

基于非负稀疏表示的 SAR 图像目标识别方法

丁 军* 刘宏伟 王英华

(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: 针对合成孔径雷达(SAR)图像目标识别中存在物体遮挡的情况, 该文提出一种基于非负稀疏表示的分类方法。通过分析 L0 范数和 L1 范数最小化在求解非负稀疏表示问题上的区别, 证明在一定条件下, L1 范数最小化方法除了保持解的稀疏性还能得到与输入信号更加相似的原子集合, 因此也更加适用于分类问题中。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, 采用 L1 范数的非负稀疏表示分类方法能达到较好的识别性能, 并且相对传统方法对存在遮挡情况下的识别问题更稳健。

关键词: SAR 目标识别; 非负稀疏表示; L1 范数最小化

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2014)09-2194-07

DOI: 10.3724/SP.J.1146.2013.01451

SAR Image Target Recognition Based on Non-negative Sparse Representation

Ding Jun Liu Hong-wei Wang Ying-hua

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

Abstract: In order to solve the occlusion issue in SAR image target recognition, a new classification method is proposed based on non-negative sparse representation. The difference between L0-norm and L1-norm minimization in solving non-negative sparse representation problem is analyzed, and it is proved that L1-norm regularization method pursuits not only the sparsity of the solution but also the similarity between the input signal and the selected atoms under some conditions, hence it is fit for classification application. The experimental results on Moving and Stationary Target Acquisition and Recognition (MSTAR) dataset show that the non-negative sparse representation classification method with L1-norm regularization can achieve much better recognition performance, and it is more robust in the recognition of targets with occlusion compared with the traditional method.

Key words: SAR target recognition; Non-negative sparse representation; L1-norm minimization

1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)具有全天候、全天时、分辨率高以及穿透力强等特点, 成为目前对地观测和军事侦察的重要手段。随着 SAR 成像技术的不断成熟和分辨率的不断提高, 对于 SAR 图像自动目标识别技术的研究一直是国内外研究的热点。除了采用基于模板匹配的方法^[1]外, 韩萍等人^[2]利用核主成分分析(Kernel Principal Component Analysis, KPCA)方法提取特征, 然后采用支持向量机(Support Vector Machine, SVM)分类器进行分类; Zhao 等人^[3]采用 SVM 分类器直接

对 SAR 图像进行分类。由于目标所处环境的复杂性, 通过 SAR 获取到的目标图像可能会存在某种形式的变体。其中较为常见的一种变体形式是由于目标被其它物体部分遮挡造成的。而现有的 SAR 图像目标识别研究中则较少关注具有遮挡情况下的目标识别问题。所以如何在存在遮挡的情况下, 仍然保持较好的识别性能是 SAR 图像目标识别需要解决的一个重要问题。

近年来, 稀疏表示方法作为一种信号分析的有效工具, 在信号处理, 计算机视觉等领域受到了广泛关注。稀疏表示的目的是将给定的输入观测信号表示为字典中少数信号(又叫做原子)的线性组合。大量的研究发现, 现实生活中的许多信号都可以使用某种字典进行稀疏表示, 如: 语音, 图像, 视频等。由于稀疏分解后的结果包含原始信号的特定信息, 部分学者将稀疏表示方法引入到模式识别领域中^[4-10]。如 Wright 等人^[4]使用训练样本数据构造字

2013-09-23 收到, 2013-11-08 改回

国家自然科学基金(61271024, 61201292, 61201283), 新世纪优秀人才支持计划(NCET-09-0630), 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

典,再根据稀疏表示分解结果进行人脸识别。Zhang等人^[5]采用动态联合稀疏表示方法进行多视角下人脸识别。同时,Zhang等人^[6]也采用联合稀疏表示方法对多幅不同方位角下的SAR图像联合进行目标识别,并取得较好效果。Maurer等人^[7]通过稀疏表示进行多任务学习;Gu等人^[8]在行为识别中也采用了非负稀疏表示模型。最近,Mehta等人^[9]给出了预测性稀疏表示^[10]的泛化误差界,为采用稀疏表示进行有监督学习提供了理论依据。

