

结合 KPCA 和稀疏表示的 SAR 目标识别方法研究

韩 萍 王 欢

(中国民航大学智能信号与图像处理天津市重点实验室, 天津 300300)

摘 要: 提出了一种结合 KPCA (Kernel Principal Component Analysis) 和稀疏表示的合成孔径雷达 (Synthetic Aperture Rader, SAR) 目标识别方法。该方法首先利用 KPCA 方法提取样本特征, 然后在特征空间内构造稀疏表示模型, 通过梯度投影法 (Gradient Projection for Sparse Reconstruction, GPSR) 求得测试样本的稀疏系数, 最后根据稀疏系数的能量特征实现分类识别。利用美国运动和静止目标获取与识别 (Moving and Stationary Target Acquisition and Recognition, MSTAR) 实测 SAR 数据进行实验, 实验结果表明该方法在方位角未知的情况下平均识别率达到 96.78%, 能够明显地提高目标的识别结果, 是一种有效的 SAR 目标识别方法。

关键词: 目标识别; 合成孔径雷达; 核主成分分析; 稀疏表示; 梯度投影法

中图分类号: TP753 文献标识码: A 文章编号: 1003-0530(2013)12-1696-06

Research on the Synthetic Aperture Rader Target Recognition Based on KPCA and Sparse Representation

HAN Ping WANG Huan

(Tianjin Key Lab for Advanced Signal Processing, CAUC, Tianjin 300300, China)

Abstract: SAR (Synthetic Aperture Rader) target recognition method based on KPCA and sparse representation is proposed. First, KPCA (Kernel Principal Component Analysis) feature extraction is used to get the feature of the samples. Then a sparse representation model is built in the feature space. The sparse coefficient is obtained by GPSR (Gradient Projection for Sparse Reconstruction). Finally, the recognition is achieved by computing the energy of the sparse coefficient. Experimental results with MSTAR (Moving and Stationary Target Acquisition and Recognition) SAR data sets show that the average recognition rate with the proposed method is up to 96.78% without knowing the target azimuth which can improve the target recognition result. And the proposed method is a effective method for SAR target recognition.

Key words: Target Recognition; Synthetic Aperture Rader; Kernel Principal Component Analysis; Sparse Representation; Gradient Projection for Sparse Reconstruction

1 引言

SAR 自动目标识别 (Automatic Target Recognition, ATR) 技术在战场感知方面非常重要, 一直是国内外学者研究的热门课题。特征提取是 SAR ATR 的关键技术之一, 文献 [1] 针对 SAR 图像特征提取与选择进行了深入的研究, 其中代表性的特征提取方法有主成分分析 (Principal Component Analysis,

PCA)^[2]、独立分量分析 (Independent Component Analysis, ICA)^[3] 以及线性判别分析 (Linear Discriminant Analysis, LDA)^[4] 等。这几种特征提取方法对具有线性可分特性的样本非常有效, 当样本非线性可分时, 可通过核函数将样本映射到高维空间使其线性可分, 如 KPCA 方法、KFD 方法等。文献 [5-6] 分别将 KPCA 方法和 KFD 方法运用到 SAR 目标识别中, 实验结果表明, 与线性特征提取方法相比, 基

于 KPCA 和 KFD 的非线性特征提取方法不仅能够提高目标识别率,同时具有良好的推广性和对目标方位变化的不敏感性。

近几年压缩感知^[7]理论的提出为稀疏表示的发展提供了工程应用的土壤,得到很多学者的广泛关注并被应用到多个领域。在 SAR 目标识别方面,文献[8]提出了一种基于主成分分析和稀疏表示的 SAR 图像目标识别方法,该方法将 PCA 特征提取方法和稀疏表示特征提取方法融合,利用最近邻法进行目标分类,结果表明在没有预处理的情况下,该算法仍能够有效地识别目标。

本文提出了一种结合 KPCA 和稀疏表示的 SAR 目标识别新方法。该方法将样本通过核函数映射到高维特征空间,在高维空间进行 PCA 特征提取,同时提取样本的稀疏特征,最后通过稀疏系数的能量进行分类。用 MSTAR 数据对该方法进行验证,结果表明该方法在方位角未知的情况下能够有效提高目标识别率。

