

应用局部约束二维稀疏表示识别 SAR 图像目标*

金斌^{1,2}, 张静³, 王威⁴, 张军⁴

(1. 海军航空工程学院 研究生管理大队, 山东烟台 264001;

2. 海军装备部兵器部, 北京 100073;

3. 海军航空工程学院 电子信息工程系, 山东烟台 264001;

4. 国防科技大学 电子科学与工程学院, 湖南长沙 410073)

摘要:在分析典型稀疏表示分类方法和局限性的基础上,提出了一种基于局部约束的二维稀疏表示方法,以有效解决 SAR 图像目标识别问题。该方法对 SAR 图像进行图像预处理,在兼顾图像相邻列(行)对应稀疏表示系数邻近性和样本间局部性的基础上,构建了局部约束目标函数,并通过解闭式解,实现稀疏表示系数的更新求解。利用美国实测 MSTAR 数据对算法进行了仿真验证,实验结果表明所提出的方法可实现 SAR 图像目标的有效识别,并对训练样本数目具有一定的鲁棒性。

关键词:合成孔径雷达;自动目标识别;二维稀疏表示;局部约束

中图分类号:TN919 **文献标志码:**A **文章编号:**1001-2486(2014)03-0177-07

Two dimensional local-constrained coding and sparse representation for SAR images targets recognition

JIN Bin^{1,2}, ZHANG Jing³, WANG Wei⁴, ZHANG Jun⁴

(1. Graduate Students' Brigade, Naval Aeronautical and Astronautical University, Yantai 264001, China;

2. Armament Branch of NED, Beijing 100073, China;

3. Department of Electronic and Information Engineering, Naval Aeronautical and Astronautical University, Yantai 264001, China;

4. College of Electronic Science and Engineering, National University of Defense Technology, Changsha 410073, China)

Abstract:By analyzing the limitation of the traditional sparse representation based classification, a novel classification framework called two dimensional Local-constrained Coding and Sparse Representation (2D-LSRC) is proposed for Synthetic Aperture Radar (SAR) images recognition. Different from other recent popular vector-based representation, 2D-LSRC preserves the global linear coding coefficients between the input matrix and these elementary matrices, as well as the local data structure. Extensive experimental results of MSTAR datasets show the effectiveness of the proposed algorithms and its robustness for the number of the training dataset.

Key words: SAR; automatic target recognition; two dimensional sparse representation; locality constrained

合成孔径雷达(Synthetic Aperture Radar, SAR)是一种工作在微波波段的主动式相干成像雷达^[1]。这种雷达具有高分辨率成像和大面积数据获取的能力,同时还具有全天候、全天时获取数据以及穿透植被和遮盖物的能力,因此基于 SAR 的自动目标识别技术在战场感知方面非常重要。然而,由于 SAR 特殊的成像机理,使得 SAR 图像存在大量的相干斑噪声,如何能够从 SAR 图像中提取出有效的识别特征,已经成为 SAR ATR 过程中的一个关键步骤^[2-3]。

近年来,各国学者已经研究了多种 SAR 图像

特征提取和识别方法,如文献[4]开展了基于 SAR 图像的模板匹配识别方法,这种方法虽能获得较好地识别结果,但对参考模板的数据量要求较高,当训练样本数较少时,识别率大大降低。文献[5]研究了一种基于支持向量机(Support Vector Machine, SVM)识别方法。文献[6]结合核函数技术研究了一种基于核主成分分析(Kernel Principal Component Analysis, KPCA)的 SAR 图像目标识别方法,可获得较好的识别效果,但该方法泛化能力较差,当测试目标与训练目标差异较大时,识别性能下降较大。

* 收稿日期:2013-12-10

基金项目:国家自然科学基金资助项目(61102167)

作者简介:金斌(1968—),男,安徽合肥人,博士研究生,E-mail:jinbin@163.com;

张军(通信作者),男,博士,研究员,E-mail:zhj64068@sina.com

稀疏表示(Sparse Representation, SP)理论是一种新兴的信号处理技术^[7-8]。该技术可以挖掘具有稀疏性信号的特征,并能在少量信息的前提下高精度的逼近原始信号。强散射中心(往往对应于感兴趣目标)的稀疏性是 SAR 图像的一个显著特征^[9-10],因此,利用稀疏表示技术处理 SAR 图像是可行的,且具有独特优势。