本文将非负稀疏表示方法引入到SAR目标分类中,与原有的基于稀疏表示的分类方法(Sparse Representation-based Classification, SRC)^[4]相比,引入非负约束可以去掉稀疏表示解中与输入信号呈负相关的原子,更加符合SAR目标识别应用。在设计基于非负稀疏表示的SAR目标识别算法时,本文重点分析了L1范数最小化方法与L0范数最小化方法在求解非负稀疏表示问题时的差别。证明在一定条件下,L1范数最小化方法除了保持解的稀疏性还能得到与输入信号更加相似的原子集合。通过在MSTAR数据集上的试验表明,采用L1范数最小化的非负稀疏表示分类方法不仅在无遮挡情况下优于传统方法,并且在具有遮挡情况下仍然能保持较好的识别性能。

2 非负稀疏表示

2.1 稀疏表示模型

在假定存在噪声的情况下,稀疏线性模型可表示为

$$\mathbf{y} = \mathbf{D} \cdot \boldsymbol{\alpha} + \mathbf{n} \quad (1)$$

其中, $\mathbf{y} \in \mathbb{R}^{n \times 1}$ 为 n 维输入信号, $\mathbf{D} \in \mathbb{R}^{n \times m}$ ($m > n$)为一冗余字典, \mathbf{D} 中列向量称为原子, $\boldsymbol{\alpha} \in \mathbb{R}^{m \times 1}$ 为稀疏分解系数,即: $\boldsymbol{\alpha}$ 中除少量元素为非零值外,其余元素都为0, $\mathbf{n} \in \mathbb{R}^{n \times 1}$ 为模型噪声。上述模型中当输入信号 \mathbf{Y} 和字典 \mathbf{D} 给定时,求解稀疏分解系数 $\boldsymbol{\alpha}$ 的问题可以转化为求解式(2)的最优化问题:

$$\min \|\boldsymbol{\alpha}\|_0, \quad \text{s.t.} \quad \|\mathbf{y} - \mathbf{D} \cdot \boldsymbol{\alpha}\|_2^2 < \varepsilon \quad (2)$$

其中 $\|\cdot\|_0$ 表示L0范数。由于L0范数并不是真正意义上的范数,上述问题为NP难问题^[11]。一般情况下对于上述问题的求解主要有两类方法:一类是采用贪婪策略思路的算法,如:匹配追踪(Matching Pursuit, MP)和正交匹配追踪(Orthogonal Matching Pursuit, OMP)^[11]。另一类是将原问题松弛到一个凸问题上进行求解,如:基追踪去噪(Basis Pursuit DeNoising, BPDN)^[12]。

以往对SAR图像目标识别的研究表明,除去相干斑的影响,同类目标在散射条件相近情况下具有

相似的图像。相近的散射条件包括:目标姿态相近,雷达成像的俯仰角度相近,目标形状和散射特性相近。所以从物理机理上要求对SAR图像的稀疏表示应该分解到结构相似的原子集合上。因此本文将把非负稀疏表示方法应用于SAR目标识别中,以避免使用与输入信号存在较大差异的负相关原子来描述输入信号。下面对非负稀疏表示模型进行介绍。

2.2 非负稀疏表示模型

如果在原有稀疏表示模型基础上添加对分解系数为非负的约束,就得到非负稀疏表示模型。该模型可以表示为

$$\mathbf{y} = \mathbf{D} \cdot \boldsymbol{\alpha} + \mathbf{n}, \quad \text{s.t.} \quad \boldsymbol{\alpha} \geq 0 \quad (3)$$

与稀疏表示模型的求解方法类似,非负稀疏表示模型也可以采用两种方法进行求解:一种是采用贪婪策略的非负正交匹配追踪(Non-Negative OMP, NNOMP)^[13],其对应的最优化问题为

$$(P_{0+}): \min \|\boldsymbol{\alpha}\|_0, \quad \text{s.t.} \quad \|\mathbf{y} - \mathbf{D} \cdot \boldsymbol{\alpha}\|_2^2 < \varepsilon, \quad \boldsymbol{\alpha} \geq 0 \quad (4)$$

另一种是采用L1范数替代L0范数的松弛方法,原问题转化为

$$(P_{1+}^{\varepsilon}): \min \|\boldsymbol{\alpha}\|_1, \quad \text{s.t.} \quad \|\mathbf{y} - \mathbf{D} \cdot \boldsymbol{\alpha}\|_2^2 < \varepsilon, \quad \boldsymbol{\alpha} \geq 0 \quad (5)$$

