

基于分组导频与压缩感知的大规模随机接入方案

俞龙鸣¹, 吴烁雨¹, 谌翔^{2, 3}, 张晶^{2, 3}

(1. 南京邮电大学波特兰学院, 江苏 南京 210023; 2. 南京邮电大学通信与信息工程学院, 江苏 南京 210023; 3. 江苏省无线通信与物联网重点实验室, 江苏 南京 210003)

摘要: 针对大规模物联网终端零星随机接入传输难题, 提出一种基于分组导频和压缩感知 (Compressive Sensing, CS) 的大规模接入方案。首先, 基站对用户预分组并为每组用户配置一个公共导频, 用户采用导频、ID 和数据构成的组合帧执行上行随机接入传输。然后, 基站逐帧接收上行信号, 依次建立导频时隙、ID 时隙、数据时隙的上行接收信号模型。最后, 设计了基于用户分组的同步正交匹配追踪 (Group Based Synchronized Orthogonal Matching Pursuit, GB-SOMP) 算法, 先利用导频时隙接收信号检测活跃分组, 再利用数据时隙的接收信号精确估计活跃用户集合, 进而完成活跃用户上行信道系数估计并重构上行数据。仿真结果表明, GB-SOMP 算法的时间复杂度和检测精度均优于经典 SOMP 算法; 所提随机接入方案有效提升了无线网络的接入承载能力。

关键词: 压缩感知; 大规模接入; 分组导频; 多观测矢量; 用户活动检测; 信道估计

中图分类号: TN929.5

文献标志码: A

doi: 10.11959/j.issn.2096-3750.XXXX.

A Massive Access Scheme Based on Group Preamble and Compressive Sensing

YU Long-Ming¹, WU Shuo-Yu¹, CHEN Xiang^{2,3}, ZHANG Jing^{2,3}

1. Portland College, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

2. School of Communications and Information Engineering, Nanjing 210003, China

3. Jiangsu Key Laboratory of Wireless Communications and Internet of Things, Nanjing 210003, China

Abstract: For the sporadic random access transmission scenario of massive IoT devices, a massive access scheme based on grouped pilots and compressive sensing (CS) is proposed. First, the base station pre-groups users and assigns a common preamble to each group, while users perform uplink random access transmission using a combined frame consisting of pilot, ID, and data. Then, the base station receives uplink signals frame by frame and sequentially establishes the uplink signal models for the preamble slot, ID slot, and data slot. Finally, a group-based synchronized orthogonal matching pursuit (GB-SOMP) algorithm is designed. It first detects active groups using the preamble slot received signals, then accurately estimates the active user set with the data-slot received signals, and subsequently completes the estimation of uplink channel coefficients for active users and reconstructs the uplink data. Simulation results show that the GB-SOMP algorithm outperforms typical SOMP algorithms in both computational complexity and detection accuracy. The proposed random access scheme effectively enhances the access capacity of wireless networks.

Key words: Compressive sensing, massive access, group preamble, multiple measurement vectors, user activity detection, channel estimation

收稿日期: 2025-11-01; 修回日期: XXXX-XX-XX

通信作者: 张晶, jingzhang@njupt.edu.cn

基金项目: 国家重点研发计划 (No.2020YFB1807202); 国家自然科学基金 (No.92067201); 江苏省重点研发计划 (No.BE2020084-1)

Foundation Items: The National Key Research and Development Program (No.2020YFB1807202), The National Natural Science Foundation of China (No.BE2020084-1), Jiangsu Province Key Research and Development Plan (No.BE2020084-1)

0 引言

随着物联网的快速发展,大规模机器类型通信(mMTC, massive Machine Type Communication)成为5G及未来B5G/6G移动通信系统的关键应用场景之一^[1-2]。该场景下,基站需支持成千上万的设备并发接入,这些设备通常具备低功耗、小包传输和随机突发的通信特性^[3-4],采用传统授权接入技术无疑会带来巨大的信令开销和传输时延,设计大规模免授权随机接入方案(MGFRA, Massive Grant-Free Random Access)势在必行。

针对 mMTC 场景中稀疏突发接入传输请求,文献[5]提出了基于压缩感知(CS, Compressive Sensing)的随机接入方案。即基站为每个用户分配唯一的扩频序列即用户身份码(ID, Identity Code),活跃用户采用其扩频序列将业务数据扩频后发送至基站;基站接收来自多个用户的叠加信号,利用用户扩频序列和接收信号构建大规模稀疏上行信号的欠定线性重构问题。其后的文献采用正交匹配追踪(OMP, Orthogonal Matching Pursuit)^[6]、近似消息传递(AMP, Approximate Message Passing)^[7]等算法完成活跃用户检测和用户上行信号重构。针对多时隙上行传输场景,多观测矢量CS算法被提出,如同步正交匹配追踪(SOMP, Simultaneous Matching Pursuit)^[8-9]、多观测矢量近似消息传递(MMV-AMP, Multiple Measurement Vectors-Approximate Message Passing)^[10-11]等算法,利用一帧中多个时隙接收信号的稀疏结构一致性实现更准确的活跃用户检测。

面向 MGFRA 的 CS 算法均依赖上行信道状态信息(CSI, Channel State Information),设计联合信道估计的CS算法成为近年来MGFRA领域的研究热点^[12-17]。文献[12-13]提出一种基于导频的CS信道估计方案,它允许用户传输上行业务数据前先行传输一个导频序列,基站利用导频序列执行活跃用户检测并同步估计出每个活跃用户的上行信道衰落系数。文献[14]联合一帧中导频时隙和数据时隙的接收信号构建多观测矢量(MMV, Multiple Measurement Vectors),并设计了MMV-CS算法实现活跃用户及其上行信道衰落系数的联合估计,利用导频和数据信号的共同稀疏模式提升多用户信号检测性能。

文献[15]充分利用多个子载波上用户活动的相似性将多载波MGFRA系统中活动用户检测和上行信道估计建模为多观测矢量模型,采用了MMV-AMP算法,提升了支持集的估计能力和多载波CS信号重构性能。文献[16]提出一种新型多用户联合接收机,采用涡轮结构耦合活动用户检测、信道估计和数据解码以提高大规模接入性能,同时引入数据解码软信息作为外部先验消息来辅助改进支撑集的估计性能。文献[17]将机器学习引入CS算法中,采用机器学习捕捉难以用模型描述的用户活动模式,据此预测用户的活跃时段作为检测活跃用户时的先验信息,但方案目前仍存在诸多挑战。针对稀疏度自适应匹配追踪(SAMP, Sparsity Adaptive Matching Pursuit)类算法^[19-21]受噪声干扰导致活跃用户支撑集过估计的问题,文献[18]提出了基于门限的块稀疏自适应子空间追踪(TA-BSASP, Threshold Aided Block Sparsity Adaptive Subspace Pursuit)方法,以抑制噪声带来的误检。文献[22]采用 $\ell_{2,0}$ 型正则化对MMV恢复问题进行建模,提出多测量向量交替方向乘子法(MMV-ADMM),有效地刻画多观测条件下的联合稀疏结构。

虽然MMV-AMP、SOMP、SAMP等算法已被广泛应用于MGFRA中,但这些算法的时间复杂度均随着用户规模的增加而线性增长^[15];同时,当用户总数与扩频序列长度的比值过高时,上行信号矩阵列间最大相关性变大,多用户信号的重构变得困难。目前,多数CS算法的检测能力有限,例如仅能在180KHz的固定带宽上实现总用户规模为 $10^2 \sim 10^3$ 个的可靠用户检测^[13-17],总用户量级增加时算法性能将急速下降,难以满足3GPP提出的高过载大规模接入需求。

针对该问题,文献[23-24]提出基于竞争的随机接入检测框架,其核心思想是活跃用户从公共导频池中随机选取一个导频执行上行接入传输,基站对接收的上行信号先利用导频进行活跃用户检测,后结合业务时隙中的ID序列完成用户身份确认。其中,文献[23]采用SOMP算法作为活跃用户检测算法,形成CB-SOMP(Contention-Based SOMP)方案。文献[24]在该框架基础上设计深度学习CS算法提升检测效率。该竞争式接入框架联合导频和ID增强用户特征,在一定程度上缓解了用户总量过大带来的CS算法性能下降问题。但当多个用户

