

一种改进的快速独立分量分析算法及其在图象分离中的应用

曾生根 朱宁波 包 晔 夏德深

(南京理工大学计算机系 603 教研室, 南京 210094)

摘 要 独立分量分析是信号处理技术的新发展,它作为盲信号分离的一种有效的方法而受到广泛的关注,并在许多方面获得成功应用.讨论了独立分量分析的基本原理、判断条件和算法,并在此基础上,介绍了独立分量分析的一种快速算法——FastICA 算法;对 FastICA 算法的核心迭代过程进行改进,得到 M-FastICA 算法,改进算法减少了独立分量分析的迭代次数,从而提高了算法的收敛速度.最后将 M-FastICA 算法应用到图象的分离上,实验结果表明,改进算法在分离效果相当的前提下,串行算法迭代次数减少了 9%,并行算法迭代次数减少了 27%,收敛速度更快.

关键词 计算机图象处理(520·6040) 独立分量分析 固定点算法 FastICA M-FastICA 图象分离
中图法分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2003)10-1159-07

A Modified Fast Independent Component Analysis and Its Application to Image Separation

ZENG Sheng-gen, ZHU Ning-bo, BAO Ye, XIA De-shen

(603 Lab Computer Department of Nanjing University of Science and Technology, Nanjing 210094)

Abstract Independent Component Analysis (ICA) is a new development of signal processing. As an effective approach to the separation of blind signal, Independent Component Analysis has attracted broad attention and has been successfully used in many fields. The fundamental, discrimination condition and practical algorithm of Independent Component Analysis are discussed. Then, a fast Independent Component Analysis algorithm (FastICA) is introduced, and it is known that the time-consuming course is computing Jacobian Matrix. Reducing the time of Jacobian Matrix will improve the performance of FastICA algorithm. So a modified FastICA (M-FastICA) algorithm is developed. By modifying kernel iterate course, several iterations of FastICA are merged into one iteration of M-FastICA, then M-FastICA algorithm only need to compute Jacobian Matrix once time and achieves the correspondent effect of FastICA. So the convergence of ICA will be accelerated. Finally, M-FastICA is applied to image separation. The experiment images are mixed with a random matrix. Independent Component Analysis can separate the mixed images and obtain the approximate of source images. The experiment results show that the iterations of serial modified algorithm reduces 9 percent, and the iterations of parallel modified algorithm reduces 27 percent with the correspondent separation performance.

Keywords Computer image processing, Independent component analysis, Fixed-point, FastICA, M-FastICA, Image separation

0 引 言

独立分量分析 (Independent Component Analysis, ICA) 是近年来发展起来的一种新的盲信号

分离 (Blind Source Separation, BSS) 技术方法. 盲信号分离是指在源信号和信号混合模型未知的情况下, 从混合信号即观测信号中分离源信号的过程. 独立分量分析的基本含义是将多道观测信号按照统计独立的原则通过优化算法分解为若干独立分量, 而这些独立

基金项目: 南京市科委基金项目 (99311)

收稿日期: 2003-01-02; 改回日期: 2003-05-27

分量是源信号的一种近似估计. 独立分量分析的前提条件为源信号是相互独立的, 且不是高斯信号.

与主成份分析(Principal Component Analysis, PCA)相比, ICA 不仅实现了 PCA 的去相关特性, 而且得到的高阶统计量是独立的; ICA 的目标是寻找一个线性但不一定正交的坐标系来表示多维数据, 而 PCA 表示数据的坐标系是正交的; ICA 处理的信号为非高斯信号, 而 PCA 一般认为信号是高斯分布的; ICA 的计算复杂度比 PCA 要高. 在许多实际应用中, 源信号大多是非高斯的, 而且其相互关系也是非正交的, 因而 ICA 较 PCA 更接近实际情况, 有着更大的应用潜力.