通过引入拉格朗日乘子可以进一步转化为式(6)的形式:

$$(P_{1+}^{\lambda}): \min \|\mathbf{y} - \mathbf{D} \cdot \boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\alpha}\|_1, \quad \text{s.t.} \quad \boldsymbol{\alpha} \geq 0 \quad (6)$$

对于问题 P_{1+}^{λ} 可以采用梯度投影的稀疏重构(Gradient Projection for Sparse Reconstruction, GPSR)算法^[14]快速求解。

3 非负稀疏表示的分类方法

要将非负稀疏表示模型应用于分类问题需要解决字典构造,优化求解,设计分类准则3方面的问题。本节将对这几个方面进行详细的介绍。

3.1 字典构造

与文献[4]中字典构造方法类似,本文直接使用训练样本数据构成字典 \mathbf{D} 。给定 c 类训练样本,第 i 类训练样本个数为 n_i 。将第 i 类的样本数据 $[s_{i1}, s_{i2}, \dots, s_{in_i}]$ 称为第 i 类样本子字典,记为 \mathbf{D}_i 。然后将所有类别子字典连接起来就是所用的字典 $\mathbf{D} = [\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_i, \dots, \mathbf{D}_c]$ 。最后将所得到的字典中每一列原子按照L2范数进行能量归一。

3.2 选择 P_{0+} 还是选择 P_{1+}^{λ} 求解

当存在具有相同稀疏性并且重构误差也相等的多组解时, P_{0+} 问题选取其中哪一组解与所采用的具体求解算法有关。而由于L1范数不仅考虑了稀疏性的度量,也考虑了非零元素的具体数值,我们发现采用 P_{1+}^{λ} 方法得到的解通常与输入信号具有更好的相似性。

定理 1 在向量能量归一化的情况下, 假定存在 m 组稀疏度为 k 且重构误差为 0 的 P_{0+} 问题解。如果每组解对应的 k 个原子中只有 1 个为该组解特有的原子, 其余 $k-1$ 个原子为 m 组解共有; 假设由 m 个特有原子构成的集合记为 A , 且 A 中所有原子与输入信号共面。那么采用 P_{1+}^λ 问题求得的最优解一定是包含集合 A 中与输入信号向量夹角最小的原子的那一组解。

证明 情况 1: 首先证明只存在两组解的情况, 即集合 A 中只有 2 个原子。

设 \mathbf{y} 表示输入信号向量, A 中的两个原子向量分别为 \mathbf{s} 和 \mathbf{t} , 且 $\mathbf{y}^T \mathbf{s} > \mathbf{y}^T \mathbf{t}$ 。 \mathbf{y} 在重构误差为 0 时的 P_{0+} 问题解为 $[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{k-1}, \mathbf{s}]$ 和 $[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{k-1}, \mathbf{t}]$, 对应的表示系数向量分别为 $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_k]$ 和 $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_k]$ 。

因为 \mathbf{y} 与 \mathbf{s}, \mathbf{t} 共面, 且 \mathbf{s}, \mathbf{t} 都为 P_{0+} 问题解中原子, 那么 \mathbf{s}, \mathbf{t} 必在由 \mathbf{y} 分割平面而成的同一半平面内。否则, 由 \mathbf{s} 和 \mathbf{t} 可直接构成稀疏度为 2 的 P_{0+} 问题解, 与假设解中还存在别的原子向量 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{k-1}$ 矛盾。

又因为 $\mathbf{y}^T \mathbf{s} > \mathbf{y}^T \mathbf{t}$, 所以 \mathbf{s} 可以由 \mathbf{y} 和 \mathbf{t} 非负线性表示, 即: $\mathbf{s} = w_1 \mathbf{y} + w_2 \mathbf{t}$, $w_i \geq 0$,

