

# FastICA 和 RobustICA 算法在 盲源分离中的性能分析

吴微<sup>a</sup>, 彭华<sup>a</sup>, 张帆<sup>b</sup>

(解放军信息工程大学 a. 信息系统工程学院; b. 训练部, 郑州 450002)

**摘要:** 首先简单介绍了 FastICA 和 RobustICA 这两种目前最为常用的盲源分离算法, 并对这算法的目标函数以及优化算法进行了分析研究, 进一步对这两种算法的稳健性及算法复杂度等方面的性能进行分析比较。总的来看, RobustICA 算法的综合性能要优于 FastICA 算法。

**关键词:** 独立分量分析; 盲源分离; FastICA; RobustICA; 峭度; 负熵

**中图分类号:** TP301      **文献标志码:** A      **文章编号:** 1001-3695(2014)01-0095-04

**doi:**10.3969/j.issn.1001-3695.2014.01.022

## Performance analysis of FastICA and RobustICA on blind sources separation

WU Wei<sup>a</sup>, PENG Hua<sup>a</sup>, ZHANG Fan<sup>b</sup>

(a. Institute of Information System Engineering, b. Training Dept., Information Engineering University of PLA, Zhengzhou 450002, China)

**Abstract:** This paper firstly introduced FastICA and RobustICA algorithms, and then researched the objective functions and optimization algorithms of these two algorithms. Furthermore, it analyzed and compared the performance of these two algorithms about robustness and computation complexity. As a result, the general performance of RobustICA is better than FastICA.

**Key words:** independent component analysis(ICA); blind sources separation; FastICA; RobustICA; kurtosis; negentropy

独立分量分析(ICA)是将观测到的随机向量分解成若干个相互统计独立成分的方法<sup>[1]</sup>。ICA 的应用十分广泛,较新的应用有因果关系分析、独立分量检测、多数据集分析等<sup>[2]</sup>。盲源分离(blind sources separation, BSS)是指在不知源信号和传输通道参数的情况下,仅由观测信号恢复出源信号各个分量的过程。ICA 的发展是与 BSS 紧密联系的,只是后者的研究范畴更宽,处理手段也更多<sup>[3]</sup>。然而,在源信号相互统计独立的假设前提下,ICA 与 BSS 的提法可以认为是完全一致的。

FastICA<sup>[4-6]</sup>是芬兰学者 Hyvärinen 等人于 1997 年以及之后提出的著名的一类 ICA 算法,该类算法的主要优点在于收敛速度快,且由于无须引入调节步长等人为设置参数而更简单方便。然而, Chevalier 等人于 2004 年首先在文献[7]中提出, FastICA 在弱的或是空间相关性高的源信号的情况下会失败,并在之后提出了 RobustICA<sup>[8-11]</sup>算法,该算法被证明不仅简单,且性能超过了 FastICA。然而, RobustICA 使用的目标函数正是 FastICA 中认为不够稳健的峭度,因此本文主要针对这个问题进行研究,并进一步对这两种算法的稳健性、算法复杂度等方面的性能进行分析比较,为以后更好地使用及进一步改进这些算法打好基础。

## 1 独立分量分析概述

### 1.1 ICA 的模型

假设观测到  $m$  个随机变量  $x_1, x_2, \dots, x_m$ , 而这些变量是由

另外  $n$  个随机变量  $s_1, s_2, \dots, s_n$  线性组合得到的:

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n \quad (1)$$

式中:  $a_{ij}$  是实系数。假设  $s_i$  在统计上彼此独立。这就是基本的 ICA 模型。由于该模型描述了观测变量是如何由独立分量  $s_i$  的混合过程得到的,因此 ICA 是一种生成模型。用向量—矩阵符号方式表示通常比式(1)的求和表达式更为方便。此时,混合模型可以写为

$$x = As \quad (2)$$

在盲源分离问题中,上式可理解为:  $s$  为源信号,  $A$  为混合矩阵,  $x$  为观测信号。由于无噪声模型的估计问题其本身已相当困难<sup>[6]</sup>,因此为了简单起见,该模型中忽略了噪声项。

ICA 模型的估计通常是通过先选择一个合适的目标函数,然后对其进行最小化或是最大化。其中目标函数的选择决定了 ICA 算法的统计性质,如一致性、渐变性、稳健性等,最优优化算法则决定了 ICA 算法运行的性能,如收敛速度、计算复杂度以及稳定性等。关于 ICA 的详细内容可参阅文献[12]。