2 基于 KPCA 和稀疏表示的 SAR 目标识别

2.1 KPCA 特征提取方法

基于 KPCA 特征提取^[9]的主要思想是通过一个非线性映射将样本映射到一个高维特征空间,在此空间上进行 PCA 特征提取,以便更好的描述不同类别样本的特征。

设有样本集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, 其中 $\mathbf{x}_i \in \mathbf{R}^M$, N 表示样本总数,通过非线性映射 $\Phi(\mathbf{x})$ 映射到高维特征空间 \mathbf{H} 中,假设样本已经中心化,则定义 \mathbf{H} 空间中样本的协方差矩阵为:

$$\mathbf{C} = \frac{1}{N} \sum_{i=1}^N \Phi(\mathbf{x}_i) \Phi(\mathbf{x}_i)^T \quad (1)$$

对 \mathbf{C} 进行特征值分解:

$$\mathbf{C}\mathbf{v}^r = \lambda_r \mathbf{v}^r \quad (2)$$

其中 \mathbf{v}^r 是特征值 λ_r 对应的特征向量, $r=1, 2, \dots, N$ 。 \mathbf{C} 的特征值一般为非负,设 $0 \leq \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_N$, 对应的特征向量分别为 $\mathbf{v}^1, \mathbf{v}^2, \dots, \mathbf{v}^N$, 它们可由 \mathbf{H} 空间中的样本 $\Phi(\mathbf{x}_i)$ 张成,记

$$\mathbf{v}^r = \sum_{i=1}^N \alpha_i^r \Phi(\mathbf{x}_i) \quad (3)$$

α_i^r 表示第 i 个样本对应的系数,将(2)式两边同时乘以 $\Phi(\mathbf{x}_k)$ 可得:

$$\Phi(\mathbf{x}_k) \cdot \mathbf{C}\mathbf{v}^r = \lambda_r (\Phi(\mathbf{x}_k) \cdot \mathbf{v}^r) \quad (4)$$

将式(1)和(3)代入(4),并令 $\mathbf{K}_{ij} = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j))$, $i, j=1, 2, \dots, N$, 得

$$\mathbf{N}\lambda_r \mathbf{a}^r = \mathbf{K}\mathbf{a}^r \quad (5)$$

其中 $\mathbf{K} = [\mathbf{K}_{1,1}, \dots, \mathbf{K}_{1,N}; \dots; \mathbf{K}_{i,j}, \dots; \dots; \mathbf{K}_{N,1}, \dots, \mathbf{K}_{N,N}]$, $\mathbf{N}\lambda_r$ 是 \mathbf{K} 的特征值, $\mathbf{a}^r = [\alpha_1^r, \alpha_2^r, \dots, \alpha_N^r]^T$ 是对应的特征向量。设 \mathbf{C} 的大于零特征值所对应的特征向量分别为 $\mathbf{v}^{N-L+1}, \mathbf{v}^{N-L+2}, \dots, \mathbf{v}^N$ (L 表示大于零的特征值个数), 此时样本 $\Phi(\mathbf{x})$ 在 \mathbf{v}^m ($m=N-L+1, N-L+2, \dots, N$) 上的投影:

$$g_m(\mathbf{x}) = (\mathbf{v}^m \cdot \Phi(\mathbf{x})) = \sum_{i=1}^N \alpha_i^m (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x})) \quad (6)$$

$g_m(\mathbf{x})$ 表示 $\Phi(\mathbf{x})$ 的第 m 个非线性主分量,将所有投影值形成一个向量 $\mathbf{V} = [g_{N-L+1}(\mathbf{x}), g_{N-L+2}(\mathbf{x}), \dots, g_N(\mathbf{x})]^T$ 作为样本的特征。

