

基于稀疏求解的改进 PCA 方法在 SAR 目标识别中的应用*

肖 垚^{1,2†}, 刘 畅¹

(1 中国科学院电子学研究所, 北京 100190; 2 中国科学院大学, 北京 100049)

(2016 年 11 月 18 日收稿; 2017 年 3 月 1 日收修改稿)

Xiao Y, Liu C. Improved PCA method for SAR target recognition based on sparse solution[J]. Journal of University of Chinese Academy of Sciences, 2018,35(1):84-88.

摘 要 针对实际军事情况下车辆目标为非合作目标,提出改进的主成分分析方法(IPCA)。它首先利用稀疏求解方法得到与测试样本最相关的部分训练样本以及它们对测试样本的表示系数。然后结合主成分分析(PCA)得到最优投影矩阵,使投影后不同测试样本能更好地利用训练样本信息进行分类。利用美国运动和静止目标获取与识别数据库中 3 类目标进行识别实验,结果表明基于改进的 PCA 方法比传统的 PCA 方法能够得到更高的识别率,并对稀疏方位角训练样本有更好的鲁棒性。

关键词 合成孔径雷达(SAR);目标识别;稀疏表示;主成分分析

中图分类号:TN957 **文献标志码:**A **doi:**10.7523/j.issn.2095-6134.2018.01.011

Improved PCA method for SAR target recognition based on sparse solution

XIAO Yao^{1,2}, LIU Chang¹

(1 Institute of Electronics, Chinese Academy of Sciences, Beijing 100190, China;

2 University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract In this work, an improved principal component analysis method (IPCA) is proposed for SAR target recognition. Firstly, we use the sparse method to obtain the training samples which are most relevant to the test samples and their representation coefficients for the test samples. Then, using the principal component analysis (PCA) we obtain the optimal projection matrix so that different test samples after projection can be better classified by using the training sample information. The results of experiments, performed on SAR ground stationary targets based on the moving and stationary target acquisition and recognition (MSTAR) database, show that IPCA reaches higher recognition rate and better robustness to sparse aspect training samples of three true objects than PCA.

Keywords synthetic aperture radar (SAR); target recognition; sparse representation; principle component analysis

* 国家部委预研项目资助
† 通信作者, E-mail: yaoxiao115@126.com

合成孔径雷达 (synthetic aperture radar, SAR) 是一种工作在微波波段的成像雷达, 凭借其全天候、全天时、高分辨率、大面积的数据获取能力成为当前遥感观测的重要手段。但随着 SAR 图像的大量获取, 并且由于其与光学成像系统的显著差异, 传统的人工 SAR 图像车辆目标识别远远不能满足实际的应用需求, 自动 SAR 图像车辆目标识别技术已经成为当今研究的热点^[1]。目前国内外关于 SAR 图像目标识别已有大量文献。文献[2]直接采取模板匹配进行识别; 文献[3]研究线性和非线性 PCA (principle component analysis, 主成分分析) 在 SAR ATR 中的应用; 文献[4]首先利用 NMF 进行特征提取, 然后选取 SVM 分类方法; 文献[5-8]均是首先提取特征例如 Gabor, PCA 等, 然后利用稀疏表示分类方法进行目标识别。文献[9-10]利用深度学习中的卷积神经网络进行目标识别; 文献[11]采用多特征决策融合的技术来改善识别性能。

虽然上述文献都取得较好的识别性能, 但均未考虑到实际情况中目标往往是非合作目标, 很难获取一个目标的大量方位角 SAR 图像。所以针对稀疏方位角的训练样本的目标识别研究是一个重要的方向。文献[12]也考虑到非合作目标的情况, 利用一种加权图像融合方法进行稀疏样本集扩充然后进行识别分类。而本文针对实际情况中的非合作目标识别问题, 考虑到稀疏表示与 PCA 特征提取各自的优势^[13], 提出一种结合稀疏求解方法的改进 PCA 方法 (improved PCA, IPCA), 它首先利用稀疏求解方法为每个测试样本寻找最相关的 k 个训练样本, 并得到这 k 个最相关的训练样本对测试样本的表示系数, 然后基于传统的 PCA 方法和这些最相关的部分训练样本信息对测试样本进行分类。因此 IPCA 方法不仅具有传统 PCA 方法的效果, 而且更有利于对测试样本的分类。

