

# 基于邻域风险最小化概率密度估计的 自适应盲分离算法\*

栾海妍<sup>1</sup>, 江桦<sup>1</sup>, 罗军<sup>2</sup>

(1. 解放军信息工程大学, 郑州 450002; 2. 解放军 91290 部队, 北京 100081)

**摘要:**为实现由不同统计特性和概率分布平滑特性信号得到混合信号的盲分离,对基于支持向量机的邻域风险最小化概率密度估计算法进行研究,提出一种邻域函数的构造方法,将其与自然梯度批处理算法相结合,形成一种新的自适应盲分离算法;利用广义高斯模型分析了分离算法的精确度。通过仿真实验,验证了该算法能分离统计特性不同的混合信号,相比于基于经验风险最小化的方法,该方法在收敛速度和精度方面的性能有很大提高。

**关键词:** 邻域风险; 概率密度估计; 支持向量机; 激活函数; 自然梯度算法; 盲分离

**中图分类号:** TN911      **文献标志码:** A      **文章编号:** 1001-3695(2010)08-3096-04

doi:10.3969/j.issn.1001-3695.2010.08.076

## Adaptive blind source separation algorithm based on vicinal risk minimizing PDF estimation

LUAN Hai-yan<sup>1</sup>, JIANG Hua<sup>1</sup>, LUO Jun<sup>2</sup>

(1. PLA Information Engineering University, Zhengzhou 450002, China; 2. The 91290th Troop of PLA, Beijing 100081, China)

**Abstract:** The paper studied the vicinal risk minimization based PDF estimation algorithm using support vector machine, and proposed a new construction algorithm for the vicinity function. Combining with natural gradient batch algorithm, put forward a new adaptive blind source separation algorithm. Analyzed the precision of the solution farther using the generalized gauss model. Carried out the several experiments, which proved that the algorithm could separate the mixtures containing signals with different statistical characteristic. Compared with the widely algorithm based on empirical risk minimization methods, the proposed algorithm has better performance both in the convergent speed and the precision.

**Key words:** vicinal risk; estimation of probability density function; support vector machine; activate function; natural gradient algorithm; blind source separation

### 0 引言

盲信号分离是信号处理领域的一个新兴的研究方向,在语音信号、生物医学、通信信号处理等很多领域得到了应用。瞬时混合信号盲分离是其中最简单的一种混合模型:在源信号  $S(t)$  和信道混合矩阵  $A$  都未知的情况下,根据观测数据  $X(t) = AS(t)$ ,利用信号的统计特性确定分离矩阵  $W$ ,使得  $Y(t) = WX(t)$  成为对源信号  $S(t)$  的拷贝和估计。

已有瞬时混叠盲分离算法可分为三大类,即联合对角化盲分离、几何盲分离以及自适应盲分离算法。联合对角化方法<sup>[1-3]</sup>设计原理简单,但计算量太大,工程可实现性不强;几何盲分离算法<sup>[4-6]</sup>在源信号数目较小时,具有简单快速的优点,当源信号数目较多时,算法中旋转角度的计算是非常复杂的,大大限制了算法的推广能力;自适应盲分离算法<sup>[7-9]</sup>是逐步逼近的智能化方法,具有结构简单、分离信号类型广泛等优点,是目前应用最多的方法。

自然梯度算法是自适应盲分离的主流算法,自适应估计源

信号概率密度函数(PDF)从而得到非线性激活函数是算法的关键,影响着算法的稳定性和精确度。Choi 等人<sup>[10]</sup>利用基于广义高斯模型的参数法对源信号 PDF 进行估计,实现了源信号服从单峰密度分布的信号分离;Vlassis 等人<sup>[11]</sup>利用加权高斯和的方法对源信号 PDF 进行估计,实现了超高斯和亚高斯混合信号的分离,但算法误差较大、运算复杂度高;付卫红等人<sup>[12]</sup>利用 Parzen 法对源信号 PDF 进行估计,实现了不同统计特性混合信号的分离,但该算法估计表达式需遍历所有样本点,当样本点数太多时很不实用;高鹰<sup>[13]</sup>提出基于非线性小波分解 PDF 估计的盲分离算法,具有较好的局部适应性和渐进性,但分离精度相对较低;胡波平等人<sup>[14]</sup>提出支持向量机(SVM)概率密度函数估计算法,通过最小化结构风险与经验风险之和,得到只与支持向量有关的密度估计表达式,简化了估计结果的结构,但当考虑到 PDF 的平滑性时,经验风险泛函可能就不是对期望风险泛函最好的逼近<sup>[15]</sup>。本文在 SVM 理论的基础上,对基于邻域风险最小化(VRM)概率密度估计算法进行研究,提出一种邻域函数的构造方法,将其应用到自然梯度算法中,并利用广义高斯模型详细分析了算法的精确度。