Herault 首次提出独立分量分析的概念^[1], 其主要思想是: 通过独立分量分析, 从一组观察信号 $x = \{x_1, x_2, \dots, x_m\}$ 中得出统计独立的信源 $s = \{s_1, s_2, \dots, s_n\}$ 的估计值 $y = \{y_1, y_2, \dots, y_n\}$, y 也是统计独立的. Comon 系统阐述了 ICA 的概念, 并提出了基于高阶累积量构造算法的代价函数, 得出一种自适应求分离矩阵的方法, 使得在线进行盲信号分离成为可能^[2]. Bell 和 Sejnowski 提出了信息最大化(Infomax)方法, 认为神经网络输出信号差熵的最大化即意味着输入与输出之间的交互信息的最大化, 并且利用随机梯度下降的学习方法实现了差熵的最大化^[3]. Lee 等对最大熵独立分量分析算法进行了扩展, 提出可以通过估计信号的峰度(kurtosis)来区别超高斯和亚高斯信号, 突破了算法不能同时用于超高斯和亚高斯信号分离的局限^[4]. Karhunen 等对独立分量分析的固定点算法(fixed-point)进行了大量的研究, 提出每次从信号中抽取出一个独立分量的方法, 得出 ICA 的一种快速算法^[5~7].

目前 ICA 主要应用于语音信号分离^[8]、生物医学信号处理^[9]、金融数据分析^[10]、人脸识别^[11]、通信信号处理^[12]、图象分离^[13]等多个领域.

1 独立分量分析

假定第 i 个观测信号是由 n 个独立分量线性混合而成

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n \quad i=1, 2, \dots, m \quad (1)$$

假定每个观测变量 x_i 和源变量 s_j 都是随机变量. 不失一般性, 假定观测变量和源变量都为零均值变量, 如果不是, 可以通过减去样本的均值而获得. 用矢量 x 表示观测变量 $\{x_1, x_2, \dots, x_m\}^T$, 矢量 s 表

示源变量 $\{s_1, s_2, \dots, s_n\}^T (m \geq n)$, $A (m \times n)$ 表示混合矩阵 a_{ij} , 式(1)可用矢量-矩阵形式表示

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

也可以写成

$$x_i = \sum_{j=1}^n a_{ij}s_j \quad (3)$$

统计模型式(2)称为独立分量分析(ICA)模型. 该模型描述了观测数据是如何由信源 s 混合生成的. 源变量 s 是隐藏变量, 不能直接观测到, 而且混合矩阵 A 也是未知的. 所有能观测到的数据是随机变量 x , 所以必须估计出混合矩阵 A 和 s .

独立分量分析的起始点基于一个非常简单的假设, 即源变量 s 是统计独立的, 同时假定源变量为非高斯分布, 显然, 在基本模型中分布是未知的(如果分布已知, 问题就相当简单). 在估计出混合矩阵 A 后, 需要计算混合矩阵 A 的逆, 也即分离矩阵 $W = A^{-1}$, 从而得到独立分量 s 的估计 y

$$y = Wx \quad (4)$$

独立分量分析包括预处理和估算分离矩阵 W 两部分.

1.1 ICA 预处理

ICA 预处理包括去均值和白化两个部分. 对观测信号去均值是 ICA 算法最基本和最必须的预处理步骤, 其处理过程是从观测信号中减去信号的均值向量 $m = E\{x\}$, 使得观测信号成为零均值变量. 这意味着 ICA 得到的源信号 s 的估计 y 也是零均值的. 该预处理只是为了简化 ICA 算法, 并不意味着均值不能估计出来. 用去均值数据估计分离矩阵 W 后, 可以在源信号的估计 y 上加上均值, 此时所加的均值矢量为 $A^{-1}m$, m 为在预处理过程中所减去的均值.

