

基于小波域 NMF 特征提取的 SAR 图像目标识别方法

宦若虹^{①②} 杨汝良^①

^①(中国科学院电子学研究所 北京 100190)

^②(中国科学院研究生院 北京 100190)

摘要: 该文提出了一种基于小波域非负矩阵分解特征提取的合成孔径雷达图像目标识别方法。该方法对图像二维离散小波分解后提取低频子带图像,用非负矩阵分解对低频子带图像提取特征向量作为目标的特征,利用支持向量机进行分类完成目标识别。将该方法用于对 MSTAR 数据中三类目标识别,识别率最高可达 97.51%,明显提高了目标的正确识别率。实验结果表明,该方法是一种有效的合成孔径雷达图像特征提取与目标识别方法。

关键词: 合成孔径雷达; 特征提取; 识别; 非负矩阵分解; 小波

中图分类号: TN957.52

文献标识码: A

文章编号: 1009-5896(2009)03-0588-04

Synthetic Aperture Radar Images Target Recognition Based on Wavelet Domain NMF Feature Extraction

Huan Ruo-hong^{①②} Yang Ru-liang^①

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

^②(Graduate University of the Chinese Academy of Sciences, Beijing 100190, China)

Abstract: This paper presents a method for synthetic aperture radar images target recognition based on wavelet domain non-negative matrix factorization feature extraction. Low-frequency sub-band image is obtained by 2-D discrete wavelet decomposition of a SAR image. Non-negative matrix factorization is used for extracting feature vectors from the low-frequency sub-band image as the feature of the target. Support vector machine is used to perform target recognition. The method is applied for recognizing three-class targets in MSTAR database and the highest correct probability of recognition arrives at 97.51% which is enhanced obviously. It is concluded that the method proposed in this paper is an effective method for SAR images feature extraction and target recognition.

Key words: Synthetic Aperture Radar (SAR); Feature extraction; Recognition; Non-negative Matrix Factorization (NMF); Wavelet

1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)图像目标识别是 SAR 图像解译和分析的重要组成部分,具有重要的商业和军事价值,是国内外 SAR 图像处理和模式识别领域的研究热点。特征提取是 SAR 图像目标识别过程中最重要的一步。为了得到可靠的目标识别结果,用于识别的特征必须在分类空间上具有良好的类内凝聚性和类间差异性^[1]。非负矩阵分解(Non-negative Matrix Factorization, NMF)是一种较新的多元数据分析方法,可在高维空间中揭示模式的低维结构,通过非负约束得到对数据的部分线性表达^[2,3],得到使数据线性估计最优的较少数量的基向量。非负矩阵分解的计算基于简单的迭代算法,在解决大矩阵问题上具有较大的优势^[4,5]。目前,非负矩阵分解被一些学者应用到特征提取领域^[6-8]。

本文提出了一种基于小波域非负矩阵分解特征提取的

SAR图像目标识别方法。对SAR图像进行二维离散小波分解,提取低频子带图像,对得到的低频子带图像用非负矩阵分解提取特征向量,用支持向量机对特征向量分类完成目标识别。用MSTAR数据库中的三类目标图像对该方法进行验证和分析。

2 非负矩阵分解

非负矩阵分解算法可描述如下^[2,3]: 给定一个 $n \times m$ 非负数据矩阵 V , 其中包含了 m 个 n 维的非负向量。为了估计原始数据矩阵, 需要寻找两个非负分解矩阵 W 和 H , 使得:

$$V \approx WH \quad (1)$$

其中 W 和 H 的维数分别是 $n \times r$ 和 $r \times m$ 。 r 值的选择通常满足:

$$(n+m)r < nm \quad (2)$$

乘积 WH 可看成是数据矩阵 V 的压缩形式。式(1)也可用列向量表示成:

$$v \approx Wh \quad (3)$$

其中 v 和 h 分别是 V 和 H 中相对应的列向量。每个向量 v

可以看作是 \mathbf{W} 中的列向量由 \mathbf{h} 中相应元素加权后的线性组合。故矩阵 \mathbf{W} 的列可看作是使矩阵 \mathbf{V} 的线性估计最优的基向量, 矩阵 \mathbf{H} 的列包含了用矩阵 \mathbf{W} 中的基向量估计矩阵 \mathbf{V} 中相应列所需的权值。由于用较少的基向量来表示较多的数据向量, 基向量必须能够揭示数据内在的结构特性才能达到对数据的最优估计。NMF 不允许 \mathbf{W} 和 \mathbf{H} 中存在负值, 即只允许用加法进行线性组合而不允许用减法进行组合, 这个约束导致了 NMF 是用部分基表示的。

