

文章编号:1001-9081(2012)09-2432-04

doi:10.3724/SP.J.1087.2012.02432

估计盲信源分离混合矩阵的通用方法

张延良^{1*}, 张伟涛², 杜静静³

(1. 河南理工大学 计算机科学与技术学院, 河南 焦作 454001; 2. 西安电子科技大学 电子工程学院, 西安 710071;

3. 河南理工大学 电气工程与自动化学院, 河南 焦作 454001)

(* 通信作者电子邮箱 yizhang119@qq.com)

摘要:混合矩阵的估计是解决盲信源分离问题的关键一步,但现有研究中缺乏一种同时适用于适定、超定及欠定情况下混合矩阵估计的通用方法。根据张量标准分解的因子矩阵和盲信源分离混合矩阵的估计均存在幅值和排列顺序的不确定性这一性质,将混合矩阵的估计转化为观测信号统计量所组成张量的标准分解问题,标准分解采用循环最小化方法,通过交替最小二乘算法实现。理论分析和仿真实验表明,所提方法可有效解决适定、超定和欠定混合矩阵的估计,是一种估计盲信源分离混合矩阵的通用方法。

关键词:盲信源分离;欠定混合;标准分解;循环最小化

中图分类号:TN911.7 文献标志码:A

General method to estimate mixture matrix in blind source separation

ZHANG Yan-liang^{1*}, ZHANG Wei-tao², DU Jing-jing³

(1. College of Computer Science and Technology, Henan Polytechnic University, Jiaozuo Henan 454001, China;

2. School of Electronic Engineering, Xidian University, Xi'an Shaanxi 710071, China;

3. College of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo Henan 454001, China)

Abstract: The estimation of mixture matrix is a key step to solve the problem of blind source separation. But there lacks a general estimation method suitable for well-determined, over-determined and under-determined mixture matrix in the existing research. Scaling and permutation ambiguities lie in both factor matrix of tensor canonical decomposition and mixture matrix in blind source separation. With this property, the estimation of mixture matrix can be transformed into tensor canonical decomposition of observed signals' statistics. The canonical decomposition can be implemented by cyclic minimization, with the algorithm of alternating least squares. The theoretical analysis and simulations show that the method proposed in this paper is a general method to estimate well-determined, over-determined and under-determined mixture matrix.

Key words: blind source separation; underdetermined mixture; canonical decomposition; cyclic minimization

0 引言

盲信源分离^[1-3]是指在源信号和传输信道均未知的情况下,根据接收到的观测信号恢复相互独立的源信号的过程。盲信源分离的实现通常需要两个步骤^[4]:1) 估计混合矩阵;2) 恢复源信号。混合矩阵估计的准确与否直接影响第二步盲分离结果的精度。自然梯度算法^[5-6]、半参数统计算法^[7]、快速近似联合对角化(Fast Approximate Joint Diagonalization, FAJD)算法^[8]、列交替对角线元素集中(Alternating Columns Diagonal Centers, ACDC)算法^[9]等可以很好地解决适定和超定情况下混合矩阵的估计问题,但这些算法都不能用于欠定混合矩阵。因为欠定混合线性系统意味着未知数的个数多于方程的个数^[3],待估计的混合矩阵是个“矮胖”矩阵,难于估计。对于欠定混合矩阵的估计,往往假设源信号在时域或者变换域满足稀疏性^[4,10-12],在这种情况下,根据稀疏混合信号的聚类特点,观测数据的散点图将聚集在各混合矩阵方向向量上,再通过局部最大化就能求出欠定混合矩阵。这种算法,对于语音等在时频域满足稀疏性的信号有效,但是对于不满足稀疏性的大多数亚高斯信号却不适用。文献[13-15]用张量分解的方法解决欠定混合矩阵的估计问题,不需要源

信号稀疏性的假设,取得了良好的效果。

本文将适定、超定和欠定情况下混合矩阵的估计转化为张量的标准分解问题,标准分解可以通过交替最小二乘实现,该方法是一种估计盲信源分离混合矩阵的通用方法。

1 盲信源分离与张量的标准分解

1.1 盲信源分离模型

盲信源分离的混合模型^[4]如下:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) \quad (1)$$