稀疏表示的优越性使其在目标识别领域得到了广泛研究和应用。2008 年, Wright 等^[11]开创性地提出了稀疏表示分类方法(Sparse Representation-based Classification, SRC),有效解决了人脸识别的两个难题:特征提取的选择和对遮挡的鲁棒性问题。2010 年, Wang 等^[12]在研究样本稀疏特性和局部特性之间关系的基础上,提出一种稀疏表示新思想—局部约束线性编码(Locality-constrained Linear Coding, LLC),该方法通过增加局部约束因子,使得那些与样本最邻近的字典基具有最大的稀疏表示系数。在此基础上,2013 年 Wei^[13]对 LLC 方法进行改进,利用解闭式解,更新稀疏表示编码和字典,以实现识别性能的提高。然而,以上这些方法存在的共性问题:稀疏表示的一维性问题,即在进行稀疏表示之前需要对图像进行处理,将二维数据转换为一维向量,这种转换不仅使数据的维数大大增加,而且将导致后续目标识别的空间信息丢失。针对该问题,文献[14]研究了一种松弛二维稀疏表示方法(Two Dimensional Relaxed Representation, 2DRR),该方法通过构建二维稀疏表示目标函数实现测试目标的重构。然而 2DRR 仅仅考虑了一幅二维图像列与列之间的临近关系,却没有考虑不同图像列之间的临近关系,即局部性问题。

本文针对以上问题,研究了一种新的基于局部约束二维稀疏表示方法(2D-LCSR),并将其应用到 SAR 图像识别中。首先在二维图像的基础上构建一种局部约束二维稀疏表示目标函数,该目标函数既考虑图像相邻列(行)对应稀疏表示系数的邻近关系,也考虑了样本间的局部性问题,使提取的稀疏表示系数更能反映出目标类间差异性的;然后给出求解推导过程;最后,利用美国实测运动和静止目标获取与识别(Moving and Stationary Target Acquisitions and Recognition, MSTAR),切片 SAR 数据^[15]对算法进行仿真验证,实验表明,利用本文算法能够有效提取出有利于鉴别的稀疏表示特征信息,可有效完成目标的识别任务。

1 局部约束二维稀疏表示算法

1.1 目标函数建立

假设 C 类二维图像训练样本集表示为 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N] \in \mathbf{R}^{m \times N}$, 其中 $\mathbf{X}_i \in \mathbf{R}^{m \times n}$ 表示训练样本集中的第 i 个样本图像。提取每一个训练样本的第 j 列构建字典 $\mathbf{H}_j = [\mathbf{X}_{1j}, \mathbf{X}_{2j}, \dots, \mathbf{X}_{ij}, \dots, \mathbf{X}_{Nj}] \in \mathbf{R}^{m \times N}$, $j = 1, \dots, n$, 其中 \mathbf{X}_{ij} 表示第 i 个训练样本的第 j 列, 则与该字典相对应的稀疏表示系数表示为 $\boldsymbol{\alpha}_j \in \mathbf{R}^{N \times 1}$, 由此可以推知稀疏表示系数矩阵 $\boldsymbol{\alpha} = [\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_j, \dots, \boldsymbol{\alpha}_n] \in \mathbf{R}^{N \times n}$ 。另设测试样本图像数据表示为 $\mathbf{Y} \in \mathbf{R}^{m \times n}$, 则局部约束二维稀疏表示算法的目标函数构建如下:

$$\begin{aligned} \min_{\{\boldsymbol{\alpha}_j\}_{j=1}^n} & \lambda_1 \sum_{j=1}^n \|\boldsymbol{\alpha}_j\|_2^2 + \lambda_2 \sum_{j=1}^n \|\mathbf{p}_j \odot \boldsymbol{\alpha}_j\|_2^2 + \\ & \eta \sum_{j=1}^n \sum_{k \in \mathcal{N}_e(j)} \|\boldsymbol{\alpha}_j - \boldsymbol{\alpha}_k\|_2^2 W_{jk} \\ \text{s. t.} & \|\mathbf{Y} - [\mathbf{H}_1 \boldsymbol{\alpha}_1, \mathbf{H}_2 \boldsymbol{\alpha}_2, \dots, \mathbf{H}_n \boldsymbol{\alpha}_n]\|_2^2 \leq \varepsilon \end{aligned} \quad (1)$$

为了求解方便,将式(1)重新书写为:

$$\begin{aligned} L = \arg \min_{\{\boldsymbol{\alpha}_j\}_{j=1}^n} & \|\mathbf{Y} - [\mathbf{H}_1 \boldsymbol{\alpha}_1, \mathbf{H}_2 \boldsymbol{\alpha}_2, \dots, \mathbf{H}_n \boldsymbol{\alpha}_n]\|_2^2 \\ & + \lambda_1 \sum_{j=1}^n \|\boldsymbol{\alpha}_j\|_2^2 + \lambda_2 \sum_{j=1}^n \|\mathbf{p}_j \odot \boldsymbol{\alpha}_j\|_2^2 \\ & + \eta \sum_{j=1}^n \sum_{k \in \mathcal{N}_e(j)} \|\boldsymbol{\alpha}_j - \boldsymbol{\alpha}_k\|_2^2 W_{jk} \end{aligned} \quad (2)$$

