文章编号：2095-4980(2013)01-0105-05

基于 L1 范数 B2DPCA 的 SAR 目标特征提取与识别

赵　昊

(南京航空航天大学 电子信息工程学院，江苏 南京 210016)

摘　要：主成分分析法(PCA)等基于 L2 范数最小均方准则的目标特征提取方法在合成孔径雷达(SAR)图像目标识别中得到广泛应用，L2 范数易受 SAR 图像中野值的干扰，影响目标特征提取效果。介绍一种基于 L1 范数双向二维主成分分析法(B2DPCA-L1)的目标特征提取方法。L1 范数对野值有较强的鲁棒性，通过在 L1 范数框架下实现 B2DPCA，有效地改善了样本中野值对特征提取的影响，同时减少了特征矩阵维数，提高了目标识别率。实验表明，所提出方法的识别性能优于基于 L2 范数的特征提取方法。

关键词：合成孔径雷达；L1 范数；双向二维主成分分析；特征提取

中图分类号：TN958　　**文献标识码：**A

SAR target feature extraction and recognition based on L1-norm B2DPCA

ZHAO Hao

(College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 210016, China)

Abstract: The Minimum Mean-Square based methods like Principal Component Analysis(PCA) are widely used in Synthetic Aperture Radar(SAR) target recognition. However the L2-norm based criteria is prone to be affected by the outliers, which is not good for the target feature extraction in SAR imagery. To solve this problem, a L1-norm based bilateral two Dimension Principal Component Analysis(B2DPCA-L1) is proposed. The L1-norm version of B2DPCA is robust to outliers, and reduces the dimension of feature matrix and improves the target recognition rate as well. Experiments show that the proposed method has a higher target recognition rate in SAR imagery compared with the traditional L2-norm based feature extraction methods.

Key words: Synthetic Aperture Radar; L1-norm; B2DPCA; feature extraction

合成孔径雷达(SAR)作为一种全天时、全天候的主动式微波辐射传感器，在军事和民用方面有着广泛应用。SAR 图像目标识别技术因其重要的军事和战略意义，一直是近年来研究的热点[1-6]。目前，基于模板匹配的目标特征提取与识别方法是 SAR 图像目标识别中应用最广泛的一类方法。该方法通过求解无标记样本在低维子空间上的特征表示，并利用这些特征实现对无标示样本的分类识别。主成分分析(PCA)通过求解 L2 范数均方误差最小化的优化问题来寻找能够使重构均方误差最小的特征投影矩阵。由于目标电磁散射特性以及 SAR 图像斑点噪声的影响，提取的目标存在野值。而 L2 范数对野值敏感[7]，L2 范数优化问题的解会受数据集中野值的影响而偏离理想解。

针对SAR图像中野值对目标识别的影响，本文提出了基于L1范数的双向二维主成分分析(B2DPCA-L1)方法。在SAR图像目标特征提取中，B2DPCA-L1直接作用于二维SAR图像，通过求解L1范数优化问题，寻找合适的左、右特征投影空间，在识别过程中采用简单的最近邻准则进行分类，并与经典的基于L2范数的特征提取方法进行比较。

1　基于 B2DPCA-L1 的 SAR 图像目标提取

假设 $\boldsymbol{I}^i \in \boldsymbol{R}^{m\times n}$ 是第 i 幅训练样本图像，$\boldsymbol{V} \in \boldsymbol{R}^{m\times l}, \boldsymbol{U} \in \boldsymbol{R}^{n\times r}$ 分别是样本左右投影矩阵，求解最优左右投影矩阵

