

一种联合阴影和目标区域图像的 SAR 目标识别方法

丁军* 刘宏伟 王英华 王正珏 齐会娇 时荔蕙
(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: 地面目标的 SAR 图像中除了包含目标散射回波形成的区域,还包括由目标遮挡地面形成的阴影区域。但是由于这两种区域中的图像特性不相同,所以传统的 SAR 图像自动目标识别主要利用目标区域信息进行目标识别,或者单独使用阴影区域进行识别。该文提出一种阴影区域与目标区域图像联合的稀疏表示模型。通过使用 $\ell_1 \setminus \ell_2$ 范数最小化方法求解该模型得到联合的稀疏表示,然后根据联合重构误差最小准则进行 SAR 图像目标识别。在运动和静止目标获取与识别(MSTAR)数据集上的识别实验结果表明,通过联合稀疏表示模型可以有效地将目标区域与阴影区域信息进行融合,相对于采用单独区域图像的稀疏表示识别方法性能更好。

关键词: SAR; 目标识别; 联合稀疏表示; $\ell_1 \setminus \ell_2$ 范数最小化

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2015)03-0594-07

DOI: 10.11999/JEIT140713

SAR Target Recognition by Combining Images of the Shadow Region and Target Region

Ding Jun Liu Hong-wei Wang Ying-hua Wang Zheng-jue Qi Hui-jiao Shi Li-hui
(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract: SAR image of the ground target contains the target region formed by the scattered echoes of the target as well as the shadow area. However, the characteristics of the two areas are essentially different, therefore the traditional SAR image Automatic Target Recognition (ATR) methods use mainly target area information alone or shadow region only for recognition. This paper presents a joint sparse representation model by combining images of the shadow region and target region. By using the $\ell_1 \setminus \ell_2$ norm minimization method to solve the joint sparse representation model, the SAR image target recognition is achieved by minimizing the joint reconstruction error. Recognition results on Moving and Stationary Target Acquisition and Recognition (MSTAR) data sets show that the joint sparse representation model can effectively fuse the information within the target region and shadow region, and it has much better recognition performance than the methods using only the target or shadow area information of the image.

Key words: SAR; Target recognition; Joint sparse representation; $\ell_1 \setminus \ell_2$ -norm minimization

1 引言

目前,各式各样合成孔径雷达(SAR)系统获取的高分辨率图像越来越多,各国对 SAR 图像理解特别是自动目标识别(Automatic Target Recognition, ATR)技术的研究需求也越来越迫切。传统的 SAR 图像自动目标识别一般利用图像中的单一信息进行目标识别,例如:基于模板匹配^[1]的方法,基于支持向量机(Support Vector Machine, SVM)分类器的方法^[2]。为了进一步提高 SAR 图像目标识别性能,除

了完善预处理方法以及改进现有分类器性能等手段外,融合 SAR 图像中多种与类别相关的信息也是一种可行的途径。Sun 等人^[3]使用 Adaptive Boosting(AdaBoost)框架将多个弱分类器融合起来进行 SAR 目标识别。Papson 等人^[4]利用多幅 SAR 图像中阴影区域进行目标识别。文献[5]中通过融合目标轮廓和阴影轮廓信息进行 SAR 图像目标识别。文献[6]中通过多层编码器对目标图像与阴影轮廓进行联合特征提取并用于 SAR 目标识别。另外,Zhang 等人^[7]利用多幅 SAR 目标图像的联合稀疏表示进行目标识别,并取得较好效果。

SAR 目标识别可以看作是一个模式识别问题。近年来,稀疏表示在模式识别领域得到了广泛的应用^[5-10]。稀疏表示方法将观测信号分解为给定字典

2014-05-23 收到, 2014-09-17 改回

国家自然科学基金(61201292, 61322103, 61372132), 全国优秀博士学位论文作者专项资金(FANEDD-201156), 国家部委基金和中央高校基本科研业务费专项资金资助课题

*通信作者: 丁军 dingjun410@gmail.com

中少数信号(又叫做原子)的线性组合。类似于传统的最小二乘解,稀疏表示也是追求对观测信号的最佳重构。但不同的是,所使用的表示系数中只有少量元素具有非零值,而其他元素均为0。在很多模式识别应用中^[7-12],由于信号的稀疏表示可以较好地重构原始信号,稀疏表示被视为与原始信号对应的某种特征使用。例如:Wright等人^[8]提出的基于稀疏表示的识别方法(Sparse Representation-based Classification, SRC)在人脸识别方面取得较好效果。该方法将训练样本数据作为字典,通过测试数据在该字典下的稀疏表示进行识别。Zhang等人^[9]通过求解多视角数据的动态联合稀疏表示进行人脸识别。Maurer等人^[10]通过稀疏表示模型进行多任务学习和迁移学习;Gu等人^[11]在行为识别中也引入了非负稀疏表示模型。最近,Wang等人^[12]从最大化间隔角度将SRC方法解释为一种间隔分类器。