式(2)中的第一项是 2-范数正则项,对重构图像起到折衷的作用。第二项表示归一化项。第三项称为局部约束项,其中符号 \odot 表示对应元素点乘运算, $\mathbf{p}_j = [p_{j1}, p_{j2}, \dots, p_{jn}]$ 称为局部适应因子,同文献[13],本文采用两种 \mathbf{p}_j 表示形式,如下所示:

$$\mathbf{p}_j = \|\mathbf{H}_{jl} - \boldsymbol{\alpha}_j\|_2^2, \quad l = 1, 2, \dots, N \quad (3)$$

$$\mathbf{p}_j = \exp\left(\frac{\|\mathbf{H}_{jl} - \boldsymbol{\alpha}_j\|_2^2}{\sigma}\right), \quad l = 1, 2, \dots, N \quad (4)$$

局部约束项反映了 \mathbf{H}_j 字典中每一个基与稀疏表示系数 $\boldsymbol{\alpha}_j$ 之间的邻近关系,当局部适应因子 \mathbf{p}_j 偏小时,说明训练样本数据与测试样本数据邻近;当 \mathbf{p}_j 偏大时,说明训练样本数据与测试样本数据较远。从距离角度出发,邻近说明训练样本与测试样本相似,通常对应同一类目标;从稀疏表示角度出发,最相似样本线性表示出的稀疏表示系数较大;从重构角度出发,较小 \mathbf{p}_j 所获得的重构误差要低于较大 \mathbf{p}_j 所获得的重构误差。因此,在满足重构的前提下,局部约束项的增加有利于目标分类(识别)。

式(2)中的第四项表示相邻列(行)图像对应稀疏表示系数之间的制约程度,反映图像相邻列(行)的相互作用,进一步说就是相邻列(行)的图像数据不是突变的,之间存在一定的渐变关系或依存关系。这种依存关系通过权矩阵 W_{jk} 以 $Ne(j)$ 邻域的形式表示,当第 k 列与第 j 列互为邻域时,则权矩阵 W_{jk} 设置为 1,否则设置为 0。

1.2 稀疏表示系数求解

令 $\alpha_v = [\alpha_1^T, \alpha_2^T, \dots, \alpha_n^T]^T, p_v = [p_1^T, p_2^T, \dots, p_n^T]^T$, 则式(2)可以表示为:

$$L = \arg \min_{\alpha_v} \|y - H\alpha_v\|_2^2 + \lambda_1 \|\alpha_v\|_2^2 + \lambda_2 \|p_v \odot \alpha_v\|_2^2 + 2\eta \alpha_v^T S \alpha_v \quad (5)$$

其中, y 表示将图像转换为列向量, H 如式(6)所示:

$$H = \begin{bmatrix} H_1 & 0 & \dots & 0 \\ 0 & H_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & H_n \end{bmatrix} \quad (6)$$

$S = (V - W) \otimes I_N$, 这里 $V_{ii} = \sum_j W_{ij}, I_N$ 表示 N 阶单位矩阵。由此可以看出式(5)实际上是一个最小方差问题,其对应的解值为:

$$\alpha_v = (H^T H + \lambda_1 I_{nN} + \lambda_2 (p_v \odot p_v) + 2\eta S)^{\dagger} H^T y \quad (7)$$

符号“ \dagger ”表示矩阵的伪逆,式(7)是方程(5)的解,当样本个数较少时,求解 α_v 是可行的。但当训练样本个数 N 很大时,求解过程所需的计算量十分庞大。针对该问题,论文采用迭代最小方差方法(Alternated Least Squares, ALS)^[16],利用迭代原理将复杂的多维参数求解问题转化一维参数求解问题。其具体求解过程如下:

固定 $\alpha_1, \alpha_2, \dots, \alpha_{j-1}, \alpha_{j+1}, \dots, \alpha_n$, 利用拉格朗日函数对第 α_j 进行更新,即 $\partial L / \partial \alpha_j = 0$, 则

$$(H_j^T H_j + \lambda_1 1 + \lambda_2 (p_j \odot p_j) + 2\eta V_j 1) \alpha_j - (H_j^T y_j + 2\eta \alpha W_j) = 0 \quad (8)$$

故

$$\alpha_j = \left(\begin{matrix} H_j^T H_j + \lambda_1 1 \\ + \lambda_2 (p_j \odot p_j) \\ + 2\eta V_j 1 \end{matrix} \right)^{\dagger} (H_j^T y_j + 2\eta \alpha W_j) \quad (9)$$

其中, $V_j = \sum_k W_{j,k}, 1 \in \mathbf{R}^{n \times 1}, W_j$ 表示全矩阵 W_{jk} 的第 j 列, y_j 表示测试样本图像的第 j 列。

