mathbf{w}$,

$$\left. \begin{aligned} \mathbf{C}_B &= \sum_{j=1}^{c-1} \sum_{l=j+1}^c \sum_{i=1}^{d_j} \sum_{h=1}^{d_l} p_{j,i} p_{l,h} (\bar{\mathbf{I}}^{j,i} - \bar{\mathbf{I}}^{l,h})^T (\bar{\mathbf{I}}^{j,i} - \bar{\mathbf{I}}^{l,h}) \in \\ &\quad \mathbf{R}^{n \times n} \text{ 和 } \mathbf{C}_W = \sum_{j=1}^c \sum_{i=1}^{d_j} \sum_{k=1}^{N_{j,i}} (\mathbf{I}_k^{j,i} - \bar{\mathbf{I}}^{j,i})^T (\mathbf{I}_k^{j,i} - \bar{\mathbf{I}}^{j,i}) \in \end{aligned} \right.$$

$\mathbf{R}^{n \times n}$ 分别为训练样本的子类类间、子类类内散布矩阵, $p_{j,i} = N^{j,i}/M$ 为第 j 类的第 i 个子类的先验概率。

因此, 上述准则函数可写为

$$J_{\text{2DCDA}}(\mathbf{w}) = \arg \max_{\mathbf{w}} \frac{\mathbf{w}^T \mathbf{C}_B \mathbf{w}}{\mathbf{w}^T \mathbf{C}_W \mathbf{w}} \quad (4)$$

最优的投影方向 \mathbf{w} 通过对式(5)的特征分解得到。

$$\mathbf{C}_B \mathbf{w} = \lambda \mathbf{C}_W \mathbf{w} \quad (5)$$

实际中, 对于多类识别问题来讲, 仅仅一个投影轴是不够的, 通常取一组正交的投影轴。取 $\mathbf{C}_W^{-1} \mathbf{C}_B$ 的前 p 个较大特征值对应的特征向量组成投影矩阵 $\mathbf{W}_{\text{2DCDA}} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \cdots \ \mathbf{w}_p] \in \mathbf{R}^{n \times p}$ ($p < n$)。任一个给定的图像 $\mathbf{I} \in \mathbf{R}^{m \times n}$, 其 2DCDA 特征为

$$\mathbf{B} = (\mathbf{I} - \bar{\mathbf{I}}) \mathbf{W}_{\text{2DCDA}} \in \mathbf{R}^{m \times p} \quad (6)$$

3 2DMCSD 及其改进算法鉴别分析

3.1 2DMCSD 鉴别分析

由于 2DCDA 需要计算子类类内散布矩阵 \mathbf{C}_W 的逆, 而在小样本问题中, \mathbf{C}_W 通常是不可逆的。为了解决这一问题, 首先提出二维最大子类散度差(2DMCSD)判决分析, 它结合了二维子类判决分析(2DCDA)和最大散度差(MSD)两种方法的思想。

基于第 2 节的子类划分, 2DMCSD 通过最大化投影后训练样本 $\mathbf{z}_i = \mathbf{I}_i \boldsymbol{\phi}$ ($i = 1, 2, \dots, M$) 的子类类间与子类类内散布之差求取最优的投影轴 $\boldsymbol{\phi}$, 即

$$J_{\text{2DMCSD}}(\boldsymbol{\phi}) = \arg \max_{\boldsymbol{\phi}} [\text{tr}(\mathbf{P}_B) - \text{tr}(\mathbf{P}_W)] = \arg \max_{\boldsymbol{\phi}} (\boldsymbol{\phi}^T \mathbf{C}_B \boldsymbol{\phi} - \boldsymbol{\phi}^T \mathbf{C}_W \boldsymbol{\phi}) \quad (7)$$

式中: $\mathbf{P}_B, \mathbf{P}_W, \mathbf{C}_B$ 和 \mathbf{C}_W 的定义同 2DCDA。

求解如式(8)所示的广义特征问题即可得到最优的投影方向 $\boldsymbol{\phi}$ 。

$$(\mathbf{C}_B - \mathbf{C}_W) \boldsymbol{\phi} = \gamma \boldsymbol{\phi} \quad (8)$$

式中: γ 为 $\mathbf{C}_B - \mathbf{C}_W$ 的特征值。

对 2DCDA 和 2DMCSD 分析可知, 2DMCSD 既可以处理多模分布问题, 又不必计算子类类内散布矩阵的逆矩阵, 避免了逆矩阵不存在的现象, 可大大加快求取投影方向的速度。

