

可学习阈值优化的大规模动态多用户接入检测

石昌伟¹, 郭里婷^{1*}, 康 芑¹, 杜伟庆¹, 陈平平¹, 方 毅²

(1. 福州大学物理与信息工程学院, 福建福州 350108; 2. 广东工业大学信息工程学院, 广东广州 510006)

摘要: 在大规模免授权非正交多址接入(Grant-Free Non-Orthogonal Multiple Access, GF-NOMA)中, 多用户检测往往依靠先验信号稀疏度进行活跃用户检测, 但在实际应用, 特别在动态多用户接入中, 用户接入过程变得更加复杂, 获取这种先验信息变得更为困难. 针对该问题, 本文提出一种可学习阈值优化的大规模动态多用户接入检测方案, 即阈值改进的自适应交替方向乘子(Threshold-Improved Adaptive Alternating Direction Method of Multipliers, TI-A-ADMM)算法. 在该算法中, 利用活跃用户连续通信的时间相关性, 引入动态相关性度量, 对活跃用户检测的噪声阈值进行自适应缩放, 提高检测性能. 此外, 为提升不同信噪比下活跃用户检测的准确度, 采用深度学习网络对活跃用户检测初始阈值进行优化, 以适应不同的接入环境. 仿真结果表明, 在未知先验稀疏度信息的动态多用户接入情况下, 所提 TI-A-ADMM 算法相较于现有已知稀疏度信息的算法, 在误活跃率(Activity Error Rate, AER)和误符号率(Symbol Error Rate, SER)上能得到 2.4 dB 的性能增益. 所提算法对因多用户接入而引起的干扰具有较低的性能衰减和更高的鲁棒性.

关键词: 大规模机器类通信; 多用户检测; 压缩感知; 交替方向乘子法; 阈值; 深度学习

基金项目: 国家自然科学基金(No.62171135); 福建省自然科学基金(No.2023J01399); 福建省杰青项目(No.2022J06010); 省教育厅重点攻关项目(No.2023XQ004)

中图分类号: TN914.5; TN929.5 **文献标识码:** A **文章编号:** 0372-2112(2025)05-1436-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20240404

Learnable Threshold Optimization for Massive Dynamic Multi-User Access Detection

SHI Chang-wei¹, GUO Li-ting^{1*}, KANG Peng¹, DU Wei-qing¹, CHEN Ping-ping¹, FANG Yi²

(1. School of Physics and Information Engineering, Fuzhou University, Fuzhou, Fujian 350108, China;

2. School of Information Engineering, Guangdong University of Technology, Guangzhou, Guangdong 510006, China)

Abstract: In massive grant-free non-orthogonal multiple access (GF-NOMA) systems, multi-user detection usually relies on the prior sparsity of signals to detect active users. However, in practical applications, especially in dynamic multi-user access, the user access process becomes more complex and obtaining such prior information becomes more difficult. Therefore, this paper proposes a learnable threshold optimization scheme for massive dynamic multi-user access detection, namely the threshold-improved adaptive alternating direction method of multipliers (TI-A-ADMM) algorithm. In this algorithm, the time correlation of active user communication is utilized to introduce a dynamic correlation measure, which adaptively scales the noise threshold for active user detection, thereby improving detection performances. Moreover, to enhance the accuracy of active user detection across different signal-to-noise ratios, a deep learning network is employed to optimize the initial detection threshold, adapting to various access environments. Simulation results indicate that, in the case of dynamic multi-user access without known prior sparsity information, the proposed TI-A-ADMM algorithm achieves a performance gain of 2.4 dB in terms of active error rate (AER) and symbol error rate (SER) compared to existing algorithms with known sparsity information. The proposed algorithm exhibits lower performance degradation and higher robustness against interference caused by multi-user access.

Key words: massive machine type communication; multi-user detection; compressed sensing; alternating direction method of multipliers; threshold; deep learning

Foundation Item(s): National Natural Science Foundation of China (No.62171135); Natural Science Foundation of Fujian Province (No.2023J01399); Outstanding Youth Project of Fujian Province (No.2022J06010); Key Tackling Project of Provincial Department of Education (No.2023XQ004)

1 引言

由于物联网(Internet of Things, IoT)等新兴应用的出现,大规模机器类通信(massive Machine Type Communication, mMTC)在5G和即将到来的6G无线网络中备受关注^[1,2]. mMTC场景要求低功耗设备之间在广阔的覆盖范围内实现大规模连接,这对多址接入技术的设计提出了挑战^[3]. 由于受到正交资源的限制,经典的正交多址接入(Orthogonal Multiple Access, OMA)技术在mMTC场景中的频带利用率较低^[4],无法满足mMTC海量设备接入的需求. 为解决这一问题,许多研究人员致力于开发高频谱效率的非正交多址接入(Non-Orthogonal Multiple Access, NOMA)技术^[5,6]. 虽然对NOMA技术的研究多年来一直在不断深入,但大多数方案通常专注于基于授权的NOMA(Grant-Based NOMA, GB-NOMA)^[7]. 此类方案在资源和功率方面,需要基站(Base Station, BS)对每个用户的传输进行调度,这会导致大量的信令开销,并且在设备数量众多的情况下会造成较大的延迟.

为了减少延迟,降低信令开销并增强接入能力,有学者提出免授权的NOMA(Grant-Free NOMA, GF-NOMA)方案,作为大规模接入的有效解决方案^[8-10]. 在GF-NOMA中,每个用户都可以根据需要来传输自己的数据,而无需BS进行调度. 因此,GF-NOMA可以降低延迟、减少用户多址接入时的冲突和BS的信令开销^[11]. 由于GF-NOMA缺乏准确的用户信息,BS需要对接收信号进行多用户检测(Multi-User Detection, MUD)^[12,13],以便后续恢复每个用户的传输数据. 根据mMTC,场景中用户发送信号的稀疏特性,MUD问题可以刻画为大规模稀疏信号的恢复问题,通过压缩感知(Compressive Sensing, CS)技术^[14]来有效地解决. MUD过程通常分为两个关键步骤:活跃用户检测(Activity User Detection, AUD)以及数据检测(Data Detection, DD).