选择同一导频且用户ID相关性较高时，将发生导频碰撞，导致用户随机接入成功率下降。这是制约该框架性能提升的关键因素。

为了减少导频碰撞同时提升上行多用户检测性能，本文提出一种基于分组导频和CS的MGFRA方案。该方案中，基站根据用户历史活跃信息对用户进行预分组并为每组用户配置一个公共导频，每个用户的配置一个独一无二的ID，用户采用导频、ID和数据构成的组合帧执行上行随机接入传输。基于此结构设计了基于用户分组的同步正交匹配追踪(GB-SOMP, Group Based-SOMP)算法，第一阶段利用接收的导频信号筛选出活跃分组，获得支持集的粗略估计值；第二阶段利用ID时隙和数据时隙的接收信号获得支持集的精确估计值，进而完成活跃用户上行信道系数估计并重构用户上行数据。这种粗细搜索结合的方式缩小了活跃用户检测的搜索范围，而分组导频联合用户ID的传输方案在增强用户特征同时限制了导频碰撞的范围，有效提升了上行信号的检测重构性能。算法分析和仿真结果表明，GB-SOMP算法在时间复杂度和检测精度上均优于SOMP算法，整体性能相较CB-SOMP算法取得了计算复杂度和信号检测性能的折衷。

本文内容安排如下：第1节介绍系统场景与传输模型；第2节建模分析上行接收信号并阐述CS信号重构问题；第3节设计上行信号检测算法即GB-SOMP算法，第4节对GB-SOMP算法性能开展理论分析；第5节对所提算法性能进行仿真分析；第6节为总结。

1 系统场景与传输模型

1.1 系统场景

考虑图1所示的单蜂窝mMTC上行传输场景，一个基站管理 N 个单天线用户设备。用户随机激活进行上行传输，任一时刻仅有少量的 n_a 个用户向基站发送信号， $n_a \ll N$ 。鉴于mMTC业务流量具有准周期性特征^[25-26]，基站每隔一段时间采用 K -means算法^[27-28]按照用户的历史活跃时间分布情况将小区内所有用户聚类得到 K 个簇，进而根据用户到 K 个簇心的距离将所有用户分为 K 个组，每组内用户数目为 G 个， $G = \lceil N/K \rceil$ ， $\lceil * \rceil$ 表示取上整数。

基站为每个分组生成一个导频序列。基站随机生成一个 $[0, 2\pi]$ 均匀分布的随机数 θ ，对于第 k 个

分组，定义相位增量 $\theta_k = \frac{2\pi k}{B} + \theta$ ，以 θ_k 为间隔从复平面单位圆上均匀抽取 B 个点构成 B 维列向量，作为分组 k 的导频序列 \mathbf{p}^k ，即

$$\mathbf{p}^k = [p_1^k, p_2^k, \dots, p_B^k]^T \in \mathbf{C}^{B \times 1} \quad (1)$$

其中， $[*]^T$ 表示向量或矩阵的转置， $p_b^k = e^{j b \theta_k}$ ， $b = 1, 2, \dots, B$ ； $\mathbf{C}^{B \times 1}$ 表示 B 维复数域列向量空间。分组内用户共享同一分组导频。

令 $K \leq B$ ，上述导频构造方式等价于对 B 点DFT矩阵的 K 个列向量施加一个相位旋转变换，因而不同分组的导频序列两两正交。对其进行归一化处理，有 $(\mathbf{p}^k)^H \mathbf{p}^l = 0$ ， $(\mathbf{p}^k)^H \mathbf{p}^k = 1$ ， $\forall k, l \in \{1, 2, \dots, K\}, k \neq l$ 。




图1 系统场景

1.2 传输模型

基站为每个用户预配置一个唯一的用户ID即扩频序列 $\mathbf{s}^n = [s_1^n, s_2^n, \dots, s_B^n]^T \in \mathbf{C}^{B \times 1}$ ，其各元素 s_b^n 从单位圆上均匀分布的随机相位集合中抽取获得，即

$$s_b^n = e^{j \theta_{n,b}}, \theta_{n,b} \sim U[0, 2\pi), b = 1, 2, \dots, B \quad (2)$$

其中， $U[0, 2\pi)$ 为区间 $[0, 2\pi)$ 上的均匀分布。

活跃用户采用时间帧执行上行随机接入。如图

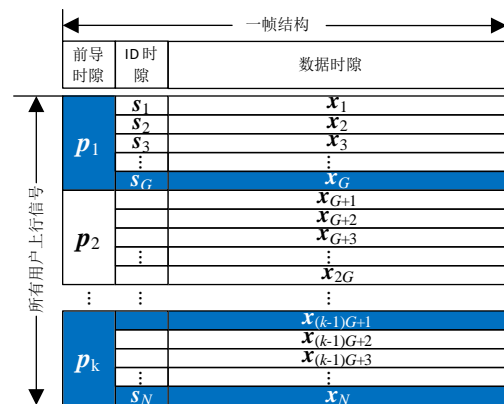


图2 上行传输帧结构

2所示, 每帧包含一个导频时隙、一个ID时隙和L个数据时隙; 活跃用户依次在一帧的(L+2)个时隙中传输导频、用户ID和L个业务数据。对任一用户n, 令其ID为 s^n , 上行业务数据向量为 $d_n = [d_{n,1}, d_{n,2}, \dots, d_{n,L}] \in \mathbf{C}^{1 \times L}$; 每个数据 $d_{n,l}$ 代表一个用户调制数据符号, 它由用户ID即 s^n 扩频为向量 $d_{n,l}s^n$ 。于是, 用户n的扩频业务信号 u^n 表示为:

$$u^n = [d_{n,1}(s^n)^T, d_{n,2}(s^n)^T, \dots, d_{n,L}(s^n)^T]^T \quad (3)$$

不妨令用户n属于分组k, 则其导频 $\bar{p}^n = p^k$; 于是, 用户n的一帧上行信号 x^n 表示为

$$x^n = [(\bar{p}^n)^T, (s^n)^T, u^n]^T = [(p^k)^T, (s^n)^T, u^n]^T \quad (4)$$

特别地, 若用户n在当前帧未发送业务数据即处于非活跃状态, 规定其业务数据向量 $d_n = 0$, 上行信号 $x^n = 0$ 。

2 上行接收信号模型

2.1 单天线基站信号接收模型

2.1.1 前导时隙的接收信号

基站逐帧接收多用户的上行信号。基站在任意一帧的前导时隙接收的信号 y_p 为来自K个分组的活跃用户导频信号之和, 它表示为

$$y_p = \sum_{k=1}^K \tilde{h}^k p^k + n_p \quad (5)$$

其中, p^k 是第k个分组的导频信号; \tilde{h}^k 为分组k的加权和信道系数, 定义为组内所有活跃用户信道衰落系数之和; n_p 是前导时隙的加性高斯白噪声, $n_p \sim CN(0, \sigma^2 I)$, 即其各元素独立同分布, 均服从零均值、方差为 σ^2 的复高斯分布。

引入导频矩阵 $P = [p^1, p^2, \dots, p^K]$, 以及加权和信道系数向量 $h_p = [\tilde{h}^1, \tilde{h}^2, \dots, \tilde{h}^K]^T$, 式(5)可以改写成矩阵形式, 即

$$y_p = Ph_p + n_p \quad (6)$$

其中, $P \in \mathbf{C}^{B \times K}$, $h_p \in \mathbf{C}^{K \times 1}$, $P^H P = I_K$ 。

根据系统模型, 每个分组内用户具有相似的活跃时段, 这意味着分组具有整体活跃或者整体静默的特征; 结合每个用户的低活跃特征, 可推知向量 h_p 为稀疏向量, 式(6)可视为一个分组维度的CS方程。

2.1.2 ID时隙的接收信号

基站在一帧中ID时隙接收的信号 y_{id} 为

$$y_{id} = \sum_{n=1}^N 1_{[u_n=1]} h^n s^n + n_{id} \quad (7)$$

其中, h^n 为用户n至基站的上行信道瑞利衰落系

数; s^n 为第n个用户的ID时隙信号; $n_{id} \in \mathbf{C}^{B \times 1}$ 是ID时隙的加性高斯白噪声, $n_{id} \sim CN(0, \sigma^2 I)$ 。

