

基于两级 2DPCA 的 SAR 目标特征提取与识别

胡利平 刘宏伟 吴顺君

(西安电子科技大学雷达信号处理国家重点实验室 西安 710071)

摘要: 对二维图像用主分量分析(PCA)来提取特征具有准确估计协方差矩阵比较困难、计算复杂度大的缺点。二维 PCA(2DPCA)克服了 PCA 的局限性,但 2DPCA 仅去除了图像中各行像素间的相关性,因此它用于特征提取时得到的特征维数较大。该文采用两级 2DPCA 的图像特征提取方法,可进一步压缩特征维数,减少识别运算量。用运动和静止目标获取与识别(MSTAR)计划录取的合成孔径雷达(SAR)地面静止目标数据的实验结果表明,结合该文的预处理方法,两级 2DPCA 在大大降低了特征维数的同时,提高了识别率,且对目标方位角变化具有较强的鲁棒性。

关键词: 合成孔径雷达; 二维 PCA; 两级 2DPCA; 最近邻分类器

中图分类号: TN957.52

文献标识码: A

文章编号: 1009-5896(2008)07-1722-05

SAR Target Feature Extraction and Recognition Based on Two-Stage 2DPCA

Hu Li-ping Liu Hong-wei Wu Shun-jun

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

Abstract: Feature extraction based on PCA for 2 dimensional images has the disadvantages of evaluating the covariance matrix accurately with great difficulty and high computational complexity, 2-dimensional PCA (2DPCA) overcomes these flaws. However, a drawback of 2DPCA is that it needs more features, since it only eliminates the correlations between rows. In this paper, two-stage 2DPCA is applied to further compress the dimensions of features and decrease the recognition computation. Experimental results performing on SAR ground targets based the Moving and Stationary Target Acquisition and Recognition (MSTAR) database indicate that two-stage 2DPCA combining with the pre-processing method in this paper not only decreases sharply feature dimensions, but increases recognition rate, and is robust to the variation of target azimuth.

Key words: SAR; 2DPCA; Two-stage 2DPCA; Nearest neighbor classifier

1 引言

随着遥感技术的发展,合成孔径雷达(SAR)越来越受到广泛关注^[1]。目前,基于SAR地面目标识别已有大量文献,它们在预处理、特征提取和分类器设计等方面各有特点。文献[2]采用模板匹配的识别算法;文献[3,4]是在图像域内直接用支撑向量机(SVM)完成目标识别。文献[5]用主分量分析(PCA)、核主分量分析(KPCA)提取特征,用SVM识别。上述这些方法的缺点就是没有将目标从杂波背景中分割出来,由于地面目标所处背景杂波具有多样性,不同的背景杂波特性会影响识别性能。因此,需要将目标从杂波背景中分割出来。

PCA 是经典的特征提取方法,但它用于图像的特征提取时要将二维图像矩阵转换成一维向量,这样会导致特征提取要在高维向量空间中进行,但在高维空间中很难准确估计协方差矩阵且维数很大。而 2DPCA^[6]直接采用二维图像,估

计协方差矩阵更准确有效且维数远小于 PCA。但 2DPCA 仅去除了图像各行像素间的相关性,因此得到的特征维数较大。为了进一步压缩特征维数,本文采用两级 2DPCA 的特征提取方法。

2 SAR 图像预处理

原始 SAR 图像中既包含感兴趣的目标,又包含大量的背景杂波,如图 1(a)所示,对其进行预处理,将目标从杂波背景中提取出来,其实现步骤如下:

(1)作对数变换 SAR 图像通常是非高斯的,且存在大量乘性相干斑。对数变换可将相干斑由乘性变为加性^[7],使图像更适合用高斯分布描述。设 $F(x, y)$ 是原始图像的幅度矩阵 F 的第 (x, y) 个像素点,对其作对数变换,得

$$G(x, y) = 10 \lg[F(x, y) + 0.001] + 30 \quad (1)$$

由于对数变换在零点没有定义,所以在变换前对原图像加一个小常数(0.001),为了保证变换后图像灰度值仍非负,在最后加一个相应的常数(30)。

(2)自适应阈值分割 估计当前图像 G 的均值 μ 和方差

σ 。假定目标强度基本大于背景强度,对 \mathbf{G} 的每个像素点 (x,y) ,有

$$\begin{cases} (x,y) \in \mathbf{T}_{ar}, \mathbf{T}_{ar}(x,y) = 1, \mathbf{G}(x,y) > \mu + c\sigma \\ (x,y) \in \mathbf{B}_{ac}, \mathbf{T}_{ar}(x,y) = 0, \text{其他} \end{cases} \quad (2)$$

其中 \mathbf{T}_{ar} 代表目标, \mathbf{B}_{ac} 代表背景, c 由训练样本先验地统计得到。

(3)形态学滤波和几何聚类操作 由于相干斑的存在,阈值分割后的图像中不可避免地会有许多伪目标,在目标内部也可能有一些“小洞”,如图1(b)所示。为了得到平滑干净的目标图像,对 \mathbf{T}_{ar} 进行形态学滤波^[8]和几何聚类操作^[9]。

形态学滤波的目的是平滑边界,去除尖凸,切断细长的搭界,接合窄的缺口,填充凹处,去除小洞等。

一般情况下,上述处理后的图像中还可能包含一些非目标区域,与目标相比,它们小很多,如图1(c)所示。几何聚类的目的是去除这些区域,方法如下:首先检测出所有独立的连通区域,对它们进行标号,然后统计每个区域的面积,面积最大的区域即是我们感兴趣的,于是得到平滑干净的目标图像,如图1(d)所示。




图1 预处理前后的SAR图像(T72)

将上述处理后的 \mathbf{T}_{ar} 与对数图像 \mathbf{G} 作像素点乘运算,得到的图像即为去掉杂波后的目标图像 \mathbf{H} 。

(4)图像增强和归一化处理 本文采用基于幂变换的灰度变换增强方法^[8],对图像的每个像素点作幂变换,即 $\mathbf{K}(x,y) = [\mathbf{H}(x,y)]^\alpha$, α 是常数。

为了去除目标相对于雷达的距离不同产生的影响,对目标图像作能量归一化处理,即

$$\mathbf{J}(x,y) = \mathbf{K}(x,y) / \sqrt{\sum_x \sum_y |\mathbf{K}(x,y)|^2}$$

由于目标在场景中具有位置不确定性,取傅里叶变换的幅频,以保证目标具有平移不变性。由于傅里叶幅频是对称的,只需用一半的幅频信息作为特征提取的输入即可,这样可降低样本维数,减小运算量。

3 SAR图像特征提取

特征提取是目标识别的关键步骤之一。若用图像的全部像素点作为特征,则维数过大,对内存、运算量要求较高,还会出现信息冗余造成识别性能损失。下面分别介绍2DPCA和两级2DPCA的特征提取方法。

3.1 基于2DPCA的特征提取方法

假设预处理后的训练样本集为 $\{\mathbf{I}_1, \mathbf{I}_2, \dots, \mathbf{I}_M\}$,且 $\mathbf{I}_i \in \mathbf{R}^{m \times n}, i = 1, 2, \dots, M$, M 为训练样本总数。将样本中心化,即 $\tilde{\mathbf{I}}_i = \mathbf{I}_i - \bar{\mathbf{I}}$,其中 $\bar{\mathbf{I}} = \frac{1}{M} \sum_{i=1}^M \mathbf{I}_i$ 为全部训练图像的均值。 $\tilde{\mathbf{I}}_i$ 作以下线性投影

$$\mathbf{A}_i = \tilde{\mathbf{I}}_i \mathbf{W} \quad (3)$$

投影矩阵 $\mathbf{W} \in \mathbf{R}^{n \times r}$ 满足: $\mathbf{W}^T \mathbf{W} = \mathbf{I}_r$, \mathbf{I}_r 是 $r \times r$ 的单位阵。重建样本 \mathbf{I}_i : $\mathbf{I}_i^{(\text{Rec})} = \bar{\mathbf{I}} + \mathbf{A}_i \mathbf{W}^T = \bar{\mathbf{I}} + \tilde{\mathbf{I}}_i \mathbf{W} \mathbf{W}^T$,则 \mathbf{I}_i 的重建误差为 $\|\mathbf{I}_i - \mathbf{I}_i^{(\text{Rec})}\|$ 。最优投影矩阵 \mathbf{W}_{opt} 应使所有训练样本的重建误差之和最小