ICA 另外一个预处理步骤是对观测信号进行白化处理. 在 ICA 算法实际计算之前, 对观测信号进行白化处理, 使得白化后的分量 \tilde{x} 为非相关的, 且为单位方差, 即满足

$$E\{\tilde{x}\tilde{x}^T\} = I \quad (5)$$

标准 PCA 常用来做白化处理. 下式给出了 PCA 的白化算法

$$\tilde{x} = VD^{-1/2}V^T x \quad (6)$$

其中, $D^{-1/2} = \text{diag}[d_1^{-1/2}, \dots, d_n^{-1/2}]$ 是 $n \times n$ 的对角矩阵, $V = [c_1, \dots, c_n]$ 是 $m \times n$ 的矩阵, d_i 为观测信号的协方差矩阵 $E\{xx^T\}$ 的第 i 个特征值, c_i 为对应的特征向量.

很容易验证 $E\{\tilde{x}\tilde{x}^T\} = I$. 由式(2)和式(6)可得

$$\tilde{x} = VD^{-1/2}V^TAs = \tilde{A}S \quad (7)$$

$$E\{\tilde{x}\tilde{x}^T\} = \tilde{A}E\{ss^T\}A^T = \tilde{A}\tilde{A}^T = I \quad (8)$$

一般而言,ICA 算法使用白化处理后收敛更快,能获得更好的稳定性.但是当混合矩阵 A 为病态矩阵或者某些源信号比其他源信号强度弱很多时,白化可能使 ICA 很难甚至不可能实现分离.

1.2 独立性度量标准

由概率理论的中心限制理论可知,一般情况下,独立随机变量的总和的分布较单个独立分量更趋向于高斯分布.两个独立随机变量的和比其中任何一个分量更趋近高斯分布.因此,判断分量之间是否独立的问题就可以转化成计算分量的非高斯性最大的问题.混合矩阵 A 的估计也就变成不断改进分离矩阵 W .使 $W^T x$ 的非高斯性最大.

非高斯性的度量标准有很多,最常见的有以下几种(所有 y 都假定具有零均值和单位方差):

(1) 峰度(kurtosis)

峰度是一种经典的非高斯性的度量方法. y 的峰度定义为

$$kurt(y) = E\{y^4\} - 3(E\{y^2\})^2 = E\{y^4\} - 3 \quad (9)$$

由于假定了 y 具有单位方差, $E\{y^2\} = 1$, $kurt(y)$ 有式(9)的简化形式.如果 y 是高斯信号,其峰度值为 0.对大多数(不是所有的)非高斯随机变量,其峰度值非 0;对于亚高斯信号,其峰度值小于 0;而对于超高斯信号,峰度值大于 0.

(2) 负熵(negentropy)

离散随机变量 y 的熵 H 定义为

$$H(y) = - \sum_i p(y_i) \lg(p(y_i)) \quad (10)$$

其中, $p(y)$ 为 y 的概率.

而负熵 J 定义为

$$N(y) = H(y_{\text{gauss}}) - H(y) \quad (11)$$

其中, y_{gauss} 为具有和 y 相同方差的高斯变量.由于信息理论有一个基本结论,即高斯变量在所有相同方差的随机变量中具有最大的熵,因此, $N(y)$ 值非负,当 y 为高斯信号时,其值为 0.最大化 $N(y)$ 即最大化非高斯性.由于 $N(y)$ 难以直接计算,实际中使用其近似计算,如使用高阶矩

$$N(y) \approx \frac{1}{12}(E\{y^3\})^2 + \frac{1}{48}(kurt(y))^2 \quad (12)$$

但是式(12)中负熵的近似是受限制的.式(12)由于应用了峰度而导致估计的非鲁棒性.为了避免该问题,使用基于最大熵原理的负熵近似

$$N(y) \approx \sum_{i=1}^n k_i [E\{G_i(y)\} - E\{G_i(v)\}]^2 \quad (13)$$

其中, k_i 为一正的常量, v 为零均值和单位方差的高斯变量.函数 G_i 为非二次函数,但式(13)的近似仍然不精确.因此使用只有一个非二次方程式 G 的负熵近似

$$N(y) \propto [E\{G(y)\} - E\{G(v)\}]^2 \quad (14)$$

当 $G(y) = y^4$ 时,式(14)等价于式(12).此处如果函数 G 不会增长太快就可以得到鲁棒性更好的负熵估计.