收稿日期: 2010-01-24; 修回日期: 2010-03-04      基金项目: 国家“863”计划资助项目(2008AA011002)

作者简介: 栾海妍(1981-),女,山东烟台人,博士研究生,主要研究方向为盲信号处理(abaoliu@126.com);江桦(1956-),男,江苏南通人,博导,教授,主要研究方向为通信信号截获与处理;罗军(1981-),男,贵州贵阳人,工程师,硕士,主要研究方向为通信信号分析。

### 1 基于 SVM 的 VRM 概率密度估计算法

#### 1.1 基本原理

首先给出邻域风险泛函的定义:

$$V(\beta) = \frac{1}{l} \sum_{i=1}^l L(y_i - E f(x, \beta)) = \frac{1}{l} \sum_{i=1}^l L(y_i - \int_{v(x_i)} f(x, \beta) p(x|x_i, d_i) dx) \quad (1)$$

其中:  $(y_1, x_1), (y_2, x_2), \dots, (y_l, x_l)$  为由  $l$  个独立同分布样本  $x_1, x_2, \dots, x_l$  得到的训练样本向量,  $p(x|x_i, d_i)$  为  $x_i$  邻域内点的密度函数,  $f(x, \beta)$  为概率密度函数集。

由于概率密度估计问题为不适定问题,采用正则化技术在目标泛函中引入非负半连续泛函因子  $\Omega(f, f)$ , 取线性  $\varepsilon$  不敏感损失函数,则最小化目标泛函为

$$V^*(\beta) = \frac{1}{l} \sum_{i=1}^l |y_i - \int_{v(x_i)} f(x, \beta) p(x|x_i, d_i) dx|_\varepsilon + \lambda \Omega(f, f) \quad (2)$$

采用 P 方法对问题求解,即在某个由核函数  $K_\gamma(x, x_i)$  定义的再生核希尔伯特空间中,寻求具有以下形式的解:

$$f(x) = \sum_{i=1}^l \beta_i \frac{1}{v_i} \int_{v(x_i)} K_\gamma(x, x') dx' = \sum_{i=1}^l \beta_i L_\gamma(x, x_i) \quad (3)$$

可通过下面的优化问题求解  $\beta$ : 最小化泛函  $\Phi(\beta, \xi_i, \xi_i^*) = \frac{1}{2}(\beta \cdot \beta) + C(\sum_{i=1}^l \xi_i^* + \sum_{i=1}^l \xi_i)$ , 约束条件为

$$\begin{aligned} Y_i - (\beta \cdot Z_i) - \sigma_i - \xi_i^* &\leq 0 \\ (\beta \cdot Z_i) - Y_i - \sigma_i - \xi_i &\leq 0 \\ -\xi_i^* \leq 0, -\xi_i \leq 0, -\beta \leq 0, \beta A = 1 \end{aligned} \quad (4)$$

其中:  $Z_i = (Z_i(x_1), \dots, Z_i(x_l))$ ,  $Z_j(x) = \int_{-\infty}^{x_j} L_\gamma(x, x') dx'$ ,  $A = [1, 1, \dots, 1]_{l \times l}$ 。这一优化问题可以利用已有的非线性规划方法对  $\beta$  进行求解,在  $\beta$  中只有部分元素不等于零,它们定义了问题中的支持向量,将  $\beta$  中不为零的元素代入式(3)即可得到概率密度函数的估计结果。

#### 1.2 邻域函数的构造方法

通过上述分析可以看出,构造合适的邻域分布函数是 VRM 方法的关键,对密度函数估计结果的性能有重要的影响。本文将构造一种具有高斯对称结构的软邻域分布函数,其表达式如下:

$$p(x|x_i, r_i) = (1/\sqrt{2\pi}r_i) \cdot \exp(-(x-x_i)^2/2r_i^2); i=1, \dots, l \quad (5)$$