收稿日期：2012-05-10；**修回日期：**2012-06-07

基金项目：航空基金资助项目(2011ZC52034)；教育部留学回国人员科研启动基金资助项目；江苏高校优势学科建设工程资助项目

的优化问题在 L1 范数下的形式如下：

$$\arg\min_{\boldsymbol{V},\boldsymbol{U}}\sum_{i=1}^{N}\sum_{j=1}^{m}\left\|\boldsymbol{I}_j^i-(\boldsymbol{V}\boldsymbol{I}_p^i\boldsymbol{U}^{\mathrm{T}})_j\right\|_1 \quad s.t.\ \ \boldsymbol{V}^{\mathrm{T}}\boldsymbol{V}=\boldsymbol{I},\boldsymbol{U}^{\mathrm{T}}\boldsymbol{U}=\boldsymbol{I} \tag{1}$$

令 $\boldsymbol{I}_{in}^i=\boldsymbol{V}\boldsymbol{I}_p^i$，式(1)可以化简为：

$$\arg\min_{\boldsymbol{U}}\sum_{i=1}^{N}\sum_{j=1}^{m}\left\|\boldsymbol{I}_j^i-\left(\boldsymbol{I}_{\mathrm{in}}^i\boldsymbol{U}^{\mathrm{T}}\right)_j\right\|_1 \quad s.t.\ \ \boldsymbol{U}^{\mathrm{T}}\boldsymbol{U}=\boldsymbol{I} \tag{2}$$

由文献[8]可知，式(2)的优化问题可以通过求解 L1 范数最大化问题，得到样本数据的投影空间，

$$\arg\max_{\boldsymbol{u}_1}\sum_{i=1}^{N}\sum_{j=1}^{m}\left|\boldsymbol{I}_j^i\boldsymbol{u}_1\right| \quad s.t.\ \ \boldsymbol{u}_1^{\mathrm{T}}\boldsymbol{u}_1=1 \tag{3}$$

式中 $\boldsymbol{u}_1$ 是右投影矩阵 $\boldsymbol{U}$ 的第 1 个主矢量，第 i 幅图像的投影特征向量 $\boldsymbol{I}_p^{i,1}$ 可以由式(4)求得：

$$\boldsymbol{I}_p^{i,1}=\boldsymbol{I}^i\boldsymbol{u}_1=\begin{bmatrix}\boldsymbol{I}_1^i\\ \boldsymbol{I}_2^i\\ \vdots\\ \boldsymbol{I}_m^i\end{bmatrix}\boldsymbol{u}_1 \tag{4}$$

式中 $\boldsymbol{I}_j^i$ 表示第 i 幅图像的第 j 行。定义极化函数 p_{ij} 来去除式(3)中优化问题的绝对值符号，其中 t 表示第 t 次迭代过程。

$$p_{ij}(t)=\begin{cases}1, & \boldsymbol{I}_j^i\boldsymbol{u}_1(t)\geqslant 0\\ -1, & \boldsymbol{I}_j^i\boldsymbol{u}_1(t)<0\end{cases} \tag{5}$$

将式(5)带入式(3)，该优化问题可以表示为：

$$\arg\max_{\boldsymbol{u}_1}\sum_{i=1}^{N}\sum_{j=1}^{m}p_{ij}(t)\boldsymbol{I}_j^i\boldsymbol{u}_1(t) \quad s.t.\ \ \boldsymbol{u}_1(t)^{\mathrm{T}}\boldsymbol{u}_1(t)=1 \tag{6}$$

式(6)的最大化问题可以通过迭代解决，其中 $\boldsymbol{u}_1(t)$ 更新过程为：

$$\boldsymbol{u}_1(t)=\frac{\sum_{i=1}^{N}\sum_{j=1}^{m}p_{ij}(t-1)\boldsymbol{I}_j^{i\mathrm{T}}}{\left\|\sum_{i=1}^{N}\sum_{j=1}^{m}p_{ij}(t-1)\boldsymbol{I}_j^{i\mathrm{T}}\right\|_2} \tag{7}$$