2.2 样本的稀疏表示

模式识别的基本问题是利用已知类别的训练样本来确定测试样本的类别。假设第 i 类有 N_i 个训练样本,则由这 N_i 个训练样本构成一个矩阵 $\mathbf{s}_i = [\mathbf{s}_i^1, \dots, \mathbf{s}_i^j, \dots, \mathbf{s}_i^{N_i}] \in \mathbf{R}^{m \times N_i}$, 其中 $\mathbf{s}_i^j \in \mathbf{R}^m$ 表示第 i 类的第 j 个样本构成的列向量。对于 q 类训练样本可构成一个新的训练样本矩阵即过完备字典 $\mathbf{A} = [\mathbf{s}_1^1, \dots, \mathbf{s}_1^{N_1}, \mathbf{s}_2^1, \dots, \mathbf{s}_2^{N_2}, \dots, \mathbf{s}_q^1, \dots, \mathbf{s}_q^{N_q}] \in \mathbf{R}^{m \times N}$, 其中 $N = \sum_{i=1}^q N_i$ 。当第 i 类有足够多的训练样本时,任意同类别的测试样本 $\mathbf{y} \in \mathbf{R}^m$ 可以近似表示为该训练样本的线性组合^[10]:

$$\mathbf{y} = \beta_1^1 \mathbf{s}_1^1 + \dots + \beta_j^i \mathbf{s}_i^j + \dots + \beta_i^{N_i} \mathbf{s}_i^{N_i} \quad (7)$$

其中 β_j^i 表示第 i 类的第 j 个样本对应的系数。

第 i 类测试样本也同样可以用所有训练样本线性表示,即:

$$\mathbf{y} = 0 \times \mathbf{s}_1^1 + \dots + 0 \times \mathbf{s}_1^{N_1} + \dots + \beta_1^i \mathbf{s}_i^1 + \dots + \beta_i^{N_i} \mathbf{s}_i^{N_i} + \dots + 0 \times \mathbf{s}_q^1 + \dots + 0 \times \mathbf{s}_q^{N_q} \quad (8)$$

写成矩阵形式:

$$\mathbf{y} = \mathbf{A}\boldsymbol{\beta} \quad (9)$$

其中 $\boldsymbol{\beta} = [0, \dots, 0, \dots, \beta_1^i, \dots, \beta_i^{N_i}, \dots, 0, \dots, 0]^T \in \mathbf{R}^N$ 是测试样本的稀疏系数向量。理想情况下, $\boldsymbol{\beta}$ 中只有与测试样本同类的第 i 类训练样本系数非零,其他类系数都为零,因此可以用 $\boldsymbol{\beta}$ 作为样本特征进行分类识别。

对于式(9),求解稀疏系数 $\boldsymbol{\beta}$, 即是求解以下的优化问题:

$$\hat{\boldsymbol{\beta}} = \arg \min \|\boldsymbol{\beta}\|_1 \quad s. t. \mathbf{A}\boldsymbol{\beta} = \mathbf{y} \quad (10)$$

当样本中存在噪声时,式(9)可以写成

$$\mathbf{y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{n} \quad (11)$$

其中 \mathbf{n} 表示噪声,其能量边界为 $\|\mathbf{n}\|_2 < \varepsilon$,式(11)中的稀疏系数可以通过以下的1-范数优化方法来求解:

$$\hat{\boldsymbol{\beta}} = \arg \min \|\boldsymbol{\beta}\|_1 \quad s. t. \|\mathbf{A}\boldsymbol{\beta} - \mathbf{y}\|_2 \leq \varepsilon \quad (12)$$

式(12)求解稀疏系数的问题又可以转化为带约束的二次规划问题,可以利用梯度投影法^[11]来求解,其优化函数形式如下:

$$\hat{\boldsymbol{\beta}} = \arg \min \{ \|\mathbf{A}\boldsymbol{\beta} - \mathbf{y}\|_2 + \lambda \|\boldsymbol{\beta}\|_1 \} \quad (13)$$

其中 $\|\mathbf{A}\boldsymbol{\beta} - \mathbf{y}\|_2$ 表示 $\mathbf{A}\boldsymbol{\beta}$ 和 \mathbf{y} 之间的误差, $\|\boldsymbol{\beta}\|_1$ 表示惩罚项,约束 $\boldsymbol{\beta}$ 的稀疏性, λ 是一个非负参数。

2.3 本文方法

本文通过 KPCA 方法将训练样本和测试样本映射到高维核空间,在高维空间对样本进行 PCA 特征提取,并进行稀疏表示,最后求出样本特征稀疏系数,计算稀疏系数的能量并进行分类识别。图1给出了算法的流程图,下面对算法的各个步骤进行详细介绍。




