

基于 SL-ICA 算法的 SAR 图像混合像元分解

曹恒智, 余先川, 张立保

北京师范大学 信息科学与技术学院, 北京 100875

摘要: 为解决合成孔径雷达(SAR)图像存在大量混合像元的问题, 针对传统 ICA 不能有效解决混合像元分解这一缺陷, 提出一种新的独立成分分析算法——有监督学习 ICA 算法(SL-ICA)。其目标函数是在原 ICA 负熵目标函数基础上增加监督学习的约束条件项, 进而在同一目标函数内实现负熵和约束条件的统一, 在最大化负熵的同时也最小化了约束条件的误差, 此外, 采用一种新的双梯度下降法优化迭代, 提高计算速度。并以人工模拟 SAR 图像和北京地区 ENVISAT-ASAR 作为数据源进行实验, 实验结果明显优于主成分分析方法(PCA)的分解结果。

关键词: 合成孔径雷达, 混合像元分解, 独立成分分析, 遥感影像, 主成分分析

中图分类号: TP722.6/TP751.1

文献标识码: A

1 引言

混合像元问题广泛出现在各类遥感影像中, SAR 图像亦然, 特别是在地物类型分布复杂密集的地区(Chang *et al.*, 2004)。混合像元已成为影响 SAR 图像分类精度的关键因素之一。

现有混合像元模型是针对光学遥感图像, 主要有线性光谱混合模型(Chang *et al.*, 2003)和非线性光谱混合模型(Chang *et al.*, 1998)两大类。线性模型是迄今为止最受欢迎因而使用最多的一种模型, 针对线性混合模型已发展出一些比较经典的方法: 比如模糊 C-Means (K-Means) (Pal, 1995)、软性极大似然估计分器(Bastin, 1997)、基于贝叶斯概率理论的方法(Achim & Bezerianos, 2001)、多层感知神经网络(Zhang & Gupta, 2003)等。实验证明, 由于合成孔径雷达(synthetic aperture radar, SAR)图像与光学遥感图像存在很大的不同(Lillesand & Kiefer, 2003), 光学遥感图像混合像元分解的许多比较成熟的理论方法并不适合 SAR 图像的混合像元分解。

独立成分分析(Independent Component Analysis, ICA)是近年由盲源分离(Blind Source Separation, BSS)技术发展起来的一种多道信号处理方法。该方法可以较好地分离出隐含在混合信号中的独立信源信号, 在语音信号方面得到了广泛深入的应用。近年来 ICA 在核磁共振成像(Zhang

et al., 2006)、光谱遥感图像分类(He *et al.*, 2007; 曾生根等, 2004)、图像特征提取(He *et al.*, 2006; 许卫东等, 2006)等领域也已得到较好的应用。

独立成分分析在 SAR 图像混合像元分解领域还未见应用。其原因在于已有 ICA 算法的目标函数不能满足遥感图像混合像元分解中所要求的一些约束条件, 即分解结果之和为 1, 分解结果中每类地物的比例应在 $[0, 1]$ 范围内, 等等。同时 SAR 图像极化方式较少的特点也导致传统的 ICA 算法进行 SAR 图像的混合像元分解并不能有效的实现分解。对人工模拟的 SAR 图像和真实的 SAR 图像进行实验, 实验结果表明 SL-ICA 有着较 PCA 更为精确的像元分解结果。

2 数学模型

2.1 SAR 图像混合像元的数学模型

假设有 m 个遥感接收器, 每个像素的接收向量为 $\mathbf{X} = (x_1, x_2, \dots, x_m)^T$, 由于这些数据测量的模型是线性的和瞬时的, 可以假设这些数据满足线性向量相乘的模型(Chang & Ren, 2003)。

$$\mathbf{X} = \sum_{i=1}^n \mathbf{a}_i s_i, x_j = \sum_{i=1}^n a_{ji} s_i, \mathbf{X} = \mathbf{A} \mathbf{S} \quad (1)$$

式中, $\mathbf{A} = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n)$ 为实时的反射系数矩阵, 它是未知的, 随像素的变化而变化, $\mathbf{S} = (s_1, s_2, \dots,$