分解矩阵 \mathbf{W} 和 \mathbf{H} 的估计由迭代算法完成。每次迭代后, \mathbf{W} 和 \mathbf{H} 的值更新为当前值乘以一个由式(1)的估计值决定的因子。反复迭代后, \mathbf{W} 和 \mathbf{H} 收敛到局部最优。

为了得到分解矩阵的估计值, 需要定义目标函数。一种目标函数定义为 \mathbf{V} 和估计的 \mathbf{WH} 之间的欧几里德(Euclid)距离的平方, 即

$$F = \sum_{i=1}^n \sum_{u=1}^m (\mathbf{V}_{iu} - (\mathbf{WH})_{iu})^2 \quad (4)$$

其中分解矩阵 \mathbf{W} 和 \mathbf{H} 按下式更新:

$$\mathbf{H}_{iu} \leftarrow \mathbf{H}_{iu} \frac{(\mathbf{W}^T \mathbf{V})_{iu}}{(\mathbf{W}^T \mathbf{WH})_{iu}} \quad (5)$$

$$\mathbf{W}_{iu} \leftarrow \mathbf{W}_{iu} \frac{(\mathbf{VH}^T)_{iu}}{(\mathbf{WHH}^T)_{iu}} \quad (6)$$

当该目标函数收敛到局部最小值时, 得到 \mathbf{W} 和 \mathbf{H} 的最优估计。

另一种目标函数定义为 Kullback-Leibler (KL) 散度:

$$F = \sum_{i=1}^n \sum_{u=1}^m [\mathbf{V}_{iu} \log(\mathbf{WH})_{iu} - (\mathbf{WH})_{iu}] \quad (7)$$

其中分解矩阵 \mathbf{W} 和 \mathbf{H} 按下式更新:

$$\mathbf{W}_{ia} \leftarrow \mathbf{W}_{ia} \sum_u \frac{\mathbf{V}_{iu}}{(\mathbf{WH})_{iu}} \mathbf{H}_{au} \quad (8)$$

$$\mathbf{W}_{ia} \leftarrow \frac{\mathbf{W}_{ia}}{\sum_j \mathbf{W}_{ja}} \quad (9)$$

$$\mathbf{H}_{au} \leftarrow \mathbf{H}_{au} \sum_i \mathbf{W}_{ia} \frac{\mathbf{V}_{iu}}{(\mathbf{WH})_{iu}} \quad (10)$$

当该目标函数达到局部最大值时, 得到 \mathbf{W} 和 \mathbf{H} 的最优估计。

3 实验数据

本文使用的图像数据是 MSTAR 项目组公布的 SAR 地面静止军用目标数据, 包括 BMP2(坦克), BTR70(装甲运兵车)和 T72(坦克)三类目标。训练样本和测试样本分别是 SAR 在俯视角为 17° 和 15° 时对这三类目标的成像切片数据。每类目标样本包含了大量图像数据, 这些图像数据是 SAR 在不同方位角下的成像数据, 方位角覆盖范围为 $0^\circ \sim 360^\circ$ 。表 1 是训练样本和测试样本的类别及其相对应的图像数目。图 1 是三类目标在俯视角为 17° , 不同方位角下的 SAR 目标图像。

表 1 训练样本、测试样本种类及样本数

训练样本	样本数	测试样本	样本数
BMP2_c21	233	BMP2_c21	196
BTR70_c71	233	BMP2_9563	195
T72_132	232	BMP2_9566	196
		BTR70_c71	196
		T72_132	196
		T72_812	195
		T72_s7	191




图 1 三类目标在俯视角为 17° , 不同方位角下的 SAR 目标图像

4 SAR 图像目标识别方法

4.1 图像预处理

目标位置的平移、旋转以及不均匀的散射都会对特征提取和分类算法的性能产生影响^[1]。图像预处理包括调整每幅目标图像的目标位置到图像中心、旋转目标图像到标准方位角和对图像幅度值进行对数变换和归一化处理。图 2 是目标 T72 在俯视角为 15° , 方位角为 303° 时预处理前后的 SAR 图像, 图 2(a)图是预处理前的图像, 图 2(b)图是预处理后的图像。预处理后图像尺寸为 64 像素 \times 64 像素。