$$\begin{aligned} \mathbf{W}_{\text{opt}} &= \arg \min_{\mathbf{W}} \sum_{i=1}^M \|\mathbf{I}_i - \mathbf{I}_i^{(\text{Rec})}\|_{\text{F}}^2 \\ &= \arg \min_{\mathbf{W}} \sum_{i=1}^M \|\tilde{\mathbf{I}}_i - \tilde{\mathbf{I}}_i \mathbf{W} \mathbf{W}^T\|_{\text{F}}^2 \end{aligned} \quad (4)$$

其中 $\|\cdot\|_{\text{F}}$ 为矩阵的F-范数。经推导,有

$$\sum_{i=1}^M \|\tilde{\mathbf{I}}_i - \tilde{\mathbf{I}}_i \mathbf{W} \mathbf{W}^T\|_{\text{F}}^2 = \sum_{i=1}^M \text{tr}(\tilde{\mathbf{I}}_i \tilde{\mathbf{I}}_i^T) - \sum_{i=1}^M \text{tr}(\mathbf{W}^T \tilde{\mathbf{I}}_i^T \tilde{\mathbf{I}}_i \mathbf{W}) \quad (5)$$

则式(4)等价于

$$\begin{aligned} \mathbf{W}_{\text{opt}} &= \arg \max_{\mathbf{W}} \text{tr}(\mathbf{W}^T \tilde{\mathbf{I}}_i^T \tilde{\mathbf{I}}_i \mathbf{W}) \\ &= \arg \max_{\mathbf{W}} \sum_{i=1}^M \text{tr}[\mathbf{W}^T (\mathbf{I}_i - \bar{\mathbf{I}})^T (\mathbf{I}_i - \bar{\mathbf{I}}) \mathbf{W}] \\ &= \arg \max_{\mathbf{W}} \text{tr}(\mathbf{W}^T \mathbf{G}_t \mathbf{W}) \end{aligned} \quad (6)$$

其中 $\mathbf{G}_t = \sum_{i=1}^M (\mathbf{I}_i - \bar{\mathbf{I}})^T (\mathbf{I}_i - \bar{\mathbf{I}})$ 为训练样本的总体散布矩阵。则最优投影矩阵 $\mathbf{W}_{\text{opt}} = [\omega_1, \omega_2, \dots, \omega_r] \in \mathbf{R}^{n \times r} (r < n)$,即

\mathbf{W}_{opt} 的列向量是 \mathbf{G}_t 的前 r 个大特征值对应的特征向量。训练样本 \mathbf{I}_i 向 \mathbf{W}_{opt} 投影,得到特征矩阵 \mathbf{B}_i 为

$$\mathbf{B}_i = [\mathbf{y}_1^{(i)}, \dots, \mathbf{y}_r^{(i)}] = (\mathbf{I}_i - \bar{\mathbf{I}}) \mathbf{W}_{\text{opt}} \in \mathbf{R}^{m \times r}, i = 1, 2, \dots, M \quad (7)$$

任给一幅待测目标图像 $\mathbf{I} \in \mathbf{R}^{m \times n}$ 向 \mathbf{W}_{opt} 投影,得到其特征矩阵 \mathbf{B} 为

$$\mathbf{B} = [\mathbf{y}_1, \dots, \mathbf{y}_r] = (\mathbf{I} - \bar{\mathbf{I}}) \mathbf{W}_{\text{opt}} \in \mathbf{R}^{m \times r} \quad (8)$$

3.2 基于两级的2DPCA的特征提取方法

2DPCA去除了图像各行像素间的相关性,但图像各列像素间的相关性依然存在。因此,它得到的特征维数还有降低的空间。本文采用两级2DPCA,可压缩特征维数,减小识别运算量。具体步骤如下:

(1)预处理后的训练图像集为 $\{\mathbf{I}_1, \mathbf{I}_2, \dots, \mathbf{I}_M\}$ 。按3.1节方法计算投影矩阵,称其为行投影矩阵,记为 $\mathbf{W}_{\text{opt}} \in \mathbf{R}^{n \times \eta} (\eta < n)$,并计算训练图像的特征矩阵 $\mathbf{A}_i \in \mathbf{R}^{m \times \eta}, i = 1, 2, \dots, M$ 。

(2)将上一步求得的训练图像的特征矩阵转置后当作新的训练样本 $\mathbf{Z}_i = \mathbf{A}_i^T \in \mathbf{R}^{\eta \times m}, i = 1, 2, \dots, M$,重复上述2DPCA特征提取过程,计算列投影矩阵 $\mathbf{W}_{\text{opt}} \in \mathbf{R}^{m \times \eta_2} (\eta_2 < m)$ 。则训练样本 \mathbf{I}_i 经两级2DPCA特征提取后得到特

征矩阵

$$\begin{aligned} \mathbf{B}_i &= \mathbf{Z}_i \mathbf{W}_{\text{copt}} = \mathbf{A}_i^T \mathbf{W}_{\text{copt}} \\ &= \mathbf{W}_{\text{ropt}}^T (\mathbf{I}_i - \bar{\mathbf{I}})^T \mathbf{W}_{\text{copt}} \in \mathbb{R}^{r_1 \times r_2}, \quad i = 1, 2, \dots, M \end{aligned} \quad (9)$$

任给一幅待测目标图像 $\mathbf{I} \in \mathbb{R}^{m \times n}$, 同时向 \mathbf{W}_{ropt} 和 \mathbf{W}_{copt} 投影, 得到该待测图像的特征矩阵 \mathbf{B} 为

$$\mathbf{B} = \mathbf{W}_{\text{ropt}}^T (\mathbf{I} - \bar{\mathbf{I}})^T \mathbf{W}_{\text{copt}} \in \mathbb{R}^{r_1 \times r_2} \quad (10)$$

4 分类器设计

本文采用基于距离的最近邻分类器对目标进行分类, 即计算待测样本的特征矩阵 \mathbf{B} 与 M 个训练样本的特征矩阵 $\mathbf{B}_1, \mathbf{B}_2, \dots, \mathbf{B}_M$ 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。下面分别介绍 2DPCA 特征的距离定义和两级 2DPCA 特征的 3 种距离定义。

4.1 基于 2DPCA 特征的分类

待测图像 \mathbf{I} 和训练图像 \mathbf{I}_i 的 2DPCA 特征为 $\mathbf{B} = [\mathbf{y}_1, \dots, \mathbf{y}_r] \in \mathbb{R}^{m \times r}$, $\mathbf{B}_i = [\mathbf{y}_1^{(i)}, \dots, \mathbf{y}_r^{(i)}] \in \mathbb{R}^{m \times r}$, 其中 $\mathbf{y}_k = (\mathbf{I} - \bar{\mathbf{I}}) \boldsymbol{\omega}_k \in \mathbb{R}^{m \times 1}$, $\mathbf{y}_k^{(i)} = (\mathbf{I}_i - \bar{\mathbf{I}}) \boldsymbol{\omega}_k \in \mathbb{R}^{m \times 1}$, $k = 1, 2, \dots, r$, $i = 1, 2, \dots, M$ 。定义待测图像与第 i 个训练图像的距离为

$$d(\mathbf{B}, \mathbf{B}_i) = \sum_{k=1}^r \|\mathbf{y}_k - \mathbf{y}_k^{(i)}\|_2 \quad (11)$$

4.2 基于两级 2DPCA 特征的分类

待测图像 \mathbf{I} 和训练图像 \mathbf{I}_i 的两级 2DPCA 特征为 $\mathbf{B} \in \mathbb{R}^{r_1 \times r_2}$, $\mathbf{B}_i \in \mathbb{R}^{r_1 \times r_2}$, $i = 1, 2, \dots, M$ 。

