

# 基于变换域单源点筛选的高效盲图像分离

徐金东,余先川,胡 丹,张立保

(北京师范大学信息科学与技术学院,北京 100875)

**摘 要:** 在基于稀疏成分分析的盲图像分离中,有效聚类点数直接影响分离的速率和精度,针对此问题,提出一种基于变换域单源点筛选的高效盲图像分离算法.根据变换域单源点的定义及分析,通过比较混合图像的一级 Haar 小波对角分量与水平分量的绝对方向,筛选出“单源点”,有效地约简了参与估计混合矩阵的聚类点数,使信号特征更加稀疏.仿真实验结果表明,Haar 小波域的单源点筛选方法能更快、更精确地估计混合矩阵,且统计直方图显示,该方法对潜在变量分析有所启发.

**关键词:** 盲图像分离;单源点;稀疏成分分析;潜变量分析;小波变换

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 0372-2112 (2013) 11-2193-06

**电子学报 URL:** <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2013.11.013

## An Efficient Blind Image Separation Based on Screening Single Source Points in Transform Domain

XU Jin-dong, YU Xian-chuan, HU Dan, ZHANG Li-bao

(Department of Information Science and Technology, Beijing Normal University, Beijing 100875, China)

**Abstract:** In the field of blind image separation based on sparse component analysis, the separation efficiency and accuracy is directly affected by the valid number of clustering samples. For this problem, a new algorithm for detection of points in the Haar wavelet domain where only single source contributions occur was proposed. The algorithm identified the single source points (SSPs) by comparing the absolute direction between diagonal component and horizontal component of Haar wavelet coefficients of mixed images. After screening SSPs, the signal features are sparser. The experiment results showed that the algorithm could estimate the mixing matrix faster and more accurately, and it could inspire to identify the latent variables by statistical histogram.

**Key words:** blind image separation; single source points; sparse component analysis; latent variable analysis; wavelet transform

### 1 引言

在基于稀疏成分分析(SCA, Sparse Component Analysis)的盲源分离技术中,有效的稀疏化是 SCA 的基础<sup>[1]</sup>,一维信号(如语音)盲分离常采用短时傅里叶(STFT, Short Time Fourier Transform)变换法<sup>[2-5]</sup>,二维信号(如图像)盲分离常采用小波稀疏化变换法<sup>[6-8]</sup>.由于图像信号较语音信号存在难以刻画的二维相关性,其稀疏化难度更大.信号的稀疏化程度直接制约了 SCA 的性能,故现有大部分盲源分离研究成果集中在一维信号(如语音、脑信号)处理<sup>[2-5,9]</sup>,二维信号的盲分离研究较少<sup>[7,8]</sup>.变换域分析法对信号进行了相应的稀疏化处

理,但变换后的系数仍存在大量冗余,这常难以满足 SCA 的需求,以致基于 SCA 的盲源分离算法甚至出现“挑源”问题——对某些源信号可以有效分离,对某些源信号无法分离,算法难以泛化.

反馈逐次分离法<sup>[7]</sup>可提高算法的稳健性,但每次只提取一个源图像信号,运行效率较低.马尔科夫随机场(MRF, Markov Random Field)对信号相关性描述较好,结合最大似然估计法(ML, Maximum Likelihood)能取得较理想的鲁棒分离结果<sup>[10,11]</sup>,但同样存在效率较低的问题.基于 SCA 的盲源分离,大部分科研工作者选择了两步法<sup>[2-9,12,13]</sup>,即先估计混合矩阵,再根据混合信号和估计的混合矩阵分离出源信号.混合矩阵的正确、快速的

估计是两步法盲源分离算法的关键. 在估计混合矩阵列向量过程中, 无论是层次 (Hierarchy) 聚类法<sup>[2]</sup>、K 均值 (K-means)<sup>[14~16]</sup>、子空间聚类法 (Subspace)<sup>[17]</sup>, 还是采用比较方向的直接聚类法<sup>[7,8]</sup>, 其根本目的都是快速、准确地找出混合矩阵的列向量方向, 而参与聚类有效点数直接决定了算法的运行效率. 因此, 在保留可分析的信息的基础上, 有效聚类点的约简是关键.

