

脉冲噪声干扰下免调度非正交多址接入系统的联合 多用户检测和信道估计方法

李有明¹, 陈江涛¹, 吴永宏², 徐伯禹², 蔡万源¹

(1. 宁波大学信息科学与工程学院, 浙江 宁波 315211;

2. 中国电波传播研究所, 山东 青岛 266107)

摘要: 针对免调度非正交多址接入 (NOMA) 系统中普遍存在的脉冲噪声干扰背景, 提出一种基于时序多重稀疏贝叶斯学习和最小二乘的联合多用户检测、信道估计和脉冲噪声估计方法。首先利用多根天线接收下用户零星通信和突发脉冲噪声的联合稀疏性, 将多用户检测、信道估计和脉冲噪声估计问题建模成多测量向量的压缩感知问题, 然后通过时序多重稀疏贝叶斯学习算法获取活跃用户和突发脉冲噪声的支撑集, 最后使用最小二乘法估计出信道和脉冲噪声。仿真结果表明, 相较于现有的方法, 所提方法在多用户检测、信道估计和脉冲噪声估计性能上均具有显著的优势。这一结论也通过误符号率进一步得到验证。

关键词: 免调度; 非正交多址接入; 多用户检测; 信道估计; 脉冲噪声

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025055

Joint multi-user detection and channel estimation method for grant-free NOMA systems under impulsive noise interference

LI Youming¹, CHEN Jiangtao¹, WU Yonghong², XU Boyu², CAI Wanyuan¹

1. Faculty of Information Science and Engineering, Ningbo University, Ningbo 315211, China

2. China Research Institute of Radiowave Propagation, Qingdao 266107, China

Abstract: Aiming at the widespread impulsive noise interference background in grant-free non-orthogonal multiple access (NOMA) systems, a joint multi-user detection, channel estimation and impulsive noise estimation method based on temporally multiple sparse Bayes learning and least square was proposed. Firstly, the joint sparsity of sporadic user communications and burst impulsive noise under multi-antenna reception was used to model the multi-user detection, channel estimation and impulsive noise estimation problems into a compressed sensing problem of multiple measurement vector. Then, the temporally multiple sparse Bayes learning algorithm was used to obtain the support set of active users and burst impulsive noise. Finally, the least square method was used to estimate the channel and impulsive noise. The simulation results show that compared with the existing methods, the proposed method has significant advantages in the performance of multi-user detection, channel estimation and impulsive noise estimation. This conclusion is further validated by the symbol error rate.

Keywords: grant-free, NOMA, multi-user detection, channel estimation, impulsive noise

收稿日期: 2024-09-02; 修回日期: 2024-12-23

通信作者: 李有明, liyouming@nbu.edu.cn

基金项目: 国家重点研发计划基金资助项目 (No.2023YFC2809400); 国家自然科学基金资助项目 (No.61571250); 浙江省自然科学基金资助项目 (No.LY22F010018)

Foundation Items: The National Key Research and Development Program of China (No.2023YFC2809400), The National Natural Science Foundation of China (No.61571250), The Natural Science Foundation of Zhejiang Province (No.LY22F010018)

0 引言

大规模机器类型通信 (mMTC, massive machine type communication) 作为 5G 的三大应用场景之一, 在工业物联网、车联网等领域受到了广泛的关注。mMTC 具有海量设备接入、数据包短、零星传输等特点^[1], 传统的基于调度的正交多址接入方案会使通信系统产生大量的信令开销和较高的传输时延, 导致频谱资源紧张, 无法满足 mMTC 的要求。免调度非正交多址接入 (GF-NOMA, grant-free non-orthogonal multiple access) 技术的出现为解决这些问题提供了全新的解决方案。GF-NOMA 允许不同的用户在不依赖基站调度的情况下, 在相同的时间或频率资源上传输数据, 可以在极大地降低信令开销和传输时延的同时显著地提高频谱利用率。但是, 传输过程中用户无须经过基站的调度, 随机地向基站发送数据, 这就导致基站在用户传输数据时无法获知活跃用户的信息^[2], 从而无法正确解码活跃用户的数据。因此, 如何实现 GF-NOMA 系统的多用户检测和信道估计是一个具有重要实际意义的课题。

在 mMTC 场景中, GF-NOMA 系统呈现出在很短的时间内只有少量用户处于活跃状态, 而大部分用户处于不发送信息的非活跃状态的特点^[3], 用户活动具有典型的稀疏特性。因此, 近年来学者们基于这种稀疏特性, 利用压缩感知 (CS, compressed sensing) 理论进行 GF-NOMA 系统的多用户检测或信道估计。文献[4]利用传输信号的稀疏特性进行多用户检测, 但是其仅关注单个时隙传输信号的稀疏性, 并未考虑到多个时隙传输中可能存在的时间相关性。为了进一步提高多用户检测的准确率, 一些研究者考虑用户在整个帧期间处于同步状态所呈现出的联合稀疏性, 将基站处的多用户检测问题推广为多测量向量 (MMV, multiple measurement vector) 问题。Du 等^[5]为了充分利用一帧内全部时隙的联合稀疏性, 将 MMV 中的块稀疏结构与经典的子空间追踪 (SP, subspace pursuit) 算法^[6]相结合, 提出了一种门限辅助的块稀疏自适应子空间追踪算法, 能够在不需要用户稀疏程度作为先验知识的前提下进行多用户检测。Wang 等^[7]在帧联合稀疏传输结构的基础上引入了一种结构化迭代支持检测算法来执行多用户检测。文献[8]利用一帧内的时间相关性, 在无须用户活跃度作为

先验信息的前提下为 GF-NOMA 系统提出了一种联合多用户检测和信道估计框架, 将多测量向量压缩感知 (MMV-CS, multiple measurement vector-compressed sensing) 问题转换为块稀疏单测量向量压缩感知 (BS-SMV-CS, block sparse-single measurement vector-compressed sensing) 问题, 并通过提出的块稀疏度自适应子空间追踪算法来解决多用户检测和信道估计问题。为了降低子空间追踪类算法中矩阵求逆的复杂度, Gao 等^[9]提出了一种低复杂度的稀疏度自适应块梯度追踪算法, 该算法在取得与子空间追踪类算法接近的多用户检测和信道估计性能下, 显著地降低了计算复杂度。此外, 随着机器学习理论的发展, 深度学习也被用于 GF-NOMA 系统中以解决多用户检测和信道估计问题。Yu 等^[10]提出了一种基于深度学习的多用户检测和信道估计方法, 该方法利用深度学习强大的学习能力挖掘隐藏在接收信号中的用户活动和信道状态信息以获得更高的检测精度。