### 1.2 ICA 的约束

为确保 ICA 模型能够被估计,必须对其进行一定的约束。

首先,独立分量也就是源信号,被假定是统计独立的。该假设是 ICA 能够成立的前提。其次,独立成分必须具有非高斯的分布。如果观测变量具有高斯分布,那么 ICA 在本质上是不能实现的。最后,为了简单起见,假定未知的混合矩阵是方阵。也就是说,独立分量的个数与观测向量的个数是相等

收稿日期: 2013-04-15; 修回日期: 2013-05-23

作者简介: 吴微(1981-),女,陕西礼泉人,博士研究生,主要研究方向为信号分析、盲信号处理(wuwe\_i0930@163.com); 彭华(1973-),男,江西萍乡人,教授,博导,主要研究方向为通信信号处理、软件无线电; 张帆(1980-),男,甘肃兰州人。

的,即  $m = n$ 。

前两个约束是为了确保 ICA 模型是可辨识的,而第三条约束则是为了简化问题,并不是必需的。

### 1.3 ICA 中的不确定因素

从 ICA 的模型中容易发现存在一些不确定因素。

一是独立分量的方差是不确定的,二是独立分量的次序是不确定的。这两个不确定因素的原因均在于源信号和混合矩阵都是未知的。然而在盲源分离问题中,这两个方面的不确定性并不会影响对于源信号的辨识,因此是允许其存在的。

## 2 FastICA 与 RobustICA 算法比较

### 2.1 FastICA 简介

1997 年芬兰学者 Hyvärinen 等人首先提出基于峭度的固定点算法<sup>[4]</sup>,其后,在 1999 年又提出了基于负熵的 ICA 固定点算法<sup>[5]</sup>,在 2001 年出版的著作<sup>[6]</sup>中又作了进一步的简化。由于这一算法比批处理甚至自适应处理具有更快的收敛速度,因此又被称为快速 ICA 算法,即 FastICA。该算法首先要求对观测数据进行白化预处理,去除数据间的相关性。对 FastICA 算法的改进主要有对其优化算法的改进以及使用更为稳健的高阶统计方法<sup>[13]</sup>。本文主要对经典的 FastICA 算法进行研究。基于峭度的 FastICA 算法以峭度作为非高斯性的度量。假设白化后的观测向量为  $x$ ,寻找观测值  $x_i$  的一个线性组合,即  $w^T x$ ,使其具有最大或最小的峭度。算法的迭代公式如下:

$$w(k) = E\{x(w(k-1))^T x\} - 3w(k-1) \tag{3}$$

式中: $E\{\cdot\}$ 表示求数学期望。

该算法虽然简单却是非常有效的,它能够快速且可靠地收敛,大部分情况下比基于梯度的算法具有明显的优势。然而在实际应用中,由于峭度的值只能从测量样本中估计,使得峭度方法也存在一些缺点。

而负熵作为非高斯性的度量其效果优于峭度,因此基于负熵的 FastICA 算法的应用更广泛一些。使用负熵的最大问题在于其计算非常困难,因此负熵的近似是十分必要的。此处略去算法的推导过程,给出算法的迭代公式如下:

$$w(k) = E\{xg(w(k-1)^T x)\} - E\{g'(w(k-1)^T x)\}w$$
$$w^*(k) = \frac{w(k)}{\|w(k)\|} \tag{4}$$

式中: $g(\cdot)$ 的选择参见文献<sup>[5]</sup>。与前面提及的峭度算法相同的是,FastICA 在无须快速适应变化环境的情况下,即使只用到负熵的一般形式的近似,其收敛特性也是二次的。更进一步,由于算法中没有调节步长或其他需要调整的参数,故算法容易使用且更加可靠。此外,利用负熵的鲁棒性近似取代峭度增强了相应估计的统计性能。

### 2.2 RobustICA 简介

Zarzoso 等人<sup>[11]</sup>研究表明,在众多的目标函数中,峭度被证明是在 ICA 中使用得最普遍的统计量。尽管峭度在渐近方差以及对于野点的稳健性方面存在不足,但是峭度被证明在数学上易处理,计算简便,对有限采样的稳健性,使得峭度被广泛使用<sup>[14]</sup>。