在实际应用中,对于高斯信号,其负熵值为 0.对于非高斯信号,其值大于 0.

(3) 互信息(mutual information)

定义 m 个随机变量 $y_i (i = 1, \dots, m)$ 之间的互信息为

$$I(y_1, y_2, \dots, y_m) = \sum_{i=1}^m H(y_i) - H(y_{\text{gauss}}) \quad (15)$$

互信息是随机变量之间相关性的度量.实际上,互信息等价于联合分布 $f(y)$ 和其边界密度乘积之间的 K-L 散布.互信息的值总是非负,当且仅当变量是统计独立时值为 0. PCA 和其他相关方法考虑协方差,而互信息考虑的是变量的整个相关的结构.互信息度量对于独立的非高斯信号其值为 0,其他情况大于 0.求独立分量即最小化互信息.

针对不同的非高斯性的度量方法,可以得到不同的获得分离矩阵 W 的改进方法,从而可以得到对观测信号的独立分离.

2 FastICA 算法及其改进

FastICA 算法是由芬兰赫尔辛基工业大学计算机及信息科学实验室提出并发展起来的,该算法通过系统学习找出一个方向,即单元矢量 w ,使其投影 $w^T x$ 具有最大的非高斯性.此处非高斯性度量公式由式(14)给出.在运行 FastICA 算法之前,假定已经进行了 ICA 的预处理过程,即去均值和白化. FastICA 是基于固定点(fixed-point)迭代理论来寻找 $w^T x$ 的非高斯性最大值,它每次只从观测信号中分离一个独立分量,是 ICA 的一种快速算法.

在 $E\{G(w^T x)\}$ 的某种优化下,可以得到 $w^T x$ 的负熵近似的最大值.对于 Kuhn-Tucker 条件

$$E\{L\} = \sum_{i=1}^n E\{\lg f_i(w_i^T x)\} + T \lg |\det W| \quad (16)$$

其中, T 为观察信号个数, n 为源的个数.

在约束条件 $E\{(w^T x)^2\} = \|w\|^2 = 1$ 下, $E\{G(w^T x)\}$ 的优化在下述条件下得到

$$E\{xg(w^T x)\} - \beta w = 0 \quad (17)$$

其中,函数 g 为 G 的导数.

式(17)函数左边部分用 $F(w)$ 表示,其雅可比矩阵 $J(w)$ 为

$$J(w) = E\{xx^T g'(w^T x)\} - \beta I \quad (18)$$

其中, $\beta = E\{w_0^T xg(w_0^T x)\}$, 而 $E\{xx^T\}g'(w^T x) \approx E\{xx^T\}E\{g'(w^T x)\} = E\{g'(w^T x)\}I$, 因此,雅可比矩阵成为对角矩阵,非奇异.可以得到下面的牛顿迭代近似

$$w_{k+1} = w_k \cdot [E\{xg(w_k^T x)\} - \beta w_k] / [E\{g'(w_k^T x)\} - \beta] \quad (19)$$

式(19)即为 FastICA 的迭代过程^[5-7].

在牛顿迭代解非线性方程的过程中,为了减少求雅可比矩阵的次数,一般对牛顿迭代法的改进为对所有迭代过程的雅可比矩阵均取为 $J(w_0)$, 得到迭代公式

$$w_{k+1} = w_k - F(w_k) / J(w_0) \quad (20)$$

该改进方法虽然能节省计算量,但却降低了迭代的收敛速度,将该方法应用到独立分量分析中,甚至可能导致算法最终不能收敛.因此,该方法在 ICA 的应用并不理想,而以下的改进方法则能在不增加求雅可比矩阵次数的情况下,大幅度减少收敛时的迭代次数,从而也获得减少计算量,提高算法的速度.假定已经求得 w_k , 则 w_{k+1} 可以通过下面的过程获得

$$\begin{cases} w_k^{(0)} = w_k \\ w_k^{(i)} = w_k^{(i-1)} - \frac{F(w_k^{(i-1)})}{J(w_k^{(i-1)})} \quad i=1, 2, \dots, m \\ w_{k+1} = w_k^{(m)} \end{cases} \quad (21)$$

