

一种基于独立分量分析的模糊图像盲分离算法

王 毅, 齐 华, 郝重阳

(西北工业大学 电子信息学院, 陕西 西安 710072)

(wangyi79@nwpu.edu.cn)

摘 要:利用独立分量分析(ICA)的不完整自然梯度算法对因混合而引起的多幅模糊灰度图像进行盲分离,并针对算法中的非线性函数与源信号概率分布密切相关,而源信号的分布却是未知的先验信息的问题,利用算法输出信号的峰度对非线性激活函数进行自适应选择,提出了一种改进的自适应不完整自然梯度算法,并将其应用于模糊图像的盲分离,分析了不同混合矩阵对本文算法恢复原始灰度图像的影响及算法性能。仿真结果证明了本文算法与经典的 FastICA 算法相比,计算耗时更少、性能指标明显优越。

关键词:独立分量分析;盲图像分离;不完整自然梯度;激活函数;混合矩阵

中图分类号: TP391.41 **文献标识码:** A

Blind separation algorithm of blurred image based on independent component analysis

WANG Yi, QI Hua, HAO Chong-yang

(School of Electronics & Information, Northwestern Polytechnical University, Xi'an Shaanxi 710072, China)

Abstract: The original images were restored from the blurred grayscale images by using the nonholonomic natural gradient (NNG) algorithm of the Independent Component Analysis(ICA) methods, and the principle of natural gradient algorithm under nonholonomic constrain was analyzed. However, the nonlinear activation function of this algorithm is closely related to the unavailable probability distribution of the sources, though it is robust to nonstationary and strongly undulate sources. To solve this problem, the nonlinear function was selected adaptively by use of the kurtosis of the output signals, an improved adaptive NNG (ANNG) blind separation algorithm of blurred image based on ICA was proposed, and the effect of the different mixture matrices on the performance of this algorithm was researched. The simulations show the validity of the proposed method. Compared with the nonholonomic natural gradient algorithm and the classical FastICA algorithm, the performance index of this proposed algorithm is better.

Key words: Independent Component Analysis(ICA); blind images separation; Nonholonomic Natural Gradient(NNG); activation function; mixture matrix

0 引言

独立分量分析(Independent Component Analysis, ICA)是近年发展起来的一种信号分解技术。这种技术以非高斯源信号为研究对象,在对它们作统计独立的假设条件下,对观测到的多路混合信号进行盲分离,从而较完好地分离出隐含在混合信号中的独立信源信号。ICA 理论和技术的发展可以追溯到 20 世纪 90 年代初期,法国学者 C. Jutten 和 J. Herault^[1]等人首次提出了 ICA 的概念。1994 年, P. Comon^[2]第一个将独立分量分析方法应用于盲源分离。

独立分量分析近年来已成为信号处理领域一个倍受关注的热点问题,其应用包括图像处理、生物医学、雷达、声纳、通信、语音处理和地震预报等许多不同领域。其中,图像分离或恢复致力于使用图像退化的先验知识来消除图像的退化(污损、杂斑、噪声和干扰等)或将其最小化。而图像盲分离或图像盲恢复是仅使用退化的模糊图像和图像系统的部分信息,

从退化图像特征中估计或分离出原始源图像的过程。文献[3]综述了图像复原的基本方法,并对神经网络等盲处理方法进行了展望。最近许多关于图像分离的论文都涉及盲分离的 ICA 方法,例如文献[4]将扩展的最大似然 ICA 方法用于自相关图像的鲁棒盲分离;文献[5]提出了一种迭代盲源分离方法用于卷积混合图像的恢复;文献[6, 7]提出一种改进的 FastICA 方法 M-FastICA 用于图像盲分离,与 FastICA 算法^[8]相比所需迭代次数有所降低;文献[9]探讨了 ICA 在序列图像处理方面的应用,提出一种基于 ICA 的运动目标检测方法。其中,前三篇论文均与 FastICA 算法作了算法性能比较。

本文提出了自适应不完整自然梯度(Adaptive Nonholonomic Natural Gradient, ANNG)ICA 算法的思想,并将其应用于模糊图像的盲复原,分析了该算法的性能,比较了其与不完整自然梯度(NNG)算法^[11]及 FastICA 算法的性能。