上述所有工作均假设 GF-NOMA 系统的背景噪声为高斯白噪声, 未考虑脉冲噪声对通信系统的影响, 这与实际的 mMTC 应用场景严重不符。例如, 在工业物联网、车联网等 mMTC 应用场景中, 由于电气设备开关、汽车点火等活动, 存在着大量的脉冲噪声^[11-12], 这些脉冲噪声会对通信系统产生极大的干扰, 严重损害通信性能^[13]。

针对非正交多址接入系统下的脉冲噪声干扰问题, 已有一些学者提出了抑制方案。文献[14]提出了一种基于深度学习的脉冲噪声抑制方法, 通过深度神经网络进行脉冲噪声检测, 然后进行相应的抑制处理。文献[15]提出了一种基于 ℓ_q 范数和图拉普拉斯正则化的脉冲噪声抑制方法, 该方法基于图信号处理理论, 充分利用了子载波之间的相关性。然而, 这些脉冲噪声抑制方法均是在功率域非正交多址接入系统下提出的, 而非码域 GF-NOMA 系统的脉冲噪声抑制策略, 目前仍缺少 GF-NOMA 系统下的脉冲噪声抑制方法。

近年来, 虽然有学者研究了非高斯噪声下的 GF-NOMA 系统的多用户检测和信道估计^[16], 但是该研究是在已知的信道信息存在误差的基础上进行实际信道的估计, 需要初始的信道估计作为先验信息, 这种假设过于理想, 实际应用受到限制。因此, 设计一种无须任何先验信息的脉冲噪声干扰下

GF-NOMA 系统的多用户检测和信道估计方法具有重要意义。

因此, 本文从 mMTC 和脉冲噪声的特点出发, 通过挖掘待恢复信号的块稀疏特性, 根据压缩感知理论提出了一种联合多用户检测、信道估计和脉冲噪声估计方法。首先利用 mMTC 零星通信的特点和突发脉冲噪声的稀疏特性, 将多根天线的接收信号进行多用户检测、信道估计和脉冲噪声估计的问题建模成 MMV-CS 问题, 然后使用时隙多重稀疏贝叶斯学习 (TMSBL, temporally multiple sparse Bayes learning) 算法^[17]求解 MMV-CS 问题以获取活跃用户和脉冲噪声突发位置的支撑集, 最后使用最小二乘 (LS, least square) 方法实现信道和脉冲噪声联合估计。仿真结果表明, 与现有的方法相比, 所提方法在多用户检测、信道估计、脉冲噪声估计和误符号率 (SER, symbol error rate) 性能上均具有显著的优势。

1 系统模型及问题

考虑一个典型的上行 GF-NOMA 系统, 其中有 K 个用户和一个基站, 所有用户均配置单根天线, 基站配置 R 根天线。在该系统中, 很短的时间内只有少量的活跃用户向基站发送数据, 而大部分的非活跃用户则保持沉默, 这使通信呈现零星的特点。此外, 由于免调度的传输模式, 基站在用户传输数据时无法获知活跃用户的信息。假设所有的用户在一帧中均处于同步状态, 即每个用户在一帧内只保持活跃或非活跃状态。在经过编码调制后, 每个活跃用户所发送的每个符号均被每个活跃用户各自独有的扩频序列扩展为一个 N 维的序列。每个活跃用户在一帧内首先发送一个导频符号, 然后发送数据符号, 非活跃用户在一帧内不会传输任何符号。考虑信道模型为平坦瑞利衰落信道, 一帧中全部时隙的信道状态均保持不变。

假设信号在传输过程中受到脉冲噪声和高斯白噪声的干扰, 则基站处的第 r 根天线在导频段所接收到的信号可以表示为

$$\mathbf{y}_p^r = \sum_{k=1}^K h_k^r s_k x_{p,k} + \mathbf{F} \mathbf{i}_p^r + \mathbf{z}_p^r = \mathbf{S} \text{diag}(\mathbf{h}^r) \mathbf{x}_p + \mathbf{F} \mathbf{i}_p^r + \mathbf{z}_p^r \quad (1)$$

其中, $\mathbf{x}_p = [x_{p,1}, x_{p,2}, \dots, x_{p,K}]^T$ 是所有用户发送的导频符号构成的 K 维导频符号向量, 对于活跃用户,

导频符号向量中相应元素的值为 1, 对于非活跃用户, 导频符号向量中相应元素的值为 0; $\mathbf{s}_k = [s_{1,k}, s_{2,k}, \dots, s_{N,k}]^T$ 是用户 k 所独有的维度为 N 的扩频序列向量, $\mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_K]$ 是维度为 $N \times K$ 的扩频矩阵, $k = 1, 2, \dots, K$, 为了应对 mMTC 的大规模连接需求, 基于非正交多址接入技术的特点, 考虑采用过载系统, 子载波数小于用户数, 即 $N < K$; $\mathbf{h}^r = [h_1^r, h_2^r, \dots, h_K^r]^T$ 是所有用户与基站第 r 根天线之间的维度为 K 的信道系数向量, h_k^r 表示用户 k 与基站第 r 根天线之间的信道增益, 不活跃用户的信道增益值为 0, 活跃用户的信道增益之间相互独立并且均服从均值为 0、方差为 1 的复高斯分布, $r = 1, 2, \dots, R$, 当仅有少量用户处于活跃状态时, 向量 \mathbf{h}^r 具有稀疏性; \mathbf{F} 表示维度为 $N \times N$ 的归一化傅里叶变换矩阵; $\mathbf{i}_p^r = [i_{p,1}, i_{p,2}, \dots, i_{p,N}]^T$ 是导频时隙突发的 N 维脉冲噪声向量; 背景噪声为高斯白噪声, \mathbf{z}_p^r 是 N 维的背景噪声向量, $\mathbf{z}_p^r \sim \mathcal{CN}(0, \sigma_z^2 \mathbf{I})$, σ_z^2 是背景噪声的方差。