在上述方法的启发下,本文提出一种阴影区域与目标区域图像联合的稀疏表示模型。通过使用 $\ell_1 \setminus \ell_2$ 范数最小化方法求解该模型得到联合的稀疏表示,再根据联合重构误差最小准则进行SAR图像目标识别。在MSTAR数据集上的试验表明,通过联合稀疏表示模型可以有效地将目标区域与阴影区域信息融合起来,比仅使用单独区域图像的稀疏表示识别方法识别精度更高。甚至在只使用一幅SAR图像的情况下识别性能可接近Zhang等人^[7]通过多幅SAR图像联合识别的结果。另外,采用联合稀疏表示模型的识别方法对SAR图像分割质量鲁棒性强,因此具有较好的推广性。

2 联合稀疏表示

2.1 共享字典联合稀疏表示模型

文献[7]中,将 N 幅同一目标的SAR图像集 $\mathbf{Y} = [y_1, y_2, \dots, y_N]$ 融合为如式(1)所示的联合稀疏表示模型:

$$\hat{\mathbf{X}} = \arg \min_{\mathbf{X}} \|\mathbf{Y} - \mathbf{D}\mathbf{X}\|_F^2, \quad \text{s.t.} \|\mathbf{X}\|_{\ell_0 \setminus \ell_2} \leq K \quad (1)$$

其中, $\|\cdot\|_F$ 表示矩阵的 Frobenius 范数, $\|\mathbf{X}\|_{\ell_0 \setminus \ell_2}$ 表示对矩阵 \mathbf{X} 的 $\ell_0 \setminus \ell_2$ 混合范数, 即: 先对矩阵的行向量求 ℓ_2 范数, 然后再对结果向量求 ℓ_0 范数。引入 $\|\mathbf{X}\|_{\ell_0 \setminus \ell_2}$ 范数约束可以使得矩阵 \mathbf{X} 的每一列向量对应相同的稀疏模式。由于上述模型中联合稀疏表示对应的是相同字典, 所以我们将其称为共享字典联合稀疏表示模型。

2.2 独立字典的联合稀疏表示模型

我们知道, 地面目标的SAR图像中除了包含目标散射回波形成的区域, 还包括由目标遮挡地面形成的阴影区域。通过稀疏表示进行分类的方法主要

利用了图像中强度值较大区域的信息(一般情况下为目标散射的回波形成), 而对于阴影部分的信息并未加以利用。而文献[4]表明阴影中具有对识别可用的信息。一方面, 目标区域和阴影区域图像产生原理不同, 其图像特性也不相同; 另一方面, 同一目标的目标区域与阴影区域又具有一一对应的关系。于是本文将具有相同稀疏模式的约束应用于目标区域和阴影区域图像, 提出如式(2)所示的基于独立字典的联合稀疏表示模型以融合图像中的目标区域和阴影区域信息:

$$\begin{aligned} \hat{\mathbf{X}} &= \arg \min_{\mathbf{X}} \|\mathbf{y}_t - \mathbf{D}_t \mathbf{x}_t\|_F^2 + \|\mathbf{y}_s - \mathbf{D}_s \mathbf{x}_s\|_F^2, \\ \text{s.t.} \quad &\|\mathbf{X}\|_{\ell_1 \setminus \ell_2} \leq \varepsilon \end{aligned} \quad (2)$$

其中, \mathbf{y}_t 表示目标区域图像, \mathbf{y}_s 表示阴影区域图像, \mathbf{D}_t 为目标区域所使用的字典, \mathbf{D}_s 为阴影区域所使用的字典; $\mathbf{X} = [\mathbf{x}_t, \mathbf{x}_s]$ 为联合稀疏表示矩阵, \mathbf{x}_t 对应为目标区域的稀疏表示, \mathbf{x}_s 为阴影区域的稀疏表示; $\|\cdot\|_{\ell_1 \setminus \ell_2}$ 表示矩阵的 $\ell_1 \setminus \ell_2$ 混合范数, 即: 先对矩阵的行向量求 ℓ_2 范数, 然后再对结果向量求 ℓ_1 范数。由于将原有的 $\ell_0 \setminus \ell_2$ 混合范数松弛为 $\ell_1 \setminus \ell_2$ 混合范数, 该模型可以采用凸优化方法进行求解。通过引入拉格朗日乘子 λ , 上述模型可以进一步转化为

$$\begin{aligned} (P_{1,2}^\lambda): \quad \hat{\mathbf{X}} &= \arg \min_{\mathbf{X}} \|\mathbf{y}_t - \mathbf{D}_t \mathbf{x}_t\|_F^2 \\ &\quad + \|\mathbf{y}_s - \mathbf{D}_s \mathbf{x}_s\|_F^2 + \lambda \|\mathbf{X}\|_{\ell_1 \setminus \ell_2} \end{aligned} \quad (3)$$

