

文章编号:1001-9081(2013)02-0534-05

doi:10.3724/SP.J.1087.2013.00534

基于加权两向二维线性鉴别分析的 SAR 目标识别方法

刘 振^{1*}, 姜 晖¹, 王粒宾²

(1. 电子工程学院, 合肥 230037; 2. 解放军 61922 部队, 北京 100094)

(* 通信作者电子邮箱 ahulz@163.com)

摘要:为解决传统 Fisher 线性鉴别分析(LDA)在 SAR 图像目标识别中存在的“小样本”问题和“次优性”问题,提出一种基于加权的两向二维线性鉴别分析方法($W(2D)^2$ LDA)。该方法对两向二维线性鉴别分析准则中散度矩阵的构造进行加入权值的改进,采用加权的两向二维鉴别准则函数进行特征提取,从理论上有效解决了“次优性”问题,并缓解了“小样本”问题。对美国运动与静止目标获取与识别(MSTAR)计划录取的 SAR 图像数据进行的仿真实验结果表明,该算法增强了提取特征的可鉴别性,能够以较小的特征维数和运算量获得更高的识别率,验证了该算法的有效性。

关键词:合成孔径雷达;目标识别;线性鉴别分析;次优性;小样本

中图分类号: TP751 **文献标志码:**A

SAR target recognition method based on weighted two-directional and two-dimensional linear discriminant analysis

LIU Zhen^{1*}, JIANG Hui¹, WANG Libin²

(1. Electronic Engineering Institute, Hefei Anhui 230037, China;
2. No. 61922 Troops of PLA, Beijing 100094, China)

Abstract: To solve the Small Sample Size (SSS) problem and the "inferior" problem of traditional Fisher Linear Discriminant Analysis (FLDA) when it is applied to Synthetic Aperture Radar (SAR) image recognition tasks, a new image feature extraction technique was proposed based on weighted two-directional and two-dimensional linear discriminant analysis ($W(2D)^2$ LDA). First, the scatter matrices in the two-directional and two-dimensional linear discriminant analysis criterion were modified by adding weights. Then, feature matrix was extracted by $W(2D)^2$ LDA. The experimental results with MSTAR dataset verify the effectiveness of the proposed method, and it can strengthen the feature's discrimination and obtain better recognition performance with fewer memory requirements simultaneously.

Key words: Synthetic Aperture Radar (SAR); target recognition; Linear Discriminant Analysis (LDA); inferiority; Small Sample Size (SSS)

0 引言

随着遥感技术的发展,合成孔径雷达(Synthetic Aperture Radar, SAR)尤其是基于 SAR 的自动目标识别(Automatic Target Recognition, ATR)受到了广泛的重视和关注。目前,国内外已有许多学者在此领域做了许多工作,如文献[1]采用模板匹配的识别算法;文献[2]是在图像域内直接用支持向量机(Support Vector Machine, SVM)进行目标的分类识别;文献[3-4]则使用主成分分析(Principal Component Analysis, PCA)、核主成分分析(Kernel Principal Component Analysis, KPCA)或核鉴别分析(Kernel Discriminant Analysis, KDA)用于特征提取并应用 SVM 进行 SAR 目标的识别;文献[5]则是将两级二维主成分分析(Two-stage Two-dimensional Principle Component Analysis, Two-stage 2DPCA)应用于 SAR 目标识别中的特征提取。

Fisher 线性鉴别分析(Fisher Linear Discriminant Analysis, FLDA)^[6]是一种有效的特征提取方法,以使目标样本在投影空间中达到最大的类间散度与最小的类内散度为目标进行投影方向的求取。然而 SAR 目标图像在转换成图像矢量后,特

征维数远远大于样本个数会造成严重的“小样本”问题,基于两向二维线性鉴别分析(Two-Directional and Two-Dimensional Linear Discriminant Analysis, (2D)²LDA)^[7-8]的 SAR 图像目标特征提取方法,缓解了“小样本”问题,降低了计算复杂度。SAR 目标图像受方位角、俯仰角等其他因素的影响,不同类别之间的差异性不同,不同类别的内部分布也有很大不同,标准的鉴别分析在计算类间散度矩阵时平等地对待所有类别,计算类内散度矩阵时也是平等地对待类内所有样本。这样会过分强调具有较大类间距离的类别,造成较小类间距离的类别在投影后出现重叠,处在类内边缘的数据样本不能很好地向类中心凝聚,即传统鉴别分析的“次优性”问题^[9-10]。为此,本文提出一种加权两向二维线性鉴别分析(Weighted Two-Directional and Two-Dimensional Linear Discriminant Analysis, $W(2D)^2$ LDA),并用于 SAR 图像目标的特征提取。 $W(2D)^2$ LDA通过对散度矩阵进行加入权值的改进,来克服 LDA 的“次优性”问题,而且使用两向二维 LDA 的鉴别准则也有利于缓解“小样本”问题。基于美国 MSTAR(Moving and Stationary Target Acquisition and Recognition)数据的实验表明,该方法不仅运算量小而且可以达到较高的识别率。

