

基于步长自适应的独立向量分析卷积盲分离算法

付卫红^{①②} 张琮^{*①}

^①(西安电子科技大学通信工程学院 西安 710071)

^②(西安中电科西电科大雷达技术协同创新研究院有限公司 西安 710075)

摘要: 独立向量分析(IVA)是解决频域卷积盲分离排序模糊性最好的方法之一,但存在迭代次数较多、运算时间较长、分离效果易受分离矩阵初值影响的局限性。该文提出一种基于步长自适应的IVA卷积盲分离算法,该算法使用特征矩阵联合近似对角化(JADE)算法对分离矩阵进行初始化,并对步长参数进行了自适应优化。JADE初始化能够使分离矩阵具有合理的初值,避免局部收敛的情况;步长的自适应优化能够显著提升算法的收敛速度。仿真结果表明,该算法进一步提升了分离性能,并显著缩短了运算时间。

关键词: 盲源分离; 卷积混合; 独立向量分析; 特征矩阵联合近似对角化; 步长自适应

中图分类号: TN911.7

文献标识码: A

文章编号: 1009-5896(2018)09-2158-07

DOI: 10.11999/JEIT171156

Independent Vector Analysis Convolutional Blind Separation Algorithm Based on Step-size Adaptive

FU Weihong^{①②} ZHANG Cong^①

^①(School of Telecommunication Engineering, Xidian University, Xi'an 710071, China)

^②(Collaborative Innovation Center of Information Sensing and Understanding, Xi'an 710075, China)

Abstract: Independent Vector Analysis (IVA) is one of the best methods to solve the sort ambiguity of convolutional blind separation in frequency domain. However, it needs more iterations and computing time, and the separation effect is susceptible to the initial value of the separation matrix. This paper proposes an IVA convolutional blind separation algorithm based on step-size adaptive, which uses Joint Approximative Diagonalization of Eigenmatrices (JADE) algorithm to initialize the separation matrix and optimizes adaptively the step step-size parameters. JADE initialization can make the separation matrix have an appropriate initial value, thus avoiding the situation of local convergence; step-size adaptive optimization can significantly improve the convergence speed of the algorithm. Simulation results show that this algorithm improves the separation performance and shortens the operation time significantly.

Key words: Blind Source Separation (BSS); Convolutional mixture; Independent Vector Analysis (IVA); Joint Approximative Diagonalization of Eigenmatrices (JADE); Step-size adaptive

1 引言

盲源分离(Blind Source Separation, BSS)是指在源信号和信号混合模型未知的情况下,从混合信号中分离出源信号的过程^[1]。在实际信号处理中,由于各种干扰、传输延迟等的影响,传感器采集到的信号往往不是信号的简单线性混合,而是具有卷积的混合形式。因此卷积混合信号的盲

分离,在通信信号处理、语音恢复^[2]、生物医学信号处理^[3]、故障检测^[4]、地震勘探等多个领域都具有重要的应用价值。

目前,解决卷积混合盲分离的方法主要有时域和频域两种形式。时域方法^[5]的思想是在时域计算一个与混合滤波器阶数相当或更大的分离滤波器。由于要用到卷积运算,当滤波器长度较长时,时域方法计算代价较为沉重,分离系统的系数难以收敛。而频域方法^[6]利用短时傅里叶变换将时域卷积混合模型转化为频域瞬时混合模型,并利用较为成熟的独立分量分析(Independent Component Analysis, ICA)算法(如FASTICA^[7], EASI^[8], JADE^[9]算法等)对频域瞬时混合信号进行盲分离,

收稿日期: 2017-12-06; 改回日期: 2018-04-23; 网络出版: 2018-07-12

*通信作者: 张琮 czhang_s@stu.xidian.edu.cn

基金项目: 国家自然科学基金(61201134)

Foundation Item: The National Natural Science Foundation of China (61201134)

因此频域方法是近几年的研究热点。但由于ICA算法存在幅度模糊性和排序模糊性，因此在进行反傅里叶变换之前，必须消除各频率点分离信号的两个模糊性，其中排序模糊性的问题更为突出。

独立向量分析(Independent Vector Analysis, IVA)^[10]是一种扩展的ICA算法，利用多维变量成分中各元素之间的内在关联性有效避免了排序模糊性问题。但是该算法仍存在以下局限性：(1) IVA算法需要对所有频点的分离矩阵进行整体优化，每次迭代的运算量相对较大。由于分离矩阵未针对混合信号作初始化，导致迭代次数较多，运算时间较长。且分离矩阵初值不合理时易陷入局部收敛，影响分离性能；(2) 优化算法主要采用梯度类方法，需要进行步长的选取。步长越小，系统稳定性越好，但是收敛速度越慢；反之，步长越大，收敛速度越快，但是同时也会引起系统的不稳定，影响收敛精度。