令  $K_\gamma(x, x_i) = (1/\sqrt{2\pi}\gamma) \cdot \exp(-(x-x_i)^2/2\gamma^2)$  (从容许参数集中选择  $\gamma$ ), 则单邻域核函数为

$$L_\gamma(x, x_i) = \int_{v(x_i)} K_\gamma(x, x') p(x|x_i, r_i) dx' = (1/\sqrt{2\pi}\gamma) \{ (1+r_i^2/\gamma^2)^{-\frac{\pi}{2}} \exp[-(x-x_i)^2/2(\gamma^2+r_i^2)] \} \quad (6)$$

分析式(6)可知,  $r_i$  影响着  $L_\gamma(x, x_i)$  的宽度;  $r_i$  越大,  $L_\gamma(x, x_i)$  越宽,平滑性越好;反之亦然。当  $r_i \rightarrow 0$  时,  $L_\gamma(x, x_i) \rightarrow K_\gamma(x, x_i)$ , 邻域风险泛函退化为经验风险泛函。

一般来说,在随机序列分布较密集的区域,其概率密度曲线起伏变化比较大,而在随机序列分布较稀疏的区域,曲线起伏较小,相对比较平滑。在估计概率密度函数时,期望在曲线起伏较大的区域利用较窄的单邻域核函数确保较高的精度,而在曲线起伏相对平缓的区域使用较宽的单邻域核函数以得到较好的平滑性。

利用训练向量间最小距离  $d_i$  在很大程度上能够表征训练向量  $(x_i, y_i)$  邻域内样本分布的密集情况,  $d_i$  越小则分布越密

集,  $d_i$  越大则分布越稀疏。图 1 给出了由概率密度函数  $f(x) = 0.5[1/\sqrt{2\pi} \exp(-(x-1)^2/2) + 2/\sqrt{2\pi} \exp(-(x-5)^2/2 \times 0.5^2)]$  产生 100 个随机样本  $x = (x_1, \dots, x_{100})$  得到的训练向量  $(x, y) = ((x_1, y_1), \dots, (x_{100}, y_{100}))$  的分布图。从图中可以看出,在密度曲线取值较大的区域,训练向量分布较密集,向量间最小距离较小;反之,训练向量分布较稀疏,向量间最小距离较大。但是由于样本的随机性,在密度曲线取值较小的区域,存在个别样点距离较小的情况,如图中矩形框标注出的两个训练向量点几乎重叠,如果只考虑最小间距,则在该样点处的单邻域核函数将很窄,使得估计结果的平滑性变差;而在概率密度曲线取值较大的区域,也可能存在个别样点与其他样点间距较大的情况,如图中椭圆框标注出的训练向量,这时如果根据最小间距采用较宽的单邻域核函数,显然是很不合理的。




图1 由已知概率密度函数产生随机样点的分布图

本文对样本点  $x_i$  邻域分布函数方差  $r_i$  的选择主要取决于两个因素:训练向量  $(x_i, y_i)$  与其他训练向量之间的最小距离  $d_i$  以及  $x_i$  所在区域样本数目占总体样本的百分比  $p_i$ 。下面分别给出这两个参数的定义:

a) 训练向量  $(x_i, y_i)$  与其他训练向量之间的最小距离  $d_i = \min_j \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}, j=1, \dots, l, j \neq i$ ;

b)  $x_i$  所在区域样本数目占总体样本的百分比  $p_i = n_i/l$ , 其中:  $n_i$  为  $x$  中满足条件  $|x_j - x_i| \leq m$  的样点数目 ( $j=1, \dots, l$ );  $m$  为某一预先设定的常数。

当  $d_i$  和  $p_i$  值都较小时,表明  $x_i$  处于概率密度曲线取值较小的区域,但存在一个训练向量(假设为  $x_k$ )与其相距很近,这两个训练向量对估计算法的贡献可以只用其中一个训练向量来代替。本文通过删除与该向量最邻近向量  $x_k$ ,重新计算该点的  $d_i$  和  $p_i$  值,从而得到  $r_i$ 。

当  $d_i$  和  $p_i$  值都较大时,表明训练向量  $x_i$  处于概率密度曲线取值较大的区域,但相对比较孤立。由于这样的训练向量对概率密度曲线估计算法的贡献很小,可以直接将其从训练样本序列中删除。