收稿日期:2012-08-16;修回日期:2012-09-17。

作者简介:刘振(1989-),男,安徽淮南人,硕士研究生,主要研究方向:合成孔径雷达图像处理、目标识别; 姜晖(1964-),男,江苏淮安人,教授,主要研究方向:嵌入式技术、图像处理系统; 王粒宾(1984-),男,河北邯郸人,博士,主要研究方向:稀疏表示、图像处理。

1 两向二维线性鉴别分析

FLDA 可以提取具有很强鉴别信息的特征,但是由于需要对图像矩阵进行矢量化转换,样本维数会远远大于样本的个数,不仅造成“小样本”问题,而且运算量大,运算成本增加。二维线性鉴别分析(Two-Dimensional Linear Discriminant Analysis, 2DLDA)尤其是(2D)²LDA 能够直接在图像矩阵上进行特征提取,不仅保留了图像矩阵的结构信息,而且大大降低了特征维数和运算复杂度。

1.1 水平方向 2DLDA

定义训练样本集 $\{A_1^1, A_2^1, \dots, A_{N_1}^1, A_1^2, \dots, A_{N_c}^c\}$, 其中每个元素为大小为 $m \times n$ 的图像矩阵。这些训练样本分别属于 C 个类, 总的训练样本的个数为 N 个, 其中 A_j^i 为第 i 类第 j 个训练样本, 第 i 类的训练样本个数为 N_i 个, 第 i 类的训练样本均值为 \bar{A}_i , 全体训练样本均值为 \bar{A} , 定义二维情况下的类间散度矩阵和类内散度矩阵^[11-12]如下:

$$S_b^R = \sum_{i=1}^{C-1} \sum_{j=i+1}^C p(\omega_i)p(\omega_j) (\bar{A}_i - \bar{A}_j)^T (\bar{A}_i - \bar{A}_j) \quad (1)$$

$$S_w^R = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{N_i} (A_j^i - \bar{A}_i)^T (A_j^i - \bar{A}_i) \quad (2)$$

其中: $p(\omega_i)$ 和 $p(\omega_j)$ 分别表示第 i 类和第 j 类的先验概率, 一般用每一类的训练样本个数与总训练样本个数的比值作为每一类的先验概率即 $p(\omega_i) = N_i/N$ 。根据 Fisher 准则, 定义如下准则函数:

$$J(\mathbf{w}) = \frac{\mathbf{w}^T S_b^R \mathbf{w}}{\mathbf{w}^T S_w^R \mathbf{w}} \quad (3)$$

其中 \mathbf{w} 为归一化的列向量。使准则函数 $J(\mathbf{w})$ 最大的 \mathbf{w} 即为最优投影轴 \mathbf{w}_{opt} , 对于多类问题, 仅仅一个投影方向是不够的, 一般取一组投影轴 $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r$, 组成投影矩阵 $\mathbf{W}_{opt}^R = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r] \in \mathbb{R}^{n \times r}$ ($r < n$)。根据广义瑞利熵原理^[7,13], 需要寻求得最优投影轴 $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r$ 满足:

$$\mathbf{S}_b^R \mathbf{w} = \lambda \mathbf{S}_w^R \mathbf{w} \quad (4)$$

则投影矩阵 \mathbf{W}_{opt}^R 就是由 $(\mathbf{S}_w^R)^{-1} \mathbf{S}_b^R$ 前 r 个较大特征值对应的特征向量组成的。

然而, 由于训练样本的个数有限, 即使在二维情况下, 类内散度矩阵 \mathbf{S}_w^R 也会出现不可逆的情况。解决此问题可以用的方法是: 在 \mathbf{S}_w^R 的对角线上加上正则化的常数^[7], 即

$$\mathbf{S}_w^R = \mathbf{S}_w^R + \mu \mathbf{I}_{n \times n} \quad (5)$$

来保证 \mathbf{S}_w^R 满足可逆。其中: $\mathbf{I}_{n \times n}$ 是 $n \times n$ 的单位矩阵; μ 是常数, 通常取 \mathbf{S}_w^R 的最大特征值。

求出投影矩阵 \mathbf{W}_{opt}^R 后, 对每一个训练样本 A_i 进行投影即可得到训练样本的特征矩阵 \mathbf{F}_i^R :

$$\mathbf{F}_i^R = (A_i - \bar{A}) \mathbf{W}_{opt}^R \in \mathbb{R}^{m \times r}; i = 1, 2, \dots, N \quad (6)$$