按照上述方法依次对 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_j, \dots, \alpha_n]$ 中的每列更新,当满足一定条件时,如迭代误差小于一定阈值或迭代次数满足提前设定的门限时,迭代结束,此时对应的 α 即为式(4)的最终解。

2 基于局部约束二维稀疏表示的 SAR 图像目标识别方法

基于局部约束二维稀疏表示的 SAR 图像目标识别方法主要由三个模块构成:图像预处理模块、基于局部约束二维稀疏表示重构模块以及目标分类模块。其流程框图如图 1 所示。

2.1 图像预处理

通常获取到的用于识别的 SAR 图像,目标往往存在一定范围的位置扰动^[17],这种扰动对识别影响很大。本文利用目标质心位置对齐原点的方法来解决该问题^[2],即将目标的质心 (\bar{s}, \bar{t}) 为中心,分别向四周扩展出一个 $L \times L$ 的矩阵。目标的质心位置 (\bar{s}, \bar{t}) 可用一阶矩和零阶矩的比值表示:

$$\bar{s} = \frac{m_{10}}{m_{00}}, \quad \bar{t} = \frac{m_{01}}{m_{00}} \quad (10)$$

而 $p+q$ 阶原点矩定义为:

$$m_{pq} = \sum_x \sum_y s^p t^q f(s, t) \quad (11)$$

其中, (s, t) 表示图像的像素坐标,而 $f(s, t)$ 表示图像分割后的目标 ROI(Region of Interest)区域上的像素幅度值。通过图像预处理后,目标质心位置与原点对应,从而消除了目标位置扰动的影响。

2.2 分类算法

根据式(4)~(6)完成测试样本的重构,同 SRC 方法,测试目标所属类别应该是对应重构误

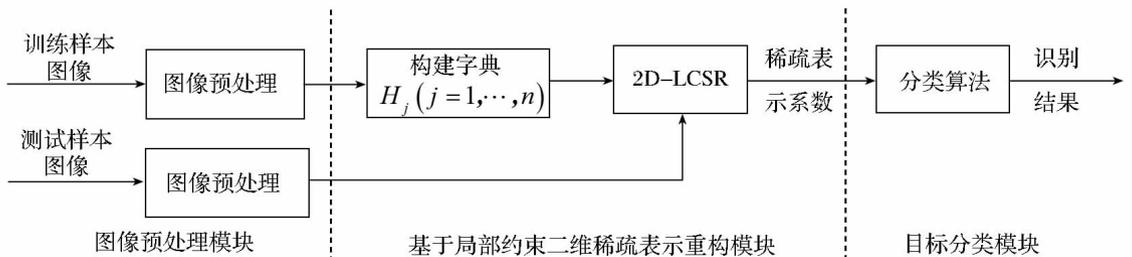


图 1 识别过程原理框图

Fig. 1 Flow of the SAR images recognition method based on 2D-LCSR

差最小的那个类,即利用每一类训练样本与其对应的稀疏表示系数可以完成对测试样本的重构,如果某类重构样本与测试样本的距离最近,则该测试样本隶属于这一类。鉴于文章讨论的是二维图像问题,因此这里需要考虑所有的 $[\alpha_1, \alpha_2, \dots, \alpha_j, \dots, \alpha_n]$, 即

$$\text{identity}(\mathbf{Y}) = \arg \min_c \frac{\|\mathbf{Y} - [\mathbf{H}_1 \alpha_1^c, \dots, \mathbf{H}_j \alpha_j^c, \dots, \mathbf{H}_n \alpha_n^c]\|_2}{\|\alpha^c\|_2}, \quad (c = 1, 2, \dots, C) \quad (11)$$

其中, α_j^c 表示利用第 c 类样本重构测试图像第 j 列时所得到的稀疏表示系数向量,而矩阵 $[\mathbf{H}_1 \alpha_1^c, \dots, \mathbf{H}_j \alpha_j^c, \dots, \mathbf{H}_n \alpha_n^c]$ 则反映利用第 c 类样本重构出的图像。

3 仿真实验与分析

本文利用美国 DARPA/AFRL MSTAR 项目提供的实测 SAR 地面静止军用目标数据进行仿真实验。随机选取 17° 下 BMP2_sn9563、T72_sn132 和 BTR70_snc71 中样本图像作为训练集,以 15° 下的 BMP2_sn9563、BMP2_sn9566、BMP2_snc21、T72_sn132、T72_sn812、T72_sns7、BTR70_snc71 作为测试集,训练集和测试集目标原始图像大小均为 128×128 ,如表 1 所示。仿真过程中,各参数分别设置为: $\lambda_1 = 0.001, \lambda_2 = 0.8, \eta = 0.1$ 。以下各种条件下所得的识别率均是在 10 次仿真实验的基础上得到的平均识别率。