图 2 目标 T72 预处理前后 SAR 图像

4.2 基于小波域非负矩阵分解的特征提取

4.2.1 二维离散小波变换 对 SAR 图像进行二维离散小波分解, 在实现图像压缩的同时可有效消除图像中的高频噪声。图像 $f(n)$ 的二维离散小波分解由下式表示^[1]:

$$f(n) = \sum_{k \in \mathbb{Z}^2} a_{j_0, k} \phi_{j_0, k}^{LL}(n) + \sum_{b \in B} \sum_{j \geq j_0} \sum_{k \in \mathbb{Z}^2} d_{j, k}^b \psi_{j, k}^b(n) \quad (11)$$

其中 $\phi_{j_0, k}^{LL}(n)$ 是二维尺度函数, $\psi_{j, k}^b$ 是二维小波函数, a_{j_0} 是

尺度系数, $d_{j,k}^b$ 是小波系数, $b \in B=\{LH,HL,HH\}$, j 是尺度因子, j_0 是固定尺度, k 是二维位移因子。LL 为分解后得到的低频子带图像, LH, HL 和 HH 为分解后得到的包含细节信息的子带图像。对预处理后的 SAR 目标图像作 3 层二维离散小波分解, 提取 3 层分解后的低频子带图像, 图像大小为 8×8 像素。

4.2.2 非负矩阵分解 将上述得到的 8×8 像素的低频子带图像表示成一个 64 维的列向量, 三类目标的训练样本总数为 698 幅(见表 1), 由该 698 幅低频子带图像变换后的列向量构成 64×698 矩阵 V 作为非负数据矩阵。经非负矩阵分解, 求得分解矩阵 W 和 H , 使得 $V \approx WH$ 。以 W 的列向量为基向量构造子空间, 将代表每一样本图像的 64 维列向量 x_i 对该子空间投影, 即 $e_i = W^T x_i$, 可得到 r 维向量 e_i 作为表征该幅目标图像的特征向量, 其中 r 的值由式(2)约束, 可得 $r < 58.62$ 。图 3 是特征向量提取示意图, 其中最左边是预处理后图像, 中间是经过 3 层二维离散小波分解后得到的低频子带图像, 右边是由非负矩阵分解提取的特征向量, 图中特征向量维数为 10, 即 $r=10$ 。




图3 特征向量提取示意图

4.3 基于支持向量机的分类识别

本文对 MSTAR 数据库中的 BMP2, BTR70 和 T72 三类目标实现分类, 设训练样本集为 (e_i, z_i) , $i=1, \dots, 698$, $e_i \in R^r$ 为上文提取的特征向量, $z_i \in \{1,2,3\}$ 是类别标号, 698 为三类目标训练样本数目总和, r 的值为特征向量的维数, 由非负矩阵分解的基向量个数决定。支持向量机的基本理论只考虑了二值分类这一最简单的情况, 本文需要对三类目标分类, 选用“一对一”组合方式构造 BMP2 和 BTR70, BMP2 和 T72, BTR70 和 T72 三个两类支持向量机, 每个支持向量机均选用同样的内积函数, 本文使用高斯径向基(RBF)内积函数 $K(x, x_i) = \exp\left\{-\frac{|x-x_i|^2}{\sigma^2}\right\}$ 。识别时, 用投票法估计类别, 得票最多的类即为测试样本所属的类别。

5 实验结果与分析

特征提取过程中非负矩阵分解选取的基向量数不同, 特征提取得到的特征向量的维数就不同, 经过 SVM 识别得到的识别率也不同。图 4(a) 和图 4(b) 分别是每类目标的识别率以及三类目标平均识别率随 NMF 基向量数变化的曲线图。由图 4 可见, 随着 NMF 基向量数增多, 识别率先呈上升趋势, 当 NMF 基向量数为 45 时, 平均识别率达到最大为 97.51%, 随后, 识别率随着 NMF 基向量的增多又呈下降趋势。




