



# 面向大规模接入的通信感知一体化

邵晓丹<sup>1</sup>, 陈枫<sup>1\*</sup>, 仇挺之<sup>1</sup>, 陈晓明<sup>2</sup>, 钟财军<sup>2</sup>

1. 西南大学人工智能学院, 重庆 400715

2. 浙江大学信息与电子工程学院, 杭州 310027

\* 通信作者. E-mail: fengchenmit@swu.edu.cn

收稿日期: 2022-07-06; 修回日期: 2022-8-27; 接受日期: 2022-10-14; 网络出版日期: 2023-06-12

**摘要** 随着万物互联的愿景不断推进, 无线电频谱稀缺已成为制约未来无线通信系统发展的严峻挑战. 为了解决上述问题, 通信感知一体化 (integrated sensing and communication, ISAC) 逐渐成为第六代 (sixth-generation, 6G) 移动通信技术与业务的主导趋势之一. ISAC 系统不仅能完成可靠的多设备通信, 同时能实现准确的感知, 有望成倍提高频谱效率. 同时, 具有高可靠、低时延和小成本特性的大规模随机接入技术被广泛认为是 6G 通信网络的核心技术之一. 为此, 本文提出了面向大规模随机接入的通信感知一体化框架, 即大规模随机接入系统可以利用相同的频谱、硬件和信号处理模块来完成物体成像的感知服务. 具体而言, 激活设备同时向基站发送待解码的数据信息, 信号被环境中物体散射后到达基站. 在基站端, 本文探究了大规模接入的偶发性通信的特性和环境信息的稀疏特性, 基于张量建模与分解、变分贝叶斯 (Bayes) 推断和字典学习技术, 提出了新的联合激活设备检测和物体成像感知算法. 严谨的理论分析和大量的仿真实验验证了所提算法的准确性和高效性.

**关键词** 通信感知一体化, 大规模随机接入, 张量正则 - 双峰分解, 贝叶斯学习, 字典学习

## 1 引言

万物互联应用的出现推动了网络从第五代 (fifth-generation, 5G) 移动通信技术向未来第六代 (sixth-generation, 6G) 移动通信技术的演进. 与 5G 相比, 6G 需要满足更高的性能指标, 包括更高的感知精度、更短的时延、更可靠的传输、更低的能耗、更广域的覆盖等, 以实现物理世界与数字世界的连接和融合. 其中, 智能设备的指数级增长以及对可靠性的高要求, 使得高精度和高分辨率感知成为 6G 系统设计的首要挑战. 此外, 无线感知和通信可以共享相同的硬件、协议和组网, 从而有效降低基础设施和部署成本. 而且感知和通信频谱的共享可以成倍地提高频谱利用率, 例如, 无线信号不仅可以被调制以承载数据, 还可以在空间传播时通过反射、散射和折射重新用于感知周围物体的形状和状态. 在此背景下, 通信感知一体化 (integrated sensing and communication, ISAC) 被广泛认为是 6G 的核心技术之一.

**引用格式:** 邵晓丹, 陈枫, 仇挺之, 等. 面向大规模接入的通信感知一体化. 中国科学: 信息科学, 2023, 53: 1197–1211, doi: 10.1360/SSI-2022-0266  
Shao X D, Chen F, Chou T Z, et al. Integrated sensing and communication for massive access (in Chinese). Sci Sin Inform, 2023, 53: 1197–1211, doi: 10.1360/SSI-2022-0266

到目前为止, 工业界和学术界已经提出了不同的 ISAC 方案. 一种方案为感知与通信系统共存. 这意味着感知和通信可以使用分离的信号和信号处理模块, 但共享相同的资源 (例如频谱资源、天线阵列等) 以实现更高的频谱和硬件效率. 在这种方法中, 干扰消除和系统管理技术是难点. 为了解决这些难点, 文献 [1, 2] 针对雷达与通信共存系统, 提出了有效的干扰消除和管理机制. 第二种方案为感知与通信合作共生. 即感知和通信可以使用相同的硬件和信号 (例如共享信号波形), 并利用联合信息来改进其中一个系统的性能而不影响另一个系统, 即感知辅助通信, 或通信辅助感知. 例如, 文献 [3] 通过从室内场景 WIFI 通信信号传达的信道信息中提取多普勒 (Doppler) 频移来识别人体的行为. 在文献 [4] 中, 作者使用正交频分复用技术, 将通信波形作为雷达信号, 联合实现车辆通信和环境感知. 第三种方案为互惠互利的感知和通信, 即感知和通信在各个方面进行协调和协作, 包括硬件、信令、协议和网络等. 它们可以相互促进和受益.