(1)沿行定义距离: 不妨将特征矩阵 \mathbf{B} , \mathbf{B}_i 写成如下形式: $\mathbf{B} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{r_1}]^T$, $\mathbf{B}_i = [\mathbf{x}_1^{(i)}, \mathbf{x}_2^{(i)}, \dots, \mathbf{x}_{r_1}^{(i)}]^T$, 其中 \mathbf{x}_{k_1} , $\mathbf{x}_{k_1}^{(i)}$ 是 r_2 维的行向量。定义两特征矩阵之间的距离为

$$d_1(\mathbf{B}, \mathbf{B}_i) = \sum_{k_1=1}^{r_1} \|\mathbf{x}_{k_1} - \mathbf{x}_{k_1}^{(i)}\|_2 \quad (12)$$

(2)沿列定义距离: 将特征矩阵 \mathbf{B} , \mathbf{B}_i 写成如下形式: $\mathbf{B} = [\mathbf{y}_1, \dots, \mathbf{y}_{r_2}]$, $\mathbf{B}_i = [\mathbf{y}_1^{(i)}, \dots, \mathbf{y}_{r_2}^{(i)}]$, 其中 \mathbf{y}_{k_2} , $\mathbf{y}_{k_2}^{(i)}$ 是 r_1 维的列向量。定义两特征矩阵之间的距离为

$$d_2(\mathbf{B}, \mathbf{B}_i) = \sum_{k_2=1}^{r_2} \|\mathbf{y}_{k_2} - \mathbf{y}_{k_2}^{(i)}\|_2 \quad (13)$$

(3)沿行和列定义距离: 综合(1), (2)定义待测图像与第 i 个训练图像之间的距离为 $d(\mathbf{B}, \mathbf{B}_i) = d_1(\mathbf{B}, \mathbf{B}_i) + d_2(\mathbf{B}, \mathbf{B}_i)$ 。

5 实验结果

实验所用的数据是 MSTAR 计划录取的实测 SAR 地面静止目标数据。训练样本是 SAR 在俯仰角 17° 时对地面目标的成像数据, 包括 BMP2sn_9563(233 个), BTR70sn_c71(233 个)和 T72sn_132(232 个)。测试样本是 SAR 在俯仰角 15° 时对地面目标的成像数据, 包括 BMP2sn_9563(195 个), BMP2sn_9566(196 个), BTR70sn_c71(196 个), T72sn_132(196 个), T72sn_812(195 个)和 T72sn_s7(191 个)。样本方位范围是 $0^\circ \sim 360^\circ$ 。

以 T72 为例分析对数变换的作用及图像增强时幂次不同对目标图像质量的影响。由于原始 SAR 图像中存在乘性相干斑, 且整体灰度值较低, 目标的许多细节不可见, 如图 2(a)所示。对数变换, 一方面将相干斑由乘性变为加性, 使图像更适合用高斯分布描述便于阈值分割, 另一方面扩展目标的灰度值, 显示出更多的细节。但目标内部的对比度却下降了, 如图 2(d)所示, 因此对比度增强是必需的, 这可由幂次 $\alpha > 1$ 的幂变换实现。从图 2(e)~图 2(h)看出, α 从 2 增大到 4, 图像对比度明显增强, 但当 α 再增大时, 目标中有些地方太暗, 从而丢失一些细节。因此得出, 对比度、可辨别细节的最好增强效果在 $\alpha = 4$ 左右。




图2 幂次取不同值时对图像质量的影响(T72)

图 3 给出幂次 α 取不同值时 2DPCA 的识别性能。得出, $\alpha = 3.5$ 时识别结果最好(以下实验中如不指明 α 均取 3.5)。由于幂次 α 的选择对识别性能的影响很难从数学上进行准确描述, 在实际应用中可基于训练和测试数据进行预设 α 的值。