假设观测数据为  $x$ ,同 FastICA 不同的是,RobustICA 所使用的观测数据  $x$  是没有经过白化处理的,仅要求其均值为零,则解混后的数据为  $y = w^T x$ ,其峭度公式为

$$\kappa(w) = \frac{E\{|y|^4\} - 2E^2\{|y|^2\} - |E\{y^2\}|^2}{E^2\{|y|^2\}} \tag{5}$$

该公式是峭度的一般公式,可以在复数域上进行运算。在没有简化假设条件的情况下,一个简单且非常自然的替换 Fast-ICA 的方法就是使用峭度绝对值目标函数的精确线性搜索,表达式如下:

$$\mu_{opt} = \arg \max_{\mu} |\kappa(w + \mu g)| \tag{6}$$

搜索方向  $g$  通常为梯度,即  $g = \nabla_w \kappa(w)$ ,但并不是必需的。

精确线性搜索计算复杂且有诸多限制,因此,尽管这是一个众所周知的优化方法,但在实际中却很少使用。然而,诸如峭度这类准则可以表示成  $\mu$  的多项式或有理函数,全局最优步长  $\mu_{opt}$  可以通过寻找低级多项式的根来确定。RobustICA 正是基于这个思路,在每次的迭代中,最优步长通过下面步骤获得:

a) 计算最优步长多项式系数。对于峭度目标函数而言,最优步长多项式由下式给出:

$$p(\mu) = \sum_{l=0}^4 a_l \mu^l \tag{7}$$

系数  $\{a_l\}_{l=0}^4$  可以在每次迭代中通过观测信号和  $w$  与  $g$  的当前值轻松获得。

b) 求出最优步长多项式的根  $\{\mu_l\}_{l=1}^4$ 。

c) 选择多项式的根,使得沿搜索方向目标函数的绝对值最大:

$$\mu_{opt} = \arg \max_l |\kappa(w(k-1) + \mu_l g)| \tag{8}$$

d) 更新:

$$w(k) = w(k-1) + \mu_{opt} g \tag{9}$$

e) 归一化:

$$w^*(k) = \frac{w(k)}{\|w(k)\|} \tag{10}$$

算法细节参阅文献<sup>[11]</sup>。RobustICA 算法能在不作任何改动的情况下处理实数源和复数源。

### 2.3 峭度作为目标函数的优缺点

假设  $v$  为零均值的实随机变量,则其峭度定义为

$$\text{kurt}(v) = E\{v^4\} - 3(E\{v^2\})^2 \tag{11}$$

对于高斯随机变量其峭度为零;峭度大于零的称为超高斯分布;峭度小于零的称为亚高斯分布。对于两个独立随机变量  $v_1$  与  $v_2$  以及标量  $\alpha$ ,峭度满足如下公式:

$$\text{kurt}(v_1 + v_2) = \text{kurt}(v_1) + \text{kurt}(v_2)$$
$$\text{kurt}(\alpha v_1) = \alpha^4 \text{kurt}(v_1) \tag{12}$$

使用峭度作为目标函数最大的优点在于其计算简便,易于实现;其次,在无噪声的模型下,对于无限采样点不存在伪局部极值点。正是峭度这个吸引人的特性可以产生全局收敛的 ICA 算法<sup>[11]</sup>。

然而,峭度作为目标函数存在的问题也是不容忽视的。峭度存在的问题主要有两个方面:a) 渐近方差问题;b) 对于野值的稳健性问题<sup>[14]</sup>。

首先,对于超高斯的独立分量而言,渐近方差最小化要求目标函数较四阶功率的增长更加缓慢。而四阶功率是四阶累积量或者说是峭度所固有的特性。此时,以峭度作为目标函数并不能满足渐近方差最小化的要求。

其次,峭度可能对野值极其敏感,即其值可能只取决于分布于边缘的少量观测值,而这些观测值可能是错误的或与问题无关的。更进一步,对于野点的稳健性也需要有缓慢增长的目标函数。而实际中的信号很多是具有超高斯分布的,这就意味着在大多数情况下,峭度并不是一个相当充分的目标函数。

综上所述,峭度并不是一个非高斯性的鲁棒度量。

### 2.4 两种算法的比较

本节主要从以下两个方面对 FastICA 和 RobustICA 这两个算法进行比较:

#### a) 目标函数的比较

基于峭度的 FastICA 算法其目标函数中峭度的定义如式 (11) 所示,称之为简单形式。而 RobustICA 算法中的目标函数的峭度为其四阶累积量的完整表达式,如式 (5) 所示。基于负熵的 FastICA 算法使用的是经过近似处理的负熵作为非高斯性的度量,与基于峭度的 FastICA 算法相比,该方法的性能更好<sup>[5]</sup>。

文献[15]中提出基于预白化阶段的正交进程有一个固有的下限,也就是说在采样数量  $N$  趋近于无穷时达到的渐近分离性能,这主要是由于在计算白化矩阵时引入的误差在后续的计算中无法补偿。因此在有限采样点的情况下,使用完整表达式且不经过白化处理的方式较使用简单形式且必须要进行白化预处理的方式,其提取性能会有所提升。

#### b) 优化算法的比较

基于峭度的 FastICA 算法使用的是固定点算法进行优化,而基于负熵的 FastICA 算法则使用的是 Newton 法进行优化。而 Newton 法本身存在一些问题:首先,可能会出现某步迭代时目标函数值上升的情况;其次,当初始值距最优值较远时,产生的点列可能不收敛,或者收敛到鞍点,或者得到的 Hesse 矩阵奇异,无法继续计算;最后,因为需要计算 Hesse 矩阵,因此计算量大。

RobustICA 算法使用的是精确线性搜索优化方法来获得最优步长。然而,精确线性搜索计算十分复杂,要想在实际中应用就必须进行一些改进。RobustICA 算法是通过将峭度表示成  $\mu$  的多项式,通过寻找低级多项式的根来确定全局最优步长  $\mu_{opt}$ 。

### 3 FastICA 与 RobustICA 的性能比较分析

本章主要对 FastICA 和 RobustICA 这两种算法的性能进行比较分析。其中,FastICA 中又包含了基于峭度的算法 (FastICA-Kurtosis, 简记为 F-K) 和基于负熵的算法 (FastICA-Negentropy, 简记为 F-N), 加上 RobustICA (简记为 R) 算法。本章主要对这三个算法在亚高斯源、超高斯源以及混合源的情况下,随信噪比以及采样点数的变化对其性能的影响进行比较。为了更精确描述信号分离的性能优劣,这里使用信号均方误差 (SMSE) 作为评判准则<sup>[9]</sup>, 公式如下:

$$SMSE = \frac{1}{K} \sum_k E\{ |s_k - \hat{s}_k|^2 \} \quad (13)$$

其中:  $s_k$  为源信号,  $\hat{s}_k$  为相应的估计信号,  $K$  为源信号个数。

本章的算法研究以 MATLAB 作为仿真平台, 分别使用了三个亚高斯源、三个超高斯源以及由两个亚高斯源和两个超高斯源组成的混合源, 混合矩阵随机生成, 加入高斯白噪声, 对混合后的含噪数据使用前面提及的三个算法进行盲源分离。

#### 3.1 信噪比的影响

首先对三个亚高斯源混合后加入高斯白噪声, 每个源取 3 000 个采样点, 信噪比从 -15 dB 增加至 45 dB, 每个实验点重复实验 200 次, 对结果进行平均。得到的结果如图 1 所示。

对三个超高斯源混合后加入高斯白噪声, 每个源取 5 000 个采样点, 信噪比从 -15 dB 增加至 51 dB, 每个实验点重复实验 200 次, 对结果进行平均。得到的结果如图 2 所示。

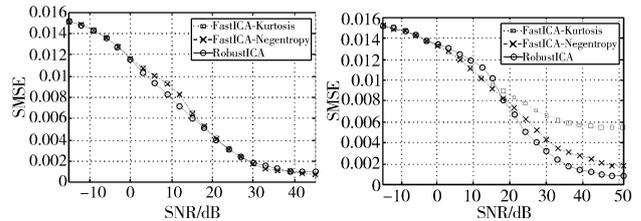


图 1 亚高斯源时三种算法随信噪比变化的性能比较

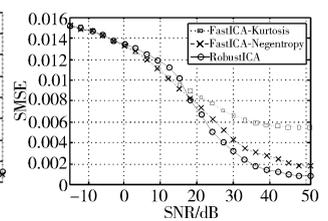


图 2 超高斯源时三种算法随信噪比变化的性能比较

对四个源组成的混合源混合后加入高斯白噪声, 每个源取 5 000 个采样点, 信噪比从 -15 dB 增加至 51 dB, 每个实验点重复实验 200 次, 对结果进行平均。得到的结果如图 3 所示。