在压缩感知理论的框架下,针对帧稀疏模型,已有研究^[15-17]提出了众多改进的算法. 帧稀疏模型下,活跃用户在一帧的时间内都是活跃的,不活跃用户一直是不活跃的. 文献[15]在GF-NOMA场景中首次引入块正交匹配追踪(Block Orthogonal Matching Pursuit, BOMP)算法,该算法通过将帧稀疏模型转换为块稀疏标量模型,以此利用帧稀疏特性来提升算法性能. 尽管BOMP算法在流程上与传统的OMP算法类似,但其复杂度高于OMP算法. 文献[16]提出了一种基于阈值辅助的块稀疏自适应子空间追踪(Threshold Aided Block Sparsity

Adaptive Subspace Pursuit, TA-BSASP)算法. 区别于传统贪婪算法,该算法不依赖稀疏度(活跃用户数)作为先验信息,而是通过选取合适的阈值来筛选活跃用户. TA-BSASP算法综合应用了多种思想:子空间追踪(Subspace Pursuit, SP)算法^[18]的多用户迭代选择机制, BOMP算法的块稀疏模型转换,以及基于阈值的活跃用户检测. 这些思想赋予了算法卓越的性能表现,尽管如此,算法的复杂度较高. 此外,原文并未详细阐述噪声阈值的确定方法.

另一方面,动态块稀疏(动态接入)模型更贴近mMTC实际用户行为,其中用户的活跃性是动态变化的,他们可能只在连续的几个时隙内传输数据,并且有可能在任何时间点开始或停止数据传输. 文献[19]中,研究者提出了一种基于动态压缩感知(Dynamic Compressive Sensing, DCS)的多用户检测方法. 该方法通过分析活跃用户在时间上的相关性来提高检测效率,它将当前时隙中的活跃用户集合预测作为下一时隙活跃用户估计的先验信息. 然而,该方法在每个时隙的检测过程中仍需依赖已知的用户稀疏度信息. 在文献[19]的工作基础上,文献[20]进一步提出一种基于侧信息辅助的块正交匹配追踪(Side-Information Aided Block Orthogonal Matching Pursuit, SIA-BOMP)算法. 该算法整合了BOMP在块稀疏模型上的转换思想与噪声阈值剪枝技术,利用多个用户在时隙上共有的块稀疏特性,无需依赖先验的稀疏度信息,通过设定固定的噪声阈值来执行剪枝,旨在增强多用户检测的准确性. 与文献[16]的情况类似,文献[20]并未详细说明如何确定噪声阈值.

在许多实际场景中,由于用户的活跃行为具有突发性和不确定性,接收端无法精确获取活跃用户数量^[21,22]. 针对这类具有动态接入特性的块稀疏模型的多用户检测问题,本文提出了一种阈值改进的自适应交替方向乘子(Threshold-Improved Adaptive Alternating Direction Method of Multipliers, TI-A-ADMM)算法,无需活跃用户数量的先验信息,同时为了适应更广泛的接入噪声变化,本文结合深度学习(Deep Learning, DL)算法来确定噪声阈值,以判断用户的活跃状态,适用于实际接入场景. 具体来说,该算法通过对阈值的深入分析,探究了动态块稀疏模型中用户活跃的时间相关性,以期提高多用户检测的准确率. 该算法首先根据活跃用户在连续通信过程中的时间相关性,引入动态相关性度量,并利用相邻时隙的活跃状态来确定缩放因子,

从而自适应地调整活跃用户检测的初始噪声阈值. 进一步地, 本文采用深度学习对该初始噪声阈值进行优化, 以增强在不同信噪比(Signal-to-Noise Ratio, SNR)环境下的检测性能. 仿真结果表明, 在低信噪比条件下, 本文提出的TI-A-ADMM算法, 可以不需要先验活跃用户数信息, 性能却优于现有已知活跃用户数信息的算法. 在误活跃率(Activity Error Rate, AER)和误符号率(Symbol Error Rate, SER)方面实现了2.4 dB的性能提升. 此外, 所提算法在多用户接入数量增加时, 具有更少的性能损失和更高的鲁棒性.

2 系统模型

本文考虑GF-NOMA上行链路通信系统, 其中包含一个BS和 K 个潜在用户. 在系统设计中, 我们假设BS和每个用户都配置单个天线, 并且所有用户的发射信号在BS处完全同步. 在GF-NOMA系统中, 用户的传输具有稀疏特性, 仅有小部分用户在上行链路传输中激活传输, 而大多数用户则处于静默状态.

图1展示了在GF-NOMA系统中采用的动态块稀疏模型. 在该模型下, 用户在连续若干个时隙内活跃, 并具有随机的突然性特征: 用户的传输起始时隙(第一个活跃时隙)是随机的. 与文献[23]相似, 动态块稀疏模型中, 相邻两个时隙的用户状态可以被建模为具有两个离散状态的平稳一阶马尔科夫链. 假设不同用户的马尔科夫链是独立同分布的. 我们用二元指针函数 $\delta_{k,t} \in \{0, 1\}$ 表示用户 k 在 t 时隙为活跃状态, 当 $\delta_{k,t} = 1$ 时, 用户 k 在 t 时隙活跃, 反之, 当 $\delta_{k,t} = 0$ 时, 用户 k 在 t 时隙静默. 用户的稳态概率由 $\Pr(\delta_{k,t} = 1) = p_a$ 给出, 其中 p_a 表示用户 k 在 t 时隙活跃的概率. 用户的转移概率矩阵定义为

$$P = \begin{bmatrix} p_{00} & p_{01} \\ p_{10} & p_{11} \end{bmatrix} \quad (1)$$

其中, $p_{10} = \Pr\{\delta_{k,t} = 0 | \delta_{k,t-1} = 1\}$, 其他三种转移概率的定义类似. 通过稳态假设, 马尔科夫链均可由 p_a 和 p_{10} 表示. 其他三个转移概率可以由 $p_{01} =$

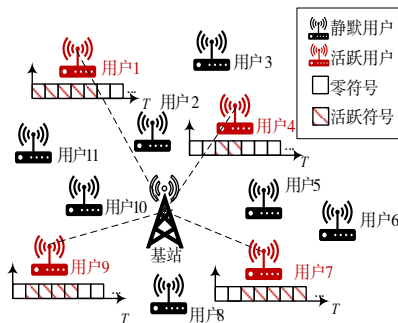


图1 GF-NOMA 动态块稀疏模型

$p_a p_{10} / (1 - p_a)$, $p_{00} = 1 - p_{01}$ 和 $p_{11} = 1 - p_{10}$ 获得. 可以发现, 当 p_{10} 越小, 活跃用户在相邻时隙上的相关性越强(转移概率 p_{11} 越大).