本文通过分析变换域图像稀疏化方法特性, 以约简聚类有效点数为根本出发点, 提出了一种高效的盲图像分离的混合矩阵估计方法. 通过定义单源点 (SSPs, Single Source Points) 的概念, 对一级离散 Haar 小波变换的高频系数进行了有效地筛选、去除冗余, 更加稀疏地描述了信号特征. 该方法显著地提高了聚类的速率, 获得更为精确的混合矩阵. 另外, 本文的方法对参与混合信号 (潜变量, Latent Variables) 数目的估计具有一定的启发.

## 2 基本原理

### 2.1 线性瞬时混合模型

盲源分离的线性瞬时混合模型<sup>[18]</sup>可以表示为

$$\mathbf{X} = \mathbf{AS} + \mathbf{N}, \mathbf{X} \in \mathbb{R}^{m \times T}, \mathbf{A} \in \mathbb{R}^{m \times n}, \mathbf{S} \in \mathbb{R}^{n \times T}. \quad (1)$$

其中:  $\mathbf{X}$  是观察信号矩阵 (混合信号),  $\mathbf{A}$  表示信道的混合特征 (混合矩阵),  $\mathbf{S}$  是源信号矩阵,  $\mathbf{N}$  是加性噪声,  $m$  表示混合信号的个数,  $n$  表示源信号个数,  $T$  表示信号采样点个数. 忽略噪声的模型可以简化为

$$\mathbf{X} = \mathbf{AS} \quad (2)$$

盲源分离就是在未知信道混合特征的情况下, 仅从观察的混合信号中辨识出源信号. 在采用两步法盲源分离技术中, 混合矩阵的准确、快速估计是整个算法的关键之一.

### 2.2 单源点的相关问题

**定义 1** 若所有混合信号相同位置采样点的值是由一个源信号引起的响应, 则该点为该单源点. 在某变换域中, 若所有混合信号对应某点的变换系数 (如小波系数) 是由一个源信号变换系数引起的响应, 则该点在变换域可视为单源点.

**定义 2** 设  $T_1(\cdot)$  和  $T_2(\cdot)$  分别表示两种变换或是某种变换的两个方向, 且变换后仍保持信号混合方式  $\mathbf{X} = \mathbf{AS}$ . 即若  $T_1(\mathbf{X})$  是对  $\mathbf{X}$  的某一变换, 则  $T_1(\mathbf{X}) = \mathbf{AT}_1(\mathbf{S})$ . 用  $\mathbf{X}^{T_1}$  和  $\mathbf{S}^{T_1}$  分别表示变换后的对应的系数矩阵, 则  $\mathbf{X}^{T_1} = \mathbf{AS}^{T_1}$ .

**定理** 若对混合信号进行  $T_1(\cdot)$  和  $T_2(\cdot)$  变换, 且变换后系数矩阵大小相同, 则对应位置的变换域单源点的列向量具有相同的绝对方向, 即列向量方向的绝对值相同.

**证明** 线性瞬时混合系统  $\mathbf{X} = \mathbf{AS}$  用各自矩阵元

素可具体描述为:

$$\begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1T} \\ x_{21} & x_{22} & \cdots & x_{2T} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mT} \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \begin{bmatrix} s_{11} & s_{12} & \cdots & s_{1T} \\ s_{21} & s_{22} & \cdots & s_{2T} \\ \vdots & \vdots & \ddots & \vdots \\ s_{n1} & s_{n2} & \cdots & s_{nT} \end{bmatrix}. \quad (3)$$

