

## 一种基于奇异值分解的解相干算法

季正燕\* 陈辉 张佳佳 李帅 陆晓飞

(空军预警学院重点实验室 武汉 430019)

**摘要:** 该文针对稀疏重构解相干问题,利用接收数据奇异值分解(SVD)后的大特征值对应的特征矢量,提出一种改进解相干方法。该方法通过迭代这一特征矢量来重构角度,无需知道信号源的数目,即可准确重构角度信息,实现解相干。相对于经典SVD算法,所提算法运算速度更快,稀疏重构效果更优。理论分析和仿真结果都验证了算法的良好性能。

**关键词:** 信号处理; 稀疏重构; 解相干; 奇异值分解

**中图分类号:** TN911.7

**文献标识码:** A

**文章编号:** 1009-5896(2017)08-1913-06

**DOI:** 10.11999/JEIT161157

## Decorrelation Algorithm Based on Singular Value Decomposition

JI Zhengyan CHEN Hui ZHANG Jiajia LI Shuai LU Xiaofei

(Key Laboratory, Air Force Early Warning Academy, Wuhan 430019, China)

**Abstract:** To solve the problem of coherent sources using sparse reconstruction method, this paper proposes an improved method for solving coherent sources using the eigenvectors corresponding to the largest eigenvalues after Singular Value Decomposition (SVD) decomposition of received data. The method reconstructs the angle by iterating the feature vector, and reconstructs the angle information accurately without knowing the number of the signal source. Compared with the classical SVD algorithm, the operation speed is faster, and the sparse reconstruction effect is better. Theoretical analysis and simulation results verify the good performance of the algorithm.

**Key words:** Signal processing; Sparse reconstruction; Decoherence; Singular Value Decomposition (SVD)

### 1 引言

波达方向(Direction Of Arrival, DOA)估计一直以来都是阵列信号处理领域的一个热点问题,在雷达、导航、天文观测、地震检测等众多领域有着广泛应用,2016年9月份投入启用的500 m口径球面射电天文望远镜——FAST,也是一种大型的天线阵列,可以利用空间谱估计算法从太空微弱的信号中获取信号的方向信息。当前国内外将稀疏重构应用到DOA估计领域的一个重要问题是对相干信号的处理。传统的空间谱估计算法解相干性能较差,必须进行相应的预处理(目前主要有平滑处理和矩阵重构两类方法),而且快拍数大于2~3倍系统自由度,这些应用条件极大地约束着解相干方面的应用。在实际阵列信号DOA估计中,由于物体反射、折射、地物遮挡和有源干扰等影响,观测的空间中仅存在可计的相干信号源,可以认为目标在空域上是稀疏的,而稀疏重构<sup>[1-9]</sup>正是利用信号在空域上的稀疏性实现对入射信号角度的估计,且其对相干信号并

不敏感,可以直接对接收数据进行处理,为解相干信号开拓了另外一个思路。

当前,基于稀疏重构对相干信号的DOA估计问题,SVD类算法是一种重要的简化计算的方法。最早的应用是基于L1范数的L1-SVD算法<sup>[10]</sup>,该算法大大减少计算量、提高DOA估计性能,但仍存在必须对信号源数已知的缺点,而且在解相干性能不是最优的。为了克服L1-SVD算法对信源数必须已知的限制,基于数据协方差的SPICE算法<sup>[11]</sup>和SRACV算法<sup>[12]</sup>被提出,但同时增加了运算量。文献[13]利用协方差矩阵特征分解的特征值之间的显著差异确定信号源数,在高信噪比的情况下效果较好,但信噪比小时特征值差异并不明显。而后研究人员将SVD与贪婪类算法结合<sup>[14,15]</sup>,进一步提高了运算速度,但L1-SVD算法存在的根本问题还是没有解决。

本文针对上述问题,从相干信号源这一角度出发,对相干信号数据秩亏损进行全面的分析,利用最大特征值对应的特征向量矩阵进行稀疏重构,解相干精度更高、运算速度更快,进而提出一种改进的解相干算法,最后仿真分析该算法的解相干性能,仿真结果验证了该算法的有效性。