收稿日期: 2007-11-26; 修订日期: 2008-05-12

基金项目: 北京市自然科学基金(编号: 4062020)、国家自然科学基金(编号: 40372129, 编号: 60602035)和教育部新世纪优秀人才支持计划。

第一作者简介: 曹恒智(1984—), 女, 北京师范大学硕士研究生, 研究方向为遥感影像处理, E-mail: jiang zu1984@163.com

通讯作者: 余先川。

$s_n)^T$ 代表不同的地物类型,它是由不同的信源形成的独立元,是图像中每个像素中各种地物的百分比,其总和必然为1。即满足下面的约束条件:

$$\sum_{i=1}^n s_i = 1 \quad (2)$$

SAR 图像混合像元分解的目标就是在未知 A 和 S 的前提下,依照某种算法,用接受向量 X 计算得到地物类型的百分比,即独立元向量 S 。

2.2 ICA 的数学模型

在假定每种地物的组成成分(即随机的信号源)都是一个随机变量的前提下,SAR 遥感影像可被看成是一个多源混合信号。由于地物的精确组成成分通常是未知的,SAR 影像的分类问题就可以看作是多元混合信号的盲源分离问题。标准 ICA 模型即如式(1),ICA 的主要任务是从观测数据 X 中估计出独立的源成分 S ,即找到相关信号 X 的一个线性变换矩阵 W 使得输出尽可能的独立:

$$U(t) = W X = W A S \quad (3)$$

式中,向量 U 是源向量的一个估计。对于线性混合或无混合模型存在如下的假设:

感应器的数量应该大于或等于源的数目,即 $N \geq M$;每一时刻的源 S 都是相互独立的;最多只有一个高斯分布源。

SAR 图像混合像元分解问题满足 ICA 的一般假设,于是可利用独立分量分析的方法,从图像信号分离的角度出发解决 SAR 图像混合像元分解问题。

同时,由 2.1 节可知,SAR 图像混合像元的数学模型不仅满足式(1),同时要满足式(2),只是利用原有的传统的 ICA 模型是不足以解决 SAR 图像混合像元分解的问题。本文 3.4 节将给出适用于 SAR 图像混合像元分解的新的 ICA-SL-ICA 的原理及实现。

3 SL-ICA 的原理

SL-ICA 实际上是一个优化问题,通常可以分 3 步来实现。第 1 步,中心化和白化。第 2 步,确立目标函数。第 3 步,选择学习算法来优化目标函数。

3.1 中心化

SL-ICA 假定所有的混合向量与独立成分都具有零均值。对于不满足零均值的,对其实施中心化来调整其均值使其满足该要求,中心化具体过程为:对原始的混合向量 x' 进行预处理: $x = x' - E\{x'\}$,这样独立成分也同时变为零均值的量,在完成对混合矩阵与独立成分的估计工作之后,被减掉

的均值可以通过在独立成分上加 $A^{-1}E\{x'\}$ 。

3.2 白化

白化就是对混合向量 x 进行线性变换从而得到一个新的向量 v 的过程, v 的分量不相关且方差为 1。也就是说 v 的协方差矩阵等于单位矩阵,即: $E\{vv^T\} = I$ 。进行白化的一个常用的方法是, $v = D^{-1/2}E^T$ 。其中 E 是 $E\{vv^T\}$ 的特征向量组成的正交矩阵, D 是特征值组成的对角矩阵。

3.3 SL-ICA 目标函数

SL-ICA 的分离过程是通过最优化目标函数(又称对比函数)来实现的。SL-ICA 以负熵为基础设计最大化的目标函数,在原有的负熵目标函数中添加有监督学习的约束条件项,得到 SL-ICA 的目标函数如下:

$$\max_{\lambda, A} L(S, A) = J(S) - E(S, A) \quad (4)$$

式(4)的第一项是负熵,负熵描述了非高斯信号的熵,其定义为 $J(S) = H(S_{\text{gauss}}) - H(S)$,其中 H 表示熵, S_{gauss} 是具有与 S 相同方差的高斯随机向量。在 X 具有零均值和单位方差的前提下,可用一种基于最大熵原理的估计方法(Hyvdrinen *et al.*, 2001)来估计负熵:

$$J(S) \propto [E\{G(S)\} - E\{G(S_{\text{gauss}})\}]^2 \quad (5)$$

其中 G 可取:

$$G(u) = -\frac{1}{a_1} \exp(a_2 u^2 / 2), (a_2 \approx 1)$$

式(4)的第二项是误差函数,误差函数 $E(S, A)$ 应满足 SAR 图像混合像元分解中的约束条件,于是考虑建立如下的误差函数:

$$E(S, A) = \lambda^T (AS - X) + (\lambda_0 - 1) \left(\sum_{i=1}^n s_i - 1 \right) + \sum_{i=1}^m \left[s_i^{2h} + (1 - s_i)^{2h} \right] \quad (6)$$

式(6)第一项保证分解结果满足式(1), λ 是拉格朗日乘子向量;式(6)第二项用来保证分解结果和为 1,即是满足式(2);式(6)第三项用来约束分解结果的范围,使之必须在 $[0, 1]$ 之间,其中 h 是一个较大的正数,当 $0 \leq s_i \leq 1$ 时, s_i^{2h} 与 $(1 - s_i)^{2h}$ 近似于零;而当 $s_i < 0$ 或 $s_i > 1$ 时, s_i^{2h} 与 $(1 - s_i)^{2h}$ 中至少有一项是远大于 1,于是通过迭代操作可以约束 s_i 回到 $[0, 1]$ 之间。

把式(5)、式(6)代入式(4)中,利用式(1)就可得到 SL-ICA 每个像素的目标函数。

上述目标函数把负熵和误差函数统一在一个框架内,形成了带有约束条件的组合目标函数,当目标函数取最大的时候,独立元的负熵为最大,而使属于约束条件的误差项达到最小。

3.4 算法优化

目标函数需要选择一种优化算法,通过迭代计算使得其达到最大值。常用优化算法有随机梯度法和自然梯度法。SL-ICA 在随机梯度算法的基础上改进得到双梯度下降算法。

随机梯度算法的基本思想是先确定分离矩阵 A 的一个初始值 A_0 ,计算出目标函数 $L(\mathbf{S}, A)$ 在 A_0 处的梯度,然后在梯度方向上移动一个适当的步长得到新的分离矩阵 A_1 ,重复上述过程就可以得到求 A 的迭代公式:

$$A(k+1) = A(k) + a(k) \frac{\partial L(\mathbf{S}, A)}{\partial A} \Big|_{A=A(k)} \quad (7)$$

式中, k 是迭代次数; $a(k)$ 为步长,简称为 a 。令 $\Delta A = A(k+1) - A(k)$,式(7)可改写成:

$$\Delta A = a \frac{\partial L(\mathbf{S}, A)}{\partial A} \quad (8)$$

这是梯度下降法的一个通用的迭代公式,对于不同的目标函数可以获得不同的迭代公式。

3.3 节所定目标函数中包括的未知向量有 λ , A , \mathbf{S} ;由式(1)可知 \mathbf{S} 可由 A 和 \mathbf{X} 唯一表示,则本文目标函数相当于是关于 λ , A 的双目标函数,所以本文考虑对随机梯度算法进行改进,采用双梯度下降的方式,即:

$$\Delta A = a \frac{\partial L(\mathbf{S}, A)}{\partial A}, \Delta \lambda = a \frac{\partial L(\mathbf{S}, A)}{\partial \lambda} \quad (9)$$

迭代直至 ΔA , $\Delta \lambda$ 小于可以接受的某个很小值为止。

4 SL-ICA 的实现流程

4.1 SL-ICA 的迭代过程

4.1.1 初始化

(1) 初始化拉格朗日乘子向量 λ 。

(2) 初始化混合矩阵 A 。

上述迭代过程的收敛性决定了 λ , A 可随机任意选取。不过,为了利用 A 与 \mathbf{X} 的先验联系,不妨取(Guo & Jiang, 2007):