因此, 传输过程中的联合稀疏性可以表示为

$$\text{supp}(\text{diag}(\mathbf{h}^1) \mathbf{x}_p) = \text{supp}(\text{diag}(\mathbf{h}^2) \mathbf{x}_p) = \dots = \text{supp}(\text{diag}(\mathbf{h}^R) \mathbf{x}_p) = \Gamma_h \quad (2)$$

$$\text{supp}(\mathbf{i}_p^1) = \text{supp}(\mathbf{i}_p^2) = \dots = \text{supp}(\mathbf{i}_p^R) = \Gamma_i \quad (3)$$

其中, $\text{supp}(\mathbf{x})$ 表示向量 \mathbf{x} 的支撑集, 即向量 \mathbf{x} 中非 0 元素值的索引构成的集合。

由于信道 \mathbf{h}^r 和导频符号向量 \mathbf{x}_p 具有相同的支持集, 除支撑集之外的位置上的元素值均为 0, \mathbf{x}_p 中活跃用户对应的元素值为 1, 则 $\text{diag}(\mathbf{h}^r) \mathbf{x}_p = \mathbf{h}^r$, 活跃用户的稀疏性就可以反映在 \mathbf{h}^r 中。因此, 式(1)可以被转化为

$$\mathbf{y}_p^r = \mathbf{S} \mathbf{h}^r + \mathbf{F} \mathbf{i}_p^r + \mathbf{z}_p^r \quad (4)$$

由于 $\mathbf{h}^1, \mathbf{h}^2, \dots, \mathbf{h}^R$ 均具有相同的支持集, 以多根天线进行信号接收, 则式(4)的 R 个稀疏信号重建问题可以被重新表示为一个新的稀疏信号重建问题。新的稀疏信号重建问题的表达式为

$$\begin{bmatrix} \mathbf{y}_p^1 \\ \mathbf{y}_p^2 \\ \dots \\ \mathbf{y}_p^R \end{bmatrix} = \mathbf{S} [\mathbf{h}^1, \mathbf{h}^2, \dots, \mathbf{h}^R] + \mathbf{F} [\mathbf{i}_p^1, \mathbf{i}_p^2, \dots, \mathbf{i}_p^R] + [\mathbf{z}_p^1, \mathbf{z}_p^2, \dots, \mathbf{z}_p^R] \quad (5)$$

由此, R 个基本的 SMV-CS 问题就可以转化为

MMV-CS问题。

令 $\mathbf{Y} = [\mathbf{y}_p^1, \mathbf{y}_p^2, \dots, \mathbf{y}_p^R]$, $\mathbf{H} = [\mathbf{h}^1, \mathbf{h}^2, \dots, \mathbf{h}^R]$, $\mathbf{I} = [\mathbf{i}_p^1, \mathbf{i}_p^2, \dots, \mathbf{i}_p^R]$, $\mathbf{Z} = [\mathbf{z}_p^1, \mathbf{z}_p^2, \dots, \mathbf{z}_p^R]$, 问题式(5)可以重写为

$$\mathbf{Y} = \mathbf{S}\mathbf{H} + \mathbf{F}\mathbf{I} + \mathbf{Z} \quad (6)$$

为了进行信道和脉冲噪声的联合估计, 构造矩阵 $\Phi = [\mathbf{S}\mathbf{F}]$, $\mathbf{W} = [\mathbf{H}^T \mathbf{I}^T]^T$, 式(6)可以被重新表示为

$$\mathbf{Y} = \Phi \mathbf{W} + \mathbf{Z} \quad (7)$$

因此多用户检测、信道和脉冲噪声联合估计问题就转换成了MMV-CS框架下的稀疏信号恢复问题, 可以通过压缩感知理论中的稀疏信号恢复方法进行求解。

2 联合多用户检测、信道估计和脉冲噪声估计方法

由于多根天线的接收信号中待估计的信道和脉冲噪声均具有相同的支撑集, 因此待恢复信号呈现出块稀疏特性, 即

$$\begin{aligned} \text{supp}\left([\mathbf{h}^{1T} \mathbf{i}_p^{1T}]^T\right) &= \text{supp}\left([\mathbf{h}^{2T} \mathbf{i}_p^{2T}]^T\right) = \dots = \\ \text{supp}\left([\mathbf{h}^{RT} \mathbf{i}_p^{RT}]^T\right) &= \text{supp}(\mathbf{W}_{(:,r)}) \end{aligned} \quad (8)$$

其中, $\mathbf{W}_{(:,r)}$ 表示矩阵 \mathbf{W} 的第 r 列。

稀疏贝叶斯学习类算法虽然能够进行稀疏信号重构, 但是其恢复效果并不理想。为了利用块稀疏特性来有效地重构信号, 本文基于块稀疏贝叶斯学习和最小二乘估计理论, 提出TMSBL-LS (temporally multiple sparse Bayes learning-least square) 算法对信道和脉冲噪声进行联合估计。具体地, 首先借助块稀疏贝叶斯学习框架, 利用多测量向量信息获取信道和脉冲噪声的支撑集, 然后通过最小二乘法实现高效的信道和脉冲噪声联合估计。在给出所提算法之前, 首先介绍用于块稀疏信号恢复的经典块稀疏贝叶斯学习算法, 同时为了降低计算复杂度, 本文在其基础上提出了计算复杂度较低的TMSBL-LS算法以实现联合多用户检测、信道估计和脉冲噪声估计。

假设 \mathbf{W} 的每一行为一个稀疏信号块, 用 $\mathbf{W}_{(i,:)}$ 来表示, 并假设所有的稀疏信号块是相互独立的, 且均服从高斯分布, 满足

$$p(\mathbf{W}_{(i,:)}; \gamma_i, \mathbf{B}_i) \sim \mathcal{CN}(\mathbf{0}, \gamma_i \mathbf{B}_i), i = 1, 2, \dots, N + K \quad (9)$$

其中, γ_i 是非负的超参数, 决定了稀疏信号块的稀疏程度; \mathbf{B}_i 是正定的块内相关矩阵, 表征着 $\mathbf{W}_{(i,:)}$ 的块内相关结构。在有限的测量条件下, 为防止过拟合, 考虑将所有 \mathbf{B}_i 固定为同一正定矩阵 \mathbf{B} 。

将式(7)的MMV模型写为块SMV模型, 可得

$$\mathbf{y} = \mathbf{D}\mathbf{c} + \mathbf{n} \quad (10)$$

其中, $\mathbf{y} = \text{vec}(\mathbf{Y}^T)$, $\mathbf{D} = \Phi \otimes \mathbf{I}_R$, \otimes 表示克罗内克积, \mathbf{I}_R 表示 $R \times R$ 维单位矩阵, $\mathbf{c} = \text{vec}(\mathbf{W}^T)$, $\mathbf{n} = \text{vec}(\mathbf{Z}^T)$, $\text{vec}(\cdot)$ 表示列向量化操作。