## 2 稀疏重构框架下的阵列 DOA 估计模型

为简便起见, 本文采用等距均匀线阵为模型, 结构如图 1 所示,  $M$  个阵元均匀分布在间隔为  $d$  的线阵上, 设窄带远场相干信号入射方向为  $\theta$ , 定义为相干入射信号与  $x$  轴法线方向沿顺时针的夹角, 线阵接收角度的范围为  $[-90^\circ, +90^\circ]$ 。本文主要讨论解相干, 信号皆为相干信号, 此后不再赘述。

图 1 中圆代表潜在信号, 实心圆代表真实信号。




图 1 均匀线阵模型

在稀疏重构的框架下考虑  $N$  个潜在窄带远场信号入射到  $M$  阵元的线阵上, 其中有  $T$  个为真实存在信号 ( $T \ll N$ ), 以最左侧阵元作为参考点,  $M$  个阵元接收的  $Q$  次快拍数据表示为

$$\mathbf{X} = \mathbf{A}\mathbf{S} + \mathbf{W} \quad (1)$$

其中,  $\mathbf{X}$  是  $M \times Q$  维数据矩阵,  $\mathbf{W}$  是  $M \times Q$  维噪声数据矩阵,  $\mathbf{S}$  是窄带远场信号的  $N \times Q$  维数据矩阵 ( $\mathbf{S}$  为  $T$  阶稀疏信号), 本文假设信号和噪声为相互独立的零均值平稳高斯的。 $\mathbf{A}$  是均匀线阵的  $M \times N$  维阵列流型矩阵, 且

$$\mathbf{A} = [\mathbf{a}(\theta_1), \mathbf{a}(\theta_2), \dots, \mathbf{a}(\theta_N)] \quad (2)$$

$$\mathbf{a}(\theta_k) = [e^{j\phi_{1k}}, e^{j\phi_{2k}}, \dots, e^{j\phi_{Mk}}] \quad (3)$$

$$\phi_{lk} = [2\pi d(l-1)/\lambda] \sin \theta_k \quad (4)$$

其中,  $\mathbf{a}(\theta_k)$  是  $M \times 1$  维的导向矢量,  $\lambda$  表示入射波波长,  $k$  为潜在信号源序号 ( $k = 1, 2, \dots, N$ ),  $l$  表示阵元序号 ( $l = 1, 2, \dots, M$ ),  $\theta_k$  表示第  $k$  个潜在信号源相对于法线方向的角度。

基于稀疏重构的 DOA 估计解相干问题就是利用一个或多个快拍的阵列接收数据  $\mathbf{X}$  得到真实信源的到达角度  $\theta_K$ ,  $K$  为真实存在信号的序号 ( $K = 1, 2, \dots, T$ ), 即由  $\mathbf{X}$  稀疏重构  $\mathbf{S}$ , 其本质是一个求解  $l_0$  范数约束下的最小化问题, 考虑噪声因素, 其优化函数为

$$\hat{\mathbf{S}} = \arg \min \|\mathbf{S}\|_0, \text{ s.t. } \|\mathbf{X} - \mathbf{A}\mathbf{S}\|_2 \leq \beta \quad (5)$$

其中,  $\beta$  是与噪声有关的参数。然而式(5)的求解是一个 NP-hard 问题。于是研究者们提出了一系列替

代算法, 主要有 3 种, 分别为贪婪类算法、凸优化类算法和贝叶斯类算法。其中, 最为实用也最有名的是贪婪迭代类算法。但经典贪婪迭代类算法要对所有快拍数据进行处理, 在贪婪迭代类算法模型上, SVD 可以大大减少运算量, 同时提高估计性能, 但同时存在致命的缺点——必须对信号源数已知。

## 3 利用数据最大特征向量解相干方法

### 3.1 算法描述

当阵列流型矩阵  $\mathbf{A}$  满足约束等容(RIP)条件时, 可通过求解数据矩阵  $\mathbf{X}$  来重构  $\mathbf{S}$ 。但数据矩阵  $\mathbf{X}$  有噪声分量  $\mathbf{W}$ , 使重构的效果恶化。

**定理** 无噪声情况下, 当所有信号源相干的时候, 数据矩阵的最大特征向量包含所有的角度信息, 该特征向量可以表示为

$$\mathbf{e} = \sum_{n=1}^K v_n \mathbf{a}(h_n) = \mathbf{A}\mathbf{V} \quad (6)$$

式中, 矩阵  $\mathbf{V}$  是 1 维的线性因子,  $\mathbf{e} = [e_1 \ e_2 \ e_3 \ \dots \ e_M]$ 。