1 改进 PCA 方法原理

1.1 稀疏求解思想找 k 个最近邻样本

稀疏描述的思想是用少量的样本来表示测试样本, 其基本原理是假设有 c 类样本, 其中 M_i 是第 i 类训练样本的个数, 每个样本表示成一个列向量的形式, 矩阵 \mathbf{A}_i 表示第 i 类的所有训练样本, 即

$$\mathbf{A}_i = [\mathbf{a}_{i1}, \mathbf{a}_{i2}, \dots, \mathbf{a}_{iM_i}] \in \mathbf{R}^{N \times M_i}, \quad (1)$$

其中 N 表示向量的维数, $\mathbf{a}_{ij} (j = 1, 2, \dots, M_i)$ 表示第 i 类的第 j 个样本。当第 i 类的训练样本充足的时候, 属于第 i 类的测试样本 \mathbf{y} 能够较准确地由第 i 类的训练样本表示为

$$\mathbf{y} \approx w_{i1}\mathbf{a}_{i1} + \dots + w_{iM_i}\mathbf{a}_{iM_i}, \quad (2)$$

系数 $w_{ij} (j = 1, \dots, M_i)$ 表示第 i 类的第 j 个样本对测试样本 \mathbf{y} 的贡献。然而, 事先不知道样本 \mathbf{y} 所属的类别, 所以矩阵 $\mathbf{A}_i (i = 1, \dots, c)$ 进行合并形成一个字典矩阵 $\mathbf{A} = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_c] \in \mathbf{R}^{N \times M}$, 其中 $M = \sum_{i=1}^c M_i$ 表示所有的训练样本数目。给定一个测试样本 \mathbf{y} , 可用所有训练样本的组合表示 \mathbf{y} , 即

$$\mathbf{y} = \mathbf{A}\mathbf{w}, \quad (3)$$

其中 $\mathbf{w} = [w_{11}, \dots, w_{1M_1}, \dots, w_{i1}, \dots, w_{iM_i}, \dots, w_{c1}, \dots, w_{cM_c}]$ 表示稀疏系数。根据式(2), 属于类别 i 的测试样本的权重系数应该是

$$\mathbf{w} = [0, \dots, 0, \dots, w_{i1}, \dots, w_{iM_i}, \dots, 0, \dots, 0], \quad (4)$$

也就是说, 测试样本 \mathbf{y} 能够被和它同类别的训练样本准确表示, 而与它不同类的训练样本无关。考虑方程(3), 给定 \mathbf{y} 和 \mathbf{A} , 解 \mathbf{w} 与 $\mathbf{A} \in \mathbf{R}^{N \times M}$ 密切相关。当 $N > M$ 时, 方程(3) 是一个过定系统, \mathbf{w} 具有唯一解。但是大部分实际情况下 $N < M$, 方程(3) 是欠定的, 存在无数多个解。由式(4) 知, 最后的解 \mathbf{w} 是稀疏的。所以方程(3) 可以通过求解以下优化问题得到:

$$\mathbf{w}_0^* = \operatorname{argmin} \|\mathbf{w}\|_0 (\text{s.t. } \mathbf{y} = \mathbf{A}\mathbf{w}), \quad (5)$$

式中 $\|\cdot\|_0$ 表示 L_0 范数, 即一个向量中非零元的个数。式(5) 在少量误差的情况下可以改写为

$$\mathbf{w}_0^* = \operatorname{argmin} \|\mathbf{w}\|_0 (\text{s.t. } \|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2 \leq \varepsilon), \quad (6)$$

其中 ε 表示误差为一个很小的正整数。然而式(6) 的求解是一个 NP 问题, 即多项式复杂程度的非确定性问题, 不仅计算复杂度极高, 而且解的可靠性也得不到保证。而研究^[14] 表明, 式(6) 的求解可以转化为 L_1 优化问题即

$$\mathbf{w}_0^* = \operatorname{argmin} \|\mathbf{w}\|_1 (\text{s.t. } \|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2 \leq \varepsilon), \quad (7)$$

式(7) 的优化问题可以通过迭代求解, 这样每一个测试样本均要进行迭代计算, 运算时间复杂度较高。为了提高 SAR 目标识别的速度, 考虑直接利用所有训练样本去表示测试样本, 保证表示误差最小化, 即简化为如下优化问题进行快速求解:

$$\min_w (\mathbf{y} - \mathbf{A}\mathbf{w})^2. \tag{8}$$

在实际情况中通常要求解向量 \mathbf{w} 的范数较小,因此将式(9)的最小化作为我们的目标函数。

$$L(\mathbf{w}) = \|\mathbf{y} - \mathbf{A}\mathbf{w}\|^2 + \lambda \|\mathbf{w}\|^2 = (\mathbf{y} - \mathbf{A}\mathbf{w})^T (\mathbf{y} - \mathbf{A}\mathbf{w}) + \lambda \mathbf{w}^T \mathbf{w}, \tag{9}$$