图1 SAR 目标识别流程图

Fig. 1 Flowchart of SAR target recognition

$$\begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \vdots \\ \hat{y}_L \end{bmatrix} = \begin{bmatrix} \hat{s}_1^{1,1} & \cdots & \hat{s}_1^{N_1,1} & \hat{s}_2^{1,1} & \cdots & \hat{s}_2^{N_2,1} & \cdots & \hat{s}_q^{1,1} & \cdots & \hat{s}_q^{N_q,1} \\ \hat{s}_1^{1,2} & \cdots & \hat{s}_1^{N_1,2} & \hat{s}_2^{1,2} & \cdots & \hat{s}_2^{N_2,2} & \cdots & \hat{s}_q^{1,2} & \cdots & \hat{s}_q^{N_q,2} \\ \vdots & & \vdots & \vdots & & \vdots & & \vdots & & \vdots \\ \hat{s}_1^{1,L} & \cdots & \hat{s}_1^{N_1,L} & \hat{s}_2^{1,L} & \cdots & \hat{s}_2^{N_2,L} & \cdots & \hat{s}_q^{1,L} & \cdots & \hat{s}_q^{N_q,L} \end{bmatrix} \begin{bmatrix} \beta_1^1 \\ \vdots \\ \beta_{N_1}^1 \\ \vdots \\ \beta_q^1 \\ \vdots \\ \beta_{N_q}^q \end{bmatrix} + \mathbf{n} \quad (14)$$

2.3.3 分类识别

本文通过梯度投影法^[11]求得测试样本在过完备字典下的稀疏系数 $\boldsymbol{\beta} = [\beta_1^1, \dots, \beta_{N_1}^1, \dots, \beta_q^1, \dots, \beta_q^{N_q}]^T$,如何根据稀疏系数进行分类识别是 SAR 目标识别的关键,本文通过提取出每类的稀疏系数 \mathbf{r}_i ,求出每类稀疏系数能量 $\|\mathbf{r}_i\|_2^2$,能量最大的那个类判为目标所在的类:

2.3.1 训练过程

- 1) 预处理:a) 给定一个 SAR 目标图像训练样本集 $\mathbf{B} = [\mathbf{x}_1^1, \dots, \mathbf{x}_{N_1}^1, \dots, \mathbf{x}_q^1, \dots, \mathbf{x}_q^{N_q}]$,其中 q 表示样本类别数, $\mathbf{x}_i^j \in \mathbf{R}^{m \times n}$ 表示第 i 类的第 j 个样本, $N = \sum_{i=1}^q N_i$,对样本集 \mathbf{B} 进行对数变换,将乘性噪声变成加性噪声;b) 进行傅里叶变换,取其幅频特性,以保证目标的平移不变性,同时利用幅频特性的对称性取一半的信息以此来降低样本的维数;c) 对幅度进行归一化处理,并形成一维列向量 $\mathbf{p}_i^j (i=1, 2, \dots, q, j=1, \dots, N_i)$,将这些列向量按从左到右的顺序排列得到样本集 $\mathbf{D} = \{\mathbf{p}_1^1, \dots, \mathbf{p}_{N_1}^1, \dots, \mathbf{p}_q^1, \dots, \mathbf{p}_q^{N_q}\}$ 。
- 2) 特征提取:由式(3)得到样本的特征向量 $\mathbf{v}^{N-L+1}, \mathbf{v}^{N-L+2}, \dots, \mathbf{v}^N (L$ 表示大于零的特征值个数),将 \mathbf{D} 投影到特征向量上,根据(6)式得到训练样本集的特征 $\mathbf{A} = [\mathbf{s}_1^1, \dots, \mathbf{s}_{N_1}^1, \dots, \mathbf{s}_q^1, \dots, \mathbf{s}_q^{N_q}]$,其中 $\mathbf{s}_i^j = [s_i^{j,1}, s_i^{j,2}, \dots, s_i^{j,k}, \dots, s_i^{j,L}]^T \in \mathbf{R}^L (s_i^{j,k}$ 表示第 i 类的第 j 个样本, k 表示该样本的第 k 个值),对 \mathbf{A} 的每一列归一化,构成过完备字典 $\hat{\mathbf{A}}$ 。