**证明** 假设  $k$  个完全相干的一组信号,  $s_i = \lambda^i v_i s_0$ ,  $v_i$  中包含了幅度相位信息 ( $i = 1, 2, \dots, k$ ),  $\lambda^i$  为比例常数, 代入式(1)的无噪声形式:

$$\mathbf{X} = \mathbf{A}\mathbf{S} = \mathbf{A} \begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_k \end{bmatrix} = \mathbf{A}\lambda^i \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_k \end{bmatrix} s_0 = \mathbf{A}\lambda^i \mathbf{V} s_0 = \lambda^i \mathbf{e} s_0 \quad (7)$$

数据矩阵  $\mathbf{X}$  并不一定是方阵, 所以对其进行 SVD 分解:

$$\mathbf{X} = \mathbf{U}\mathbf{L}\mathbf{V}^H = [\mathbf{e} \ \mathbf{U}_{Q-1}] \mathbf{L}\mathbf{V}^H \quad (8)$$

其中,  $\mathbf{e}$  是最大特征值对应的信号子空间,  $\mathbf{U}_{Q-1}$  是其他特征值对应的子空间, 数据矩阵  $\mathbf{X}$  中  $\mathbf{e}$  对应的数据分量为

$$\mathbf{X}_e = \mathbf{U}\mathbf{L}\mathbf{D}_1 = \mathbf{X}\mathbf{V}\mathbf{D}_1, \quad \mathbf{D}_1 = [1 \ \mathbf{0}]^H \quad (9)$$

式中,  $\mathbf{0}$  为零矩阵, 化简式(9)可得  $\mathbf{X}_e = \lambda^i \mathbf{e}$ , 其中  $\lambda^i$  最大的特征值, 代入式(7)

$$\mathbf{X} = \frac{\lambda^i}{\lambda^i} \mathbf{X}_e s_0 = \frac{\lambda^i s_0}{\lambda^i} \mathbf{X}_e = \eta \mathbf{X}_e \quad (10)$$

由式(10)可知  $\mathbf{X}_e = \lambda^i \mathbf{e}$  包含了所有信号源的信息,  $\lambda^i$  是一个常数, 可以省去, 所以这个特征向量  $\mathbf{e}$  包含所有信源的角度信息。

证毕

以上谈论的是在无噪声情况下的对应关系, 但现实中是有噪声存在的。在有噪声影响时, 因为噪声为相互独立的零均值平稳高斯的, 所以特征值都会叠加由  $\mathbf{W}$  噪声分解的近似同等的噪声分量, 特征向量  $\mathbf{U}$  每一列向量同样会叠加近似同等的噪声分量, 大特征值对应 1 维特征向量  $\mathbf{e}$  仍然完全包含所

有信号, 利用  $\mathbf{e}$  进行稀疏重构可以改善解相干效果。

对数据矩阵进行奇异值分解得到最大特征值对应的特征矢量  $\mathbf{e}$ , 再用快速稀疏重构算法进行解相干, 相对经典 SVD 算法, 进一步减少了运算量, 而且无需对信号源数已知, 从而解决了上节末所述的亟待解决的难题。与经典正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法<sup>[16]</sup>不同, 本文算法只对最大特征值对应的特征矢量  $\mathbf{e}$  进行重构, 将  $\mathbf{A}$  中每一个列向量记作一个原子, 计算每个原子与特征向量  $\mathbf{e}_L$  的内积, 初始值  $\mathbf{e}_1 = \mathbf{e}$ ,  $L$  为迭代次数

$$\psi = \arg \max_{k=1,2,\dots,N} |\langle \mathbf{a}_k, \mathbf{e}_L \rangle| \quad (11)$$

每次迭代找出最大内积的角度, 即与  $\mathbf{e}_L$  最相关的原子对应的角度, 原子加入原子集合  $\mathbf{H}_L$ , 更新原子集合  $\mathbf{H}_L$  和原子序号索引集合  $\Phi_L$

$$\mathbf{H}_L = \mathbf{H}_{L-1} \cup \{\mathbf{a}_\psi\}, \quad \Phi_L = \Phi_{L-1} \cup \{\psi\} \quad (12)$$