在上述三种方案中, 方案二在性能提升和实现难易程度之间达到了最好的均衡, 因此本文关注于感知与通信合作共生的应用场景. 具体而言, 在通信感知一体化研究中, 无线感知侧重于利用电磁波信号, 特别是射频信号来检测和估计物体和环境的各种特征<sup>[5]</sup>. 而成像也成为了其中非常重要的应用之一. 目前, 毫米波成像技术已经有许多应用, 例如, 自主机器人<sup>[6]</sup> 和安全检查<sup>[7]</sup>. 在毫米波成像中, 感兴趣区域由一个或多个发射器照亮, 相应的信号在传播中所造成的散射能量被接收端采样, 用于合成孔径雷达图像<sup>[8]</sup>. 由于无线信号的穿透力有限, 为了提高成像的分辨率, 需要在空间环境中配备多个发射端和接收端来从各个角度照亮物体. 但是配备大量发射接收端会导致感知系统硬件代价过大.

为了解决这个问题, 本文提出共享大规模随机接入系统的硬件设施和信号处理模块来实现物体成像感知. 大规模机器通信 (massive machine-type communications, mMTC) 是 5G 的典型应用场景, 6G 将在 5G 基础上, 融合感知和通信等能力, 构建持续演进的大规模机器通信 (continuous evolution of mMTC, mMTC+) 场景, mMTC+ 在 5G mMTC 基础上, 将连接对象扩展至智慧城市、智慧工厂、智慧交通等场景<sup>[9]</sup>. mMTC+ 是典型的事件驱动的无线通信, 海量设备中只有一小部分设备同时处于激活状态<sup>[10]</sup>, 具有极强的偶发性. 为了节省物联网设备的能量, 需要采用大规模随机接入技术. 激活的多个设备在向基站发送数据的过程中, 信号可以从不同的角度将物体照亮, 这自然而然地为感知提供了良好的感知网络和信号资源, 而无需重新配备多个发射接收感知设备和发送专门的感知信号, 节省了硬件资源和频谱资源. 在传统的基于授权的随机接入方案中, 一个序列被多个设备重复选择的概率 (即碰撞概率) 非常高, 使得此方案有极高的接入延迟和信令开销. 因此, 免授权随机接入方案被认为是解决这一问题一个很有前景与竞争力的技术<sup>[10~16]</sup>. 免授权随机接入方案包括有源随机接入和无源随机接入. 目前讨论较多的是有源随机接入, 在该技术中, 每个设备都被预先分配了唯一的非正交导频序列, 从而避免了碰撞的发生. 基站基于接收到的信号辨识发送来的导频序列, 进而识别出哪些设备处于激活状态<sup>[10]</sup>. 然而, 由于 6G 无线网络中的设备数量增长相当迅速, 为了从总共  $\bar{K}$  个设备中检测出  $K_a$  个激活的设备, 导频序列的长度也会以  $K_a \log(\bar{K})$  的规模迅速增长<sup>[17, 18]</sup>. 为了攻克这一难题, 另一类免授权随机接入, 即无源随机接入 (unsourced random access, URA) 方案被提出<sup>[19]</sup>. 事实上, URA 的提出很大程度上受到了物联网的激励, 在物联网场景中有大量的低功耗设备, 这些设备在生产时拥有一个通用码本<sup>[19~22]</sup>. 激活的设备将其消息映射为公共码本的码字, 接着基站通过检测传输的码字恢复消息, 无需确定激活设备的身份标识. 激活设备如果想让自己被识别, 可以将身份信息嵌入自己的数据中. 与有源随机接入相比, URA 具有更高的频谱效率, 因为它不用发送用于身份检测的导频序列. 此外, URA 具有较低的计算复杂度, 其复杂度仅取决于激活的设备数, 而与潜在设备总数目无关<sup>[23]</sup>. 因此, URA 非常契合拥有大量设备接入而较少设备激活的 6G 无线通信网络.