引入加权信道系数向量 $h_d = [1_{[u_1=1]} h^1, 1_{[u_2=1]} h^2, \dots, 1_{[u_N=1]} h^N]^T$, 以及扩频序列矩阵 $S = [s^1, s^2, \dots, s^N]$, 式(7)可以改写为:

$$y_{id} = Sh_d + n_{id} \quad (8)$$

其中, $S \in \mathbf{C}^{B \times N}$, $h_d \in \mathbf{C}^{N \times 1}$ 。

根据系统模型, 任一时刻只有少量用户传输数据, 所以 h_d 亦为稀疏向量。

2.1.3 数据时隙的接收信号

基站在一帧中第l个数据时隙接收的信号 $y_{d,l}$ 表示为

$$y_{d,l} = \sum_{n=1}^N h^n d_{n,l} s^n + n_{d,l} = SHd_l + n_{d,l} \quad (9)$$

其中, $y_{d,l} \in \mathbf{C}^{B \times 1}$; s^n 表示用户n的扩频序列; $S = [s^1, s^2, \dots, s^N] \in \mathbf{C}^{B \times N}$ 为用户扩频序列矩阵; $H = \text{diag}\{[h^1, h^2, \dots, h^N]\} \in \mathbf{C}^{N \times N}$ 表示上行信道系数矩阵, $d_l = [d_{1,l}, d_{2,l}, \dots, d_{n,l}, \dots, d_{N,l}]^T \in \mathbf{C}^{N \times 1}$ 为第l个数据时隙传输的业务数据向量, $n_{d,l} \in \mathbf{C}^{B \times 1}$ 为第l个数据时隙接收的加性噪声向量 $n_{d,l} \sim CN(0, \sigma^2 I)$ 。

于是, 基站在一帧L个数据时隙中收的信号矩阵 $Y_d = [y_{d,1}, y_{d,2}, \dots, y_{d,l}, \dots, y_{d,L}]$ 表示为

$$Y_d = SHD + N_d = SX + N_d \quad (10)$$

其中, $D = [d_1, d_2, \dots, d_l, \dots, d_L] \in \mathbf{C}^{N \times L}$ 表示L个数据时隙上传的业务数据矩阵; $X = HD \in \mathbf{C}^{N \times L}$ 表示加权业务数据矩阵; $N_d = [n_{d,1}, n_{d,2}, \dots, n_{d,l}, \dots, n_{d,L}] \in \mathbf{C}^{B \times L}$ 表示L个数据时隙的加性噪声矩阵。

鉴于任意时刻仅有少数用户处于活跃状态, 且每个用户在一帧多个时隙呈现相同的状态, 因此矩阵 X 具有行稀疏特性, 式(10)可视为一个CS方程, 采用CS算法可以重构加权业务数据矩阵 X , 进而恢复用户业务数据矩阵 D 。

2.2 多天线基站信号接收模型

将上述单天线接收模型推广至多天线基站场景。假设基站配备M根接收天线, 第m根接收天线在前导时隙的接收信号为

$$y_{p,m} = Ph_{p,m} + n_{p,m} \quad (11)$$

其中, $h_{p,m} \in \mathbf{C}^{K \times 1}$ 为第m根天线对应的加权和信道系数向量, $n_{p,m} \sim CN(0, \sigma^2 I)$ 。将M根天线的接收的前导信号按列顺序排列形成矩阵 Y_p , 即

$$Y_p = PH_p + N_p \quad (12)$$

其中, $H_p = [h_{p,1}, h_{p,2}, \dots, h_{p,m}]$

第 m 根天线在第 l 个数据时隙的接收信号为

$$\begin{aligned} \mathbf{y}_{d,l,m} &= \sum_{n=1}^N \mathbf{h}_{n,m} d_{n,l} \mathbf{s}^n + \mathbf{n}_{d,l,m} \\ &= \mathbf{S} \text{diag} \{ \mathbf{d}_l \} \mathbf{h}_{d,m} \end{aligned} \quad (13)$$

其中, $\mathbf{h}_{d,m} \in \mathbf{C}^{N \times 1}$ 为用户至第 m 根天线的加权信道系数向量。

将数据时隙 l 中 M 根天线的接收信号顺序排列形成矩阵 $\mathbf{Y}_{d,l}$, 可表示为

$$\mathbf{Y}_{d,l} = \mathbf{S} \text{diag} \{ \mathbf{d}_l \} \mathbf{H}_d + \mathbf{N}_{d,l} = \mathbf{S} \mathbf{X}_l + \mathbf{N}_{d,l} \quad (14)$$

其中, $\mathbf{H}_d = [\mathbf{h}_{d,1}, \mathbf{h}_{d,2}, \dots, \mathbf{h}_{d,M}]$, $\mathbf{X}_l = \text{diag} \{ \mathbf{d}_l \} \mathbf{H}_d$ 。

在大规模天线系统中, 上行信道在角度域通常呈现稀疏特性。参考文献[15], 基站可根据阵列结构构造角域变换矩阵 $\mathbf{A} \in \mathbf{C}^{M \times M}$, 并对式(14)中的接收信号进行角度基下的表示, 定义

$$\tilde{\mathbf{Y}}_{d,l} = \mathbf{Y}_{d,l} \mathbf{A}^H, \tilde{\mathbf{H}}_d = \mathbf{H}_d \mathbf{A}^H, \tilde{\mathbf{N}}_{d,l} = \mathbf{N}_{d,l} \mathbf{A}^H,$$

则角度域下的业务时隙接收信号模型可写为

$$\tilde{\mathbf{Y}}_{d,l} = \mathbf{S} \text{diag} \{ \mathbf{d}_l \} \tilde{\mathbf{H}}_d + \tilde{\mathbf{N}}_{d,l} = \mathbf{S} \tilde{\mathbf{X}}_l + \tilde{\mathbf{N}}_{d,l} \quad (15)$$

其中, $\tilde{\mathbf{X}}_l = \text{diag} \{ \mathbf{d}_l \} \tilde{\mathbf{H}}_d$ 。由于每个用户的上行信号能量仅集中于有限的入射角区间, 因此经过矩阵 \mathbf{A} 变换后, 信道矩阵 $\tilde{\mathbf{H}}_d$ 在每个非零行上的能量分布更集中, 每个角域分量上的活跃用户数更少, 从而更有利于后续CS算法进行活跃用户检测。

3 上行信号检测算法

3.1 设计思想

鉴于每帧上行信号具有行稀疏特性, 本文利用CS原理设计了基于用户分组的同步正交匹配追踪(GB-SOMP)算法联合完成上行活跃用户检测、信道估计以及信号重构。首先考虑单天线模型的信号检测, 如图3所示, 该算法设计思想为:




图3 算法原理框图

步骤2: 检测活跃分组集合。

根据式(17)计算前导时隙的功率阈值 τ (该式在下节给出推导):

$$\tau = \sqrt{-(1 + \sigma^2) \ln(1 - P_{miss})} \quad (17)$$

将分组 k 的和信道系数估计值 $\hat{\mathbf{h}}_p(k)$ 的模平方

首先, 利用导频时隙的接收信号 \mathbf{y}_p , 采用最小二乘法估计加权和信道系数向量 \mathbf{h}_p , 据此检测活跃用户分组, 即至少包含一个活跃用户的分组; 所有活跃分组中的用户构成活跃用户集合即用户支持集的粗略估计值。

然后, 利用数据时隙的接收信号 \mathbf{Y}_d , 采用SOMP算法估计活跃用户支持集 Γ ; 据此获得上行信道系数矩阵 \mathbf{H} 的估计值 $\hat{\mathbf{H}}$;

最后, 根据用户支持集 Γ 和信道系数矩阵 $\hat{\mathbf{H}}$, 结合式(10)重构加权业务数据矩阵 \mathbf{X} , 并恢复活跃用户的业务数据向量 \mathbf{d}_l 。

GB-SOMP算法通过粗细搜索结合的方式缩小活跃用户搜索范围, 降低算法的计算复杂度; 充分利用ID时隙和数据时隙中用户活动的一致性提升支持集估计质量, 提升上行信号的检测重构性能。

3.2 算法步骤

输入: 导频时隙接收信号 \mathbf{y}_p , ID时隙接收信号 \mathbf{y}_{id} , 数据时隙接收信号 \mathbf{Y}_d , 导频矩阵 \mathbf{P} , 扩频矩阵 \mathbf{S} , 分组到用户的映射关系 \mathcal{G} , 噪声方差的统计值 σ^2 , 活跃分组漏检概率 P_{miss} 。

