

基于密度的空间聚类与霍夫变换相结合的欠定盲源分离混合矩阵估计^①

孙洁娣^{②*} 李玉霞^{*} 温江涛^{**} 闫盛楠^{*}

(^{*} 燕山大学信息科学与工程学院 秦皇岛 066004)

(^{**} 河北省测试计量技术及仪器重点实验室 燕山大学 秦皇岛 066004)

摘要 为解决欠定盲源分离中混合矩阵估计问题,提出了一种基于密度的空间聚类与霍夫变换相结合的混合矩阵估计算法。该算法首先通过基于相角的单源时频点处理增强信号的稀疏性,然后针对 K-means 算法需预先设置聚类个数的问题,采用基于密度的空间聚类算法对单源点进行自动分类以估计源信号个数,进而估计得到混合矩阵。为提高估计混合矩阵的精度,采用霍夫变换方法修正聚类中心。基于密度的空间聚类算法的运用也克服了霍夫变换峰值簇拥问题。实验结果表明,基于密度的空间聚类与霍夫变换相结合的方法能在源信号数量未知情况下准确估计混合矩阵,且估计精度高于 K-means 算法和基于密度的空间聚类算法。

关键词 欠定盲源分离(UBSS),混合矩阵估计,霍夫变换,基于密度的空间聚类,K-means

0 引言

在源信号的先验知识未知的情况下,仅利用观测到的混叠信号来恢复源信号的波形的过程称为盲源分离(blind source separation, BSS)。BSS 已广泛应用于生物医学、图像处理、语音信号处理等领域。在实际应用中,源信号的数量往往会超出传感器数量,称此类情况下的盲源分离为欠定盲源分离(underdetermined BSS, UBSS)。针对 UBSS 问题,目前研究比较多的为稀疏分量分析(sparse component analysis, SCA)方法,该方法利用信号的稀疏特性进行混合矩阵估计,然后恢复源信号,因此混合矩阵估计的准确程度对于源信号的恢复很重要。

聚类算法与势函数算法是解决 UBSS 问题常用

的混合矩阵估计方法。文献[1]研究了势函数法估计混合矩阵,这是较早解决 UBSS 问题的算法,但是此方法的参数选择缺乏理论指导。文献[2]将霍夫变换方法引入到混合矩阵估计中,但源信号稀疏性较低时易出现峰值簇拥。为解决此问题,文献[3]将 K-means 算法与霍夫变换相结合,提出了 K-Hough 方法,但 K-means 算法具有对初始聚类中心敏感并需已知源信号个数^[4,5]的缺点。而基于密度的空间聚类算法^[6],能克服 K-means 聚类算法的缺点,但是参数选择是个难点。针对稀疏性^[7-9]较低的信号,出现了单源点^[10-12]检测方法,此类方法虽能增强信号稀疏性^[13,14],但是存在方法复杂、不易符合条件等问题。本文针对 K-means 聚类方法估计混合矩阵时需预先设定源信号数量,且依赖初始中心选择的不足和信号稀疏性较弱的情况进行了研

^① 国家自然科学基金(51204145),河北省自然科学基金(E2013203300),河北省高等学校自然科学研究青年基金(Q2012087)和秦皇岛市科学技术研究与发展计划(201302A033)资助项目。

^② 女,1975 年生,副教授;研究方向:盲源分离理论及应用,复杂振动信号处理方法;E-mail:wjtsjd@163.com
(收稿日期:2014-10-14)

究,提出了一种将基于密度的空间聚类与霍夫变换相结合的混合矩阵估计算法。该算法首先采用基于相角的单源时频点检测方法增强信号稀疏性,然后对单源点采用基于类度的空间聚类算法进行自动分类,类簇个数即为源信号个数,分别对每类数据求其聚类中心进而估计混合矩阵。为提高混合矩阵估计精度,本文研究了基于霍夫变换的聚类中心修正算法,解决了霍夫变换的峰值簇拥问题,同时修正了聚类中心。

1 单源点检测增强信号稀疏性

忽略噪声影响的线性瞬时混合欠定盲源分离(UBSS)数学模型可以表示为

$$\begin{aligned} \mathbf{x}(t) &= \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_m(t) \end{bmatrix} = \begin{bmatrix} a_{11}a_{12}\cdots a_{1n} \\ a_{21}a_{22}\cdots a_{2n} \\ \vdots \\ a_{m1}a_{m2}\cdots a_{mn} \end{bmatrix} \begin{bmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_n(t) \end{bmatrix} \\ &= \mathbf{As}(t), \quad t = 1, 2, \dots, T \end{aligned} \quad (1)$$