表 1 MSTAR 数据子集
Tab.1 MSTAR datasets

训练样本	样本数目	测试样本	样本数目
BMP2_sn9563	233	BMP2_sn9563	195
T72_sn132	232	BMP2_sn9566	196
BTR70_snc71	233	BMP2_snc21	196
		T72_sn132	196
		T72_sn812	195
		T72_sns7	191
		BTR70_snc71	195

3.1 不同邻域范围情况下的仿真分析

由式(1), $Ne(j)$ 表示邻域的范围,下面给出不同邻域范围条件下算法的识别性能,这里选择 $Ne(j) = \{2, 4, 6, 8\}$,此时分别从三类训练样本图像集中随机 150 个样本构成训练库。表 2 给出对应的识别结果。

表 2 邻域范围取值不同时对应的目标识别结果

Tab.2 Classification accuracy comparison with different values of $Ne(j)$

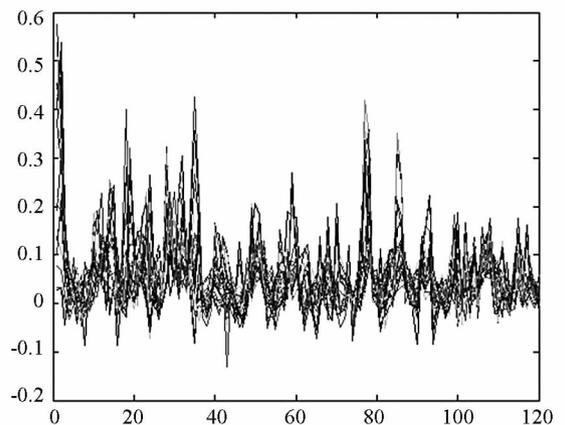
训练样本	$Ne(j) = 2$	$Ne(j) = 4$	$Ne(j) = 6$	$Ne(j) = 8$
BMP2_sn9563	0.800 0	0.876 9	0.805 1	0.682 1
BMP2_sn9566	0.811 2	0.867 3	0.790 8	0.642 9
BMP2_snc21	0.826 5	0.869 1	0.775 5	0.581 6
T72_sn132	0.841 8	0.867 3	0.806 1	0.722 5
T72_sn812	0.820 5	0.846 2	0.789 7	0.635 9
T72_sns7	0.822 0	0.890 1	0.785 3	0.628 3
BTR70_snc71	0.825 6	0.897 4	0.820 5	0.774 4

由表 2 可以看出,当邻域 $Ne(j)$ 选取不同的取值范围时,对目标的识别结果是存在一定的影响的。对比各种条件下的实验结果,当 $Ne(j) = 4$ 时获得的识别结果效果最好,因此在后续仿真实验中将 $Ne(j)$ 设置为 4。

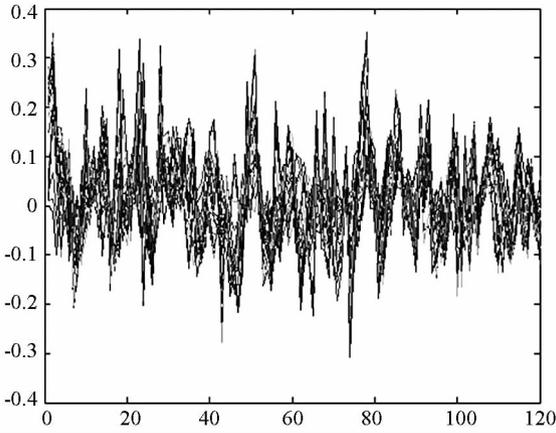
3.2 不同二维稀疏表示方法性能的对比如

将本文提出的局部约束稀疏表示方法与文献 [14] 提出的二维松弛表示方法进行比对。分别从 BMP2_sn9563、T72_sn132 和 BTR70_snc71 随机挑选三个图像作为测试样本,检验两种方法获得的稀疏表示系数情况,如图 2~4 所示。其中训练样本集分别从三类目标图像集中选取 $m = 40$ 个目标,则训练集中样本总数为 120。

由图 2~4 可以看出:本文所提出的二维稀疏表示方法可以使稀疏表示系数更加集中与所属类别的训练样本上,体现出更好的稀疏表示特性,这正是因为本文方法在重构过程中考虑到样本间的局部特性,使得那些与测试样本距离远的那些训练样本尽可能少参与重构过程中,或者说对于重构的贡献少一些;而 2DRR 方法虽然也能够表示出目标对应的所属类别,但稀疏表示系数分散较均匀,这在一定程度上会影响测试目标类别的正确划分。