因此, 为了实现高精度低成本成像, 本文利用大规模无源随机接入 URA 来实现成像感知. 我们的

设计描述如下. 首先, 激活设备同时向基站发送待解码的数据信号, 信号被物体散射, 然后到达基站. 基站通过张量分解技术可以同时解码出激活设备发送来的数据、激活设备数目, 和包含物体成像信息的参量, 然后利用字典学习和压缩感知技术, 可以从此参量中提取出物体的信息. 具体而言, 本文的创新性主要包括以下 3 个方面.

(1) 本文首次提出了面向大规模接入的通信感知一体化架构, 该架构利用相同的频谱、硬件和信号处理模块同时完成激活设备检测和环境感知功能, 为 6G 通信感知一体化打下坚实基础.

(2) 本文利用大规模接入的偶发通信的特性和环境信息的稀疏特性, 将 ISAC 问题建模为高阶张量分解问题, 并基于变分贝叶斯 (Bayes) 学习、字典学习和稀疏信号处理技术, 设计了一种新的低复杂度的联合激活设备检测和感知算法.

(3) 本文提供了所提出算法的理论分析, 结果表明所提算法具有快速收敛、低计算复杂度和分解唯一性等优点.

本文其余部分组织如下: 第 2 节介绍了面向大规模接入的通信感知一体化的系统模型. 第 3 节设计了联合激活设备检测和感知算法, 并且分析了其性能. 第 4 节提供了仿真结果以证明所提算法的有效性. 最后第 5 节总结了全文的工作.

**符号说明.** 本文使用粗体大写 (小写) 字母表示矩阵 (矢量), 使用  $\mathbb{C}^{A \times B}$  表示维度为  $A \times B$  的复矩阵空间,  $|\cdot|$  表示对复数取模,  $(\cdot)^H$  和  $(\cdot)^T$  分别表示取复矩阵的共轭转置与转置,  $\otimes$  表示克罗内克 (Kronecker) 积,  $\circ$  表示矢量的外积,  $\|\cdot\|_F$  表示矩阵的弗罗贝尼乌斯 (Frobenius) 范数,  $\|\cdot\|_2$  表示矢量的  $l_2$  范数,  $[\cdot]$  表示克鲁斯卡尔 (Kruskal) 算子.  $x \in [a, b]$  意味着标量  $x$  在  $a$  和  $b$  之间的闭区间上.  $\mathbb{E}$  表示输入参数的期望.  $\|\cdot\|_0$  表示矢量的  $l_0$  范数.  $*$  表示共轭. Khatri Rao 乘积用  $\diamond$  表示. 哈达玛 (Hadamard) 积用  $\odot$  表示.  $\mathbf{I}_K$  表示  $K \times K$  的单位矩阵. 矢量  $\mathbf{1}_K \in \mathbb{R}^K$  是长度为  $K$  的全 1 矢量.  $\mathbf{a}(n)$  表示矢量  $\mathbf{a}$  第  $n$  个元素.  $\mathbf{A}(n, k)$  表示矩阵  $\mathbf{A}$  的  $(n, k)$  位置上的元素.  $\mathbf{A}(:, n)$  和  $\mathbf{A}(n, :)$  分别表示矩阵  $\mathbf{A}$  的第  $n$  列和第  $n$  行.  $\text{Tr}(\cdot)$  表示矩阵的迹.  $\mathbf{x} \in \mathbb{C}^n$  矢量值服从均值为  $\mathbf{u}$ , 协方差矩阵为  $\Sigma$  的正态分布, 形式为  $\mathcal{CN}_n(\mathbf{x}|\mathbf{u}, \Sigma)$ .  $\mathcal{O}(\cdot)$  表示大 O 符号.  $p(\cdot| \cdot)$  表示条件概率分布.  $\text{diag}(\mathbf{x})$  表示对角线项是由矢量  $\mathbf{x}$  指定的对角矩阵.