图 2 给出了计算训练样点  $x_i$  邻域分布函数方差  $r_i$  的流程图。其中  $d_{\text{threshold}}$  和  $p_{\text{threshold}}$  是预先设定的门限值。对整个样本集合进行  $l$  次循环,即可求出每一样本点对应的邻域分布函数方差,从而对同一样本点构造出不同的邻域分布函数,使得所得到的概率密度分布函数在不同核函数上展开。




图2 计算  $x_i$  邻域分布函数方差的流程图

由式(7)概率密度函数产生 100 个随机样本,分别采用三种不同的方法进行概率密度估计。

$$f(x) = \frac{1}{2} \left[ \frac{1}{0.8\sqrt{2\pi}} \exp\left(-\frac{(x-1)^2}{2 \times 0.8^2}\right) + \frac{1}{0.5\sqrt{2\pi}} \exp\left(-\frac{(x-3)^2}{2 \times 0.5^2}\right) \right] \quad (7)$$

方法一、二为基于 SVM 邻域风险最小化方法,方法一采用了本文提出的方法构造邻域函数;方法二中邻域函数的构造只利用了训练样点间最小距离,没有结合所在区域样本数目占总体样本的百分比这一参数;方法三为目前常用的基于 SVM 经验风险最小化方法(这里采用的是文献[16]的单核函数法)。分别对三种方法进行 100 次实验,得到各方法的误差分布框状图(boxplot)如图 3 所示。图中每个框代表一组实验的结果分布,至下而上的横线分别指示出了误差分布的 5%、25%、50%、75%、95% 分位数。可以看出,基于本文提出的邻域函数构造方法的概率密度估计算法较其他两种方法在估计性能上有一定的改善。

### 2 基于 VRM 概率密度估计的自然梯度盲分离算法

采用自然梯度算法中的批处理学习算法<sup>[17]</sup>:

$$Y(t, k) = W(k)X(t) \tag{8}$$

$$W(k+1) = W(k) + \Delta W(k) \tag{9}$$

$$\Delta W(k) = \alpha(k) \left[ I - \frac{1}{T} \sum_{t=1}^T \varphi(Y(t, k)) Y^T(t, k) \right] W(k) \tag{10}$$

$$\text{激活函数 } \varphi(Y(t, k)) = \left[ -\frac{f'_1(y_1(t, k))}{f_1(y_1(t, k))}, \dots, -\frac{f'_N(y_N(t, k))}{f_N(y_N(t, k))} \right],$$

$t = 1 \sim T, k = 0, 1, 2, \dots$ 。设源信号与观测信号数目相等且都为  $N$ ,  $f_i$  为对第  $i$  个源信号的概率密度估计函数,  $f'_i(y_i(t, k))$  是  $f_i(y_i(t, k))$  对  $y_i(t, k)$  的导数。

由于对源信号进行概率密度函数估计时,是没有源信号的训练样本的,这里采用观测的混合信号经去均值和白化处理后的结果来替代源信号样本。自适应盲分离算法的全过程如下:

- a) 将观测数据  $Y$  去均值并白化得到  $Z$ ;
- b) 利用基于支持向量机的 VRM 概率密度估计算法,估计  $Z$  中若干个样本(如取  $Z$  中各信号前 100 个样本点)的概率密度函数  $f(\cdot)$ ;
- c) 由  $f(\cdot)$  计算激活函数  $\varphi(\cdot)$ ;
- d) 为学习步幅和分离矩阵赋初值  $\alpha(0)$  和  $W(0)$ ;
- e) 按照学习规则(8)~(10)逐点进行迭代即可。

### 3 批处理算法解的精确度分析

关于分离算法解的精确度,Pham 在文献[18]中推导得到如下结论:只有当估计得到的源信号概率密度函数与源信号真实的概率密度函数一致时,第  $j$  个信号源对第  $i$  个信号源干扰的均方值  $\sigma_{\varepsilon_{ij}}^2$  达到最小值  $(\sigma_{\varepsilon_{ij}}^2)_{\min} = \frac{\rho_i^2}{T(1-\rho_i^2\rho_j^2)}$ 。其中

$$\rho_i = \frac{E[\varphi_i(S_i)S_i]}{\sigma \sqrt{E[\varphi_i^2(S_i)]}}$$

由于  $\rho_i \leq 1$ ,对固定的  $\rho_j^2$ ,  $(\sigma_{\varepsilon_{ij}}^2)_{\min}$  为  $\rho_i^2$  的单调增函数。根据  $E[\varphi_i(S_i)S_i] = 1$ ,则  $\rho_i^2 = 1/\sigma^2 E[\varphi_i^2(S_i)]$ 。