式中 λ 为一小的正常数,利用拉格朗日方法:

$$\frac{\partial L(\mathbf{w})}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = (\mathbf{A}^T \mathbf{A} + \lambda \mathbf{I})^{-1} \mathbf{A}^T \mathbf{y}, \tag{10}$$

式中 \mathbf{I} 表示单位矩阵。

假设 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_M]$, 利用公式(10) 求出 \mathbf{w} , 然后根据下式

$$d_i = \|\mathbf{y} - \mathbf{w}_i \mathbf{a}_i\|_2 \tag{11}$$

计算第 i 个训练样本到测试样本的距离,取最小的 k 个距离的训练样本 $\mathbf{A}' = [\mathbf{a}'_1, \mathbf{a}'_2, \dots, \mathbf{a}'_k]$ 作为与测试样本最相关的样本。

利用式(10)重新利用最相关的 k 个训练样本构成新的训练样本矩阵 \mathbf{A}' 对 \mathbf{y} 进行描述,得到最相关的 k 个样本在测试样本描述中的权重 $\mathbf{w}' = [w'_1, w'_2, \dots, w'_k]$, 其中越大的 w'_i 对应的训练样本越与测试样本相关。

1.2 传统的主成分分析 (PCA)

首先对训练样本集 \mathbf{A} 的每一列进行零均值化,然后计算 \mathbf{A} 的协方差矩阵 $\mathbf{S}_x = \mathbf{A}\mathbf{A}^T$ 的特征值和相应的特征向量,实际上,当原始样本的每个向量的维数非常大时,协方差矩阵 $\mathbf{S}_x = \mathbf{A}\mathbf{A}^T$ 的维数将非常高,这样直接求取协方差矩阵的特征值和特征向量将付出很高的计算代价。事实上可以通过一种转化的方式先求矩阵 $\mathbf{A}^T \mathbf{A}$ 的前 p 个最大特征值和相对应的特征向量,再转化为求解 $\mathbf{S}_x = \mathbf{A}\mathbf{A}^T$ 的特征值和所对应的特征向量。假设 γ, \mathbf{v} 分别表示 $\mathbf{A}^T \mathbf{A}$ 的特征值和相应的特征向量,则有

$$(\mathbf{A}^T \mathbf{A}) \mathbf{v} = \gamma \mathbf{v}. \tag{12}$$

将式(12)两边同时左乘 \mathbf{A} 得到

$$\mathbf{A}(\mathbf{A}^T \mathbf{A}) \mathbf{v} = \gamma \mathbf{A} \mathbf{v}, \tag{13}$$

$$(\mathbf{A}\mathbf{A}^T)(\mathbf{A}\mathbf{v}) = \gamma (\mathbf{A}\mathbf{v}), \tag{14}$$

从(14)式可以看出 $\mathbf{S}_x = \mathbf{A}\mathbf{A}^T$ 的特征值和特征向量分别为 $\gamma, \mathbf{A}\mathbf{v}$ 。所以取矩阵 $\mathbf{A}^T \mathbf{A}$ 的前 p 个最大特征值对应的特征向量构成矩阵 \mathbf{B} , 则 $\mathbf{S}_x = \mathbf{A}\mathbf{A}^T$ 的前 p 个最大值对应的特征向量构成的投影矩阵 $\mathbf{E} = \mathbf{A}\mathbf{B}$ 。 \mathbf{E} 用于后续特征提取。

1.3 改进 PCA 特征提取分类

利用式(15)和式(16)对最相关的训练样本和测试样本 \mathbf{y} 进行特征抽取。

$$\mathbf{z}_j = \mathbf{w}'_j \mathbf{E}^T \mathbf{a}'_j, j = 1, 2, \dots, k, \tag{15}$$

$$\mathbf{z} = \mathbf{E}^T \mathbf{y}. \tag{16}$$

式中, \mathbf{z}_j 和 \mathbf{z} 分别表示第 j 个最相关的训练样本 \mathbf{a}'_j 和测试样本 \mathbf{y} 的特征抽取结果,即改进 PCA 的特征与传统 PCA 特征区别在于多了表示系数这一乘积项。最后根据下式将测试样本 \mathbf{y} 分类到 \mathbf{a}'_m 所属的类别。

$$m = \operatorname{argmin}_j \|\mathbf{z}_j - \mathbf{z}\|, j = 1, 2, \dots, k. \tag{17}$$