输出: 活跃用户集合即支撑集 Γ , 用户信道系数向量 \mathbf{h}_d 的估计值 $\hat{\mathbf{h}}_d$, 业务数据 \mathbf{D} 的估计值 $\hat{\mathbf{D}}$ 。

步骤1: 重构加权和信道系数向量。

基于前导时隙的接收信号 \mathbf{y}_p , 采用最小二乘法求解式(6), 获得各分组的加权和信道系数向量 \mathbf{h}_p 的估计值 $\hat{\mathbf{h}}_p$ 为

$$\hat{\mathbf{h}}_p = (\mathbf{P}^H \mathbf{P})^{-1} \mathbf{P}^H \mathbf{y}_p \quad (16)$$

由于导频正交化且能量归一化, 即 $\mathbf{P}^H \mathbf{P} = \mathbf{I}$, 式(16)简写为 $\hat{\mathbf{h}}_p = \mathbf{P}^H \mathbf{y}_p$ 。

$|\hat{\mathbf{h}}_p(k)|^2$ 与阈值 τ 比较:

若 $|\hat{\mathbf{h}}_p(k)|^2 > \tau$, 表示第 k 个用户分组活跃, 将该分组序号 k 加入活跃分组集合 Γ_p 中;

若 $|\hat{\mathbf{h}}_p(k)|^2 \leq \tau$, 表示第 k 个用户分组不活跃。

步骤3: 噪声方差估计

根据估计的活跃用户分组支撑集 Γ_p ，将接收时隙信号模型重写为

$$\mathbf{y}_p = \mathbf{P}_{\Gamma_p} \mathbf{h}_{p\Gamma_p} + \mathbf{n}_p \quad (18)$$

其中 $\mathbf{P}_{\Gamma_p} = \mathbf{P}[:, \Gamma_p]$ ， $\mathbf{h}_{p\Gamma_p} = \mathbf{h}_p[\Gamma_p]$ ，并根据式 (18) 计算该时隙的噪声方差 σ^2 的无偏估计

$$\hat{\sigma}^2 = \frac{1}{B - |\Gamma_p|} \left\| \mathbf{y}_p - \mathbf{P}_{\Gamma_p} \mathbf{P}_{\Gamma_p}^H \mathbf{y}_p \right\|_2^2 \quad (19)$$

步骤4：获得活跃用户支撑集粗略估计值。

根据分组-用户映射关系 \mathcal{G} ，将活跃分组集合 Γ_p 包含的所有用户序号放入集合 $G[\Gamma_p]$ 中作为粗略估计的支持集 Γ_d ，即 $\Gamma_d = G[\Gamma_p]$ 。

步骤5：构造新的CS方程，初始化SOMP算法。

步骤5-1：基于支撑集粗略估计值构造新的CS方程。

按集合 Γ_d 中用户序号取扩频序列矩阵 \mathbf{S} 中各列构成新观测矩阵 \mathbf{S}_{Γ_d} ，即 $\mathbf{S}_{\Gamma_d} = \mathbf{S}[:, \Gamma_d]$ ；按集合 Γ_d 中用户序号取加权业务数据矩阵 \mathbf{X} 中各行构成新的加权数据矩阵 \mathbf{X}_{Γ_d} ，即 $\mathbf{X}_{\Gamma_d} = \mathbf{X}[\Gamma_d, :]$ ，根据式 (10) 构造新的CS方程为

$$\mathbf{Y}_d = \mathbf{S}_{\Gamma_d} \mathbf{X}_{\Gamma_d} + \mathbf{N}_d \quad (20)$$

基于式 (20)，采用SOMP算法检测重构数据时隙信号。

步骤5-2：SOMP算法初始化。

定义SOMP算法迭代轮次为 t ；第 t 轮次迭代的稀疏度为 s'_d ；第 t 轮次迭代的支持集为 Γ^t ；第 t 轮次迭代的数据残差为 \mathbf{R}'_d 。

令 $t = 0$ ， $\Gamma^t = \emptyset$ ， $\mathbf{R}'_d = \mathbf{Y}_d$ ； $t = t + 1$ 。

步骤6：检测活跃用户，更新支撑集。

计算新观测矩阵 \mathbf{S}_{Γ_d} 各列与残差矩阵 \mathbf{R}'_d 的相关性，找到相关性最大的列对应的活跃用户序号 j^t ，即

$$j^t = \arg \max_{n \in |\Gamma_d|} \left(\left\| (\mathbf{S}_{\Gamma_d}^H \mathbf{R}'_d) [n, :] \right\|_2 \right) \quad (21)$$

其中， $\mathbf{S}_{\Gamma_d}^H$ 表示矩阵 \mathbf{S}_{Γ_d} 的共轭转置矩阵， $\|\cdot\|_2$ 表示向量或矩阵的2-范数。

将 j^t 加入支撑集 Γ^{t-1} 中，得到第 t 轮次迭代的支持集 Γ^t ，即

$$\Gamma^t = \Gamma^{t-1} \cup j^t \quad (22)$$

步骤7：重构活跃用户上行信号，计算残差。

按支持集 Γ^t 中用户序号取出新观测矩阵 \mathbf{S}_{Γ_d} 中各列构成矩阵 \mathbf{S}_{Γ^t} ，即 $\mathbf{S}_{\Gamma^t} = \mathbf{S}_{\Gamma_d}[:, \Gamma^t]$ ，基于式 (23) 估计支持集 Γ^t 中活跃用户的加权业务数据矩阵 \mathbf{X}_{Γ^t} 为：

$$\mathbf{X}_{\Gamma^t} = (\mathbf{S}_{\Gamma^t}^H \mathbf{S}_{\Gamma^t})^{-1} \mathbf{S}_{\Gamma^t}^H \mathbf{Y}_d \quad (23)$$

依式 (24) 计算加权数据残差 \mathbf{R}'_d 为

$$\mathbf{R}'_d = \mathbf{Y}_d - \mathbf{S}_{\Gamma^t} \mathbf{X}_{\Gamma^t} \quad (24)$$

步骤8：判断迭代过程是否收敛。

借鉴文献[9,29]，采用式 (25) 计算第 t 轮次迭代的噪声阈值 τ^t 为：

$$\tau^t = \hat{\sigma} \sqrt{L(B - s'_d) \gamma}, \gamma \in [1.05, 1.3] \quad (25)$$

计算残差 \mathbf{R}'_d 的 F -范数 $\|\mathbf{R}'_d\|_F = \sqrt{\sum_{i=1}^L \sum_{j=1}^B \mathbf{R}'_d[i, j]^2}$ ，将其与噪声阈值 τ^t 比较：

若 $\|\mathbf{R}'_d\|_F < \tau^t$ 或 $t >$ 迭代预设最大轮数 B ，活跃用户迭代检测终止，精确支持集为 $\Gamma = \Gamma^t$ ，执行步骤8；

否则，进一步比较本次迭代的残差 F -范数 $\|\mathbf{R}'_d\|_F$ 与前次迭代的残差 F -范数 $\|\mathbf{R}'_d{}^{t-1}\|_F$ ：

若 $\|\mathbf{R}'_d\|_F < \|\mathbf{R}'_d{}^{t-1}\|_F$ ，令迭代次数 $t = t + 1$ ，返回步骤5；

否则，活跃用户迭代检测终止，精确支撑集为 $\Gamma = \Gamma^{t-1}$ ，执行步骤8。

步骤9：检测活跃用户信道系数。

根据式 (26) 构建扩展导频矩阵 $\tilde{\mathbf{P}}$ ：

$$\tilde{\mathbf{P}} = \mathbf{P} \otimes \mathbf{1}_G^T = \{ \underbrace{\mathbf{p}^1, \dots, \mathbf{p}^1}_{G\text{列}}, \underbrace{\mathbf{p}^2, \dots, \mathbf{p}^2}_{G\text{列}}, \dots, \underbrace{\mathbf{p}^K, \dots, \mathbf{p}^K}_{G\text{列}} \} \quad (26)$$