上述模型中联合稀疏表示系数分别对应不同的字典, 所以称该模型为独立字典的联合稀疏表示模型。

3 JSRI(Joint Sparse Representation with Independent dictionary)算法

虽然对于独立字典的联合稀疏表示模型可以采用传统的“内点法”进行求解, 但在实际应用中, 出于对计算效率和问题规模的考虑, 需要采用只用向量矩阵乘积操作的一阶方法。文献[13]证明, FISTA(Fast Iterative Shrinkage Thresholding Algorithm)方法可以达到 $O(1/k^2)$ 的收敛率, 为目前一阶方法中可以证明的最优收敛率。

3.1 优化求解

本节给出基于 FISTA 方法的独立字典联合稀疏表示求解算法。

令 $F(\mathbf{X}) := f(\mathbf{X}) + g(\mathbf{X}) = \|\mathbf{y}_t - \mathbf{D}_t \mathbf{x}_t\|_F^2 + \|\mathbf{y}_s - \mathbf{D}_s \mathbf{x}_s\|_F^2 + \lambda \|\mathbf{X}\|_{\ell_1 \setminus \ell_2}$, 其中 $f(\mathbf{X}) = \|\mathbf{y}_t - \mathbf{D}_t \mathbf{x}_t\|_F^2 + \|\mathbf{y}_s - \mathbf{D}_s \mathbf{x}_s\|_F^2$, $g(\mathbf{X}) = \lambda \|\mathbf{X}\|_{\ell_1 \setminus \ell_2}$, L 为函数 f 梯度的 Lipschitz 常量, 即: 对所有 $\mathbf{A}, \mathbf{B} \in \mathbb{R}^{n \times 2}$, $\|\nabla f(\mathbf{A}) - \nabla f(\mathbf{B})\| \leq L \|\mathbf{A} - \mathbf{B}\|$ 。可以得到如表1所示的独立字典联合稀疏表示问题的JSRI算法:

表 1 JSRI 算法

算法	JSRI 算法
输入:	目标区域字典 \mathbf{D}_t , 阴影区域字典 \mathbf{D}_s , 目标区域数据 \mathbf{y}_t , 阴影区域数据 \mathbf{y}_s , 拉格朗日乘子 λ , Lipschitz 常量 L 。
步骤 1	初始化 $\mathbf{X}_0 = 0, \mathbf{Z}_1 = 0, t_1 = 1$;
步骤 2	While Not Stop
	(1) $\mathbf{X}_k = p_L(\mathbf{Z}_k)$, 其中
	$p_L(\mathbf{Z}_k) := \arg \min_{\mathbf{X}} \left\{ g(\mathbf{X}) + \frac{L}{2} \left\ \mathbf{X} - \left(\mathbf{Z}_k - \frac{1}{L} \nabla f(\mathbf{Z}_k) \right) \right\ ^2 \right\}$
	(2) $t_{k+1} = \left(1 + \sqrt{1 + 4t_k^2} \right) / 2$
	(3) $\mathbf{Z}_k = \mathbf{X}_k + \left(\frac{t_k - 1}{t_{k+1}} \right) (\mathbf{X}_k - \mathbf{X}_{k-1})$
End While	
输出:	目标区域稀疏表示系数 \mathbf{x}_t 为 \mathbf{X}_k 第 1 列向量, 阴影区域稀疏表示系数 \mathbf{x}_s 为 \mathbf{X}_k 第 2 列向量。

由于算法收敛速度较快, 上述 JSRI 算法可采用固定迭代次数的方式, 或者设定 \mathbf{X}_k 相对变化门限的方式作为停止条件。另外, 算法的收敛性证明可以参考文献[13]。