式中 $\mathbf{x}(t)$ 为 m 个观测信号; $\mathbf{A} \in \mathbb{R}^{m \times n}$ 为混合矩阵; $\mathbf{s}(t)$ 为 n 个源信号且 $m < n$ 。源信号为稀疏信号时绝大多数采样点取值接近于零,少数采样点的取值偏离零。即在同一时刻 t_k 处通常只有一个源信号取值较大,则:

$$\frac{x_1(t_k)}{a_{1i}} = \frac{x_2(t_k)}{a_{2i}} = \dots = \frac{x_m(t_k)}{a_{mi}} \quad (2)$$

此时 $\mathbf{x}(t)$ 分布在过原点的直线上,直线的方向即为混合矩阵的列向量,因此稀疏信号具有线性聚类特征。

多数信号在时域稀疏性较弱,因此需要在变换域中进行稀疏增强处理,本文采用短时傅立叶变换(STFT),则式(1)的时频域表达形式为

$$\mathbf{X}(t, k) = \sum_{i=1}^n \mathbf{a}_i S_i(t, k) \quad (3)$$

式中 $\mathbf{X}(t, k)$ 与 $S_i(t, k)$ 分别表示观测信号与第 i 个

源信号的 STFT 系数。

通常信号稀疏性较强时,观测信号散点图呈现出清晰的直线方向,反之观测信号的方向性不清晰,影响混合矩阵的估计。为解决此问题,本文研究了用基于相角的单源时频点检测方法增强信号稀疏性。

将时频域中任一时频点上仅有一个源信号存在的点视为有效时频点,称之为单源点,假设某时频点 (t_1, k_1) 上只有信号 s_1 存在,则式(3)为

$$\mathbf{X}(t_1, k_1) = \mathbf{a}_1 S_1(t_1, k_1) \quad (4)$$

式中 $\mathbf{X}(t_1, k_1)$ 和 $S_1(t_1, k_1)$ 均为复数形式,分别对式(4)两边取相角可得

$$\text{angle}\{\mathbf{X}(t_1, k_1)\} = \text{angle}\{S_1(t_1, k_1)\} \quad (5)$$

式中 $\text{angle}\{\cdot\}$ 代表求复数的相角,由式(4)可得观测信号各分量的相角与 $S_1(t_1, k_1)$ 相角一致,即观测信号虚部与实部比值相同。假设在时频点 (t_2, k_2) 上有多个源信号 s_1 和 s_2 存在,则此时式(4)为

$$\mathbf{X}(t_2, k_2) = \mathbf{a}_1 S_1(t_2, k_2) + \mathbf{a}_2 S_2(t_2, k_2) \quad (6)$$

对式(6)两边取相角可得

$$\begin{aligned} \text{angle}\{\mathbf{X}(t_2, k_2)\} &= \arctan \frac{I\{\mathbf{X}(t_2, k_2)\}}{R\{\mathbf{X}(t_2, k_2)\}} \\ &= \arctan \frac{\mathbf{a}_1 I\{S_1(t_2, k_2)\} + \mathbf{a}_2 I\{S_2(t_2, k_2)\}}{\mathbf{a}_1 R\{S_1(t_2, k_2)\} + \mathbf{a}_2 R\{S_2(t_2, k_2)\}} \end{aligned} \quad (7)$$

式中 $R\{\cdot\}$ 和 $I\{\cdot\}$ 分别表示取实部和虚部。此时若观测信号各分量相角相同,即式(7)中观测信号各分量虚部与实部比值相同,则有

$$\frac{I\{S_1(t_2, k_2)\}}{R\{S_1(t_2, k_2)\}} = \frac{I\{S_2(t_2, k_2)\}}{R\{S_2(t_2, k_2)\}} \quad (8)$$

即必有 $\frac{I\{X_i\}}{R\{X_i\}} = \frac{I\{X_j\}}{R\{X_j\}}$, $i \neq j$ 且 $1 \leq i, j \leq m$, 但实际中式(8)成立概率极低,考虑可实现性,设阈值 $\varepsilon \in (0, 1)$, 可得单源点检测公式

$$\left| \frac{I\{X_i\}}{R\{X_i\}} - \frac{I\{X_j\}}{R\{X_j\}} \right| < \varepsilon \quad (9)$$

为了克服低能量时频点的影响,提高混合矩阵估计精度,利用式

$$\|X(t, k)\| > \lambda \cdot \max \|X(t, k)\| \quad (10)$$

过滤低能量点。式中 $\lambda \in (0, 1)$ 。经过上述处理增强了信号稀疏性, 观测信号在散点图中将呈现清晰的方向性, 进而便于估计混合矩阵。

2 基于密度的空间聚类与霍夫变换相结合的混合矩阵估计

传统聚类算法估计混合矩阵时, 均需已知源信号个数。针对传统算法的不足, 本文提出基于密度的空间聚类与霍夫变换相结合的混合矩阵估计算法, 该算法能在未知源信号个数的情况下估计出混合矩阵。

2.1 基于密度的空间聚类算法的混合矩阵估计

基于密度的空间聚类算法, 可以自动确定类簇的个数和估计源信号数量, 然后寻找聚类中心估计混合矩阵。该算法的主要影响因素包括类的半径 Eps 及类内最小数据对象个数 $MinPts$, 该算法涉及到的主要概念如下:

定义 1(Eps 邻域) 对于样本集合 D 中任意一点 p , 以 p 为圆心, 以 Eps 为半径的球形区域称为 p 的 Eps 邻域。

定义 2(核心对象) 如果 p 的 Eps 邻域内的样本点数大于等于 $MinPts$, 则称 p 为核心对象。

定义 3(直接密度可达) 如果点 q 在核心对象 p 的 Eps 邻域内, 则 q 从 p 直接密度可达。

定义 4(密度可达) 集合 D 中若有数据序列 p_1, p_2, \dots, p_n 且 $p_1 = p, p_n = q$, 若 p_{i+1} 是从 p_i 直接密度可达, 则称 q 从 p 密度可达。

定义 5(密度相连) 集合 D 中若存在一个数据对象 o 使得 p 和 q 都是从 o 密度可达, 那么 q 与 p 密度相连。

定义 6(聚类) 给定 Eps 和 $MinPts$, 基于密度可达性的最大密度相连对象的集合称为簇, 也称聚类, 不属于任何聚类的数据点为干扰点。

基于密度的空间聚类算法将聚类定义为密度可

达的数据对象组成的集合。该算法的具体过程为: 从数据集合 D 中任选一点 p , 查找关于 Eps 和 $MinPts$ 的邻域, 若 p 为核心对象, 则 p 邻域内所有对象为一个聚类, 否则标记 p 为干扰点; 然后寻找邻域中每个对象的密度可达的点, 来扩展所在的类。如果类不能进一步扩大, 则选取未被标记的对象, 执行同样的操作, 直到所有对象均被标记。

由此可见参数 Eps 及 $MinPts$ 决定了聚类结果的优劣, 并且参数全局唯一, 传统选择参数方法是利用 K-dist 图粗略估算 Eps , K 通常取 4, 因而误差较大。针对此类参数选择的不足, 本文通过研究网格算法^[6] 与基于密度的空间聚类算法的等效规则改进参数选择方法。

对于单个单元来说, 两种算法的核心思想均为: 一定容积的单元内包含超过给定数目的数据点, 则该单元为密集单元, 而该单元的中心对象为核心对象。但不同的是网格算法中的单元为 m 维矩形, 并将所有对象作为一体; 而基于密度的空间聚类中的单元为 m 维球形, 并对每个对象构造一个单元。利用式(10)得到的 N 个时频点组成样本集合 D , 根据相同容积内对象数目相同的思想, 针对单个单元进行等效可得

$$\frac{MinPts}{V_E} = \frac{N}{V} \quad (11)$$

式中 V 和 V_E 与数据维数有关, V 表示能够包含集合 D 的 m 维矩形的容积; V_E 表示 m 维球形的容积; 由此可得 Eps 表达式:

$$\left\{ \begin{array}{l} \text{二维: } Eps = \left(\frac{MinPts \times V}{\pi \times N} \right)^{\frac{1}{2}} \\ \text{三维: } Eps = \left(\frac{3 \times MinPts \times V}{4 \times \pi \times N} \right)^{\frac{1}{3}} \end{array} \right. \quad (12)$$

由式(12)确定 Eps , 并进行基于密度的空间聚类算法, 聚类后数据集自动被分类, 所得类别数即为源信号个数。但是该算法并未寻找聚类中心, 本文采用传统求数据中心点的方法, 即分别对每类数据求其平均值得聚类中心, 经过上述处理得仅采用基于密度的空间聚类算法估计的混合矩阵。但由于该算法

无法确定聚类中心,因此单一方法估计的混合矩阵精度不高,需要进一步修正聚类中心,减小混合矩阵估计的误差。本研究引入霍夫变换来修正聚类中心。

2.2 基于霍夫变换的聚类中心修正

霍夫变换(Hough transform, HT)是实现从图形空间到参数空间转化的映射方法,应用在混合矩阵估计中的基本思想为:将原始空间中共线的点通过某种坐标变换转化为参数空间里相交的曲线。由于稀疏源信号具有线性聚类特点,因此观测信号进行HT之后在变换空间形成一系列相交的曲线,统计曲线的交点并进行累加形成为局部极大值点,通过检

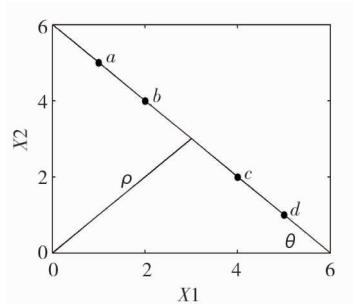
测这些局部极大值点,估计直线方向,进而估计混合矩阵。

假设原图形空间中过点 (x_1, x_2) 的某一直线为 $x_2 = ax_1 + b$,经过坐标变换映射到变换空间 $\rho - \theta$ 中的表达式为