$$a_{ji} \approx x_j \frac{1}{1 + e^{-x_i}} \quad (10)$$

(3) 中心化,过程见 2.1.1 节。

(4) 白化,过程见 2.1.2 节。

4.1.2 递归操作

(1) 根据式(5)计算 $L(\mathbf{S}, A)$ 。

(2) 计算 $\frac{\partial L(\mathbf{S}, A)}{\partial A}$ 。

(3) 计算 $\frac{\partial L(\mathbf{S}, A)}{\partial \lambda}$ 。

(4) 根据式(9)计算 $\Delta \lambda$ 。

(5) 产生进一步迭代的 λ , $\lambda + = \Delta \lambda$ 。

(6) 根据式(9)计算 ΔA 。

(7) 产生进一步迭代的 A , $A + = \Delta A$ 。

(8) 若 $\Delta \lambda$, ΔA 小于某一指定较小值,结束算法。否则跳至(1)式。

4.1.3 后期处理

恢复 \mathbf{S} 因中心化而被减去的均值,方法见 3.1 节。

4.2 SL-ICA 的算法流程

上述过程的流程图如图 1。

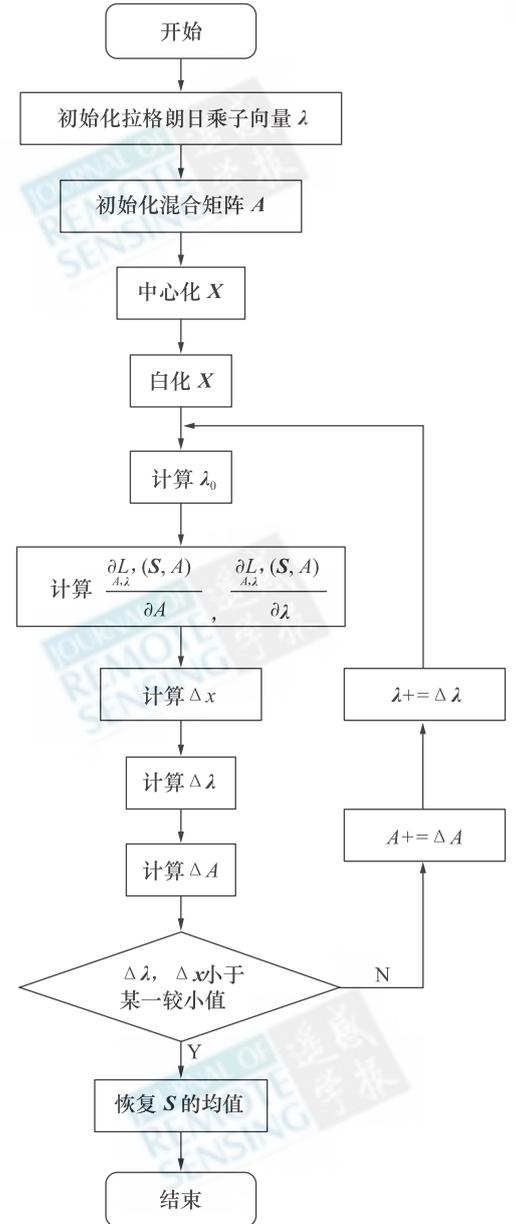


图 1 SL-ICA 的流程

Fig. 1 The algorithm process of SL-ICA

5 实验及结果分析

选用人工模拟的带有混合像元的三极化通道 SAR 图像和北京市先进合成孔径雷达 (Advanced Synthetic Aperture Radar, ASAR) 遥感图像 (VV, VH) 作为试验图像衡量 SL-ICA 的像元分解精度。

5.1 人工模拟的多极化通道 SAR 遥感图像试验

(1) 随机产生 256×256 个像素的独立元向量 $s_i, i \in (1, n)$, 满足如下条件:

$$s_i \in (0, 1), \sum_{i=1}^n s_i = 1, i \in (1, n)$$

这里产生的独立元向量可用作标准, 用来比较 SL-ICA 和 PCA (邵美珍和邓广林, 1989) 的分解效果。

(2) 随机产生 256×256 个像素的混合矩阵 A 。

(3) 用 A 和 S 根据 $X = \sum_{i=1}^n a_i s_i, x_j = \sum_{i=1}^n a_{ji} s_i, X = A S$ (1 式) 计算 256×256 个像素形成的接收向量为 X , 将向量 X 转换成 m 个 256×256 像素的图像, 即人工模拟的带有混合像元的多极化通道 SAR 图像。