## 2 系统模型

本文考虑 6G 中的 mMTC+ 场景, 其对通信的需求是海量终端通过轻度连接来承载零散业务, 虽然连接数可达每平方公里支持千万级连接, 但是其中仅有少量设备激活, 其他设备为了节省能量而暂时处于休眠状态; 对感知的需求是精准感知辅助完成物理世界的数据采集. 因此本文考虑如图 1 所示的面向大规模接入的通信感知一体化系统, 其中毫米波基站配备了  $M$  根天线, 服务于大规模单天线设备, 其中只有  $K_a$  个设备处于激活状态, 设备和基站之间存在一个待成像的物体. 激活的设备同时向基站发送数据, 而基站感兴趣的是激活设备传输来的数据消息. 例如, 在智能工厂的海量设备质量检查过程中, 一小部分设备激活并生成其当前可靠性能指标, 同时发送给基站. 基站解码出激活设备所发送的数据后, 对这些数据信息进行加权平均计算, 以生成这批设备的平均可靠性能指标. 因为大规模接入的接入点、基站、设备已经遍布在通信网络中, 因此自然而然地提供了良好的感知网络, 而无需重新配备新的感知设备和发送额外的感知信号. 本文旨在用通信设备和通信信号在完成激活设备数据解码的过程中, 同时完成物体感知. 传统的感知是一种独立功能, 通过各种专用设备实现. 与传统的感知实现方式相比, 本文的通信感知一体化设计大幅降低了由额外的感知设备带来的成本.

激活设备发送的信号经过物体散射后到达基站, 本文首先离散化环境, 将成像区域 (region of




图 1 (网络版彩图) 面向大规模接入的通信感知一体化

Figure 1 (Color online) Integrated sensing and communication for massive access

imaging, ROI) 视为像素的集合, 即将 ROI 划分为大小均匀的  $D$  个子立方体, 每个子立方体视为一个像素. ROI 的特征是  $\mathbf{z} = [z_1, \dots, z_D]^T \in \mathbb{C}^D$ , 其中  $z_d$  表示第  $d$  个像素的散射系数, 如果小立方体的内部是空的, 则  $z_d = 0$ . 因此, 可以将 ROI 视为稀疏信号 [12]. 在无源大规模随机接入中 [24], 数百万低成本设备在生产时就将其码本固定化了, 使得所有设备需要共享通用码本 [20], 即  $\varphi = \{\mathbf{c}_1, \dots, \mathbf{c}_{2^B}\}$ , 其中  $B$  为激活设备需要向基站发送信息的比特数. 激活的设备将其消息映射为公共码本的码字发送, 基站的接收信号可以表示为

$$\mathbf{Y} = \sum_{k=1}^{K_a} \mathbf{U} \text{diag}(\mathbf{h}_k) \mathbf{z} \mathbf{s}_k^H + \mathbf{W}, \quad (1)$$

其中,  $\mathbf{s}_k \in \varphi \subset \mathbb{C}^\tau$  是从第  $k$  个设备发出的通过信道时长为  $\tau$  的复基带符号序列. 毫米波频段的分辨率高, 相对于低频段可以明显提高成像精度 [25, 26]. 因此本文采用文献 [26] 中的毫米波信道模型. 其中  $\mathbf{U} \in \mathbb{C}^{M \times D}$  是从基站到物体的信道, 且  $\mathbf{h}_k \in \mathbb{C}^D$  是从物体到第  $k$  个设备的信道.  $\mathbf{W} \in \mathbb{C}^{M \times \tau}$  是加性高斯 (Gauss) 白噪声.

首先, 本节将问题 (1) 转换成以下等价形式:

$$\mathbf{y} = \sum_{k=1}^{K_a} \mathbf{s}_k \otimes (\mathbf{U} \text{diag}(\mathbf{h}_k) \mathbf{z}) + \mathbf{w}. \quad (2)$$

然后, 根据张量分解的形式, 本文使用文献 [24] 中的子星座图. 具体来说, 本文假设信道时长  $\tau$  可以被分解为  $\tau = \prod_i^d \tau_i$ , 其中  $d \geq 2, \forall i$ . 接下来, 第  $k$  个设备发出信号  $\mathbf{s}_k \in \mathbb{C}^\tau$  可以利用矢量张量积的形式表示成秩为 1, 维度为  $\tau_1, \tau_2, \dots, \tau_d$  的张量  $\mathcal{S}_k \in \mathbb{C}^{\tau_1 \times \tau_2 \times \dots \times \tau_d}$ , 即

$$\mathbf{s}_k = \text{vec}(\mathcal{S}_k) \in \mathbb{C}^{\prod_i^d \tau_i} = \mathbb{C}^\tau, \quad (3)$$

$$\mathcal{S}_k = \mathbf{x}_{1,k} \circ \mathbf{x}_{2,k} \circ \dots \circ \mathbf{x}_{d,k}, \forall k, \quad (4)$$