与 2DCDA 类似, 取 $\mathbf{C}_B - \mathbf{C}_W$ 的前 r 个较大特征值对应的特征向量 $\boldsymbol{\phi}_1, \boldsymbol{\phi}_2, \dots, \boldsymbol{\phi}_r$ 组成投影矩阵

$\mathbf{W}_{\text{2DMCSD}} = [\boldsymbol{\phi}_1 \ \boldsymbol{\phi}_2 \ \cdots \ \boldsymbol{\phi}_r] \in \mathbf{R}^{n \times r}$ ($r < n$)。对于任一图像 $\mathbf{I} \in \mathbf{R}^{m \times n}$, 其 2DMCSD 特征为

$$\begin{aligned} \mathbf{C} &= [\mathbf{a}_1 \ \mathbf{a}_2 \ \cdots \ \mathbf{a}_r] = \\ (\mathbf{I} - \bar{\mathbf{I}}) [\boldsymbol{\phi}_1 \ \boldsymbol{\phi}_2 \ \cdots \ \boldsymbol{\phi}_r] &= \\ (\mathbf{I} - \bar{\mathbf{I}}) \mathbf{W}_{\text{2DMCSD}} &\in \mathbf{R}^{m \times r} \end{aligned} \quad (9)$$

3.2 Alternate 2DMCSD 鉴别分析

同 2DMCSD 类似, 该方法通过最大化投影后训练样本 $\mathbf{z}_i = \boldsymbol{\phi}^T \mathbf{I}_i$ ($i = 1, 2, \dots, M$) 的子类类间与子类类内散布矩阵之差求取最优的投影轴 $\boldsymbol{\phi}$ 。类似 2DCDA 的推导可得, 训练样本的子类类间、子类类内散布矩阵分别为

$$\left. \begin{aligned} \mathbf{S}_B &= \sum_{j=1}^{c-1} \sum_{l=j+1}^c \sum_{i=1}^{d_j} \sum_{h=1}^{d_l} p_{j,i} p_{l,h} (\bar{\mathbf{I}}^{j,i} - \bar{\mathbf{I}}^{l,h}) \cdot \\ &(\bar{\mathbf{I}}^{j,i} - \bar{\mathbf{I}}^{l,h})^T \in \mathbf{R}^{m \times m} \\ \mathbf{S}_W &= \sum_{j=1}^c \sum_{i=1}^{d_j} \sum_{k=1}^{N_{j,i}} (\mathbf{I}_k^{j,i} - \bar{\mathbf{I}}^{j,i}) \cdot \\ &(\mathbf{I}_k^{j,i} - \bar{\mathbf{I}}^{j,i})^T \in \mathbf{R}^{m \times m} \end{aligned} \right\} \quad (10)$$

则最优投影轴 $\boldsymbol{\phi}$ 为式(11)所示广义特征问题的最大特征值对应的特征向量。

$$(\mathbf{S}_B - \mathbf{S}_W) \boldsymbol{\phi} = \eta \boldsymbol{\phi} \quad (11)$$

式中: η 为 $\mathbf{S}_B - \mathbf{S}_W$ 的特征值。

取 $\mathbf{S}_B - \mathbf{S}_W$ 的前 l 个较大特征值对应的特征向量组成投影矩阵 $\mathbf{W}_{\text{A}_\text{2DMCSD}} = [\boldsymbol{\phi}_1 \ \boldsymbol{\phi}_2 \ \cdots \ \boldsymbol{\phi}_l] \in \mathbf{R}^{m \times l}$ ($l < m$)。对于任一图像 $\mathbf{I} \in \mathbf{R}^{m \times n}$, 向 $\mathbf{W}_{\text{A}_\text{2DMCSD}}$ 投影, 得到其特征矩阵为

$$\begin{aligned} \mathbf{D} &= [b_1 \ b_2 \ \cdots \ b_l]^T = \\ [\boldsymbol{\phi}_1 \ \boldsymbol{\phi}_2 \ \cdots \ \boldsymbol{\phi}_l]^T (\mathbf{I} - \bar{\mathbf{I}}) &= \\ \mathbf{W}_{\text{A}_\text{2DMCSD}}^T (\mathbf{I} - \bar{\mathbf{I}}) &\in \mathbf{R}^{l \times n} \end{aligned} \quad (12)$$

