

基于二项分布改进的宽带压缩频谱检测方案

马 彬¹, 王宏明^{1,2}, 谢显中¹

(1. 重庆邮电大学移动通信技术重庆市重点实验室, 重庆 400065; 2. 重庆邮电大学通信与信息工程学院, 重庆 400065)

摘 要: 宽带压缩频谱检测存在依赖稀疏度先验信息和信号重构时延较高的问题. 因此, 本文提出了一种高效可靠的宽带压缩频谱检测方案. 首先, 推导出了基于二项分布精确置信区间改进的稀疏度估计模型. 其次, 利用稀疏度估计上下界改进了稀疏度自适应匹配追踪算法. 最后, 提出了一种宽带压缩频谱检测方案. 仿真结果表明, 本文所提出方法可以同时精确的估计信号稀疏度的上下界, 提高了频谱检测的效率和可靠性, 加快了算法的收敛速度.

关键词: 宽带频谱检测; 压缩感知; 稀疏度估计; 置信区间; 信号重构

中图分类号: TN929.5 **文献标识码:** A **文章编号:** 0372-2112 (2020)02-0243-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.02.003

An Improved Wideband Compressed Spectrum Sensing Scheme Based on Binomial Distribution

MA Bin¹, WANG Hong-ming^{1,2}, XIE Xian-zhong¹

(1. Chongqing Key Laboratory of Mobile Communications Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China; 2. School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Wideband compressed spectrum sensing has the problem of relying on sparsity prior information and high signal reconstruction delay. Therefore, this paper proposes an efficient and reliable wideband compressed spectrum sensing scheme. Firstly, the sparsity estimation model based on the improved confidence interval of binomial distribution is derived. Secondly, using the sparsity estimation upper and lower bounds improves the sparsity adaptive matching pursuit algorithm. Finally, a wideband compressed spectrum sensing scheme is proposed. The simulation results show that the proposed method can accurately estimate the upper and lower bounds of signal sparsity at the same time, improve the efficiency and reliability of spectrum sensing, and accelerate the convergence speed of the algorithm.

Key words: wideband spectrum sensing; compressed sensing; sparsity estimation; confidence interval; signal reconstruction

1 引言

随着5G网络的快速发展以及多样化服务的出现, 频谱资源稀缺和利用率不足的问题越来越受到重视^[1]. 认知无线电(Cognitive Radio, CR)技术能够通过机会性的接入授权频谱来提高频谱的利用率^[1,2]. 为了避免对主用户的干扰, CR的首要任务就是进行快速准确的频谱检测. 由于未来的CR需要在数千兆赫的宽频谱中检测频谱机会, 这导致无法直接应用窄带频谱检测, 因此需要宽带频谱检测来准确检测出可用的频谱资源^[3].

在宽带频谱检测中, 通常使用模数转换器(Analog-to-Digital Converter, ADC)将宽带谱转化为若干窄带谱, 再执行窄带频谱检测^[4]. 根据采样定理, ADC的采样率至

少是宽带信号中出现的最大频率的两倍, 这在硬件实现上相当困难. 为了解决高采样率问题, Tian等基于压缩感知(Compressed Sensing, CS)理论, 提出了一种宽带压缩频谱检测方案^[5]. CS表明, 对于稀疏信号, 恢复信号需要的采样率可以远低于奈奎斯特速率. 宽带压缩频谱检测正是利用了宽带信号固有的稀疏特性, 有效降低了采样率.

虽然CS能够解决高采样率的问题, 但是也带来了新的挑战, 即如何准确估计信号的稀疏度 k . 在CS中, k 是确定观测值数目和重构算法的重要参数. 然而在实际情况下, 宽带信号是动态变化的, 获取准确的 k 值非常困难. 通常将宽带信号的 k 值设置为一个定值, 但是如果 k 值低于真实值时, 会导致信号重构失败, 当高于真实值时, 则会给系统带来不必要的开销. 因此, 估计信

收稿日期: 2019-01-28; 修回日期: 2019-05-15; 责任编辑: 覃怀银

基金项目: 重庆市教委科学技术研究重点项目(No. KJZD-K201800603); 重庆市自然科学基金(No. CSTC2018jcyjAX0432); 重庆市研究生科研创新项目(No. CYS19252)