3.2 应用 FISTA 求解联合稀疏表示模型

由上面的算法可以看出, 循环中主要计算迭代后的邻近点操作 $p_L(\mathbf{Z}_k)$ 。当模型中 $g(\cdot)$ 为 ℓ_1 范数时, 其闭式解可通过元素级的软阈值操作得到。根据文献[14,15], 当 $g(\cdot)$ 取 $\ell_1 \setminus \ell_2$ 混合范数时, $p_L(\mathbf{Z}_k)$ 的闭式解可通过将软阈值操作推广到矩阵行上进行求解。按矩阵行的软阈值操作定义如下:

定义 1 (按矩阵行的软阈值操作 RST(Row based Soft-Thresholding)) 给定矩阵 $\mathbf{M} \in \mathbb{R}^{n \times m}$, 阈值 $v > 0$, 则对矩阵 \mathbf{M} $\text{RST}_v(\cdot)$ 操作定义为

$$\text{RST}_v(\mathbf{M}) = \forall i \in \{1, 2, \dots, n\}, \text{RST}_v(\mathbf{M}_i) \quad (4)$$

$$\text{其中 } \text{RST}(\mathbf{M}_i) := \begin{cases} 0, & \|\mathbf{M}_i\|_2 \leq v \\ \frac{\|\mathbf{M}_i\|_2 - v}{\|\mathbf{M}_i\|_2}, & \text{其它} \end{cases}$$

\mathbf{M}_i 表示矩阵的第 i 行。

由于独立字典的联合稀疏表示模型为凸优化问题, 通过对偶原理及文献[14,15]中相似的推导过程可得到如下定理:

定理 1 对任意给定的矩阵 $\mathbf{A} \in \mathbb{R}^{n \times m}$ 和 $v > 0$, 优化问题 $\mathbf{M}^* = \arg \min_{\mathbf{M}} \frac{1}{2} \|\mathbf{M} - \mathbf{A}\|_F^2 + v \|\mathbf{M}\|_{\ell_1 \setminus \ell_2}$ 具有唯一的闭式解: $\mathbf{M}^* = \text{RST}_v(\mathbf{A})$ 。

将上述定理应用于 JSRI 算法中可得

$$p_L(\mathbf{Z}_k) = \text{RST}_{\lambda L^{-1}} \left(\mathbf{Z}_k - \frac{1}{L} \nabla f(\mathbf{Z}_k) \right) \quad (5)$$

3.3 JSRI 算法复杂度分析

本节将讨论文中提出的 JSRI 算法的时间复杂度。对于式(3)的 $P_{1,2}^\lambda$ 问题, 本文主要运行时间消耗在计算邻近点操作 $p_L(\mathbf{Z}_k)$ 上。假定模型中所使用的字典 $\mathbf{D}_t, \mathbf{D}_s \in \mathbb{R}^{d \times n}$, 那么求解梯度 $\nabla f(\mathbf{Z}_k)$ 的复杂度为 $O(dn)$ 。而用于进行 RST 操作的复杂度为 $O(d)$ 。总体进行 $p_L(\mathbf{Z}_k)$ 操作的复杂度为 $O(dn)$ 。若算法循环次数为 k 次, 那么 JSRI 算法的时间复杂度为 $O(kdn)$ 。在实际应用过程中, 通常只需较少迭代次数算法就可以收敛, 故 JSRI 算法的运行时间只与数据维度 d 和字典中原子个数 n 有关。

4 联合阴影区域与目标区域图像的 SAR 目标识别

4.1 阴影区域和目标区域提取

目前有许多 SAR 图像分割方法可用于提取目标与阴影区域, 如基于条件三元马尔科夫场的方法^[6]等。由于本文的重点并不是寻找一种最优的分割方法, 而是关注所提出的 JSRI 模型融合目标与阴影信息后, 与单独使用某种信息相比, 对识别效果所带来的改善。所以文中采用比较简单的阈值分割方法进行 SAR 目标和阴影区域的提取。在 SAR 图像中, 目标区域像素一般具有较高的强度值, 而阴影区域具有较低的强度值。我们首先根据预先设定的阈值 $a, b \in [0, 1]$, 将 SAR 图像中像素值按照从大到小排序, 选取比例为 $[0, a]$ 的大像素作为目标区域, 同时选取比例为 $[b, 1]$ 的小像素作为阴影区域。为了去除孤立点, 接着对得到的目标区域和阴影区域二值图像进行形态学滤波。图 1 给出了一幅 BMP2 目标 SAR 图像经过分割后得到的结果。其中, 图 1(a) 为原始图像, 图 1(b) 为使用阈值 a 分割出目标区域后得到的目标区域图像, 图 1(c) 为使用阈值 b 分割出阴影区域后得到的阴影区域图像。由于阴影区域的实际回波值强度较小, 为了增强阴影区域对分类的影响, 将阴影区域像素值置为 1 减去原始幅值, 背景像素值赋为 0。