3.3 (2D)² MCSD 鉴别分析

通过分析可知, 2DMCSD 仅对图像行进行压缩, 而 Alternate 2DMCSD 仅对图像列进行压缩。由于 2DMCSD 和 Alternate 2DMCSD 仅对图像行或列压缩, 因此需要较多的特征系数, 这会带来存储量较大以及识别运算时间较长等问题。为此, 将 2DMCSD 和 Alternate 2DMCSD 两种形式结合起来, 提出 (2D)² MCSD, 其实现步骤如下: ①分别采用 3.1 节和 3.2 节的方法找到投影矩阵 $\mathbf{W}_{\text{2DMCSD}} \in \mathbf{R}^{n \times r}$ 和 $\mathbf{W}_{\text{A}_\text{2DMCSD}} \in \mathbf{R}^{m \times l}$; ②对于任一图像 $\mathbf{I} \in \mathbf{R}^{m \times n}$, 同时向这两个投影矩阵投影, 得到其特征矩阵为

$$\mathbf{E} = \mathbf{W}_{\text{A}_\text{2DMCSD}}^T (\mathbf{I} - \bar{\mathbf{I}}) \mathbf{W}_{\text{2DMCSD}} \in \mathbf{R}^{l \times r} \quad (13)$$

由于 $(2D)^2$ MCSD 同时去除了图像行和列的相关性(即“冗余信息”),因此可大大降低特征维数、改善识别性能。

在 2DCDA 及本文的特征提取方法中,假设每类目标的子类划分是已知的。因此在特征提取之前需要对每类目标数据进行聚类以找到相应的子类划分。本文采用的是二维快速全局 k 均值聚类算法(2D Fast Global k -means Clustering Algorithm),它是将快速全局 k 均值算法(Fast Global k -means Clustering Algorithm)^[11]推广到二维空间中。与二维 k 均值聚类算法(k 均值聚类算法推广到二维空间中)相比,二维快速全局 k 均值聚类算法不依赖初始聚类中心的选择,且能保证聚类结果达到全局最优,进而保证最终的识别性能稳定、最优。

4 分类器设计

采用基于距离的最近邻分类器对测试目标进行识别,即计算待测样本的特征矩阵与 M 个训练样本的特征矩阵之间的距离,将使距离最小的训练样本所属的类别作为该待测样本的类别。

4.1 基于 2DMCSD 特征的距离定义

待测图像 \mathbf{I} 和训练图像 \mathbf{I}_i ($i=1, 2, \dots, M$) 的特征矩阵 $\mathbf{C} = [\mathbf{a}_1 \quad \mathbf{a}_2 \quad \dots \quad \mathbf{a}_r] \in \mathbf{R}^{m \times r}$ 和 $\mathbf{C}_i = [\mathbf{a}_1^{(i)} \quad \mathbf{a}_2^{(i)} \quad \dots \quad \mathbf{a}_r^{(i)}] \in \mathbf{R}^{m \times r}$ 之间的距离定义为

$$d(\mathbf{C}, \mathbf{C}_i) = \sum_{k=1}^r \|\mathbf{a}_k - \mathbf{a}_k^{(i)}\|_2 \quad (14)$$

式中: $\|\mathbf{a}_k - \mathbf{a}_k^{(i)}\|_2$ 为向量 \mathbf{a}_k 和 $\mathbf{a}_k^{(i)}$ 之间的欧氏距离。

4.2 基于 Alternate 2DMCSD 特征的距离定义

定义测试图像 \mathbf{I} 和训练图像 \mathbf{I}_i 的特征矩阵 $\mathbf{D} = [\mathbf{b}_1 \quad \mathbf{b}_2 \quad \dots \quad \mathbf{b}_l]^T \in \mathbf{R}^{l \times n}$ 和 $\mathbf{D}_i = [\mathbf{b}_1^{(i)} \quad \mathbf{b}_2^{(i)} \quad \dots \quad \mathbf{b}_l^{(i)}]^T \in \mathbf{R}^{l \times n}$ 之间的距离为

$$d(\mathbf{D}, \mathbf{D}_i) = \sum_{k=1}^l \|\mathbf{b}_k - \mathbf{b}_k^{(i)}\|_2 \quad (15)$$