则  $\mathbf{X}^{T_1} = \mathbf{AS}^{T_1}$  可描述为:

$$\begin{bmatrix} x_{11}^T & x_{12}^T & \cdots & x_{1k}^T \\ x_{21}^T & x_{22}^T & \cdots & x_{2k}^T \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1}^T & x_{m2}^T & \cdots & x_{mk}^T \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \begin{bmatrix} s_{11}^T & s_{12}^T & \cdots & s_{1k}^T \\ s_{21}^T & s_{22}^T & \cdots & s_{2k}^T \\ \vdots & \vdots & \ddots & \vdots \\ s_{n1}^T & s_{n2}^T & \cdots & s_{nk}^T \end{bmatrix}. \quad (4)$$

式(3)和(4)中的混合信号矩阵和源信号矩阵写成行向量形式, 可分别表示为式(5)和(6).

$$\begin{bmatrix} \mathbf{x}_{1:} \\ \mathbf{x}_{2:} \\ \vdots \\ \mathbf{x}_{m:} \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \begin{bmatrix} \mathbf{s}_{1:} \\ \mathbf{s}_{2:} \\ \vdots \\ \mathbf{s}_{n:} \end{bmatrix}. \quad (5)$$

$$\begin{bmatrix} \mathbf{x}_{1:}^T \\ \mathbf{x}_{2:}^T \\ \vdots \\ \mathbf{x}_{m:}^T \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \begin{bmatrix} \mathbf{s}_{1:}^T \\ \mathbf{s}_{2:}^T \\ \vdots \\ \mathbf{s}_{n:}^T \end{bmatrix}. \quad (6)$$

若矩阵  $\mathbf{X}^{T_1}$  第  $j$  列  $\mathbf{x}_{:j}^{T_1}$  仅由矩阵  $\mathbf{S}^{T_1}$  第  $i$  行  $\mathbf{s}_{i:}^{T_1}$  引起的响应, 即

$$\mathbf{x}_{:j}^{T_1} = \mathbf{a}_{:i} \mathbf{s}_{i:}^{T_1}. \quad (7)$$

则  $\mathbf{x}_{:j}^{T_1}$  与  $\mathbf{a}_{:i}$  具有相同的绝对方向, 此时列向量  $\mathbf{x}_{:j}^{T_1}$  上所有的点为单源点; 同理, 若矩阵  $\mathbf{X}^{T_2}$  第  $j$  列  $\mathbf{x}_{:j}^{T_2}$  仅由矩阵  $\mathbf{S}^{T_2}$  第  $i$  行  $\mathbf{s}_{i:}^{T_2}$  引起的响应, 即

$$\mathbf{x}_{:j}^{T_2} = \mathbf{a}_{:i} \mathbf{s}_{i:}^{T_2}. \quad (8)$$

向量  $\mathbf{x}_{:j}^{T_2}$  上所有的点也为单源点, 且  $\mathbf{x}_{:j}^{T_2}$  与  $\mathbf{a}_{:i}$ 、 $\mathbf{x}_{:j}^{T_1}$  具有相同的绝对方向. [证毕]

若变换域混合信号某点是由两点引起的响应, 即两源点 (DSPs, Dual Source Points), 则可表示为

$$\mathbf{x}_{:j}^T = \mathbf{a}_{:1} \mathbf{s}_{1:}^T + \mathbf{a}_{:2} \mathbf{s}_{2:}^T. \quad (9)$$

$\mathbf{s}_{1:}^T$ 、 $\mathbf{s}_{2:}^T$  分别表示第 1 路和第 2 路  $T_1(\cdot)$  变换域  $j$  点处的

系数值.  $T_2(\cdot)$ 变换域可以表示为:

$$\mathbf{x}_{:j}^T = \mathbf{a}_{:1} s_{1j}^T + \mathbf{a}_{:2} s_{2j}^T. \quad (10)$$

由于  $\mathbf{a}_{:1}$  和  $\mathbf{a}_{:2}$  是混合矩阵的两个线性无关的列向量, 故当且仅当  $\frac{s_{1j}^T}{s_{1j}^T} = \frac{s_{2j}^T}{s_{2j}^T}$  时,  $\mathbf{x}_{:j}^T$  与  $\mathbf{x}_{:j}^T$  才具有相同的绝对方向.