号的稀疏度意义重大。

Lopes 提出了一种数值估计模型来估计稀疏度的下界^[6]。Huang 等利用该模型改进了贪婪重构算法,降低了算法的迭代次数^[7]。Sharma 等利用观测协方差矩阵的子空间分析来估计信号稀疏度^[8]。Gao 等采用主成分分析和斜率分析法,利用协方差矩阵的特征值分布来估计信号稀疏度^[9]。Bioglio 等利用观测向量中非零元素的数目来获取稀疏度的上界^[10]。Wang 等利用蒙特卡罗仿真分别计算了估计稀疏度和重构信号所需要的样本数目^[11]。Malioutov 等提出了一种批处理的方法,通过判断信号收敛来确定采样数目^[12]。

为了解决稀疏度估计时存在先验条件较强和估计模型效率较低的问题,本文提出一种同时精确估计稀疏度上下界的方法,利用二项分布的精确置信区间,改进了稀疏度估计模型,通过观测向量估计稀疏度上下界,实现了在已知感知矩阵和观测向量的前提下即可精确估计信号稀疏度上下界的目的,在准确恢复信号的同时还降低了 SAMP 算法的迭代次数。

2 当前压缩感知算法分析

假设原始信号 s 的长度为 N ,其在某个变换域的信号 $\mathbf{x} = \Psi s$, Ψ 是 $N \times N$ 的变换矩阵, \mathbf{x} 中非零元素的数目为 k ,即 $k = \|\mathbf{x}\|_0$, k 远小于 N ,则称 \mathbf{x} 为 s 的 k 阶稀疏信号。在 CS 中,使用 $M \times N$ ($M < N$) 的感知矩阵 \mathbf{A} 获得观测向量 \mathbf{y} ,即 $\mathbf{y} = \mathbf{A}\mathbf{x} = \Phi\Psi s$, M 是观测值数目, Φ 是 $M \times N$ 的测量矩阵,通常 $M = O(k \log(N/k))$ ^[13]。研究表明,当 \mathbf{A} 满足约束等距性 (Restricted Isometry Property, RIP)^[14],则重构信号的问题为:

$$\mathbf{x}' = \operatorname{argmin} \|\mathbf{x}\|_0 \text{ s. t. } \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2 \leq \varepsilon \quad (1)$$

ε 是噪声误差, $\|\mathbf{x}\|_0$ 是指 \mathbf{x} 的 l_0 范数。

2.1 信号稀疏度估计

稀疏度估计模型主要包括数值估计模型^[6]、主成分分析法^[9]、最大似然估计 (Maximum Likelihood Estimation, ML) 模型及最大后验概率估计 (Maximum Posterior Probability Estimate, MAP) 模型^[10] 等。其中 ML 模型和 MAP 模型如式(3)和式(4)所示, h 表示观测向量中非零元素的数目, δ 是感知矩阵中非零元素满足均值为 0,方差为 $1/\delta M$ 的正态分布的概率, z_β 表示标准正态分布的 β 分位数。

上述模型考虑了在稀疏度分布已知和未知的情况下,估计稀疏度上界,但是仍存在问题。首先,ML 模型在小样本情况下,估计成功率低,稀疏度估计上界值不够精确。其次,实际中很难获得稀疏度的先验分布及其最值。此外,上述模型只能单一的估计稀疏度上界,效率低下。

2.2 稀疏信号重构

由式(1)可知,求解向量的零范数属于一类 NP 难题,主要通过两类非线性算法来完成。第一类是凸优化

算法,Lorenzi 等提出了一种最小化 l_1 范数的线性模型,证明了在 \mathbf{A} 满足 RIP 时,可以利用基追踪方法求解^[15]:

$$\mathbf{x}' = \operatorname{arg min} \|\mathbf{x}\|_1 \text{ s. t. } \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2 \leq \varepsilon \quad (2)$$