针对式(10)的块SMV模型, 假设向量 \mathbf{n} 服从 $\mathcal{CN}(\mathbf{0}, \sigma^2 \mathbf{I})$, 稀疏向量 \mathbf{c} 的先验分布满足式(11), 则高斯似然函数模型为式(12), 即

$$p(\mathbf{c}; \gamma_i, \mathbf{B}, \forall i) \sim \mathcal{CN}(\mathbf{0}, \Sigma_0) \quad (11)$$

$$p(\mathbf{y}|\mathbf{c}; \sigma^2) \sim \mathcal{CN}(\mathbf{D}\mathbf{c}, \sigma^2 \mathbf{I}) \quad (12)$$

其中, $\Sigma_0 = \Gamma \otimes \mathbf{B}$, 超参数矩阵 $\Gamma = \text{diag}(\gamma_1, \gamma_2, \dots, \gamma_{N+K})$ 。

根据贝叶斯公式, 稀疏向量 \mathbf{c} 的后验分布满足

$$p(\mathbf{c}|\mathbf{y}; \sigma^2, \gamma_i, \mathbf{B}, \forall i) \sim \mathcal{CN}(\boldsymbol{\mu}, \Sigma_c) \quad (13)$$

其中, $\boldsymbol{\mu} = \sigma^{-2} \Sigma_c \mathbf{D}^H \mathbf{y}$, $\Sigma_c = (\Sigma_0^{-1} + \sigma^{-2} \mathbf{D}^H \mathbf{D})^{-1}$ 。

因此在估计出 γ_i 、 σ^2 和 \mathbf{B} 后, 即可得到稀疏向量 \mathbf{c} 的最大后验估计

$$\mathbf{c} = \boldsymbol{\mu} = \Sigma_0 \mathbf{D}^H (\sigma^2 \mathbf{I} + \mathbf{D} \Sigma_0 \mathbf{D}^H)^{-1} \mathbf{y} \quad (14)$$

定义超参数集 $\boldsymbol{\theta} = \{\Gamma, \mathbf{B}, \sigma^2\}$, 采用期望值最大化 (EM, expectation maximization) 算法求得使边缘概率密度 $p(\mathbf{y}; \Gamma, \mathbf{B}, \sigma^2)$ 最大的超参数值并进行 $\boldsymbol{\theta}$ 的更新。在迭代中, E步将 \mathbf{c} 视为隐藏变量, 利用当前参数计算条件概率分布下联合概率分布的期望, 即

$$Q(\boldsymbol{\theta}) = \mathbb{E}_{\mathbf{c}|\mathbf{y}; \boldsymbol{\theta}^{(old)}} \left\{ \log p(\mathbf{y}, \mathbf{c}; \boldsymbol{\theta}) \right\} \quad (15)$$

其中, 有

$$p(\mathbf{y}, \mathbf{c}; \boldsymbol{\theta}) = p(\mathbf{y}|\mathbf{c}; \sigma^2) p(\mathbf{c}; \Gamma, \mathbf{B}) \quad (16)$$

M步通过最大化期望值 $Q(\boldsymbol{\theta})$ 来获得超参数的更新值, 得到 $\boldsymbol{\theta}$ 的更新规则

$$\gamma_i = \frac{\text{Tr} \left[\mathbf{B}^{-1} \left(\Sigma_c^i + \boldsymbol{\mu}^i (\boldsymbol{\mu}^i)^H \right) \right]}{R} \quad (17)$$

$$\mathbf{B} = \frac{1}{N+K} \sum_{i=1}^{N+K} \frac{\boldsymbol{\Sigma}_c^i + \boldsymbol{\mu}^i (\boldsymbol{\mu}^i)^H}{\gamma_i} \quad (18)$$

$$\sigma^2 = \frac{\|\mathbf{y} - \mathbf{D}\boldsymbol{\mu}\|_2^2}{NR} + \frac{\sigma^2[(N+K)R - \text{Tr}(\boldsymbol{\Sigma}_c \boldsymbol{\Sigma}_0^{-1})]}{NR} \quad (19)$$

其中, $\boldsymbol{\mu}^i$ 表示 $\boldsymbol{\mu}$ 的 $((i-1)R+1:iR)$ 行构成的子向量, $\boldsymbol{\Sigma}_c^i$ 表示 $\boldsymbol{\Sigma}_c$ 的 $((i-1)R+1:iR)$ 行与 $((i-1)R+1:iR)$ 列构成的子矩阵, $\text{Tr}(\cdot)$ 为取矩阵的迹。

由于上述的块稀疏贝叶斯学习框架是将 MMV 模型转换为块 SMV 模型, 原问题的观测矩阵维度是 $N \times (N+K)$, 转换后的观测矩阵维度是 $NR \times (N+K)R$, 因此是在更高维度的空间进行相关参数学习和信号重构, 这会导致计算复杂度急剧增加。

为了降低计算复杂度, 本文通过近似将该算法反映射到原始问题空间, 提出 TMSBL-LS 算法。首先使用 TMSBL 算法获取稀疏信号的支撑集, 然后利用 LS 方法有效地恢复出稀疏信号。该算法的主要思想基于引理 1。

引理 1 如果 MMV 模型中每个 SMV 模型的稀疏信号具有相同的支撑集, 那么, 引入自动相关性确定 (ARD, automatic relevance determination) 概念于贝叶斯推导过程后, MMV 模型中稀疏信号矩阵的后验估计均值和协方差可以表示为

$$\boldsymbol{\Sigma}_w = (\boldsymbol{\Gamma}^{-1} + \sigma^{-2} \boldsymbol{\Phi}^H \boldsymbol{\Phi})^{-1} \quad (20)$$

$$\bar{\boldsymbol{\mu}} = \boldsymbol{\Gamma} \boldsymbol{\Phi}^H (\sigma^2 \mathbf{I} + \boldsymbol{\Phi} \boldsymbol{\Gamma} \boldsymbol{\Phi}^H)^{-1} \mathbf{Y} \quad (21)$$