下面首先给出广义 Gauss 密度模型的表达式: $f(s) = (a/2b\Gamma(1/a))e^{-|s/b|^a}$ 。其中  $b = \sigma \sqrt{\Gamma(1/a)/\Gamma(3/a)}$  ( $\sigma$  为方差),根据形状参数  $a$  的取值不同可描述不同统计特性的信号,如 Gauss 信号、超 Gauss 信号和亚 Gauss 信号等。下面将利用此模型对于干扰均方值的最小值  $(\sigma_{\varepsilon_{ij}}^2)_{\min}$  进行较深入的分析。

图 4 给出了该模型下  $\rho^2$  随参数  $a$  的变化关系。可以看出,当  $a=2$  时,广义 Gauss 分布特例化为高斯分布,  $\rho^2$  取得最大值 1;当  $0 < a \leq 0.5$  时,  $\rho^2$  恒等于 0;当  $0.5 < a < 1$  时,随着  $a$  的增加,  $\rho^2$  急剧增大;当  $a > 1$  时,随着  $a$  的增加,  $\rho^2$  逐渐减小,

当  $a \rightarrow \infty$  时,  $\rho^2 \rightarrow 0$ 。可以得到如下结论:

- a)  $\sigma_{\varepsilon_{ij}}^2$  随着批处理容量  $T$  的增加而下降,当  $T \rightarrow \infty$  时,  $\sigma_{\varepsilon_{ij}}^2 \rightarrow 0$ ;
- b) 当第  $i$  和第  $j$  个源信号均为高斯分布时,  $\rho_i^2 = \rho_j^2 = 1$ ,  $(\sigma_{\varepsilon_{ij}}^2)_{\min} \rightarrow \infty$ ,这再次证明了当源信号中有一个以上服从高斯分布时是不可分的;
- c) 当  $a_i$  (第  $i$  个源信号的形状参数) 满足条件时  $0 < a_i \leq 0.5$ ,  $(\sigma_{\varepsilon_{ij}}^2)_{\min} = 0$ ;
- d) 当  $0.5 < a_i < 1$  时,  $(\sigma_{\varepsilon_{ij}}^2)_{\min}$  为  $a_i$  的单调增函数;当  $a_i > 1$  时,  $(\sigma_{\varepsilon_{ij}}^2)_{\min}$  为  $a_i$  的单调减函数,当  $a_i \rightarrow \infty$  时,  $(\sigma_{\varepsilon_{ij}}^2)_{\min} \rightarrow 0$ 。由此可以看出,源信号越偏离高斯分布,分离算法解的精确度越高。




图3 三种方法的估计误差比较




图4 广义高斯模型下  $\rho^2$  与参数  $a$  的关系图

### 4 仿真实验

以包含超高斯、亚高斯和高斯统计特性的六路源信号经瞬时线性混合后得到的混合信号盲分离的仿真实验来验证算法的有效性。六路源信号表达式分别为  $s_1(t) = \text{sign}(\cos(310\pi t))$ ,  $s_2(t) = \sin(1600\pi t)$ ,  $s_3(t) = \sin(180\pi t)$ ,  $s_4(t) = \sin(600\pi t + 6\cos(12\pi t))$ ,  $s_5(t) = ((\text{mod}(100t, 2) - 11)/9)^{15} + 3$ ,  $s_6(t)$  为长度为 1 000 的高斯序列。六路源信号的归一化峭度值分别为  $-2, -1.5, -1.5, -1.4984, 0.7788$  和 0。混合矩阵  $A$  为在区间内随机产生的  $6 \times 6$  方阵,以采样率  $f_s = 3\ 000\text{Hz}$  对得到的观测信号进行采样,采样长度为 1 000。