其中， \otimes 为克罗克内积， $\mathbf{1}_G^T$ 为 G 维全1行向量。

将扩展导频矩阵 $\tilde{\mathbf{P}}$ 和扩频序列矩阵 \mathbf{S} 拼接后构成联合观测矩阵 $\mathbf{W} = \begin{bmatrix} \tilde{\mathbf{P}} \\ \mathbf{S} \end{bmatrix} \in \mathbb{C}^{2B \times N}$ ，同时将前导时隙接收信号 \mathbf{y}_p 和ID时隙接收信号 \mathbf{y}_{id} 拼接构成联合观测信号 $\mathbf{y}_c = \begin{bmatrix} \mathbf{y}_p \\ \mathbf{y}_{id} \end{bmatrix} \in \mathbb{C}^{2B \times 1}$ ，并构建联合观测方程

$$\mathbf{y}_c = \mathbf{W} \mathbf{h}_d \quad (27)$$

采用最小二乘法重构支撑集 Γ 中活跃用户的信道衰落系数向量 $\mathbf{h}_{d,\Gamma}$ 为

$$\hat{\mathbf{h}}_{d,\Gamma} = ((\mathbf{W}_\Gamma)^H \mathbf{W}_\Gamma)^{-1} (\mathbf{W}_\Gamma)^H \mathbf{y}_c \quad (28)$$

其中， $\mathbf{W}_\Gamma = \mathbf{W}[:, \Gamma]$ 。令支撑集 Γ 之外的非活跃用户的信道衰落系数均为零，即 $\hat{\mathbf{h}}_{d,\mathcal{U}\Gamma} = \mathbf{0}$ ， \mathcal{U} 为所有用户构成的全集， $\mathcal{U}\Gamma$ 表示非活跃用户构成的集合。

将 $\hat{\mathbf{h}}_{d,\Gamma}$ 和 $\hat{\mathbf{h}}_{d,\text{MR}}$ 按用户序号顺序合并，即可得到上行信道衰减系数向量 \mathbf{h}_d 的估计值 $\hat{\mathbf{h}}_d$ 。

步骤 10: 重构业务数据矩阵。

构造对角阵 $\hat{\mathbf{H}} = \text{diag}\{\hat{\mathbf{h}}_d(1), \hat{\mathbf{h}}_d(2), \dots, \hat{\mathbf{h}}_d(N)\}$,

利用活跃用户支撑集 Γ 和 $\hat{\mathbf{H}}$ 重构活跃用户的业务数据矩阵 $\hat{\mathbf{D}}_\Gamma$ 为:

$$\hat{\mathbf{D}}_\Gamma = \hat{\mathbf{H}}_\Gamma^{-1} (\mathbf{S}_\Gamma^H \mathbf{S}_\Gamma)^{-1} \mathbf{S}_\Gamma^H \mathbf{Y}_d \quad (29)$$

其中, $\mathbf{S}_\Gamma = \mathbf{S}[:, \Gamma]$ 。

令支撑集 Γ 之外的非活跃用户的业务数据为零, 即 $\hat{\mathbf{D}}_{\text{MR}} = \mathbf{0}$; 将 $\hat{\mathbf{D}}_\Gamma$ 和 $\hat{\mathbf{D}}_{\text{MR}}$ 按用户序号顺序合并, 即得到用户业务数据矩阵 $\hat{\mathbf{D}}$ 的估计值。

步骤 10: 输出估计出的活跃用户支撑集 Γ , 信道衰落系数 $\hat{\mathbf{h}}_d$, 业务数据信号 $\hat{\mathbf{D}}$ 。

上述算法总结如下。

算法 1 GB-SOMP 算法

输入: 导频和信号 \mathbf{y}_p , 用户 ID 和信号 \mathbf{y}_{id} , 用户数据和信号 \mathbf{Y}_d , 用户导频矩阵 \mathbf{P} , 用户 ID 矩阵 \mathbf{S} , 噪声方差 σ^2 。

1. 基于式(16)计算各分组的加权和信道系数向量 \mathbf{h}_p 的估计值 $\hat{\mathbf{h}}_p$; 基于式(17)计算噪声阈值 τ ;

2. 构造活跃分组集合: $\Gamma_p = \left\{ k \mid \left| \hat{\mathbf{h}}_p(k) \right|^2 > \tau, k \in \{1, 2, \dots, K\} \right\}$;

3. 依据式(19)估计噪声方差 $\hat{\sigma}^2$

4. 构造活跃用户初选集合: $\Gamma_d = \bigcup_{k \in \Gamma_p} G[k], G[k]$ 为第 k 个分组

中所有用户序号构成的集合;

5. 根据活跃用户初选集 Γ_d 将数据时隙的观测方程改写为式(20);

6. 基于式(20)执行 SOMP 算法参数初始化: $t = 0, s_d^1 = 1, \Gamma^1 = \emptyset, \mathbf{R}_d^1 = \mathbf{Y}_d, t = t + 1$;

7. 迭代检测支撑集;

Repeat:

根据式(21)选择第 t 次迭代的活跃用户 j' ;

根据式(22)更新支撑集 Γ^t ;

根据式(23)-(24)重构支撑集 Γ^t 对应的活跃用户信号 $\mathbf{X}_{j'}$

并更新残差 \mathbf{R}_d^t ;

根据式(25)计算噪声阈值 τ^t

if $\|\mathbf{R}_d^t\|_F < \tau^t$ 或 $t > B$ then: $\Gamma = \Gamma^t$, break;

else if $\|\mathbf{R}_d^t\|_F < \|\mathbf{R}_d^{t-1}\|_F$ then: $t = t + 1$

else: $\Gamma = \Gamma^{t-1}$, break;

8. 初始化 $\hat{\mathbf{h}}_d = \mathbf{0}$, 根据式(26)-(28)重构活跃用户信道系数 $\hat{\mathbf{h}}_{d,\Gamma}$;

构造对角矩阵 $\hat{\mathbf{H}} = \text{diag}\{\hat{\mathbf{h}}_d(1), \hat{\mathbf{h}}_d(2), \dots, \hat{\mathbf{h}}_d(N)\}$,

初始化 $\hat{\mathbf{D}} = \mathbf{0}$, 根据式(29)重构上行活跃用户数据矩阵 $\hat{\mathbf{D}}_\Gamma$;

输出: 活跃用户集合 Γ , 用户信道系数 \mathbf{h}_d , 用户信号 $\hat{\mathbf{D}}$ 。

3.3 多天线场景推广

所提 GB-SOMP 算法具备可扩展性, 本节讨论其在多天线基站场景下的扩展应用。

假设基站配备 M 根接收天线。在活跃分组检测阶段, 基于前导时隙接收信号 $\mathbf{y}_{p,m}$, 由式(11)可以得到用户至任一天线 m 的加权和信道向量 $\mathbf{h}_{p,m}$ 的最小二乘估计值 $\hat{\mathbf{h}}_{p,m} = \mathbf{P}^H \mathbf{y}_{p,m}$ 。对所有天线的加权和信道向量估计进行平均, 得到

$$\hat{\mathbf{h}}_p = \frac{1}{M} \sum_{m=1}^M \mathbf{P}^H \mathbf{y}_{p,m} \quad (30)$$

重新推导噪声阈值 τ 的公式。类似单天线场景方法构造活跃分组集合 Γ_p 和活跃用户初选集合 Γ_d , 计算每根天线上噪声方差估计值 $\hat{\sigma}_m^2$ 并平均后得到 $\hat{\sigma}^2$ 。

在 CS 活跃用户精确检测阶段, 基于角域变换后的业务时隙接收信号模型式(15)和活跃用户初选集 Γ_d , 针对每一个角域分量 m , 可在多个业务数据时隙上构造多测量矢量模型

$$\tilde{\mathbf{y}}_{d,l,m} = \mathbf{S}_{\Gamma_d} \tilde{\mathbf{x}}_{l,m} + \tilde{\mathbf{n}}_{d,l,m}, l = 1, 2, \dots, L \quad (31)$$

其中, $\mathbf{S}_{\Gamma_d} = \mathbf{S}[:, \Gamma_d]$, $\tilde{\mathbf{x}}_{l,m} = \tilde{\mathbf{X}}_l[\Gamma_d, m]$, 其稀疏支撑在 L 个数据时隙之间保持一致。对角域分量 m , 可采用 SOMP 算法估计 L 个时隙中的 $\{\tilde{\mathbf{x}}_{l,m}\}_{l=1}^L$ 的公共支撑集。综合 M 个角域分量结果, 得到活跃用户支撑集 Γ 。