$$\begin{aligned} \mathbf{y} &= \alpha_1 \mathbf{x}_1 + \alpha_2 \mathbf{x}_2 + \dots + \alpha_{k-1} \mathbf{x}_{k-1} + \alpha_k \mathbf{s} \\ &= \alpha_1 \mathbf{x}_1 + \alpha_2 \mathbf{x}_2 + \dots + \alpha_{k-1} \mathbf{x}_{k-1} + \alpha_k \cdot (w_1 \mathbf{y} + w_2 \mathbf{t}) \\ &= (\alpha_1 + \alpha_k w_1 \beta_1) \mathbf{x}_1 + (\alpha_2 + \alpha_k w_1 \beta_2) \mathbf{x}_2 + \dots, \\ &\quad + (\alpha_{k-1} + \alpha_k w_1 \beta_{k-1}) \mathbf{x}_{k-1} + (\alpha_k w_2 + \alpha_k w_1 \beta_k) \mathbf{t} \end{aligned}$$

因为 $\mathbf{y} = \beta_1 \mathbf{x}_1 + \beta_2 \mathbf{x}_2 + \dots + \beta_{k-1} \mathbf{x}_{k-1} + \beta_k \mathbf{t}$, 所以 $\beta_i = \alpha_i + \alpha_k w_1 \beta_i$, $i \leq k-1$; $\beta_k = \alpha_k w_2 + \alpha_k w_1 \beta_k$ 。

由三角不等式可得 $\sum_{i=1}^k \beta_i \geq 1$, $w_1 + w_2 \geq 1$; 又因为 $\mathbf{s} \neq \mathbf{t}$, 所以 $w_1 + w_2 > 1$ 。于是有

$$\begin{aligned} \|\boldsymbol{\beta}\|_1 - \|\boldsymbol{\alpha}\|_1 &= \sum_{i=1}^k \beta_i - \sum_{i=1}^k \alpha_i = \alpha_k w_1 \sum_{i=1}^k \beta_i + \alpha_k w_2 - \alpha_k \\ &> \alpha_k w_1 + \alpha_k w_2 - \alpha_k > 0 \end{aligned}$$

故采用 P_{1+}^λ 得到的解应为 $[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{k-1}, \mathbf{s}]$ 。

情况 2: 集合 A 中存在 2 个以上原子。

此时, 可根据非负稀疏表示系数的 L1 范数大小诱导出一个集合 A 上的全序关系。而有限集合上的全序关系为良序关系, 其中最小值即为 P_{1+}^λ 得到的解中包含的原子。 证毕

3.3 引入相对稀疏因子

在实际识别过程中, 由于输入样本可被字典非负稀疏表示的程度不一样, 很难针对一类问题确定一个绝对量的正则化因子。而对于 P_{1+}^λ 问题, λ 的有效取值范围为 $[0, \lambda_{\max}]$, $\lambda_{\max} = \|2\mathbf{D}^T \mathbf{y}\|_\infty$, 其中 $\|\cdot\|_\infty$ 为向量的 L_∞ 范数^[15]。即当 $\lambda \geq \lambda_{\max}$ 时, 稀疏表示最优值为 $\mathbf{0}$ 。为便于针对具体问题对正则化因子进行调节, 我们引入一个相对稀疏因子 $\tau \in [0, 1]$, 并使用 $\tau \cdot \lambda_{\max}$ 替换原有 P_{1+}^λ 问题中的 λ , 得到如下非负稀疏表示模型:

$$(P_{1+}^\tau): \min \|\mathbf{y} - \mathbf{D} \cdot \boldsymbol{\alpha}\|_2^2 + \tau \cdot \lambda_{\max} \|\boldsymbol{\alpha}\|_1, \text{ s.t. } \boldsymbol{\alpha} \geq 0 \quad (7)$$

3.4 分类过程

与文献[4]中分类准则相同, 本文采用重构误差最小准则进行分类。对于给定的测试样本 \mathbf{y} 通过求解 P_{1+}^τ 问题, 得到 \mathbf{y} 在训练样本字典 \mathbf{D} 上的非负稀疏表示系数 $\boldsymbol{\alpha}$ 。取出其对应于第 i 类样本字典的系数向量 $\boldsymbol{\alpha}^{(i)}$, 即取出 $\boldsymbol{\alpha}$ 中与字典 \mathbf{D}_i 位置对应的系数值。于是可以计算出测试样本 \mathbf{y} 在第 i 类样本字典上的重构误差 $\text{res}_i(\mathbf{y}) = \|\mathbf{y} - \mathbf{D}_i \boldsymbol{\alpha}^{(i)}\|_2^2$ 。最后根据重构误差最小的原则给出分类结果 c :