在仿真中各参数设置如下:分离矩阵的初始值  $W(0)$  为任意随机生成的  $6 \times 6$  方阵,采用固定步幅  $\alpha(k) = 0.02, T = 500$ ,在概率密度估计算法中各参数设置为  $m = [\max(x) - \min(x)]/20, C = 1, \gamma = 0.5, \sigma_l = 0.03, d_{\text{threshold}}$  为最小距离矩阵  $|d_i, i = 1, \dots, l|$  按降序排序后前 10 项元素的均值,  $p_{\text{threshold}} = 0.1$ 。图 5 给出了六路源信号的波形图,图 6 为分离后六路信号的波形图。为便于观察,这里只给出了前 500 点的波形图,可以看出算法较好地实现了对源信号的还原。

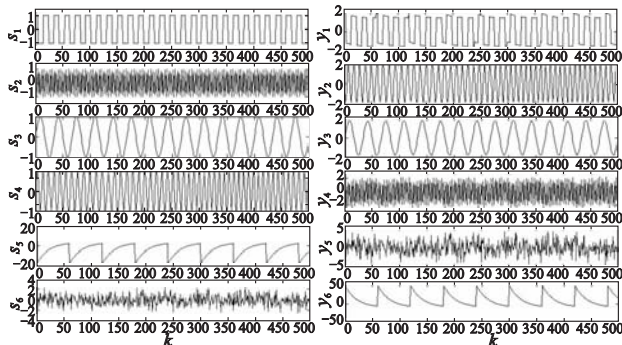


图5 六路源信号的波形图 图6 分离出的六路信号波形图

采用串音误差来评价算法的收敛性能<sup>[16]</sup>:

$$CE = \sum_{i=1}^N \left( \sum_{k=1}^N \frac{|p_{ij}|}{\max_k |p_{ik}|} - 1 \right) + \sum_{j=1}^N \left( \sum_{i=1}^N \frac{|p_{ij}|}{\max_k |p_{kj}|} - 1 \right)$$

这里  $P = (p_{ij}) = W\Sigma A, \Sigma$  为白化矩阵。图 7 给出了本文所提出的算法与基于 SVM 最小经验风险原则下概率密度估计<sup>[16]</sup>的

自然梯度批处理算法性能对比(在仿真中两种方法的共同参数设置相同)。从图 7(a)可以看出,本文提出的算法在收敛速度方面有很大的提高,在 100 个点左右能够收敛,而基于 ERM 算法需要接近 300 个数据点时才能收敛;图 7(b)给出了两种算法在收敛后串音误差的对比,可以看出基于 VRM 算法解的精确度要明显高于基于 ERM 的算法。




图7 算法串音误差性能比较

## 5 结束语

本文对基于 VRM 概率密度函数估计方法进行了研究,提出一种新的邻域函数构造方法,使得概率密度估计式对不同样点是在不同形式核函数上展开的;将该概率密度估计算法应用到自然梯度批处理盲分离算法中,并在前人工作的基础上对盲分离算法解的精确度作了进一步分析。仿真实验表明,相对于基于 ERM 概率密度估计的盲分离算法,本文提出的算法在收敛速度和精确度方面有很大优势,但由于概率密度估计算法需要逐样点设计合理的邻域函数,算法的运算复杂度相对有所增加。

### 参考文献:

- [1] CARDOSO. Blind beamforming for non-Gaussian signals [J]. IEE Proceedings F, 1993, 140(6): 224-230.
- [2] XIE S L, HE Z S, FU Y L. FIR convolutive BSS based on sparse representation [C]// Proc of the 2nd International Symposium on Neural Networks. 2005:532-537.
- [3] PARRA L, SPENCE C. Convolutive blind separation of non-stationary sources [J]. IEEE Trans on Speech Audio Processing, 2000, 8(3): 320-327.
- [4] PUNTONET C G, PRIETO A, ORTEGA J. New geometrical approach for blind separation of sources mapped to a neural network [C]// Proc of International Workshop on Neural Networks for Identifi-

cation, Control, Robotics and Signal/Image Processing. 1996: 174-182.