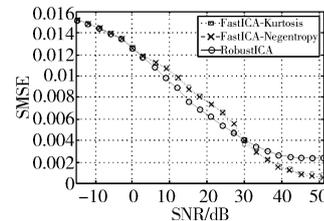


图 3 混合源时三种算法随信噪比变化的性能比较

从图 1 中可以看出, F-K 和 F-N 算法在亚高斯源的情况下随着信噪比的增加性能变化基本一致, 而 R 算法在信噪比为 0 ~ 20 dB 之间的性能略优于 F-K 和 F-N 算法。在超高斯源的情况下, 从图 2 中可见, 三个算法在信噪比低于 15 dB 时, 性能差别不大, F-K 和 F-N 算法略优于 R 算法, 当信噪比大于 15 dB 时, R 算法优于 F-N 算法, F-N 算法优于 F-K 算法。混合源的情况下 (图 3), F-K 与 F-N 算法性能基本一致, 在 0 ~ 30 dB 之间 R 算法的性能略优于这两种算法, 大于 30 dB 时, F-K 和 F-N 算法优于 R 算法。

综上所述, 在亚高斯源和混合源的情况下, 信噪比较低时, R 算法优于 F-K 和 F-N 算法, 信噪比较高时, FastICA 的两个算法的性能更好。而对超高斯信号而言, 低信噪比时 F-K 和 F-N 算法性能相当, 略优于 R 算法, 信噪比较高时 R 算法的性能最优, 其次是 F-N 算法, F-K 算法的性能相对最差。

#### 3.2 采样点数的影响

本部分实验对三个亚高斯源混合后加入高斯白噪声, 信噪比分别取 10 dB、20 dB 和 30 dB, 每个源从 150 个采样点取至 1 350 个采样点, 间隔 50 个采样点, 每个实验点重复实验 200 次, 对结果进行平均。三个不同的信噪比下得到的性能对比如图 4 所示。

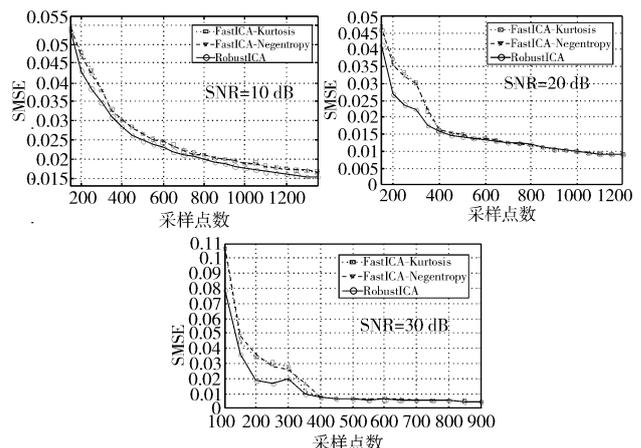


图 4 亚高斯源时三种算法随采样点数变化的性能比较  
从图中可以看出, 对亚高斯源而言, 低信噪比时, R 算法的

性能随着采样点数的增加始终优于 FastICA 算法。而在信噪比较高时,在采样点数少于 400 时,R 算法的性能明显优于 FastICA 算法,采样点数大于 400 时,几种算法的性能随采样点数的变化基本一致。

接下来对三个超高斯源混合后加入高斯白噪声,信噪比分别取 10 dB、20 dB 和 30 dB,每个源从 100 个采样点取至 3 500 个采样点,间隔 200 个采样点,每个实验点重复实验 200 次,对结果进行平均,得到的性能对比如图 5 所示。