4.3 基于 $(2D)^2$ MCSD 特征的距离定义

给定测试图像 \mathbf{I} 和训练图像 \mathbf{I}_i 的 $(2D)^2$ -MCSD 特征为 $\mathbf{E} \in \mathbf{R}^{l \times r}$ 和 $\mathbf{E}_i \in \mathbf{R}^{l \times r}$ 。

(1) 沿行定义距离: \mathbf{E} 和 \mathbf{E}_i 可写为 $\mathbf{E} = [\mathbf{x}_1 \quad \mathbf{x}_2 \quad \dots \quad \mathbf{x}_l]^T$, $\mathbf{E}_i = [\mathbf{x}_1^{(i)} \quad \mathbf{x}_2^{(i)} \quad \dots \quad \mathbf{x}_l^{(i)}]^T$ 。它们之间的距离定义为

$$d_1(\mathbf{E}, \mathbf{E}_i) = \sum_{k_1=1}^l \|\mathbf{x}_{k_1} - \mathbf{x}_{k_1}^{(i)}\|_2 \quad (16)$$

(2) 沿列定义距离: \mathbf{E} 和 \mathbf{E}_i 可写为 $\mathbf{E} = [\mathbf{y}_1 \quad \mathbf{y}_2 \quad \dots \quad \mathbf{y}_r]^T$, $\mathbf{E}_i = [\mathbf{y}_1^{(i)} \quad \mathbf{y}_2^{(i)} \quad \dots \quad \mathbf{y}_r^{(i)}]^T$ 。它们之间的距离定义为

$$d_2(\mathbf{E}, \mathbf{E}_i) = \sum_{k_2=1}^r \|\mathbf{y}_{k_2} - \mathbf{y}_{k_2}^{(i)}\|_2 \quad (17)$$

(3) 沿行和列定义距离:综合上述两种距离定义方式,则 \mathbf{E} 和 \mathbf{E}_i 之间的距离为

$$d(\mathbf{E}, \mathbf{E}_i) = d_1(\mathbf{E}, \mathbf{E}_i) + d_2(\mathbf{E}, \mathbf{E}_i) \quad (18)$$

5 实验结果

实验采用的是美国运动和静止目标获取与识别(Moving and Stationary Target Acquisition and Recognition,MSTAR)数据库计划录取的地面静止目标合成孔径雷达(Synthetic Aperture Radar,SAR)数据,分辨率为 $0.3 \text{ m} \times 0.3 \text{ m}$ 。原始图像大小均为 128×128 。训练和测试样本分别是 SAR 在俯仰角 17° 和 15° 时对地面目标的成像数据,如表 1 所示。每类样本的方位覆盖范围是 $0^\circ \sim 360^\circ$ 。同类不同型号的目标在配备上有些差异。

表 1 训练和测试样本集

Table 1 Training and testing dataset in experiments

目标类别	目标型号	俯仰角/(°)	
		17	15
BMP	SNC21	196	
	SN9563	233	195
	SN9566	196	
BTR70	C71	233	196
	SN132	232	196
T72	SN812	195	
	SNS7	191	

5.1 训练和测试图像的预处理

由于原始 SAR 图像中包含大量的相干斑,因此需要对其进行预处理^[12],其实现步骤如下:

① 对原始图像(如图 1(a)所示)的幅度矩阵做对数变换,可将相干斑噪声由乘性变为加性,使图像直方图更适合用高斯分布描述,还可压缩图像灰度的动态范围^[13],减小图像中某几个大值像素的影响。

② 在对数域内采用自适应阈值分割获得目标图像 \mathbf{T}_{ar} (如图 1(b)所示)。在对数域内估计当前图像 \mathbf{G} 的均值 μ 和方差 σ 。假定目标强度大于背景强度,对 \mathbf{G} 的每个像素点 (x, y) ,有

$$\left. \begin{array}{l} (x, y) \in \mathbf{T}_{ar}, T_{ar(x, y)} = 1, \\ \text{如果 } \frac{G_{(x, y)} - \mu}{\sigma} > c_1 \\ (x, y) \in \mathbf{B}_{ac}, T_{ar(x, y)} = 0, \\ \text{其他} \end{array} \right\} \quad (19)$$

式中 \mathbf{T}_{ar} , \mathbf{B}_{ac} 分别表示目标和背景; 常数 c_1 通过分析训练样本库中原始图像像素灰度值分布先验地确定, 如图 1(c)所示。