从而将一个 NP 难问题转化为一种可求解的凸优化问题。但是凸优化算法计算复杂度高,时间开销大。第二类是贪婪算法主要包括匹配追踪算法 (Matching Pursuit, MP)^[16]、正交匹配追踪算法 (Orthogonal Matching Pursuit, OMP)^[17] 和稀疏度自适应的匹配追踪算法 (Sparsity Adaptive Matching Pursuit, SAMP)^[18] 等。本文主要讨论 SAMP 算法。

SAMP 算法的基本思想是通过设置起始支撑集,采用步长迭代的方法逼近信号稀疏度,利用向量的内积运算,将信号在完备字典集上进行分解,并对已选择的原子进行正交化处理。SAMP 算法的迭代次数取决于起始支撑集维度、迭代步长和停止条件的设置。此外还需要确定合适的观测值数目,保证信号的准确重构。

$$k_{\text{ML}}^\beta = \frac{1}{\log(1-\delta)} \cdot \log \left(1 - \frac{h}{M} - \sqrt{\frac{\frac{h}{M} \left(1 - \frac{h}{M}\right)}{M} z_\beta} \right) \quad (3)$$

$$k_{\text{MAP}} = \operatorname{argmax}_{k_{\text{min}} \leq k \leq k_{\text{max}}} \left(\frac{\binom{M}{h} (1-p)^h (p(k))^{M-h} p(k)}{p(h)} \right) \quad (4)$$

3 基于二项分布改进的稀疏度估计模型

本节首先介绍了感知矩阵 \mathbf{A} 的选取,然后推导了稀疏度与观测向量 \mathbf{y} 之间的关系,最后采用二项分布的精确置信区间来估计稀疏度上下界。

张波等证明了稀疏随机矩阵在观测值数目足够大时满足 RIP 性质^[19]。该矩阵的每一列中随机抽取 d 个元素为 1,每一个元素 a_{ij} 都是独立同分布的, $a_{ij} = 1$ 的概率为 γ , $\gamma = d/M$,即:

$$a_{ij} = \begin{cases} 0, & 1 - \gamma \\ 1, & \gamma \end{cases} \quad (5)$$

然后计算 \mathbf{y} 中每个元素为 0 的概率,即 $P(y_i = 0)$,定义 d_i 为 a_{ij} 和 \mathbf{x}_j 同时不为 0 的个数 ($1 \leq i \leq M, 1 \leq j \leq N$), \mathbf{x}_j 表示原始信号中的元素,则:

$$\begin{aligned} P(y_i = 0) &= \sum_{j=0}^k P(y_i = 0 | d_i = j) P(d_i = j) \\ &= P(d_i = 0) \end{aligned} \quad (6)$$

当 $d_i > 0$ 时, $P(y_i = 0 | d_i > 0) = 0$,所以 $P(y_i = 0) = P(d_i = 0)$,记为 ξ 。由于 ξ 取决于 k ,可记为 $\xi(k)$ 。假设 $\omega = \|\mathbf{y}\|_0$,又 $\xi = p(y_i = 0)$,则 ω 的分布为:

$$P(\omega | k) \sim B(M, 1 - \xi) \quad (7)$$

而 d_i 的值取决于在感知矩阵中的相对应的 k 个位置的元素取值,所以 $p(d_i)$ 的分布为:

$$P(d_i) \sim B(k, \gamma) \quad (8)$$

得到 ξ 的值为:

$$\xi = \xi(k) = C_k^0 \gamma^0 (1-\gamma)^k = (1-\gamma)^k \quad (9)$$

故:

$$k = \log_{1-\gamma} \xi = \frac{\log \xi}{\log(1-\gamma)} \quad (10)$$

由于 $0 < 1-\gamma < 1$, k 是 ξ 的单调递减函数. 由估计样本可得:

$$1 - \hat{\xi} = \frac{\|y\|_0}{M} \rightarrow \hat{\xi} = \frac{M - \omega}{M} \quad (11)$$