任意一幅待识别目标的图像 $A \in \mathbb{R}^{m \times n}$ 向 \mathbf{W}_{opt}^R 投影, 即可得到测试样本的特征矩阵 \mathbf{F}^R :

$$\mathbf{F}^R = (A - \bar{A}) \mathbf{W}_{opt}^R \in \mathbb{R}^{m \times r} \quad (7)$$

1.2 垂直方向 2DLDA

1.1 节水平方向 2DLDA 实际上是将图像按行划分为块, 然后使用 FLDA 方法进行处理^[14]。它消除了图像列之间的相关性, 沿水平方向上对图像进行压缩, 将水平方向上的判别信息压缩在极少的列上, 这也是将之称为水平方向 2DLDA 的原因。但是, 它忽视了图像行之间的相关性以及垂直方向上判别信息的压缩。为此, 给出垂直方向 2DLDA。垂直方向 2DLDA 是在水平方向 2DLDA 的类间散度和类内散度矩

阵定义的基础上, 对类间离散度和类内离散度矩阵另一种形式的定义:

$$S_b^L = \sum_{i=1}^{C-1} \sum_{j=i+1}^C p(\omega_i)p(\omega_j) (\bar{A}_i - \bar{A}_j)^T (\bar{A}_i - \bar{A}_j) \quad (8)$$

$$S_w^L = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{N_i} (A_j^i - \bar{A}_i)^T (A_j^i - \bar{A}_i) \quad (9)$$

式中各项的定义与 1.1 节类似, 通过对 $(S_w^L)^{-1} S_b^L$ 的特征值分解, 取前 l 个较大特征值对应的特征向量构成垂直方向上的投影矩阵 $\mathbf{W}_{opt}^L = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_l] \in \mathbb{R}^{m \times l}$ ($l < m$)。在求解过程中, 同样可以对 S_w^L 进行非奇异化处理: $S_w^L = S_w^L + \mu \mathbf{I}_{m \times m}$, μ 则取 S_w^L 的最大特征值, $\mathbf{I}_{m \times m}$ 是 $m \times m$ 的单位矩阵。同样地, 将训练样本 A_i 和待识别的测试样本 $A \in \mathbb{R}^{m \times n}$ 向 \mathbf{W}_{opt}^L 投影, 求取训练样本特征矩阵 \mathbf{F}_i^L 和测试样本特征矩阵 \mathbf{F}^L :

$$\mathbf{F}_i^L = (\mathbf{W}_{opt}^L)^T (A_i - \bar{A}) \in \mathbb{R}^{l \times n}; i = 1, 2, \dots, N \quad (10)$$

$$\mathbf{F}^L = (\mathbf{W}_{opt}^L)^T (A - \bar{A}) \in \mathbb{R}^{l \times n} \quad (11)$$

1.3 (2D)²LDA

为了能够同时消除图像矩阵的行相关性和列相关性, 可以使用两向 2DLDA 进行 SAR 图像的特征提取。分别参照 1.1 节和 1.2 节求出水平方向 2DLDA 的投影矩阵 \mathbf{W}_{opt}^R 和垂直方向 2DLDA 的投影矩阵 \mathbf{W}_{opt}^L , 将训练样本 A_i 同时向 $\mathbf{W}_{opt}^R \in \mathbb{R}^{n \times r}$ 和 $\mathbf{W}_{opt}^L \in \mathbb{R}^{l \times m}$ 投影, 即可得到 A_i 的特征矩阵 \mathbf{F}_i^{LR} :

$$\mathbf{F}_i^{LR} = (\mathbf{W}_{opt}^L)^T (\mathbf{A}_i - \bar{A}) \mathbf{W}_{opt}^R \in \mathbb{R}^{l \times r}; i = 1, 2, \dots, N \quad (12)$$

对于任一幅待识别的测试样本 $A \in \mathbb{R}^{m \times n}$, 可以得到测试样本 A 的特征矩阵 \mathbf{F}^{LR} :

$$\mathbf{F}^{LR} = (\mathbf{W}_{opt}^L)^T (A - \bar{A}) \mathbf{W}_{opt}^R \in \mathbb{R}^{l \times r} \quad (13)$$

2 加权两向二维线性鉴别分析

2.1 次优性问题

如图 1 所示, 不论是一维的还是二维的, 线性鉴别分析都是平等地对待所有的训练样本, 这样在投影空间中最大化类别之间的距离时, 类间距离较大的类别起到了主导作用, 在求解投影方向时就会过分强调类间距离较大的、已经具有较好可分性的类别的作用, 并且容易导致类间距离本来就较小的类出现重叠, 进而降低识别性能, 即“次优性”问题。而且, 在计算类内散度矩阵时, 平等地对待类内的所有样本, 那些偏离类中心的样本不能很好地向类中心凝聚, 造成投影后同类样本的分布不够凝聚, 也容易造成类与类之间的重叠。