③ 对 \mathbf{T}_{ar} 做形态学滤波^[13], 可去除小的非目标区域以平滑边界等, 如图 1(d)所示。

④ 对滤波后的 \mathbf{T}_{ar} 做几何聚类处理^[14], 以去除小的非目标区域, 如图 1(e)所示。

⑤ 将得到的二值图像 \mathbf{T}_{ar} 与对数图像 \mathbf{G} 做点乘运算, 得到目标的强度图像 \mathbf{H} , 如图 1(f)所示。

⑥ 对 \mathbf{H} 基于幂变换做图像增强^[13]以增强对目标的识别能力, 如图 1(g)所示。

⑦ 为了克服目标相对于雷达距离不同产生的影响, 对增强后的目标图像做能量归一化处理, 使归一化后图像所有像素值的平方和为 1, 如图 1(h)所示。

⑧ 为了克服目标在场景中的位置不确定性, 对归一化后的目标图像做二维傅里叶变换, 取其幅频信息的一半作为特征提取的输入以降低样本维数、减小运算量, 如图 1(i)所示。

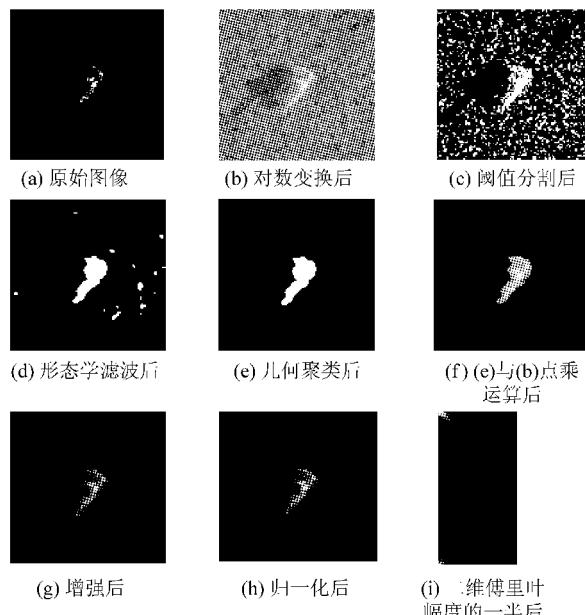


图 1 预处理前后的 SAR 图像

Fig. 1 SAR images before and after pre-processing

5.2 测试结果

为了验证本文方法的有效性, 图 2 给出了本文 SAR 自动目标识别(ATR)系统的基本流程: ①图像预处理。对 SAR 目标图像进行预处理, 以减弱背景杂波对识别性能的影响。②聚类。对每类预处理后的训练图像采用二维快速全局 k 均值聚类算法找到最优的子类划分结果。③特征提

取。采用本文提出的特征提取方法来提取目标特征。④利用最近邻分类器进行分类。在聚类过程中, 需要确定子类数目。为方便起见, 假定每类目标具有相同的子类数目 k_{\max} 。

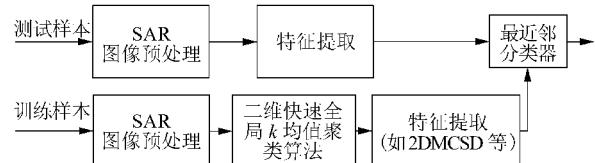


图 2 本文的 SAR ATR 系统流程

Fig. 2 Flow chart of present SAR ATR system

由于很难从理论上确定子类数目和特征维数, 因此通过实验确定最优的子类数目和特征维数。图 3 给出了 2DMCSD 和 Alternate 2DMCSD 的识别率 P_c 随 k_{\max} 和 r (或 l) 的关系曲线。不难看出, 2DMCSD 和 Alternate 2DMCSD 均可以获得相当好的识别性能。