引理 1 的证明可参考文献[18]。

采用引理 1 中的后验均值和协方差作为 TMSBL 算法估计所得的后验均值和协方差。为降低式(17)~式(19)超参数更新中矩阵求逆的复杂度, 采用以下近似

$$\begin{aligned} (\sigma^2 \mathbf{I}_{NR} + \mathbf{D} \boldsymbol{\Sigma}_0 \mathbf{D}^H)^{-1} &= \\ (\sigma^2 \mathbf{I}_{NR} + (\boldsymbol{\Phi} \boldsymbol{\Gamma} \boldsymbol{\Phi}^H) \otimes \mathbf{B})^{-1} &\approx \\ (\sigma^2 \mathbf{I}_N + \boldsymbol{\Phi} \boldsymbol{\Gamma} \boldsymbol{\Phi}^H)^{-1} \otimes \mathbf{B}^{-1} & \end{aligned} \quad (22)$$

由此, 超参数的更新规则可以重新表示为

$$\gamma_i = \frac{1}{R} \bar{\boldsymbol{\mu}}_i \mathbf{B}^{-1} \bar{\boldsymbol{\mu}}_i^H + (\boldsymbol{\Sigma}_w)_{ii} \quad (23)$$

$$\tilde{\mathbf{B}} = \sum_{i=1}^{N+K} \frac{\bar{\boldsymbol{\mu}}_i^H \bar{\boldsymbol{\mu}}_i}{\gamma_i} + \eta \mathbf{I} \quad (24)$$

$$\mathbf{B} = \frac{\tilde{\mathbf{B}}}{\|\tilde{\mathbf{B}}\|_F} \quad (25)$$

$$\sigma^2 = \frac{\|\mathbf{Y} - \boldsymbol{\Phi} \bar{\boldsymbol{\mu}}\|_F^2}{NR} + \frac{\sigma^2}{N} \text{Tr} \left[\boldsymbol{\Phi} \boldsymbol{\Gamma} \boldsymbol{\Phi}^H (\sigma^2 \mathbf{I} + \boldsymbol{\Phi} \boldsymbol{\Gamma} \boldsymbol{\Phi}^H)^{-1} \right] \quad (26)$$

其中, $\eta (\eta > 0)$ 是为了增强算法鲁棒性而引入的常数。求得 γ_i , \mathbf{B} 和 σ^2 后, 将结果代入式(20)和式(21), 得到更新后的后验均值 $\bar{\boldsymbol{\mu}}$ 和协方差矩阵 $\boldsymbol{\Sigma}_w$, 然后利用更新后的 $\bar{\boldsymbol{\mu}}$ 和 $\boldsymbol{\Sigma}_w$ 来计算新的超参数, 反复迭代, 直到满足终止条件。

迭代停止后, 从决定信号块稀疏性的 γ_i 中提取出高于设定阈值 ε 的 γ_i 索引并构成索引集 \mathcal{A} , 即活跃用户和脉冲噪声突发位置的索引集, 最后使用 LS 方法即可得到包含信道和脉冲噪声估计值的解 $\tilde{\mathbf{W}}$ 。

$$\tilde{\mathbf{W}}_{\mathcal{A}} = \boldsymbol{\Phi}_{\mathcal{A}}^{\dagger} \mathbf{Y} \quad (27)$$

$$\tilde{\mathbf{W}}_{\{1,2,\dots,N+K\} \setminus \mathcal{A}} = \mathbf{0} \quad (28)$$

根据压缩感知方程式(7), 可知 \mathbf{W} 的构成为

$$\mathbf{W} = \begin{bmatrix} \mathbf{H} \\ \mathbf{I} \end{bmatrix} = \begin{bmatrix} \mathbf{h}^1, \mathbf{h}^2, \dots, \mathbf{h}^R \\ \mathbf{i}_p^1, \mathbf{i}_p^2, \dots, \mathbf{i}_p^R \end{bmatrix} \quad (29)$$

因此, 从最终得到的 $\tilde{\mathbf{W}}$ 中提取出 $[\tilde{\mathbf{h}}^1, \tilde{\mathbf{h}}^2, \dots, \tilde{\mathbf{h}}^R]$ 构成的矩阵, 即估计所得的信道。再从 $\tilde{\mathbf{W}}$ 中提取出与脉冲噪声相关的参数 $[\tilde{\mathbf{i}}_p^1, \tilde{\mathbf{i}}_p^2, \dots, \tilde{\mathbf{i}}_p^R]$, 即估计所得的脉冲噪声。基于 TMSBL-LS 的联合多用户检测、信道估计和脉冲噪声估计方法如算法 1 所示。

算法 1 基于 TMSBL-LS 的联合多用户检测、信道估计和脉冲噪声估计方法

输入 $\mathbf{Y}, \boldsymbol{\Phi}, l_{\max}$

输出 $\tilde{\mathbf{W}}$

- 1) 初始化: $\gamma_i^{(0)} = 0.001, \mathbf{B}^{(0)} = \mathbf{I}_R, (\sigma^2)^{(0)} = 1$
- 2) for $l = 1:l_{\max}$
- 3) 按照式(20)更新 $\boldsymbol{\Sigma}_w^{(l)}$
- 4) 按照式(21)更新 $\bar{\boldsymbol{\mu}}^{(l)}$
- 5) 按照式(23)更新 $\gamma_i^{(l)}$
- 6) 按照式(24)和式(25)更新 $\mathbf{B}^{(l)}$
- 7) 按照式(26)更新 $(\sigma^2)^{(l)}$
- 8) end for