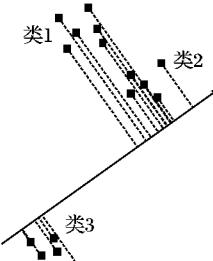


图 1 加权改进前的投影方向

2.2 加权两向二维线性鉴别分析

鉴于“次优性”问题对识别的不利影响, 以样本之间的欧式距离为依据对(2D)²LDA 的散度矩阵进行加入权值的改进。改进后的散度矩阵定义如下:

$$S_b^R = \frac{1}{N^2} \sum_{i=1}^{C-1} \sum_{j=i+1}^C N_i N_j \omega^{i,j} (\bar{A}_i - \bar{A}_j)^T (\bar{A}_i - \bar{A}_j) \quad (14)$$

$$S_w^R = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{N_i} \omega_j^i (A_j^i - \bar{A}_i)^T (A_j^i - \bar{A}_i) \quad (15)$$

$$\mathbf{S}_b^L = \frac{1}{N^2} \sum_{i=1}^{C-1} \sum_{j=i+1}^C N_i N_j \omega^{i,j} (\bar{\mathbf{A}}_i - \bar{\mathbf{A}}_j) (\bar{\mathbf{A}}_i - \bar{\mathbf{A}}_j)^T \quad (16)$$

$$\mathbf{S}_w^L = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{N_i} \omega_j^i (\mathbf{A}_j^i - \bar{\mathbf{A}}_i) (\mathbf{A}_j^i - \bar{\mathbf{A}}_i)^T \quad (17)$$

定义 $\mathbf{x}_j^i \in \mathbb{R}^{(m \times n) \times 1}$ 为图像矩阵 \mathbf{A}_j^i 矢量化处理后得到的图像矢量, ω_j^i 为第 i 类中第 j 个样本 \mathbf{x}_j^i 在类内的权值, ω_j^i 的计算如下:

$$\omega_j^i = d_j^i \cdot \left(\frac{1}{N_i} \sum_{j=1}^{N_i} d_j^i \right)^{-1} \quad (18)$$

其中: $d_j^i = \frac{1}{(N_i - 1)} \sum_{k=1}^{N_i} d_{j,k}^i$ 表示 \mathbf{x}_j^i 的类内离散度, $d_{j,k}^i = \|\mathbf{x}_j^i - \mathbf{x}_k^i\|$ 表示 \mathbf{x}_j^i 与 \mathbf{x}_k^i 的欧氏距离, N_i 为第 i 类样本的个数。

定义第 i 类与第 j 类的类间散度矩阵的权重为 $\omega^{i,j}$, $\omega^{i,j}$ 的计算如下:

$$\omega^{i,j} = (d^{i,j})^{-1} \cdot \left(\frac{2}{C(C-1)} \sum_{i=1}^{C-1} \sum_{j=i+1}^C (d^{i,j})^{-1} \right)^{-1} \quad (19)$$

其中: $d^{i,j} = \frac{1}{N_i} \sum_{k=1}^{N_i} d_k^i$ 表示第 i 类与第 j 类的距离, $d_k^i = \frac{1}{N_j} \sum_{p=1}^{N_j} \|\mathbf{x}_k^i - \mathbf{x}_p^j\|$ 表示 \mathbf{x}_k^i 到第 j 类的距离, C 为总的样本类别个数。计算出加权改进后的散度矩阵,然后使用两向二维线性鉴别分析的准则进行投影矩阵 $\mathbf{W}_{opt}^R \in \mathbb{R}^{n \times r}$ ($r < n$) 和 $\mathbf{W}_{opt}^L \in \mathbb{R}^{m \times l}$ ($l < m$) 的求取。

通过上面的加权改进可以看出,在计算类间散度矩阵时,类间距离较大的类别获得较小的权值,这就削弱了具有较大类间距离的类别在鉴别分析中的主导作用,在保持较大距离类别可分的情况下更加注重较小距离类别之间的区分力度。同时在计算类内散度时也加入权值,对于偏离类中心的样本给予较大的权值,增强它向所属类别中心的凝聚力度。通过加权改进后的鉴别分析,突出了那些具有较小类间距离以及较大类内离散度的样本,以期得到如图 2 所示的最优投影方向:类内更加凝聚,类别之间的距离也不仅仅只考虑总体的最大化,同时更加注重具有较小类间距离的类别间的可分性,以使每两类之间都能够有较好的区分度。