针对上述不足，本文提出了基于步长自适应的IVA卷积盲分离算法。该算法选用JADE算法对分离矩阵进行初始化，确保分离矩阵针对混合信号具有合理的初值，能够有效避免算法出现局部收敛的情况；并且该算法对迭代步长参数 η 进行了自适应优化，相较使用固定步长的传统IVA算法能够在显著提升收敛速度的同时保持收敛精度。

2 卷积盲源分离的数学模型

实际环境中由于源信号既存在直达传输路径又存在反射传输路径，每个路径又有各自的传输时间和传输通道，所以第 i 个传感器上接收到的混合信号用数学表达式可以表示为

$$x_i(t) = \sum_{j=1}^n \sum_{p=0}^P h_{ij}(p) \cdot s_j(t-p) = \sum_{j=1}^n h_{ij} * s_j(t), \quad (1)$$

$i = 1, 2, \dots, m$

式中， $s_j(t)$ 表示第 j 个源信号， $x_i(t)$ 表示第 i 个混合信号， $*$ 表示卷积， h_{ij} 表示第 j 个源信号到第 i 个传感器之间的传输函数， P 是传输函数的阶数。即接收到的信号是各个源信号的卷积混合，此时盲源分离问题被称为卷积混合盲源分离。

为了方便起见，把式(1)表示为向量形式可得

$$\mathbf{x}(t) = \sum_{p=0}^P \mathbf{H}(p) \mathbf{s}(t-p) \quad (2)$$

其中，

$$\mathbf{H}(p) = \begin{pmatrix} h_{11,p} & h_{12,p} & \dots & h_{1n,p} \\ h_{21,p} & h_{22,p} & \dots & h_{2n,p} \\ \vdots & \vdots & \ddots & \vdots \\ h_{m1,p} & h_{m2,p} & \dots & h_{mn,p} \end{pmatrix} \quad (3)$$

是指延迟为 p 时的混合滤波器矩阵。

因为反射路径越长信号能量的衰减越大，同时反射物也会吸收信号的一部分能量，因此可以用一个有限冲激响应(FIR)滤波器来近似传输函数 h_{ij} 。卷积混合盲分离目的就是要找到一个 Q 阶的 $n \times m$ 的分离滤波器矩阵 $\mathbf{W}(q)$ ，使得

$$\mathbf{y}(t) = \sum_{q=0}^Q \mathbf{W}(q) \mathbf{x}(t-p) \quad (4)$$

频域方法的思想是：利用短时傅里叶变换(STFT)将时域上的卷积混合过程转换成频域上各个频率点上的瞬时混合过程。短时傅里叶变换的数学表达式为

$$X(\omega, m) = \sum_{n=0}^{L-1} \text{win}(n) x(n+ml) \exp(-j2\pi\omega n/L) \quad (5)$$

其中， n 是信号采样后的时间变量， L 和 l 分别是傅里叶变换的帧数和滑动长度， $\omega = 0, 1, \dots, L-1$ 是频率索引， m 是新生成的时间索引， $\text{win}(n)$ 是窗函数。对式(2)两边进行STFT，可以得到信号卷积混合的时频域形式：

$$\mathbf{X}(\omega, m) = \mathbf{A}(\omega) \mathbf{S}(\omega, m) \quad (6)$$

其中， $\mathbf{S}(\omega, m) = [S_1(\omega, m), S_2(\omega, m), \dots, S_n(\omega, m)]^T$ ， $\mathbf{X}(\omega, m) = [X_1(\omega, m), X_2(\omega, m), \dots, X_n(\omega, m)]^T$ 。如果短时傅里叶帧长 L 远大于混响脉冲响应的长度 P ，那么就可以认为式(2)表示的时域卷积混合的过程在各频率点 ω 上成为式(6)所表示的瞬时混合形式，然后在每个频率点上就可以使用ICA算法分离混合信号。但由于每个频点的分离过程是独立的，因此ICA的排序模糊性会导致各频点分离信号的顺序不一致，从而无法正确还原出时域估计信号。

3 独立向量分析

3.1 IVA算法的模型

IVA的模型由一组标准的频域ICA模型组成。2.2节中提到了频域ICA算法是在单个频率点上对混合信号进行分离，而ICA模型中不同频率点上的源信号分量是存在内在联系的。IVA算法利用这一点将这些存在联系的单变量成分归结为一个多维变量或向量。因此IVA算法的分离过程是在所有频点上整体分离出独立的频域成分，这一频域成分是整个频域源信号的一个估计，该成分中各元素是同一个时域源信号在各个频率点上对应的频域分量。