2 实验设计与结果分析

2.1 实验数据

本文实验采用美国 MSTAR 数据库^[15]中的 3 类 SAR 车辆静止目标 BMP、BTR 和 T72, 17°俯仰角的作为训练数据, 15°俯仰角的作为测试数据, 原始图像大小为 128 × 128。实验数据由表 1 所示, 其中总共有 698 个训练样本, 1 365 个测试样本, 通过对 3 类训练样本中每类的部分选取来考虑稀疏方位角训练样本集情况。本文所有实验均不对原始 SAR 目标图像进行任何预处理。

表 1 实验数据集

Table 1 Experimental dataset

训练样本(17°)	训练样本数目	测试样本(15°)	测试样本数目
BMPSNCN21	233	BMPSNCN21	196
		BMPSN9563	195
		BMPSN9566	196
BTRSNC71	233	BTRSNC71	196
		T72SN87T	191
T72SN132T	232	T72SN812T	195
		T72SN132T	196

2.2 实验方案及结果分析

本文通过理想训练样本集实验和方位角稀疏训练样本集实验对改进的 PCA 方法(IPCA)和 PCA 方法进行识别性能对比, 实验中 2 种方法的分类器均为最近邻分类器。图 1 是本文改进 PCA 的 SAR 目标识别流程图。




图 1 改进 PCA 的 SAR 目标识别流程图

Fig. 1 Flowchart of IPCA SAR target recognition

2.2.1 理想训练样本实验

首先在 3 类训练样本总共为 698 个的情况下

进行实验,观察识别率随主成分数的影响,得到的实验结果如图 2 所示。




图 2 识别率随主成分数的变化

Fig. 2 Variation in target recognition rate with principal component number

从图 2 可以看出,随着主成分数的增加,IPCA 与 PCA 的识别率都趋于稳定,说明提取一定维数特征的样本已经表达了足够的原始样本信息,并且 IPCA 的识别率始终比传统 PCA 的识别率要好 5% 左右,说明在理想训练样本集情况下,IPCA 方法比传统 PCA 方法具有更好的识别性能。

2.2.2 稀疏方位角训练样本实验

在前面实验结果的基础上,不妨选取主成分数 $p=50$ 的条件下,对稀疏训练样本集进行实验。

第 1 种情况:对每类训练样本进行等间隔方位角抽取,例如当方位角间隔为 2° 时,每类选取方位角为 $0^\circ, 2^\circ, 4^\circ, \dots$ 等训练样本,将 IPCA 与 PCA 分别用在等间隔方位角抽取训练样本集上的结果如图 3 所示。从图 3 可以看出,等间隔方位角抽取的间隔从 2° 递增到 7° 时,IPCA 方法的识别率曲线一直处于 PCA 方法的识别率曲线之上,当每类训练样本从 120 左右降到 30 左右的时候,IPCA 的识别率维持在 90% 左右,而 PCA 从 85% 降到大约 70%,说明 IPCA 的识别精度随着方位角等间隔抽取度的增加下降不明显,相反传统 PCA 方法的识别精度随着方位角等间隔抽取度的增加而下降。可以看出 IPCA 比 PCA 在等间隔上的稀疏训练样本集上有更好的识别率和更高的鲁棒性。

第 2 种情况:在每类训练样本中随机选取若干个方位角样本构成训练样本集进行实验。得到的实验结果如图 4 所示。从图 4 可以看出,随着每类训练样本的随机减少,IPCA 始终比 PCA 有更好的识别率,并且每类随机剩下的训练样本越




图 3 等间隔稀疏训练集的实验结果

Fig. 3 Experimental results for equidistant interval sparse training set

少,IPCA 方法比 PCA 方法的识别性能优势越明显。例如,每类随机剩下 140 个训练样本时,IPCA 比 PCA 的识别率高 5% 左右,当每类随机剩下 20 个训练样本时,IPCA 比 PCA 的识别率高 17% 左右。所以 IPCA 对随机稀疏方位角训练样本集也有更好识别性能和更高的鲁棒性。