本文为了满足动态块稀疏模型中的帧传输机制, 设定了长度为 T 的数据帧进行用户信号传输. 活跃用户采用的传输数据 $\hat{x}_{k,t}$ 由经过归一化处理的复星座图集合 \mathcal{X}_0 中选取, 例如多进制正交幅度调制(Multiple-Quadrature Amplitude Modulation, M-QAM)集合. 所有静默用户不传输任何符号, 等于零传输. 因此, 我们使用增广的归一化复星座图集合 $\mathcal{X} = \mathcal{X}_0 \cup \{0\}$ 表示所有用户的发送符号集. 每个用户的传输符号 $\hat{x}_{k,t}$ 用长度为 N ($N < K$) 的扩频序列 \hat{s}_k 进行扩频, 然后通过相同的 N 个正交子载波, 传输所有用户的信号. 在本文中, 我们假设理想的大尺度衰落系数信道估计, 通过功率控制调节补偿用户的大尺度衰落^[24]. 因此, 我们将重点放在研究小尺度信道变化对多用户检测性能的影响, 使用复高斯分布对小尺度衰落进行建模^[25]. 在 t 时隙, BS在第 n 个子载波上的接收信号 $\hat{y}_{n,t}$ 是所有 K 个用户信号的叠加, 可以表示为

$$\hat{y}_{n,t} = \sum_{k=1}^K \hat{h}_{n,k} \hat{s}_{n,k} \hat{x}_{k,t} + \hat{v}_{n,t}, n=1, 2, \dots, N \quad (2)$$

其中, $\hat{h}_{n,k}$ 表示用户 k 在第 n 个子载波上的信道系数, 是服从独立同分布的复高斯变量 $\hat{h}_{n,k} \sim \mathcal{CN}(0, 1)$. $\hat{s}_{n,k}$ 是扩频序列 \hat{s}_k 的第 n 个分量. $\hat{x}_{k,t} \in \mathcal{X}$ 是用户 k 在 t 时隙的传输符号. $\hat{v}_{n,t}$ 是在 t 时隙下第 n 个子载波上的复加性高斯白噪声 $\hat{v}_{n,t} \sim \mathcal{CN}(0, \sigma_v^2)$.

将所有 N 个子载波上的接收信号叠加后, 可以将时隙 t 上的接收矢量表示为

$$\hat{\mathbf{y}}_t = \hat{\mathbf{H}} \hat{\mathbf{x}}_t + \hat{\mathbf{v}}_t, t=1, 2, \dots, T \quad (3)$$

其中, $\hat{\mathbf{y}}_t = [\hat{y}_{1,t}, \hat{y}_{2,t}, \dots, \hat{y}_{N,t}]^T \in \mathbb{C}^{N \times 1}$. 为BS在时隙 t 下的接收向量, $\hat{\mathbf{x}}_t = [\hat{x}_{1,t}, \hat{x}_{2,t}, \dots, \hat{x}_{K,t}]^T \in \mathbb{C}^{K \times 1}$ 为所有 K 个用户在时隙 t 发送的信号向量, $\hat{\mathbf{H}} \in \mathbb{C}^{N \times K}$ 为观测矩阵, 其中第 n 行第 k 列的元素等于 $\hat{h}_{n,k} \times \hat{s}_{n,k}$, $\hat{\mathbf{v}}_t = [\hat{v}_{1,t}, \hat{v}_{2,t}, \dots, \hat{v}_{N,t}]^T \in \mathbb{C}^{N \times 1}$ 为 N 个正交子载波在时隙 t 上的噪声向量.

为了方便, 我们在这里将式(3)以实数形式重写为

$$\mathbf{y}_t = \mathbf{H} \mathbf{x}_t + \mathbf{v}_t \quad (4)$$

其中, $\mathbf{y}_t = [\text{Re}(\hat{\mathbf{y}}_t)^T, \text{Im}(\hat{\mathbf{y}}_t)^T]^T$, $\mathbf{x}_t = [\text{Re}(\hat{\mathbf{x}}_t)^T, \text{Im}(\hat{\mathbf{x}}_t)^T]^T$,

$$\mathbf{v}_t = [\text{Re}(\hat{\mathbf{v}}_t)^T, \text{Im}(\hat{\mathbf{v}}_t)^T]^T, \mathbf{H} = \begin{bmatrix} \text{Re}(\hat{\mathbf{H}}) & -\text{Im}(\hat{\mathbf{H}}) \\ \text{Im}(\hat{\mathbf{H}}) & \text{Re}(\hat{\mathbf{H}}) \end{bmatrix}, \text{Re}(\cdot)$$

表示取向量或矩阵内各元素的实部, $\text{Im}(\cdot)$ 表示取向量或矩阵内各元素的虚部.

3 TI-A-ADMM 算法

本节将对所提出的阈值改进的自适应交替方向乘

子(TI-A-ADMM)算法进行详细描述,包括用户时间相关性的介绍、未优化初始阈值的TI-A-ADMM算法介绍以及初始阈值优化方法的介绍。

3.1 时间相关性

在本文中,我们利用噪声阈值来判断用户是否活跃. 由于在动态块稀疏模型下,活跃用户不会在整个传输帧内保持活跃,因此无法根据帧稀疏特性来联合多时隙数据进行活跃用户检测. 为此,考虑利用活跃用户在相邻时隙间的特性来优化噪声阈值. 在第2节“系统模型”中,通过构建状态转移矩阵 \mathbf{P} 来表示用户在连续时隙中活跃状态的变化,这种变化称之为时间相关性. 由于免授权系统的特性,BS无法获得用户在不同时隙的状态转移概率,因此,引入相关性度量 $\tau_{k,t}$,通过统计活跃用户在连续时隙中的状态,以近似体现这种时间相关性:

$$\tau_{k,t}^{[i]} = \delta_{k,t-1}^{[i]} + \delta_{k,t+1}^{[i-1]} \quad (5)$$

当 $\tau_{k,t}^{[i]}$ 的值增大时,表示用户 k 在 t 时隙处于活跃状态的概率相应提高;反之,则表示用户 k 在 t 时隙为活跃的概率降低. 需要注意的是,在现实应用中,下一个时隙的用户活跃状态 $\delta_{k,t+1}$ 是不可知的. 但在本文的研究中,由于采用的是迭代检测的方法,因此时隙 $t+1$ 的用户活跃状态是从前一次迭代中 $\delta_{k,t+1}^{[i-1]}$ 得到的. 我们利用缩放因子 $\sigma_{k,t}^{[i]}$ 表示相关性度量 $\tau_{k,t}^{[i]}$ 对活跃用户检测判决的影响:

$$\sigma_{k,t}^{[i]} = 1 - \beta \times \tau_{k,t}^{[i]} \quad (6)$$

其中,常数 β 表示缩放步长. 在第 i 次迭代中,用缩放因子 $\sigma_{k,t}^{[i-1]}$ 对初始噪声阈值进行自适应缩放,即 $P_{\text{th}} \times \sigma_{k,t}^{[i-1]}$. 于是,动态块稀疏模型下的活跃用户检测表示为

$$\delta_{k,t}^{[i]} = \begin{cases} 1, & |z_{k,t}^{[i]}| > P_{\text{th}} \times \sigma_{k,t}^{[i-1]} \\ 0, & \text{Otherwise} \end{cases} \quad (7)$$

其中, P_{th} 表示初始噪声阈值,即首次迭代 $i=0$ 中活跃用户检测的能量阈值,其定义了非活跃用户重构信号的能量上限.

3.2 TI-A-ADMM算法

考虑满足式(4)的动态块稀疏模型,从长度为 $2N$ 的接收向量 \mathbf{y} 中恢复出长度为 $2K$ 的系数向量 \mathbf{x} ,本文提出了阈值改进的自适应交替方向乘子(TI-A-ADMM)算法. 该算法将稀疏向量重构问题等效为搜索支持集 $\Sigma_t^* = \{k: \delta_{k,t} = 1\}$ 之外最稀疏的信号,并尽可能地与估计的信号值 $\tilde{\mathbf{x}}_t$ 接近,满足约束:

$$\min_{\mathbf{x} \in \mathbb{R}^{2K \times 1}} \frac{1}{2} \|\mathbf{y}_t - \mathbf{H}\mathbf{x}\|_2^2 + \frac{\alpha_t}{2} \|\mathbf{x} - \tilde{\mathbf{x}}_t\|_2^2 + \lambda_t \|\mathbf{x}\|_{1,w} \quad (8)$$

其中, $\alpha_t > 0$ 是正则参数, $\lambda_t > 0$ 为常数. $\|\mathbf{x}\|_{1,w} = \sum_{i=1}^{2K} w_i |x_i|$,

其中权重 w_i 用于表示第 i 个恢复信号是否位于搜索支持集 Σ_t^* 之外,即当 $i \in \Sigma_t^*$ 时, $w_i = 0$,当 $i \notin \Sigma_t^*$ 时, $w_i = 1$,即

$$w_{k,t} = \delta_{k,t} \oplus 1 \quad (9)$$

其中,符号 \oplus 表示异或操作. 上述式(8)进一步改写为

$$\begin{aligned} \min_{\mathbf{x} \in \mathbb{R}^{2K \times 1}} & \underbrace{\frac{1}{2} \|\mathbf{y}_t - \mathbf{H}\mathbf{x}\|_2^2 + \frac{\alpha_t}{2} \|\mathbf{x} - \tilde{\mathbf{x}}_t\|_2^2}_{f(\mathbf{x})} + \underbrace{\lambda_t \|\mathbf{x}\|_{1,w}}_{g(\mathbf{z})} \\ & = \min_{\mathbf{x}, \mathbf{z} \in \mathbb{R}^{2K \times 1}} f(\mathbf{x}) + g(\mathbf{z}) \end{aligned} \quad (10)$$

s.t. $\mathbf{x} = \mathbf{z}$

通过引入变量 \mathbf{z} ,我们可以利用ADMM算法的优势,进行变量的交替迭代,将优化问题进行分布式求解,提高检测效率. 在第 i 次迭代中,式(7)的缩放形式可以通过三个的交替更新进行求解:

$$\begin{aligned} \mathbf{x}_t^{[i+1]} &= \arg \min_{\mathbf{x}} \left(f(\mathbf{x}) + \frac{\rho_t}{2} \|\mathbf{x} - \mathbf{z}_t^{[i]} + \mathbf{u}_t^{[i]}\|_2^2 \right) \\ \mathbf{z}_t^{[i+1]} &= \arg \min_{\mathbf{z}} \left(g(\mathbf{z}) + \frac{\rho_t}{2} \|\mathbf{x}_t^{[i+1]} - \mathbf{z} + \mathbf{u}_t^{[i]}\|_2^2 \right) \\ \mathbf{u}_t^{[i+1]} &= \mathbf{u}_t^{[i]} + \mathbf{x}_t^{[i+1]} - \mathbf{z}_t^{[i+1]} \end{aligned} \quad (11)$$

其中, \mathbf{u}_t 是缩放的对偶变量, $\rho_t > 0$ 为惩罚参数. 式(11)中的变量 \mathbf{x}_t 可以由式(12)计算:

$$\begin{aligned} \mathbf{x}_t^{[i+1]} &= \left(\mathbf{H}^H \mathbf{H} + (\rho_t + \alpha_t^{[i]}) \mathbf{I}_{2K} \right)^{-1} \\ & \quad \times \left(\mathbf{H}^H \mathbf{y}_t + \alpha_t^{[i]} \tilde{\mathbf{x}}_t^{[i]} + \rho_t (\mathbf{z}_t^{[i]} - \mathbf{u}_t^{[i]}) \right) \end{aligned} \quad (12)$$