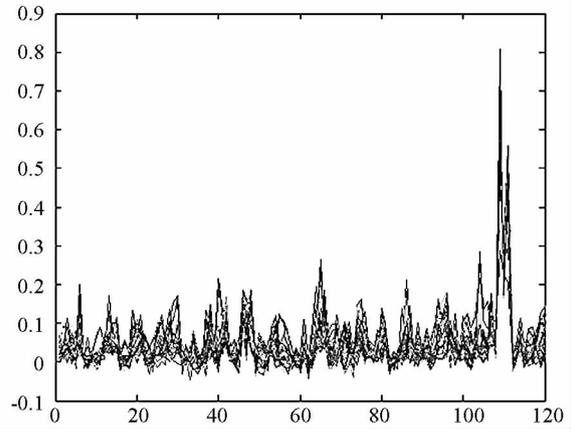
(a) 本文方法



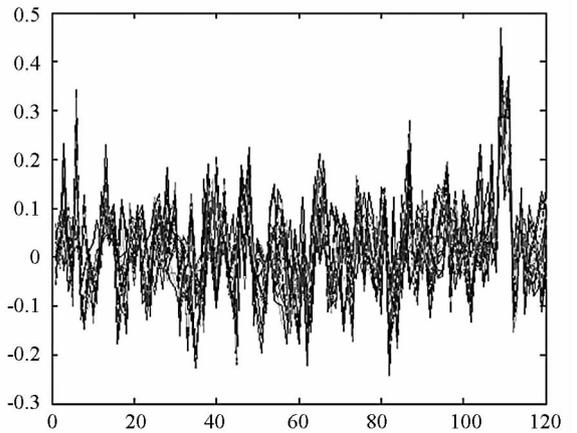
(b) 2DRR 方法

图2 利用两种不同二维稀疏表示方法重构 BMP2_sn9563 测试目标获得的稀疏表示系数

Fig.2 Sparse coefficients obtained by two different 2D sparse representation methods in reconstructing the target of BMP2_sn9563



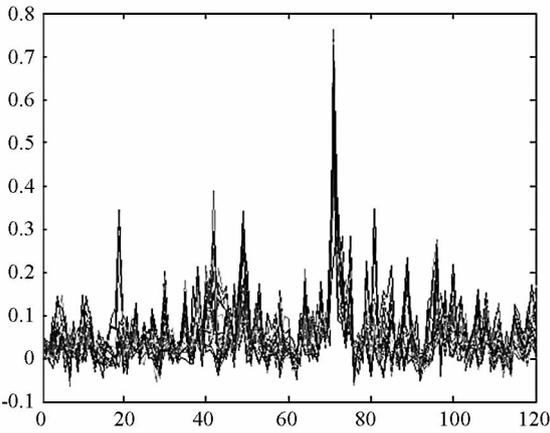
(a) 本文方法



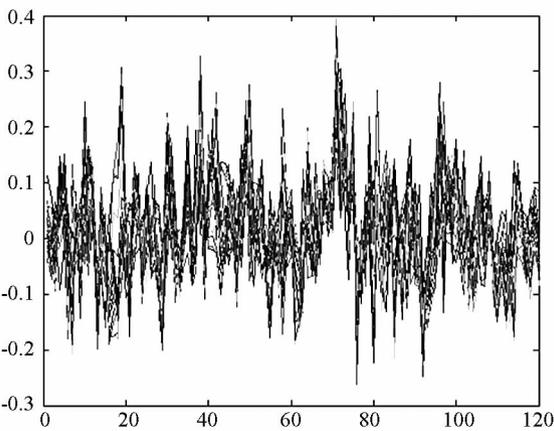
(b) 2DRR 方法

图4 利用两种不同二维稀疏表示方法重构 BTR70_snc71 测试目标获得的稀疏表示系数

Fig.4 Sparse coefficients obtained by two different 2D sparse representation methods in reconstructing the target of BTR70_snc71



(a) 本文方法



(b) 2DRR 方法

图3 利用两种不同二维稀疏表示方法重构 T72_sn132 测试目标获得的稀疏表示系数

Fig.3 Sparse coefficients obtained by two different 2D sparse representation methods in reconstructing the target of T72_sn132

3.3 不同训练样本条件下的仿真分析

为了验证算法的鲁棒性,分别从三类样本图像集中选取 $m = \{40, 100, 150, 220\}$ 个训练样本构成特征库,并将本文算法与其他稀疏表示方法进行比较,以验证本文算法的优越性,见表 3~6。表中的“SRC”表示文献[11]提出的稀疏表示方法,“2DRR”表示文献[14]提出的二维松弛稀疏表示方法,“2DLCSR-L2”表示本文提出的方法,其局部适应因子选取欧式距离方法;“2DLCSR-EXP”为本文所提方法,其局部适应因子选取指数函数方法,参数 $\sigma = 0.5$ 。