而满足  $\frac{s_{1j}^T}{s_{1j}^T} = \frac{s_{2j}^T}{s_{2j}^T}$  成立, 是一小概率事件. 可以类推, 更多源信号点的响应满足相同绝对方向发生的概率更低, 所以可以通过判断  $\mathbf{x}_{:j}^T$  与  $\mathbf{x}_{:j}^T$  是否具有相同的绝对方向来进行有效地单源点筛选. 当然, DSPs 的  $\mathbf{x}_{:j}^T$  与  $\mathbf{x}_{:j}^T$  具有相同绝对方向也有存在的可能(当且仅当  $\frac{s_{1j}^T}{s_{1j}^T} = \frac{s_{2j}^T}{s_{2j}^T}$ ), 即此时是伪单源点, 但这种情况较少; 另外三个及三个以上源信号点满足  $\mathbf{x}_{:j}^T$  与  $\mathbf{x}_{:j}^T$  具有相同绝对方向的概率就更低了.

### 3 基于 Haar 小波域 SSPs 筛选的混合矩阵估计算法

#### 3.1 Haar 小波域 SSPs 筛选分析

在盲图像分离领域, 文献[7]已证明一级小波变换后的高频系数满足定义 2. Haar 小波对图像信号具有良好的稀疏能力, 因此, 取混合图像的 Haar 小波水平分量和对角分量, 分别表示为  $X^T$  和  $X^T$ .



图1 标准灰度测试图像

选取三幅标准灰度测试图像(256 × 256 pixel) Lena、Cameraman 和 Man(图 1 所示)作为源图像, 由 Matlab 的 rand(3)函数随机生成 3 × 3 的混合矩阵:

$$A = \begin{bmatrix} 0.646605087681649 & 0.739176378504631 & 0.722423569894283 \\ 0.193377647125387 & 0.415215159583313 & 0.555016597098355 \\ 0.737907139263780 & 0.530296759100962 & 0.412384241462453 \end{bmatrix}.$$

根据式(2)进行随机混合, 获得三幅混合图像, 混合结果如图 2 所示.



图2 Lena、Cameraman和Man的混合结果

通过混合图像的 Haar 小波系数  $\mathbf{x}_{:j}^T$  与  $\mathbf{x}_{:j}^T$  的夹角小

于某值来筛选 SSPs, 即

$$\left| \frac{(\mathbf{x}_{:j}^T)^T \cdot \mathbf{x}_{:j}^T}{\|\mathbf{x}_{:j}^T\| \cdot \|\mathbf{x}_{:j}^T\|} \right| > \cos(\Delta\theta). \quad (11)$$

$|\cdot|$  表示求绝对值,  $(\mathbf{x}_{:j}^T)^T$  表示求  $\mathbf{x}_{:j}^T$  的转置,  $\|\mathbf{x}_{:j}^T\|$  表示求  $\mathbf{x}_{:j}^T$  的模,  $\Delta\theta$  为一夹角常数. 设置参数  $\cos(\Delta\theta) = 1 - 0.0001$  (即  $\Delta\theta = 0.0057^\circ$ ).

每幅图像(256 × 256 pixel)的一级 Haar 小波变换三个方向(水平、对角、垂直)系数个数均为 128 × 128 = 16384 个, 经单源点筛选后的个数为 636 个. 图 3 是混合图像的空域、Haar 小波域和单源点筛选后的散点图.