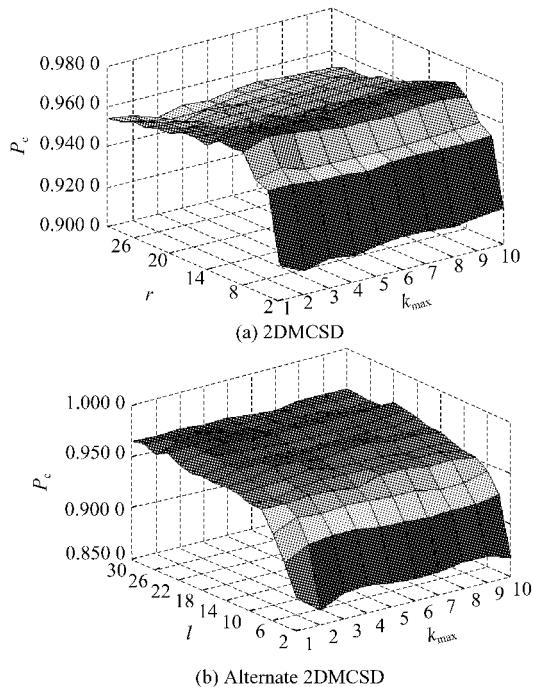


图 3 2DMCSD 和 Alternate 2DMCSD 的识别率随 k_{\max} 和 r (或 l) 的变化关系

Fig. 3 Recognition rates of 2DMCSD and Alternate 2DMCSD over k_{\max} and r (or l)

为了进行性能对比, 还采用了 FLDA, MSD, 2DPCA, 2DLDA 和 2DCDA 进行特征提取。由于在 FLDA 和 MSD 中类内、类间散布矩阵的维数为 $(128 \times 64) \times (128 \times 64)$, 构造维数如此大的矩阵且对它们特征分解存在计算负担较大的问题, 因此本文重点对比 2DPCA, 2DLDA, 2DCDA, 2DMCSD,

Alternate 2DMCSD 和 $(2D)^2$ MCSD。表 2 给出了它们最高识别率的对比情况,其中 2DPCA, 2DLDA 和 2DCDA 中距离定义方式同 4.1 节的距离定义方式。

表 2 几种特征提取方法的最高识别率对比

Table 2 Comparison of highest recognition rates of several feature extraction methods

方法	识别率(特征矩阵维数)
2DPCA	0.969 8 (128×8)
2DLDA ($\mu = \lambda_{\max}$)	0.964 7 (128×8)
2DCDA ($\mu = \lambda_{\max}$)	0.971 5 ($k_{\max} = 3, 128 \times 10$)
2DMCSD	0.971 5 ($k_{\max} = 2, 128 \times 8$)
Alternate 2DMCSD	0.972 7 ($k_{\max} = 3, 26 \times 64$)
$(2D)^2$ MCSD, 列	0.975 5 ($k_{\max} = 2, 20 \times 12$)
$(2D)^2$ MCSD, 行	0.976 6 ($k_{\max} = 4, 24 \times 16$)
$(2D)^2$ MCSD, 行和列	0.977 2 ($k_{\max} = 8, 24 \times 10$)

由表 2 看出, 2DPCA 和 2DLDA 的最高识别率不及 2DCDA 和本文方法, 这是因为 2DPCA 和 2DLDA 假设每类目标线性可分, 服从单模分布; 2DCDA 及本文方法假设每类目标服从多模分布, 考虑了每类目标中含有多个线性可分的子类的情况。因此 2DCDA 和本文方法性能较优。

2DLDA 和 2DCDA 通过最大化投影后样本的类间与类内(或子类类间与子类类内)散度之比求取投影轴, 因此需要计算类内(或子类类内)散布矩阵的逆, 然而在小样本问题中, 逆矩阵通常是不存在的(解决办法是: 在类内或子类类内散布矩阵的主对角线上加一个正则化常数 u , 本文取 u 为该矩阵的最大特征值)。本文方法在寻找投影方向时最大化投影后样本的子类类间与子类类内散度之差, 从根本上避免了小样本问题及矩阵求逆, 因此, 本文方法的计算效率要优于 2DLDA 和 2DCDA。

图 4 也给出了不同子类数目下, 2DCDA, 2DMCSD 和 Alternate 2DMCSD 的最高识别率 $P_{c,\max}$ 对比。可以看出, 在不同的子类个数下, 它们的识别性能大致相当。但是在求取投影矩阵时, 由于 2DCDA 需要先对 C_w 求逆, 再对 $C_w^{-1}C_b$ 进行特征分解, 而 2DMCSD 仅需对 $C_b - C_w$ 特征分解即可, 不仅避免了对 C_w 求逆及逆矩阵不存在的现象, 还可提高求取投影矩阵的速度, 因此总的来说, 2DMCSD 要优于 2DCDA。