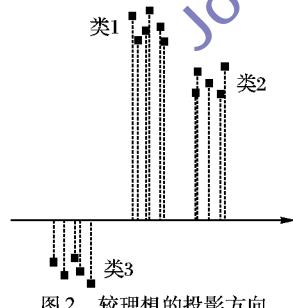


图 2 较理想的投影方向

3 基于 W(2D)²LDA 的 SAR 目标识别

3.1 分类器设计

为了体现本文提取特征的有效性,使用简单的最近邻分类器:先计算在特征空间中待识别的测试样本 \mathbf{A} 与每个训练样本 \mathbf{A}_i 之间的距离,与测试样本距离最小的训练样本的类别即为该测试样本的类别。对于最近邻分类器中的距离作如下定义:

沿行定义距离 定义测试样本的特征为 $\mathbf{F}^{LR} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_l]^T$, 第 i 个训练样本的特征为 $\mathbf{F}_i^{LR} = [\mathbf{y}_{i,1}, \mathbf{y}_{i,2}, \dots, \mathbf{y}_{i,l}]^T$, 则它们之间的距离定义为:

$$d_{row}(\mathbf{F}^{LR}, \mathbf{F}_i^{LR}) = \sum_{j=1}^l \|\mathbf{y}_j - \mathbf{y}_{i,j}\|_2 \quad (20)$$

沿列定义距离 定义测试样本的特征为 $\mathbf{F}^{LR} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_r]^T$, 第 i 个训练样本的特征为 $\mathbf{F}_i^{LR} = [\mathbf{y}_{i,1}, \mathbf{y}_{i,2}, \dots, \mathbf{y}_{i,r}]^T$, 则它们之间的距离定义为:

$$d_{col}(\mathbf{F}^{LR}, \mathbf{F}_i^{LR}) = \sum_{j=1}^r \|\mathbf{y}_j - \mathbf{y}_{i,j}\|_2 \quad (21)$$

沿行和列定义距离 将式(20) 和式(21) 计算得到的距离进行相加即可得到:

$$d(\mathbf{F}^{LR}, \mathbf{F}_i^{LR}) = d_{row}(\mathbf{F}^{LR}, \mathbf{F}_i^{LR}) + d_{col}(\mathbf{F}^{LR}, \mathbf{F}_i^{LR}) \quad (22)$$

3.2 识别步骤

在上述分析的基础上,将基于 W(2D)²LDA 的 SAR 图像目标识别的步骤归纳如下:

1) 输入:训练样本集 $\{\mathbf{A}_1^1, \mathbf{A}_2^1, \dots, \mathbf{A}_{N_i}^1, \mathbf{A}_1^2, \dots, \mathbf{A}_{N_c}^2\}$, 待识别的测试样本 $\mathbf{A} \in \mathbb{R}^{m \times n}$, 水平降维维数 r 和垂直降维维数 l ($r < n, l < m$)。

2) 首先需对数据进行一定的预处理:对数变换、阈值分割、形态滤波;然后作二维傅里叶变换,取一半的幅频信息作为特征提取的输入^[15]。

3) 根据第 2.2 节阐述的加权两向二维线性鉴别分析求出水平方向投影矩阵 $\mathbf{W}_{opt}^R \in \mathbb{R}^{n \times r}$ ($r < n$) 和垂直方向投影矩阵 $\mathbf{W}_{opt}^L \in \mathbb{R}^{m \times l}$ ($l < m$)。

4) 将每个训练样本 \mathbf{A}_i 和待识别测试样本 \mathbf{A} 同时向 \mathbf{W}_{opt}^R 和 \mathbf{W}_{opt}^L 投影,求得相应的特征矩阵 \mathbf{F}_i^{LR} 和 \mathbf{F}^{LR} 。

5) 在 3.1 节定义的三种距离下,利用最近邻分类器进行测试样本的分类识别。

4 实验结果与分析

实验基于美国 MSTAR 计划录取的数据进行仿真实验, MSTAR 数据是迄今公开较为完备的、评价 SAR ATR 算法性能较为标准的数据。数据由聚束式 SAR 获取, 分辨率为 0.3 m, 图像切片大小为 128 × 128 像素, 包括了俯仰角在 17° 和 15° 下的三类目标, 即 BMP2(装甲运兵车)、BTR70(装甲车)及 T72(主战坦克), 每类目标包含了大量不同方位角下的图像, 方位覆盖范围为 0° ~ 360°。图 3 为三类目标的光学图像, 图 4 给出了 BMP2_9563 装甲车在方位角 8°、80°、160° 下的 SAR 图像。选择 17° 俯仰角下的三类目标数据作为训练样本, 15° 俯仰角下的数据作为测试样本, 表 1 列出了所用数据的种类和个数。分别用数据库中的测试样本进行识别, 方位角信息未知, 识别率取所有测试样本的平均识别率, 水平方向降维的维数和垂直方向降维的维数分别取 38、34、30、26、22、18、14、10、6、2。

