

基于改进 K-means 聚类和霍夫变换的稀疏源混合矩阵盲估计算法

付 宁, 乔立岩, 彭喜元

(哈尔滨工业大学自动化测试与控制系, 哈尔滨工业大学 3033 信箱, 黑龙江哈尔滨 150080)

摘 要: 混合矩阵的估计是稀疏源盲分离的关键组成部分, 其估计精度直接影响到源信号的估计精度. 本文首先针对 K-means 聚类算法依赖初始值选取的问题, 将微分进化算法思想引入到 K-means 聚类算法中, 提出了一种改进的 K-means 聚类算法. 利用该算法, 对稀疏源混合信号数据进行聚类, 保证了聚类结果的鲁棒性. 然后利用霍夫变换, 对每一类数据的聚类中心进行修正, 从而估计出混合矩阵, 提高了混合矩阵的估计精度. 仿真实验表明, 相比于经典的稀疏源混合矩阵盲估计算法, 本文算法具有更强的鲁棒性和更高的估计精度.

关键词: 盲源分离; 稀疏信号; 聚类; K-means; 微分进化; 霍夫变换

中图分类号: TN911 **文献标识码:** A **文章编号:** 0372-2112 (2009) 4A-092-05

Blind Recovery of Mixing Matrix with Sparse Sources Based on Improved K-means Clustering and Hough Transform

FU Ning, QIAO Li-yan, PENG Xi-yuan

(Department of Automatic Test and Control, Harbin Institute of Technology, P. O. Box 3033, Harbin, Heilongjiang 150080, China)

Abstract: Blind mixing matrix recovery is one of the most important steps in blind separation of sparse sources, which impacts significantly on the recovery accuracy of source signals. A novel improved K-means clustering algorithm is proposed based on differential evolution, to avoid the partial convergence problem of the K-means algorithm. The proposed algorithm is applied to allocate the sparse mixture data to several clusters, thus guaranteeing the robustness of the clustering. Then the cluster centers are amended through Hough transform to recover the mixing matrix. Experimental results show that the proposed mixing matrix recovery algorithm has advantages of high robustness and accuracy compared with conventional algorithms.

Key words: blind source separation; sparse signals; clustering; K-means; differential evolution; Hough transform

1 引言

近年来, 建立在源信号稀疏特性基础之上的稀疏源盲分离, 因其能够处理观测信号数目小于源信号数目的欠定问题, 已成为盲源分离(Blind Source Separation, BSS)领域的研究热点^[1~4].

考虑 BSS 的基本瞬时线性混合模型,

$$x(t) = As(t) = \sum_{i=1}^N a_i s_i(t), t = 1, 2, \dots, K \quad (1)$$

其中, $s(t) = [s_1(t), s_2(t), \dots, s_N(t)]^T$ 表示 N 维源信号向量, $x(t) = [x_1(t), x_2(t), \dots, x_M(t)]^T$ 表示 M 维观测信号向量, A 表示 $M \times N$ 维的混合矩阵, a_i 是 A 的列向量, t 是离散时刻, K 是观测信号点数. BSS 的命题就是, 对任何 t , 根据已知的 $x(t)$, 在 A 未知的条件下求未知的 $s(t)$. 根据观测信号数目 M 和源信号数目 N 的

大小关系, BSS 问题可分为正定问题 ($M = N$)、超定问题 ($M > N$) 和欠定问题 ($M < N$).

在自然界中, 很多信号都服从稀疏分布, 或者在某种变换域(如傅里叶变换域或小波变换域)中具有稀疏性. 因此稀疏源盲分离具有很广阔的应用前景. 文献[1]中指出, 信号的稀疏性是指信号在大多数时刻为零或接近零. 如果源信号足够稀疏, 那么在大多数采样时刻只有一个源信号取值占优. 假设在时刻 t , $s_i(t)$ 单独作用, 则式(1)可写为 $x(t) = a_i s_i(t)$, 它是 M 维空间中的一条直线, 其斜率取决于 A 的列向量 a_i . 当不止一个源信号作用时, 观测数据分布在 M 维空间中的某一直线附近, 呈线性聚类特征. 利用这一特征, 无论是在正定、超定还是欠定条件下, 都可以用聚类算法检测出这些直线, 它们的斜率即为混合矩阵的各列向量. 在混合矩阵估计出后, 便可通过矩阵求逆的方法(正定或超定情况)或线性

规划方法(欠定情况)估计源信号.因此,混合矩阵的估计是稀疏源盲分离的关键部分,其估计精度直接影响到源信号的估计精度.