从表 2 还看出, 2DMCSD 和 Alternate 2DMCSD 得到的特征维数较大, 这会大大增加存储量和识别时间。由于 $(2D)^2$ MCSD 同时去除了图像行和列的相关性, 因此不仅大大降低了特征维数, 还改善了识别性能。

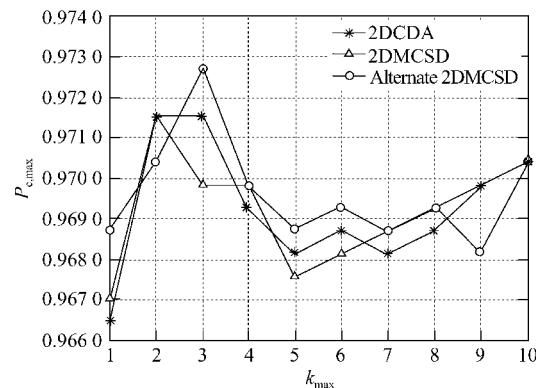


图 4 不同 k_{\max} 下, 2DCDA, 2DMCSD 和 Alternate 2DMCSD 最高识别率对比

Fig. 4 Comparison of the highest recognition rates of 2DCDA, 2DMCSD and Alternate 2DMCSD over k_{\max}

为了进一步证明 $(2D)^2$ MCSD 的优势, 表 3 给出不同方法的存储量对比, 包括两个部分: 求得的投影矩阵和训练样本的特征矩阵。从表 3 可以看出, 与 2DPCA, 2DLDA, 2DCDA, 2DMCSD 和 Alternate 2DMCSD 相比, $(2D)^2$ MCSD 的存储量是最低的。

表 3 几种特征提取方法的存储量对比

Table 3 Comparison of storage of several feature extraction methods

方法	存储量
2DPCA	$n \times r + M \times m \times r = 64 \times 8 + 698 \times 128 \times 8 = 715 264$
2DLDA	$n \times r + M \times m \times r = 64 \times 8 + 698 \times 128 \times 8 = 715 264$
2DCDA	$n \times r + M \times m \times r = 64 \times 10 + 698 \times 128 \times 10 = 894 080$
2DMCSD	$n \times r + M \times m \times r = 64 \times 8 + 698 \times 128 \times 8 = 715 264$
Alternate 2DMCSD	$m \times l + M \times l \times n = 128 \times 26 + 698 \times 26 \times 64 = 1 164 800$
$(2D)^2$ MCSD	$(n \times r + m \times l) + M \times l \times r =$ $\begin{cases} 64 \times 12 + 128 \times 20 + 698 \times 20 \times 12 = 170 848 \\ (\text{当特征矩阵维数} = 20 \times 12 \text{ 时}) \\ 64 \times 16 + 128 \times 24 + 698 \times 24 \times 16 = 272 128 \\ (\text{当特征矩阵维数} = 24 \times 16 \text{ 时}) \\ 64 \times 10 + 128 \times 24 + 698 \times 24 \times 10 = 171 232 \\ (\text{当特征矩阵维数} = 24 \times 10 \text{ 时}) \end{cases}$

图 5 给出了不同子类数目下, 2DMCSD, Alternate 2DMCSD 和 $(2D)^2$ MCSD 的最高识别率对比, 再次证明了: 不管是沿行、列或行和列定义分类器中的距离, $(2D)^2$ MCSD 均可获得优于 2DMCSD 和 Alternate 2DMCSD 的识别性能。

综上所述, 本文提出的方法具有如下优点: ①采用子类散度差准则, 从根本上避免了子类类内散布矩阵奇异及矩阵求逆, 大大提高了求取投影矢量的效率; ②求解投影方向时直接基于二维

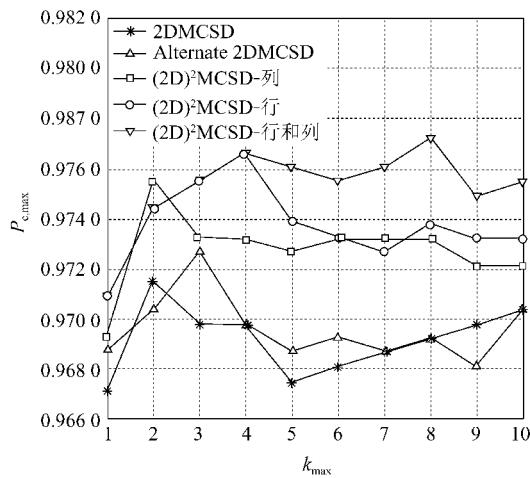


图 5 不同 k_{\max} 下, 2DMCSD, Alternate 2DMCSD 和 $(2D)^2$ MCSD 的最高识别率对比

Fig. 5 Comparison of the highest recognition rates of 2DMCSD, Alternate 2DMCSD and $(2D)^2$ MCSD over a k_{\max}