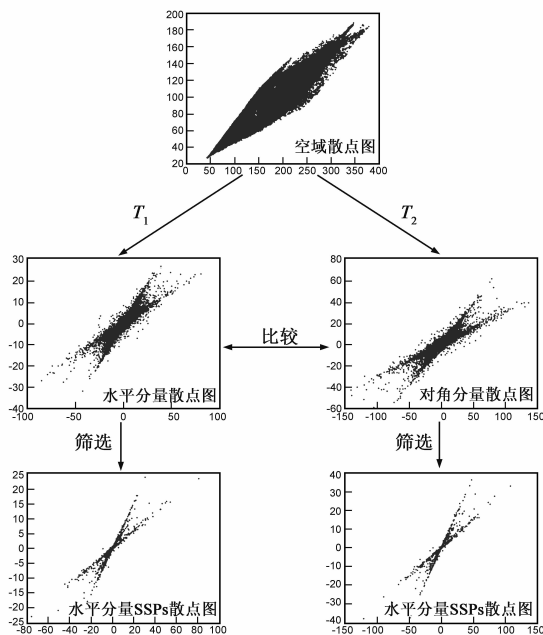


图3 混合图像的空域、Haar小波域和筛选后散点图

由筛选出“单源点”个数及图 3 显然可见, 信号点数得到了极为有效地约简(近 30 倍), 筛选后的散点图更加“稀疏”, 方向性更为明显、集中. 因此, 本文通过单源点筛选的方法, 去除估计混合矩阵的冗余、干扰因素, 提高估计的速率和精度.

#### 3.2 SSPs 筛选算法

- Step1: 对混合图像进行一级 Haar 小波变换, 取水平和对角分量高频系数;
- Step2: 检查是否满足 SSPs 筛选条件(11);
- Step3: 若满足(11), 保留该点, 否则删除;
- Step4: 重复 Step2-Step3, 直至所有的点检测完毕.

#### 3.3 混合矩阵的估计

根据文献[7,8], 通过直接比较方向的线性聚类法估计混合矩阵, 选取 3.2 算法筛选后的对角分量  $X^T$  作为聚类对象, 按是否共线原则, 获得聚类元素最多的前  $n$  类. 这  $n$  类的各自的聚类中心即为估计的混合矩阵的列向量. 即对于  $X^T$  的任意 2 个列向量  $\mathbf{x}_{:j}^T$  和  $\mathbf{x}_{:j}^T$ , 若

$$\cos(\mathbf{x}_{:i}^T, \mathbf{x}_{:j}^T) = \frac{\mathbf{x}_{:i}^T \mathbf{x}_{:j}^T}{\|\mathbf{x}_{:i}^T\| \|\mathbf{x}_{:j}^T\|} = 1, \quad (12)$$

则  $\mathbf{x}_{:i}^T$  和  $\mathbf{x}_{:j}^T$  共线; 设  $\mathbf{x}_{:i}^T \in \beta(k)$ ,  $\mathbf{x}_{:j}^T \in \beta(k)$ , 按此将所有列向量线性聚类得到  $\{\beta | \beta(k), k = 1, 2, 3, \dots, T\}$ , 选取聚类元素最多的前  $n$  类。

## 4 实验与结果分析

实验环境: Win 7 OS, CPU 2 core 2.5GHz, RAM 6GB, Matlab2010. 根据前期实验设置参数  $\cos(\Delta\theta) = 1 - 0.0001$  ( $\Delta\theta = 0.0057^\circ$ ). 3.1 已表明该方法对参与聚类的点数进行非常有效地约简, 此处采用 CPU Time 进一步验证算法的执行速率; 对混合矩阵的估计准确度采用归一化均方误差(NMSE, Normalized Mean Square Error)衡量, 即

$$\text{NMSE} = 10 \log_{10} \left( \frac{\sum_{p,q} (a_{pq} - \hat{a}_{pq})^2}{\sum_{p,q} (a_{pq})^2} \right) \quad (13)$$