在估计混合矩阵的聚类算法中,比较有代表性的有势函数算法^[1]、K-means 算法^[2]、Fuzzy C-means 算法^[3]以及 Hard-LOST 算法^[4]等.这些算法都取得了不错的效果.然而,它们都存在不同程度的局部收敛问题,即算法依赖于初始点的选取,很可能收敛于次优解,从而导致算法的鲁棒性不好.另外,这些算法虽然对信号的聚类比较成功,但其聚类中心由于受噪声及无关信号的影响,对直线方向的估计精度较差,从而导致混合矩阵的估计精度较差.

另外, J. K. Lin^[5]、H. Shindo^[6]等将图像处理中的霍夫变换引入到混合矩阵的估计中,将直线方向的检测化作变换空间峰值点的检测,以此估计混合矩阵.这种方法精度较高,抗干扰能力强,但是因为峰值簇拥现象,一般的峰值提取算法都难以得到令人满意的结果^[7].

微分进化(Differential Evolution, DE)是一种新兴的智能优化算法,具有高效性、收敛性和鲁棒性等优点.本文将引入到经典的 K-means 聚类算法中,提出了一种改进的 K-means 聚类算法,克服了经典 K-means 算法的局部收敛问题.同时,将这种聚类算法与霍夫变换相结合,用于稀疏源盲分离的混合矩阵估计,获得了较好的鲁棒性和较高的估计精度.

2 改进 K-means 聚类算法

2.1 K-means 聚类算法

设有 n 个样本组成的集合 $D = \{x_1, \dots, x_n\}$, 聚类的目标就是将该集合分为 k 个互不重叠的子集 D_1, \dots, D_k , 每个子集代表一个聚类, 同一类中的样本点比不同类中的样本点具有更高的内在相似性.

K-means 算法是一种经典的聚类算法, 其主要工作过程为: 首先, 随机选择 k 个样本, 每个样本称为一个种子, 代表一个簇(类)的均值或中心, 对剩余的每个样本, 根据其与各簇中心的距离将它赋给最近的簇(即最近邻准则). 然后重新计算每个簇内样本的平均值形成新的聚类中心, 这个过程重复进行, 直到各聚类中心不再变化为止^[9].

K-means 算法的实质是通过局部搜索的方法寻找误差平方和准则函数 J_e 的最小值, 其结果依赖于初始聚类中心的选择, 算法很可能收敛于次优解. 误差平方和准则函数 J_e 如下式所示,

$$J_e = \sum_{i=1}^k \sum_{x \in D_i} \|x - m_i\|^2 \quad (2)$$

其中, m_i 表示第 i 类的均值向量.

2.2 DE 算法

DE 算法最先由 R. Storn 和 K. Price 于 1995 年提出, 它是一种实数编码的基于种群进化的全局优化算法, 能够处理非线性、不可微、多峰的目标函数. 其控制参数少, 而且易于选取^[10].

DE 算法通过迭代搜寻最优值, 系统初始化为一组随机解. 假设 DE 算法种群规模为 NP , 每个个体有 D 维变量, 则第 G 代的个体可表示为 $X_{i,G} (i = 1, 2, \dots, NP)$. 其主要操作包括: 变异、交叉、选择^[10].