其中: $\mathbf{x}(t) \in \mathbb{R}^J$ 表示 J 维观测信号向量, $\mathbf{s}(t) \in \mathbb{R}^R$ 表示各分量相互独立的 R 维源信号向量, $\mathbf{n}(t) \in \mathbb{R}^J$ 表示与源信号独立的加性噪声;事先未知的混合矩阵 $\mathbf{A} \in \mathbb{R}^{J \times R}$ 行满秩。

辨识混合矩阵 \mathbf{A} 是实现盲分离的第一步。在盲分离问题中,混合矩阵的辨识存在列向量幅值和排列顺序两种固有的不确定性^[1],记 $\hat{\mathbf{A}}$ 为 \mathbf{A} 的辨识,这两种不确定性可以表示为:

$$\mathbf{A} = \hat{\mathbf{A}}\mathbf{P}\mathbf{D} \quad (2)$$

其中: \mathbf{P} 为 $R \times R$ 的置换矩阵, \mathbf{D} 为 $R \times R$ 的非奇异对角矩阵。

1.2 张量的标准分解

张量^[16-19]又称为多维阵列,它是矩阵的高维扩展。张量

收稿日期:2012-03-20;修回日期:2012-06-07。基金项目:国家自然科学基金资助项目(60775013, 61104079);河南理工大学青年基金资助项目(Q2011-50);河南理工大学博士基金资助项目(648753)。

作者简介:张延良(1979-),男,河南汝州人,副教授,博士,主要研究方向:盲信号处理、独立分量分析;张伟涛(1983-),男,陕西户县人,讲师,博士,主要研究方向:通信信号处理;杜静静(1982-),女,河南博爱人,副教授,博士,主要研究方向:非线性控制。

主要有两种分解方法:标准分解^[16-18]和塔克分解^[16-18]。张量分解在心理测验学和化学统计学得到了广泛的应用^[19]。因其强大的数据分析功能,近十年来,研究者开始尝试将其应用于信号处理、机器视觉、数据挖掘等信息科学领域^[13]。

盲信源分离混合矩阵的估计可以转化为张量的标准分解问题,为阐释这一方法,先介绍有关标准分解的概念。

定义1 外积^[16]。向量 $\mathbf{u} \in \mathbf{R}^M$ 、 $\mathbf{v} \in \mathbf{R}^N$ 、 $\mathbf{w} \in \mathbf{R}^P$ 的外积构成一个三阶张量 $\bar{\mathbf{Z}} \in \mathbf{R}^{M \times N \times P}$,记作 $\bar{\mathbf{Z}} = \mathbf{u} \circ \mathbf{v} \circ \mathbf{w}$ 。其中 $\bar{\mathbf{Z}}$ 的每个元素:

$$\begin{aligned} z_{mnp} &= \mathbf{u}_m \mathbf{v}_n \mathbf{w}_p; m = 1, 2, \dots, M; n = 1, 2, \dots, N; \\ p &= 1, 2, \dots, P \end{aligned} \quad (3)$$

定义2 标准分解^[16]。若张量 $\bar{\mathbf{Y}} \in \mathbf{R}^{M \times N \times P}$,则张量 $\bar{\mathbf{Y}}$ 的标准分解定义为:

$$\bar{\mathbf{Y}} = \sum_{i=1}^{\text{rank}(\bar{\mathbf{Y}})} \mathbf{u}_i \circ \mathbf{v}_i \circ \mathbf{w}_i \quad (4)$$

其中: $\mathbf{u}_i \in \mathbf{R}^M$ 、 $\mathbf{v}_i \in \mathbf{R}^N$ 、 $\mathbf{w}_i \in \mathbf{R}^P$, $\text{rank}(\bar{\mathbf{Y}})$ 为张量 $\bar{\mathbf{Y}}$ 的秩。张量秩的定义见文献[16, 18]。

1.3 标准分解本质唯一存在条件

假设 $\bar{\mathbf{Y}} \in \mathbf{R}^{M \times N \times P}$ 有如式(4)所示的分解,记:

$$I = \text{rank}(\bar{\mathbf{Y}})$$

$$\bar{\mathbf{Y}} = \sum_{i=1}^I \mathbf{u}_i \circ \mathbf{v}_i \circ \mathbf{w}_i = [\mathbf{U}, \mathbf{V}, \mathbf{W}]$$