收稿日期:2006-04-17;修订日期:2006-06-07

基金项目:国家博士点基金资助项目(20040699015);航空科学基金资助项目(02153072)

作者简介:王毅(1979-),女,陕西人,博士研究生,主要研究方向:信号与信息处理、图像处理、虚拟现实等;齐华(1963-),女,陕西人,博士研究生,主要研究方向:信号处理等;郝重阳(1940-),男,河北人,教授,博士生导师,主要研究方向:图像处理、虚拟现实、医学可视化等。

1 ICA 的数学模型

设 $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$ 为 m 维零均值随机观测信号向量, 它由源信号向量 $\mathbf{s} = (s_1, s_2, \dots, s_n)^T$ 中 n 个未知的零均值独立源信号 $s_j (j = 1, \dots, n)$ 线性组合而成, 则 ICA 的线性混合模型可表示为:

$$\mathbf{x} = \mathbf{H}\mathbf{s} = \sum_{j=1}^n \mathbf{h}_j s_j, \quad j = 1, 2, \dots, n \quad (1)$$

式中, $\mathbf{H} = [\mathbf{h}_1, \dots, \mathbf{h}_n]$ 是满秩的 $m \times n$ 阶矩阵 (称为混合矩阵), \mathbf{h}_j 为混合矩阵的基向量。(1) 式写成明显的矩阵形式为:

$$\begin{bmatrix} x_1(t) \\ \vdots \\ x_m(t) \end{bmatrix} = \begin{bmatrix} h_{11} & \cdots & h_{1n} \\ \vdots & & \vdots \\ h_{m1} & \cdots & h_{mn} \end{bmatrix} \begin{bmatrix} s_1(t) \\ \vdots \\ s_n(t) \end{bmatrix} \quad (2)$$

式中, 每个混合信号 $x_i (i = 1, \dots, m)$ 都是一随机变量 (不是时间信号), 而每个观测值 $x_i(t)$ 是在 t 时刻对随机变量 x_i 的一次抽样 (即 x_i 在 t 时刻的值)。由此看出, 各观测数据 x_i 是由独立源信号 s_j 经不同 h_{ij} 线性加权得到的。

(1) 式是一种统计“隐藏变量”模型, 即 ICA 模型。其中的独立分量 s_j 是隐藏的变量, 不能被直接观测到。而混合矩阵 \mathbf{H} 也是未知矩阵, ICA 唯一可利用的信息只有传感器观测到的随机向量 \mathbf{x} 。因此, 为了仅从观测到的混合信号 $\mathbf{x}(t)$ 来恢复 (或分离) 出源信号 $\mathbf{s}(t)$, 设置 $n \times n$ 阶的分离 (或解混) 矩阵 \mathbf{W} , 使:

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) = \mathbf{W}\mathbf{H}\mathbf{s}(t) = \mathbf{G}\mathbf{s}(t) \quad (3)$$

其中 $\mathbf{y}(t)$ 称为估计 (或分离) 信号。若由某种学习算法得到的 \mathbf{W} 能令全局矩阵 $\mathbf{G} = \mathbf{I}$ (\mathbf{I} 为 $n \times n$ 维单位阵), 则 $\mathbf{y}(t) = \mathbf{s}(t)$, 从而达到恢复源信号的目标。

独立分量分析算法包括优化判据 (目标函数) 和寻优算法两个方面。即学习时首先建立一个以 \mathbf{W} 为变元的目标函数 $\rho(\mathbf{W})$, 若某个 $\hat{\mathbf{W}}$ 能使 $\rho(\mathbf{W})$ 达到极大 (小) 值, 该 $\hat{\mathbf{W}}$ 即为所需的解; 其次是寻找一种有效的算法求解 $\hat{\mathbf{W}}$ 。

2 不完整约束的自然梯度 ICA 算法及其改进

根据信息理论及独立性要求, 可以建立如下目标函数^[12]:

$$\begin{aligned} \rho(\mathbf{y}, \mathbf{W}) &= -H(\mathbf{y}) + \sum_{i=1}^n H_i(y_i) \\ &= -H(\mathbf{x}) - \log |\det(\mathbf{W})| - \sum_{i=1}^n E\{\log(q_i(y_i))\} \end{aligned} \quad (4)$$