DE 算法的变异操作如下:

$$v_{i,G+1} = X_{r_1,G} + F \cdot (X_{r_2,G} - X_{r_3,G}) \quad (3)$$

其中, $v_{i,G+1}$ 是变异操作后得到的中间个体, $r_1, r_2, r_3 \in \{1, 2, \dots, NP\}$ 且 $r_1 \neq r_2 \neq r_3 \neq i$, F 为一常数, 称作变异因子.

交叉操作如下: 将变异得到的中间个体 $v_{i,G+1} = (v_{1i,G+1}, v_{2i,G+1}, \dots, v_{Di,G+1})$ 和当前个体 $X_{i,G} = (X_{1i,G}, X_{2i,G}, \dots, X_{Di,G})$ 进行杂交, 得到当前个体的候选个体 $u_{i,G+1} = (u_{1i,G+1}, u_{2i,G+1}, \dots, u_{Di,G+1})$, 如下式所示:

$$u_{ji,G+1} = \begin{cases} v_{ji,G+1}, & \text{if } (\text{randb}(j) < CR) \text{ 或 } j = \text{mbr}(i) \\ x_{ji,G}, & \text{else} \end{cases} \quad (4)$$

其中, $i = 1, 2, \dots, NP, j = 1, 2, \dots, D$. $\text{mbr}(i)$ 是一个随机参数, 保证 $u_{i,G+1}$ 至少从 $v_{i,G+1}$ 中取到一个分量值, $\text{randb}(j) \in [0, 1]$ 是一个均匀分布的随机数, $CR \in [0, 1]$ 是杂交因子.

选择操作如下: 对候选个体 $u_{i,G+1}$ 进行适应度评价, 然后根据下式决定是否选取新产生的个体,

$$X_{i,G+1} = \begin{cases} u_{i,G+1}, & \text{if } f(u_{i,G+1}) < f(X_{i,G}) \\ X_{i,G}, & \text{else} \end{cases} \quad (5)$$

其中, $f(\cdot)$ 是个体的适应度函数.

算法迭代的终止条件根据具体问题一般选为最大迭代次数或(和)种群个体迄今为止搜索到的最优位置满足预定的最小适应阈值.

2.3 基于 DE 的改进 K-means 聚类算法

如前所述, K-means 算法的实质是求解寻找式(2)最小值的优化问题, 但是它的结果依赖初始点的选取, 很可能收敛于次优解. 根据文献^[10], 一个可能的方法是重复地随机选取 k 个样本并聚类, 从而降低聚类结果对初始点的依赖性. 而对于基于种群进化的 DE 算法而言, 种群中的每个个体都是解空间中的一个候选解, 正好可以解决这个问题. 所以我们将 DE 算法的思想与 K-means 算法的局部搜索操作相结合, 提出了如下的改进 K-means 聚类算法, 借助 DE 算法良好的全局寻优能力和高寻优成功率, 提高 K-means 算法的求解质量和鲁棒性.

首先,为应用 DE 算法,需要通过对个体进行适当的编码,使每个个体包含各子集的聚类中心,即每个个体均代表一种划分.然后选择式(2)所示的误差平方和准则函数 J_e 作为适应度函数,通过对个体进行变异、交叉、选择等操作,寻找该适应度函数的最小值.

在选择操作中,对于第 G 代的个体 $X_{i,G} (i = 1, 2, \dots, NP)$,按照某一概率,进行如下的局部搜索操作.即,根据这些个体所包含的聚类中心,划分所有样本,并重新计算各类的均值向量,联合起来作为一个新的个体,记为局部中间个体 $z_{i,G+1}$.将 $z_{i,G+1}$ 与相应的通过变异、交叉得到的候选个体 $u_{i,G+1}$ 以及当前个体 $X_{i,G}$ 进行适应度评价,选择适应度最小的个体作为下一代个体 $X_{i,G+1}$,如下式所示,

$$X_{i,G+1} = \begin{cases} z_{i,G+1}, & \text{if } f(z_{i,G+1}) < f(X_{i,G}) \text{ 并且 } f(z_{i,G+1}) < f(u_{i,G+1}) \\ u_{i,G+1}, & \text{if } f(u_{i,G+1}) < f(X_{i,G}) \text{ 并且 } f(u_{i,G+1}) < f(z_{i,G+1}) \\ X_{i,G}, & \text{else} \end{cases} \quad (6)$$

若对于某些个体,不需要进行局部搜索操作,则将候选个体 $u_{i,G+1}$ 与当前个体 $X_{i,G}$ 进行适应度评价,按照式(5)形成下一代个体 $X_{i,G+1}$.每个个体进行局部搜索操作的概率称作局部搜索因子 $SP \in [0, 1]$.