由式(7)知, $p(\omega|k)$ 服从二项分布, 根据二项分布的精确置信区间, 当 $p = u/n$ 时, 如式(14)所示. 由式(11)可知, $u = M - \omega$, $n = M$, ξ 的区间如式(15)所示. 其中 $F_{v1, v2, \chi}$ 表示自由度为 $v1, v2$ 的 F 分布的上 $100 \times (1-\chi)$ 分位数, χ 称为显著性水平. 令 $I = ((\omega + 1) F_{2(\omega+1), 2(M-\omega), \alpha/2}) / (M - \omega)$, $J = ((M - \omega + 1) F_{2(M-\omega+1), 2\omega, \alpha/2}) / \omega$, 将下区间带入式(10)中, 得到稀疏度上界:

$$k_u = \lceil \frac{1}{\log(1-\gamma)} \log(\frac{1}{1+I}) \rceil \quad (12)$$

将上区间带入式(10)中, 得到稀疏度下界:

$$k_l = \lfloor \frac{1}{\log(1-\gamma)} \log(\frac{J}{1+J}) \rfloor \quad (13)$$

$\lceil \cdot \rceil$ 运算代表向上取整, $\lfloor \cdot \rfloor$ 运算代表向下取整.

4 基于稀疏度估计上下界改进的 SAMP 算法

改进后的 SAMP 算法流程如下, 其中 r 表示残差, t 表示迭代次数, j 表示阶段数, F 表示支撑集, L 表示支撑集维度, S 为测试集, C 为候选集.

算法 1 改进后的 SAMP 算法

输入: 原始信号 x 、下界 k_l 、步长 step 、上界 k_u

输出: 重构信号 x'

1、 $M = O(k_u \log(N/k_u))$;

2、构建感知矩阵 $A \in C^{M \times N}$;

3、观测向量 $y = Ax$, 其中 $y \in C^{M \times N}$;

4、初始化: $x' = 0, r_0 = y, F_0 = \emptyset, L = k_l, t = 1, j = 1$;

5、 $S_t = \max(A^T r_{t-1}, L)$;

(选取 A 与 r_{t-1} 内积最大的 L 列的索引作为测试集)

6、 $C_t = F_{t-1} \cup S_t$; (选取候选集的索引)

7、 $F = \max((A_{C_t}^T A_{C_t})^{-1} A_{C_t}^T y, L)$;

(最小二乘解最大的 L 列的索引构成支撑集)

8、 $r = y - A_F (A_F^T A_F)^{-1} A_F^T y$; (计算残差)

9、如果 $\|r\|_2 = 0$, 进入步骤 10; 如果 $\|r\|_2 \geq \|r_{t-1}\|_2$, 更新 $j = j + 1$, $L = L + \text{step}$, 返回步骤 5; 否则, $F_t = F, r_t = r, t = t + 1$, 如果 $t \geq M$, 进入步骤 10, 否则返回步骤 5.

10、 $x' = (A_F^T A_F)^{-1} A_F^T y$;

$$\frac{1}{1 + \frac{n-u+1}{u} F_{2(n-u+1), 2u, \alpha/2}} \leq p \leq \frac{\frac{u+1}{n-u} F_{2(u+1), 2(n-u), \alpha/2}}{1 + \frac{u+1}{n-u} F_{2(u+1), 2(n-u), \alpha/2}} \quad (14)$$

$$\frac{1}{1 + \frac{\omega+1}{M-\omega} F_{2(\omega+1), 2(M-\omega), \frac{\alpha}{2}}} \leq \hat{\xi} \leq \frac{\frac{M-\omega+1}{\omega} F_{2(M-\omega+1), 2\omega, \frac{\alpha}{2}}}{1 + \frac{M-\omega+1}{\omega} F_{2(M-\omega+1), 2\omega, \frac{\alpha}{2}}} \quad (15)$$

当信号未知时, 为了保证重构精度, L 和 step 通常设置为 1, 这会导致迭代次数的剧增. 本文利用稀疏度上下界改进了 SAMP 算法, 将 L 初始化为稀疏度下界, 有效的降低了迭代次数. 同时使用稀疏上界计算观测值数目, 使得改进后的 SAMP 算法能够实时调整采样数目, 提高了算法的可靠性.