图 2 是人工模拟的 3 极化通道 SAR 图像, 用 SL-ICA 和 PCA 对其进行像元分解。



图 2 人工模拟的 3 通道的 SAR 遥感图像

Fig. 2 Artificial simulated SAR remote sensing image with three channels

从 SL-ICA 和 PCA 的处理结果中随机选取 20 个像素点的分解结果与原始独立元分量的比较图 (图 3), 可以看出, SL-ICA 的分解结果更接近于真实地物的比例, 在图上的直观反映为小圆与原始地物比例的重合率更高, 不重合的小圆与原始地物比例的差距也较小, 方块与原始地物比例的差距小。图 3 说明了 SL-ICA 有着比 PCA 算法更高精度的分解结果。

计算两种算法的均方根误差 RMSE 和系统误差 SE 两个指标 (Li *et al.*, 2007; Lu & Weng, 2006), 具体公式如下 (其中 $RMSE_1, RMSE_2, RMSE_3$ 分别代表着 SL-ICA 分解结果的分量 1, 分量 2, 分量 3 所对应的 RMSE 值; SE_1, SE_2, SE_3 分别代表着 SL-ICA 分解结果的分量 1, 分量 2, 分量 3 所对应的 SE 值):

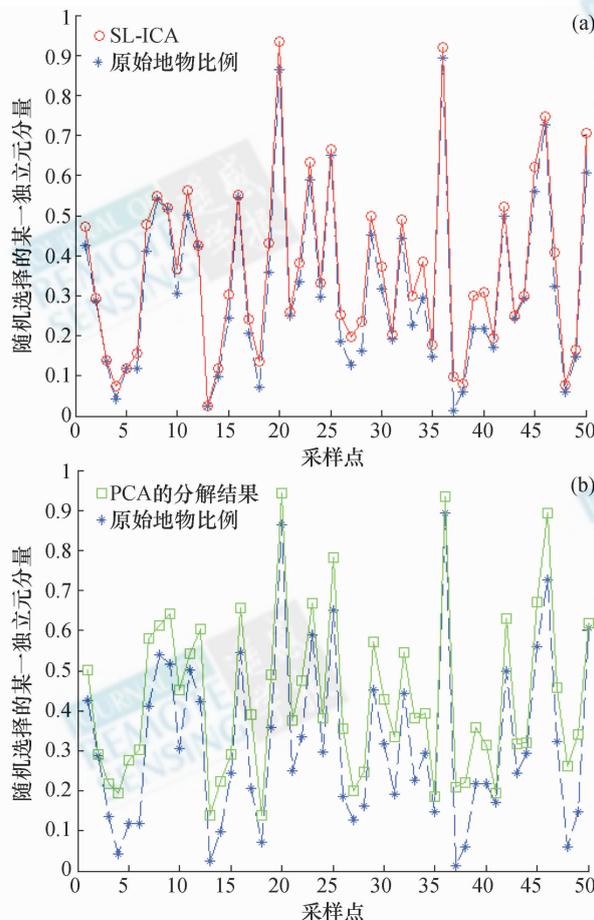


图 3 SL-ICA 和 PCA 算法分解精度比较

(a) 本文方法分解结果与原始地物比; (b) PCA 分解结果与原始地物比

Fig. 3 The accuracy comparisons of SL-ICA's decomposition results and PCA's decomposition results

(a) The proportion of our method's decomposition result and primitive terrain feature;

(b) The proportion of PCA's decomposition result and primitive terrain

$$RMSE_i = \sqrt{\frac{\sum_{i=1, j=1}^{i=m, j=N} (s_i(j) - \hat{s}_i(j))^2}{N}} \quad (11)$$

$$SE_i = \frac{\sum_{i=1, j=1}^{i=m, j=N} |s_i(j) - \hat{s}_i(j)|}{N} \quad (12)$$