$$c = \min_i \text{res}_i(\mathbf{y}) \quad (8)$$

4 基于非负稀疏表示分类的 SAR 图像目标识别

4.1 预处理

采用对数变换加中值滤波方法对原始 SAR 图像进行处理, 以减弱相干斑的影响。图 1 给出了一幅 BMP2 目标 SAR 图像的预处理结果。

4.2 随机投影降维

随机投影方法是近年来出现的一种有效的降维




图 1 SAR 图像预处理结果示意图

方法^[16]。该方法实现简单，运算快速，并且与所需降维数据无关。给定一个具有 m 个训练样本的矩阵 $\mathbf{S} \in \mathbb{R}^{n \times m}$ ，需要将其由 n 维降低到 r 维，只需要简单的对 \mathbf{S} 左乘上一个具有独立同标准正态分布的随机矩阵 $\mathbf{R} \in \mathbb{R}^{r \times n}$ 。即：降维后的数据矩阵 $\tilde{\mathbf{S}} = \mathbf{R}\mathbf{S} \in \mathbb{R}^{r \times m}$ ，其中每一列向量为降维后的 r 维样本特征。需要注意的是，对于训练数据和测试数据均采用相同的随机投影矩阵进行降维。

4.3 基于非负稀疏表示分类的SAR图像目标识别过程

基于非负稀疏表示分类方法的SAR图像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。




图2 基于非负稀疏表示的SAR图像目标识别方法流程图

(1) 训练阶段

第1步 预处理：如4.1节所述，为了减轻SAR图像中相干斑现象对识别性能的影响，对所有训练样本数据进行对数变换和中值滤波，得到预处理后的数据矩阵 $\mathbf{S} \in \mathbb{R}^{n \times m}$ ；

第2步 随机投影降维：如4.2节所述，根据预处理后的数据 \mathbf{S} 的维数 n 和降维后的维数 r 生成一个随机高斯矩阵 $\mathbf{R} \in \mathbb{R}^{r \times n}$ 。计算降维后的样本数据 $\tilde{\mathbf{S}} = \mathbf{R}\mathbf{S} \in \mathbb{R}^{r \times m}$ ；

第3步 构造字典：对降维后的数据矩阵 $\tilde{\mathbf{S}}$ 进行能量归一化得到数据字典 \mathbf{D} ，同时记录各原子对应的类别标号。

(2) 测试阶段

第1步 预处理：与训练阶段采用相同的预处理过程；

第2步 随机投影降维：使用训练阶段生成的随机高斯矩阵 \mathbf{R} 进行降维；

第3步 求解非负稀疏表示问题：通过贪婪策略方法或者凸优化方法求解非负稀疏表示问题，得到非负稀疏表示系数 α 。为了方便叙述，本文中采用贪婪策略求解的分类方法记为 NSG (Non-negative Sparse representation via Greedy strategy)，而通过优化求解 P_{1+} 问题的分类方法记为 NSC (Non-negative Sparse representation via Convex optimization)；

第4步 分类：根据非负稀疏表示系数 α 计算各子类重构误差，按照3.4节的分类准则得到分类结果 c 。

5 实验结果与分析

为了验证本文算法的有效性，将本文 NSC 和 NSG 算法与线性 SVM(记为 SVM)和核 SVM(记为 K-SVM)，以及 SRC 算法在 MSTAR 数据集上进行比较。NSC 采用 GPSR 进行求解，如未加说明，参数 $\tau=0.85$ ；参考文献[17]，SRC 采用 $l1_ls$ ^[15]进行求解；SVM 和 K-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]。其中 K-SVM 中使用径向基核函数，惩罚参数 C 从集合 $[10^{-4}, 10^{-2}, \dots, 10^2, 10^3]$ 中，核参数 σ 从集合 $[10^{-5}, 10^{-3}, \dots, 10^3, 10^5]$ 通过 10 折交叉验证选取。如无特别说明，所有结果均为独立进行 5 次实验以后取平均值得到。