2.3.2 测试过程

给定一个待识别的样本 \mathbf{y} ,根据 2.3.1 相同的预处理和特征提取方法对测试样本进行处理,得到样本特征 $\hat{\mathbf{y}}$ 。将 $\hat{\mathbf{y}}$ 用过完备字典 $\hat{\mathbf{A}}$ 线性表示,即 $\hat{\mathbf{y}} = \hat{\mathbf{A}}\boldsymbol{\beta} + \mathbf{n}$,具体形式如下:


$$\text{identity}(\mathbf{y}) = \arg \max (\|\mathbf{r}_i\|_2^2), \text{其中 } i \in \{1, 2, \dots, q\} \quad (15)$$

3 实验结果及分析

3.1 实验数据介绍

本实验所用的数据是由美国 DARPA/AFRL MSTAR 工作组提供的实测 SAR 地面静止目标数

据。包括三大类目标,七种型号的 SAR 图像,训练样本是在俯仰角为 17°时的成像数据,包括 T72sn_132、BMP2sn_c21、BTR70sn_c71 三类目标,测试样本是在俯仰角为 15°时的成像数据,包括 T72 的三种型号(T72sn_132、T72sn_812、T72sn_s7)、BMP2 的三种型号(BMP2sn_c21、BMP2sn_9563、BMP2sn_9566)和 BTR70sn_c71 七种型号目标。图像大小均为 128×128,成像方位为 0°~360°。图 2 给出了三种训练样本在某一方位角下的 SAR 图像,为了说明本文处理图像的形状,图 3 给出了相应的光学图像,表 1 给出了样本具体类别型号及样本数。



(a) T72sn_132 (b) BMP2sn_c21 (c) BTR70sn_c71

图 2 三类军用目标的 SAR 图像

Fig. 2 The SAR image of three military targets



(a) T72sn_132 (b) BMP2sn_c21 (c) BTR70sn_c71

图 3 三类军用目标的光学图像

Fig. 3 The optical image of three military targets

$$\begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \vdots \\ \hat{y}_L \end{bmatrix} = \begin{bmatrix} \hat{s}_{1,1} & \dots & \hat{s}_{232,1} \\ \hat{s}_{1,2} & \dots & \hat{s}_{232,2} \\ \vdots & \dots & \vdots \\ \hat{s}_{1,L} & \dots & \hat{s}_{232,L} \end{bmatrix} \begin{bmatrix} \hat{s}_{233,1} & \dots & \hat{s}_{465,1} \\ \hat{s}_{233,2} & \dots & \hat{s}_{465,2} \\ \vdots & \dots & \vdots \\ \hat{s}_{233,L} & \dots & \hat{s}_{465,L} \end{bmatrix} \begin{bmatrix} \hat{s}_{466,1} & \dots & \hat{s}_{698,1} \\ \hat{s}_{466,2} & \dots & \hat{s}_{698,2} \\ \vdots & \dots & \vdots \\ \hat{s}_{466,L} & \dots & \hat{s}_{698,L} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_{698} \end{bmatrix} + \mathbf{n} \quad (16)$$

通过梯度投影法^[11]得到的稀疏系数中,列序号 1-232 对应所有 T72 的稀疏系数,列序号 233-465 对应所有 BMP2 的稀疏系数,列序号 466-698 对应所有 BTR70 的稀疏系数。

图 4 给出了三类目标稀疏系数分布情况。图 4 (a)、(b)和(c)分别为 T72、BMP2 和 BTR70 三类训练样本所对应的测试样本在 44°方位角下的稀疏系

表 1 实验所用训练和测试样本

Tab. 1 The training and testing samples in experiments

数据类型	目标类别与型号	样本个数	样本总数
训练样本	T72 (sn_132)	232	698
	BMP2 (sn_c21)	233	
	BTR70 (sn_c71)	233	
测试样本	T72 (sn_132)	196	1365
	T72 (sn_812)	195	
	T72 (sn_s7)	191	
	BMP2 (sn_c21)	196	
	BMP2 (sn_c9563)	195	
	BMP2 (sn_c9563)	195	
	BTR70 (sn_c71)	196	