5 基于改进稀疏度估计模型的宽带压缩频谱检测方案

本文所提出的宽带压缩频谱检测方案如图 1 所示. 首先从宽带信号中抽取估计样本 M_e 计算观测向量中非零元素的数目 ω , 利用 M_e 和 ω 求得置信区间, 得到上下界, 利用上界计算观测样本 M . 然后, 将下界和 M 带入改进的 SAMP 算法中. 为了进一步降低检测成本, 在得到 M 后, 计算所需要的补充采样值 $M_r = M - M_e$, 最后重构宽带信号.

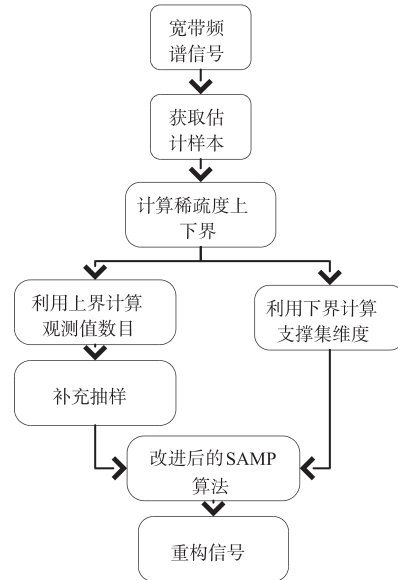


图 1 检测方案

该方案利用少量估计样本, 即可同时得到稀疏度上下界, 提高了方案的整体效率. 使用稀疏度上界计算观测值数目, 可以保证原始信号的准确重构, 提高了检测方案的可靠性. 而改进后的 SAMP 算法, 有效的提高

了检测方案的速度.

6 实验仿真

为了对本文所提检测方案的综合性能进行分析,分别对改进的估计模型和改进的 SAMP 算法进行仿真,主要分析了稀疏度上界估计成功率、采样率、算法的迭代次数和重构效果四个方面的性能,前两组实验与 ML 模型^[10]对比来分析改进后的估计模型性能,后两组与 SAMP 算法^[18]对比来分析改进后的 SAMP 算法性能.取观测值数目 $M = 1.7k_u \log(N/k_u)$,如果没有特别说明,部分参数设置如下:原始信号长度 $N = 256$,稀疏度 $k = 20$,感知矩阵中 $d = 4$,置信度为 $1 - \alpha = 0.99$.

6.1 稀疏度上界估计成功率

图 2 是稀疏度上界估计成功率的仿真结果. M_e 在闭区间 $[10, 60]$ 内以 2 为间隔等距取值.

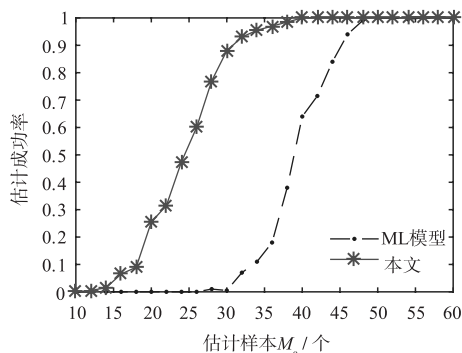


图2 估计成功率

由图可知,随着 M_e 的增加,两种模型的估计成功率逐渐上升.但是本文模型在 M_e 达到 k 左右时,开始上升,而 ML 模型出现上升趋势时 M_e 大于 k .这是因为 ML 模型总是假设误差幅度是对称的,当 ξ 过小时,置信下界是一个负数,导致了估计上界无穷大.所以,在 M_e 相同的情况下,本文改进的估计模型成功率一定会大于等于 ML 模型的估计成功率.

6.2 采样率

本组实验考虑所提方案与 ML 模型在采样率上的对比.定义采样率为 M/N ,设置 $M_e = 40$, N 在闭区间 $[300, 2100]$ 以 300 为间隔等距取值.

结果如图 3 所示,两种模型的采样率都略高于真实采样率,但是本文方案的采样率更加接近于真实采样率.这是因为本文模型所估计的上界值更加精确,从而得出的观测值数目也更加精确.同时,本文方案中提出的两步采样进一步降低了采样率.该结果表明,本文所提出的检测方案的采样率低于 ML 模型的采样率,更接近于真实采样率.