其中 $\mathbf{U}, \mathbf{V}, \mathbf{W}$ 称为标准分解的因子矩阵:

$$\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_I]$$

$$\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_I]$$

$$\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_I]$$

下面讨论给定 $\bar{\mathbf{Y}}$ 其标准分解 $[\mathbf{U}, \mathbf{V}, \mathbf{W}]$ 的唯一存在问题。显然分解因子存在固有的幅值和排列顺序的不确定性^[16]。如

果 $\alpha_i \beta_i \gamma_i = 1 (1 \leq i \leq I)$, 则 $\bar{\mathbf{Y}} = \sum_{i=1}^I (\alpha_i \mathbf{u}_i) \circ (\beta_i \mathbf{v}_i) \circ (\gamma_i \mathbf{w}_i)$

成立,此谓幅值不确定性;另外 $\bar{\mathbf{Y}} = [\mathbf{U}, \mathbf{V}, \mathbf{W}] = [\mathbf{U}\mathbf{P}, \mathbf{V}\mathbf{P}, \mathbf{W}\mathbf{P}]$ 成立,其中 \mathbf{P} 为任一 $I \times I$ 置换矩阵,此谓排列顺序的不确定性。在研究标准分解存在问题时,如果分解因子仅存在幅值和排列顺序的不确定性,则称该张量的标准分解是本质唯一存在的^[16]。

综上所述,张量标准分解的因子矩阵和盲信源分离混合矩阵的估计一样,也存在幅值和排列顺序的不确定性,这就为运用张量的标准分解估计盲分离的混合矩阵提供了条件。

2 用张量的标准分解估计混合矩阵

2.1 模型转化

盲分离模型(式(1))中混合信号的二阶时延相关矩阵为:

$$\mathbf{C}_k = E[\mathbf{x}(t)\mathbf{x}^T(t + \tau_k)] = \mathbf{A}\mathbf{D}_k\mathbf{A}^T; k = 1, 2, \dots, K \quad (5)$$

其中 $\mathbf{D}_k = E[\mathbf{s}(t)\mathbf{s}^T(t + \tau_k)]$ 为对角矩阵。为了保证估计的稳健性,通常取 K 是一个较大的值,本文假定 $K \gg R$ 。由 $\mathbf{C}_k \in \mathbf{R}^{J \times J}$ 按如下方式组成一个三阶张量:

$$\bar{\mathbf{C}} \in \mathbf{R}^{J \times J \times K}: (\bar{\mathbf{C}})_{ijk} = (\mathbf{C}_k)_{ij}; i, j = 1, 2, \dots, J; k = 1, 2, \dots, K$$

定义矩阵:

$$\mathbf{D} \in \mathbf{R}^{K \times R}: (\mathbf{D})_{kr} = (\mathbf{D}_k)_{rr}; k = 1, 2, \dots, K; r = 1, 2, \dots, R$$

这样张量 $\bar{\mathbf{C}}$ 可以写为如式(6)所示的分解形式:

$$\bar{\mathbf{C}} = \sum_{r=1}^R \mathbf{a}_r \circ \mathbf{a}_r \circ \mathbf{d}_r = [\mathbf{A}, \mathbf{A}, \mathbf{D}] \quad (6)$$

其中: $\mathbf{a}_r, \mathbf{d}_r$ 分别是矩阵 \mathbf{A}, \mathbf{D} 的第 r 列。式(6)恰好是张量 $\bar{\mathbf{C}}$ 的标准分解形式。

2.2 本质唯一存在条件

张量 $\bar{\mathbf{C}}$ 已知,如果它的标准分解本质唯一存在,则通过对 $\bar{\mathbf{C}}$ 进行标准分解来估计混合矩阵 \mathbf{A} 。文献[20]给出了标准分解式(6)本质唯一存在的一个充分条件如下:

$$\frac{R(R-1)}{2} \leq \frac{J(J-1)}{4} \left(\frac{J(J-1)}{2} + 1 \right) - \frac{J!}{(J-4)!4!} \quad (J \geq 4) \quad (7)$$