图4 识别率随NMF基向量数变化曲线图

表 2 列出了分别用小波域主成分分析(PCA)、小波域线性判别分析(LDA)、小波域独立分量分析(ICA)和小波域非负矩阵分解(NMF)特征提取方法得到的识别率。用小波域 PCA, 小波域 LDA 或小波域 ICA 特征提取时, 识别过程中的其他步骤不改变, 只是在 NMF 步骤时用 PCA, LDA 或 ICA 替代 NMF。由表 2 可见, 当 NMF 基向量取为 45 时, 由小波域 NMF 特征提取方法得到的识别率高于其他几种特征提取方法得到的识别率。将本文基于小波域 NMF 特征提取的识别方法与几种典型的识别方法得到的识别率相比较, 比较结果如表 3 所列。文献[9]给出了一种模板匹配法, 该方法以 10° 为方位单元, 对每个方位单元内的训练图像样本取平均作为模板, 用最小距离准则作匹配完成分类。文献[10]给出了一种支持向量机分类方法, 该方法没有进行任何特征提取, 以 30° 为方位单元, 在每个方位单元内对图像样本用支持向量机完成分类。文献[11]是对目标图像求多个离散角度上的 Radon 变换, 用变换后生成的一系列统计量组成特征向量, 用隐马尔可夫模型(HMM)完成识别。由表 3 可见, 本文方法得到的最高平均识别率明显高于其他几种识别方法得到的识别率。

表 2 多种特征提取方法的识别率比较(%)

	BMP2	BTR70	T72	平均识别率
小波域 PCA	96.25	99.49	96.22	96.70
小波域 LDA	95.40	99.49	96.91	96.63
小波域 ICA	96.25	99.49	96.74	96.92
小波域 NMF(45 个基向量)	96.76	99.49	97.59	97.51

表 3 几种识别方法的识别率比较(%)

	BMP2	BTR70	T72	平均识别率
文献[9]模板匹配法	82.79	93.37	94.50	89.30
文献[10]SVM	90.97	99.49	88.14	90.99
文献[11]HMM	90.80	92.30	100	94.90
本文方法	96.76	99.49	97.59	97.51

6 结束语

本文提出了一种基于小波域非负矩阵分解特征提取的 SAR 图像目标识别方法。用二维离散小波变换对图像进行压缩去噪, 通过 NMF 对低频子带图像提取特征向量作为目标的特征, 对提取出的特征用支持向量机实现目标识别。实验结果证实, 这种 SAR 图像特征提取和识别方法可有效识别目标, 明显提高目标的正确识别率。

参考文献

- [1] Sandirasegaram N and English R. Comparative analysis of feature extraction (2D FFT and wavelet) and classification (Lp metric distances, MLP NN, and HNeT) algorithms for SAR imagery. *Proc. SPIE*, 2005, 5808: 314-325.
- [2] Lee D and Seung H. Learning the parts of objects by non-negative matrix factorization. *Nature*, 1999, 401: 788-791.
- [3] Lee D and Seung H. Algorithms for non-negative matrix factorization. Neural Information Processing Systems (NIPS). Denver, CO, USA, 2000, 7.
- [4] Tsuge S, Shishibori M, and Kuroiwa S, *et al.* Dimensionality reduction using non-negative matrix factorization for information retrieval. IEEE Conf. Systems, Man, and Cybernetics. Tucson, USA, 2001, Vol.2: 960-965.
- [5] Monga V and Mihcak M K. Robust and secure image hashing via non-negative matrix factorizations. *IEEE Trans. on Information Forensics and Security*, 2007, 2(3): 376-390.
- [6] Kotsia I, Zafeiriou S, and Pitas I. A novel discriminant non-negative matrix factorization algorithm with applications to facial image characterization problems. *IEEE Trans. on Information Forensics and Security*, 2007, 2(3): 588-595.
- [7] Benetos E, Kotti M, and Kotropoulos C. Musical instrument classification using non-negative matrix factorization algorithms. IEEE Proceedings International Symposium on Circuits and Systems. Island of Kos, Greece, 2006: 1844-1847.
- [8] Kaarna A. Non-negative matrix factorization features from spectral signatures of AVIRIS images. IEEE Conf. Geoscience and Remote Sensing Symposium. Denver, Colorado, USA, 2006: 549-552.
- [9] Ross T D, Worrell S W, and Velten V J, *et al.* Standard SAR ATR evaluation experiments using the MSTAR public release data set. *Proc. SPIE*, 1998, 3370: 566-573.
- [10] Zhao Q and Principe J C. Support vector machines for SAR automatic target recognition. *IEEE Trans. on Aerospace and Electronic Systems*, 2001, 37(2): 643-654.
- [11] Nilubol C and Pham Q H. Translational and rotational invariant hidden Markov model for automatic target recognition. *Proc. SPIE*, 1998, 3374: 179-185.

宦若虹: 女, 1979 年生, 博士生, 研究方向为合成孔径雷达图像处理、模式识别。

杨汝良: 男, 1943 年生, 研究员, 博士生导师, 研究方向为微波成像新体制新技术及信息处理。