在 SAR 目标识别中, 不同的预处理会严重影响识别性能。下面对比几种预处理方法的性能, 它们是: 方法 1, 对原始图像的幅度矩阵作归一化的对数变换后取一半的傅里叶幅频; 方法 2, 将第 2 节得到的二值矩阵 \mathbf{T}_{ar} 与原始图像 \mathbf{F} 掩模得到目标强度图像, 对它直接能量归一化, 再取一半的傅里叶幅频; 方法 3, 对方法 2 的目标强度图像, 先作幂变换对其增强, 再作能量归一化, 其它同方法 2; 方法 4, 将 \mathbf{T}_{ar} 与对数图像 \mathbf{G} 掩模获得目标图像, 直接对其能量归一化, 其它步骤同方法 2; 方法 5, 即本文第 2 节所述的预处理方法。图 4 给出了结合以上 5 种预处理方法 2DPCA 的识别性能。方法 1 的结果最差, 这是因为它没有将目标从背景杂波中分割出来, 大量背景杂波严重干扰了对目标的识别。方法 5 与方法 4、方法 3 与方法 2 相比, 都多了一步基于幂变换的图像增强, 结果表明基于幂变换的图像增强是有效的。方法 5 与方法 3 的区别是, 前者是对 \mathbf{T}_{ar} 与对数图像 \mathbf{G} 掩模的图像作增强(图 3 表明幂次取 3.5 时结果最优), 后者是对 \mathbf{T}_{ar} 与




图3 幂次 α 取不同值时的识别性能




图4 不同预处理下, 2DPCA 识别性能

始图像 F 掩模的图像作增强(同图3的方法得幂次取0.6时结果最优), 由于对数变换的作用, 所以前者的识别性能优于后者。比较所有结果得出, 本文的预处理方法是有效的。

表1给出结合上述方法3和本文预处理方法, 2DPCA和两级2DPCA的识别结果, 并与文献[2,3,5]进行对比。从该表看到, 文献[2,3,5]的识别结果均低于本文, 这是因为: 首先, 文献[2,3,5]均没有将目标从杂波背景中提取出来, 大量杂波的存在影响了识别性能; 其次, 文献[2,3]没有进行特征提取, 而有效的特征提取有助于提高识别性能, 文献[5]用PCA和KPCA在提取特征时要将二维图像矩阵变成一维向量, 损失了目标的空间信息。而本文方法先将目标从杂波背景中提取出来, 减弱了背景杂波的影响, 再采用图像增强操作突出目标的有用信息, 且在特征提取时直接基于二维图像, 完整地保留了目标的二维空间结构信息, 估计协方差矩阵更准确有效, 所以获得较好的识别性能。两种不同预处理下的性能对比进一步验证了本文预处理的有效性。结合本文预处理, 两级2DPCA在大大降低了特征维数的同时, 又提高了识别性能。但两级2DPCA提取特征后, 按不同方式定义距离, 得到的识别结果大致相当。

某些情况下可获得目标的姿态信息, 利用这些信息可以改善识别性能。训练时, 将每一类训练样本在 $0^\circ \sim 360^\circ$ 内按

表1 不同预处理下, 各种方法的最优识别性能对比

识别方法	识别率(%)
模板匹配(文献[2])	40.76
SVM(文献[3])	90.92
线性PCA+SVM(文献[5])	84.54
KPCA+SVM(文献[5])	91.50
2DPCA(预处理方法3)	96.84
两级2DPCA(预处理方法3, 沿行定义距离)	96.75
两级2DPCA(预处理方法3, 沿列定义距离)	96.35
两级2DPCA(预处理方法3, 沿行和列定义距离)	96.61
2DPCA(本文预处理方法)	97.12
两级2DPCA(本文预处理方法, 沿行定义距离)	97.49
两级2DPCA(本文预处理方法, 沿列定义距离)	97.44
两级2DPCA(本文预处理方法, 沿行和列定义距离)	97.52

等方位间隔分组, 对3类训练样本, 在相同的方位组内进行特征提取。识别时, 利用待识别样本的方位信息, 选出相应的方位单元进行分类。本文将每类训练样本按 180° , 90° 和 30° 间隔分组。表2给出不同方位间隔分组情况下2DPCA, 两级2DPCA的最优识别结果, 并与文献的结果进行对比。从该表看出, 利用目标的方位信息本文方法的识别性能仍优于文献[2,3,5], 且对目标方位角变化具有较好的鲁棒性, 同时进一步验证了两级2DPCA在降低了特征维数的同时, 又提高了识别率。