得到原子集合  $\mathbf{H}_L$  后进行信号的逼近, 最常用的方法是最小二乘的方法, 设逼近的信号为  $\mathbf{S}_L$

$$\mathbf{S}_L = (\mathbf{H}_L^T \mathbf{H}_L)^{-1} \mathbf{H}_L^T \mathbf{e} \quad (13)$$

继而用逼近的信号为  $\mathbf{S}_L$  更新残差, 去掉原子集合  $\mathbf{H}_L$  在特征矢量  $\mathbf{e}$  对应的分量

$$\mathbf{e}_L = \mathbf{e} - \mathbf{H}_L \mathbf{S}_L \quad (14)$$

将导向矢量  $\mathbf{A}$  中的与  $\mathbf{e}_L$  最相关的原子剔除, 简单的方法就是将这一原子全部置零, 迭代次数加 1, 最后当残差估计信号与特征向量  $\mathbf{e}$  的差值达到一定阈值时,

$$|\mathbf{H}_L \mathbf{S}_L - \mathbf{e}|_2^2 \leq \eta \quad (15)$$

停止迭代, 即可计算出所有角度。大量仿真实验表明, 当阈值  $\eta = \epsilon^{-12}$  时, 较好完成角度重构的同时运行时间较短。

### 3.2 算法步骤

基于以上的讨论分析, 本文提出一种改进的 MSO 算法(Modified SVD OMP, MSO), 算法步骤如下:

步骤 1 对原始数据进行奇异值分解, 如式(8);

步骤 2 找出最大的特征值对应的  $M \times 1$  维特征向量矩阵  $\mathbf{e}$ ;

步骤 3 阵列流型矩阵  $\mathbf{A}$  为观测矩阵, 特征向量矩阵  $\mathbf{e}_L$  作为数据矩阵, 记录式(11)内积最大值时对应的原子序号, 初始特征向量为  $\mathbf{e}_1 = \mathbf{e}$ ;

步骤 4 计算式(12)更新原子集合  $\mathbf{H}_L$  和原子序号索引集合  $\Phi_L$ ;

步骤 5 利用式(13)最小二乘法得到逼近信号  $\mathbf{S}_L$ ;

步骤 6 利用式(14)更新残差, 剔除导向矢量  $\mathbf{A}$  中相应原子, 迭代次数  $L = L + 1$ ;

步骤 7 满足式(15)时, 停止迭代, 输出原子序号索引集合和相应的相关值; 否则继续运算步骤 3。

### 3.3 MSO 算法与基于正交匹配追踪 SVD 算法和 OMP 算法的对比

为了对比方便, 下面给出数据奇异值分解后包含信号的数据矩阵:

$$\mathbf{X}_S = \mathbf{U} \mathbf{L} \mathbf{D} = \begin{bmatrix} \mathbf{e}_1 & \mathbf{u}_{12} & \cdots & \mathbf{u}_{1Q} \\ \mathbf{e}_2 & \mathbf{u}_{22} & \cdots & \mathbf{u}_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{e}_M & \mathbf{u}_{M2} & \cdots & \mathbf{u}_{MQ} \end{bmatrix} \begin{bmatrix} \lambda & 0 & \cdots & 0 & 0 \\ 0 & \lambda_1 & 0 & \vdots & \vdots \\ 0 & 0 & \ddots & 0 & 0 \\ \vdots & \vdots & 0 & \ddots & 0 \\ 0 & 0 & \cdots & 0 & \lambda_{Q-1} \end{bmatrix} \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & 1 \end{bmatrix} \quad (16)$$

$$= \begin{bmatrix} \lambda \mathbf{e}_1 & \lambda_1 \mathbf{u}_{12} & \cdots & \lambda_{Q-1} \mathbf{u}_{1Q} \\ \lambda \mathbf{e}_2 & \lambda_1 \mathbf{u}_{22} & \cdots & \lambda_{Q-1} \mathbf{u}_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ \lambda \mathbf{e}_M & \lambda_1 \mathbf{u}_{M2} & \cdots & \lambda_{Q-1} \mathbf{u}_{MQ} \end{bmatrix}$$

其中,  $\lambda$  是最大的特征值,  $\lambda_1, \lambda_2, \dots, \lambda_{Q-1}$  为  $Q-1$  个小特征值,  $\mathbf{U}$  是各个特征值对应的  $M \times Q$  维特征向量矩阵,  $\mathbf{D}$  是  $Q \times Q$  维单位矩阵。