4.2 随机投影降维

将分割得到的图像数据列向量化后得到的数据维度通常较高, 需要采用有效的降维方法对其进行处理。本文采用稀疏表示分类方法中常用的随机投影法^[17]。给定原始的特征向量维数 d 和降维后的维数 r , 产生一个具有独立同标准正态分布的随机矩阵 $\mathbf{P} \in \mathbb{R}^{r \times d}$, 将矩阵 \mathbf{P} 左乘原始的特征向量 \mathbf{S} , 以得到降维后的向量 $\tilde{\mathbf{S}} = \mathbf{P}\mathbf{S} \in \mathbb{R}^{r \times n}$ 。训练数据和测试数据采用相同的随机投影矩阵 \mathbf{P} 进行降维。

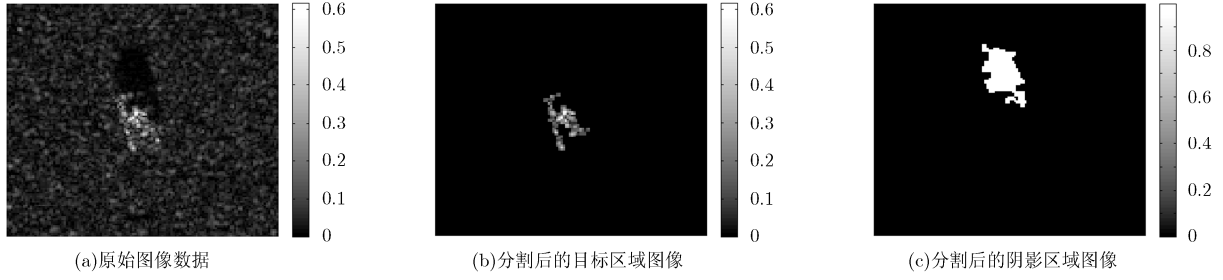


图1 SAR 图像目标区域与阴影区域提取示意图

4.3 字典构造

由于目标区域与阴影区域图像不同，我们采用独立字典的联合稀疏表示模型，因此需要对阴影区域和目标区域图像分别构造字典。给定 u 类训练样本，第 i 类训练样本个数为 n_i 。将降维后的第 i 类目标区域特征按列拼接成一个大小为 $r \times n_i$ 的矩阵 $[s_{i1}^{(i)}, s_{i2}^{(i)}, \dots, s_{in_i}^{(i)}]$ ，称为第 i 类目标区域字典 $D_t^{(i)}$ 。然后将所有目标区域字典连接起来就是所用的目标区域字典 $D_t = [D_t^{(1)}, D_t^{(2)}, \dots, D_t^{(u)}]$ 。按照与目标区域相同的顺序将降维后的第 i 类阴影区域特征拼接成一个大小为 $r \times n_i$ 的矩阵 $[s_{s1}^{(i)}, s_{s2}^{(i)}, \dots, s_{sm_i}^{(i)}]$ ，称为第 i 类阴影区域字典 $D_s^{(i)}$ 。接着将所有 $D_s^{(i)}$ 连接成 $D_s = [D_s^{(1)}, D_s^{(2)}, \dots, D_s^{(u)}]$ 。最后将字典中每一列原子按照 ℓ_2 范数进行能量归一化。

4.4 分类准则

通过求解 $P_{1,2}^\lambda$ 问题得到测试样本 y 在训练样本字典 D_t, D_s 上的联合稀疏表示后，本文根据联合重构误差最小准则进行类别判定。假定对应目标区域和阴影区域的联合稀疏表示系数分别为 x_t 和 x_s ，首先取出它们对应于第 i 类样本子字典的系数向量 $x_t^{(i)}$ 和 $x_s^{(i)}$ ，即取出 x_t 中与第 i 类目标区域字典 $D_t^{(i)}$ 位置对应的系数值，同时取出 x_s 中与第 i 类目标区域字典 $D_s^{(i)}$ 位置对应的系数值。于是可以计算出测试样本 y 在第 i 类子字典上的联合重构误差 $res_i(y) = \|y_t - D_t^{(i)}x_t^{(i)}\|_2^2 + \|y_s - D_s^{(i)}x_s^{(i)}\|_2^2$ 。最后根据联合重构误差最小准则给出分类结果 c ：