同时,式(11)的第2个等式可以通过软阈值操作近似求解为

$$\begin{aligned} z_{k,t}^{[i+1]} &= \max \left\{ x_{k,t}^{[i+1]} + u_{k,t}^{[i]} - \frac{\lambda_t w_{k,t}^{[i]}}{\rho_t}, 0 \right\} \\ & \quad - \max \left\{ -x_{k,t}^{[i+1]} - u_{k,t}^{[i]} - \frac{\lambda_t w_{k,t}^{[i]}}{\rho_t}, 0 \right\} \end{aligned} \quad (13)$$

其中, $z_{k,t}$ 是向量 \mathbf{z}_t 中的第 k 个元素. 同时,本文中引入原始残差 $\mathbf{r}_t^{[i]} = \mathbf{x}_t^{[i]} - \mathbf{z}_t^{[i]}$ 和对偶残差 $\mathbf{s}_t^{[i]} = -\rho_t (\mathbf{z}_t^{[i]} - \mathbf{z}_t^{[i-1]})$ 作为终止迭代的条件,即 $\|\mathbf{r}_t^{[i]}\|_2$ 和 $\|\mathbf{s}_t^{[i]}\|_2$ 都小于误差限 ϵ 时迭代终止,其中 $\|\cdot\|_2$ 表示向量的2-范数.

为了提高算法的收敛效率,TI-A-ADMM采用文献[26]动态正则参数的更新方法:

$$\alpha_t^{[i]} = \frac{KC_a}{N \left(\|\mathbf{r}_t^{[i]}\|_2 + \|\mathbf{s}_t^{[i]}\|_2 \right)} \quad (14)$$

其中, C_a 为常数. 整体算法归纳如算法1所示.

算法 1 TI-A-ADMM 算法

输入: 接收向量 \mathbf{y} , 测量矩阵 \mathbf{H} , 初始阈值 P_{th} , 放缩步长 β , 惩罚参数

ρ , 常数 λ_r , 误差限 ϵ 以及最大迭代次数 I_{max}

输出: 输出重构信号 $\mathbf{z}_t^{[i]}$ 和重构活跃用户集合 Σ^*

初始化: $i = 1, \Sigma^* = \mathbf{0}_{2K \times T}, \alpha_t^{[0]} = 0, \tilde{\mathbf{x}}_t^{[0]} = \mathbf{z}_t^{[0]} = \mathbf{u}_t^{[0]} = \mathbf{0}_{2K \times 1},$

$\mathbf{s}_t^{[0]} = \mathbf{r}_t^{[0]} = \infty, \mathbf{w}_t^{[0]} = \mathbf{1}_{2K \times 1}, \delta_{k,0}^{[0]} = \delta_{k,T+1}^{[0]} = 0$ 和 $\sigma^{[0]} = \mathbf{1}_{2K \times 1}$

WHILE $i < I_{max}$

DO

FOR $t = 1:T$

DO

按照式(12)和式(13)计算目标变量 $\mathbf{x}_t^{[i]}$ 和变量 $\mathbf{z}_t^{[i]}$

按照式(11)更新对偶变量 $\mathbf{u}_t^{[i]}$

按照式(7)进行活跃用户检测, 得到活跃用户状态 $\delta_{k,t}^{[i]}$, 更新用户活跃集合 Σ^* (集合 Σ^* 的第 k 行第 t 列的元素为 $\delta_{k,t}^{[i]}$)

按照式(5)、式(6)、式(9)分别对参数 $\tau_{k,t}^{[i]}$ 、 $\sigma_{k,t}^{[i]}$ 以及 $\mathbf{w}_{k,t}^{[i]}$ 进行更新

对残差 $\mathbf{r}_t^{[i]}$ 和 $\mathbf{s}_t^{[i]}$ 进行更新

按照式(14)更新正则化系数 $\alpha_t^{[i]}$

更新迭代次数 $i \leftarrow i + 1$

END

由于在不同信噪比条件下噪声能量有所不同, 因此初始噪声阈值也随之变化, 增加了寻找合适噪声阈值的难度. 为了解决这一问题, 我们利用深度学习框架对判定活跃用户的初始噪声阈值进行了优化.

3.3 优化初始阈值

在研究的过程中观察到, TI-A-ADMM 算法的性能在很大程度上受到初始噪声阈值设定的影响. 算法利用活跃用户通信的时间相关性对检测阈值进行自适应缩放, 而这一缩放过程本质上基于初始设定的噪声阈值. 在图 2 中, 我们展示了这一影响, 即在不同 SNR 条件下, 如何通过改变初始噪声阈值进而显著影响 TI-A-ADMM 算法的检测性能. 观察发现, 在 SNR 分别为 4、6 和 8 dB 的情况下, 当初始阈值分别设置约为 0.55、0.5 和 0.45 时, 算法得到的误符号率 (SER) 性能表现出局部最优. 这一结果表明初始噪声阈值的选择在




图 2 初始噪声阈值对 SER 性能的影响

不同 SNR 场景下具有显著的差异性, 强调了根据不同 SNR 条件进行针对性优化初始阈值的必要性.

鉴于信道条件的多变与复杂性, 本研究旨在在不同信噪比条件下提高活跃用户检测的准确性. 为此, 特别选取了具体的 SNR 数值作为优化对象, 并采用 DL 网络来优化初始噪声阈值设置. 通过这种方法, 得到了相对优化后的初始噪声阈值 P_{th}^* , 旨在进一步增强算法在多变信道环境下的检测性能.

深度学习 (DL) 优化网络的架构如图 3 所示. 网络中, 每个优化层均采用统一的结构, 具体包括 TI-A-ADMM 信号重构单元 (基于算法 1)、损失函数单元以及优化器单元. 特别地, 活跃用户检测的初始噪声阈值被设计为一个可学习的参数变量. 在这一架构下, 每个层的优化结果及相应参数, 都会被有效传递到下一层以实现进一步的学习与优化. 通过这样的迭代学习过程, 网络最终能够反复优化直至输出一个精化的初始噪声阈值 P_{th}^* .