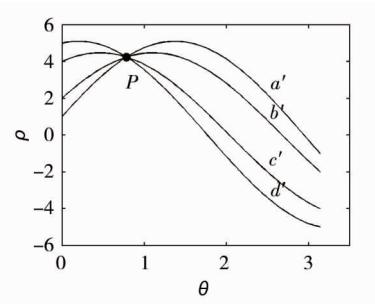
$$\rho = x_1 \sin\theta + x_2 \cos\theta \quad (13)$$

式(13)为点 (x_1, x_2) 的霍夫变换,其中 θ 为直线与 x_1 轴的夹角。

具体HT原理如图1(a)图形空间中同一直线上的各点,经HT之后在参数空间图1(b)中相交于同一点P,P即为局部极大值点,通过检测P的坐标进行直线方向估计。



(a) 图形空间直线图



(b) 参数空间曲线图

图1 HT 原理图

由于信号具有线性聚类特性,观测信号数据点主要集中在n条直线上,直线向量l表示为

$$l = \begin{bmatrix} \sin\theta_1 & \sin\theta_2 & \sin\theta_3 & \cdots & \sin\theta_{m-1} \\ \cos\theta_1 & \sin\theta_2 & \sin\theta_3 & \cdots & \sin\theta_{m-1} \\ \cos\theta_2 & \sin\theta_3 & \cdots & \sin\theta_{m-1} \\ \vdots & & & & \\ \cos\theta_{m-2} & & & \sin\theta_{m-1} \\ \cos\theta_{m-1} & & & & \end{bmatrix} \quad (14)$$

式中 $\|l\| = 1, (\theta_1, \theta_2, \dots, \theta_{m-1}) \in [0, \pi]^{m-1}$ 。将直线转化到参数空间可表示为

$$\rho = l^T x \quad (15)$$

将经基于密度的空间聚类得到的聚类结果分别进行

霍夫变换,通过检测局部极大值出现位置进行聚类中心修正,弥补了基于密度的空间聚类算法估计精度较差的缺陷。霍夫变换极大值计算时容易产生峰值簇拥问题,采用基于密度的空间聚类算法预先确定类别个数则可以解决这个问题。

本文研究的将于基于密度的空间聚类与霍夫变换相结合的混合矩阵估计算法的步骤如下:

步骤1 利用短时傅立叶变换(STFT)将观测信号变换到时频域。

步骤2 通过式(9)检测单源时频点,增强信号稀疏性,利用式(10)去除低能量点,并将观测数据对称到上半单位超球面上。

步骤3 利用式(12)设置Eps,采用基于密度的空间聚类算法处理观测数据,估计源信号个数,同时

初步估计混合矩阵。

步骤 4 设置分辨率参数 β , 将 θ 分成 β 个单元, 构成累加数组, 对步骤 3 中所得每一类数据, 分别利用式(14)、(15)进行霍夫变换, 寻找局部极大值中最大值的坐标参数, 代入式(14)得直线向量(即混合矩阵列向量), 从而可得修正的混合矩阵 A 估计值。

3 实验结果及分析

3.1 算法性能评价准则

为了评价本文算法的估计精度, 利用归一化均方误差(normalized mean square error, NMSE)与偏离角度两种指标评价混合矩阵估计性能。

归一化均方误差表达式

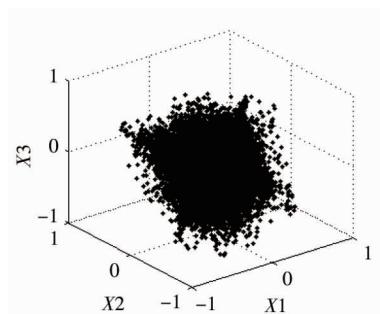
$$NMSE = 10 \log_{10} \left(\frac{\sum_{i=1}^m \sum_{j=1}^n (\hat{a}_{ij} - a_{ij})^2}{\sum_{i=1}^m \sum_{j=1}^n a_{ij}^2} \right) \quad (16)$$

式中 m, n 分别表示混合矩阵 A 的行数和列数, \hat{a}_{ij} 和 a_{ij} 分别为估计的混合矩阵 \hat{A} 及原混合矩阵 A 的第 i 行 j 列元素。NMSE 越小, 则估计的混合矩阵性能越好。

偏离角度表达式为

$$\text{ang}(\mathbf{a}, \hat{\mathbf{a}}) = \frac{180}{\pi} \arccos \left(\frac{\langle \mathbf{a}, \hat{\mathbf{a}} \rangle}{\|\mathbf{a}\| \cdot \|\hat{\mathbf{a}}\|} \right) \quad (17)$$

式(17)表示 $\hat{\mathbf{a}}$ 与 \mathbf{a} 对应的列向量之间的夹角。其中 \mathbf{a} 表示 \mathbf{a} 的列向量, $\hat{\mathbf{a}}$ 表示 $\hat{\mathbf{a}}$ 中与 \mathbf{a} 对应的列向量, 偏角越小, 则 \hat{A} 的性能越好。