表 1 SL-ICA 分解结果和 PCA 算法分解结果的精度指标

Table 1 The accuracy indexes of SL-ICA's decomposition results and PCA's decomposition results

	RMSE ₁	RMSE ₂	RMSE ₃	SE ₁	SE ₂	SE ₃
SL-ICA	0.118	0.112	0.986	0.024	0.023	0.012
PCA	0.221	0.213	0.698	0.044	0.043	0.019

表 1 给出了 SL-ICA 和 PCA 分解结果的上述两种指标, 图 4 给出了上述指标的直观比较。图 4(a)

为 $RMSE_1, RMSE_2, RMSE_3$ 的结果。图 4(b) 为 SE_1, SE_2, SE_3 的结果。

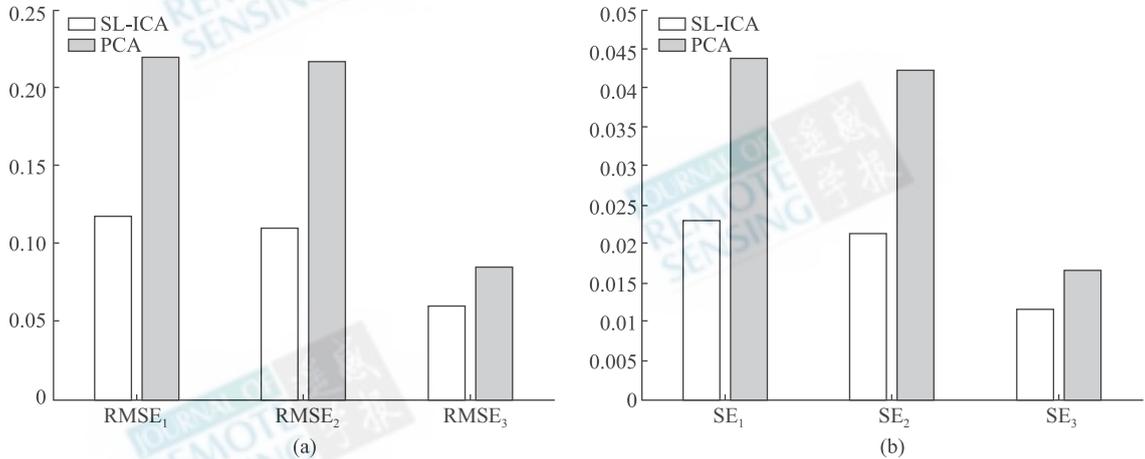


图 4 SL-ICA 和 PCA 分解结果的指标比较图

(a) SL-ICA 和 PCA 算法分解结果的均方根误差 RMSE 的比较; (b) SL-ICA 和 PCA 算法分解结果的系统误差 SE 的比较

Fig. 4 The accuracy comparison of SL-ICA's decomposition results and PCA's decomposition results

(a) the accuracy comparison of SL-ICA's RMSE and PCA; (b) the accuracy comparison of SL-ICA's SE and PCA

5.2 真实的多极化通道 SAR 遥感图像试验

为实验 SL-ICA 用于 SAR 图像混合像元分解的目视效果, 试验采用两个极化通道的北京市 ENVISAT-ASAR 图像 (VV, VH) 作为数据源进行实验, 从中截取 512×512 大小的图像 (图 5 (a), (b))。从图像和实际调查可知图像中主要包含 2 类地物: 植被/道路及建筑物群。

图 5(c)、(d) 是 SL-ICA 进行混合像元分解后

的结果, 分别为植被/道路图和人工建筑物图, 道路轮廓清晰可见, 建筑物群也被整齐的分割了出来, 可见 SL-ICA 的结果具有比较好的目视效果。

图 5(e)、(f) 是 PCA 进行混合像元分解后的结果, 其道路的轮廓明显比图 5(c)、(d) 中的模糊, 而且建筑物中间的细微的道路已完全模糊变得不可辨认。