式中, $H(\mathbf{x}) = -\int_{-\infty}^{\infty} p_{\mathbf{x}}(\mathbf{x}) \log p_{\mathbf{x}}(\mathbf{x}) d\mathbf{x}$ 与解混矩阵 \mathbf{W} 无关, 故可省略。

由 (4) 式及梯度下降方法不难得到在线自然梯度学习算法^[13] 为:

$$\begin{aligned} \Delta \mathbf{W}(k) &= \mathbf{W}(k+1) - \mathbf{W}(k) \\ &= -\eta(k) \frac{\partial \rho(\mathbf{y}, \mathbf{W})}{\partial \mathbf{W}} \mathbf{W}^T \mathbf{W} \\ &= \eta(k) [\mathbf{I} - \mathbf{f}[\mathbf{y}(k)] \mathbf{y}^T(k)] \mathbf{W}(k) \end{aligned} \quad (5)$$

式中: $\eta(k)$ 为第 k 步迭代的学习速率, $\partial \rho / \partial \mathbf{W}$ 是元素为 $\partial \rho / \partial w_{ij}$ 的 $n \times n$ 阶梯度矩阵, $\mathbf{f}(\mathbf{y})$ 是激活函数向量 (详见公式 (8))。

为了推导不完整自然梯度算法, 引入不完整基 $d\mathbf{x}$ 。不完

整自然梯度限制了 $\Delta \mathbf{W}$ 可能的变化方向, 即其受 $dx_{ii} = 0 (i = 1, 2, \dots, n)$ 约束^[11, 13], 而标准自然梯度未对 $\Delta \mathbf{W}$ 的变化方向施加这种约束条件。又因为由 $d\mathbf{x} = d\mathbf{W}\mathbf{W}^{-1}$ 定义的基是一种不完整基, 因此称该约束为不完整约束。显然, 在该约束下, 可将 (5) 式重写为^[11]:

$$\Delta \mathbf{W}(k) = \eta(k) [\mathbf{A}(k) - \mathbf{f}[\mathbf{y}(k)] \mathbf{y}^T(k)] \mathbf{W}(k) \quad (6)$$

式中 $\mathbf{A} = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_n\}$ 是元素为 $\lambda_{ii} = f(y_i) y_i$ 的对角正定矩阵。(6) 式就是不完整自然梯度学习算法 (NNG), 实际是用一种特定的对角阵 \mathbf{A} 代替自然梯度算法中的单位阵 \mathbf{I} 。文献 [9] 论证了当源信号幅度随时间快速变化或在某段时间为零时, 不完整自然梯度学习算法仍能很好地工作, 而标准自然梯度算法则不具备这种能力, 它们会放大不包含在源信号内的零分量, 造成算法性能的恶化。

改进的自适应不完整自然梯度 (ANNG) ICA 算法可表示为:

$$\begin{aligned} \Delta \mathbf{W}(k) &= \eta(k) [\mathbf{A}(k) - \mathbf{f}[\mathbf{y}(k)] \mathbf{y}^T(k)] \mathbf{W}(k) \\ &= \eta(k) [\mathbf{A}(k) - \mathbf{y}(k) \mathbf{y}^T(k) - \\ &\quad \mathbf{T} \tanh(\mathbf{y}(k)) \mathbf{y}^T(k)] \mathbf{W}(k) \\ &= \eta(k) [\mathbf{A}(k) - \mathbf{D}(k)] \mathbf{W}(k) \end{aligned} \quad (7)$$

式中: $\mathbf{D}(k) = \mathbf{y}(k) \mathbf{y}^T(k) + \mathbf{T} \tanh(\mathbf{y}(k)) \mathbf{y}^T(k)$; $\mathbf{A} = \text{diag}[\text{diag}(\mathbf{D})]$ 是以矩阵 \mathbf{D} 的对角元素为元素的对角矩阵; $\mathbf{f}(\mathbf{y}) = [f_1(y_1), f_2(y_2), \dots, f_n(y_n)]^T$ 为列向量, 其第 i 个分量:

$$f_i(y_i) = -\frac{d \log q_i(y_i)}{dy_i} = -\frac{d q_i(y_i)/dy_i}{q_i(y_i)} = -\frac{q'_i(y_i)}{q_i(y_i)} \quad (8)$$