(a) 时域散点图

3.2 实验结果与分析

为验证本文算法的有效性, 进行了实验仿真与分析。使用的仿真软件为 MATLAB R2010a, 采用的源信号为文献[1]中的 FourVoices 语音信号, 采样频率为 8kHz, 将源信号中的 4 路信号混合为 3 路观测信号, 即 $m = 3, n = 4$, 随机选择混合矩阵 A 为:

$$A = \begin{bmatrix} 0.7110 & 0.2883 & -0.6712 & 0.4539 \\ 0.1773 & 0.9421 & 0.6480 & 0.3956 \\ -0.6817 & 0.1740 & 0.3580 & 0.7990 \end{bmatrix}$$

混合所得的 3 路观测信号如图 2 所示。

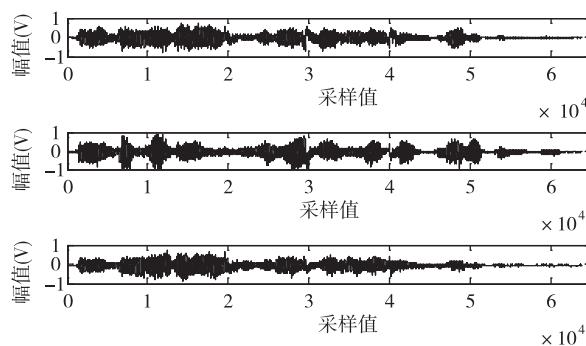
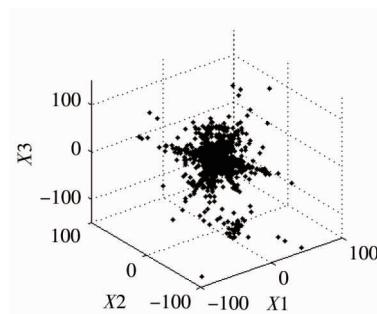


图 2 观测信号时域波形图

观测信号时域与时频域散点图如图 3 所示。

由图 3(b)可见观测信号方向性不清晰, 因此采用基于相角的单源时频点检测方法增强信号稀疏性, 使其呈现出良好的方向性, 通常参数 ε 根据经验^[10]取值范围为 0.01 ~ 0.1, 本文取 $\varepsilon = 0.05$, 则单源点检测处理后所得散点图如图 4(a)。设置 $\lambda = 0.1$ 去除低能量点, 将观测信号对称到上半单位超球面内得到归一化散点图如图 4(b)。



(b) 时频域散点图

图 3 观测信号时域与频域散点图

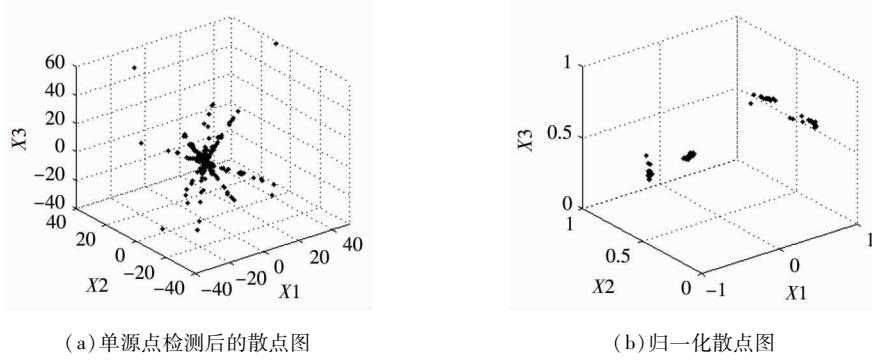


图 4 增强观测信号稀疏性后的散点图

由图 4 可知,经单源点检测处理后,观测信号方向性变得比较清晰。将归一化所得的数据集进行基于密度的空间聚类算法,通常取参数 $MinPts = 4$ 。本实验采用基于密度的空间聚类算法得到的类别数为 4,与图中数据归一化之后呈现的类别数正好相等,