综上,改进 K-means 聚类算法的流程图如下:

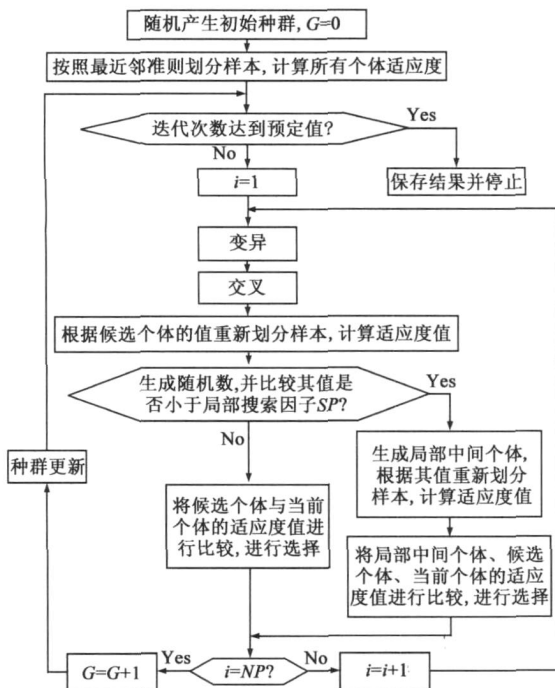


图1 基于DE的改进K-means聚类算法流程图

3 霍夫变换简介

3.1 霍夫变换

霍夫变换是一种快速形状匹配技术,它是对图像进行某种形式的坐标变换,使得经过变换以后原图上给定形状曲线上的所有点都集中到变换空间的某些位置上,形成峰值点.这样就将对原图中给定形状曲线的检测问题转化为寻找变换空间中峰值点问题.关于霍夫变换的详细解释可见文献[6].

3.2 霍夫变换在混合矩阵估计中的应用

在稀疏源盲分离中,利用霍夫变换,可以检测观测空间中最密的 N 条直线方向,从而确定混合矩阵 $A^{[5]}$.假设观测空间中数据点为 $(x_1, x_2, \dots, x_M)^T$,由于观测空间中直线均过零点,所以直线的参数方程可以表示为

$$\begin{pmatrix} x_M \\ x_{M-1} \\ \dots \\ x_3 \\ x_2 \\ x_1 \end{pmatrix} = \sqrt{\sum_{i=1}^M x_i^2} \begin{pmatrix} \cos \theta_{M-1} \\ \sin \theta_{M-1} \cos \theta_{M-2} \\ \dots \\ \sin \theta_{M-1} \sin \theta_{M-2} \dots \sin \theta_3 \cos \theta_2 \\ \sin \theta_{M-1} \sin \theta_{M-2} \dots \sin \theta_3 \sin \theta_2 \cos \theta_1 \\ \sin \theta_{M-1} \sin \theta_{M-2} \dots \sin \theta_3 \sin \theta_2 \sin \theta_1 \end{pmatrix} \quad (7)$$

其中, $(\theta_1, \dots, \theta_{M-2}, \theta_{M-1}) \in [0, \pi)^{M-1}$ 称作变换空间.观测空间中的每个数据对应变换空间中的一个点.观测空间中相同直线上的数据都对应变换空间中相同的点.通过量化变换空间,观测空间中的直线就会在变换空间中形成峰值点.