6.3 SAMP 算法的迭代次数

图 4 是算法在迭代次数上的仿真结果.设置 $M_e =$




图3 采样率




图4 迭代次数

40, SAMP 算法参数设置如下: $L = 1$, $\text{step} = 1$.

由图 4 可知,在 $k = 20$ 时, SAMP 算法所需的迭代次数在 40 左右,而本文改进后 SAMP 算法的平均迭代次数降低了一半左右.这是因为本文改进的 SAMP 算法将起始支撑集维度设置为稀疏估计下界,而不是保守的从 1 开始迭代,从而大幅降低了迭代次数.所以,改进后的 SAMP 算法能够显著降低迭代次数.

6.4 改进 SAMP 算法的重构效果

图 5 和图 6 是信号重构效果的对比,每组分别对 $k = 20$ 和 $k = 50$ 的两组稀疏信号进行了重构. $M_e = 60$, SAMP 算法的参数设置如下: $M = 100$, $L = 1$, $\text{step} = 1$.

由图 5 可知,在 $k = 20$ 时, SAMP 算法得到的重构信号与原始信号在非零元素的幅度和位置上的一致,重构成功.而当 $k = 50$ 时, SAMP 算法得到的重构信号中非零元素的幅度和位置与原始信号存在极大的差异,重构失败.由图 6 可知,在 $k = 20$ 和 $k = 50$ 时,改进后的 SAMP 得到的重构信号中非零元素的幅度和位置与原始信号基本一致,即本文改进的 SAMP 算法在两种稀疏度下都能成功恢复原始信号.

由上述结果可知,在 $k = 20$ 时,两种算法都可准确重构,在 $k = 50$ 时, SAMP 算法无法准确重构,而本文改进的 SAMP 算法仍然能够准确重构.这是因为改进后的 SAMP 算法,能够实时利用稀疏度上界更新观测值数目.而 SAMP 算法由于没有稀疏度的先验信息,其观测




图5 SAMP算法的重构结果




图6 改进后的SAMP算法的重构结果

值数目只能设置为一个固定值,无法动态更新,当稀疏度过大时,观测值数目较低导致了重构失败.仿真结果表明,本文改进的 SAMP 算法能够实时、有效的重构原始信号,具有更高的准确性.

7 结论

本文利用改进的稀疏度估计模型,提出了一种同时精确的估计稀疏度上下界的方法和一种高效、准确的宽带压缩频谱检测方案,最后通过仿真,分别从估计模型和改进的 SAMP 算法两部分分析了该方案的综合性能.仿真结果表明利用稀疏度上下界所提出的宽带压缩频谱检测方案能够实时、准确的重构原始信号,并且在估计成功率,采样率和重构算法的性能方面都有

所提高.在接下来的工作中,希望结合宽带频谱的历史稀疏统计信息,进一步完善检测方案.

参考文献

- [1] Khalfi B, Zaid A, Hamdaoui B. When machine learning meets compressive sampling for wideband spectrum sensing [A]. Proceedings of the 13th International Wireless Communications and Mobile Computing Conference [C]. Valencia, Spain: IEEE, 2017. 1120 - 1125.
- [2] Ali A, Hamouda W. Advances on spectrum sensing for cognitive radio networks: theory and applications [J]. IEEE Communications Surveys & Tutorials, 2017, 19(2): 1277 - 1304.
- [3] Sun H, Nallanathan A, Wang C, et al. Wideband spectrum