其中:

$$1_{\{J \geq 4\}} = \begin{cases} 0, & J < 4 \\ 1, & J \geq 4 \end{cases}$$

表1中给出了当接收传感器个数 J 一定时,由充分条件式(7)所得到的标准分解本质唯一存在所允许的源信号个数 R 的最大值 R_{\max} 。

表1 传感器数目 J 与所允许的源信号数目最大值 R_{\max} 的关系

J	R_{\max}	J	R_{\max}	J	R_{\max}
2	2	8	26	18	132
3	4	10	41	23	216
5	10	15	92		

由表1可看出,当 J 一定时,只要源信号数目 $R \leq R_{\max}$,就可以运用标准分解的方法估计混合矩阵,因此这种方法可以估计欠定、超定和适定情况下的混合矩阵。

3 运用循环最小化实现张量的标准分解

通过如式(8)所示的最小化代价函数来实现张量 $\bar{\mathbf{C}}$ 的标准分解。

$$f(\mathbf{A}, \mathbf{D}) = \| \bar{\mathbf{C}} - \sum_{r=1}^R \hat{\mathbf{a}}_r \circ \hat{\mathbf{a}}_r \circ \hat{\mathbf{d}}_r \|_F^2 \quad (8)$$

对于这种多变量优化问题,循环最小化^[19]是常用的一种方法。循环最小化的思路是将变量集合划分为若干个子集合,在每步中运用优化算法估计其中一个子集合中的变量,而将其余子集合中的变量视为常数,如此循环往复直到代价函数收敛为止。结合最小代价函数(式(8))的特点,采用交替最小二乘(Alternating Least Squares, ALS) 实现循环最小化。

张量 $\bar{\mathbf{C}}$ 的第一、第二和第三维切片矩阵分别为

$$\mathbf{E}_i \in \mathbf{R}^{J \times K}; i = 1, 2, \dots, J$$

$$\mathbf{F}_j \in \mathbf{R}^{K \times J}; j = 1, 2, \dots, J$$

$$\mathbf{G}_k \in \mathbf{R}^{J \times J}; k = 1, 2, \dots, K$$

由式(6)及张量 $\bar{\mathbf{C}}$ 的对称性可得:

$$\mathbf{G}_k = \mathbf{A} \text{diag}_k(\mathbf{D}) \mathbf{A}^T; k = 1, 2, \dots, K \quad (9)$$

$$\mathbf{E}_i = \mathbf{A} \text{diag}_i(\mathbf{A}) \mathbf{D}^T; i = 1, 2, \dots, J \quad (10)$$

$$\mathbf{F}_j = \mathbf{D} \text{diag}_j(\mathbf{A}) \mathbf{A}^T; j = 1, 2, \dots, J \quad (11)$$

式(9)可以写为矩阵的形式:

$$\begin{bmatrix} \mathbf{G}_1 \\ \mathbf{G}_2 \\ \vdots \\ \mathbf{G}_K \end{bmatrix} = \begin{bmatrix} \mathbf{A} \text{diag}_1(\mathbf{D}) \\ \mathbf{A} \text{diag}_2(\mathbf{D}) \\ \vdots \\ \mathbf{A} \text{diag}_K(\mathbf{D}) \end{bmatrix} \mathbf{A}^T \quad (12)$$

由式(12)可得 \mathbf{A} 的最小二乘估计为:

$$\hat{\mathbf{A}}^T = \begin{bmatrix} \mathbf{A} \text{diag}_1(\mathbf{D}) \\ \mathbf{A} \text{diag}_2(\mathbf{D}) \\ \vdots \\ \mathbf{A} \text{diag}_K(\mathbf{D}) \end{bmatrix}^\dagger \begin{bmatrix} \mathbf{G}_1 \\ \mathbf{G}_2 \\ \vdots \\ \mathbf{G}_K \end{bmatrix} \quad (13)$$

其中“ $\hat{\cdot}$ ”表示 Moore-Penrose 逆矩阵。同理, 可由式(10)、(11)可得 D 、 A 的最小二乘估计分别为:

$$\hat{D}^T = \begin{bmatrix} A \operatorname{diag}_1(A) \\ A \operatorname{diag}_2(A) \\ \vdots \\ A \operatorname{diag}_J(A) \end{bmatrix}^\dagger \begin{bmatrix} E_1 \\ E_2 \\ \vdots \\ E_J \end{bmatrix} \quad (14)$$

$$\hat{A}^T = \begin{bmatrix} D \operatorname{diag}_1(A) \\ D \operatorname{diag}_2(A) \\ \vdots \\ D \operatorname{diag}_J(A) \end{bmatrix}^\dagger \begin{bmatrix} F_1 \\ F_2 \\ \vdots \\ F_J \end{bmatrix} \quad (15)$$