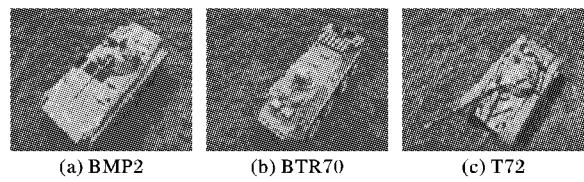


图 3 三类目标的光学图像

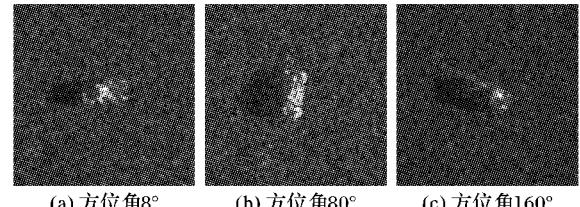


图 4 BMP2_9563 在俯仰角 17° 不同方位角的 SAR 图像

表1 实验数据的种类及样本数

数据类型	目标类别	型号	样本个数	样本总数
训练数据 (俯仰角 为17°)	BMP2	9563	233	698
	BTR70	c71	233	
	T72	132	232	
测试数据 (俯仰角 为15°)	BMP2	9563	195	1365
	BMP2	9566	196	
	BMP2	c21	196	
	BTR70	c71	196	
	T72	132	196	
	T72	812	195	
	T72	s7	191	

图5显示了在沿行和列距离定义下,识别率与水平降维维数 r 和垂直降维维数 l 之间的关系。从图中可以看出达到较高识别率的特征维数一般分布在水平维数10~26、垂直维数6~18的低维数范围内,说明本文提取的特征具有良好的可鉴别性,且不需要太高的维数。从图中也可以看出有相当一部分的识别率都能达到98%以上,相对于原始的 $(2D)^2LDA$ 特征提取方法的识别率有了很大的提高(见表5),说明对散度矩阵加入权值的改进,确实能缓解鉴别分析中的“次优性”问题,提高提取特征的分类性能。

为了更加具体地说明本文所提方法的可行性,表2~4分别给出了在3.1节三种距离定义下,在不同降维维数时的平均识别率数据,带下划线的数据为取得的最高识别率。从表中的数据可以看出,在沿行定义下的识别在 $l=22,r=18$,

14,10时均可以达到最高识别率98.32%;沿列定义距离下的识别率在 $l=26,r=6$ 时可以达到最高识别率98.46%;沿行和列定义距离下的识别率在 $l=22,r=10$ 时达到最高识别率98.47%。从数据表中可以更加准确地看出,在较低特征维数($l=2,r=2$)时,三种识别率也在90%以上,由此可见 $W(2D)^2LDA$ 所提取的特征即使在很低的特征维数下,依然具有良好鉴别信息。较低的特征维数有利于降低运算复杂度、提高识别速度,对于在实时性要求较高的战争场合下,保证识别率的同时提高识别速度是非常有意义的。

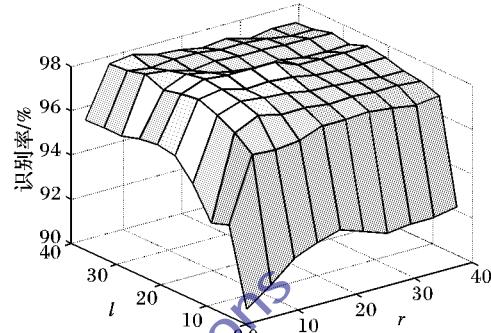


图5 在沿行和列定义距离下的识别率

为了进一步验证本文方法的有效性,表5给出了本文识别结果与文献[4,7,11,16]方法识别结果的比较。可以看出三种距离定义下的最优识别率均高于其他方法的最优识别率,并且所需特征矩阵的维数也较小,进一步验证了本文方法的有效性。

表2 沿行定义距离下在不同维数时的识别率

l	38	34	30	26	22	18	14	10	6	2	r
38	0.9766	0.9766	0.9752	0.9759	0.9766	0.9781	0.9803	0.9796	0.9788	0.9531	
34	0.9781	0.9781	0.9781	0.9788	0.9788	0.9781	0.9788	0.9766	0.9781	0.9568	
30	0.9795	0.9795	0.9795	0.9795	0.9803	0.9810	0.9795	0.9781	0.9795	0.9538	
26	0.9781	0.9781	0.9788	0.9795	0.9788	0.9788	0.9803	0.9810	0.9795	0.9546	
22	0.9817	0.9817	0.9817	0.9817	0.9825	0.9832	0.9832	0.9832	0.9795	0.9553	
18	0.9810	0.9810	0.9810	0.9810	0.9803	0.9817	0.9810	0.9810	0.9788	0.9575	
14	0.9795	0.9802	0.9802	0.9810	0.9810	0.9795	0.9795	0.9781	0.9788	0.9472	
10	0.9788	0.9788	0.9788	0.9795	0.9774	0.9788	0.9774	0.9795	0.9729	0.9369	
6	0.9729	0.9729	0.9729	0.9729	0.9729	0.9729	0.9715	0.9707	0.9700	0.9383	
2	0.9275	0.9275	0.9268	0.9268	0.9268	0.9238	0.9253	0.9209	0.9076	0.9011	