$$c = \min_i res_i(y) \quad (6)$$

4.5 联合阴影与目标区域图像的 SAR 目标识别过程

联合阴影与目标区域图像的 SAR 目标识别方法的流程如图 2 所示，下面对训练阶段与测试阶段分别进行介绍。

(1)训练阶段 首先，通过分割算法提取出 SAR 图像中的目标区域图像数据 S_t 和阴影区域图像数据 S_s 。然后根据原始样本维数 d 和设定的降维维数 r 生成一个随机高斯矩阵 $P \in \mathbb{R}^{r \times d}$ 。计算降维后的目标区域特征数据 $\tilde{S}_t = PS_t$ 和阴影区域数据 $\tilde{S}_s = PS_s$ 。最后，将降维后的数据矩阵 \tilde{S}_t 和 \tilde{S}_s 进行能量归一化得到数据字典 D_t 和 D_s ，同时记录各原子对应的类别标号。

(2)测试阶段 采用与训练阶段相同的分割算法提取测试图像 y 对应的目标区域图像数据 y_t 和阴影区域图像数据 y_s 。接着使用训练阶段生成的随机高斯矩阵 P 对 y_t 和 y_s 进行降维。然后通过 JSRI 算法求解得到联合稀疏表示系数 x_t 和 x_s 。最后根据联合稀疏表示系数 x_t 和 x_s 计算各子类联合重构误差，按照 4.4 节的分类准则得到分类结果 c 。为了叙述方便，我们将采用 JSRI 算法的分类方法记为 JSRC (Joint Sparse Representation with independent dictionary based Classification)。

5 实验结果与分析

本节所用的实验数据是美国国防预研计划署和空军研究实验室(DARPA/AFRL)联合资助的运动和静止目标获取与识别(MSTAR)计划录取的实测 SAR 地面静止目标数据。该数据是由 X 波段聚束式

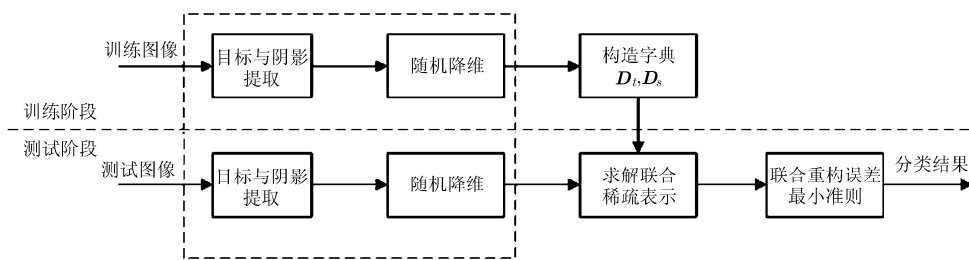


图2 联合阴影与目标区域图像的 SAR 目标识别方法流程图

SAR 采集得到。图像大小为 128×128 像素,分辨率为 $0.3 \text{ m} \times 0.3 \text{ m}$ 。该数据集包含了俯仰角为 15° 和 17° 下的 3 类目标共 7 种型号: BMP2(包含 3 个型号: SNC21, SN9563, SN9566), BTR70(包含 1 个型号: C71), T72(包含 3 个型号: SN132, SN812, SNS7)。本节实验主要涉及两种典型的目标识别场景: 3 类目标识别场景和 7 种型号识别场景。其中, 3 类目标识别场景主要验证识别算法对属于同一类型但不同型号的目标的识别能力; 7 种型号识别场景主要验证在不同类别数据具有较大相似情况下算法的识别能力。各场景使用的具体样本数目如表 2 和表 3 所示。两种场景中均使用俯仰角 17° 下的图像数据作为训练数据, 俯仰角 15° 下的图像数据作为测试数据。

为了验证本文算法的有效性, 将本文 JSRC 方法与只使用目标区域数据的 SRC 方法(记为 SRC-T), 只使用阴影区域数据的 SRC 方法(记为 SRC-S)以及 SVM 算法在两种 SAR 目标识别场景上进行性能比较。其中, SVM 分类实验采用 LIBSVM 算法包^[18]进行求解, 多类分类策略采用一对多策略^[19]。惩罚参数 C 从集合 $[10^{-4}, 10^{-2}, \dots, 10^2, 10^3]$ 中, 通过 10 折交叉验证选取。如无特别说明, 实验中所用分割阈值 $a = 0.05$, $b = 0.20$ 。文中所有结果均为独立进行 5 次实验以后取平均值得到。