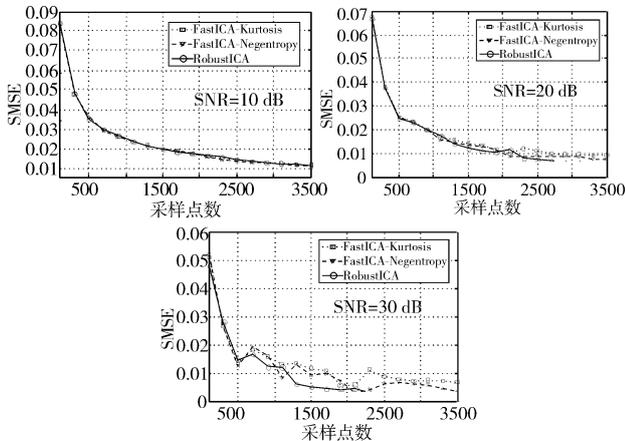


图 5 超高斯源时三种算法随采样点数变化的性能比较

从图 5 中可以看出,当源信号为超高斯信号时,SNR = 10 dB 时几种算法的性能基本一致。而当信噪比较高时,随着采样点数的增加 R 算法的性能最优,F-N 算法次之,F-K 算法相对较差。此外,信噪比较高时,FastICA 算法随着采样点数的增加性能的波动较大,R 算法则相对平稳一些。

最后对混合源信号混合时加入高斯白噪声,信噪比分别取 10 dB、20 dB 和 30 dB,每个源从 100 个采样点取至 2 250 个采样点,间隔 100 个采样点,每个实验点重复实验 200 次,对结果进行平均,得到的性能对比如图 6 所示。

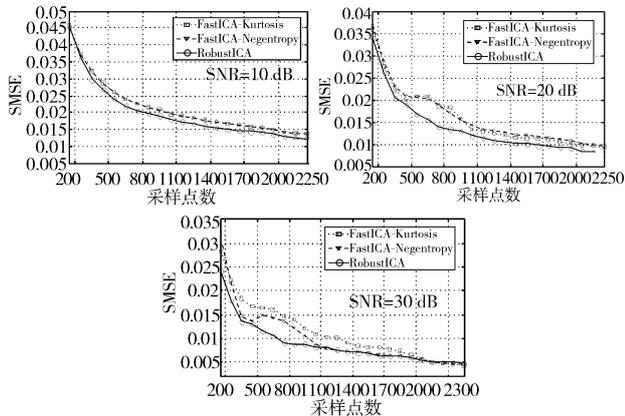


图 6 混合源时三种算法随采样点数变化的性能比较

从图 6 中混合源的情况可以看出,信噪比为 10 dB 和 20 dB 的时候,F-K 和 F-N 算法的性能随采样点数的变化基本一致,R 算法则要优于这两个算法。当信噪比为 30 dB 时,采样点数小于 1 100 时,R 算法的性能最优,F-N 次之,F-K 最后;当采样点数大于 1 100,小于 2 000 时,R 和 F-N 算法性能相当,F-K 次之;当采样点数大于 2 000 时,三个算法性能基本相同。

### 3.3 算法的复杂度分析

一些文献中,算法复杂度通常使用迭代次数来作为评测标准。有的算法可能需要上千次的迭代,但其每次迭代的运算量

很小,算法的复杂度并不高;还有一类仅需很少的迭代就可收敛的算法,其每次迭代中可能包含很大的运算量,因此迭代次数这个标准并不是十分合理。此外,还有一些文献中使用算法的平均运行时间作为评判标准,但是这个标准也并不客观。因为使用不同的编程语言,不同的运行环境,对同一问题不同的处理手段会使算法的运行时间产生显著的差别。因此考虑使用算法在完成一次完整运算时所需要的浮点操作的数量作为复杂度更客观的评测标准。

一次浮点操作可以看做是一次加法再加一次乘法,实际执行中,在一个数字信号处理器中一次浮点操作相应于一次乘累加循环。在信号提取问题中,提取算法的总代价可以使用迭代次数、每个源每次迭代的代价以及提取源的数量的乘积来计算。此外,如果数据需要进行白化预处理,此阶段中在计算奇异值分解的过程中,会额外增加  $2K^2T$  次浮点操作。每个源每个采样点的复杂度可以通过总代价除以  $KT$  获得,其中  $K$  为源信号的个数, $T$  为采样长度。