9) $A = \text{find}(\gamma > \varepsilon)$

10) 按照式(27)和式(28)得到 \tilde{W}

3 仿真结果与分析

本文通过蒙特卡罗仿真, 将所提 TMSBL-LS 算法与基于高斯广义近似消息传递的稀疏贝叶斯学习 (GGAMP-SBL, Gaussian generalized approximate message passing-sparse Bayes learning) 算法^[19]、多响应稀疏贝叶斯学习 (MSBL, multiple response sparse Bayes learning) 算法^[20]、未进行脉冲噪声抑制的 Oracle LS (oracle least square) 算法^[21]和考虑脉冲噪声抑制的 OLS-WINS (oracle least square-with impulsive noise suppression) 算法在多用户检测正确率、信道估计、脉冲噪声估计和 SER 方面的性能上进行了比较。GGAMP-SBL 算法是基于稀疏贝叶斯学习的框架引入高斯广义近似消息传递的稀疏信号恢复算法, 其利用单测量向量信息进行稀疏信号恢复。MSBL 算法是基于稀疏贝叶斯学习框架利用多测量向量信息进行稀疏信号恢复的算法。TMSBL-LS 算法、GGAMP-SBL 算法和 MSBL 算法的计算复杂度如表 1 所示, 其中, s 表示信号稀疏度。在 Oracle LS 算法中, 基站处已获知活跃用户支撑集信息, 但未考虑脉冲噪声抑制, 由于需要预先获知准确的活跃用户信息, 这在实际中是不可能的, 因此可以看作不进行脉冲噪声抑制下估计性能的上限。为了提供信道和脉冲噪声联合估计的上限, 本文将 Oracle LS 算法推广到脉冲噪声干扰下的 GF-NOMA 系统, 提出 OLS-WINS 算法。在 OLS-WINS 算法中, 基站端已获知活跃用户支撑集和脉冲噪声突发位置的信息, 将原压缩感知的欠定问题转化为超定问题后, 使用 LS 方法实现信道和脉冲噪声的联合估计。由于实际中不可能预先获知准确的用户活跃和脉冲噪声突发位置信息, 因此可以看作联合估计性能的上限。

在 GF-NOMA 系统中, 设置 mMTC 的总用户数 K 为 200, 活跃用户数为 10, 子载波数 N 为 100,

基站天线根数 R 为 7, 采用 4-QAM 调制, 扩频序列采用伪随机高斯序列。脉冲噪声模型采用高斯混合模型, 若令复高斯随机变量 i 表示脉冲噪声, 则 i 的概率密度函数为 $f(i) = \sum_{s=1}^S \beta_s f_s(i_s)$, 其中, β_s 表示

第 s 个随机变量 i_s 出现的概率, $\sum_{s=1}^S \beta_s = 1$; $f_s(i_s)$ 表示 i_s 的概率密度函数, 其服从均值为 0、方差为 v_s 的复高斯分布。脉冲噪声模型中, 设置 $\beta = [0.9, 0.07, 0.03]$, 方差分别为 $v = [0, 100\sigma_z^2, 1000\sigma_z^2]$ 。

信噪比为 $\text{SNR} = \frac{P_s}{P_i + P_z}$, 其中, P_s 表示信号功率, P_i 表示脉冲噪声功率, P_z 表示背景噪声功率。信道估计的归一化均方误差 (NMSE, normalized mean square error) 和脉冲噪声估计的均方误差 (MSE, mean square error) 分别定义为

$$\text{NMSE} = \text{E} \left\{ \frac{\| \mathbf{h}^r - \tilde{\mathbf{h}}^r \|^2}{\| \mathbf{h}^r \|^2} \right\} \quad (30)$$

$$\text{MSE} = \text{E} \left\{ \left\| i_p^r - \tilde{i}_p^r \right\|_2^2 \right\} \quad (31)$$

图 1 展示了不同信噪比下各算法的多用户检测正确率。由于 Oracle LS 算法和 OLS-WINS 算法已预先获知活跃用户信息, 因此多用户检测正确率均为 100%。从图 1 中可以看出, TMSBL-LS 算法、MSBL 算法和 GGAMP-SBL 算法的多用户检测正确率均随着信噪比的增加而逐渐上升, 最终都趋于 100%。在信噪比较高时, 即脉冲噪声干扰较弱的情况下, 各种算法的多用户检测正确率差异不大, 但 TMSBL-LS 算法的多用户检测正确率略高于 MSBL 算法和 GGAMP-SBL 算法。然而, 在信噪比较低时, 即脉冲噪声干扰较强的情况下, TMSBL-LS 算法仍然具有非常高的多用户检测正确率, 而 MSBL 算法和 GGAMP-SBL 算法的多用户检测正确率均明显低于 TMSBL-LS 算法, 并且随着信噪比

表 1 3 种算法的计算复杂度对比

算法	计算复杂度
TMSBL-LS	$O((N+K)^3 + N(N+K)^2 + (2NR + 2N^2 + R^2)(N+K) + R^3 + s^3 + N^3 + (2s+R)N^2 + NRs)$
GGAMP-SBL	$O((N+K)N)$
MSBL	$O(N^3 + N(N+K)^2 + 2N^2(N+K) + 2NR(N+K))$

的降低，这种差距变得更加显著。这是因为 TMSBL-LS 算法相比于 MSBL 算法能更好地利用多测量向量信息，相比于 GGAMP-SBL 算法则是利用了更多的接收信息进行活跃用户检测。这使 TMSBL-LS 算法能够在信噪比更低的情况下相较于 MSBL 算法和 GGAMP-SBL 算法更准确地检测出活跃用户。

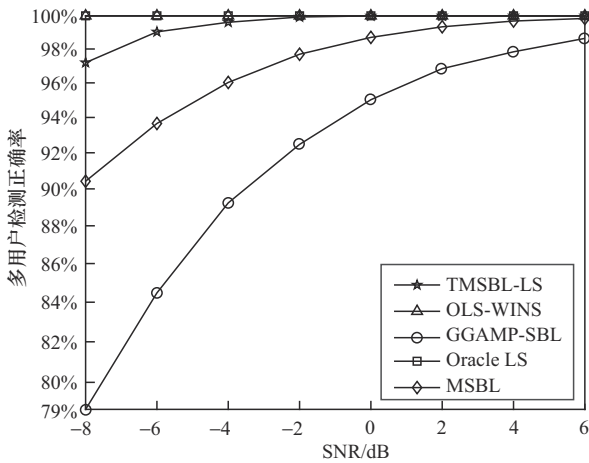


图1 不同信噪比下各算法的多用户检测正确率

图2为各算法的信道估计NMSE随信噪比变化曲线。从图2可以看出，随着信噪比的增加，各算法的信道估计NMSE均在减小。在所有算法中，Oracle LS算法表现出的信道估计性能最差，这可以被视为未进行脉冲噪声抑制的信道估计性能上限。这是因为该算法已预先获知活跃用户的支撑集信息，但并未考虑对脉冲噪声的干扰进行抑制，这表明脉冲噪声会对上行GF-NOMA系统的性能产生严重损害。在所有的信噪比区间内，TMSBL-LS算法的信道估计NMSE均优于MSBL算法和GGAMP-SBL算法，并且随着信噪比的增加，这种性能优势变得更加明显。在各算法中，OLS-WINS算法展现出最佳的信道估计性能，这是因为该算法可被视为估计性能的上限。此外，随着信噪比的增加，TMSBL-LS算法的信道估计NMSE逐渐接近于OLS-WINS算法，这充分体现了TMSBL-LS算法在信道估计方面的优越性能。