可证明式(21)的收敛阶为 $m+1$ ^[14], 且每 m 次迭代只需要计算一次 $J(w)$, 因此减少了计算量,提高了迭代速度.当 $m=2$ 时,式(21)可简化为

$$w_{k+1} = w_k - \frac{F(w_k) + F(w_k) - F(w_k) / J(w_k)}{J(w_k)} \quad (22)$$

将 $F(w_k)$ 和 $J(w_k)$ 所表示的内容代入式(22), 即得到改进 FastICA (M-FastICA) 算法的迭代过程. M-FastICA 算法的基本形式如下:

- (1) 选择初始随机权值矢量 w_0 .
- (2) 利用式(22)更新 w_{k+1} .
- (3) 归一化 $w_{k+1}; w_{k+1} = \frac{w_{k+1}}{\|w_{k+1}\|}$.
- (4) 如果 $\|w_{k+1} - w_k\| > \epsilon$, 算法不收敛, 返回至第

2 步, 否则估算出一个独立分量, 算法结束.

对于多个独立分量的提取, 重复使用 M-FastICA 算法的基本形式进行分离即可. 但在每次提取出一个分量后, 需要从观测信号中减去该独立分量, 如此重复执行, 直到所有独立分量提取出来. 去掉已经抽取的独立分量的方法为

$$w_{k+1} = w_{k+1} - \sum_{j=1}^k w_k^T w_j w_j, w_{k+1} = \frac{w_{k+1}}{\sqrt{w_{k+1}^T w_{k+1}}} \quad (24)$$

3 实验结果及分析

下面的实验就是使用 FastICA 算法对线性混合的图象进行分离. 首先对 3 幅 256×256 原始图象如图 1 所示, 按随机生成的混合矩阵 A 进行混合, 得到实验所需要分离的混合图象, 如图 2 所示.

$$A = \begin{bmatrix} 0.9501 & 0.4860 & 0.4565 \\ 0.2311 & 0.8913 & 0.0185 \\ 0.6068 & 0.7621 & 0.8214 \end{bmatrix} \quad (25)$$

对混合图象进行去均值和白化处理后, 得到白化图象, 如图 3 所示, 此处白化采用的是标准 PCA 算法, 由此也可见, PCA 算法只去相关, 而不能把图象分离出来. 在此处, 所有 ICA 算法基本上都一致.

为了白化图象, 对图象用 M-FastICA 算法进行处理, 得到分离矩阵 W

$$W = \begin{bmatrix} -0.0158 & 0.0039 & 0.0080 \\ -0.0026 & 0.0225 & -0.0187 \\ -0.0193 & 0.0042 & 0.0358 \end{bmatrix} \quad (26)$$

并由分离矩阵获得原始图象的近似 y , 如图 4 所示(实验结果可能图象的顺序不定, 某些图象是图象的近似反相, 这是由于 ICA 算法的比例不确定性和次序不确定性造成的, 为清楚起见, 文中对图象的顺序以及反相图象作了调整). 为比较 M-FastICA 与 FastICA 的效果, 给出 FastICA 所得结果如图 5 所示.

M-FastICA 算法和基本 FastICA 算法速度性能比较结果如表 1 所示(由于算法迭代初初始权值 w_0 有关, 为了得到比较真实的性能比较, 每种算法均做 10 次).

利用同样的迭代过程, 将式(19)的 w 由矢量形式改为矩阵形式, 可以得到 FastICA 算法的类似神经网络的并行 FastICA 算法, 可并行估计出所有的分量. 同样地, 利用式(22)可改进得到并行 M-FastICA 算法, 试验结果如表 2 所示.