从上述实验结果可以看出, SL-ICA 明显优于 PCA 的混合像元分解效果。

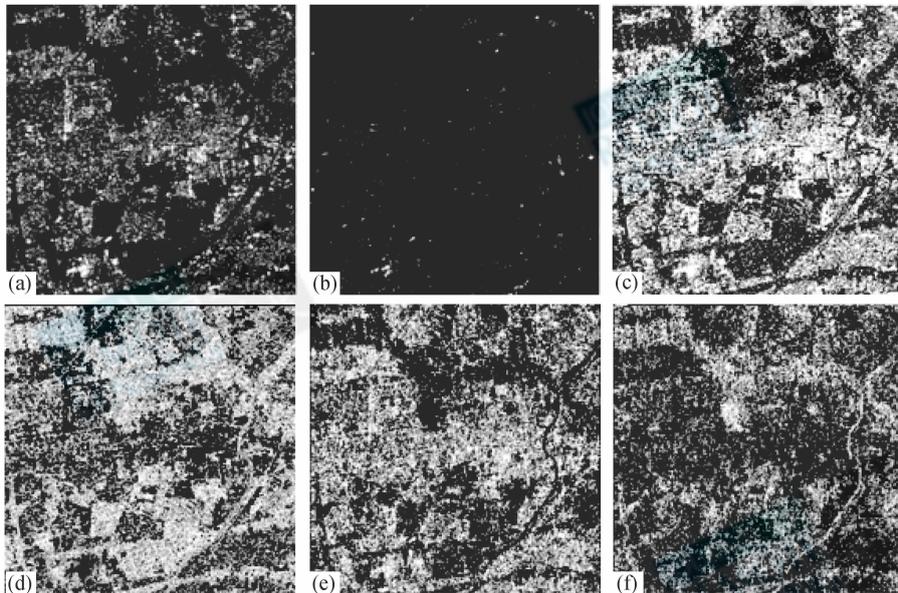


图 5 SL-ICA 与 PCA 的分解结果的比较

(a) SAR 原始图像 (VV); (b) SAR 原始图像 (VH); (c) SL-ICA 的分解结果——植被/道路图;

(d) SL-ICA 的分解结果——人工建筑物图; (e) PCA 的分解结果——植被/道路图; (f) PCA 的分解结果——人工建筑物图

Fig. 5 The comparisons of decomposition results of SL-ICA and PCA

(a) VV polarimetric method image; (b) VH polarimetric method image; (c) the decomposition results of SL-ICA: trees/ roads; (d) the decomposition results of SL-ICA: buildings; (e) the decomposition results of PCA: trees/ roads; (f) the decomposition results of PCA: buildings

6 结 论

本文提出了 SL-ICA 方法,给出了其目标函数及其优化算法,并将其应用于 SAR 图像混合像元分解。实验结果表明,SL-ICA 有着较高的分解精度和较好的目视结果。该方法对于解决高精度地物分类、目标检测及识别等问题有较重要的理论和现实意义。同时,由于本文混合像元分解的数学模型选用的是光学遥感图像中混合像元分解模型中的线性模型,可以适用于光学遥感图像的混合像元分解问题。但因为 SAR 图像极化方式较少的特点,传统的混合像元分解方法并不适用于 SAR 图像,本文的 SL-ICA 算法可较为有效的弥补这一空白。

致 谢 感谢中国科学院对地观测与数字地球科学中心董庆研究员为本文提供实验数据。

REFERENCES

- Achim A, Bezerianos A and Tsakalides P. 2001. Novel Bayesian multi-scale method for speckle removal in medical ultrasound images. *IEEE Trans. Med. Imag.*, **20**:772—783
- Bastin L. 1997. Comparison of fuzzy C-means classification, linear mixture modelling and MLC probabilities as tools for unmixing coarse pixels. *International Journal of Remote Sensing*, **17**:3629—3648
- Chang C I, Ren H, Chang C C, Jensen J O and Amico F D. 2004. Estimation of subpixel target size for remotely sensed imagery. *IEEE Trans. on Geoscience and Remote Sensing*, **42**(6): 1309—1320
- Chang C I, Althouse M L G and Pan J J. 1998. Least squares subspace projection approach to mixed pixel classification for hyperspectral images. *IEEE Trans. on Geoscience and Remote Sensing*, **36**(3): 898—912
- Chang C I and Ren H. 2003. Estimation of sub pixel target size for remotely sensed imagery. *IEEE Transactions on Geoscience and Remote Sensing*, **14**(1):3—28
- Guo Y Y and Jiang L H. 2007. Morphological shared-weight probabilistic neural networks for pattern classification of SAR images. *IEEE Proceedings of 2007 International Conference on*