其中  $a_{pq}$ ,  $\hat{a}_{pq}$  分别是原始混合矩阵  $\mathbf{A}$  和估计的混合矩阵  $\hat{\mathbf{A}}$  在  $(p, q)$  位置处的值。

小波变换对不同图像具有不同的稀疏能力, 而稀疏度直接影响基于 SCA 的盲图像分离的效果, 所以下面采取多种组合的方式进行实验测试。

### 4.1 不同图像组合测试

采用 3.1 的混合矩阵  $\mathbf{A}$  对不同标准灰度测试图像 ( $256 \times 256$  pixel) 组合进行随机混合, 然后估计混合矩阵. 组合方式如图 4 所示, 即组合一: Columbia, Airplane, Boats; 组合二: Columbia, Lena, Cameraman; 组合三: Crowd, Cameraman, Man.



图4 不同图像组合方式

表 1 是不同图像组合方式下, 本文方法从聚类点数、CPU Time、混合矩阵估计精度三个方面与比较方向直接聚类法<sup>[7,8]</sup>的性能比较. 显然, 本文方法有效地约简了聚类点数(20 倍左右), 执行速率得到极大地提升, 且混合矩阵的估计精度也有所提高。

表 1 本文方法与直接聚类法性能比较

组合	聚类点数		CPU Time (s)		混合矩阵估计精度(dB)	
	本文方法	直接聚类法	本文方法	直接聚类法	本文方法	直接聚类法
组合一	849	16384	6.58	206.64	-638.79	-19.14
组合二	770	16384	6.22	249.27	-629.77	-28.88
组合三	852	16384	6.80	345.69	-663.48	-622.77

### 4.2 遥感图像测试

实际遥感图像与标准灰度测试图像(自然图像)相比, 结构组合更加复杂, 分辨率的限制造成纹理特征不够明显, 而这些特征往往是小波等变换提取的稀疏成分, 这类成分对于基于 SCA 的盲图像分离非常重要. 为了验证算法对遥感图像的有效性, 根据文献[11, 19]中的遥感图像仿真方法, 选取一幅 ETM 遥感图像 ( $256 \times 256$  pixel) 和一幅云图像 ( $256 \times 256$  pixel) (图 5(a) 所示) 进行随机混合, 然后进行盲源分离。

原始随机混合矩阵

$$\mathbf{A} = \begin{bmatrix} 0.988311874042823 & 0.453794078337320 \\ 0.152445530029460 & 0.891106578623445 \end{bmatrix}, \text{ 经单源点筛选后的聚类点数为 } 1884 \text{ 个. 估计的混合矩阵 } \hat{\mathbf{A}} = \begin{bmatrix} 0.988311874042821 & 0.453794078337305 \\ 0.152445530029473 & 0.891106578623453 \end{bmatrix}, \text{ 估计误差}$$

NMSE 为  $-637.22$  dB. 文献[11]的 CHMF (Contextual Hidden Markov Field) 法估计的混合矩阵误差 NMSE 为  $-15.27$  dB. 文献[19]的 MoG (Mixture of Gaussians) 模型贝叶斯法估计的混合矩阵误差 NMSE 为  $-101.25$  dB. 本文方法的估计误差均低于文献[11]和文献[19]中的方法。

由于此处是适定盲源分离 ( $m = n$ ), 得到估计的混合矩阵  $\hat{\mathbf{A}}$  后, 可以直接采用  $\hat{\mathbf{S}} = \hat{\mathbf{A}}^{-1} \mathbf{X}$  (其中,  $\hat{\mathbf{S}}$  是分离的源图像,  $\hat{\mathbf{A}}^{-1}$  是  $\hat{\mathbf{A}}$  的逆矩阵) 的方法进行分离. 图 5(c) 是分离出的图像。