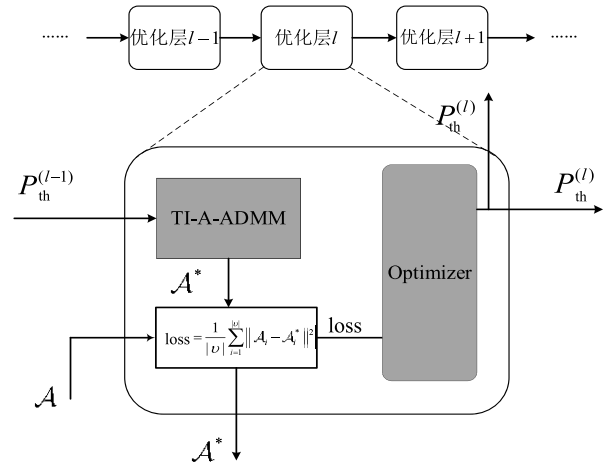


图 3 DL 优化网络图

在优化网络的运行过程中, 其操作方式与算法 1 中定义的 TI-A-ADMM 算法相似. 该过程要求输入如接收向量 \mathbf{y} 、测量矩阵 \mathbf{H} 和初始噪声阈值 P_{th} 等, 以便执行算法 1 的活跃用户检测估计. 此外, 在优化过程中还需要准确的活跃用户集合 \mathcal{A} 来计算损失函数:

$$\text{loss}(P_{th}) = \frac{1}{|v|} \sum_{i=1}^{|v|} \| \mathcal{A}_i - \mathcal{A}_i^* \|^2 \quad (15)$$

其中, v 是批大小 (batch size), 为 $|v|$ 的小批量 (mini-batch) 训练数据对; \mathcal{A}^* 是通过训练估计得到的活跃用户集合. 借助深度学习网络极强的学习能力和出色的适应性, 本研究利用算法 1、损失函数式 (15) 以及优化器, 得到了针对不同信噪比的优化的初始噪声阈值.

4 算法仿真结果及分析

在本研究的实验设计中,考虑了一个总数为 $K=200$ 的潜在用户群体,这些用户在 $T=7$ 时间内共享 $N=100$ 个正交资源用于数据传输.用户活跃概率 $p_a=0.1$,转移概率 $p_{11}=0.85$.扩频序列 \hat{s}_k 根据伪随机序列生成,活跃用户传输符号 $\hat{x}_{k,t}$ 从 4-QAM 星座图集合中选择.误差限 ϵ 、宽限步长 β 、最大迭代次数 I_{\max} 、常数 λ_t 以及惩罚参数 ρ_t 分别设置为 0.01、0.2、20、0.1 和 1.

我们采用 MATLAB 搭建的仿真平台执行蒙特卡罗模拟实验,旨在评估所提 TI-A-ADMM 算法的检测性能.具体地,通过计算误活跃率(AER)和误符号率(SER)来评估算法地检测性能,即

$$\begin{aligned} \text{AER} &= \frac{1}{N_s} \sum_{n=1}^{N_s} \frac{\text{aer}_n}{K \times T} \\ \text{SER} &= \frac{1}{N_s} \sum_{n=1}^{N_s} \frac{\text{ser}_n}{K \times T} \end{aligned} \quad (16)$$

其中, N_s 表示模拟实验的总次数, aer_n 表示第 n 次模拟实验中的活跃检测错误时段总数, ser_n 表示第 n 次模拟实验中的错误符号总数.每个信噪比下的 AER 和 SER 结果是 $N_s=1\ 000$ 次实验结果的平均值.

DL 优化网络的设置如下:在每个 SNR 下,优化网络包含 $L=10$ 个优化层和 50 个轮次(epochs).在每个 epoch 中生成 1 000 个数据对以供训练使用.学习率设置为 0.001,而 batch size 为 300.此外,初始的优化噪声阈值 $P_{\text{th}}^{(0)}=0.3$.作为关键部分的优化器,本实验选用了 Adam 优化器以实施优化操作.

如图 4 所示,在不同信噪比条件下,可以观察到噪声阈值的优化过程.从图 4 可以明显看出,经过 10 层的

优化后,阈值与 SNR 之间呈单调相关的趋势:随着信道质量的提高(即 SNR 值增大),优化后的阈值随之减小.




图 4 不同 SNRs 下的阈值优化过程

对每个 SNR 条件下的优化过程进行进一步的观察,我们发现随着优化层数的增加,阈值 P_{th}^* 逐渐收敛并趋于稳定.然而,有一个值得注意的现象是,在 SNR 为 -2 dB 的特定情况下,优化后的阈值并没有显示出稳定性,相反它显示出连续上升的趋势.即使在提高了学习率的情况下,优化阈值还是在不断增加,并最终在信号传输能量水平附近稳定下来.这提示我们在极其恶劣的信道条件下,信号几乎被噪声所掩盖,难以仅凭阈值的优化进行有效区分.因此,为保证研究的实用性,本文将系统的工作区间设定为高于 -2 dB 的范围.为了实验的连贯性,我们在 -2 dB 的条件下依旧使用图 4 所示的优化阈值执行活跃用户检测.经过深度学习优化后的初始噪声阈值在不同 SNR 条件下的结果列于表 1 中.

表 1 不同 SNRs 下的优化阈值参数

信噪比 SNR/dB	-2	0	2	4	6	8	10	12	13	14
优化噪声阈值 P_{th}^*	0.670 3	0.567 9	0.575 9	0.554 7	0.487 1	0.450 9	0.418 7	0.426 5	0.410 4	0.403 1

通过与多种经典算法的比较分析,包括正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法^[27]、侧信息辅助的块正交匹配追踪(SIA-BOMP)^[20]、子空间追踪(SP)算法^[18]、动态压缩感知(DCS)算法^[19],以及本文提出的 TI-A-ADMM 算法,本研究对动态块系数模型中的算法检测性能进行了评估实验.实验假设中,OMP、SIA-BOMP 以及 TI-A-ADMM 算法操作时未知用户活跃信息,如活跃用户数量、活跃概率和状态转移概率.

其中,本文提出的 TI-A-ADMM 算法采用了深度学习优化的噪声阈值.而 SP 和 DCS 算法则预设了活跃用户数量信息,据此进行活跃用户检测.作为参考标准,本文还引入了具备确切活跃用户信息的最小二乘法(Least Squares, LS),即 Oracle LS^[28]算法.