表3 沿列定义距离下在不同维数时的识别率

l	38	34	30	26	22	18	14	10	6	2	r
38	0.9642	0.9686	0.9700	0.9722	0.9737	0.9759	0.9788	0.9817	0.9832	0.9582	
34	0.9679	0.9730	0.9737	0.9730	0.9752	0.9773	0.9781	0.9817	0.9832	0.9567	
30	0.9715	0.9730	0.9737	0.9737	0.9759	0.9781	0.9788	0.9832	0.9832	0.9560	
26	0.9708	0.9715	0.9722	0.9744	0.9752	0.9781	0.9781	0.9832	0.9846	0.9560	
22	0.9715	0.9723	0.9737	0.9730	0.9781	0.9803	0.9803	0.9839	0.9831	0.9546	
18	0.9708	0.9708	0.9723	0.9752	0.9774	0.9781	0.9796	0.9810	0.9810	0.9524	
14	0.9708	0.9715	0.9715	0.9737	0.9759	0.9781	0.9766	0.9824	0.9817	0.9479	
10	0.9700	0.9700	0.9715	0.9701	0.9708	0.9708	0.9752	0.9781	0.9743	0.9383	
6	0.9628	0.9635	0.9664	0.9679	0.9708	0.9700	0.9678	0.9656	0.9670	0.9405	
2	0.9158	0.9188	0.9180	0.9187	0.9187	0.9246	0.9246	0.9238	0.9121	0.9048	

5 结语

$(2D)^2LDA$ 直接在图像矩阵上提取特征,能从行和列两个方向消除相关性,大大降低了特征维数,缓解了“小样本”

问题。本文提出的 $W(2D)^2LDA$ 特征提取方法在两向二维鉴别准则的基础上对散度矩阵进行加入权值的改进,能够有效地克服“次优性”问题带来的不利影响,使提取的特征在类内更加凝聚、类间差异性更加合理,充分利用了训练样本的类别

信息,使得所求取的特征空间更加有利于正确分类。实验结果表明,在无方位角信息、较低特征维数时识别率仍可达到 98.47%;通过与其他方法比较,可以看出本文方法的识别性

能有了一定的提高,充分表明本文方法可行有效。由于通过加权来解决“次优性”问题,增加了训练样本的时间,如何减少训练时间是下一步需要研究的方向。

表 4 沿行和列定义距离下在不同维数时的识别率

<i>l</i>	<i>r</i>									
	38	34	30	26	22	18	14	10	6	2
38	0.9752	0.9752	0.9737	0.9766	0.9752	0.9774	0.9781	0.9810	0.9795	0.9568
34	0.9759	0.9759	0.9774	0.9781	0.9781	0.9795	0.9796	0.9788	0.9802	0.9575
30	0.9781	0.9781	0.9781	0.9788	0.9788	0.9795	0.9781	0.9810	0.9824	0.9575
26	0.9766	0.9759	0.9766	0.9781	0.9773	0.9788	0.9810	0.9832	0.9788	0.9597
22	0.9796	0.9795	0.9795	0.9795	0.9839	0.9839	0.9847	0.9810	0.9612	
18	0.9781	0.9781	0.9781	0.9788	0.9810	0.9817	0.9810	0.9839	0.9824	0.9597
14	0.9759	0.9759	0.9773	0.9781	0.9781	0.9803	0.9810	0.9824	0.9788	0.9509
10	0.9752	0.9759	0.9759	0.9766	0.9759	0.9773	0.9773	0.9795	0.9743	0.9369
6	0.9722	0.9708	0.9722	0.9737	0.9730	0.9730	0.9693	0.9678	0.9685	0.9398
2	0.9253	0.9239	0.9238	0.9224	0.9260	0.9297	0.9268	0.9223	0.9135	0.9055

表 5 不同方法的识别率比较

方法	识别率/%	特征维数
LDA ^[4]	89.01	—
KLDA ^[4]	97.95	—
2DLDA ^[16]	96.26	$48 \times 10 = 480$
2DPCA ^[11]	96.98	$128 \times 8 = 1024$
(2D) ² LDA ^[7] (沿行和列定义距离)	96.93	$12 \times 22 = 264$
(2D) ² MCSD ^[11] (沿行和列定义距离)	97.72	$24 \times 10 = 240$
沿行定义距离	98.32	$22 \times 10 = 220$
沿列定义距离	98.46	$26 \times 6 = 156$
W(2D) ² LDA 沿行和列 定义距离	98.47	$22 \times 10 = 220$