霍夫变换实际上得到的是变换空间中的直方图,然后求此直方图的若干峰值点.它具有精度较高、抗干扰能力强、对无关信号点不敏感等优点.但是由于噪声的干扰和直方图本身的离散性,现在一般的多峰值提取算法都会遇到峰值簇拥的难题^[7],即变换空间中会存在很多我们所不期望得到的峰值点,而如果要提取多个峰值点,那么所提取出来的某些点往往并不是我们所期望的.

4 新的混合矩阵估计算法

如前所述,目前基于经典聚类的混合矩阵估计算法均存在局部收敛和精度不高的问题.为此,本文将第2节所示的改进 K-means 聚类 and 霍夫变换相结合,提出了一种新的混合矩阵估计算法.

首先,采用改进 K-means 聚类将观测信号点划分为若干类,利用 DE 算法优良的全局收敛特性,保证算法的鲁棒性.然后,在聚类的基础上,对每一类数据应用霍夫变换,通过在变换空间寻找全局极大值点来确定密度最大的直线方向,从而估计出混合矩阵 A ,以提高 A 的估计精度.同时,由于只需在变换空间中寻找全局极大值点,所以可以避免采用霍夫变换进行多峰值提取时的峰值簇拥问题.

新的混合矩阵估计算法步骤如下:

(1) 如果信号不够稀疏,则首先对观测信号进行加窗傅里叶变换或小波变换转化为稀疏信号;

(2) 由于观测空间中零点附近的数据对直线方向的估计作用不大,所以设定一个阈值,将观测数据点中绝对值小于该阈值的点去掉;

(3) 将剩余观测数据点投影到上半单位超球面上,这样在上半单位超球面上数据点的密度具有很明显的聚类特征;

(4) 采用 2.3 节的改进 K-means 聚类算法,将观测数据点分为 N 类.其中,需设置算法的几个参数:种群规模 NP 、变异因子 F 、杂交因子 CR 、局部搜索因子 SP 以及最大迭代次数 G_{\max} ;

(5) 对每一类数据点,采用式(7)所示的参数方程进行霍夫变换,求变换空间中累加数组的极大值点,该点对应的参数即为直线方程的参数.其中,需要设置变换空间的量化步长($1, \dots, M-2, M-1$);

(6) 各直线方向向量即为混合矩阵 A 的各列向量,联合起来即得到 A 的估计.

5 仿真实验及结果分析

5.1 算法性能评价准则

5.1.1 混合矩阵估计精度的评价

为了评价混合矩阵估计算法的估计精度,一般将估计出的 \hat{A} 和已知的 A 进行比较,采用“泛化交扰误差”(Generalized Crosstalking Error, GCE)进行评价^[8]. GCE 定义如下:

$$GCE = \min_B \|A - \hat{A}B\| \quad (7)$$

其中, B 是所有 $N \times N$ 维可逆矩阵组成的集合,这些矩阵的每一列只有一个非零值“1”.在采用 GCE 计算之前,需要将 A 和 \hat{A} 都进行列向量归一化,以消除 \hat{A} 的幅度不确定性.

如果 $GCE = 0$,则表示矩阵 \hat{A} 和 A 完全等价;而 GCE 的值越小,则表示两矩阵越接近.

5.1.2 算法鲁棒性的评价

算法的鲁棒性主要是指算法在不同初始条件下多次运行结果的一致性.参考聚类分析中算法鲁棒性的评价准则^[10],本文采用算法多次运行所得 GCE 的标准差进行评价.标准差反映了算法运行结果的离散程度,标准差越小,说明算法的鲁棒性越好.

5.2 实验方法及结果分析

实验所用的源信号采用文献[4]中作者采用的语音信号 s_1, s_2, s_3, s_4, s_5 (可从[11]获得),根据混合矩阵生成观测信号.设 M 和 N 分别表示观测信号的个数和源信号的个数,那么采用“ $MmNs$ ”表示一种混合情况.