图5给出各种方法在不同训练样本数条件下获得的平均识别结果。

表 3 $m = 40$ 时对应的目标识别结果

Tab. 3 Recognition rate with the parameter of $m = 40$

训练样本	BMP2_sn9563	BMP2_sn9566	BMP2_snc21	T72_sn132	T72_sn812	T72_sns7	BTR70_snc71
SRC	0.564 1	0.668 4	0.640 2	0.739 8	0.666 7	0.581 2	0.697 4
2DRR	0.733 3	0.774 3	0.785 7	0.775 6	0.723 0	0.727 7	0.794 9
2DLCSR - L2	0.748 7	0.789 7	0.785 7	0.780 6	0.738 4	0.743 5	0.830 7
2DLCSR - EXP	0.748 7	0.739 7	0.755 1	0.780 6	0.748 7	0.753 9	0.830 7

表 4 $m = 100$ 时对应的目标识别结果

Tab. 4 Recognition rate with the parameter of $m = 100$

训练样本	BMP2_sn9563	BMP2_sn9566	BMP2_snc21	T72_sn132	T72_sn812	T72_sns7	BTR70_snc71
SRC	0.656 4	0.785 7	0.693 9	0.765 3	0.707 7	0.780 1	0.743 6
2DRR	0.759 0	0.8	0.812 4	0.785 7	0.753 8	0.785 3	0.815 4
2DLCSR - L2	0.784 6	0.794 9	0.816 3	0.806 1	0.779 5	0.769 6	0.841 0
2DLCSR - EXP	0.774 3	0.794 9	0.775 5	0.811 2	0.810 2	0.759 1	0.830 7

表 5 $m = 150$ 时对应的目标识别结果

Tab. 5 Recognition rate with the parameter of $m = 150$

训练样本	BMP2_sn9563	BMP2_sn9566	BMP2_snc21	T72_sn132	T72_sn812	T72_sns7	BTR70_snc71
SRC	0.882 0	0.841 0	0.852 0	0.892 5	0.846 2	0.863 8	0.902 6
2DRR	0.871 8	0.825 6	0.846 9	0.858 7	0.815 3	0.795 8	0.876 9
2DLCSR - L2	0.876 9	0.867 3	0.869 1	0.867 3	0.846 2	0.890 1	0.897 4
2DLCSR - EXP	0.876 9	0.821 4	0.841 8	0.867 3	0.851 3	0.900 5	0.892 3

表 6 $m = 220$ 时对应的目标识别结果

Tab. 6 Recognition rate with the parameter of $m = 220$

训练样本	BMP2_sn9563	BMP2_sn9566	BMP2_snc21	T72_sn132	T72_sn812	T72_sns7	BTR70_snc71
SRC	0.923 1	0.917 9	0.902 8	0.949 0	0.933 3	0.916 2	0.948 7
2DRR	0.897 4	0.871 8	0.857 1	0.898 0	0.861 5	0.869 1	0.876 9
2DLCSR - L2	0.928 2	0.928 5	0.903 1	0.918 3	0.907 6	0.926 7	0.959 0
2DLCSR - EXP	0.928 2	0.933 7	0.898 0	0.918 3	0.917 9	0.911 0	0.959 0

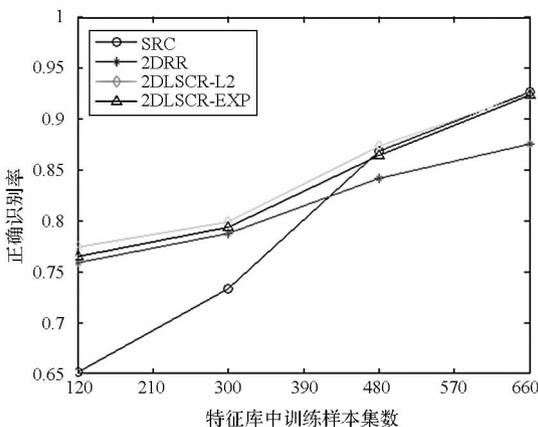


图 5 不同方法获得的平均识别率

Fig. 5 Average recognition rates obtained by different methods

由表 3 ~ 6 及图 5 可以得出以下结论:

1) 利用本文提出的 2D - LCSR 方法能够完成 SAR 图像目标类型的识别。

2) 从测试集的平均识别率来看,随着特征库中样本集个数 m 的增多,各种方法的识别性能提高。当 $m = 220$ 时,虽然本文提出方法的识别性能要略好一些,但各种方法的差异性不是很大;然而,随着训练样本数目的减少,传统 SRC 方法的识别性能下降更快,在 $m = 40$ 时,仅为 65.1%,而本文提出方法随着样本数的减少识别性能下降相对平缓。这充分说明了本文提出方法对训练样本数具有较好的鲁棒性,适合于工程实际应用,因为在现实中尤其是战场环境下,要想获得目标全方位全姿态的训练样本几乎是不可能。