随机初始化矩阵 A 、 D , 然后分别运用交替最小二乘式(13)、(14)、(15)更新 \hat{A} 、 \hat{D} , 在更新的过程中, 等式右边的 A 、 D 用前一步估计得到的 \hat{A} 、 \hat{D} 代替。

4 仿真研究

分别运用本文算法和文献[9, 21]算法对欠定、适定和超定情况下的混合矩阵进行估计的数值仿真实验来检验本文算法的有效性。将本文算法记为 TCD, 将文献[9]和文献[21]提出的基于非正交联合对角化的算法分别记为 ACDC 和 NU-JD。

混合信号的二阶时延相关矩阵按式(5)模拟产生, 其中混合矩阵 A 的维数为 $M \times N$, 对角矩阵 D_k 的维数为 $N \times N$, 它们的元素在每次独立实验中随机产生且均服从标准正态分布。这些矩阵按照 2.1 节描述的方法组成三阶张量 $\bar{C} \in \mathbb{R}^{M \times M \times K}$ 。混合矩阵估计的准确性由相对误差^[22]error 来衡量:

$$\text{error} = E \left\{ \frac{\|A - \hat{A}\|_F}{\|A\|_F} \right\} \quad (16)$$

其中: \hat{A} 为混合矩阵 A 的估计, 假设它们的列向量均已单位化且消除了排列顺序的不确定性。为了便于比较, 把相对误差通过 $10 \lg(\text{error})$ 转换为分贝(dB)的形式, 显然相对误差的分贝数越低对混合矩阵的估计精度越高。

实验 1 本实验比较适定情况下($M = N$)基于标准分解的 TCD 算法与基于非正交联合对角化的 NU-JD 算法的性能, 时延相关矩阵数目 K 取为 100。ALS 算法迭代终止条件设定为:

$$|(f_n(\hat{A}', \hat{D}') - f_{n-1}(\hat{A}', \hat{D}'))/f_n(\hat{A}', \hat{D}')| < 10^{-6}$$

其中 f 函数的定义见式(8)。

分别运用 TCD 与 NU-JD 算法估计 M 取不同值时的混合矩阵, 100 次 Monte-Carlo 实验得到的相对误差均值如表 2 所示。从表 2 可看出, TCD 性能明显好于基于联合对角化的 NU-JD 算法。

表 2 适定情况下算法估计精度比较 dB

A 的维数	TCD	NU-JD
$M=4, N=4$	-147.9440	-116.6677
$M=6, N=6$	-155.5280	-95.4903
$M=8, N=8$	-157.7282	-90.1111
$M=10, N=10$	-156.3930	-92.6749
$M=16, N=16$	-161.8886	-96.2367
$M=20, N=20$	-156.5335	-82.2258
$M=30, N=30$	-156.7149	-58.9309
$M=40, N=40$	-155.1101	-11.0987

表 3 列出了 $K = 100$ 时两种算法独立运行一次所需的平均时间, 从中可看出: 在 M 、 N 取不同值的情况下, 除了在维数较低的情况下($M = N = 4, M = N = 6$)外, 其他情况 NU-JD 算法的运算时间均明显超过本文的 TCD 算法, 而且 NU-JD 算法的运算时间随着混合矩阵维数的增加急剧增加。

表 3 适定情况下算法运算时间比较($K = 100$) s

A 的维数	TCD	NU-JD
$M=4, N=4$	1.5529	0.0536
$M=6, N=6$	1.2034	0.1764
$M=8, N=8$	1.1880	0.3557
$M=10, N=10$	1.2655	0.7216
$M=16, N=16$	1.4023	2.7487
$M=20, N=20$	1.8284	10.1810
$M=30, N=30$	3.7504	90.2568
$M=40, N=40$	7.4014	423.3555

实验 2 本实验比较超定情况下($M > N$)基于标准分解的 TCD 算法与基于非正交联合对角化的 ACDC 算法的性能。实验基本的设置与实验 1 相同, 其中 A 为“瘦高”的超定混合矩阵, 其维数 $M > N$ 。

分别运用 TCD 与 ACDC 算法估计 M 、 N 取不同值时的混合矩阵, 100 次 Monte-Carlo 实验得到的相对误差均值如表 4 所示。表 5 为两种算法独立运行一次所需的平均时间。