(a) 随机噪声图象 (b) Lena 图象 (c) Baboo 图象

图 1 原始图象



图 2 混合图象



图 3 白化图象



图 4 M-FastICA 分离图象



图5 FastICA 分离图象

表1 算法迭代次数比较表

序号	FastICA				M-FastICA			
	第1分量	第2分量	第3分量	总迭代次数	第1分量	第2分量	第3分量	总迭代次数
1	5	9	2	16	8	6	2	16
2	6	6	2	14	7	3	2	12
3	6	6	2	14	4	4	2	10
4	9	5	2	16	8	3	2	13
5	9	8	2	19	6	4	2	12
6	6	5	2	13	7	5	2	14
7	7	4	2	13	5	7	2	14
8	8	6	2	16	7	7	2	16
9	5	7	2	14	5	9	2	16
10	7	4	2	13	5	6	2	13
平均	6.8	6.0	2.0	14.8	6.2	5.4	2.0	13.6

表2 并行算法迭代次数比较表

	FastICA 迭代次数	M-FastICA 迭代次数
1	5	5
2	4	4
3	4	4
4	5	5
5	8	4
6	6	5
7	7	5
8	8	5
9	7	7
10	6	3
平均	6.0	4.7

离的图象的熵值比较接近,和原始图象的熵值也比较接近,因此 M-FastICA 算法与 FastICA 算法分离效果相当,而且独立分量分析能有效分离混合图象.

表3 算法平均熵值比较表

	随机噪音图象	Lena 图象	Baboo 图象
原始图象熵值	0.6	5.25	5.18
FastICA 分离图象熵值	2.12	5.33	5.27
M-FastICA 分离图象熵值	2.14	5.32	5.21

为了比较 M-FastICA 在提高了独立分量分析的收敛速度的基础上,是否造成图象信息的丢失,计算每幅图象的熵.熵是图象所具有信息量的度量,根据该参量可以大致判断算法的分离效果.熵的计算公式为

$$H = - \sum_{i=0}^{255} p_i \log p_i \quad (27)$$

式中, p_i 为图象直方图的灰度出现的频率.

表3所示为原始图象、FastICA 分离图象与 M-FastICA 分离图象的平均熵值.表中随机噪音图象的分离图象熵值增加,是因为分离的噪音图象中有 Lena 图象和 Baboo 图象的一些信息,导致其熵值增加.从表3可以看出,改进算法和基本算法所分

从实验结果可以看出, M-FastICA 算法不仅继承了 FastICA 算法的优点,而且能在 FastICA 算法的基础上减少算法收敛时的迭代次数,分离效果与原始 FastICA 算法相当. M-FastICA 有以下优点:

- (1) M-FastICA 收敛阶最多可达到 $m + 1$, 而 FastICA 算法收敛阶是 3, 一般 ICA 算法其收敛是线性的, 因此, M-FastICA 算法有非常快的收敛速度.
- (2) 同梯度下降法实现 ICA 相比, M-FastICA 算法不需要选择步长参数, 算法更易于使用、更可靠.
- (3) 大多数 ICA 算法是并行计算整个混合矩阵, 而 M-FastICA 算法一次只估算一个独立分量, 这可以估计某个想要的独立分量, 提高了算法的效率.
- (4) 独立分量是逐个估算的, 这近似于投影追