3.2 实验结果及分析

对于给定的实验数据,按照 2.3 的步骤进行预处理和特征提取,其中 KPCA 特征提取中所用核函数为高斯径向基核函数, $K(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma * \|\mathbf{x}_i - \mathbf{x}\|^2)$, 核参数 $\gamma = 14$, 选取特征值大于零所对应的特征向量形成样本特征,特征向量个数即为特征维数。将 T72、BMP2 和 BTR70 三类样本的特征按从左到右的顺序排列构成过完备字典 $\hat{\mathbf{A}}$, 即过完备字典 $\hat{\mathbf{A}}$ 中列序号 1-232 对应所有 T72 样本,列序号 233-465 对应所有 BMP2 样本,列序号 466-698 对应所有 BTR70 样本,对于任意的测试样本 \mathbf{y} , 经过预处理和特征提取后变成 $\hat{\mathbf{y}} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_L]^T \in \mathbf{R}^{L \times 1}$, 将其用过完备字典 $\hat{\mathbf{A}}$ 线性表示,具体形式如下:

数分布情况,由图可知,在求得的稀疏系数中,大部分非零值都分布在目标所在类,大部分零值都分布在其他类,故可以通过求每类稀疏系数的能量来对测试样本进行分类识别。

采用相同的 SAR 图像预处理,将本文的方法与 PCA 特征提取方法相比,得到的实验结果如表 2 所示,由表可知本文方法的识别结果为 96.78%, 明显

优于 PCA 特征提取方法。

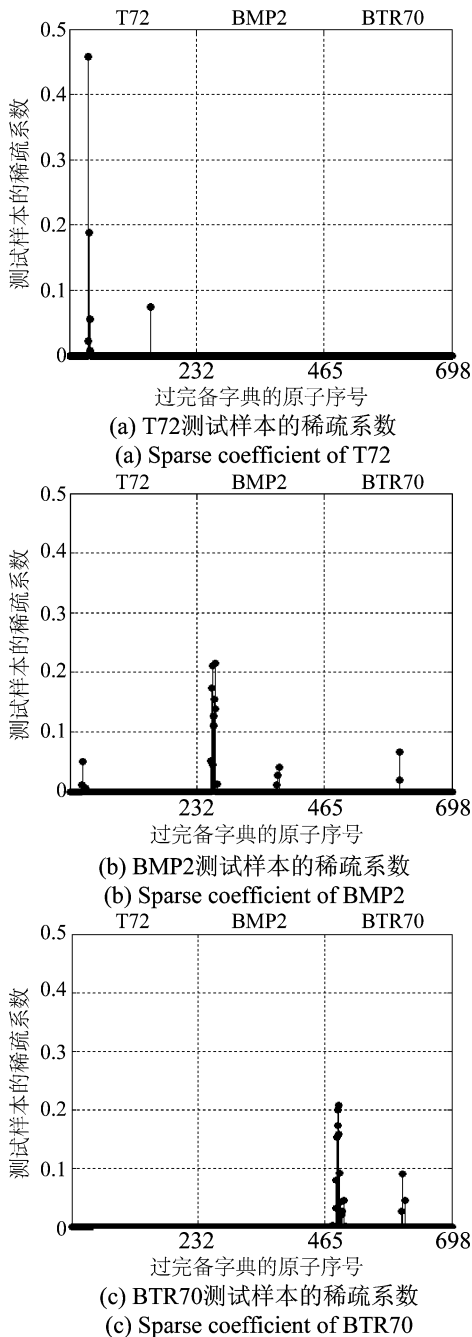


图4 三类测试样本的稀疏系数分布

Fig. 4 Sparse coefficient distribution of three types of test samples

为了说明本文算法对小样本情况具有鲁棒性,表3给出了训练样本数分别为108个、216个、324个、432个、486个、540个和698个时两种方法的识别结果,每个结果都是通过50次蒙特卡罗实验并取其平均值得到的。由表3可知,随着训练样本数的减

少,本文方法的识别结果始终高于PCA特征提取方法,当样本数减少到一半时,基于KPCA和稀疏表示目标识别方法的识别结果达到95.37%,并且当样本数减少到108个时,KPCA方法识别结果为89.15%,在样本数较少的情况下KPCA方法识别结果比PCA方法要高2.27%,说明在核空间进行PCA特征提取并提取样本稀疏特征进行分类能够更有效的区分样本类别。