- sensing for cognitive radio networks: a survey [J]. IEEE Wireless Communications, 2013, 20(2): 74–81.
- [4] Quan Z, Cui S, Sayed A H, et al. Optimal multiband joint detection for spectrum sensing in cognitive radio networks [J]. IEEE Transactions on Signal Processing, 2009, 57(3): 1128–1140.
- [5] Tian Z, Giannakis G B. Compressed sensing for wideband cognitive radios [A]. Proceedings of the 2007 IEEE International Conference on Acoustics, Speech and Signal Processing [C]. Honolulu, HI, USA: IEEE, 2007. 1357–1360.
- [6] Lopes M E. Unknown sparsity in compressed sensing: denoising and inference [J]. IEEE Transactions on Information Theory, 2016, 62(9): 5145–5166.
- [7] Weiqiang H, Jianlin Z, Zhiqiang L, et al. Sparsity and step-size adaptive regularized matching pursuit algorithm for compressed sensing [A]. Proceedings of the IEEE 7th Joint International Information Technology and Artificial Intelligence Conference [C]. Chongqing, China: IEEE, 2014. 536–540.
- [8] Sharma S K, Chatzinotas S, Ottersten B. Compressive sparsity order estimation for wideband cognitive radio receiver [J]. IEEE Transactions on Signal Processing, 2014, 62(19): 4984–4996.
- [9] Gao Y, Si Y, Zhu B, et al. Sparsity order estimation algorithm in compressed sensing by exploiting slope analysis [A]. Proceedings of the 14th International Wireless Communications & Mobile Computing Conference [C]. Limassol, Cyprus: IEEE, 2018. 753–756.
- [10] Bioglio V, Bianchi T, Magli E. On the fly estimation of the sparsity degree in compressed sensing using sparse sensing matrices [A]. Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing [C]. Brisbane, QLD, Australia: IEEE, 2015. 3801–3805.
- [11] Wang Y, Tian Z, Feng C. Sparsity order estimation and its application in compressive spectrum sensing for cognitive radios [J]. IEEE Transactions on Wireless Communications, 2012, 11(6): 2116–2125.
- [12] Malioutov D M, Sanghavi S, Willsky A S. Compressed sensing with sequential observations [A]. Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing [C]. Las Vegas, NV, USA: IEEE, 2008. 3357–3360.
- [13] Arias-Castro E, Candes E J, Davenport M A. On the fundamental limits of adaptive sensing [J]. IEEE Transactions on Information Theory, 2013, 59(1): 472–481.
- [14] Candes E J, Tao T. Decoding by linear programming [J]. IEEE Transactions on Information Theory, 2005, 51(12): 4203–4215.
- [15] Lorenzi L, Mercier G, Melgani F. Adaptive basis pursuit compressive sensing reconstruction with histogram matching [A]. Proceedings of the IEEE International Geoscience and Remote Sensing Symposium [C]. Melbourne, VIC, Australia: IEEE, 2013. 872–875.
- [16] Mallat S, Zhang Z. Adaptive time-frequency decomposition with matching pursuits [A]. Proceedings of the IEEE-SP International Symposium on Time-Frequency and Time-Scale Analysis. Victoria, BC, Canada: IEEE, 1992. 7–10.
- [17] Sahoo S K, Makur A. Signal recovery from random measurements via extended orthogonal matching pursuit [J]. IEEE Transactions on Signal Processing, 2015, 63(10): 2572–2581.
- [18] Do T T, Gan L, Nguyen N, et al. Sparsity adaptive matching pursuit algorithm for practical compressed sensing [A]. Proceedings of the 42nd Asilomar Conference on Signals, Systems and Computers [C]. Pacific Grove, CA, USA: IEEE, 2008. 581–587.
- [19] 张波, 刘郁林, 王开. 稀疏随机矩阵有限等距性质分析 [J]. 电子与信息学报, 2014, 36(1): 169–174.
Zhang Bo, Liu Yu-lin, Wang Kai. Restricted isometry property analysis for sparse random matrices [J]. Journal of Electronics and Information Technology, 2014, 36(1): 169–174. (in Chinese)

作者简介



马彬男, 1978 年生于四川宜宾, 现为重庆邮电大学教授, 主要研究方向为异构无线网络、认知无线电网络等。

E-mail: mabin@cqupt.edu.cn



王宏明(通信作者)男, 1994 年生于安徽芜湖, 现为重庆邮电大学通信与信息工程学院硕士研究生, 主要研究方向为认知无线电网络。

E-mail: whm_cqupt@163.com



谢显中男, 1966 年生于四川通江, 现为重庆邮电大学教授, 主要研究方向为干扰对齐与 MIMO 技术。

E-mail: xiexzh@cqupt.edu.cn