(1)关于运算量的讨论: 在信号都是相干的情况下, MSO 算法只对式(16)数据矩阵第 1 组( $\lambda$  为常数, 去掉后对结果无影响, 即相当于对大特征值特征向量处理)与阵列流型矩阵做自相关来重构信号角度, 基于正交匹配追踪 SVD 算法利用式(16)  $K$  组( $K$  为信号源数)  $M \times 1$  数据矩阵依次进行计算, 而 OMP 算法要对快拍数  $Q$  组原始数据  $\mathbf{X}$  运算, MSO 算法运算时间最少。当信号源个数较小时, 基于正交匹配追踪 SVD 算法运算速度较 OMP 算法, 运算速度有优势, 但当信号源个数增加时, 算法处理的信息量增加, 运算速度大大降低, 尤其信号源数等于快拍数时, 经典的 SVD 算法不会减少计算量, 而且由于还进行奇异值分解, 比 OMP 算法运算速度更慢。

(2)关于重构精度的讨论: MSO 算法与基于正交匹配追踪 SVD 算法利用包含信号的数据矩阵进行稀疏重构, 不同程度上消除噪声的影响, 在 DOA 估计精度方面较 OMP 算法要高。由式(16)可知, 信号角度信息只分布在第 1 列数据中, 其他列向量都是噪声分量, 相当于基于正交匹配追踪 SVD 算法多运算了  $K-1$  组噪声误差向量, 所以 MSO 算法要比

基于正交匹配追踪 SVD 算法重构精度高。

(3)关于对信号源敏感程度讨论:基于正交匹配追踪 SVD 算法必须要有信号源数的先验信息,但在现实中信号源数是未知的,算法失效。补救的方法通常利用信号源估计方法(信息论方法、平滑序列法和盖式圆方法等信源数估计方法)得到信号源数再进行后续计算,增加了计算量,或将信源数直接设为快拍数的一半,但这样误差较大。MSO 算法和 OMP 算法无需知道信号源数,可以快速重构信号角度。性能比较如表 1 所示。

表 1 3 类算法性能比较

算法	运算列向量组数	重构精度	是否知道信号源数
MSO 算法	1 组	最高	不需要
SVD 算法	$K$ 组	中等	需要
OMP 算法	$Q$ 组	最低	不需要

## 4 仿真与分析

本文仿真信号采用远场窄带高斯信号,从大特征值个数、运行时间和处理相干源个数3个方面进行仿真验证。

### 仿真1 相干信号与非相干信号奇异值分解特征值比较

实验仿真采用 16 阵元的 ULA,快拍数为 6,角度步长  $1^\circ$ ,角度分别为  $69^\circ$ ,  $15^\circ$  和  $9^\circ$ 。图 2 为分别采用相干和非相干 3 个信号源原始数据奇异值分解后的两组特征值。

由实验结果图 2 可以看出,对于独立信号源,奇异值分解后有和信号源数相同数目的大特征值,是没有秩亏损的;而对于相干信号源,奇异值分解后只有一个大特征值,产生了秩亏损,唯一的大特征值对应的信号数据包含了所有的角度信息。

### 仿真 2 选择后的原始数据的组数与运算时间的关系

实验采用 16 阵元的 ULA,快拍数为 6,3 个等功率相干信号源,方位分别是  $69^\circ$ ,  $15^\circ$  和  $9^\circ$ ,角度步长  $1^\circ$ ,图 3 实验仿真了信噪比在 5 dB, -3 dB 分别对应运算组数与运算时间的关系。

由图 3(a)可以看出,信噪比在 5 dB 时,随着组数的增加,运算时间增长,且斜率越来越大;图 3(b)可以看出在信噪比 -3 dB 时,有同样的结论。当组数为 1 的时候,即为 MSO 算法,运行时间非常短;当组数为 3 的时候,即为 SVD 算法,运行时间是 MSO 算法 6 倍多;当组数为 6 的时候,即为没有进

行 SVD 分解的传统 OMP 算法,运行时间是 MSO 算法 23 倍多,是 SVD 算法 3 倍多。

### 仿真 3 幅相一致时 OMP, SVD 与 MSO 算法的估计性能

实验采用 16 阵元的 ULA,3 个等功率同相位相干信号源,方位分别是  $9^\circ$ ,  $15^\circ$  和  $69^\circ$ ,实验仿真信噪比由 -6 dB 到 4 dB 时,OMP, SVD 和本文提出 MSO 对信号源的估计的成功概率、估计偏差以及均方误差根。仿真进行 200 次蒙特卡洛实验。因为在角度绝对值较大时,网格划分存在较大偏差,则在实验中当估计方位与实际方位左右偏差小于 2 个步长时,认为估计成功。