获得活跃用户支撑集 Γ 后, 可结合 ID 时隙观测, 通过最小二乘估计活跃用户的上行信道矩阵 \mathbf{H}_d , 进而重构加权业务数据矩阵 \mathbf{D} , 综合 M 根天线结果得到最终 $\hat{\mathbf{D}}$ 。

需要指出的是, 在角域表示下, 每个角域分量通常仅与落在该入射角区间的用户的信号相关。基于该特性, 在高负载有源场景中可引入角域引导的预筛选机制: 即在初步确定活跃分组的用户集合后, 根据对应的角度分量, 仅保留落在对应角度区间的用户作为该角域分量后续精确检测阶段的初选支撑集, 以进一步降低后续算法的搜索空间。

4 算法性能分析

4.1 活跃分组漏检概率与虚警概率

下面分析单天线场景下活跃用户分组的漏检概率 P_{miss} 和虚警概率 P_{fa} 。

定义活跃分组漏检率 (Miss Detection Rate, MDR) 为活跃分组未被检出的概率, 用 P_{miss} 表示:

定义非活跃分组虚警率 (False Alarm Rate, FAR) 为非活跃分组误判为活跃分组的概率, 用 P_{fa} 表示。

4.1.1 活跃分组漏检概率

假定用户分组 k 为活跃分组, 根据式 (16), 分组 k 的和信道系数的估计值为

$$\begin{aligned}\hat{\mathbf{h}}_p &= \mathbf{P}^H * \mathbf{y}_p = \mathbf{P}^H * (\mathbf{P} \mathbf{h}_p + \mathbf{n}_p) \\ &= \mathbf{h}_p + \mathbf{P}^H \mathbf{n}_p\end{aligned}\quad (32)$$

根据活跃分组的定义, 不妨令分组 k 中仅有一个活跃用户。鉴于前导矩阵 \mathbf{P} 具有正交性, 式 (32) 中的噪声项 $\mathbf{P}^H \mathbf{n}_p$ 仍服从均值为 0、方差为 σ^2 的复高斯分布, 即 $\mathbf{P}^H \mathbf{n}_p \sim CN(0, \sigma^2 \mathbf{I})$ 。进一步可推知, $\hat{\mathbf{h}}_p(k)$ 服从均值为 0、方差为 $1 + \sigma^2$ 的复高斯分布, 即 $\hat{\mathbf{h}}_p(k) \sim CN(0, 1 + \sigma^2)$; 其功率 $|\hat{\mathbf{h}}_p(k)|^2$ 服从参数为 $\frac{1}{1 + \sigma^2}$ 的指数分布, 即 $|\hat{\mathbf{h}}_p(k)|^2 \sim \exp(-\frac{1}{1 + \sigma^2})$ 。

给定前导时隙噪声功率阈值 τ , 活跃分组漏检概率 P_{miss} 可以计算为:

$$\begin{aligned}P_{\text{miss}} &= \Pr\left\{|\hat{\mathbf{h}}_p(k)|^2 \leq \tau\right\} = F_{|\hat{\mathbf{h}}_p(k)|^2}(\tau) \\ &= 1 - \exp\left(-\frac{\tau}{1 + \sigma^2}\right)\end{aligned}\quad (33)$$

由式 (33) 可直接推导出式 (17)。

4.1.2 非活跃分组虚警概率

假定用户分组 k 为非活跃分组。根据式 (16), 其和信道系数的估计值 $\hat{\mathbf{h}}_p(k)$ 为

$$\hat{\mathbf{h}}_p(k) = \mathbf{P}^H * \mathbf{y}_p = \mathbf{P}^H * \mathbf{n}_p \sim CN(0, \sigma^2)\quad (34)$$

可推知, $\hat{\mathbf{h}}_p(k)$ 服从均值为 0、方差为 σ^2 的复高斯分布, 即 $\hat{\mathbf{h}}_p(k) \sim CN(0, \sigma^2)$, 其功率服从指数分布, 即 $|\hat{\mathbf{h}}_p(k)|^2 \sim \exp(-\frac{1}{\sigma^2})$ 。

于是, 非活跃分组的虚警概率 P_{fa} 计算为

$$\begin{aligned}P_{\text{fa}} &= \Pr\left\{|\hat{\mathbf{h}}_p(k)|^2 > \tau\right\} \\ &= 1 - F_{|\hat{\mathbf{h}}_p(k)|^2}(\tau) = \exp\left(-\frac{\tau}{\sigma^2}\right)\end{aligned}\quad (35)$$

给定噪声方差 σ^2 和漏检率 P_{miss} , 可依式 (17) 和式 (35) 计算出判决阈值 τ 和虚警概率 P_{fa} 。例如, 令 $P_{\text{miss}} = 0.01$, $\sigma^2 = 0.01$, 可以计算出判决阈值 $\tau = 0.1$, 虚警概率 $P_{\text{fa}} = 0.3$ 。在实际系统中, 导频时隙的发送功率可根据噪声水平进行适当调整。

多天线场景的漏检概率和虚警概率可以类比分析, 此处不再赘述。

4.2 活跃用户搜索空间和碰撞概率

CS 观测矩阵的列相关性即观测矩阵任意两列相关性的最大值是影响稀疏信号能否被重构的关键因素^[30]。当列相关性增大时, 算法重构概率显著降低; 当观测矩阵的列数增加或搜索空间扩大时, 其列相关性通常随之增强, 这正是高过载或密集大规模接入场景下 CS 算法性能退化的主要原因。

本文提出的 GB-SOMP 算法通过分组检测仅保留判定为活跃的分组参与第二阶段的精确检测, 该策略使得第二阶段中参与检测的用户总数减少至约 $\bar{k}_a G$ 个, 显著小于用户总数 N ; 其中 \bar{k}_a 表示活跃分组的平均数目, 计算为

$$\begin{aligned}\bar{k}_a &= E\left[\sum_{k=1}^K I_k\right] = \sum_{k=1}^K E[I_k] = \sum_{k=1}^K P(I_k = 1) \\ &= K \left[1 - (1 - P_{ac})^G\right] = K \left[1 - \left(1 - \frac{n_a}{KG}\right)^G\right]\end{aligned}\quad (36)$$

其中, P_{ac} 为单个用户平均活跃概率, 当 $P_{ac} \ll 1$ 时, 上式可近似为

$$\bar{k}_a = K \left(1 - 0.36 \frac{n_a}{K}\right)\quad (37)$$

因此, GB-SOMP 在第二阶段构建的等效观测矩阵维度显著降低, 有效减弱了观测矩阵的列相关性, 提升了稀疏重构的稳定性和鲁棒性。相比之下, 传统 SOMP 算法直接在全用户空间内进行检测, 其观测矩阵列数较大, 在活跃用户数增加时更易出现性能退化。

相比于 CB-SOMP 算法, 在中等或较低活跃用户数目场景下, GB-SOMP 算法的活跃用户搜索空间 $\bar{k}_a G$ 较小, 用户接入成功率更高; 在活跃用户数较大的场景下, GB-SOMP 算法的分组搜索优势下降, CB-SOMP 算法的前导搜索空间 K 较小, 其性能略优于 GB-SOMP 算法。同时, CB-SOMP 算法存在因导频复用带来的碰撞, 且单个用户发生碰撞的概率 $\approx 1 - (1 - \frac{1}{N_p})^{N_p - 1}$, 大于 GB-SOMP 因漏检分组带来的接入失败概率, 因而总体性能不如 GB-SOMP。

4.3 算法时间复杂度

GB-SOMP 算法的计算开销主要由每轮次迭代中的矩阵乘法运算和范数运算引起, 具体来自式 (21) 的相关性计算、式 (23) 的最小二乘估计,

以及式(24)的残差更新,每轮次迭代的计算复杂度分别计算为 $O(B\bar{k}_aGL)$ 、 $O(Bn_a^2)$ 、 $O(n_aLB)$ 。因此,GB-SOMP算法的时间复杂度可计算为 $O(IB\bar{k}_aGL + IBn_a^2 + In_aL)$,其中, I 代表算法迭代轮次,在OMP类算法中, I 与活跃用户数 n_a 成正比; B 表示导频长度; G 表示每组内用户数目; L 表示数据时隙; \bar{k}_a 为活跃分组平均数。