图 4 随机抽取的稀疏训练集的实验结果

Fig. 4 Experimental results for randomly selected sparse training set

2.2.3 结果分析

综合以上可以得出,与传统的 PCA 方法相比,不管在方位角较全的训练集还是稀疏方位角训练样本集上,改进 PCA 方法都具有明显的优势,这是因为传统的 PCA 方法能够以最小的误差表示训练样本,但它不可以以最小的误差表示每一个测试样本。而 IPCA 首先利用训练样本为每一个测试样本提供不同的最优描述,然后结合表示系数信息进行特征提取,这样不仅具有传统 PCA 方法的效果,而且更有利于对测试样本的分类,并且它只需要计算测试样本与最相关的那些训练样本的距离来确定最终测试样本所属的类别,这样能减少训练样本中的噪声点对测试样本

分类的影响,取得更高的识别率和更好的鲁棒性。

3 总结

本文提出一种结合稀疏求解方法的改进 PCA 方法用于 SAR 图像车辆目标识别中,通过实验验证该 IPCA 方法可以有效地改善 PCA 方法的识别率,而且对稀疏训练样本具有更好的识别性能和鲁棒性,因此是一种有效的 SAR 图像非合作目标识别方法。本文没有对原始图像进行任何的预处理过程,研究预处理方法来提高目标的识别率是下一步工作的重点。

参考文献

[1] Maitre H. 合成孔径雷达图像处理[M]. 孙洪,译. 北京: 电子工业出版社,2005.

[2] Novak L M, Owirka G J, Brower W S. Performance of 10- and 20- target MSE classifiers[J]. IEEE Transactions on Aerospace and Electronic Systems, 2000, 36 (4): 1 279-1 289.

[3] Mishra A K, Motaung T. Application of linear and nonlinear PCA to SAR ATR [C] // 25th International Conference Radioelektronika, RADI-OELEKTRONIKA 2015. Pardubice, Czech Republic: the IEEE Inc, 2015: 349-354.

[4] Cao Z, Min R, Pi Y, et al. The feasibility analysis of applying NMF in SAR target recognition [C] // IEEE International Conference on Digital Signal Processing, DSP 2015. Singapore: the IEEE Inc, 2015: 721-725.

[5] 向卫力, 李晓辉, 周勇胜, 等. 一种鲁棒的多尺度稀疏表示 SAR 目标识别方法[J]. 中国科学院大学学报, 2016, 34(1): 99-105.

[6] 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.

[7] 程建, 黎兰, 王海旭. 稀疏表示框架下的 SAR 目标识别[J]. 电子科技大学学报, 2014, 43(4): 524-529.

[8] Thiagarajan J J, Ramamurthy K N, Knee P, et al. Sparse representations for automatic target classification in SAR images[C] // 4th International Symposium on Communications, Control, and Signal Processing, ISCCSP-2010. Limassol, Cyprus: IEEE Computer Society, 2010: 1-4.

[9] Morgan D A E. Deep convolutional neural networks for ATR from SAR imagery [C] // Algorithms for Synthetic Aperture Radar Imagery XXII. Baltimore, MD, United states: SPIE, 2015:94750F.

[10] Wang H, Chen S, Xu F, et al. Application of deep-learning algorithms to MSTAR data [C] // IEEE International Geoscience and Remote Sensing Symposium, IGARSS 2015. Milan, Italy: the IEEE Inc, 2015: 3 743-3 745.

[11] Huan R H, Zhang P, Pan J. SAR ta-rget recognition using PCA, ICA and Gabor wavelet decision fusion[J]. Journal of Remote Sensing, 2012, 16(2):268-274.

[12] 丁军, 刘宏伟, 陈渤, 等. 姿态图像缺失情况下的 SAR 目标识别[J]. 西安电子科技大学学报, 2016, 43(4): 5-9.

[13] 徐勇, 范自柱, 张大鹏. 基于稀疏算法的人脸识别[M]. 北京: 国防工业出版社, 2014.

[14] Candès E J, Tao T. The power of convex relaxation: Nearoptimal matrix completion [J]. IEEE Transactions on Information Theory, 2010, 56(5): 2 053-2 080.

[15] Defense Advanced Research Project Agency (DARPA), Air Force Research Laboratory (AFRL). Moving and stationary target acquisition and recognition (MSTAR) public release dataset [DB/OL]. (2015-09-21) [2016-10-20]. <https://www.sdms.afrl.af.mil/datasets/mstar/>.