RobustICA 和 FastICA 在每次迭代中需要的主计算量如表 1 所示。其中,基于负熵的 FastICA 算法使用的函数  $g(\cdot)$  按下式选取:

$$g(y) = y \times \exp(-y^2/2) \tag{14}$$

表 1 RobustICA 和 FastICA 在每次迭代中的计算量

Methods	FastICA-Kurtosis	FastICA-Negentropy	RobustICA
每次迭代	$(2K+2)T$	$(2K+4)T$	$(5K+12)T$
计算复杂度			

计算量的统计细节参阅文献[16],统计过程中的期望观测信号的采样平均来代替。采样长度  $T$  假设足够大,此时只有由  $T$  决定的项被考虑。从表中可以看出 RobustICA 单次迭代的代价通常比 FastICA 高,然而,正如文献[11]所证实的那样,RobustICA 的每一次迭代在搜索好的解决方案时更加有效,因此在同样精度要求下,其总的复杂度要低于 FastICA。更进一步,在一些情况如超高斯源或是采样点数较少时 FastICA 不能达到 RobustICA 的精度。

## 4 结束语

本文对 RobustICA 和 FastICA 算法的性能进行了分析,其中 RobustICA 在超高斯源、低信噪比以及采样点数较少的情况下,其性能较 FastICA 而言更有优势。其他情况下,两种算法的性能基本相当。综合来看,RobustICA 算法的性能要优于 FastICA 算法,但其抗噪能力仍然不尽人意,下一步可以对 RobustICA 算法进行改进,增加其抗噪能力的同时保留其对超高斯源具有较好分离效果的优势,获得更优的盲源分离算法。

### 参考文献:

- [1] COMON P. Independent component analysis, a new concept? [J]. *Signal Processing*, 1994, 36(3): 287-314.
- [2] HYVÄRINEN A. Independent component analysis: recent advances [J]. *Philosophical Trans Royal Society A*, 2013, 371(1984): 20110534.
- [3] 杨福生,洪波. 独立分量分析的原理与应用[M]. 北京:清华大学出版社,2006.
- [4] HYVÄRINEN A, OJA E. A fast fixed-point algorithm for independent component analysis[J]. *Neural Computation*, 1997, 9(7): 1483-1492.

## 4 结束语

本文对证据的冲突进行了分析,对融合高冲突证据时所出现的问题进行了研究,在此基础上提出了基于证据偏离度的组合方法,通过多组实验对比分析表明本文所提的方法可以解决“一票否决”和鲁棒性差等证据组合问题。总体来分析本文所提的基于证据平均偏离度的组合方法具有以下特点:a)只对证据源进行修改,不改变经典组合规则的结构;b)在对证据进行异常判定后,采用加权平均证据替换异常证据,降低了异常证据对融合结果的影响;c)能够解决一般冲突、“一票否决”、鲁棒性差等证据的组合问题;d)本文的方法在对弱冲突证据进行融合时依然可以取得理想的结果;e)本文的方法只替换了异常的证据,保留了非异常证据对正确假设的支持,从而使融合结果向正确假设聚焦。