5.1 实验数据与实验设置

5.1.1 实验数据 本节实验所用的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。数据是由聚束式 SAR 采集而得，分辨率为 $0.3 \text{ m} \times 0.3 \text{ m}$ ，目标图像大小为 128×128 像素。本实验使用的数据集包括了俯仰角在 17° 和 15° 下 3 大类目标共 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)。每类目标的方位覆盖范围均为 $0^\circ \sim 360^\circ$ 。

5.1.2 实验场景 本文实验选取 17° 俯仰角下的图像数据作为训练样本， 15° 俯仰角下的图像数据作为测试样本。实验主要涉及如下两种典型的场景。各场景使用的具体样本数目如表 1 所示。

场景 1：3 类目标识别

测试数据中存在与训练数据类型相同但型号不同的数据。该测试场景主要验证识别算法对于不同型号的同一种目标的识别能力。

场景 2：7 种型号识别

测试数据中出现的型号与训练数据完全相同。同一种类型不同型号的数据被认为属于不同的类别。该测试场景主要验证在不同类别数据具有较大相似情况下的识别能力。

5.1.3 遮挡数据生成 为了验证算法在存在遮挡时的识别效果，本文人工合成了一组具有部分遮挡效果的 SAR 目标图像测试数据。图 3 为一幅遮挡图像的产生过程。首先将 MSTAR 数据集中 SLICY 图像数

表1 不同场景使用的训练和测试数据个数 (a) 3类目标识别场景数据

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 1 不同场景使用的训练和测试数据个数 (b) 7 种型号识别场景数据

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

据(为了达到较大遮挡面积,选取方位角为 260.95° 的图像,如图 3(a)所示)经过分割后得到的图像数据作为遮挡图像。接着从原始图像中指定区域(图 3(c)中虚线框区域,该矩形区域左上点坐标为[50,50],高度和宽度均为 30 像素)随机选取一个点作为被遮挡区域的中心位置;然后使用遮挡图像除以原始图像中像素最大值后的图像替换掉原始图像中被遮挡部分(图 3(c)中实线框区域显示了这种遮挡效果)。

接下来,5.2 节将研究相对稀疏因子取值对非负稀疏表示分类方法在识别性能方面的影响;然后在 5.3 节,进一步讨论训练样本集大小与识别性能之间的关系;最后在 5.4 节中,针对两种实验场景,分别分析测试样本在有无遮挡情况下的识别效果,并将本文方法与一些现有方法进行对比。

5.2 相对稀疏因子对性能的影响

本节选取 7 种型号识别场景,在测试数据具有遮挡情况下,研究相对稀疏因子对识别性能的影响。其中随机降维维数为 300,相对稀疏因子 τ 值的选取范围为[0.20, 0.40, 0.60, 0.80, 0.85, 0.90]。为了减小随机产生遮挡对实验结果的影响,固定了 5 次实验的测试数据,但每次实验产生不同的随机降维矩阵。实验结果如图 4 所示,其中图 4(a)显示了识别率随相对稀疏因子 τ 的变化情况,图 4(b)显示了稀疏度

K 随相对稀疏因子 τ 的变化情况。

由图 4 可以看出,当解的稀疏度相对集中(即符合数据的非负稀疏表示分布情况)时,识别效果较好。例如:在 $\tau = 0.40$ 时,稀疏度中值为 44,四分位间距为 30; $\tau = 0.60$ 时,稀疏度中值为 36,变化不大,但四分位间距为 336,数据的稀疏度分布范围变宽,识别率下降。一般情况下,数据的稀疏度不会太大,所以相对稀疏因子应该稍微取大一些,例如:0.85。而当进一步加大解的稀疏度惩罚至 0.9 左右,解的平均稀疏度大约为 2。此时非负稀疏表示对于输入信号的重构误差变大,无法很好地表示输入信号,使得分类效果下降。

5.3 训练样本集大小对性能的影响

本节同样选取 7 种型号识别场景,具有遮挡情况下的实验,研究不同训练样本集大小对不同算法识别性能的影响。其中随机降维维数为 300,相对稀疏因子为 0.85,样本集大小范围为[800, 1000, 1200, 1400, 1600]。图 5 给出了实验结果。如图 5 所示,NSC 和 NSG 识别性能随样本集增大而呈线性上升。相对于 SVM 方法只利用支撑向量信息而言,NSC 和 NSG 方法可以利用样本字典中全部信息,所以通过扩充样本集大小可以提高 NSC 和 NSG 方法的识别性能。