图1所示的是一个 2×2 维的IVA算法混合模型。从图示混合模型可见，IVA模型中的每一层对应着一个瞬时混合过程，即式(6)所表示的单频




图1 IVA算法混合模型

点混合模型(为了推导和书写方便省略时间索引 m)。因此IVA的混合模型满足卷积混合信号的盲分离在频域上的混合模型。由于IVA算法将多维变量作为一个整体来分离,理论上分离后自然不会出现排序模糊性问题。

3.2 目标函数及其优化

与传统ICA算法一致,IVA算法需要根据独立性准则得到目标函数,然后优化目标函数得到分离矩阵 $\mathbf{W}(\omega)$ 的迭代公式。根据最大化输出信号之间的独立性这一思路,使用互信息最小化(MMI)^[11]作为独立性准则。文献[10]中定义两个函数之间的KL散度为独立性判据,如式(7)所示。

$$\begin{aligned} \Phi(\mathbf{Y}) &= \text{KL} \left(p(\mathbf{Y}), \prod_{i=1}^N q(\mathbf{Y}_i) \right) \\ &= \int p(\mathbf{Y}) \ln \frac{p(\mathbf{Y})}{\prod_{i=1}^N q(\mathbf{Y}_i)} d\mathbf{Y} \\ &= \int p(\mathbf{Y}) \ln p(\mathbf{Y}) d\mathbf{Y} \\ &\quad - \sum_{i=1}^N \int p(\mathbf{Y}) \ln q(\mathbf{Y}_i) d\mathbf{Y} \end{aligned} \quad (7)$$

其中, $\mathbf{Y}_i = [Y_i(\omega_1), Y_i(\omega_2), \dots, Y_i(\omega_L)]^T$; 这里的 $p(\mathbf{Y}) = p(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_i, \dots, \mathbf{Y}_N)$ 表示信号的联合概率密度函数; $\prod_{i=1}^N q(\mathbf{Y}_i)$ 是每个源信号概率密度函数的乘积。

一方面,将式(7)等号右边第1项用微分熵 $H(\cdot)$ 表示可得

$$\Phi(\mathbf{Y}) = -H(\mathbf{Y}) - \sum_{i=1}^N \int p(\mathbf{Y}) \ln q(\mathbf{Y}_i) d\mathbf{Y} \quad (8)$$

又因为 $\mathbf{Y}(\omega) = \mathbf{W}(\omega) \mathbf{X}(\omega)$, 则微分熵可以表示为

$$H(\mathbf{Y}) = H(\mathbf{X}) + \sum_{\omega} \ln |\det(\mathbf{W}(\omega))| \quad (9)$$

由于信号经过去均值和白化,因此式(9)中 $H(\mathbf{X})$ 必然是一个常量。

另一方面,对于式(7)等号右边第2项,有

$$\begin{aligned} \int p(\mathbf{Y}) \ln q(\mathbf{Y}_i) d\mathbf{Y} &= \int \ln q(\mathbf{Y}_i) \int p(\mathbf{Y}) d\tilde{\mathbf{Y}}^i d\mathbf{Y}_i \\ &= \int p(\mathbf{Y}_i) \ln q(\mathbf{Y}_i) d\mathbf{Y}_i \\ &= E(\ln q(\mathbf{Y}_i)) \end{aligned} \quad (10)$$

其中, $\tilde{\mathbf{Y}}^i$ 表示 \mathbf{Y} 中除去 \mathbf{Y}_i 后的向量组。

因此,目标函数可写为

$$\begin{aligned} \Phi(\mathbf{W}, \mathbf{Y}) &= - \sum_{\omega} \ln |\det(\mathbf{W}(\omega))| \\ &\quad - \sum_{i=1}^N E \ln q(\mathbf{Y}_i) \end{aligned} \quad (11)$$

其中,概率密度函数 $q(\mathbf{Y}_i)$ 应针对源信号类型而选取,文献[10]中将其设为

$$q(\mathbf{Y}_i) = \exp(-\|\mathbf{Y}_i\|_2) \quad (12)$$

由此得到目标函数最终形式:

$$\begin{aligned} \Phi(\mathbf{W}) &= - \sum_{\omega} \ln |\det(\mathbf{W}(\omega))| \\ &\quad + \sum_i E \left[G \left(\sum_{\omega} |\mathbf{Y}_i(\omega)|^2 \right) \right] \end{aligned} \quad (13)$$