### 参考文献:

- [1] DEMPSTER A P. Upper and lower probabilities induced by a multi-valued mapping [J]. *Ann Mathematical Statistics*, 1967, 38(2): 325-339.
- [2] SHAFER G. A mathematical theory of evidence [M]. Princeton, New Jersey: Princeton University Press, 1976.
- [3] 王红亮,张美仙,丁海飞. D-S 证据理论在目标识别中的应用[J]. *自动化与仪表*, 2011, 26(7): 14-17.
- [4] CAO Jie, LI Wei, WU Di. Multi-feature fusion tracking based on a new particle filter [J]. *Journal of Computers*, 2012, 12(7): 2939-2947.
- [5] 邹伟,朱智平,李园,等. 一种基于粒子滤波的任意姿态头部椭圆轮廓跟踪方法[J]. *高技术通讯*, 2009, 19(12): 1288-1293.
- [6] MURPHY C K. Combining belief functions when evidence conflicts [J]. *Information Fusion*, 2001, 2(1): 91-101.
- [7] 邓勇,施文康,朱振福. 一种有效处理冲突证据的组合方法[J]. *红外与毫米波学报*, 2004, 23(1): 27-32.
- [8] 吴英,蒋雯,王栋,等. 一种最优冲突证据组合方法[J]. *电机与控制学报*, 2009, 13(1): 178-182.
- [9] 白剑林,王煜. 一种解决 D-S 理论证据冲突的有效方法[J]. *系统工程与电子技术*, 2009, 31(9): 2106-2109.
- [10] 张多林,潘泉,张洪才,等. 一种基于信息源可信度的证据组合方法[J]. *系统工程与电子技术*, 2008, 30(7): 1210-1213.
- [11] 李军伟,程咏梅,梁彦. 基于局部冲突分配策略的 DST 算法研究[J]. *控制与决策*, 2010, 25(10): 1484-1488.
- [12] 韩德强,韩崇昭,邓勇,等. 基于证据方差的加权证据组合[J]. *电子学报*, 2011, 39(3A): 153-157.
- [13] 韩德强,韩崇昭,邓勇,等. 基于证据距离与不确定度的证据组合方法[J]. *红外与毫米波学报*, 2011, 30(5): 396-399.
- [14] 张捍东,王翠华,强克坤. 基于焦元相似度的合成规则[J]. *控制理论应用*, 2011, 28(5): 741-744.
- [15] 杨善林,罗贺,胡小建. 基于焦元相似度的证据理论合成规则[J]. *模式识别与人工智能*, 2009, 22(2): 169-175.
- [16] 潘泉,张山鹰,程咏梅,等. 证据推理的鲁棒性研究[J]. *自动化学报*, 2001, 27(6): 798-805.
- [17] JOUSSELME A L, GRENIER D, BOSSE E. A new distance between two bodies of evidence [J]. *Information Fusion*, 2001, 2(1): 91-101.
- [18] 孙全,叶秀清,顾伟康. 一种新的基于证据理论的合成公式[J]. *电子学报*, 2000, 28(8): 117-119.
- [19] YAGER R. On the Dempster-Shafer framework and new combination rules[J]. *Information Sciences*, 1987, 41(2): 93-137.
- [20] 李弼程,王波,魏俊,等. 一种有效的证据理论合成公式[J]. *数据采集与处理*, 2002, 17(1): 33-36.
- [5] HYVÄRINEN A. Fast and robust fixed-point algorithms for independent component analysis [J]. *IEEE Trans on Neural Networks*, 1999, 10(3): 626-634.
- [6] HYVÄRINEN A, KARHUNEN J, OJA E. Independent component analysis [M]. New York: Wiley, 2001.
- [7] CHEVALIER P, ALBERA L, COMON P, *et al.* Comparative performance analysis of eight blind source separation methods on radio-communications signals [C]//Proc of International Joint Conference on Neural Networks. 2004: 25-31.
- [8] ZARZOSO V, COMON P, KALLEL M. How fast is FastICA? [C]//Proc of EUSIPCO, XIV European Signal Processing Conference. 2006: 48-53.
- [9] ZARZOSO V, COMON P. Comparative speed analysis of FastICA [C]//Proc of the 7th International Conference on Independent Component Analysis and Signal Separation. 2007: 293-300.
- [10] ZARZOSO V, COMON P. Robust independent component analysis for blind source separation and extraction with application in electrocardiography [C]//Proc of the 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 2008: 3344-3347.
- [11] ZARZOSO V, COMON P. Robust independent component analysis by iterative maximization of the kurtosis contrast with algebraic optimal step size [J]. *IEEE Trans on Neural Networks*, 2010, 21(2): 248-261.
- [12] HYVÄRINEN A. Survey on independent component analysis [J]. *Neural Computing Surveys*, 1999, 2: 94-128.
- [13] MESSINAY F, CERNUSCHI-FRÍAS B. Robust parallel FastICA algorithms using batch and adaptive MMSE estimators [C]//Proc of the 13th Argentine Symposium on Technology. 2012: 241-251.
- [14] HYVÄRINEN A. One-unit contrast functions for independent component analysis: a statistical analysis [C]//Proc of IEEE Neural Networks for Signal Processing Workshop. 1997: 388-397.
- [15] BERMEJO S. Finite sample effects of the FastICA algorithm [J]. *Neurocomputing*, 2007, 71(1-3): 392-399.
- [16] ZARZOSO V, COMON P. Robust independent component analysis [EB/OL]. [http://www.i3s.unice.fr/\\_mh/RR/2009/RR-09-02-V.ZARZOSO.pdf](http://www.i3s.unice.fr/_mh/RR/2009/RR-09-02-V.ZARZOSO.pdf).

(上接第 98 页)