更新 $\boldsymbol{u}_1(t)$ 后，按式(5)对 $p_{ij}(t)$ 进行更新。该过程计算出了右投影矩阵 $\boldsymbol{U}$ 的第 1 个主矢量 $\boldsymbol{u}_1$，要计算第 $k(1<k\leqslant r)$ 个主矢量，需要先将训练样本进行迭代更新，如式(8)所示，其中 $\boldsymbol{I}_i^k$ 表示第 i 幅图像样本的第 k 次更新矩阵。

$$\boldsymbol{I}_i^k=\boldsymbol{I}_i^{k-1}-\boldsymbol{I}_i^{k-1}\boldsymbol{u}_{k-1}\boldsymbol{u}_{k-1}^{\mathrm{T}} \tag{8}$$

经过 r 次更新后，可以得到右投影矩阵 $\boldsymbol{U}=[\boldsymbol{u}_1,\boldsymbol{u}_2,\cdots,\boldsymbol{u}_r]$。由 B2DPCA 可知，在得到右投影矩阵后，令原训练样本的右投影特征的转置 $(\boldsymbol{I}_i\boldsymbol{U})^{\mathrm{T}}$ 作为新的训练样本 $\boldsymbol{I}_p^i$，按式(9)、式(10)和式(11)进行更新迭代，其中 $\boldsymbol{I}_p^{i,k}$ 表示第 k 次更新后第 i 幅图像的新样本矩阵，$\boldsymbol{I}_{j,p}^{i,k}$ 表示更新样本矩阵的第 j 行。经过 l 次更新后，可以得到左投影矩阵 $\boldsymbol{V}=[\boldsymbol{v}_1,\boldsymbol{v}_2,\cdots,\boldsymbol{v}_l]$。

$$\boldsymbol{v}_k(t)=\frac{\sum_{i=1}^{N}\sum_{j=1}^{m}p_{ij}(t-1)\boldsymbol{I}_{j,p}^{i,k\,\mathrm{T}}}{\left\|\sum_{i=1}^{N}\sum_{j=1}^{m}p_{ij}(t-1)\boldsymbol{I}_{j,p}^{i,k\,\mathrm{T}}\right\|_2} \tag{9}$$

$$p_{ij}^k(t)=\begin{cases}1, & \boldsymbol{I}_{j,p}^{i,k}\boldsymbol{v}_k(t)\geqslant 0\\ -1, & \boldsymbol{I}_{j,p}^{i,k}\boldsymbol{v}_k(t)<0\end{cases} \tag{10}$$

$$\boldsymbol{I}_p^{i,k}=\boldsymbol{I}_p^{i,k-1}-\boldsymbol{I}_p^{i,k-1}\boldsymbol{v}_{k-1}\boldsymbol{v}_{k-1}^{\mathrm{T}} \tag{11}$$

综上所述，基于 L1 范数的 B2DPCA 特征提取算法的具体步骤如下：

1) 以原始图像样本为初始样本，逐次更新迭代，得到右投影矩阵 $\boldsymbol{U}$ 的 r 个主矢量；

2) 以图像样本右投影特征矩阵的转置作为新的初始样本，逐次更新迭代，得到左投影矩阵 $\boldsymbol{V}$ 的 l 个主矢量；

3) 对于任何样本 $\boldsymbol{I}\in\boldsymbol{R}^{m\times n}$，本算法提取的特征 $\boldsymbol{I}_f=\boldsymbol{V}^{\mathrm{T}}\boldsymbol{I}\boldsymbol{U}$，其中 $\boldsymbol{I}_f\in\boldsymbol{R}^{l\times r}$。

2　实验结果

表1 MSTAR数据集
Table1 Data set of MSTAR

target	training number	testing number
BRDM2	274	298
BTR70	196	233
D7	274	299
T72	196	232
ZSU234	274	299