表 4 超定情况下算法估计精度比较 dB

A 的维数	TCD	ACDC
$M=4, N=3$	-343.1359	-79.3570
$M=6, N=4$	-345.4922	-84.4296
$M=8, N=5$	-343.0113	-91.6824
$M=10, N=6$	-339.4966	-95.9004
$M=16, N=10$	-321.6591	-100.9049
$M=20, N=12$	-330.9681	-107.1148
$M=30, N=20$	-320.5955	-116.0088
$M=40, N=30$	-306.7069	-121.9591

表 5 超定情况下算法运算时间比较($K = 100$) s

A 的维数	TCD	ACDC
$M=4, N=3$	0.2839	0.9568
$M=6, N=4$	0.3042	1.4134
$M=8, N=5$	0.3305	1.6524
$M=10, N=6$	0.3770	2.4805
$M=16, N=10$	0.5089	7.8012
$M=20, N=12$	0.6537	13.9125
$M=30, N=20$	1.4688	49.0328
$M=40, N=30$	3.0930	158.4669

从表 4 可看出, TCD 算法的估计精度明显好于基于联合对角化的 ACDC 算法。从表 5 可看出, 在 M 、 N 取不同值的情况下, 基于张量分解的 TCD 算法的运算时间均明显小于 ACDC 算法, 而且 ACDC 算法的运算时间随着混合矩阵维数的增加急剧增加。

实验 3 本实验分析欠定情况($M < N$)下 TCD 算法估计混合矩阵的性能。 M 、 N 取不同值时, 100 次 Monte-Carlo 实验得到的相对误差均值和运算时间均值如表 6 所示。通过表 6 可看出, TCD 算法可以很好地实现欠定混合矩阵的估计。而基于非正交联合对角化的算法 NU-JD 和 ACDC, 均不能用于估计欠定情况下的混合矩阵。

表6 欠定情况下本文算法的估计精度和运算时间

A的维数	估计精度/dB	运算时间/s
$M=4, N=5$	-155.1909	1.4748
$M=5, N=6$	-149.4912	1.5918
$M=6, N=8$	-146.5334	2.5185
$M=8, N=10$	-144.2351	3.0151
$M=10, N=16$	-140.0284	4.2947
$M=15, N=20$	-134.6824	5.4100
$M=18, N=30$	-111.3785	9.1283
$M=23, N=40$	-72.6443	15.6118

5 结语

本文将盲信源分离混合矩阵的估计转化为观测信号统计量所组成张量的标准分解问题,张量分解通过循环最小化技术实现。该方法不仅能够实现适定、超定情况下的混合矩阵估计问题,而且可以解决一般情况下欠定混合矩阵的估计问题。仿真实验表明,本文方法的估计精度和运算时间较以往算法均有明显的改善,是一种有效的估计盲分离混合矩阵的通用方法。

参考文献:

- [1] HYVÄRINEN A, KARHUNEN J, OJA E. Independent component analysis [M]. New York: John Wiley & Sons, 2001.
- [2] CICHOCKI A, AMARI S I. Adaptive blind signal and image processing [M]. New York: John Wiley & Sons, 2002.
- [3] COMON P, JUTTEN C. Handbook of blind source separation, independent component analysis and applications [M]. London: Academic Press, 2010.
- [4] BOFILL P, ZIBULEVSKY M. Underdetermined blind source separation using sparse representations [J]. Signal Processing, 2001, 81(11): 2353–2362.
- [5] CICHOCKI A, SABALA I, CHOI S, et al. Self-adaptive independent component analysis for sub-Gaussian and super-Gaussian mixtures with unknown number of source signals and additive noise [EB/OL]. [2009-10-10]. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.215.776&rep=rep1&type=pdf>.
- [6] YE J M, ZHU X L, ZHANG X D. Adaptive blind source separation with an unknown number of sources [J]. Neural Computation, 2004, 16(8): 1641–1660.
- [7] 治继民, 张贤达, 金海红. 超定盲信号分离的半参数统计方法 [J]. 电波科学学报, 2006, 21(3): 331–336.
- [8] LI X L, ZHANG X D. Non-orthogonal approximate joint diagonalization free of degenerate solution [J]. IEEE Transactions on Signal

Processing, 2007, 55(51): 1803–1814.