其中, $G(z) = \sqrt{z}$, 是 $-\ln q(\mathbf{Y}_i)$ 对应的非线性函数。

使用自然梯度法优化目标函数^[12]得到最终的迭代方程为

$$\begin{aligned} \mathbf{w}_{i,k+1}(\omega) &= \mathbf{w}_{i,k}(\omega) + \eta_k \\ &\quad \cdot \left[\mathbf{I} - G' \left(\sum_{\omega} |\mathbf{Y}_{i,k}(\omega)|^2 \right) \mathbf{Y}_{i,k}^T(\omega) \right] \\ &\quad \cdot \mathbf{w}_{i,k}(\omega) \end{aligned} \quad (14)$$

其中, $\mathbf{w}_{i,k}(\omega)$ 是分离矩阵 $\mathbf{W}(\omega)$ 的第 i 行, k 指迭代次数, $G'(\cdot)$ 是 $G(\cdot)$ 的1阶导数, η_k 是步长参数。

可以看到,虽然IVA求解分离矩阵仍然是分别在每个频率点上求出,但是其推导过程是在所有频点上进行的,这是与传统频域ICA算法主要的不同。

4 基于步长自适应的IVA算法

4.1 基于JADE的分离矩阵初始化

在频域盲源分离中, JADE算法性能稳健高效,并且能够分离复数域的线性混合信号,所以被广泛应用。JADE算法步骤^[9]如下:

假设源信号 $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T$ 之间满足相互独立,且其中最多有一个为高斯信号。

(1) 应用预白化或正交化^[13]方法得到 N 个白化的矢量 $\mathbf{z}(t) = \mathbf{V}\mathbf{x}(t)$;

(2) 构造 $N(N+1)/2$ 个特征矩阵:

$$\mathbf{M}_{pq} = \begin{cases} \mathbf{e}_p \mathbf{e}_q^T, & p = q \\ (\mathbf{e}_p \mathbf{e}_q^T + \mathbf{e}_q \mathbf{e}_p^T) / \sqrt{2}, & p < q \\ (\mathbf{e}_p \mathbf{e}_q^T - \mathbf{e}_q \mathbf{e}_p^T) / \sqrt{2}, & p > q \end{cases} \quad (15)$$

其中, \mathbf{e}_p 代表 N 维矢量, 它的第 p 个位置为1, 其它位置为0。

(3) 计算 $N(N+1)/2$ 个样本4阶协方差矩阵 $\mathbf{F}(\mathbf{M}_{pq})$:

$$\mathbf{F}(\mathbf{M}_{pq}) = E \left\{ \left(\mathbf{z}^T(t) \mathbf{M}_{pq} \mathbf{z}(t) \right) \mathbf{z}(t) \mathbf{z}^T(t) \right. \\ \left. - 2\mathbf{M}_{pq} - \text{trace}(\mathbf{M}_{pq}) \mathbf{I} \right\} \quad (16)$$

其中, $\text{trace}(\cdot)$ 表示求矩阵的迹。

(4) 利用联合近似对角化数值方法为所有的 $N(N+1)/2$ 个矩阵 $\{\mathbf{F}(\mathbf{M}_{pq})\}$ 找到一个正交的联合对角化的正交矩阵 \mathbf{U} ;

(5) 估计混合矩阵为: $\mathbf{W} = \mathbf{V}^+ \mathbf{U}$ 。

使用JADE算法可以快速得到单个频点上的分离矩阵 $\mathbf{W}_{\text{JADE}}(\omega)$, 但其具有幅度模糊性和排序模糊性。其中, 幅度模糊性可利用以最小畸变准则^[14]为依据的幅度算法解决。排序模糊性的消除则比较困难。

传统IVA算法中, 分离矩阵的初值为单位矩阵。本文利用JADE算法对所有频点的分离矩阵进行初始化:

$$\mathbf{W}_0(\omega) = \mathbf{W}_{\text{JADE}}(\omega) \quad (17)$$

该方法有两个优点: (1) 原算法分离矩阵初值为单位矩阵, 未针对混合信号进行优化, 导致迭代次数较多, 运算时间较长。用JADE算法产生的分离矩阵初值更接近最终结果, 可以减少迭代次数, 缩短运行时间。(2) 当混合阶数较大时, IVA算法由于需要对所有频点的分离矩阵进行迭代, 求解情况较为复杂, 以单位矩阵作为初值往往是不合理的, 容易使结果陷入局部收敛。针对混合信号使用JADE算法初始化后, 分离矩阵初值更为合理, 能避免局部收敛, 得到全局最优值。