由实验结果可以看出,在信噪比小于 0 dB 时,MSO 算法在方位估计成功概率要高于 OMP 算法和 SVD 算法,同时在信噪比小于 -3 dB 时 SVD 算法方位估计成功概率比 OMP 算法更高。随着信噪比的增大,在均方误差根这一性能指标中,3 种算法的均方误差根均逐渐减小,MSO 算法相对于其他两种算法均方误差根更小。

### 仿真 4 幅相不一致时 OMP, SVD 与 MSO 算法的估计性能

实验采用 16 阵元的 ULA,3 个幅相不一致的相干信号源,方位分别是  $9^\circ$ ,  $15^\circ$  和  $69^\circ$ ,叠加的幅度分量分别为  $e^{0.1}$ ,  $e^{0.7}$ ,  $e^{1.1}$ ,相位分量分别为  $30^\circ$ ,  $60^\circ$ ,  $90^\circ$ ,实验仿真信噪比由 -9~1 dB 时,OMP, SVD 和本文提出 MSO 对信号源的估计的成功概率、估计偏差以及均方误差根。仿真进行 200 次蒙特卡洛实验,在实验中当估计方位与实际方位左右偏差小于 2 个步长时,认为估计成功。

由实验结果可以看出,在信噪比小于 -6 dB 时,MSO 算法在方位估计成功概率要高于 SVD 算法和 OMP 算法。随着信噪比的增大,在均方误差根这一性能指标中,随着信噪比的增大,3 种算法的均方误差根均逐渐减小,MSO 算法相对于其他两种算法均方误差根更小。与仿真 3 对比,3 种算法对于幅相不一致的相干信号 DOA 估计性能更佳,是因为幅相不一致时,相干信号之间可区分的信息更多。

## 5 结论

本文分析表明,对于完全相干的一组信号,原始数据会出现秩亏损,奇异值分解后有唯一的大特征值,这一大特征值对应的特征向量包含了所有的角度信息,运用此特征向量即可完美重构所有相干信号的角度,实现解相干。在此基础上从信号子空间大特征值对应的特征向量出发,提出了一种改进的算法—MSO 算法,该算法选取 SVD 算法中最






图 2 奇异值分解特征值分布




(a) 信噪比 5 dB




(b) 信噪比 -3 dB

图 3 不同信噪比情况下运行时间随降维后的组数变化




(a) 成功概率与信噪比的关系




(b) 均方根误差与信噪比的关系

图 4 幅相一致相干信号 DOA 估计性能



(a) 成功概率与信噪比的关系



(b) 均方根误差与信噪比的关系

图 5 幅相不一致相干信号 DOA 估计性能

大的特征值对应的特征向量，运用正交匹配追踪 (OMP)的思想进行角度重构，实现了比单一用基于正交匹配追踪SVD算法更好的性能。最后仿真结果表明，与OMP和SVD算法进行相比，该算法具有更好的算法稳健性和更低的信噪比门限，运算速度更快，重构精度更高，对信号源数的敏感度更低，尤其在处理幅相不一致相干信号时，本文算法具有更佳的解相干性能。

参 考 文 献

[1] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306. doi: 10.1109/TIT.2006.871582.  
 [2] GU Jianfeng, ZHU Weiping, and SWAMY M NS. Joint 2-D DOA estimation via sparse L-shaped array[J]. *IEEE Transactions on Signal Processing*, 2015, 63(5): 1171-1182. doi: 10.1109/TSP.2015.2389762.