赶法,同时它也有并行的算法。

(5) M-FastICA 算法继承了神经计算并行、分布式、计算简单、需要很少内存空间等优点。

4 结 论

独立分量分析作为盲信号分离技术发展起来的一种新处理方法,在图象处理方面有着越来越多的应用。本文对独立分量分析在图象分离的应用进行研究,分析独立分量分析的快速算法 FastICA 的核心迭代过程,发现算法每次迭代均需要计算雅可比矩阵,而计算该矩阵是算法最为耗时的过程,因此提出改进的算法 M-FastICA,将多次迭代合成一次迭代,只需进行一次雅可比矩阵计算就可以获得原始算法多次迭代的效果,从而减少了算法的计算量,提高了算法的效率。图象分离的实验结果表明,独立分量分析能有效分离混合图象,在图象分离效果相当的情况下,M-FastICA 较 FastICA 减少了雅可比矩阵的计算次数,即减少了算法的计算量,提高了算法的效率。说明 M-FastICA 在继承 FastICA 的优点的基础上,进一步提高了快速独立分量分析算法的效率,因此 M-FastICA 算法是有效的。然而,M-FastICA 算法同 FastICA 算法一样,都假设图象混合是线性的,而实际混合图象则不一定是线性的,用线性 ICA 算法去逼近非线性 ICA 混合函数,结果不一定精确,因此考虑如何应用非线性 ICA 算法处理非线性混合问题将是下一步研究的工作。

参 考 文 献

- Jutten C, Herault J. Independent component analysis versus principal component analysis[A]. In: Proceedings of European Signal Processing Conference[C], Grenoble, France, 1988, 643~646.
- Comon P. Independent component analysis, A new concept?[J]. Signal Processing, 1994, 36(3):287~314.
- Bell A J, Sejnowski T J. An information-maximization approach to blind separation and blind deconvolution [J]. Neural Computation, 1995, 7(6):1129~1159.
- Lee T W et al. Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources[J]. Neural Computation, 1999, 11(2): 417~441.
- Hyvärinen A, Aerkki Oja. Independent component analysis: A tutorial [EB/OL]. <http://www.cis.hut.fi/projects/ica/IJCNN99-tutorial2.html>. 1999-04.
- Hyvärinen A, Aerkki Oja. A fast fixed-point algorithm for independent component analysis[J]. Neural Computation, 1997, 9(7):1483~1492.
- Hyvärinen A. Fast and robust fixed-point algorithms for independent component analysis [J]. IEEE Transactions on Neural Networks, 1999, 8(3):622~634.
- Ehlers F, Schuster H G. Blind separation of convolutive mixtures and an application in automatic speech recognition in a noisy environment[J]. IEEE Transactions on Signal Processing, 1997, 45(10): 2608~2612.
- 杨福生,洪波,唐庆玉. 独立分量分析及其在生物医学工程中的应用[J]. 国外医学生物医学工程分册, 2000, 23(3): 129~134.
- Xu L. Temporal BYJ learning for state space approach, hidden Markov model, and blind source separation [J]. IEEE Transactions on Signal Processing, 2000, 48(7): 2132~2141.
- Bartlett M, Lades H, Sejnowski T. Independent component representations for face recognition[A]. In: Proceeding of the SPIE Symposium on Electronic Imaging: Human Vision and Electronic Imaging[C], SanJose, California, USA, 1998:3249~3310.
- 刘璐,梅良模,何振亚. 一种基于 ICA 和过采样技术的盲反卷积方法[J]. 现代雷达, 1998, 20(4):41~45.
- 吴小培,冯焕清,周荷琴等. 基于独立分量分析的图象分离技术及应用[J]. 中国图象图形学报, 2001, 6A(2): 133~137.
- 蒋长锦. 科学计算和 C 程序集[M]. 安徽:中国科学技术大学出版社, 1998.

曾生根 1977 年生, 1999 年获南京理工大学获计算机应用专业学士学位, 现为硕博连读生, 主要研究方向为模式识别、数字图象处理和遥感图象分类。



朱宁波 1972 年生, 1994 年获南京理工大学计算机应用专业学士学位, 现为硕博连读生, 主要研究方向为模式识别、数字图象处理和手写汉字识别。



包 晔 1980 年生, 2002 年南京理工大学获计算机应用专业学士学位, 现为硕士研究生, 主要研究方向为数字图象处理和模式识别。



夏德深 1941 年生, 教授, 博士生导师, 1987 年于法国鲁昂大学获计算机应用专业博士学位, 主要研究方向为图象处理、卫星遥感、模式识别, 已发表论文 45 篇, 专著 4 本。