4.2 自适应步长优化

在IVA算法中步长参数 η 的作用就是在每一步迭代过程中, 控制分离矩阵 \mathbf{W} 各元素更新的幅度。步长参数的合理选择对算法的性能至关重要, 一般采用固定步长的盲分离算法会限制收敛速度或者导致分离算法较差的稳定性。

为了加速收敛并且保持较低的稳态误差, 本文通过步长最优化的思想^[15]提出一种步长迭代算法。

设第 $k+1$ 次迭代时的步长为

$$\eta_{k+1} = \eta_k + \gamma \times \Delta\eta_k \quad (18)$$

其中, γ 是一个足够小的常数, $\Delta\eta_k$ 是步长 η_k 的偏

移量。该偏移量的选取应该使得步长 η_{k+1} 接近最优, 即使得在下一次迭代时的目标函数 Φ 最小, 故

$$\Delta\eta_k = \frac{\partial\Phi_{k+1}}{\partial\eta_k} \quad (19)$$

对于每个频点上的步长, 有

$$\Delta\eta_{k,\omega} = \frac{\partial\Phi(\mathbf{W}_{k+1}(\omega))}{\partial\eta_k} \\ = \left\langle \frac{\partial\Phi(\mathbf{W}_{k+1}(\omega))}{\partial\mathbf{W}_{k+1}(\omega)} \cdot \frac{\partial\mathbf{W}_{k+1}(\omega)}{\partial\eta_k} \right\rangle \\ = \text{trace} \left\{ \left[\frac{\partial\Phi(\mathbf{W}_{k+1}(\omega))}{\partial\mathbf{W}_{k+1}(\omega)} \right]^T \cdot \frac{\partial\mathbf{W}_{k+1}(\omega)}{\partial\eta_k} \right\} \quad (20)$$

其中, $\langle \cdot \rangle$ 表示矩阵的内积, $\text{trace}(\cdot)$ 表示求矩阵的迹。

一方面, 根据分离矩阵更新式(14), 可以得到

$$\frac{\partial\mathbf{W}_{k+1}(\omega)}{\partial\eta_k} = [\mathbf{I} - f(\mathbf{Y}_k) \cdot \mathbf{Y}_k^T(\omega)] \mathbf{W}_k(\omega) \\ \triangleq \Delta\mathbf{W}_k(\omega) \quad (21)$$

其中, 非线性函数 $f(\mathbf{Y}_k) = G' \left(\sum_{\omega} |\mathbf{Y}_k(\omega)|^2 \right)$ 。

另一方面, $\Phi(\mathbf{W})$ 是基于自然梯度的目标函数瞬时估计, 因此可得

$$\frac{\partial\Phi(\mathbf{W}_{k+1}(\omega))}{\partial\mathbf{W}_{k+1}(\omega)} = [\mathbf{I} - f(\mathbf{Y}_{k+1}) \cdot \mathbf{Y}_{k+1}^T(\omega)] \\ \cdot \mathbf{W}_{k+1}(\omega) \triangleq \mathbf{W}_{k+1}(\omega) \quad (22)$$

将式(21), 式(22)代入(20)得到

$$\Delta\eta_{k,\omega} = \text{trace}(\Delta\mathbf{W}_{k+1}^T(\omega) \cdot \Delta\mathbf{W}_k(\omega)) \quad (23)$$

最后将所有频点的更新迭代步长统一, 有

$$\Delta\eta_k = \frac{1}{N} \sum_{\omega=1}^N \Delta\eta_{k,\omega} \quad (24)$$

因此, 得到最终的步长更新公式为

$$\eta_{k+1} = \eta_k + \gamma \cdot \frac{1}{N} \sum_{\omega=1}^N \text{trace}(\Delta\mathbf{W}_{k+1}^T(\omega) \cdot \Delta\mathbf{W}_k(\omega)) \quad (25)$$

为了防止 η 过大或者变负, 应该设置一个上限以及一个小的正下限。

4.3 算法的步骤

综上所述, 基于步长自适应的IVA卷积盲分离算法具体实现步骤示于表1。

在之后的仿真中, 本文算法将简称为JS-IVA算法(JADE initialization & Step-size adaptive IVA)。

表 1 基于步长自适应的IVA卷积盲分离算法

步骤1	将时域卷积混合信号经STFT转换为各个频率点的线性瞬时混合复值信号;
步骤2	对各频率点的混合信号进行中心化和白化预处理;
步骤3	使用JADE算法初始化各频点的分离矩阵 $\mathbf{W}_0(\omega)$, 并初始化迭代步长 η_0 ;
步骤4	根据 $\mathbf{Y}(\omega) = \mathbf{W}(\omega) \mathbf{X}(\omega)$ 来估计各频点的源信号;
步骤5	根据估计出的源信号来计算目标函数和非线性函数, 并判断分离矩阵是否收敛。若收敛, 执行步骤9;
步骤6	根据式(14)来更新各频点分离矩阵;
步骤7	根据式(25)来更新迭代步长;
步骤8	若达到最大迭代次数, 输出最终各频点分离信号, 否则返回步骤4;
步骤9	将各频点分离信号经ISTFT恢复成时域分离信号, 即源信号估计。