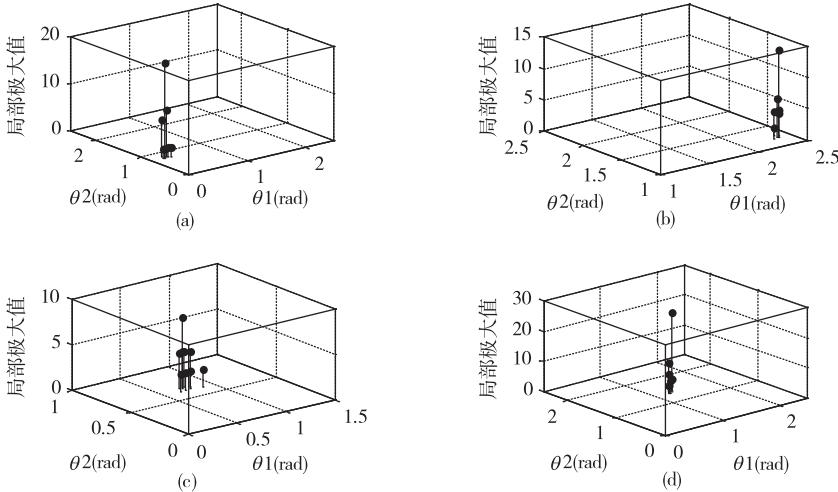


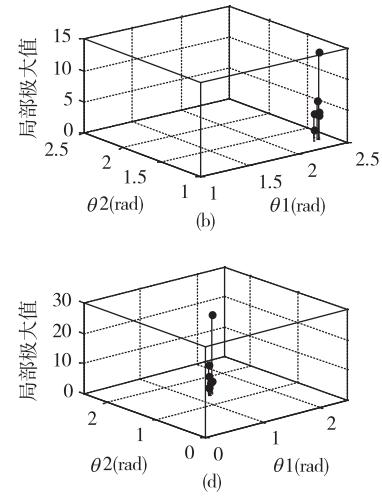
图 5 基于密度的空间聚类与霍夫变换处理后所得局部极大值图

图 5 中可得此时统计的是每一类内的局部极大值,而类与类之间互不影响,因此可以避免霍夫变换的全局峰值簇拥问题。

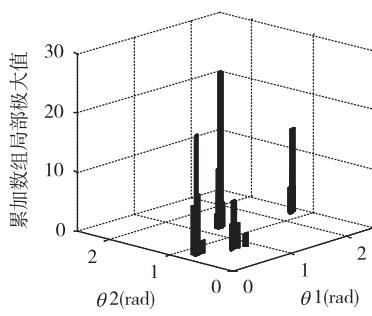
为了说明基于密度的空间聚类算法与霍夫变换算法结合的必要性,下面将图 4(b)得到的归一化数据直接进行霍夫变换,统计局部极大值估计混合矩阵,得到的局部极大值分布图如图 6(a)所示,为了更加清晰地统计局部极大值的幅值,将三维图投影到二维空间中如图 6(b)所示。

由图 6(b)可以得出,将归一化数据直接进行霍

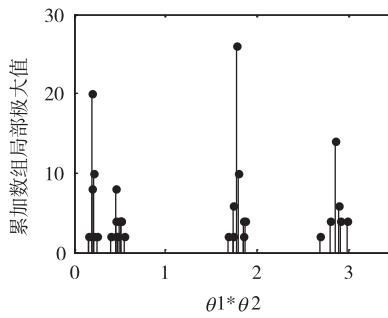
从而估计出源信号个数即为 4。为了克服聚类中心不易确定的问题,分别对各类进行霍夫变换以修正聚类中心。结合实际情况取 $\beta = 180$,则每一类经霍夫变换得到的局部极大值分布图如图 5 所示。



夫变换,导致全局峰值簇拥问题,局部极大值的幅值相互间形成了干扰,无法准确估计混合矩阵。而本文提出的基于密度的空间聚类与霍夫变换相结合的混合矩阵估计算法,聚类之后可以消除峰值簇拥问题。对比仅利用基于密度的空间聚类算法得到的聚类中心与引入霍夫变换修正后的聚类中心,为了清晰对比,将三维散点图投影到 $X2 - X3$ 平面内,分别用虚线与实线标注聚类中心的横纵坐标,如图 7(a)所示,分析并代入式(16)计算所得各个聚类中心的精度,详细性能参数如图 7(b)所示。

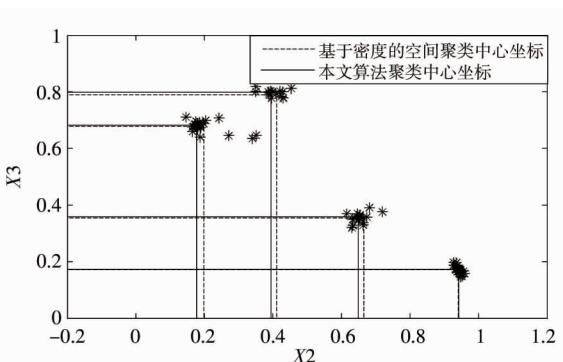


(a) 局部极大值分布图

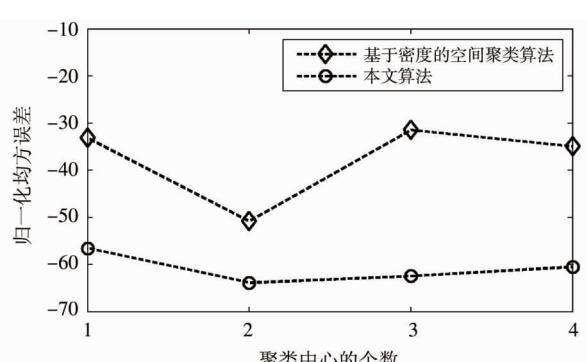


(b) 二维空间的极大值分布图

图 6 霍夫变换处理后的局部极大值分布图



(a) 聚类中心坐标对比图



(b) 聚类中心的性能比较

图 7 霍夫变换处理前后聚类中心的对比

由图 7 可得, 经霍夫变换修正后的聚类中心的归一化均方误差明显小于未修正前, 因此霍夫变换算法能够修正聚类中心, 提高聚类中心的估计精度, 基于密度的空间聚类与霍夫变换相结合的混合矩阵估计算法具有重要意义。