图 3 遮挡产生过程示例图

5.4 有无遮挡情况下的对比实验

本节针对两种识别场景，分别在目标有无遮挡情况下，测试不同算法的识别性能。基于 5.2 节和 5.3 节的分析，本文提出的 NSG 和 NSC 算法中的参数设置如下：训练样本集选取全部训练数据， $\tau = 0.85$ 。图 6 给出了遮挡前后各方法对应识别率随数据维度的变化曲线。从图 6 可以看出，4 种情况下 NSC 的识别性能都要优于其他方法。随着数据维数的增大，包含的类别信息更多，识别率也随之升高。另外，同样为非负稀疏表示方法，采用 L1 范数最小化得到的识别结果(图 6 中 NSC 曲线)要高于采用贪婪策略求解的识别结果(图 6 中 NSG 曲线)，且识别率高出 5% 以上。由此验证了本文在 3.2 节关于 L1 范数与 L0 范数之间在分类应用下存在差异性的分析。

遮挡前后各算法识别率下降情况如表 2 所示，其中黑体标注的为每一列中下降幅度的最小值。由

表 2 可以看出，从识别率降低情况来看，基于稀疏表示的方法(NSC, NSG 和 SRC)受遮挡情况的影响相对较小。但是由于 NSC 本身识别率最高(3 类时候达到 89%，7 类问题达到 99%)，所以从相对性能下降标准来看 NSC 受遮挡影响最小，因此也更加适合应用于存在遮挡情况下的 SAR 图像目标识别。

6 结束语

在存在一定遮挡情况下目标识别算法的稳健性对于 SAR 图像目标识别具有十分重要的意义。本文提出了一种基于非负稀疏表示的 SAR 目标识别方法。该方法对于目标是否被遮挡不敏感，识别性能相对传统分类方法更加稳健。理论分析和实验结果表明，采用 L1 范数优化的 NSC 方法比采用 L0 范数优化的非负稀疏表示分类方法具有更好的识别性能，这说明在追求非负稀疏表示稀疏性的同时保证分解原子与输入信号之间的相似性，对于分类问题的求解是有益处的。