本文采用实验数据来自美国运动和静止目标获取与识别(Moving and Stationary Target Acquisition and Recognition，MSTAR)公开数据集。该数据集中图像样本的大小为 128×128，分辨率为 0.3 m×0.3 m，训练样本是 SAR 在俯仰角为 17°时对地面目标的成像数据。测试样本是 SAR 在俯仰角 15°时对地面目标的成像数据。每类样本的方位覆盖范围是 0°~360°。数据的详细信息如表 1 所示。本文提出的方法属于无监督子空间分析算法，特征提取中没有利用训练样本的类标示信息。因此，本文选择的比较方法都是无监督类特征提取算法，包括 PCA、L1 范数主成分分析(L1-norm based PCA，PCA-L1)[8]、二维主成分分析(Two-dimensional PCA，2DPCA)[9]、广义二维主成分分析(Generalized Two-dimensional PCA，G2DPCA)[10]、双边二维主成分分析(Bilateral Two-dimensional PCA，B2DPCA)[11]、L1 范数二维主成分分析(L1-norm based Two-dimensional PCA，2DPCA-L1)[12]。其中识别方法采用最近邻距离法。

2.1 本文方法的不同目标识别性能

图 1 给出了本文算法在不同特征矩阵维数下各类目标的识别准确率。为便于比较，实验中令特征矩阵行数 l 和列数 r 相等。从图 1 中可以看出，当 r 小于 4 时，各目标的识别准确率及平均识别率随着 r 的增加快速增加，当 r 大于 4 时，各目标均有较高的识别准确率，且随着 r 的增长各目标识别准确率保持稳定。

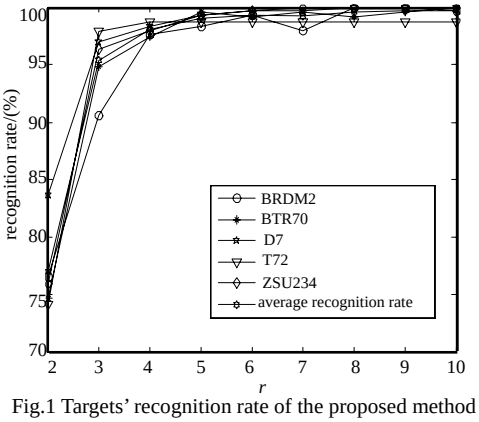

Fig.1 Targets' recognition rate of the proposed method
图 1 本文算法的各类目标识别率

2.2 不同特征提取算法的识别性能比较

1) 与双向投影特征类方法的比较

本文的算法与 B2DPCA 和 G2DPCA 一样，都需要通过训练样本得到左右投影矩阵。图 2 给出了 3 种算法的平均识别效果图。为便于比较，令特征矩阵行数 l 和列数 r 相等。从图中可以看出，当特征矩阵列数 r<7 时，B2DPCA-L1 算法的平均识别率要高于 B2DPCA 和 G2DPCA。当提取的特征矩阵维数为 3×3 时，算法的目标平均识别率已经超过 95%，这表明算法在提取特征维数较小的情况下依然能保持较高的识别率。当特征矩阵列数 r≧7 时，由于提取的特征维数较高，目标平均识别率趋向一致。

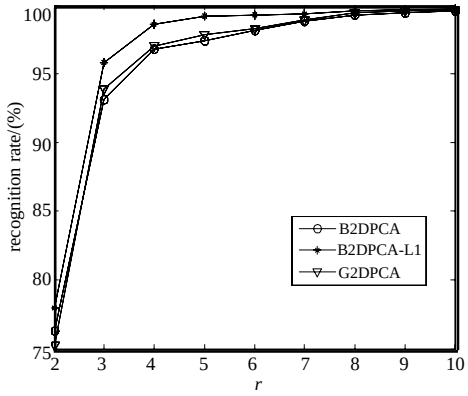

Fig.2 Target recognition of B2DPCA, G2DPCA,B2DPCA-L1
图 2 B2DPCA,G2DPCA,B2DPCA-L1 的目标识别性能

2) 与 PCA,PCA-L1 方法的比较

为证明 L1 范数方法的有效性，将 PCA,PCA-L1 作比较。为便于比较，PCA,PCA-L1 算法提取的特征维数为本文算法特征矩阵行数 r 的平方。当提取的特征矩阵行数 r 在 3~6 之间时，PCA-L1 算法的平均识别率要明显高于传统 PCA 算法，而算法的平均识别率又高于 PCA-L1 算法，当特征矩阵行数大于 6 时，各方法的平均识别率变化缓慢，差距不明显(见图 3)。