5.1 联合阴影和目标区域的 SAR 目标识别

本节选取两种实验场景设置, 对比 JSRC 和 SRC-T, SRC-S 以及 SVM 算法的识别性能。实验中降维维度 r 选取 $[50, 100, 200, 300, 500]$, 图 3 给出了实验结果。由图可知, 在各种降维维度下 JSRC 识别性能是 4 种算法中性能最好的。如图 3 所示, 无论是 3 类识别场景还是 7 种型号识别场景, JSRC 算法要都比 SRC-T 算法识别率高出大约 2 个百分点。并且在 3 类识别场景中, 数据维度为 500 维时本文提出的 JSRC 算法已可达到 93.6% 的识别率。

在文献[7]中, 通过将 3 幅方位角度间隔为 $1^\circ \sim 3^\circ$ 的同目标图像联合进行识别, 并且在降维维度为 512 时才可达到 94.1%。而本文提出的 JSRC 算法只需要一幅目标图像就可以达到相近的识别结果。可见采用独立字典的联合稀疏表示模型可以有效地利用阴影区域信息, 从而提升识别性能。

我们知道, 阴影区域不包含强度信息, 只是目标形状遮挡地面反射回波形成。所以即使各类目标的散射特性有所差异, 但如果在雷达视线方向投影出的形状大体相似, 则成像后形成的阴影区域也会很相似。因此单纯借助阴影区域进行识别的性能较差, 且对目标姿态变化敏感(文献[4])。而单纯采用目标区域进行识别虽然可以达到较好的识别结果, 却损失了阴影区域中的有用信息。由于目标区域与阴影区域这两种信息在识别性能方面的差异较大, 使得传统的融合方法(如: 投票法)很难奏效。要想将阴影信息合理有效地融合进目标识别任务中, 就必须采用保守的融合方式, 即: 只利用两种信息之间的必然联系。为了进一步说明, 我们给出某幅 BMP2 图像在 SRC-T, SRC-S 以及 JSRC 算法中求得的稀疏表示系数示意图(见图 4)。其中虚线将图像划分成的 3 个区域分别对应 3 个不同的类别, 从左到右依次为 BMP2, BTR70 和 T72。如图 4 所示, 若单从目标区域的稀疏表示来看, 该类型应该属于 BTR70, 但是与 BMP2 类别之间的差异并不显著。而单从阴影的稀疏表示来看, 该类型会被判定属于 T72。可见单纯依赖某种信息得到的判决结果之间存在矛盾。本文 JSRC 算法在构造字典时对 D_t 和 D_s 使用了相同的拼接顺序, 测试时通过 $\ell_1 \setminus \ell_2$ 混合范数强迫联合稀疏表示系数中 x_t 和 x_s 所选原子具有相同的位置(如图 4(c)所示)。因此利用了目标与阴影之间应该具有的对应关系, 使得到的联合稀疏表示更加合理, 从而提升了识别性能。

表2 3类目标识别场景使用的训练和测试数据个数

数据类型	BMP2			BTR70		T72	
	SNC21	SN9563	SN9566	C71	SN132	SN812	SNS7
训练样本(俯仰角 17°)	233	0	0	233	232	0	0
测试样本(俯仰角 15°)	196	195	196	196	196	195	191

表3 7种型号识别场景使用的训练和测试数据个数

数据类型	BMP2			BTR70		T72	
	SNC21	SN9563	SN9566	C71	SN132	SN812	SNS7
训练样本(俯仰角 17°)	233	233	232	233	232	231	228
测试样本(俯仰角 15°)	196	195	196	196	196	195	191




图3 联合阴影和目标区域的 SAR 目标识别结果




图4 某幅 BMP2 测试图像在 3 种算法中求得的稀疏表示系数

5.2 分割阈值对识别性能的影响

本节选取 3 类识别场景，测试 JSRC 算法受图像分割质量影响的程度。本节实验中随机降维固定为 500 维，高强度分割阈值 a 取值范围为 [0.03, 0.04, 0.05, 0.06, 0.07]，低强度分割阈值 b 取值范围为 [0.30, 0.25, 0.20, 0.15, 0.10]。如图 5 所示，识别率随分割阈值的变化情况不大，平均识别率达到 93.26%，标准差为 0.0088。由此我们可看出 JSRC 算法受分割质量的好坏影响不大，因此可更好地应用于 SAR 目标识别任务。

6 结束语

地面 SAR 目标图像由目标区域和阴影区域两部分组成，如何充分而合理地利用 SAR 图像中的信息是提升 SAR 目标识别性能的关键。本文提出了一

种联合阴影区域与目标区域图像的 SAR 目标识别方法。该方法通过引入独立字典的联合稀疏表示模型达到了阴影区域与目标区域信息的有效融合。实验表明，该方法不仅可以进一步提高 SAR 目标识别精度，并且受 SAR 图像分割质量影响较小，具有较好的推广性。另外，本文模型中的字典是由训练样本直接构成的，如何通过机器学习的方法学习出识别性能更好，结构更紧凑的字典是需要进一步研究的问题。

参考文献

[1] 张红, 王超, 张波, 等. 高分辨率 SAR 图像目标识别[M]. 北京: 科学出版社, 2009: 5.2 节.
Zhang Hong, Wang Chao, Zhang Bo, et al. High Resolution SAR Image Target Recognition[M]. Beijing: Science Press, 2009: Chapter 5.2.