称为激活函数, 而 $q_i(y_i)$ 是对源信号 $\{s_i\}$ 概率密度函数 (pdf) 的近似估计; $T_i = \text{sign}(k_i)$, 其中:

$$k_i(s_i) = m_4/m_2^2 - 3 \quad (9)$$

为归一化峰度, m_2 和 m_4 分别指信号 s_i 的二阶矩和四阶矩。 $p_i(s_i)$ 为高斯函数时, $k = 0$; $p_i(s_i)$ 为超高斯函数时, $k > 0$; $p_i(s_i)$ 为亚高斯函数时, $k < 0$ 。由于源信号未知, 其峰度可由每步迭代计算得到的估计信号峰度近似表示, 迭代算法为:

$$k_i^{(k)}(y_i) = m_{4i}^{(k)} / (m_{2i}^{(k)})^2 - 3 \quad (10)$$

NNG 算法一般选择正切函数作为激活函数, 即 $f(y) = \tanh(y)$, 不理睬源信号为何种分布, 对某些源信号的概率密度并不适用。与 NNG 算法不同的是, 改进的 ANNG 算法无需已知源信号的先验信息, 既保留了不完整自然梯度算法恢复非平稳源信号的优势, 又能够利用峰度更为精确地拟合各源信号的概率密度函数, 可使其适用于服从任意分布的源信号, 并针对各种分布的源信号自适应地调节权重矩阵 \mathbf{W} 的变化方向。

3 算法仿真与分析

3.1 算法性能指标

$$\begin{aligned} \text{PI} &= \frac{1}{n(n-1)} \sum_{i=1}^n \left\{ \left(\sum_{k=1}^n \frac{|g_{ik}|}{\max_j |g_{jk}|} - 1 \right) + \right. \\ &\quad \left. \left(\sum_{k=1}^n \frac{|g_{ki}|}{\max_j |g_{ji}|} - 1 \right) \right\} \end{aligned} \quad (11)$$

式中, g 为全局矩阵 \mathbf{G} 的元素, $\max_i |g_{ij}|$ 表示 \mathbf{G} 的第 i 行元素绝对值中的最大值, $\max_j |g_{ji}|$ 表示第 i 列元素绝对值中的最大值。分离出的估计信号 $\mathbf{y}(t)$ 与源信号 $\mathbf{s}(t)$ 波形完全相同时 $\text{PI} = 0$ 。实际当 PI 达到 10^{-2} 时说明该算法分离性能已经相当好。

3.2 仿真与分析

选择四幅 128×128 的原始灰度图像进行线性混合,得到模糊的混合灰度图像,然后对其进行盲分离。算法仿真环境为 Intel Pentium 4 Prescott 2.71GHz, 256M DDR SDRAM。初始分离矩阵 W 为随机产生的正态分布矩阵,取混合矩阵为均匀分布随机矩阵:

$$H = \begin{bmatrix} 0.950129 & 0.891299 & 0.821407 & 0.921813 \\ 0.231139 & 0.762097 & 0.444703 & 0.738207 \\ 0.606843 & 0.456468 & 0.615432 & 0.176266 \\ 0.485982 & 0.018504 & 0.791937 & 0.405706 \end{bmatrix}$$

(7)式所示算法的分离结果如图1所示。其中,图1(a)为源图像,即清晰的未知原始图像;图(b)为经混合矩阵线性混合后的混合图像,即模糊图像;图(c)为本文算法的复原结果图像,直观上可以看出它与源图像十分接近,即从混合图像中成功恢复出了源图像。图2比较了本文算法 ANNG 与选择正切函数作为激活函数的 NNG 算法的性能,图中曲线数据均为 50 次 Monte Carlo 实验结果。根据图2的收敛曲线可见,本文算法收敛更快,大约 150 次迭代之后就基本完成分离,而 NNG 算法则需大约 250 步迭代。