参考文献:

- [1] KAPLAN L M. Analysis of multiplicative speckle models for template-based SAR ATR [J]. IEEE Transactions on Aerospace and Electronic Systems, 2001, 37(4): 1424–1432.
- [2] ZHAO Q, PRINCIPE J C. Support vector machine for SAR automatic target recognition [J]. IEEE Transactions on Aerospace and Electronic Systems, 2001, 37(2): 643–654.
- [3] 韩萍, 吴仁彪, 王兆华, 等. 基于 KPCA 准则的 SAR 目标特征提取与识别[J]. 电子与信息学报, 2003, 25(10): 1297–1301.
- [4] 韩萍, 吴仁彪, 王兆华. 基于 KFD 准则的 SAR 目标特征提取与识别[J]. 现代雷达, 2004, 26(7): 27–30.
- [5] 胡利平, 刘宏伟, 吴顺君. 基于两级 2DPCA 的 SAR 目标特征提

取与识别[J]. 电子与信息学报, 2008, 30(7): 1722–1726.

- [6] 赵武锋, 沈海斌, 严晓浪. 直接 LDA 在人脸识别中的鉴别力分析 [J]. 浙江大学学报: 工学版, 2010, 44(8): 1479–1483.
- [7] 胡利平. 合成孔径雷达图像目标识别技术研究[D]. 西安: 西安电子科技大学, 2009.
- [8] 杜海顺, 柴秀丽, 汪凤泉, 等. 一种基于双向 2DLDA 特征融合的人脸识别方法[J]. 仪器仪表学报, 2009, 30(9): 1880–1885.
- [9] 刘水俊, 陈才扣, 王正群. 修正的最大散度差鉴别分析及人脸识别[J]. 电子与信息学报, 2008, 30(1): 190–193.
- [10] 邓泳聪, 谢宏威, 欧阳高飞, 等. 基于加权双向二维线性判别特征的焊点检测算法[J]. 华南理工大学学报: 自然科学版, 2010, 38(12): 35–40.
- [11] 胡利平, 刘宏伟, 尹奎英, 等. 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[J]. 航空学报, 2009, 30(12): 2380–2386.
- [12] LOOG M. Approximate pairwise accuracy criteria for multiclass linear dimension reduction: generalisations of the Fisher criterion [M]. Delft: Delft University Press, 1999.
- [13] 张贤达. 矩阵分析与应用[M]. 北京: 清华大学出版社, 2004: 540–547.
- [14] 俞王新. 计算机人脸检测与识别方法的研究[D]. 上海: 上海交通大学, 2009.
- [15] 胡利平, 刘宏伟, 吴顺君. 一种新的 SAR 图像目标识别预处理方法[J]. 西安电子科技大学学报: 自然科学版, 2007, 34(5): 733–737.
- [16] 张静, 王国宏, 杨智勇, 等. 基于二维子分类鉴别分析的 SAR 图像识别方法研究[J]. 电子学报, 2010, 38(4): 797–803.

(上接第 518 页)

- [13] TARDIF J P. Non-iterative approach for fast and accurate vanishing point detection [C]// ICCV'09: Proceedings of the 2009 IEEE International Conference on Computer Vision. Washington, DC: IEEE Computer Society, 2009: 1250–1257.
- [14] COUGHLAN J M, YUILLE A L. Manhattan world: compass direction from a single image by Bayesian inference [C]// ICCV'99: Proceedings of the 1999 IEEE International Conference on Computer Vision. Washington, DC: IEEE Computer Society, 1999: 941–947.
- [15] SCHMITT F, PRIESE L. Vanishing point detection with an intersection point neighborhood [C]// Proceedings of the 15th IAPR International Conference on Discrete Geometry for Computer Image-

ry. Berlin: Springer-Verlag, 2009: 132–143.

- [16] DENIS P, ELDER J H, ESTRADA F J. Efficient edge-based methods for estimating Manhattan frames in urban imagery [C]// Proceedings of the 10th European Conference on Computer Vision. Berlin: Springer-Verlag, 2008: 197–210.
- [17] 李畅, 张祖勋, 张永军. 灭点误差分布的理论精度评定[J]. 测绘学报, 2011, 40(3): 393–396.
- [18] 王丽. 面向建筑物重建的摄像机自标定方法研究[D]. 南昌: 南昌航空大学, 2012.
- [19] CAPRILE B, TORRE V. Using vanishing points for camera calibration [J]. International Journal of Computer Vision, 1990, 4(2): 127–140.