- Machine Learning and Cybernetics*
- He H, Zhang T and Yu X C. 2006. Application of fast independent component analysis on extracting the information of remote sensing imagery. *IEEE ICML2006*
- He H, Yu X C and Peng W L. 2007. A comparison between FastICA and KernelICA in remote sensing imagery classification. *Geoscience and Remote Sensing Symposium*, **3**: 1658—1661
- Hyvdrinen A, Karhunen J and Oja E. 2001. *Independent Component Analysis*, John Wiley&Sons, Inc
- Li Y, Lei X G and Bai B D. 2007. Information compression and speckle reduction for multi-frequency polar metric SAR imagery using KPCA. *IEEE Proceedings of 2007 International Conference on Machine Learning and Cybernetics*
- Lillesand T M and Kiefer R W. 2003. *Remote Sensing and Image Interpretation*. New York; John Wiley & Sons, Inc
- Lu D S and Weng Q H. 2006. Use of impervious surface in urban land-use classification. *Remote Sensing of Environment*, **102**(1—2): 146—160
- Pal N T. 1995. On cluster validity for the fuzzy C-means model. *IEEE Trans. fuzzy systems*, **3**(3):370—379
- Shao M Z and Deng G L. 1989. Mixed image cell decomposition based on principle component analysis. *Chinese Space Science Technology*, **2**(1):51—56
- Xu W D, Yin Q and Kuang D B. 2006. Decision tree classification of hyperspectral image based on discrete Wavelet transform. *Journal of Remote Sensing*. **10**(2):204—210
- Zeng S G, WANG X M, Fan R B and Xia D S. 2004. Remote image classification based on independent component analysis. *Journal of Remote Sensing*. **8**(2):150—157
- Zhang N, Yu X C and Ding G S. 2006. An optimal independent component analysis approach for functional magnetic resonance imaging data. *IEEE IHMSP'06*
- Zhang Q J, Gupta K C and Devabhaktuni V K. 2003. Artificial neural networks for RF and microwave design—from theory to practice. *IEEE Trans. MTT*, **51**(4): 1339—1350

附中文参考文献

- 邵美珍,邓广林.1989.基于主成分分析的混合像元分解. *中国空间科学技术*,**2**(1):51—56
- 许卫东,尹球,匡定波.2006.小波变换在高光谱决策树分类中的应用研究. *遥感学报*.**10**(2):204—210
- 曾生根,王小敏,范瑞彬,夏德深.2004.基于独立分量分析的遥感图像分类技术. *遥感学报*.**8**(2):150—157

Decomposition of SAR images' mixed pixels based on supervised learning ICA algorithm

CAO Heng-zhi, YU Xian-chuan, ZHANG Li-bao

College of Information Science and Technology, Beijing Normal University, Beijing 100875, China

Abstract: For resolving the problem that there are lots of mixed pixels in the Synthetic Aperture Radar (SAR) images, against the flaw that the traditional Independent Component Analysis (ICA) can not solve the decomposition of mixed pixels effectively, we propose a new algorithm: Supervised Learning ICA algorithm (SL-ICA). Adding supervised learning restrictive conditions to the negentropy objective function, we implement negentropy and restrictive conditions in a unified objective function, which minimizes the error while maximizing the negentropy. At the same time, we optimize the objective function using a new dual-gradient descent algorithm iteratively, which accelerates the computing speed. By testing SL-ICA and Principal Component Analysis (PCA) on artificial simulated SAR images and ENVISAT-ASAR (Advanced Synthetic Aperture Radar) images of Beijing, the results show that SL-ICA can get more precise results than the PCA.

Key words: Synthetic Aperture Radar (SAR), decomposition of mixed pixels, Independent Component Analysis (ICA), remote sensing image, Principal Component Analysis (PCA)