图 5 与图 6 分别展示了在动态块稀疏 GF-NOMA 场

景下不同检测算法在 AER 和 SER 方面的性能表现.Oracle LS 算法,由于其拥有完整的活跃用户信息,被作为一个理想的参考基线,因此没有包含在 AER 性能的对比分析中.我们观察到 SER 性能显著依赖于算法在活跃用户检测上的准确性.在众多算法中,未知活跃信息的 OMP 算法表现最弱,这是因为它依赖于活跃用户的稀疏度作为先验信息.当用户活跃数量未知时,OMP 算法无法准确判断活跃用户.而 SIA-BOMP,尽管也没有活跃用户信息,但通过利用前一时隙的检测结果作为辅助信息,并采用预设的能量阈值进行剪枝,得以提升了 AER 和 SER 的表现.本文提出的 TI-A-ADMM 算法则进一步优化了性能,它的噪声阈值不仅自适应于动态块稀疏模型的时间相关性,还通过深度学习网络优化了不同信噪比条件下的初始阈值.




图5 不同算法的AER性能比较


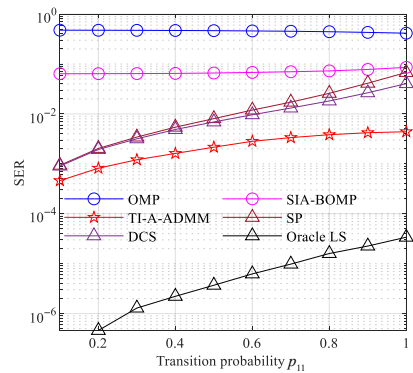


图6 不同算法的SER性能比较

仿真结果表明,即使在未知活跃用户数信息的情况下,所提TI-A-ADMM算法在AER和SER方面的表现仍显著优于需要已知活跃用户数量的SP算法.对于需要先验活跃用户数信息的DCS算法,在低SNR条件下, TI-A-ADMM算法表现更为出色.然而,当SNR大于12 dB时,DCS算法的性能更好.这是因为DCS算法利用每个时隙的活跃用户数量作为先验信息,而TI-A-ADMM仅依赖优化的噪声阈值来识别活跃用户.因此,在高SNR下,当 $SER < 10^{-6}$ 时,DCS算法的性能提升更为显著.但是DCS仅适用于预知活跃用户数量的场景,无法适用于未知活跃用户数的场景.同时TI-A-ADMM在SER为 10^{-5} 取得的性能优势,也可满足无线通信的典型性能指标^[29].

图7描述了用户状态转移概率 p_{11} 对各检测算法SER性能的影响,其中信噪比(SNR)设定为6 dB.结果显示,转移概率的提升导致每个用户的活跃时间延长,进而增加了时隙中的活跃用户数量,从而降低了信号的稀疏性.在此情况下,SP算法、DCS算法和Oracle LS算法的性能均随转移概率的提高而显著下降.由于OMP算法在6 dB信噪比条件下本身性能较差,转移概

率的变动对其性能影响甚微. SIA-BOMP算法尽管利用了前一时隙的检测结果来辅助当前检测,能够在一定程度上抑制由转移概率增加所引起的多用户干扰,但在6 dB的条件下其性能仍有限. TI-A-ADMM算法则采用相关性度量对噪声阈值进行缩放,实现了自适应优化,缓解了由用户活跃度升高带来的不利影响,确保了即便在转移概率增加的情况下仍能维持较高的检测性能.

图7 转移概率 p_{11} 对算法SER性能的影响

进一步地,我们对TI-A-ADMM算法的计算复杂度进行了评估,并将其与其他算法进行了比较.考虑到Oracle LS算法不涉及活跃用户的检测流程,我们排除了它的比较.依据文献[26]中的方法,我们通过测量中央处理单元(Central Processing Unit, CPU)的处理时间来量化算法的时间复杂度.在本文的复杂度评估中,硬件设备采用了Intel(R) Core(TM) i5-10400处理器,软件仿真平台为MATLAB 2022b.图8展示了在不同信噪比(SNR)条件下,各算法的运行时间.显著地, TI-A-ADMM算法的计算复杂度低于SIA-BOMP算法,但高于SP算法和DCS算法.这是因为SP和DCS算法能够直接利用已知的每个时隙活跃用户数量进行迭代,显著降低了处理时间.相比之下, SIA-BOMP算法由于不知道活跃用户数量,必须依赖于残差结果来判断迭代是否

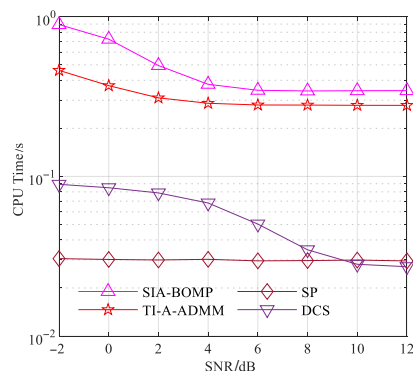


图8 每个帧的平均处理时间

终止,导致其复杂度与算法的收敛速度相关. TI-A-ADMM 算法通过采用优化后的阈值进行活跃用户检测,减少了对残差要求的依赖,从而实现了相对于 SIA-BOMP 的复杂度降低.

5 结论

本研究针对 GF-NOMA 动态块稀疏(动态接入)系统中的多用户检测难题,提出了一种新型的阈值改进自适应交替方向乘子(TI-A-ADMM)算法. 此算法基于用户连续时隙活跃状态的相关性,无需依赖先验稀疏度信息,引入动态相关性度量对检测中的噪声阈值进行自适应调整,并利用深度学习技术进一步优化阈值,显著提升了多用户检测的准确性. 仿真实验结果表明,该方法在动态块稀疏模型环境下,即便在没有信号稀疏度信息的情况下,也能实现优于现有技术的检测性能,展现出对多用户干扰的低衰减和高鲁棒性.