本文针对以下三种情况进行实验:

(1) $2m3s$:源信号采用 s_1, s_2, s_3 ,其混合矩阵为

$$A_{2m3s} = \begin{bmatrix} 0.4472 & 0.8321 & -0.8000 \\ 0.8944 & 0.5547 & 0.6000 \end{bmatrix};$$

(2) $3m4s$:源信号采用 s_1, s_2, s_3, s_4 ,其混合矩阵为

$$A_{3m4s} = \begin{bmatrix} 0.5044 & -0.1545 & -0.6371 & 0.3314 \\ 0.6325 & 0.4755 & -0.6371 & -0.8001 \\ 0.5878 & 0.8660 & 0.4339 & 0.5000 \end{bmatrix};$$

(3) $3m5s$:源信号采用 s_1, s_2, s_3, s_4, s_5 ,其混合矩阵为

$$A_{3m5s} = \begin{bmatrix} 0.7500 & 0.4330 & -0.1545 & -0.8127 & 0.6124 \\ 0.4330 & 0.7500 & 0.2676 & -0.4064 & -0.3536 \\ 0.5000 & -0.5000 & 0.9511 & 0.4175 & 0.7071 \end{bmatrix}.$$

为使信号更加稀疏,对观测信号进行加窗傅里叶变换,窗函数选为 512 点的 Hamming 窗,与文献[4]中设置的参数一致.观测数据点的绝对值预定阈值设为 0.2. DE 算法中的参数设置为: $NP = 2 \times M \times N$, $F = 0.5$, $CR = 0.5$, $SP = 0.5$, $G_{\max} = 200$. 算法的霍夫变换空间每个参数的量化步长均设为 $\pi/180$.

为了使算法的测试结果更具有对比性,我们将本文算法与基于 K-means 的混合矩阵估计算法^[2]和 Hard+LOST 算法^[4]进行了比较.其中,Hard+LOST 算法的收敛速度参数 r 设为 0.0005.每个算法运行前,都对观测信号进行加窗傅里叶变换,参数设置和前面一样.

针对每种混合情况,各种算法都运行 20 次,对每次运行结果计算 GCE,记录 20 次运行的最大值(GCE_{\max})和最小值(GCE_{\min}),并计算平均值(GCE_{avg})和标准差(GCE_s),列入表 1~表 3 中.

表 1 “ $2m3s$ ”情况算法仿真结果

算法	GCE_{avg}	GCE_s	GCE_{\max}	GCE_{\min}
K-means	0.0599	0	0.0599	0.0599
Hard+LOST	0.4845	0.6601	1.6606	0.0425
本文算法	0.0302	0	0.0302	0.0302

表 2 “ $3m4s$ ”情况算法仿真结果

算法	GCE_{avg}	GCE_s	GCE_{\max}	GCE_{\min}
K-means	0.5482	0.7175	1.9469	0.1986
Hard+LOST	1.1245	0.8067	2.3734	0.0812
本文算法	0.0565	0	0.0565	0.0565

表 3 “ $3m5s$ ”情况算法仿真结果

算法	GCE_{avg}	GCE_s	GCE_{\max}	GCE_{\min}
K-means	0.5188	0.0004	0.5190	0.5182
Hard+LOST	1.6366	1.2226	4.0556	0.1548
本文算法	0.0788	0	0.0788	0.0788

由表中结果可看出,在三种混合情况中,本文算法都得到了最高的估计精度,并且算法所得的 GCE 标准差均为 0,说明算法各次运行结果完全一致,鲁棒性较好.而基于 K-means 的混合矩阵估计算法的 GCE 标准差仅在“ $2m3s$ ”情况中为 0,在其余两种情况中均不为

0,特别是在“3 m4s”情况中其 GCE 标准差较大;Hard-LOST 算法在三种情况中 GCE 标准差均较大。

本文算法较好的鲁棒性得益于 DE 算法的引入,在实际应用时,其参数设置范围可参考文献[10]。在保证种群规模 NP 和最大迭代次数 G_{\max} 都不太小的情况下,其他参数的变化对算法的鲁棒性影响不大,仅会影响到算法的收敛速度。另外,本文算法较高的估计精度得益于霍夫变换的引入,其变换空间量化步长的设置对算法的估计精度有一定影响。一般情况下,该量化步长越小,估计精度越高,但算法运行时间也越长。所以,在保证实际所需精度的情况下,该量化步长设置为合适的值即可,不宜设置太小。