- [9] YEREDOR A. Non-orthogonal joint diagonalization in the least-squares sense with application in blind source separation [J]. IEEE Transactions on Signal Processing, 2002, 50(7): 1545–1553.
- [10] LI YUANQING, AMARI S, CICHOCKI A, et al. Underdetermined blind source separation based on sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54(2): 423–437.
- [11] AISSA-EL-BEY A, LINH-TRUNG N, ABED-MERAIM K, et al. Underdetermined blind separation of nondisjoint sources in the time-frequency domain [J]. IEEE Transactions on Signal Processing, 2007, 55(3): 897–907.
- [12] PENG DEZHONG, XIANG YONG. Underdetermined blind source separation based on relaxed sparsity condition of sources [J]. IEEE Transactions on Signal Processing, 2009, 57(2): 809–814.
- [13] de LATHAUWER L, CASTAING J. Blind identification of under-determined mixtures by simultaneous matrix diagonalization [J]. IEEE Transactions on Signal Processing, 2008, 56(3): 1096–1105.
- [14] 张延良, 楼顺天, 张伟涛. 欠定盲信源分离混合矩阵估计的张量分解方法 [J]. 系统工程与电子技术, 2011, 33(8): 1703–1706.
- [15] 张延良. 线性混合盲信源分离的算法研究 [D]. 西安: 西安电子科技大学, 2011.
- [16] KOLDA T G, BADER B W. Tensor decompositions and applications [J]. SIAM Review, 2009, 51(3): 455–500.
- [17] de LATHAUWER L. A survey of tensor methods [C]// Proceedings of IEEE International Symposium on Circuits and Systems. Piscataway, NJ: IEEE Press, 2009: 2773–2776.
- [18] CICHOCKI A, ZDUNEK R, PHAN A H, et al. Nonnegative matrix and tensor factorizations [M]. New York: Wiley, 2009.
- [19] STOICA P, SELÉN Y. Cyclic minimizers, majorization techniques, and the expectation-maximization algorithm: a refresher [J]. IEEE Signal Processing Magazine, 2004, 21(1): 112–114.
- [20] STEGEMAN A, TEN B, JOS M F, et al. Sufficient conditions for uniqueness in CANDECOMP/PARAFAC and INDSCAL with random component matrices [J]. Psychometrika, 2006, 71(2): 219–229.
- [21] WANG FUXIANG, LIU ZHONGKAN, ZHANG JUN. Nonorthogonal joint diagonalization algorithm based on trigonometric parameterization [J]. IEEE Transactions on Signal Processing, 2007, 55(11): 5299–5308.
- [22] de LATHAUWER L, CASTAING J, CARDOSO J-F. Fourth-order cumulant-based blind identification of underdetermined mixtures [J]. IEEE Transactions on Signal Processing, 2007, 55(6): 2965–2973.

(上接第 2431 页)

- [8] WANG J, URRIZA P, HAN Y X. Weighted centroid localization algorithm: Theoretical analysis and distributed implementation [J]. IEEE Transactions on Wireless Communications, 2011, 10(10): 3403–3413.
- [9] CHENG HAI-QING, WANG HUA, WANG HUA-KUI. An improved centroid localization algorithm based on weighted average in WSN [C]// ICECT: Proceedings of International Electronics Computer Technology Conference. Piscataway, NJ: IEEE Press, 2011: 258–262.
- [10] 安恂, 蒋挺, 周正. 一种用于无线传感器网络的质心定位算法 [J]. 计算机工程与应用, 2007, 43(20): 136–138.

- [11] 衣晓, 刘瑜, 邓露. 一种基于 PIT 的无线传感器网络质心定位算法 [J]. 传感技术学报, 2010, 23(7): 1012–1016.
- [12] BEHNKE R, TIMMERMANN D. AWCL: Adaptive weighted centroid localization as an efficient improvement of coarse grained localization [C]// WPNC 2008: Proceedings of the 5th Workshop on Positioning, Navigation and Communication. Piscataway, NJ: IEEE Press, 2008: 243–250.
- [13] ZHOU QUAN, LI XIAO-WEI, XU YONG-JUN. Smallest enclosing circle based localization approach for wireless sensor networks [C]// Proceedings of 2009 International Conference on Communications and Mobile Computing. Washington, DC: IEEE Computer Society, 2009: 61–65.