[3] 蔡晶晶, 宗汝, 蔡辉. 基于空域平滑稀疏重构的DOA估计算法[J]. *电子与信息学报*, 2016, 38(1): 168-173. doi: 10.11999/JEIT150538.  
 CAI Jingjing, ZONG Ru, and CAI Hui. DOA estimation via sparse representation of the smoothed array covariance matrix[J]. *Journal of Electronics & Information Technology*, 2016, 38(1): 168-173. doi: 10.11999/JEIT150538.  
 [4] WU Xiaohuan, ZHU Weiping, YAN Jun, et al. Direction of arrival estimation for off-grid signals based on sparse Bayesian learning[J]. *IEEE Sensors Journal*, 2016, 16(7): 2004-2016. doi: 10.1109/JSEN.2015.2508059.  
 [5] LU Wang, ZHAO Lifan, BI Guoan, et al. Novel wideband DOA estimation based on sparse Bayesian learning with dirichlet process priors[J]. *IEEE Transactions on Signal Processing*, 2016, 64(2): 275-289. doi: 10.1109/TSP.2015.2481790.  
 [6] WANG Xiuhong, MAO Xingpeng, and ZHANG Naitong.

- Single-snap DOA estimation based on compressed sensing in pulse compression radar system[J]. *Systems Engineering & Electronics*, 2014, 36(9): 1737-1743. doi: 10.1109/RADAR.2014.6875648.
- [7] ZHAO Tan. Sparse direction of arrival estimation using co-prime arrays with off-grid target[J]. *IEEE Signal Processing Letters*, 2014, 21(1): 26-29. doi: 10.1109/LSP.2013.2289740.
- [8] 季正燕, 陈辉, 张佳佳. 两种基于SVD的稀疏重构解相干改进算法[J]. *空军预警学院学报*, 2017, 31(1): 5-10. doi: 10.3969/j.issn.2095-5839.2017.01.002.
- JI Zhengyan, CHEN Hui, and ZHANG Jiajia. Two ameliorated de-coherence algorithms in sparse reconstruction based on SVD[J]. *Journal of Air Force Early Warning Academy*, 2017, 31(1): 5-10. doi: 10.3969/j.issn.2095-5839.2017.01.002.
- [9] XU D, DU L, LIU H, *et al.* Compressive sensing of stepped-frequency radar based on transfer learning[J]. *IEEE Transactions on Signal Processing*, 2015, 63(12): 3076-3087. doi: 10.1109/TSP.2015.2421473.
- [10] MALIOUTOV D, CETIN M, and WILLSKY A S. A sparse signal reconstruction perspective for source localization with sensor arrays[J]. *IEEE Transactions on Signal Processing*, 2005, 53(8): 3010-3022. doi: 10.1109/TSP.2005.850882.
- [11] STOICA P, BABU P, LI J, *et al.* A sparse covariance-based estimation method for array processing[J]. *IEEE Transactions on Signal Processing*, 2011, 59(2): 629-638. doi: 10.1109/TSP.2010.2090525.
- [12] YIN Jihao and CHEN Tianqi. Direction-of-arrival estimation using a sparse representation of array covariance vectors[J]. *IEEE Transactions on Signal Processing*, 2011, 59(9): 4489-4494. doi: 10.1109/TSP.2011.2158425.
- [13] HAN Shunan, LI Dongsheng, and WANG Xiao. Novel approach for DOA estimation based on sparse reconstruction of eigenvector[J]. *Modern Defence Technology*, 2015, 43(4): 161-165. doi: 10.3969/j.issn.1009-086x.2015.04.027.
- [14] WEI Dong and ZHOU Jianpeng. Application of K-SVD and OMP algorithm on ultrasonic signal denoising[J]. *Journal of Applied Acoustics*, 2016, 35(2): 95-101. doi: 10.11684/j.issn.1000-310X.2016.02.001
- [15] WANG Chunguang, LIU Jinjiang, and SUN Jixiang. Compression algorithm for electrocardiograms based on sparse decomposition[J]. *Chinse Journal of Biomedical Engineering*, 2008, 27(1): 13-17. doi: 10.1007/s11460-009-0009-y.
- [16] TROPP J and GILBERT A. Signal recovery from random measurements via orthogonal matching pursuit[J]. *IEEE Transactions on Information Theory*, 2008, 53(12): 4655-4666. doi: 10.1109/TIT.2007.909108.
- 季正燕: 男, 1992年生, 助教, 研究方向为压缩感知、阵列信号处理.
- 陈辉: 男, 1974年生, 教授, 研究方向为阵列信号处理.
- 张佳佳: 女, 1986年生, 博士生, 研究方向为阵列信号处理.
- 李帅: 男, 1991年生, 硕士生, 研究方向为阵列信号处理.
- 陆晓飞: 男, 1993年生, 硕士生, 研究方向为阵列信号处理.