6 结论

本文在分析现有基于经典聚类的稀疏源混合矩阵估计算法优缺点的基础上,提出了一种新的基于改进 K-means 聚类 and 霍夫变换的混合矩阵估计算法。该算法利用 DE 良好的全局收敛特性,克服了 K-means 聚类的局部收敛问题,提高了算法运行的鲁棒性;利用霍夫变换精度高、抗干扰能力强的优点,提高了算法的估计精度。同时,算法有效避免了应用霍夫变换进行多峰值提取时经常遇到的峰值簇拥问题。仿真结果表明,新算法相对于经典的稀疏源混合矩阵估计算法,混合矩阵估计精度和算法鲁棒性都有了大幅度提高。

参考文献:

- [1] Bofill P, Zibulevsky M. Underdetermined blind source separation using sparse representations[J]. Signal Processing, 2001, 81(11): 2353 - 2362.
- [2] Li Y Q, Cichocki A, Amari S. Analysis of sparse representation and blind source separation[J]. Neural Computation, 2004, 16(6): 1193 - 1234.
- [3] Zibulevsky M, Kisilev P, Zeevi Y Y, Pearlmutter B A. Blind source separation via multinode sparse representation[A]. Advances in Neural Information Processing Systems [C]. Cambridge, MA, USA: MIT, 2002. 1049 - 1056.
- [4] O'Grady P D, Pearlmutter B A. Hard-LOST: Modified k-means for oriented lines[A]. Proceedings of the Irish Signals and Systems Conference [C]. Belfast, Ireland: IEE, 2004. 247 - 252.
- [5] Lin J K, Grier D G, Cowan J D. Feature extraction approach to blind source separation[A]. Proceedings of the IEEE Workshop on Neural Networks for Signal Processing [C]. Amelia Island, FL, USA: IEEE, 1997. 398 - 405.
- [6] Shindo H, Hirai Y. Blind source separation by a geometrical method[A]. Proceedings of the International Joint Conference on Neural Networks [C]. Honolulu, HI, USA: IEEE, 2002. 1108 - 1114.
- [7] 梁彦, 金术玲, 潘泉, 程咏梅. 基于投票样本方差的 Hough 变换权值积累方法[J]. 控制工程, 2005, 12(7): 43 - 45, 48.
Liang Y, Jin S L, Pan Q, Cheng Y M. A sample-variance based weight accumulation method for Hough transforms[J]. Control Engineering of China, 2005, 12(7): 43 - 45, 48. (in Chinese)
- [8] Theis F J, Lang E W, Puntonet C G. A geometric algorithm for overcomplete linear ICA[J]. Neurocomputing, 2004, 56(1-4): 381 - 398.
- [9] Xu R, Wunsch D. Survey of clustering algorithms[J]. IEEE Transactions on Neural Networks, 2005, 16(3): 645 - 678.
- [10] Paterlinia S, Krinkb T. Differential evolution and particle swarm optimisation in partitional clustering[J]. Computational Statistics & Data Analysis, 2006, 50(5): 1220 - 1247.
- [11] O'Grady P D. Sound Examples [DB/OL]. http://ee.ucd.ie/~pogrady/LOST_experiments/sources, 2007

作者简介:



付宁男, 1979 年出生于河南省鹤壁市, 在读博士研究生, 哈尔滨工业大学自动化测试与控制系讲师, 主要研究方向为盲信号处理、自动测试技术等。

E-mail: farnold1224@yahoo.com.cn



乔立岩男, 1973 年出生于黑龙江省哈尔滨市, 回族, 博士, 哈尔滨工业大学自动化测试与控制系副教授, 主要研究方向为进化算法、模式识别、故障诊断技术等。

E-mail: qiaoliyan@163.com