分离精度用分离图像与源图像的归一化相关系数 (NCC, Normalized correlation coefficients) 度量, NCC 的计算方法如式(14)。

$$\text{NCC} = \frac{\sum_{i,j} |s(i,j) - \bar{s}| \times |\hat{s}(i,j) - \bar{\hat{s}}|}{\sqrt{\sum_{i,j} |s(i,j) - \bar{s}|^2} \times \sqrt{\sum_{i,j} |\hat{s}(i,j) - \bar{\hat{s}}|^2}} \quad (14)$$

其中,  $s(i, j)$  与  $\hat{s}(i, j)$  分别是两幅图像  $\mathbf{S}$  与  $\hat{\mathbf{S}}$  在  $(i, j)$  的像素灰度值,  $\bar{s}$  与  $\bar{\hat{s}}$  是对应两幅图像的像素灰度平均值. NCC 越大, 说明两幅图像间相关程度越大, 即越相似. 当 NCC 等于 1 时, 认为两幅图像是一致的 (注: 整体幅度可能不同)。

经计算图 5(a) 与图 5(c) 对应图像间的归一化相

关系数均为 1,说明该方法已完全分离出源图像.




图5 遥感图像盲分离仿真结果

### 4.3 潜变量个数估计

现有成熟的盲源分离算法是已知源信号个数假设

的基础上实现的,而实际应用中源信号个数是未知的,所以众多研究者目光转向了潜变量分析(LVA, Latent Variable Analysis),每年度的独立成分分析(ICA, Independent Component Analysis)国际大会也改为了 ICA/LVA. 所以,本文采用统计归一化聚类点分布(直方图)的方法,对源信号个数的估计做了相关研究测试.

图 6 是 4.1 中不同组合时的归一化统计直方图: (a)图(一级 Haar 小波稀疏化的对角分量系数)除了存在三个最高峰外,剩下的峰非常接近这三个高峰,且为数较多,即不够稀疏;(b)图(单源点筛选后的系数)中均很明显地存在三个最高峰,剩下的峰与这三个高峰差距较大,且数量较少,即稀疏程度较大. 因此,经单源点筛选后归一化统计结果能较好地估计出源信号的数目.




图6 不同组合时的归一化统计直方图

## 5 结论

本文的主要贡献在于提出了二维图像的单源点筛

选方法:通过 Haar 小波系数单源点筛选的方法,去除冗余信息,提高了基于 SCA 的盲图像分离算法的执行速率和精度. 相比单纯小波稀疏化处理,经单源点筛选后

散点图更加稀疏,方向性更为集中,并通过统计直方分布图对源信号数目的估计有所启发.由于该方法不涉及混合信号数目  $m$  和源信号数目  $n$  之间的关系,故对欠定情况 ( $m > n$ ) 的混合矩阵估计将依然有效.