[2] Zhao Qun and Principe J C, et al. Support vector machines for SAR automatic target recognition[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2001, 37(2): 643-655.

[3] Sun Yi-jun, Liu Zhi-peng, Todorovics S, et al. Adaptive boosting for synthetic aperture radar automatic target recognition[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(1): 112-125.

[4] Scott P and Narayanan R M. Classification via the shadow region in SAR imagery[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(2): 969-980.




图5 识别率随分割阈值的变化

- [5] 尹奎英, 金林, 李成, 等. 融合目标轮廓和阴影轮廓的 SAR 图像目标识别[J]. 空军工程大学学报(自然科学版), 2011, 12(1): 24-28.
Yin Kui-ying, Jin Lin, Li Cheng, *et al.* An SAR ATR based on fusion of target contour and shadow contour[J]. *Journal of Air Force Engineering University (Natural Science Edition)*, 2011, 12(1): 24-28.
- [6] 孙志军, 薛磊, 许阳明, 等. 基于多层编码器的 SAR 目标及阴影联合特征提取算法[J]. 雷达学报, 2013, 2(2): 203-209.
Sun Zhi-jun, Xue Lei, Xu Yang-ming, *et al.* Shared representation of SAR target and shadow based on multilayer auto-encoder[J]. *Journal of Radars*, 2013, 2(2): 203-209.
- [7] Zhang Hai-chao, Nasrabadi N M, Zhang Yan-ning, *et al.* Multi-view automatic target recognition using joint sparse representation[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(3): 2481-2497.
- [8] Wright J, Yang A Y, *et al.* Robust face recognition via sparse representation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 210-227.
- [9] Zhang Hai-chao, Nasrabadi N M, Zhang Yan-ning, *et al.* Joint dynamic sparse representation for multi-view face recognition[J]. *Pattern Recognition*, 2012, 45(4): 1290-1298.
- [10] Maurer A, Pontil M, and Romera-Paredes B. Sparse coding for multitask and transfer learning[C]. Proceedings of the International Conference on Machine Learning, Atlanta, 2013: 343-351.
- [11] Gu H T and Ward R K. Learning sparse representations for human action recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(8): 1576-1588.
- [12] Wang Zhao-wen, Yang Jian-chao, *et al.* A max-margin perspective on sparse representation-based classification[C]. Proceedings of the IEEE International Conference on Computer Vision, Sydney, 2013: 1217-1224.
- [13] Amir Beck and Marc Teboulle. A fast iterative shrinkage-thresholding algorithm for linear inverse problems[J]. *Society for Industrial and Applied Mathematics Journal on Imaging Sciences*, 2009, 2(1): 183-202.
- [14] Chen Xi, Lin Qi-hang, *et al.* Smoothing proximal gradient method for general structured sparse regression[J]. *The Annals of Applied Statistics*, 2012, 6(2): 719-752.
- [15] Francis B, Rodolphe J, *et al.* Structured sparsity through convex optimization[J]. *Statistical Science*, 2012, 27(4): 450-468.
- [16] Lian Xiao-jie, Wu Yan, Zhao Wei, *et al.* Unsupervised SAR image segmentation based on conditional triplet markov fields[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(7): 1185-1189.
- [17] Baraniuk R and Wakin M. Random projections of smooth manifolds[J]. *Foundations of Computational Mathematics*, 2009, 9(1): 51-77.
- [18] Chang Chih-chung and Lin Chih-jen. LIBSVM: a library for support vector machines[J]. *ACM Transactions on Intelligent Systems and Technology*, 2011, 2(3): 1-27.
- [19] Bishop C M. Pattern Recognition and Machine Learning [M]. New York: Springer, 2008: 200-201.
- 丁 军: 男, 1982 年生, 博士生, 研究方向为雷达目标识别.
- 刘宏伟: 男, 1971 年生, 教授, 博士生导师, 实验室主任, 研究方向为自适应信号处理、雷达信号处理、雷达目标识别等.
- 王英华: 女, 1982 年生, 副教授, 硕士生导师, 研究方向为 SAR 图像目标检测与识别.