经基于密度的空间聚类分类后, 分别对每类进行霍夫变换, 在每一类内多个局部极大值中取最大值, 求其所对应的坐标参数利用式(14)估计直线所对应的列向量, 从而得到 A 的估计矩阵 \hat{A}_1 为

$$\hat{A}_1 = \begin{bmatrix} 0.7096 & 0.2879 & -0.6716 & 0.4542 \\ 0.1769 & 0.9418 & 0.6485 & 0.3948 \\ 0.6820 & 0.1736 & 0.3584 & 0.7986 \end{bmatrix}$$

为了说明本文算法的有效性与准确性, 下面对比仅采用基于密度的空间聚类算法和仅采用 K-means 算法以及 K-Hough 算法分别估计所得的混合矩阵。其中仅采用基于密度的空间聚类算法估计所

得混合矩阵 \hat{A}_2 为。

$$\hat{A}_2 = \begin{bmatrix} 0.7059 & 0.2888 & -0.6672 & 0.4500 \\ 0.1983 & 0.9417 & 0.6536 & 0.4009 \\ 0.6777 & 0.1712 & 0.3550 & 0.7969 \end{bmatrix}$$

利用传统 K-means 聚类算法所得的混合矩阵 \hat{A}_3 为

$$\hat{A}_3 = \begin{bmatrix} 0.7059 & 0.2888 & -0.6513 & 0.4515 \\ 0.1983 & 0.9417 & 0.6652 & 0.4107 \\ 0.6777 & 0.1712 & 0.3537 & 0.7897 \end{bmatrix}$$

通过 K-Hough 算法所得估计矩阵 \hat{A}_4 为

$$\hat{A}_4 = \begin{bmatrix} 0.7096 & 0.2879 & -0.6601 & 0.4610 \\ 0.1769 & 0.9418 & 0.6601 & 0.3968 \\ 0.6820 & 0.1736 & 0.3584 & 0.7986 \end{bmatrix}$$

分析对比几种算法的混合矩阵估计精度, 分别将估计的混合矩阵代入式(16), 计算可得仅采用基于密度的空间聚类算法所估计的 \hat{A}_2 的 NMSE 为

-38.2753dB,仅通过 K-means 算法所得的 $\hat{\mathbf{A}}_3$ 的 NMSE 为 -34.1992dB,而通过 K-Hough 算法估计的 $\hat{\mathbf{A}}_4$ 的 NMSE 为 -40.9120dB,采用本文算法得到的 $\hat{\mathbf{A}}_1$ 的 NMSE 为 -59.9163dB。

由以上几种不同算法估计矩阵的 NMSE 可知:采用传统 K-means 算法估计混合矩阵精度较低,结合霍夫变换之后的 K-Hough 算法虽然提升了混合矩阵估计精度,但是精度仍不够高,并且需已知源信

号个数;采用基于密度的空间聚类算法能够克服 K-means 算法要求源信号个数已知的限制,但混合矩阵精度仍然较低,而结合霍夫变换算法后,能够修正基于密度的空间聚类算法的聚类中心,提高了混合矩阵估计精度。

为进一步分析并计算所得混合矩阵的估计精度,根据式(17)计算估计的混合矩阵与原始矩阵偏离角度的结果,如表 1 所示。

表 1 估计的 $\hat{\mathbf{A}}$ 与初始 \mathbf{A} 的偏角对比 (°)

对比算法	分别与混合矩阵对应列向量之间的夹角			
	$ang(\mathbf{a}_1, \hat{\mathbf{a}}_1)$	$ang(\mathbf{a}_2, \hat{\mathbf{a}}_2)$	$ang(\mathbf{a}_3, \hat{\mathbf{a}}_3)$	$ang(\mathbf{a}_4, \hat{\mathbf{a}}_4)$
基于密度的空间聚类算法	1.2522	0.1594	0.4304	0.3885
K-means 算法	1.2522	0.1594	1.5183	1.0169
K-Hough 算法	0.0694	0.0251	0.9407	0.3637
本文算法	0.0694	0.0251	0.0096	0.0458

由表 1 可得几种算法中,K-means 算法、基于密度的空间聚类算法偏离角度较大,K-Hough 偏离角度虽然偏小,但始终受源信号个数限制,而本文算法所得的估计矩阵中每一列的偏离角度均是最小,估计的混合矩阵精度更高,与通过 NMSE 分析所得结论一致,进一步验证了本文算法的有效性与准确性。