参考文献

- [1] NGUYEN D C, DING M, PATHIRANA P N, et al. 6G Internet of Things: A comprehensive survey[J]. IEEE Internet of Things Journal, 2022, 9(1): 359-383.
- [2] 柴蓉, 陈米铃, 李锦红. 基于效用优化的星地融合网络联合用户关联及资源块调度算法[J]. 电子学报, 2023, 51(12): 3483-3495.
CHAI R, CHEN M L, LI J H. Utility optimization-based joint user association and resource allocation algorithm for integrated satellite-terrestrial network[J]. Acta Electronica Sinica, 2023, 51(12): 3483-3495. (in Chinese)
- [3] LIU J A, WANG X D. A grant-based random access scheme with low latency for mMTC in IoT networks[J]. IEEE Internet of Things Journal, 2023, 10(20): 18211-18224.
- [4] LEE W, CHOI S I, JANG Y H, et al. Distributed hybrid NOMA/OMA user allocation for wireless IoT networks[J]. IEEE Internet of Things Journal, 2023, 11(3): 5316-5330.
- [5] 丁青锋, 李怡浩, 徐梦引. 去蜂窝大规模 MIMO-NOMA 系统能效优化算法[J]. 电子学报, 2023, 51(8): 2020-2029.
DING Q F, LI Y H, XU M Y. Energy efficiency optimization algorithm for cell-free massive MIMO-NOMA systems[J]. Acta Electronica Sinica, 2023, 51(8): 2020-2029. (in Chinese)
- [6] LV S, XU X, HAN S, et al. Energy-efficient secure short-packet transmission in NOMA-assisted mMTC networks with relaying[J]. IEEE Transactions on Vehicular Technology, 2022, 71(2): 1699-1712.
- [7] LIU J A, WANG X D. A grant-based random access scheme with low latency for mMTC in IoT networks[J]. IEEE Internet of Things Journal, 2023, 10(20): 18211-18224.
- [8] BAI Y, CHEN W, AI B, et al. Prior information aided deep learning method for grant-free NOMA in mMTC[J]. IEEE Journal on Selected Areas in Communications, 2022, 40(1): 112-126.
- [9] 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.
- [10] GAO P, LIU Z, XIAO P, et al. Low-complexity block coordinate descend based multiuser detection for uplink grant-free NOMA[J]. IEEE Transactions on Vehicular Technology, 2022, 71(9): 9532-9543.
- [11] KHAN S, DURRANI S, SHAHAB M B, et al. Joint user and data detection in grant-free NOMA with attention-based BiLSTM network[J]. IEEE Open Journal of the Communications Society, 2023, 4: 1499-1515.
- [12] 陈平平, 王宣达, 谢肇鹏, 等. 基于稀疏贝叶斯学习的大规模多用户检测算法[J]. 通信学报, 2023, 44(10): 186-197.
CHEN P P, WANG X D, XIE Z P, et al. Sparse Bayesian learning-based massive multi-user detection algorithm[J]. Journal on Communications, 2023, 44(10): 186-197. (in Chinese)
- [13] 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.
- [14] BAI Y, CHEN W, SUN F, et al. Data-driven compressed sensing for massive wireless access[J]. IEEE Communications Magazine, 2022, 60(11): 28-34.
- [15] ZHANG Y, GUO Q, WANG Z, et al. Block sparse Bayesian learning based joint user activity detection and channel estimation for grant-free NOMA systems[J]. IEEE Transactions on Vehicular Technology, 2018, 67(10): 9631-9640.
- [16] DU Y, DONG B, ZHU W, et al. Joint channel estimation and multiuser detection for uplink grant-free NOMA[J]. IEEE Wireless Communications Letters, 2018, 7(4): 682-685.
- [17] HASAN S M, MAHATA K, HYDER M M. Uplink grant-free NOMA with sinusoidal spreading sequences[J]. IEEE Transactions on Communications, 2021, 69(6): 3757-3770.
- [18] DAI W, MILENKOVIC O. Subspace pursuit for compres-

- sive sensing signal reconstruction[J]. IEEE Transactions on Information Theory, 2009, 55(5): 2230-2249.
- [19] WANG B, DAI L, ZHANG Y, et al. Dynamic compressive sensing-based multi-user detection for uplink grant-free NOMA[J]. IEEE Communications Letters, 2016, 20(11): 2320-2323.
- [20] CUI Y, XU W, 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.
- [21] LIU Y, YI W, DING Z, et al. Developing NOMA to next generation multiple access: Future vision and research opportunities[J]. IEEE Wireless Communications, 2022, 29(6): 120-127.
- [22] CAMPO A, FABREGAS A G I, BIGLIERI E. Large-system analysis of multiuser detection with an unknown number of users: A high-SNR approach[J]. IEEE Transactions on Information Theory, 2011, 57(6): 3416-3428.
- [23] ZHU W, TAO M, GUAN Y. Double-sided information aided temporal-correlated massive access[J]. IEEE Wireless Communications Letters, 2022, 11(9): 1860-1864.
- [24] BELHABIB A, AMADID J, ZEROUAL A. Large-scale fading coefficients classification-aided power control strategy for mitigating the pilot contamination in massive MIMO systems[J]. Statistics, Optimization & Information Computing, 2022, 10(1): 107-118.
- [25] ZHANG X, FAN P, LIU J, et al. Bayesian learning-based multiuser detection for grant-free NOMA systems[J]. IEEE Transactions on Wireless Communications, 2022, 21(8): 6317-6328.
- [26] LIU H, SONG B, QIN H, et al. An adaptive-ADMM algorithm with support and signal value detection for compressed sensing[J]. IEEE Signal Processing Letters, 2013, 20(4): 315-318.
- [27] TROPP J A, GILBERT A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655-4666.
- [28] DU Y, DONG B, CHEN Z, et al. Efficient multi-user detection for uplink grant-free NOMA: Prior-information aided adaptive compressive sensing perspective[J]. IEEE Journal on Selected Areas in Communications, 2017, 35(12): 2812-2828.
- [29] GHAFOR U, ALI M, KHAN H Z, et al. NOMA and future 5G & B5G wireless networks: A paradigm[J]. Journal of Network and Computer Applications, 2022, 204: 103413.

作者简介



石昌伟 男, 1999年10月出生于福建省福州市. 现为福州大学物理与信息工程学院博士研究生. 主要研究方向为无线通信、信号与信息处理及多址接入.

E-mail: 949497088@qq.com



郭里婷 女, 1976年11月出生于福建省漳州市. 现为福州大学物理与信息工程学院副教授, 硕士生导师. 主要研究方向为无线通信、信息与信号处理及多址接入等.

E-mail: guoliting@fzu.edu.cn