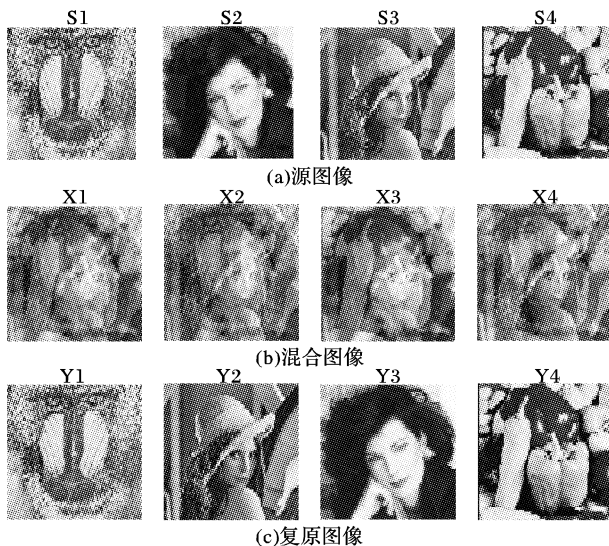


图1 本文算法图像恢复结果

表1比较了本文算法与经典的 FastICA 算法^[8](也称为

Fixed-Point ICA 算法)的性能。由该表中的全局矩阵 G 、性能指标 PI 及计算时间 t 可以看出,在选择相同激活函数和混合矩阵的情况下,二者均成功地从混合图像中分离出了源图像的估计图像,即复原图像。其中,性能指标 PI 均达到了 10^{-2} ,说明分离是成功的;虽然二者的全局矩阵都不是单位阵,但其各行各列均只有一个元素为 1,其余各元素均接近于 0,说明只是复原图像(图1(c))的排列顺序与源图像(图1(a))不同,而不影响算法的实际应用。此外,本文算法迭代的最终性能指标值比 FastICA 算法小 0.014175,计算时间比后者少 1s。鉴于二者计算时间均很短,1s 的差距足以说明本文算法性能优于 FastICA 算法。表2列出了不同混合矩阵 H 对文算法性能的影响。表2的数据说明:对于特殊的混合矩阵——Toeplitz 阵和 Hilbert 阵,算法也都有效地实现了图像的分离。特别地,表2中 Hilbert 矩阵的条件数非常大($\text{cond}(H) = 15513.7 > 10000$),已经是一种病态矩阵,这将导致某些算法各步迭代的解变化较大,造成数值上的不稳定。然而,从表2所示的各项仿真结果来看,本文算法仍然保持着较好的性能。

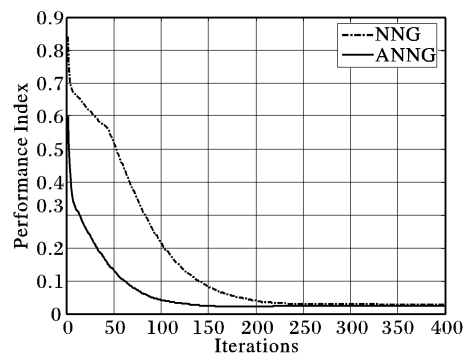


图2 算法性能指标收敛曲线

表1 本文算法与 FastICA 算法性能比较

算法	G	PI	$t(s)$
本文算法	$\begin{bmatrix} 0.033346 & 1.000000 & 0.034452 & 0.107224 \\ 0.034500 & 0.066320 & 1.000000 & 0.128910 \\ 1.000000 & 0.046993 & 0.034296 & 0.038850 \\ 0.080686 & 0.006338 & 0.093298 & 1.000000 \end{bmatrix}$	0.058768	1.44
FastICA 算法	$\begin{bmatrix} 0.016004 & 0.038544 & 0.101360 & 1.000000 \\ 1.000000 & 0.088961 & 0.035619 & 0.058408 \\ 0.133859 & 1.000000 & 0.017318 & 0.156651 \\ 0.039247 & 0.057888 & 1.000000 & 0.131451 \end{bmatrix}$	0.072942	2.44