5 仿真实验与分析

为了验证本文方法的有效性, 下面通过仿真实验对改进前后的方法进行对比。本文的实验采用来自NTT通信科学实验室Hiroshi Sawada的主页所提供的2路语音信号作为源信号。性能指标方面, 本

文采用评价盲源分离算法性能的工具箱BSS_EVAL^[16]中的信干比SIR来评估混合信号分离的效果, 其定义为

$$\text{SIR} = 10 \lg \frac{\|s_{\text{tg}}(n)\|^2}{\|c_{\text{t}}(n)\|^2} \quad (26)$$

其中, $s_{\text{tg}}(n)$ 为目标信号(即要估计的源信号), $c_{\text{t}}(n)$ 为干扰信号(即其它源信号的干扰)。

5.1 定性测试

为了验证JADE初始化对于收敛精度的改善以及自适应步长对于收敛速度的提升, 本节进行了2组仿真测试。图2给出了用两种初始化方法进行200次卷积盲分离实验的性能对比图; 图3给出了固定步长与本文自适应步长的收敛曲线。

图2(a)是200次仿真结果的原始数据。为了方便对比, 图2(b)是将数据按JADE初始化方法的分离性能排序后画出的对比图。由图2可以看出, 在200次实验中, 有大约30~40次实验出现了单位矩阵初始化的分离性能远低于JADE初始化的情况。

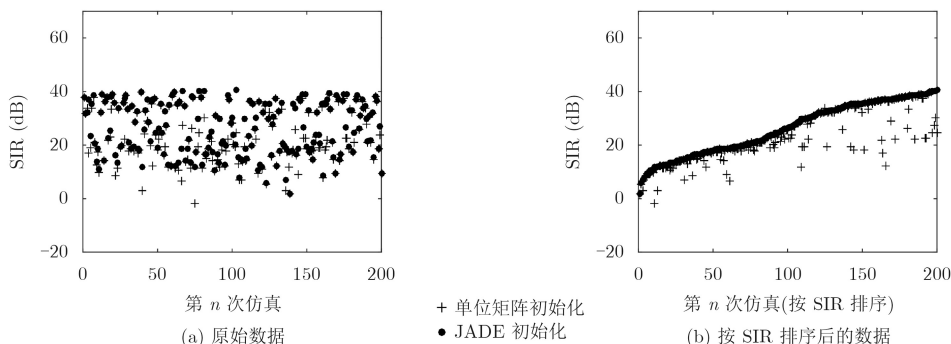


图 2 200次仿真性能对比图

可见在这些情况下, 由于初值不合理导致IVA算法陷入局部收敛从而影响了分离性能。而本文所提的JADE初始化方法改善了这一问题, 提高了IVA算法的收敛精度。

由图3可知, 本文提出的自适应步长优化使IVA算法的收敛速度显著提升, 并且在稳定时的性

能没有因为收敛速度的加快而恶化, 说明本文算法在提升收敛速度的同时保持收敛精度不变。

5.2 定量测试

本节中进行3组实验, 分别为5阶滤波器卷积混合、20阶滤波器卷积混合以及模拟室内情况卷积混合。其中模拟室内混合的条件为4 m×4 m×4 m的房间, 产生的混合滤波器阶数约为400左右^[17]。

在混合信号中加入不同信噪比的高斯白噪声进行测试。两种算法参数设置如下:

IVA算法: 固定步长参数 $\eta=0.1$, 分离矩阵初值为单位阵。

JS-IVA算法: 初始步长参数 $\eta=0.1$, 步长更新参数 $\gamma=0.001$, JADE算法产生各频点分离矩阵初值。

仿真实验中, 5阶和20阶情况下的仿真次数为100次, 每次仿真的滤波器系数均为随机生成; 模拟室内情况下的仿真次数为30次。




图 3 收敛曲线对比图

分离信号的平均SIR如图4所示。

由图4可以看出，在卷积混合阶数较低的5阶和20阶情况下，本文算法的SIR相较原算法有1~

2 dB的提升；而在模拟室内混合的情况下，混合阶数超过400阶，此时本文算法分离性能提升较为明显，SIR提高了2~4 dB。




图4 分离性能对比图

下面是改进算法的复杂度分析。

对于IVA算法，其运行时间主要消耗在迭代运算上。而每次迭代中，计算目标函数的部分由于要对每个频点上的信号进行矩阵运算，会占用大部分时间。

本文改进的算法在迭代开始前增加了JADE算法，在每次迭代时增加了更新步长的运算，会增加初始化和单次迭代的运算量。但改进后的算法会使迭代次数大大减少，因此，算法的运行时间会有明显缩短。