- [5] MANSOUR A, PUNTONET C G, OHNISHI N A. Simple ICA algorithm based on geometrical approach [C]//Proc of the 6th International Symposium on Signal Processing and Its Applications. 2001: 835-836.
- [6] 谭北海,赵敏,谢胜利. 带源个数估计的 BPSK 信号盲分离算法 [J]. 电子与信息学报, 2009, 31(7): 1624-1626.
- [7] AMARI S, CICHOCKI A, YANG H. A new learning algorithm for blind signal separation [J]. Advances in Neural Information Processing Systems, 1996, 8: 657-663.
- [8] 何文雪. 自适应盲信号分离理论与算法研究 [D]. 上海:上海交通大学, 2005.
- [9] 张贤达. 盲信号处理几个关键问题的研究 [J]. 深圳大学学报:理工版, 2004, 21(3): 196-200.
- [10] CHOI S, CICHOCKI A, AMARI S. Flexible independent component analysis [C]//Proc of IEEE Workshop on Neural Networks for Signal Processing. 1998: 83-92.
- [11] VLASSIS N, MOTOMURA Y. Efficient source adaptivity in independent component analysis [J]. IEEE Trans on Neural Networks, 2001, 12(3): 559-565.
- [12] 付卫红,杨小牛,刘乃安,等. 基于概率密度估计盲分离的通信信号盲侦察技术 [J]. 华中科技大学学报:自然科学版, 2006, 34(10): 24-27.
- [13] 高鹰. 基于小波概率密度函数估计的盲信号分离算法 [J]. 广州大学学报:自然科学版, 2006, 5(6): 15-18.
- [14] 胡波平,何选森. 盲源分离的 SVM 概率密度函数估计算法 [J]. 计算机工程与应用, 2009, 45(17): 142-144.
- [15] VAPNIK V N. 统计学习理论的本质 [M]. 张学工,译. 北京:清华大学出版社, 2000: 187-200.
- [16] 张κ,张素,章琛曦,等. 基于支持向量机的概率密度估计方法 [J]. 系统仿真学报, 2005, 17(10): 2355-2357.
- [17] 杨行峻,郑君里. 神经网络与盲信号处理 [M]. 北京:清华大学出版社, 2003: 339-357.
- [18] PHAM D T, GARAT P. Blind separation of mixture of independent sources through a quasi-maximum likelihood approach [J]. IEEE Trans on Signal Processing, 1997, 45(7): 1712-1725.
- [19] CICHOCKI A, UNBEHAUEN R, MOSZCZYNSKI L, et al. A new online algorithm for blind separation of source signals [C]//Proc of ISANN. 1994: 406-411.

(上接第 3089 页)

### 参考文献:

- [1] SIRIWONGPAIRAT W P, SADEK A K, LIU K J R. Cooperative communications protocol for multiuser OFDM networks [J]. IEEE Trans on Communications, 2008, 7(7): 2430-2435.
- [2] SADEK A K, SU W, LIU K J R. Multi-node cooperative communications in wireless networks [J]. IEEE Trans on Signal Processing, 2007, 55(1): 341-355.
- [3] 3GPP TS 36. 300. E-UTRA and E-UTRAN: overall description: stage 2 (release 8) [S]. 2008.
- [4] GENC V, MURPHY S, YU Y, et al. IEEE 802. 16j relay-based wireless access networks: an overview [J]. IEEE Wireless Communications, 2008, 15: 56-65.
- [5] KANEKO M, POPOVSKI P. Radio resource allocation algorithm for relay-aided cellular ofdma system [C]// Proc of IEEE ICC. 2007: 4831-4836.

- [6] KIM B G, LEE Jang-won. Opportunistic power scheduling for OFDMA cellular networks with scheduling at relay stations [C]//Proc of IEEE WCNC. 2009.
- [7] PISCHELLA M, BELFIORE J-C. Resource allocation for QoS-aware OFDMA using distributed network coordination [J]. IEEE Trans on Vehicular Technology, 2009, 58(4): 1766-1775.
- [8] SONG Guo-cong, LI Ye. Cross-layer optimization for OFDM wireless networks-Part II: algorithm development [J]. IEEE Trans on Communications, 2005, 4(2): 625-634.
- [9] KUO W H, LIAO W. Utility-based optimal resource allocation in wireless networks [C]// Proc of IEEE GLOBECOM. 2005.
- [10] LANEMAN J N. Cooperative diversity in wireless networks: algorithms and architectures [D]. [S. l.]: Massachusetts Institute of Technology, 2002.
- [11] HUANG Xiao-yan, MAO Yu-ming, WU Fan. Low complexity utility-based scheduling algorithm for heterogeneous services in OFDM wireless networks [C]// Proc of ICCAS. 2009: 48-52.