表2 选择其他混合矩阵时本文算法的性能

H	G	PI	$t(s)$
Toeplitz 矩阵			
$\begin{bmatrix} 1.000000 & 0.500000 & 0.333333 & 0.250000 \\ 0.500000 & 1.000000 & 0.500000 & 0.333333 \\ 0.333333 & 0.500000 & 1.000000 & 0.500000 \\ 0.250000 & 0.333333 & 0.500000 & 1.000000 \end{bmatrix}$	$\begin{bmatrix} 1.000000 & 0.047062 & 0.034278 & 0.038777 \\ 0.080846 & 0.006193 & 0.093448 & 1.000000 \\ 0.034450 & 0.065739 & 1.000000 & 0.129041 \\ 0.033558 & 1.000000 & 0.033287 & 0.107212 \end{bmatrix}$	0.058658	1.31
Hilbert 矩阵			
$\begin{bmatrix} 1.000000 & 0.500000 & 0.333333 & 0.250000 \\ 0.500000 & 0.333333 & 0.250000 & 0.200000 \\ 0.333333 & 0.250000 & 0.200000 & 0.166667 \\ 0.250000 & 0.200000 & 0.166667 & 0.142857 \end{bmatrix}$	$\begin{bmatrix} 0.032535 & 1.000000 & 0.036631 & 0.107388 \\ 1.000000 & 0.046690 & 0.034429 & 0.038913 \\ 0.080659 & 0.006455 & 0.093398 & 1.000000 \\ 0.034682 & 0.067416 & 1.000000 & 0.128841 \end{bmatrix}$	0.059003	1.22

4 结语

从计算机仿真结果可知,本文算法能够有效地恢复出隐含在混合灰度图像中的源图像,对不同混合矩阵的影响不敏感,且对病态问题具有一定的稳健性,是一种具有等变化性质

的算法。就与 FastICA 算法的比较结果而言,也证明了本文算法具有如上所述较好的性能和较快的运算速度。今后将进一步研究学习速率 η 对本文算法稳定性以及收敛速度的影响,研究该算法对于病态问题的特性,并将该算法推广到源信号带噪和非线性混合的应用中。(下转第 2371 页)

算法的基本步骤:

- 1) 特征向量的提取。
- 2) 初始化(聚类中心、局部最优、全局最优)。
- For T = 1: MAXITER
- 3) 根据欧几里得几何距离进行聚类。
- 4) 根据公式(12)计算 mbest, 根据公式(15)计算适应性函数值。
- 5) 更新局部最优 pbest, 及全局最优 gbest。
- 6) 根据公式(13)计算随机点。
- 7) 根据公式(14)更新粒子的中心向量。
- End
- 重复计算 2) ~ 6) 步, 直到满足迭代的次数。

3 实验结果

实验中用的图像为一幅 24 位真彩色 JPEG 图像 (600 × 800), 每个像素点有三个特征向量, 聚为五类。为了实现对比, 所用的参数如下:

粒子数 (popsize) 为 30; 染色体的长度 (lchrom) 为 3; 迭代代数 (maxgen) 为 100; 变异概率 (pcross) 为 0.01; X 为 10; K 为 500; R 为 100

测试结果如表 1 所示。

表 1 GA 算法与 QPSO 算法在下列部分迭代中偏差的对比 (E)

	5	10	15	20	25	30	50	70	80	90	100
GA	101	206	126	103	173	81	103	115	94	149	167
QPSO	163	15	87	21	60	55	13	69	78	116	55

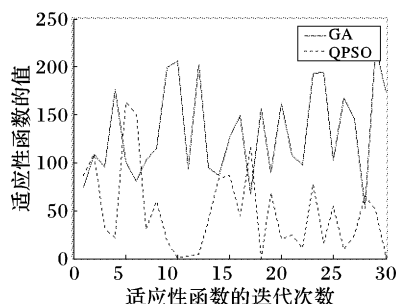


图 1 在 100 次的迭代中取前 30 次迭代结果

表 1 给出了 GA 算法与 QPSO 算法的运算复杂度的对比, E 为编码中最大的搜索偏差。从对比看出, QPSO 算法搜索距离明显低于 GA 算法。相应的曲线图见图 1。