表2列出了仿真实验运行的总时间对比。由表2可看出，本文算法相比传统IVA算法运算效率提升了48.4%。

表2 仿真运行时间

算法	运行次数	运行总时间(s)
IVA	1840	23803.8
JS-IVA	1840	12283.4

为了便于进一步对比，表3给出了仿真实验过程中，在不同情况下算法进行单次迭代的平均时间对比；表4给出了相同情况下，进行盲分离运算的平均迭代次数和运行时间。

由表3、表4可以看出，本文算法由于增加了更新步长的运算，所以单次迭代的平均时间要略高于传统IVA算法的单次迭代时间。但是由于所提算法

表3 算法单次迭代时间对比(ms)

算法	5阶混合	20阶混合	模拟室内混合
IVA	27.81	34.73	51.18
JS-IVA	28.70	38.31	63.10

表4 算法迭代次数和运行时间对比(次数/s)

算法	5阶混合	20阶混合	模拟室内混合
IVA	114/3.17	167/5.80	658/33.68
JS-IVA	62/1.78	89/3.41	174/10.98

增加了JADE初始化以及步长自适应的优化，迭代次数相对传统IVA算法大大降低，因此总体来说本文所提算法的运行效率相较原算法有明显提升。在5阶和20阶情况下，本文算法相较原来的算法迭代次数减少了45%以上，运行时间缩短了40%以上；在较复杂的模拟室内混合情况下，迭代次数减少了73%以上，运行时间缩短了65%以上。

6 结束语

本文从改进算法的分离性能与缩短运算时间的角度出发，提出了基于步长自适应的IVA卷积盲分离算法。该算法在初始化过程中使用JADE算法对分离矩阵进行初始化，确保分离矩阵针对混合信号具有合理的初值，有效避免了算法局部收敛的情况，提升了分离性能；在迭代过程中对该算法的步长参数 η 进行了自适应优化，在显著提升收敛速度的同时保持系统稳定。本文针对不同情况下的卷积混合信号进行了仿真实验，并对分离性能和算法复杂度进行了分析。实验结果表明，在本文所设置的仿真条件下，本文算法使分离性能提升了1~4 dB，并且使运算时间缩短了40%~65%。

参考文献

[1] BELAID S, HATTAY J, NAANAA W, *et al.* A new multi-scale framework for convolutive blind source separation[J]. *Signal Image & Video Processing*, 2016, 10(7): 1–8. doi: 10.1007/s11760-016-0877-6.