图3为各算法的脉冲噪声估计MSE随信噪比变化曲线。由于Oracle LS算法不考虑脉冲噪声抑制，因此未绘制相应曲线。从图3可以看出，随着信噪比的增加，各算法的脉冲噪声估计MSE均在下降。在所有算法中，可被视为估计性能上限的OLS-

WINS算法表现出最佳的脉冲噪声估计性能。从所有的信噪比区间内可以看出，TMSBL-LS算法的脉冲噪声估计MSE均低于MSBL算法和GGAMP-SBL算法，并且随着信噪比的增加，这种性能提升变得更加明显。这同样是因为相较于MSBL算法和GGAMP-SBL算法，TMSBL-LS算法能够更充分地利用多根天线接收下脉冲噪声呈现的联合稀疏性来准确获取突发脉冲噪声的支撑集，最终通过使用LS方法有效地估计出了脉冲噪声。此外，随着信噪比的增加，TMSBL-LS算法与OLS-WINS算法的脉冲噪声估计MSE差距略有缩小，这表明TMSBL-LS算法在脉冲噪声估计方面同样具有出色的性能。

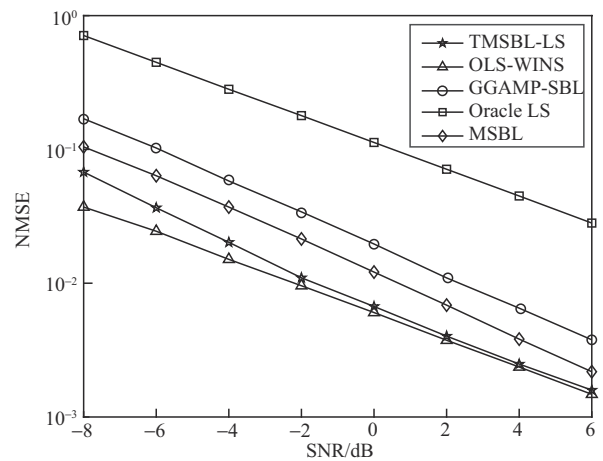


图2 各算法的信道估计NMSE随信噪比变化曲线

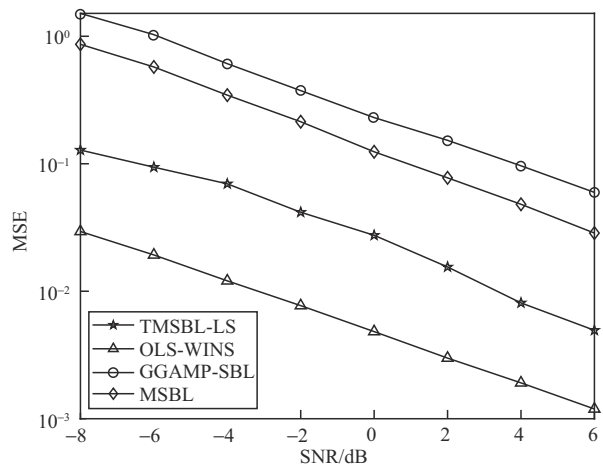


图3 各算法的脉冲噪声估计MSE随信噪比变化曲线

图4展示了不同信噪比下各算法的SER。从图4可以看出，随着信噪比的增加，各算法的SER均在减小。其中，Oracle LS算法表现出的SER性能

非常糟糕,这是由于该算法未对脉冲噪声的干扰进行抑制,这也反映出脉冲噪声会严重影响GF-NOMA系统的性能。至于图4中出现的Oracle LS算法与GGAMP-SBL算法的交叉点,这是因为GGAMP-SBL算法仅能利用单测量向量的信息,在低信噪比时,对稀疏信号的恢复效果欠佳,影响多用户检测、信道估计和脉冲噪声估计性能,从而导致糟糕的误码率性能。而Oracle LS算法虽未考虑进行脉冲噪声抑制,但已知活跃用户支撑集信息,即多用户检测正确率为100%,远高于低信噪比下的GGAMP-SBL算法,故在此情况下的误码率性能优于GGAMP-SBL算法。此外,从图1中可以看出,随着信噪比的增加,GGAMP-SBL算法的多用户检测正确率逐渐接近100%,同时考虑了脉冲噪声抑制,其误码率性能也随之改善,从而逐渐优于未进行脉冲噪声抑制的Oracle LS算法。在各算法中,OLS-WINS算法展现出最佳的SER性能,这是因为该算法可被视为联合估计性能的上限。在所有的信噪比区间内,TMSBL-LS算法的SER性能始终优于MSBL算法和GGAMP-SBL算法。此外,随着信噪比的增加,TMSBL-LS算法的SER逐渐接近OLS-WINS算法,这也展示出TMSBL-LS算法在SER性能上的优越性。




图4 不同信噪比下各算法的SER

图5展示了不同信噪比下各算法的运行时间。一方面,从表1容易看出,GGAMP-SBL算法的计算复杂度最低,TMSBL-LS算法的复杂度最高,MSBL算法的计算复杂度虽介于GGAMP-SBL算法和TMSBL-LS算法之间,但和TMSBL-LS算法的计算复杂度仍属于同一量级。另一方面,从图5可

以看出,GGAMP-SBL算法的运行时间最短,这是因为该算法在处理单测量向量压缩感知问题中涉及的运算量较低,这与表1中计算复杂度分析结果一致。

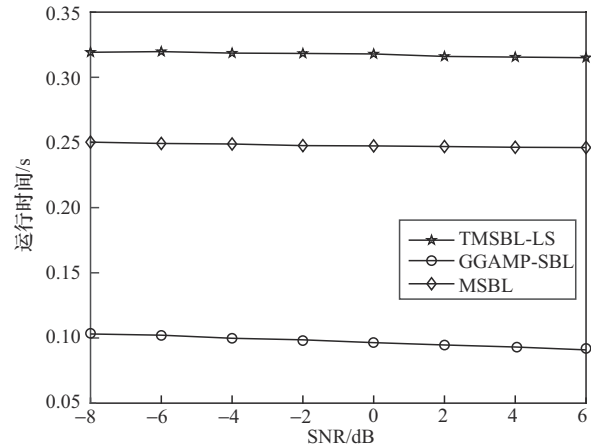


图5 不同信噪比下各算法的运行时间

4 结束语

针对脉冲噪声干扰下GF-NOMA系统中的多用户检测和信道估计问题,本文基于GF-NOMA系统中用户通信的零星特性和突发脉冲噪声的稀疏特性,利用多测量向量下的待重构信号呈现的块稀疏性提出了一种基于TMSBL-LS的联合多用户检测、信道估计和脉冲噪声估计方法。首先根据mMTC零星通信的特点和突发脉冲噪声的稀疏性将从多根天线接收的信号中进行多用户检测、信道估计和脉冲噪声估计的问题建模成MMV-CS问题,然后通过TMSBL算法获取活跃用户和突发脉冲噪声的支撑集,最后使用LS方法有效地估计出信道和脉冲噪声。本文方法充分利用了多测量向量下的待恢复信号的联合稀疏性,从而显著地提高了多用户检测、信道估计和脉冲噪声估计的性能。仿真结果表明,与现有的方法相比,本文方法在多用户检测、信道估计、脉冲噪声估计和SER方面均表现出更好的性能。