4 结 论

为增强信号的稀疏性,需用基于相角的单源点检测所在短时傅立叶变换(STFT)变换域中增强观测信号的方向性,利用基于密度的空间聚类算法进行聚类,可以自动确定类别的个数(类别数即为源信号个数),克服传统 K-means 聚类算法估计混合矩阵需要假设源信号数目已知的不足;引入霍夫变换修正基于密度的空间聚类算法的聚类中心,提高混合矩阵估计精度。实验结果表明,相对于 K-means 聚类算法与基于密度的空间聚类算法以及 K-Hough 算法,本文所提出的方法较大程度能够提高

混合矩阵的估计精度。

参 考 文 献

- [1] Bofill P,Zibulevsky M.Underdetermined blind source separation using sparse representations. *Signal Processing*, 2001,81(11):2353-2362
- [2] Shindo H,Hirai Y.Blind source separation by a geometrical method. In: Proceedings of the International Joint Conference on Neural Networks (IJNN), Honolulu, USA, 2002. 1109-1114
- [3] 付宁,彭喜元. K-Hough 欠定盲信道估计算法. *电子测量与仪器学报*,2008,22(5):63-67
- [4] Cui Z T,Jian K. A new elgorithm to estimate mixing-matrix of underdetermined blind signal separation. In: Proceedings of the 8th International Conference on Computational Intelligence and Security (CIS), Guangzhou, China, 2012. 374-377
- [5] Xie S L,Yang L,Yang J M, et al. Time-frequency approach to underdetermined blind source separation. *Neural Networks and Learning Systems, IEEE Transactions on*,

2012,23(2):306-316

- [6] Jiang H , Li J , Yi S H , et al. A new hybrid method based on partitioning-based DBSCAN and ant clustering. *Expert Systems With Applications*, 2011, 38(8):9373-9381
- [7] Zhou G X , Yang Z Y , Xie S L , et al. Mixing matrix estimation from sparse mixtures with unknown number of sources. *IEEE Transactions on Neural Networks*, 2011, 22(2):211-221
- [8] Peng D Z , Xiang Y . Underdetermined blind sources separation based on relaxed sparsity condition of sources. *IEEE Transactions on Signal Processing*, 2009, 57(2):809-814
- [9] Bofill P. Identifying single source data for mixing matrix estimation in instantaneous blind source separation. In: Proceedings of the 18th International Conference on Artificial Neural Networks (ICANN 2008) , Prague, Czech Republic, 2008. 759-767

- [10] Reju V G , Koh S N , Soon I Y . An algorithm for mixing matrix estimation in instantaneous blind source separation. *Signal Processing*, 2009, 89(9):1762-1773
- [11] Dong T B , Lei Y K , Yang J S . An algorithm for underdetermined mixing matrix estimation. *Neurocomputing*, 2013, 104(15):26-34
- [12] Thiagarajan J J , Ramamurthy K N , Spanias A . Mixing matrix estimation using discriminative clustering for blind source separation. *Digital Signal Processing*, 2013, 23(1):9-18
- [13] Rhabi M E , Fenniri H , Keziou A , et al. A robust algorithm for convolutive blind source separation in presence of noise. *Signal Processing*, 2013, 93(4):818-827
- [14] Syed M N , Georgiev P G , Pardalos P M . A hierarchical approach for sparse source Blind Signal Separation problem. *Computers & Operations Research*, 2014, 41:386-398

Mixing matrix estimation using density based spatial clustering combined with Hough Transform in underdetermined blind source separation

Sun Jiedi * , Li Yuxia * , Wen Jiangtao ** , Yan Shengnan *

(* School of Information Science and Engineering, Yanshan University, Qinhuangdao 066004)

(** Key Laboratory of Measurement Technology and Instrumentation of HeBei Province , Yanshan University , Qinhuangdao 066004)

Abstract

A method using the combination of density based spatial clustering and Hough transform is proposed to solve the mixing matrix estimation problem in underdetermined blind source separation. The method firstly conducts the single source point processing in the time-frequency domain based on phase angle to improve the signal sparsity, and then, to overcome the K-means algorithm's restriction of giving the cluster number in advance, uses the density based spatial clustering algorithm to automatically classify single resource points to estimate the source signal number, and then estimates the mixing matrix. To improve the mixing matrix estimation accuracy, the Hough transform is used to modify the clustering center. Moreover, the use of the density based spatial clustering algorithm can solve the peak clustering of Hough transform. The simulation results show that the proposed method using the density based spatial clustering and Hough transform can accurately estimate mixing matrix when the source signal number is unknown, and its estimation accuracy is higher than the K-means method and the density based spatial clustering algorithm.

Key words: underdetermined blind source separation(UBSS), mixing matrix estimation, Hough transform, density based spatial clustering, K-means