## 参考文献

- [1] Rubinstein R, Zibulevsky M, et al. Double sparsity learning sparse dictionaries for sparse signal approximation[J]. IEEE Transactions on Signal Processing, 2010, 58(3): 1553 – 1564.
- [2] Reju V G, Koh S N, et al. An algorithm for mixing matrix estimation in instantaneous blind source separation[J]. Signal Processing, 2009, 89(9): 1762 – 1773.
- [3] 董天宝, 杨景曙. 基于孤立点检测的欠定混合矩阵盲辨识[J]. 电子学报, 2012, 40(12): 2367 – 2373.  
Dong Tianbao, Yang Jingshu. Blind identification of underdetermined mixtures based on outlier detection[J]. Acta Electronica Sinica, 2012, 40(12): 2367 – 2373. (in Chinese)
- [4] 肖明, 谢胜利, 傅予力. 基于频域单源区间的具有延迟的欠定盲分离[J]. 电子学报, 2007, 35(12): 2279 – 2283.  
Xiao Ming, Xie Shengli, Fu Yuli. Undetermined blind delayed source separation based on single source intervals in frequency domain[J]. Acta Electronica Sinica, 2007, 35(12): 2367 – 2373. (in Chinese)
- [5] Thiagarajan J J, Ramamurthy K N, Spanias A. Mixing matrix estimation using discriminative clustering for blind source separation[J]. Digital Signal Processing, 2013, 23: 9 – 18.
- [6] Fadili J M, Starck J L, Bobin J, et al. Image decomposition and separation using sparse representations: an overview[J]. Proceedings of the IEEE, 2010, 98(6): 983 – 994.
- [7] 余先川, 曹婷婷, 胡丹, 张立保, 代莎. 基于小波变换和稀疏成分分析的盲图像分离法[J]. 北京邮电大学学报, 2010, 33(2): 58 – 63.  
Yu Xianchuan, Cao Tingting, Hu Dan, et al. Blind image separation based on wavelet transformation and sparse component analysis[J]. Journal of Beijing University of Posts and Telecommunications, 2010, 33(2): 58 – 63. (in Chinese)
- [8] Yu X C, Xu J D, D Hu, et al. A new blind image source separation algorithm based on feedback sparse component analysis[J]. Signal Processing, 2013, 93(1): 288 – 296.
- [9] Georgiev P, Theis F, Cichocki A. Sparse component analysis and blind source separation of underdetermined mixtures[J]. IEEE Transactions on neural network, 2005, 16(4): 992 – 996.
- [10] Guidara R, Hosseini S, Deville Y. Maximum likelihood blind image separation using non-symmetrical half-plane Markov random fields[J]. IEEE Transactions on Image Processing, 2009, 18(11): 2435 – 2450.
- [11] Ichir M M, Djafari A M. Hidden markov models for wavelet-based blind source separation[J]. IEEE Transactions on Image

Processing, 2006, 15(7): 1887 – 1899.

- [12] Zhang S X, et al. A new algorithm estimating the mixing matrix for the sparse component analysis[A]. Internet Conference on Computational Intelligence and Security[C]. Washington: IEEE Computer Society, 2009. 25 – 29.
- [13] Liu H L, Yang J J. A new clustering algorithm based on normalized signal for sparse component analysis[A]. Internet conference on computational intelligence and security[C]. Washington: IEEE Computer Society, 2010. 60 – 63.
- [14] He Z, Cichocki A, Li Y, et al. K-hyperline clustering learning for sparse component analysis[J]. Signal Processing, 2009, 89: 1011 – 1022.
- [15] Ye J, Zhao Z, Wu M. Discriminative k-means for clustering[A]. Advances in Neural Information Processing Systems[C]. Boston: MIT Press, 2008. 1649 – 1656.
- [16] Thiagarajan J J, Ramamurthy K N, Spanias A. Optimality and stability of the K-hyperline clustering algorithm[J]. Pattern Recognition Letter, 2011, 32(9): 1299 – 1304.
- [17] Naini F M, Mohimani G H, et al. Estimating the mixing matrix in Sparse Component Analysis (SCA) based on multidimensional subspace clustering[A]. Proceedings of IEEE International Conference on Telecommunications[C]. Penang, Malaysia: IEEE, 2007. 670 – 675.
- [18] 余先川, 胡丹. 盲源分离理论与应用[M]. 科学出版社, 2011. 1 – 6.  
Yu Xianchuan, Hu Dan. Blind Source Separation Theory and Applications[M]. Beijing: Science Press, 2011. 1 – 6. (in Chinese)
- [19] Djafari A M. Bayesian source separation: beyond PCA and ICA[A]. Proceedings of the European Symposium on Artificial Neural Networks[C]. Bruges, Belgium: D-Side, 2006. 313 – 322.

## 作者简介



徐金东 男, 1980 年生于山东招远. 北京师范大学信息科学与技术学院博士生. 研究方向为数据挖掘、盲信号处理.

E-mail: xujindong@mail.bnu.edu.cn



余先川(通信作者) 男, 1967 年生于重庆梁平. 北京师范大学信息科学与技术学院教授博导. 研究方向为数据挖掘与影像处理.

E-mail: yuxianchuan@163.com