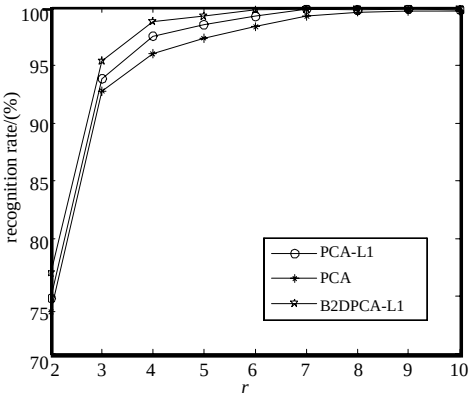

Fig.3 Target recognition of PCA, PCA-L1, B2DPCA-L1
图 3 PCA,PCA-L1,B2DPCA-L1 的目标识别性能

2.3 不同特征提取算法的稳定性比较

1) 训练样本数减少对各算法的影响

为了比较算法的稳定性，在减少训练样本数量的情况下，比较不同特征提取方法的识别效果。实验中训练样本减少为原来的 1/2，提取的特征维数固定为 3×3。如表 2 所示，在减少训练样本数量的情况下，基于 L1 范数的特征提取方

法在目标平均识别率上高于相应的传统特征提取算法。由表 2 可以看出，本文提出算法在训练样本数目减少的情况下，仍保持较高的目标平均识别率，具有较好的稳定性。

表2 不同训练样本数的目标识别效果

Table2 Target recognition effect with different train numbers

method	BRDM2	BTR70	D7	T72	ZSU234	average recognition rate
PCA	79.55	87.99	93.16	92.54	88.97	88.40
PCA-L1	81.58	90.99	93.32	92.84	91.65	90.08
G2DPCA	83.93	91.42	94.99	91.40	91.65	90.68
B2DPCA	83.27	93.14	93.99	92.69	91.13	90.88
B2DPCA-L1	83.58	93.14	94.66	97.00	95.33	92.74

2) 样本中添加野值时对各算法的影响

为了验证不同特征提取算法对野值的鲁棒性，在样本中添加随机高斯分布的强闪射点作为野值，通过对这些样本进行训练得到左右投影矩阵，并用其对测试样本进行特征提取和分类识别。表 3 给出了 G2DPCA,B2DPCA 和本文提出的算法在训练样本出现野值的目标平均识别率。从表 3 可以看到，B2DPCA-L1 算法的目标平均识别率受野值影响最小，而 G2DPCA 和 B2DPCA 由于是基于 L2 范数的特征提取方法，其识别性能受野值影响较大。

表 3 野值对目标平均识别率的影响

Table3 Effects of outliers on target recognition rate

method	B2DPCA-L1	B2DPCA	G2DPCA
adding outliers	95.82	93.15	93.88
no adding outliers	93.27	86.73	87.86

2.4 不同特征提取算法的耗时比较

B2DPCA-L1 方法属于迭代算法，不能直接得到优化问题的解析解，算法运行耗时取决于其迭代收敛速度。图 4 给出了各类特征提取算法识别过程的总耗时。由图 4 可以看出，特征维数为右投影矩阵列数 r，且 r 为 3 时，B2DPCA-L1 的耗时要少于 B2DPCA，但随着特征维数增大，B2DPCA-L1 收敛速度变慢，而 B2DPCA 耗时增速较慢。如图 4 所示，由于 2DPCA 和 2DPCA-L1 提取的特征维数较大，其识别过程耗时较长。由上述可知，本文提出的算法在提取特征维数较少时达到较高识别率，同时相比其他方法运行耗时较少。但当提取特征维数变大时，由于迭代过程收敛较慢，运行耗时较长。