3) 当选取不同的局部适应因子时,从测试样本的平均识别率来看,两种方法的识别性能相差不大,即在当前的仿真参数设置条件下,2DLSCR-L2 的识别性能要略好一些。

4 结束语

本文在分析现有稀疏表示识别方法的基础上提出了一种基于局部约束二维稀疏表示方法。该方法首先结合二维图像的特点构建基于局部约束的目标函数,然后通过目标函数求导,解闭式解,实现稀疏表示系数的更新求解。本文将该算法应用于 SAR 图像目标识别中,通过仿真实验结果表明本文方法在获得较好识别准确率的同时,对训练样本数目存在一定的鲁棒性,适合于工程实际应用。

参考文献 (References)

- [1] 高贵,周蝶飞,张军,等. 基于遗传算法的 SAR 图像目标鉴别特征选择[J]. 电子学报, 2008, 36(6): 1041-1046.
GAO Gui, ZHOU Diefei, ZHANG Jun, et al. Feature selection for target discriminant in sar images based on genetic algorithm [J]. Acta Electronica Sinica, 2008, 36(6): 1041-1046. (in Chinese)
- [2] 韩萍,王蕴红,吴仁彪,等. 一种有效的 SAR 自动目标识别方法[J]. 模式识别与人工智能, 2003, 16(2): 208-212.
HAN Ping, WANG Yunhong, WU Renbiao, et al. An efficient SAR automatic target recognition approach [J]. Pattern Recognition and Artificial Intelligence, 2003, 16(2): 208-212. (in Chinese)
- [3] Jones G, Bhanu B. Recognition of articulated and occluded objects [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21(7): 603-613.
- [4] Novak L M, Owirka G J, Brower W S. Performance of 10-and 20-traget MSE classification [J]. IEEE Transactions on Aerospace and Electronic Systems, 2000, 36(4): 1279-1289.
- [5] Patel V M, Nasraba N M, Chellappa R. Sparsity inspired automatic target recognition [J]. Proceedings of SPIE, 2010, 7696: 1-8.
- [6] Sun T, Jiao L C, Liu F, et al. Selective multiple kernel learning for classification with ensemble strategy [J]. Pattern Recognition. 2013, 46(11): 3081-3090.
- [7] 石光明,刘丹华,高大化,等. 压缩感知理论及其研究进展[J]. 电子学报. 2009, 37(5): 1070-1081.
SHI Guangming, LIU Danhua, GAO Dahua, et al. Advances in theory and application of compressed sensing [J]. Acta Electronica Sinica. 2009, 37(5): 1070-1081. (in Chinese)
- [8] Donoho D L. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4): 1285-1306.
- [9] 王伟,毕笃彦,熊磊,等. 基于稀疏流形学习的 SAR 图像识别[J]. 电子学报, 2010, 38(11): 2540-2541.
WANG Wei, BI Duyan, XIONG Lei, et al. SAR image recognition based on sparse manifold learning [J]. Acta Electronica Sinica, 2010, 38(11): 2540-2541. (in Chinese)
- [10] 王燕霞,张弓. 基于特征参数稀疏表示的 SAR 图像目标识别[J]. 重庆邮电大学学报(自然科学版). 2012, 24(3): 308-313.
WANG Yanxia, ZHANG Gong. Target recognition in SAR images using sparse representation based on feature space [J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition). 2012, 24(3): 308-313. (in Chinese)
- [11] Wringt J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence. 2009, 31(2): 210-227.
- [12] Wang J J, Yang J C, Yu K, et al. Locality-constrained linear coding for image classification [C] // Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition, 2010: 3360-3367.
- [13] Wei C P, Chao Y W, Yeh Y R, et al. Locality-sensitive dictionary learning for sparse representation based classification [J]. Pattern Recognition, 2013, 46(5): 1277-1278.
- [14] Dong Q L. Two dimensional relaxed representation [J]. Neurocomputing, 2013, 121: 248-253.
- [15] Air force research laboratory, model based vision laboratory. Sensor data management system [CP/OL]. <http://www.Mbvlab.wpafb.af.mil/publica/sdms/datasets/mstar>.
- [16] Hu Y F, Koren Y, Volinsky C. Collaborative filtering for implicit feedback datasets [C] // Proceedings of the IEEE International Conference on Data Mining, 2008: 263-272.
- [17] 成功,赵巍,毛士艺. 基于快速提升 KLDA 准则的 MSTAR SAR 目标特征提取与识别研究 [J]. 航空学报. 2007, 28(3): 667-674.
CHONG Gong, ZHAO Wei, MAO Shiyi. Study on fast improving KLDA criterion for MSTAR SAR feature extraction and recognition [J]. Acta Aeronautica ET Astronautica Sinica. 2007, 28(3): 667-674. (in Chinese)