图像矩阵, 完整保留了图像的二维空间结构信息, 且避免了在高维向量空间中构造散布矩阵, 节省了计算负担; ③考虑了每类目标数据中包含多个子类的情况, 即充分利用了同类目标的不同子类之间的可分性信息, 可处理多模数据分布问题; ④同时去除了图像行和列的相关性, 降低了特征维数, 改善了识别性能。

6 结 论

为了克服 2DMCSD 和 Alternate 2DMCSD 得到的特征维数过大的问题, 提出了 $(2D)^2$ MCSD。该方法结合了 2DCDA 和 MSD 两种方法的思想, 它具有以下优点: ①通过采用最大化子类散度差准则避免了子类类内散布矩阵奇异问题和矩阵求逆问题; ②基于二维图像矩阵构造子类散布矩阵, 大大提高了特征抽取的效率; ③同时对图像行和列压缩, 大大降低了存储量和识别运算时间、提高了识别性能。

基于 MSTAR 实测数据的实验结果也验证了本文方法的有效性。

参 考 文 献

- [1] Belhumeur V, Hespanha J, Kriegman D. Eigenfaces vs. fisherfaces: recognition using class specific linear projection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.
 - [2] Swets D L, Weng J. Using discriminant eigenfeatures for image retrieval[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996, 18(8): 831-836.
 - [3] 宋枫溪, 程科, 杨靖宇, 等. 最大散度差和大间隔线性投影与支持向量机[J]. 自动化学报, 2004, 30(6): 890-896.
 - [4] 刘永俊, 陈才扣. 最大散度差鉴别分析及人脸识别[J]. 计算机工程与应用, 2006, 42(34): 208-210.
 - [5] Liu Yongjun, Chen Caikou. Maximum scatter difference discriminant analysis and face recognition[J]. Computer Engineering and Applications, 2006, 42(34): 208-210. (in Chinese)
 - [6] Song F X, Zhang D, Mei D Y, et al. A multiple maximum scatter difference discriminant criterion for facial feature extraction[J]. IEEE Transactions on System, Man, and Cybernetic—Part B: Cybernetics, 2007, 37(6): 1599-1606.
 - [7] Chen X W, Huang T. Facial expression recognition: a clustering-based approach[J]. Pattern Recognition Letters, 2003, 24(9-10): 1295-1302.
 - [8] Zhu M, Martinez A M. Subclass discriminant analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(8): 1274-1286.
 - [9] Ma B, Wong H S. 2D clustering based discriminant analysis for 3D head model classification[J]. Pattern Recognition, 2006, 39(3): 491-494.
 - [10] Yang J, Zhang D, Frangi A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.
 - [11] Li M, Yuan B. 2D-LDA: a statistical linear discriminant analysis for image matrix[J]. Pattern Recognition Letters, 2005, 26(5): 527-532.
 - [12] Likas A, Vlassis N, Verbeek J. The global k -means clustering algorithm[J]. Pattern Recognition, 2003, 36(2): 451-461.
 - [13] Hu Liping, Liu Hongwei, Wu Shunjun. Novel pre-processing method for SAR image based automatic target-recognition[J]. Journal of Xidian University, 2007, 34(5): 733-737. (in Chinese)
 - [14] Gonzalez R C, Woods R E. Digital image processing[M]. 2nd ed. Boston: Addison-Wesley Longman Publishing Company, 2002: 75-146.
 - [15] Musman S, Kerr D. Automatic recognition of ISAR ship images[J]. IEEE Transactions on Aerospace and Electronic Systems, 1996, 32(4): 1392-1404.
- 作者简介:**
胡利平(1979—) 女,博士。主要研究方向:合成孔径雷达图像处理及目标识别。
Tel: 029-88209286
E-mail: fox_plh@yahoo.com.cn

(编辑:张利平, 杨冬)