- [2] ZOULIKHA M and DJENDI M. A new regularized forward blind source separation algorithm for automatic speech quality enhancement[J]. *Applied Acoustics*, 2016, 112: 192–200. doi: [10.1016/j.apacoust.2016.05.012](https://doi.org/10.1016/j.apacoust.2016.05.012).
- [3] NEGRO F, MUCELI S, CASTRONOVO A M, *et al*. Multi-channel intramuscular and surface EMG decomposition by convolutive blind source separation[J]. *Journal of Neural Engineering*, 2016, 13(2): 026027. doi: [10.1088/1741-2560/13/2/026027](https://doi.org/10.1088/1741-2560/13/2/026027).
- [4] HAILE M A and DYKAS B. Blind source separation for vibration-based diagnostics of rotorcraft bearings[J]. *Journal of Vibration & Control*, 2016, 22(18): 3807–3820. doi: [10.1177/1077546314566041](https://doi.org/10.1177/1077546314566041).
- [5] CHERRAK O, GHENNIQUI H, THIRION-MOREAU N, *et al*. Preconditioned optimization algorithms solving the problem of the non unitary joint block diagonalization: Application to blind separation of convolutive mixtures[J]. *Multidimensional Systems & Signal Processing*, 2017(1): 1–24. doi: [10.1007/s11045-017-0506-8](https://doi.org/10.1007/s11045-017-0506-8).
- [6] 贾志成, 韩大伟, 陈雷, 等. 基于复Givens矩阵与蝙蝠优化的卷积盲分离算法[J]. *通信学报*, 2016, 37(7): 107–117. doi: [10.11959/j.issn.1000-436x.2016138](https://doi.org/10.11959/j.issn.1000-436x.2016138).
JIA Zhicheng, HAN Dawei, CHEN Lei, *et al*. Convolutive blind separation algorithm based on complex Givens matrix and bat optimization[J]. *Journal of Communications*, 2016, 37(7): 107–117. doi: [10.11959/j.issn.1000-436x.2016138](https://doi.org/10.11959/j.issn.1000-436x.2016138).
- [7] BINGHAM E and HYVARINEN A. A fast fixed-point algorithm for independent component analysis of complex valued signals[J]. *International Journal of Neural Systems*, 2000, 10(1): 1–8. doi: [10.1142/S0129065700000028](https://doi.org/10.1142/S0129065700000028).
- [8] CARDOSO J F. Equivariant adaptive source separation[J]. *IEEE Transactions on Signal Processing*, 1996, 44(12): 3017–3029. doi: [10.1109/78.553476](https://doi.org/10.1109/78.553476).
- [9] CARDOSO J F. High order contrast for independent component analysis[J]. *Neural Computation*, 1999, 11(1): 157–193. doi: [10.1162/089976699300016863](https://doi.org/10.1162/089976699300016863).
- [10] KIM T, ATTIAS H T, LEE S Y, *et al*. Blind source separation exploiting higher-order frequency dependencies[J]. *IEEE Transactions on Audio Speech & Language Processing*, 2006, 15(1): 70–79.
- [11] 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: 20–23.
- YANG Fusheng and HONG Bo. The Principle and Application of Independent Component Analysis[M]. Beijing: Tsinghua University Press, 2006: 20–23.
- [12] 孙守宇, 郑君里, 吴德伟. 基于自然梯度算法的盲信源分离研究[J]. *空军工程大学学报(自然科学版)*, 2003, 4(3): 50–54. doi: [10.3969/j.issn.1009-3516.2003.03.013](https://doi.org/10.3969/j.issn.1009-3516.2003.03.013).
SUN Shouyu, ZHENG Junli, and WU Dewei. Research on blind source separation based on natural gradient algorithm[J]. *Journal of Air Force Engineering University (Natural Science Edition)*, 2003, 4(3): 50–54. doi: [10.3969/j.issn.1009-3516.2003.03.013](https://doi.org/10.3969/j.issn.1009-3516.2003.03.013).
- [13] ERIKSSON J and KOIVUNEN V. Complex random vectors and ICA models: Identifiability, uniqueness, and separability[J]. *IEEE Transactions on Information Theory*, 2006, 52(3): 1017–1029. doi: [10.1109/TIT.2005.864440](https://doi.org/10.1109/TIT.2005.864440).
- [14] MATSUOKA K. Minimal distortion principle for blind source separation[C]. Proceedings of the 41th SICE Annual Conference, Kitakyushu, Japan, 2002, 4: 2138–2143. doi: [10.1109/SICE.2002.1195729](https://doi.org/10.1109/SICE.2002.1195729).
- [15] 付卫红, 杨小牛, 刘乃安, 等. 基于步长最优化的EASI盲源分离算法[J]. *四川大学学报(工程科学版)*, 2008, 40(1): 118–121. doi: [10.15961/j.jsuese.2008.01.023](https://doi.org/10.15961/j.jsuese.2008.01.023).
FU Weihong, YANG Xiaoniu, LIU Naian, *et al*. Step-size optimization based EASI algorithm for blind source separation[J]. *Journal of Sichuan University (Engineering Science)*, 2008, 40(1): 118–121. doi: [10.15961/j.jsuese.2008.01.023](https://doi.org/10.15961/j.jsuese.2008.01.023).
- [16] VINCENT E, GRIBONVAL R, and FEVOTTE C. Performance measurement in blind audio source separation[J]. *IEEE Transactions on Audio, Speech, and Language Processing*, 2006, 14(4): 1462–1469. doi: [10.1109/TSA.2005.858005](https://doi.org/10.1109/TSA.2005.858005).
- [17] PHAM D T, SERVIERE C, and BOUMARAF H. Blind separation of speech mixtures based on nonstationarity[C]. International Symposium on Signal Processing and ITS Applications, Grenoble Cedex, France, 2003, 2: 73–76. doi: [10.1109/ISSPA.2003.1224818](https://doi.org/10.1109/ISSPA.2003.1224818).
- 付卫红: 女, 1979年生, 副教授, 研究方向为宽带无线通信、通信信号处理。
张 琮: 男, 1994年生, 硕士生, 研究方向为卷积盲源分离。