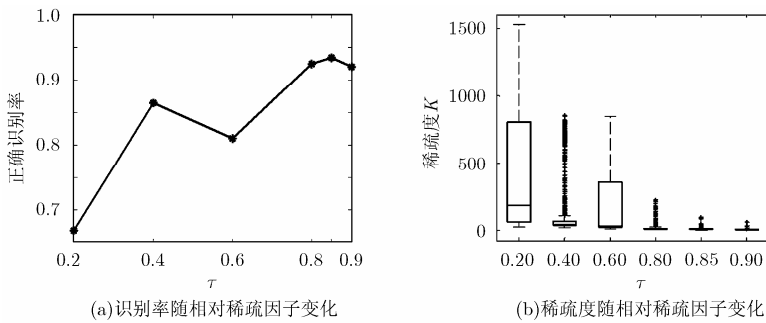


图 4 识别率和稀疏度随相对稀疏因子的变化曲线




图 5 识别率随训练样本集大小的变化图

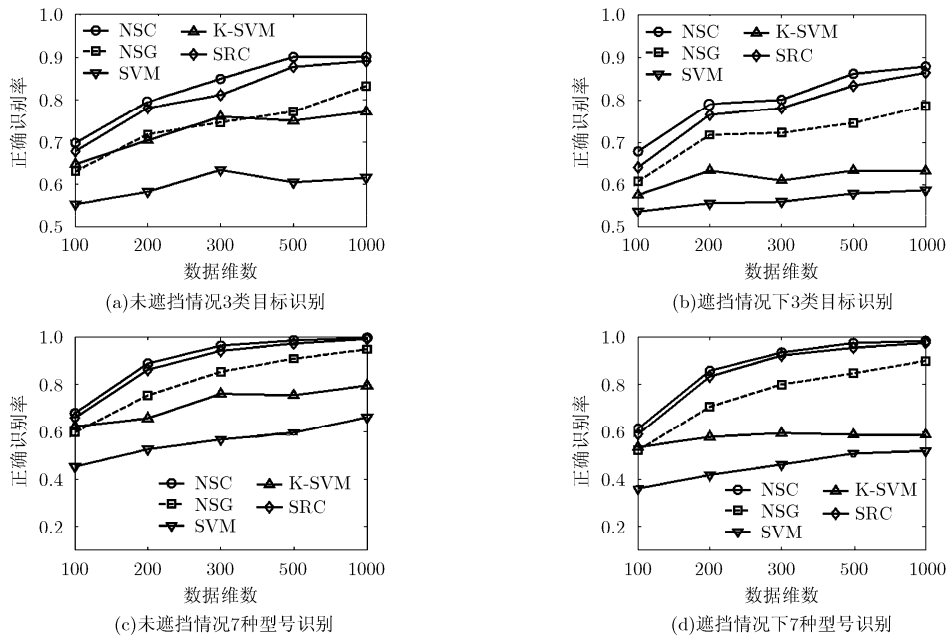


图 6 遮挡前后各算法识别率随数据维数的变化

表2 遮挡后的识别率与遮挡前相比下降的百分比 (a) 3类目标识别场景实验结果(%)

算法	100 维	200 维	300 维	500 维	1000 维	平均值
SRC	3.74	1.61	2.92	4.28	2.56	3.022
K-SVM	7.11	7.11	15.02	11.65	13.92	10.962
SVM	1.76	2.64	7.40	2.49	3.00	3.458
NSG	2.20	0.80	2.42	2.56	4.54	2.504
NSC	1.90	0.43	4.76	3.88	2.12	2.618

表 2 遮挡后的识别率与遮挡前相比下降的百分比 (b) 7 种型号识别场景实验结果(%)

算法	100 维	200 维	300 维	500 维	1000 维	平均值
SRC	6.96	3.00	2.05	1.76	1.70	3.094
K-SVM	8.93	8.05	16.77	16.70	20.95	14.280
SVM	9.18	10.79	10.65	8.74	14.16	10.704
NSG	7.69	4.91	5.27	6.01	4.84	5.744
NSC	6.59	3.00	2.78	1.03	1.39	2.958

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.
- [2] 韩萍, 吴仁彪, 王兆华, 等. 基于 K P C A 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.
- [3] Zhao Qun, 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.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] Maurer A, Pontil M, and Romera-Paredes B. Sparse coding for multitask and transfer learning[C]. Proceedings of International Conference on Machine Learning, Atlanta, 2013: 343-351.
- [8] 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.
- [9] Mehta N and Gray A. Sparsity-based generalization bounds for predictive sparse coding[C]. Proceedings of International Conference on Machine Learning, Atlanta, 2013: 36-44.
- [10] Bach F, Mairal J, and Ponce J. Task-driven dictionary learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(4): 791-804.
- [11] Elad M. Sparse and Redundant Representations: from Theory to Applications in Signal and Image Processing[M]. New York: Springer, 2010: 34-35.
- [12] Chen S S, Donoho D L, *et al.*. Atomic decomposition by basis pursuit[J]. *Society for Industrial and Applied Mathematics Review*, 2001, 43(1): 129-159.
- [13] Bruckstein A M, Elad M, and Zibulevsky M. On the uniqueness of nonnegative sparse solutions to underdetermined systems of equations[J]. *IEEE Transactions on Information Theory*, 2008, 54(11): 4813-4820.
- [14] Figueiredo M A T, Nowak R D, *et al.*. Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2007, 1(4): 586-597.
- [15] Kim Seung-Jean, Koh K, Lustig M, *et al.*. An interior-point method for large-scale l_1 -regularized least squares[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2007, 1(4): 606-617.
- [16] Baraniuk R and Wakin M. Random projections of smooth manifolds[J]. *Foundations of Computational Mathematics*, 2009, 9(1): 51-77.
- [17] Zhang Lei, Yang Meng, and Feng Xiang-chu. Sparse representation or collaborative representation: which helps face recognition? [C]. Proceedings of the IEEE International Conference on Computer Vision, Barcelona, 2011: 471-478.
- [18] Chang Chih-chung and Lin Chih-jen. LIBSVM: a library for support vector machines[J]. *ACM Transactions on Intelligent Systems and Technology*, 2011, DOI: 10.1145/1961189.1961199.
- [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, 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.