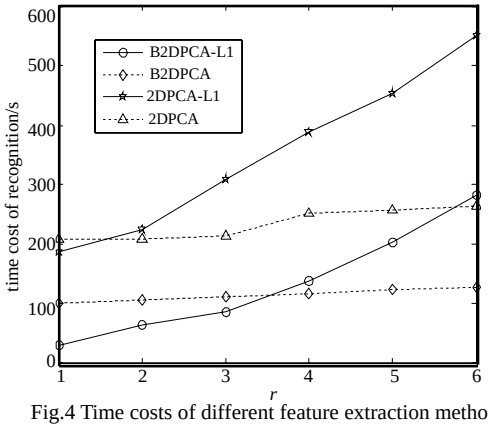

Fig.4 Time costs of different feature extraction methods

图 4 不同特征提取方法的耗时比较

3 结论

针对传统特征提取方法易受 SAR 图像中野值影响的问题，本文提出了 B2DPCA-L1，并将其应用于 SAR 图像目标特征提取和识别。该算法直接作用于二维图像矩阵，通过求解 L1 范数最大化问题寻找左、右投影矩阵。实验结果表明，相比传统方法，本文算法的识别性能受样本中野值的影响较小，具有较强的鲁棒性。

参考文献：

[1] 陈思,杨健. 基于一维匹配滤波的 SAR 目标识别[J]. 信息与电子工程, 2011,9(4):133-137. (CHEN Si,YANG Jian. SAR target recognition based on one dimensional matched filtering[J]. Information and Electronic Engineering, 2011,9(4):133-137.)

[2] 林华. 无人机载太赫兹合成孔径雷达成像分析与仿真[J]. 信息与电子工程, 2010,8(4):373-377. (LIN Hua. Analysis and Simulation of UAV Terahertz Wave Synthetic Aperture Radar Imaging[J]. Information and Electronic Engineering, 2010, 8(4):373-377.)

[3] ZHOU J,SHI Z,CHEN X,et al. Automatic target recognition of SAR images based on global scattering center model[J]. IEEE Transaction on Geoscience and Remote Sensing, 2011,49(10):3713-3729.

[4] HUAN R,PAN Y. Decision Fusion Strategies for SAR Image Target Recognition[J]. IET Radar Sonar and Navigation, 2011, 5(7):747-755.

[5] ZHANG X,GOU L,Hou B,et al. Gaussian Process Classification using Automatic relevance Determination for SAR Target Recognition[C]// Proceedings of SPIE. Bellingham,US:[s.n.], 2010:73800R1-73800R7.

[6] Du C,Gabriel R,Mike D,et al. Automatic Target Recognition from Highly Incomplete SAR Data[C]// Proceedings of SPIE. Orlando,Florida:[s.n.], 2011:8051115-1-8051115-12.

[7] Black M J,Rangarajan A. On the unification of line processes, outlier rejection, and robust statistics with applications in

early vision[J]. International Journal of Computer Vision, 1996,19(1):57–91.

[8] Kwak N. Principal component analysis based on L1-norm maximization[J]. IEEE Transactions on Pattern Analysis, 2008, 30(9):1672–1680.

[9] YANG J,ZHANG D,Frangi A F. Two-dimensional PCA:A new approach to appearance-based face representation and recognition[J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2004,26(1):131–137.

[10] KONG H,LI X,WANG L,et al. Generalized 2D principal component analysis[C]// IEEE International Joint Conference on Neural Networks. Montreal,Canada:[s.n.], 2005:108–113.

[11] WANG J G,KONG H,YAU W Y. Bilateral Two Dimensional Linear Discriminant Analysis for Stereo Face Recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition. NewYork:[s.n.], 2006:429–432.

[12] LI X,P Y,YUAN Y. L1-Norm-Based 2DPCA[J]. IEEE Transactions on Systems, Man, and Cybernetics, 2009,40(4):1170–1175.

作者简介:

赵　昊(1988–),男,山西省大同市人,在读硕士研究生,主要研究方向为雷达图像处理与目标识别.email:zhaohanha@163.com.