本文将GB-SOMP算法与SOMP^[8]、SAMP^[19]、

CB-SOMP^[23]算法以及MMV-ADMM^[22]算法的计算复杂度进行比较,如表1所示。其中,SOMP是一种经典的MMV稀疏重建算法,运算速度较快,适用于低稀疏度、低噪声场景;CB-SOMP算法同样基于导频争用,其对抗接入碰撞性能较好;SAMP算法采用一种单时隙稀疏度自适应匹配追踪算法,在本文对比方案中仅利用ID时隙信号进行支撑集估计。MMV-ADMM算法是一种适用于多观测矢量模型的优化类稀疏重构方法。

表1 不同算法的时间复杂度比较

算法	时间复杂度
GB-SOMP	$O(IB\bar{k}_aGL + IBn_a^2 + In_aL)$
SOMP ^[8]	$O(IBNL + IBn_a^2 + In_aLB)$
CB-SOMP ^[23]	$O(IBKL + IBn_a^2 + In_aLB)$
SAMP ^[19]	$O(2IBN + 2IBn_a^2 + 2In_a^3)$
MMV-ADMM ^[22]	$O(I(BNL + N^2L))$

考虑高稀疏度上行传输场景即 $n_a \ll N$,GB-SOMP、SOMP、CB-SOMP、SAMP算法的时间复杂度分别近似为 $O(n_aB\bar{k}_aGL)$ 、 $O(n_aBNL)$ 、 $O(n_aBKL)$ 、 $O(2n_aBN)$ 。可以看出因 $\bar{k}_aG < N$,GB-SOMP算法的时间复杂度明显低于SOMP算法。尽管在高活跃用户场景下 $K < \bar{k}_aG$,CB-SOMP算法的时间复杂度略低于GB-SOMP算法,但用户接入碰撞概率较高。SAMP算法虽然时间复杂度较低,但仿真结果知其性能较弱。MMV-ADMM算法时间复杂度中含有 N^2 明显高于其余算法,后续主要用于性能对比。

5 仿真结果与分析

5.1 仿真环境与参数设置

本文采用MATLAB软件对所提GB-SOMP算法性能进行仿真研究,重点探索单天线场景下用户随机接入成功率与活跃用户数目、分组方案的关系,其中随机接入成功率定义为活跃用户被基站正确检测且其传输的业务信号能被无误重构的概率。本文亦将GB-SOMP算法与前文所提的几种主流方案进行对比,包括:SOMP算法^[8]、CB-SOMP算法^[23-24]、MMV-ADMM^[22]算法以及SAMP算法^[19]。除特殊说明外,仿真参数设置如表2所示。

5.2 随机接入性能分析

图4展示了不同算法的随机接入成功率与活跃

表2 仿真参数

仿真参数	参数值
总用户数 N	1000
活跃用户数 n_a	1-80
扩频码长度 B	80
用户分组数 K	80
基站接收信噪比SNR	5-30dB
数据时隙长度 L	7
调制方式	64QAM
载波带宽	180KHZ
接收天线数	1

用户数目的关系曲线。可以看到,随着活跃用户数目增加,各算法的接入成功率先缓慢减小,在超过某一阈值即最大有效接入用户数目后快速下降。相比SOMP、SAMP以及MMV-ADMM算法,本文所提GB-SOMP算法的最大有效接入用户数目明显更多且接入成功率更高。虽然GB-SOMP算法的最大有效接入用户数目略低于CB-SOMP算法,但其在最大有效接入用户数目以内的成功接入概率高出10%,因此GB-SOMP算法的接入性能总体更优。GB-SOMP算法的性能优势主要来源于其分组导频机制与“粗一细”两阶段支撑集检测策略。通过在第一阶段的活跃分组进行预筛选,有效剔除大量非活跃用户分组,从而显著缩小第二阶段精确检测时的等效观测矩阵的列维度及其相关性。相比之下,CB-SOMP算法由于采用小规模导频池,其效能

测矩阵的列维度更小，最大可接入用户数目较高。但当多个用户选择相同导频时发生碰撞，即使在算法高概率成功重构的条件下，仍有10%接入失败概率。而MMV-ADMM算法在该仿真设置下性能相对较弱的主要原因是 **B/N** 比值较小的高过载场景下观测矩阵的列相关性增加导致该算法性能退化较大。

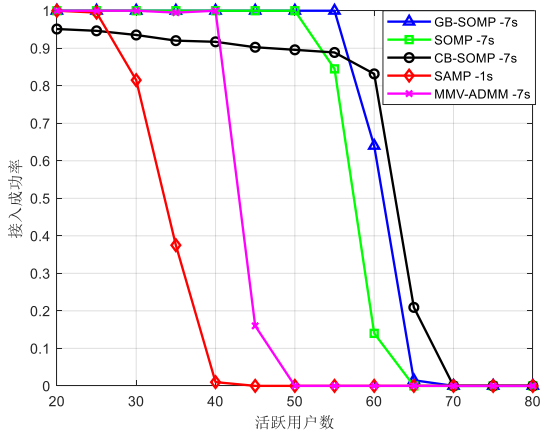



图4 在不同活跃用户数下接入成功率对比(SNR = 30dB)


图5展示了用户随机接入成功率随接收信噪比变化曲线。可以看到，当SNR<15dB时，五种算法的随机接入成功率均近似0，这是由LS估计在低信噪比下误差较大所致。随着接收信噪比提升，所有算法的接入成功率均迅速上升并最终趋于上限。当活跃用户数目即稀疏度 $n_a=30$ 时，本文提出的GB-SOMP算法与SOMP算法性能接近，随机接入成功率高于其余三种算法。五种算法的随机接入成功率均受到活跃用户数目即稀疏度的影响；当稀疏度 n_a 从30提升为60时，GB-SOMP算法在高信噪比条件下的随机接入成功率从1下降至0.98，仅降低约2%；CB-SOMP算法的随机接入成功率从0.93下降至0.9，下降约3%；SOMP算法的随机接入成功率从1下降至0.6，下降40%；而MMV-ADMM和SAMP算法的接入成功率均下降至0。上述结果表明，GB-SOMP算法和CB-SOMP算法对用户稀疏度的变化不敏感，鲁棒性较好；SAMP和MMV-ADMM算法在所设仿真场景下对用户稀疏度变化敏感，在高稀疏度条件下算法失效。因此，GB-SOMP算法的随机接入性能更好。

5.3 算法时间开销

图6展示了不同活跃用户数量下GB-SOMP算



(a) 接入成功率 ($n_a=30$)



(b) 接入成功率 ($n_a=60$)

图5 不同SNR下不同方案接入成功率和误码率对比

法的运行时间，并与SOMP、CB-SOMP、SAMP、三种算法进行比较。由图6可见，随着活跃用户数目即稀疏度的上升，四种算法的运行时间均逐渐上升。当活跃用户数目 n_a 较少于20时，本文所提GB-SOMP算法的运行时间少于SOMP和CB-SOMP算法，仅比单纯利用单时隙信号进行支撑集检测的SAMP算法略多。当活跃用户数目较多时，本文所提GB-SOMP算法的运行时间仍少于SOMP算法，略大于CB-SOMP算法，这是由于GB-SOMP算法第一阶段活跃用户粗略估计的活跃用户范围随活跃用户数增加而增大引起的。综合图6，本文所提GB-SOMP相比SOMP算法总体运行时间降低约30%，低稀疏度下的时间开销相比CB-SOMP算法的略低，高稀疏度下相比CB-SOMP算法的时间开销略高。

5.4 分组方式对算法性能的影响

由于缺乏实际数据的支撑，难以对聚类算法的




图6 算法运行时间与活跃用户数目的关系(SNR = 20dB)

性能进行评估。为了衡量聚类结果对本文所提算法性能的增益,本文引入相对活跃分组数的概念用于衡量一次随机接入中活跃用户在分组层面的聚集程度,它定义一次随机接入中真实活跃用户分组数目 K_a 与活跃分组数目的期望值 \bar{k}_a 的比值,用 ρ 表示:

$$\rho = \frac{K_a}{\bar{k}_a} \quad (30)$$




图7 算法的时间开销与分组规模的关系曲线(SNR = 30 dB)

图7展示了相对活跃分组数 ρ 对 GB-SOMP 算法的用户随机接入成功率的影响。从图7可以看到,随着 ρ 的从1减少到0.5,即活跃用户在分组层面的聚集程度增强一倍,GB-SOMP 算法的最大用户接入有了进一步的提升,从55提升至60,表明分组结果的集中性有助于降低检测搜索空间并提升算法的重构稳定性。