表2 不同方位间隔分组情况下, 各种方法的最优识别性能(%)对比

识别方法	180°	90°	30°
模板匹配(文献[2])	45.79	56.92	70.55
SVM(文献[3])	89.89	88.35	90.62
线性PCA+SVM(文献[5])	92.38	95.46	95.16
KPCA+SVM(文献[5])	88.79	95.02	93.85
2DPCA(预处理方法3)	97.62	97.68	97.45
两级2DPCA(预处理方法3, 沿行定义距离)	97.96	98.08	98.12
两级2DPCA(预处理方法3, 沿列定义距离)	97.60	98.25	98.44
两级2DPCA(预处理方法3, 沿行和列定义距离)	97.84	98.18	98.59
2DPCA(本文预处理方法)	98.05	97.94	98.06
两级2DPCA(本文预处理方法, 沿行定义距离)	98.21	98.50	98.42
两级2DPCA(本文预处理方法, 沿列定义距离)	98.49	98.54	98.96
两级2DPCA(本文预处理方法, 沿行和列定义距离)	98.52	98.51	98.84

6 结束语

本文给出有效的SAR图像预处理方法, 去除了背景杂波的影响, 获得了平滑干净的目标图像, 并且将两级2DPCA用于SAR目标特征提取。通过与2DPCA和其它方法比较, 证明本文预处理方法是有效的, 两级2DPCA大大降低了特征维数, 减小了识别运算量, 提高了识别性能, 并且对目标方位变化具有较好的鲁棒特性, 降低了对目标方位估计的精度要求。

参考文献

[1] 郭华东. 感知天地—信息获取与处理技术. 第1版. 北京: 科学出版社, 2000, 第2章.

[2] Ross T, Worrell S, and Velten V, *et al.* Standard SAR ATR evaluation experiment using the MSTAR public release data set. SPIE Conf. on Algorithms for SAR, 1998, 3370: 566-573.

- [3] Zhao Q and Principe J C. Support Vector machine for SAR automatic target recognition. *IEEE Trans. on Aerospace and Electronic Systems*, 2001, 37(2): 643-654.
- [4] Bryant M and Garber F. SVM classifier applied to the MSTAR public data set. SPIE Conf. on Algorithms for SAR, 1999, 3721: 355-360.
- [5] 韩萍, 吴仁彪, 王蕴红, 等. 基于 KPCA 准则的 SAR 目标特征提取与识别. 电子与信息学报, 2003, 25(10): 1297-1301.
Han Ping, Wu Ren-biao, and Wang Yun-hong, *et al.* SAR automatic target recognition based on KPCA criterion. *Journal of Electronics & Information Technology*, 2003, 25(10): 1297-1301.
- [6] Yang J, Zhang D, and Frangi A F, *et al.* Two-dimensional PCA: A new approach to appearance-based face representation and recognition. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2004, 26(1): 131-137.
- [7] Casasent D and Ashizawa S. Synthetic aperture radar detection, recognition and clutter rejection with new minimum noise and correlation energy filters. *Optical Engineering*, 1997, 36(10): 2729-2736.
- [8] Gonzalez R C and Woods R E. Digital Image Processing. Second Edition, New York: Prentice-Hall, 2003, chapter 3.
- [9] Musman S and Kerr D. Automatic recognition of ISAR ship images. *IEEE Trans. on Aerospace and Electronic Systems*, 1996, 32(4): 1392-1404.
- 胡利平: 女, 1979年生, 博士生, 研究方向为合成孔径雷达图像处理及目标识别.
- 刘宏伟: 男, 1971年生, 教授, 博士生导师, 研究方向为雷达信号处理、雷达自动目标识别等.
- 吴顺君: 男, 1942年生, 教授, 博士生导师, 研究方向为雷达系统、雷达信号处理等.