4 结语

所有的测试在同一幅图像中, 所有的各步操作在本文中是有效的。与遗传算法相比较, QPSO 没有遗传操作如交叉和变异, 而根据随机点来搜索。在遗传算法中, 搜索一个最优的序列来满足相邻像素点的最优位置, 整个种群的移动是比较均匀地向最优区域移动。而在 QPSO 算法中, 用粒子群的最优位置来对像素点进行调整, 整个搜索更新过程是跟随当前最优解的过程。通过上述实验结果分析可以得出: 基于量子行为的微粒群优化算法在处理图像压缩问题上算法简单, 效果明显, 是一种高效的、可靠的算法, 它具有一定的实用价值。

参考文献:

- [1] 原岛博. 图像信息压缩[M]. 北京: 科学出版社, 2004.
- [2] BHUYAN J. Genetic Algorithm for Clustering with an Ordered Representation[A]. Proceedings of Fourth International Conference on Genetic Algorithms[C]. 1991. 408 - 415.
- [3] DUBES K. Experiments in projection and clustering by simulated annealing[J]. Pattern Recognition, 1989, 22(1): 213 - 220.
- [4] 何小海. 图像通信[M]. 西安: 西安电子科技大学出版社, 2005.
- [5] 谷口庆治. 数字图像处理[M]. 北京: 科学出版社共立出版, 2002.
- [6] 全子一. 数字视频图像处理[M]. 北京: 北京电子工业出版社, 2005.
- [7] SUN J, XU WB. A Global Search Strategy of Quantum-behaved Particle Swarm Optimization[A]. Proceedings of IEEE conference on Cybernetics and Intelligent Systems[C]. 2004. 111 - 116.
- [8] SUN J, FENG B, XU WB. Particle Swarm Optimization with Particles Having Quantum Behavior[A]. Proceedings of 2004 Congress on Evolutionary Computation[C]. 2004. 325 - 331.
- [9] 曾建潮, 介婧, 崔志华. 微粒群算法[M]. 北京: 科学出版社, 2004.
- [10] 王小平, 曹立明. 遗传算法——理论、应用与软件实现[M]. 西安: 西安交通大学出版社, 2002.

(上接第 2368 页)

参考文献:

- [1] JUTTEN C, HERAULT J. Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic architecture[J]. Signal Processing, 1991, 24(1): 1 - 10.
- [2] COMON P. Independent component analysis, a new concept[J]. Signal Processing, 1994, 36: 287 - 314.
- [3] 柏森, 张邦礼, 曹长修. 神经网络图像复原方法的研究进展[J]. 中国图象图形学报, 2002, 7(11): 1105 - 1112.
- [4] GERACE I, CRICCO F, TONAZZINI A. An extended maximum likelihood approach for the robust blind separation of autocorrelated images from noisy mixtures[A]. In: Proc. ICA2004[C]. Granada, Spain, 2004. 954 - 961.
- [5] CASTELLA M, PESQUET JC. An Iterative Blind Source Separation Method for Convolutional Mixtures of Images[A]. In: Proc. ICA2004[C]. Granada, Spain, 2004. 922 - 929.
- [6] 曾生根, 朱宁波, 包晔, 等. 一种改进的快速独立分量分析算法及其在图像分离中的应用[J]. 中国图象图形学报, 2003, 8(10): 1159 - 1165.
- [7] 曾生根, 王小敏, 范瑞彬, 等. 基于独立分量分析的遥感图像分类技术[J]. 遥感学报, 2004, 8(2): 150 - 157.
- [8] HYVÄRINEN A. Fast and robust fixed-point algorithms for independent component analysis[J]. IEEE Transactions on Neural Networks, 1999, 10(3): 626 - 634.
- [9] 吴小培, 冯焕清, 周荷琴, 等. 基于独立分量分析的图像分离技术及应用[J]. 中国图象图形学报, 2001, 6(2): 133 - 137.
- [10] AMARI S, CHEN TP, CICHOCKI A. Non-holonomic constraints in learning algorithms for blind source separation[J]. Neural Computation, 2000, 12: 1463 - 1484.
- [11] BELL AJ, SEJNOWSKI TJ. An information maximization approach to blind separation and blind deconvolution[J]. Neural Computation, 1995, 7(6): 1004 - 1159.
- [12] CICHOCKI A, AMARI S. Adaptive Blind Signal and Image Processing: learning algorithm and applications[M]. Chichester, England: John Wiley, 2002.