同时,本文也将导频分组与两阶段检测思想应用于 MMV-ADMM 算法。由图7所示,改进后的 MMV-ADMM 算法相较原始算法在高过载场景下的

随机接入成功率取得了显著提升,其最大可支持的活跃用户数提升约15。该结果进一步验证了分组导频与两阶段检测思想在大规模随机接入场景下对不同稀疏重构算法均具有良好的通用性和增益效果。

综上所述,本文所提 GB-SOMP 算法有效提升了用户设备的随机接入成功率,其上行信号检测的时间开销较小,适用于中高过载的大规模接入场景,且鲁棒性较好。

6 总结

本文提出了一种基于分组导频和压缩感知的大规模随机接入方案。该方案中,基站根据用户历史活跃信息对用户预分组并配置分组导频,用户采用由分组导频、用户 ID 和业务数据组成的上行帧独立执行随机接入传输;对于来自多个用户的上行和信号,基站采用 GB-SOMP 算法执行信道估计、活跃用户及其上行信号的联合检测。所提 GB-SOMP 算法在经典 SOMP 算法前引入活跃用户预检测机制,即利用导频时隙接收信号检测活跃分组以粗略估计活跃用户集合,缩小算法的精确搜索空间,同时获得活跃分组的上行信道衰减系数的估计值;随后联合多个数据时隙的接收信号采用 SOMP 算法执行精确支撑集检测并重构活跃用户的上行信号,通过粗细搜索结合的方式提高 CS-MUD 检测性能。仿真结果表明,本文方案不仅显著降低了 MMV-CS 类算法的计算开销,而且极大提升了用户设备的随机接入成功率,对用户稀疏度变化具有良好的鲁棒性;随着活跃用户聚集度的增加,其优势更加明显。

参考文献:

- [1] GAO Z, KE M L, MEI Y K, et al. Compressive-sensing-based grant-free massive access for 6G massive communication[J]. IEEE Internet of Things Journal, 2024, 11(5): 7411-7435.
- [2] MA Z, WU W, GAO F, et al. Model-driven deep learning for non-coherent massive machine-type communications[J]. IEEE Transactions on Wireless Communications, 2024, 23(3): 2197 - 2211.
- [3] QIAO L, GAO Z, HE C, et al. Non-coherent grant-free massive IoT access for mMTC: an index modulation perspective[C]//Proceedings of the 2021 IEEE/CIC International Conference on Communications in China (ICCC). Piscataway: IEEE Press, 2021: 694-699.
- [4] SHAHAB M B, ABBAS R, SHIRVANIMOGHADDAM M, et al. Grant-free non-orthogonal multiple access for IoT: a survey[J].

- IEEE Communications Surveys & Tutorials, 2020, 22(3): 1805-1838.
- [5] BOCKELMANN C, SCHEPKER H F, DEKORSY A. Compressive sensing based multi-user detection for machine-to-machine communication[J]. Transactions on Emerging Telecommunications Technologies, 2013, 24(4): 389-400.
- [6] DETERME J F, LOUVEAUX J, JACQUES L, et al. On the exact recovery condition of simultaneous orthogonal matching pursuit [J]. IEEE Signal Processing Letters, 2016, 23(1): 164-168.
- [7] KE M L, GAO Z, WU Y P, et al. Compressive massive random access for massive machine-type communications (mMTC)[C]//Proceedings of the 2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Piscataway: IEEE Press, 2018: 156-160.
- [8] DETERME J F, LOUVEAUX J, JACQUES L, et al. On the noise robustness of simultaneous orthogonal matching pursuit[J]. IEEE Transactions on Signal Processing, 2017, 65(4): 864-875.
- [9] ZHANG W, KIM T. Successful recovery performance guarantees of SOMP under the ℓ_2 -norm of noise[J]. IEEE Transactions on Vehicular Technology, 2024, 73(2): 2156-2170.
- [10] LIU L, YU W. Massive connectivity with massive MIMO: Part I: Device activity detection and channel estimation[J]. IEEE Transactions on Signal Processing, 2018, 66(11): 2933-2946.
- [11] HARA T, ISHIBASHI K. Blind multiple measurement vector AMP based on expectation maximization for grant-free NOMA [J]. IEEE Wireless Communications Letters, 2022, 11(6): 1201-1205.
- [12] BAI Y, CHEN W, AI B, et al. Contention based massive access scheme for B5G: a compressive sensing method[C]//Proceedings of 2020 International Wireless Communications and Mobile Computing (IWCMC). Piscataway: IEEE Press, 2020:1854-1859.
- [13] MEI Y K, GAO Z, MI D, et al. Compressive sensing based grant-free random access for massive MTC[C]// Proceedings of the 2020 International Conference on UK-China Emerging Technologies (UCET). Piscataway: IEEE Press, 2020: 1-4.
- [14] 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.
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. [LinkOut]
- [15] KE M L, GAO Z, WU Y P, et al. Compressive sensing-based adaptive active user detection and channel estimation: Massive access meets massive MIMO[J]. IEEE Transactions on Signal Processing, 2020, 68: 764-779.
- [16] LIU K H, LI X N, ZHAO H Y, et al. Joint active user detection and channel estimation for massive grant-free access via difference of convex programming[C]// Proceedings of the GLOBECOM 2023 - 2023 IEEE Global Communications Conference. Piscataway: IEEE Press, 2023: 2335-2340.
- [17] BAI Y, CHEN W, SUN F F, et al. Data-driven compressed sensing for massive wireless access[J]. IEEE Communications Magazine, 2022, 60(11): 28-34.
- [18] DU Y, CHENG C, DONG B H, et al. Block-compressed-sensing-based multiuser detection for uplink grant-free NOMA systems [C]//Proceedings of the 2018 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2018: 1-7.
- [19] GAO Z, DAI L L, WANG Z C, et al. Spatially common sparsity based adaptive channel estimation and feedback for FDD massive MIMO[J]. IEEE Transactions on Signal Processing, 2015, 63(23): 6169-6183. [LinkOut]
- [20] 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.
- [21] CHANG J Y, FU X J, ZHAN K, et al. Target detection method based on adaptive step-size SAMP combining off-grid correction for coherent frequency-agile radar[J]. Remote Sensing, 2023, 15(20): 4921.
- [22] LIU Z K, YU S W. Alternating direction method of multipliers based on $\ell_{2,0}$ -norm for multiple measurement vector problem[J]. IEEE Transactions on Signal Processing, 2023, 71: 3490-3501.
- [23] BAI Y N, CHEN W, AI B, et al. Contention-based nonorthogonal massive access with massive MIMO[J]. China Communications, 2020, 17(11): 79-90.
- [24] BAI Y N, CHEN W, AI B, et al. Deep learning for asynchronous massive access with data frame length diversity[J]. IEEE Transactions on Wireless Communications, 2024, 23(6): 5529-5540.
- [25] RUIZ-GUIROLA D E, LÓPEZ O L A, MONTEJO-SANCHEZ S. Modeling IoT traffic patterns: Insights from a statistical analysis of an MTC dataset[J]. Expert Systems with Applications, 2025, 272: 126726.
- [26] WANG Q P, LIU L, ZHANG S W, et al. On massive IoT connectivity with temporally-correlated user activity[C]// Proceedings of the 2021 IEEE International Symposium on Information Theory (ISIT). Piscataway: IEEE Press, 2021: 3020-3025.
- [27] BOISGUENE R, ALTHAMARY I, HUANG C W. A Learning-Based Energy-Efficient Device Grouping Mechanism for Massive Machine-Type Communication in the Context of Beyond 5G Networks[J]. Journal of Sensor and Actuator Networks, 2024, 13(3): 33.
- [28] YANG B, WEI F, SHE X, et al. Intelligent random access for massive-machine type communications in sliced mobile networks [J]. Electronics, 2023, 12(2): 329.
- [29] SHCHUKINA A, KASPRZAK P, DASS R, et al. Pitfalls in compressed sensing reconstruction and how to avoid them[J]. Journal of Biomolecular NMR, 2017, 68(2): 79-98.
- [30] FOUCAIT S, RAUHUT H. A Mathematical Introduction to Compressive Sensing[M]. New York, NY: Springer New York, 2013: 93 - 105.