参考文献:

- [1] CHEN X M, NG D W K, YU W, et al. Massive access for 5G and beyond[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(3): 615-637.
- [2] WU L T, SUN P, WANG Z B, et al. Temporal correlation enhanced multiuser detection for uplink grant-free NOMA[J]. IEEE Transactions on

- Mobile Computing, 2023, 22(4): 2446-2457.
- [3] CUI Y P, XU W B, WANG Y, et al. Side-information aided compressed multi-user detection for up-link grant-free NOMA[J]. IEEE Transactions on Wireless Communications, 2020, 19(11): 7720-7731.
- [4] SHIM B, SONG B. Multiuser detection via compressive sensing[J]. IEEE Communications Letters, 2012, 16(7): 972-974.
- [5] DU Y, CHENG C, DONG B H, et al. Block-sparsity-based multiuser detection for uplink grant-free NOMA[J]. IEEE Transactions on Wireless Communications, 2018, 17(12): 7894-7909.
- [6] DAI W, MILENKOVIC O. Subspace pursuit for compressive sensing signal reconstruction[J]. IEEE Transactions on Information Theory, 2009, 55(5): 2230-2249.
- [7] WANG B C, DAI L L, MIR T, et al. Joint user activity and data detection based on structured compressive sensing for NOMA[J]. IEEE Communications Letters, 2016, 20(7): 1473-1476.
- [8] DU Y, DONG B H, ZHU W Y, et al. Joint channel estimation and multiuser detection for uplink grant-free NOMA[J]. IEEE Wireless Communications Letters, 2018, 7(4): 682-685.
- [9] GAO P Y, LIU Z L, XIAO P, et al. Low-complexity channel estimation and multi-user detection for uplink grant-free NOMA systems[J]. IEEE Wireless Communications Letters, 2022, 11(2): 263-267.
- [10] YU H X, FEI Z S, ZHENG Z, et al. Deep learning-based user activity detection and channel estimation in grant-free NOMA[J]. IEEE Transactions on Wireless Communications, 2023, 22(4): 2202-2214.
- [11] LIU S C, YANG F, DING W B, et al. Double kill: compressive-sensing-based narrow-band interference and impulsive noise mitigation for vehicular communications[J]. IEEE Transactions on Vehicular Technology, 2016, 65(7): 5099-5109.
- [12] SACUTO F, LABEAU F, AGBA B L. Wide band time-correlated model for wireless communications under impulsive noise within power substation[J]. IEEE Transactions on Wireless Communications, 2014, 13(3): 1449-1461.
- [13] SELIM B, ALAM M S, KADDOUM G, et al. Effect of impulsive noise on uplink NOMA systems[J]. IEEE Transactions on Vehicular Technology, 2020, 69(3): 3454-3458.
- [14] HUSSAIN M, SHAKIR H, RASHEED H. Deep learning approaches for impulse noise mitigation and classification in NOMA-based systems[J]. IEEE Access, 2021, 9: 143836-143846.
- [15] CAI W Y, LI Y M, ZHANG X L, et al. Impulsive noise suppression based on ℓ_q -norm and graph Laplacian regularization for NOMA system[J]. IEEE Wireless Communications Letters, 2024, 13(8): 2050-2054.
- [16] LI F, PENG Y T, CHEN W. Sparse multi-user detection with imperfect channel estimation for NOMA systems under non-Gaussian noise[J]. IEEE Wireless Communications Letters, 2021, 10(2): 246-250.
- [17] ZHANG Z L, RAO B D. Sparse signal recovery with temporally correlated source vectors using sparse Bayes learning[J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(5): 912-926.
- [18] WIPF D P, RAO B D. An empirical Bayes strategy for solving the simultaneous sparse approximation problem[J]. IEEE Transactions on Signal Processing, 2007, 55(7): 3704-3716.
- [19] AL-SHOUKAIRI M, SCHNITER P, RAO B D. A GAMP-based low complexity sparse Bayes learning algorithm[J]. IEEE Transactions on Signal Processing, 2018, 66(2): 294-308.
- [20] 吕新荣, 李有明, 国强. MIMO-OFDM 系统的信道与脉冲噪声联合估计方法[J]. 通信学报, 2021, 42(12): 54-64.
- LYU X R, LI Y M, GUO Q. Joint channel and impulsive noise estimation method for MIMO-OFDM systems[J]. Journal on Communications, 2021, 42(12): 54-64.
- [21] WU L T, SUN P, WANG Z B, et al. Joint user activity identification and channel estimation for grant-free NOMA: a spatial-temporal structure-enhanced approach[J]. IEEE Internet of Things Journal, 2021, 8(15): 12339-12349.

[作者简介]



李有明 (1963-), 男, 陕西扶风人, 博士, 宁波大学教授, 主要研究方向为无线宽带通信、电力线通信、协作中继、认知无线电等。



陈江涛 (2000-), 男, 湖北大悟人, 宁波大学硕士生, 主要研究方向为压缩感知、多用户检测、信道估计、脉冲噪声估计。



吴永宏 (1974-), 男, 山西怀仁人, 博士, 中国电波传播研究所高级工程师, 主要研究方向为短波通信、网络规划和信号处理等。



徐伯禹 (1988-), 男, 山东青岛人, 博士, 中国电波传播研究所工程师, 主要研究方向为短波通信、信号检测和智能处理等。



蔡万源 (1998-), 男, 浙江温州人, 宁波大学博士生, 主要研究方向为毫米波 MIMO 信道估计、脉冲噪声估计、图信号处理理论与应用。