表2 各类目标的识别率

Tab. 2 The recognition rate of different samples

	PCA+SRC	KPCA+SRC
T72 (sn_132)	100%	100%
T72 (sn_812)	86.15%	94.87%
T72 (sn_s7)	97.38%	97.38%
BMP2 (sn_c21)	98.98%	99.49%
BMP2 (sn_c9563)	94.36%	96.92%
BMP2 (sn_c9566)	81.12%	88.78%
BTR70 (sn_c71)	100%	100%
平均识别率	94.00%	96.78%

表3 减少训练样本时两种方法的识别结果

Tab. 3 The recognition results of two methods with the reduction of training samples

训练样本个数	特征提取方法	
	PCA+SRC	KPCA+SRC
108 (每类每隔10°随机选取1个样本)	86.88%	89.15%
216 (每类每隔10°随机选取2个样本)	91.74%	93.31%
324 (每类每隔10°随机选取3个样本)	93.36%	95.37%
432 (每类每隔30°随机选取12个样本)	93.71%	95.95%
486 (每类每隔40°随机选取18个样本)	93.87%	96.21%
540 (每类每隔60°随机选取30个样本)	94.02%	96.34%

4 结论

基于PCA特征提取的稀疏表示SAR目标识别是一种线性特征提取的目标识别方法,为了提高样本的线性可分度,本文提出了结合KPCA和稀疏表

示的 SAR 目标识别方法,将样本通过核函数映射到核空间,在核空间进行 PCA 特征提取,并采用梯度投影法求解测试样本在过完备字典下的稀疏系数,进一步构造不同类别样本的特征,利用系数的能量特征对目标进行分类识别。通过 MSTAR 实测 SAR 数据的实验结果证明在没有考虑方位信息的情况下本文的方法能够有效提高目标的识别率。

参考文献

- [1] 贺志国,陆军,匡纲要. SAR 图像特征提取与选择研究[J]. 信号处理,2008,24(5):813-823.
HE Z G, LU J, KUANG G Y. A survey on feature extraction and selection of SAR images[J]. Signal Processing, 2008,24(5):813-823. (in Chinese)
- [2] Karhunen J, Joutsensalo J. Generalizations of principal component analysis, optimization problems and neural networks[J]. Neural Networks, 1995,8(4):549-562.
- [3] Comon P. Independent component analysis: A new concept? [J]. Signal Processing, 1994,36(3):287-314.
- [4] Belhumeur P N, Hespanha J P, Kriegman J K. Eigenfaces vs fisherfaces: recognition using class specific linear projection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997,19:711-720.
- [5] 韩萍,吴仁彪,王兆华. 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.
HAN P, WU R B, WANG Z H. SAR automatic target recognition based on KPCA criterion[J]. Journal of Electronics and Information Technology, 2003,25(10):1297-1301. (in Chinese)
- [6] 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.
HAN P, WU R B, WANG Z H. SAR target feature extraction and automatic recognition based on KFD criterion

- [J]. Modern Rader,2004,26(7):27-30. (in Chinese)
- [7] Donoho D L. Compressed Sensing[J]. IEEE Transactions on Information Theory,2006,52(4):1289-1306.
- [8] 刘中杰,庄丽葵,曹云峰等. 基于主元分析和稀疏表示的 SAR 图像目标识别[J]. 系统工程与电子技术,2013,35(2):282-286.
LIU Z J, ZHUANG L K, CAO Y F, et al. Target recognition of SAR images using principal component analysis and sparse representation[J]. Systems Engineering and Electronics, 2013,35(2):282-286. (in Chinese)
- [9] Schölkopf B, Smola A, Müller K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998,10(5):1299-1319.
- [10] Wright J, Yang A Y, Ganesh A, etc. Robust Face Recognition via Sparse Representation [J]. 2009,31(2):210-227.
- [11] Figueiredo M A T, Nowak R D, Wright S J. Gradient Projection for Sparse Reconstruction; Application to Compressed Sensing and Other Inverse Problems[J]. IEEE journals of selected topics in signal processing, 2007,1(4):586-597.

作者简介



韩 萍 女,1966 年生,天津人,中国民航大学教授、硕士生导师。研究方向为图像处理与模式识别、SAR 目标检测与识别等。

E-mail: hanpingcauc@163.com



王 欢 女,1990 年生,安徽安庆人,中国民航大学电子信息工程学院硕士研究生,研究方向为合成孔径雷达目标识别。

E-mail: tianjinwanghuan@126.com