其中, 每个  $\mathbf{x}_{i,k}$  都从子星座图  $\varphi_i$  中生成,  $\varphi_i$  定义为  $\mathbb{C}^{\tau_i}$  的一个离散子集. 因此, 式 (2) 可以化简为

$$\mathbf{y} = \sum_{k=1}^{K_a} \mathbf{x}_{1,k} \circ \mathbf{x}_{2,k} \circ \dots \circ \mathbf{x}_{d,k} \circ \underbrace{\mathbf{U} \text{diag}(\mathbf{h}_k) \mathbf{z}}_{\mathbf{A}_k} + \mathbf{W}. \quad (5)$$

假设信道信息未知, 本文的目标是恢复物体信息  $\mathbf{z}$  和数据  $\mathbf{x}_{i,k}$ . 注意一旦得到  $\mathbf{z}$  的估计值, 便可以得到物体的成像信息, 即感知环境中散射体位置的分布和散射系数. 而得到  $\mathbf{x}_{i,k}$  的估计值后, 激活的设备的信息便可以恢复出来. 注意毫米波的穿透性体现在散射系数中<sup>[12]</sup>. 具体而言, 本文假设目标点云是可以被毫米波穿透的, 可以恢复出整个物体的形状. 在实际应用里, 当毫米波本身穿透性不够, 不能穿透点云时, 物体被遮挡位置的成像结果, 即散射系数便为 0, 此时只能感知出物体的外表轮廓, 这不会影响接下来的算法设计.

### 3 联合激活设备检测和感知算法设计

从式 (5) 中恢复出物体和数据信息主要面临两个挑战. 首先, 数据信息、物体信息和未知的信道信息相互耦合在一起, 这阻碍了数据和物体信息的恢复. 另外, 由于设备是随机激活的, 激活设备数目 (张量的秩) 是未知的, 且估计其真实值是 NP 难的问题. 为了应对这些挑战, 本节设计了新的联合激活设备检测和感知算法.

#### 3.1 激活设备数据检测

为了应对  $K_a$  未知的这一挑战, 一个行之有效的方案是引入两个正则化项<sup>[27]</sup> 来惩罚模型的复杂度并且防止对噪声的过拟合, 如下所示:

$$\begin{aligned} & \arg \min_{\{\mathbf{X}^i \in \mathbb{C}^{\tau_i \times K}\}_{i=1}^d, \mathbf{G} \in \mathbb{C}^{M \times K}} \|\mathcal{Y} - [\mathbf{X}^1, \dots, \mathbf{X}^d, \mathbf{G}]\|_F^2 \\ & + \sum_{k=1}^K \gamma_k \sum_{i=1}^d \mathbf{X}^i(:, k)^H \mathbf{X}^i(:, k) + \eta_k \mathbf{G}(:, k)^H \mathbf{G}(:, k), \end{aligned} \quad (6)$$

其中  $\mathbf{X}^i \in \mathbb{C}^{\tau_i \times K}$  的第  $k$  列为  $\mathbf{x}_{i,k}$ , 类似的,  $\mathbf{G} \in \mathbb{C}^{M \times K}$  的第  $k$  列为  $\mathbf{A}_k \mathbf{z}$ . 此处, 因为  $\mathbf{z}$  包含物体信息, 本文故称  $\mathbf{G}$  为兴趣矩阵. 这里我们将所有因子矩阵  $\{\mathbf{X}^1, \dots, \mathbf{X}^d, \mathbf{G}\}$  的列数都设置为活跃设备数  $K_a$  的最大可能取值  $K$ . 关于正则化项的想法是如果在推断之后  $\gamma_k > 0$  与  $\eta_k > 0$  足够大 (如  $10^3$ ), 则  $\{\mathbf{X}^i\}_{i=1}^d$  和  $\mathbf{G}$  的第  $k$  列的元素值接近零. 那么, 可以删去其相应的列, 每个因子矩阵中剩余列的数量即为激活设备数量的估计值. 然而, 正则化参数  $\gamma_k$  和  $\eta_k$  的选择并不简单, 且计算复杂度非常高. 这是因为将  $\gamma_k$  和  $\eta_k$  设置得太大会导致均方误差的残差过大, 设置得太小可能会导致噪声拟合过度. 因此, 本文在贝叶斯学习框架下开发了一种智能算法, 使其自动学习因子矩阵和正则化参数.

##### 3.1.1 低秩诱导概率建模

首先, 式 (6) 中  $\mathbf{X}^i$  和  $\mathbf{G}$  可以被分别建模成服从零均值的复高斯先验分布的信号, 如下所示<sup>[28]</sup>:

$$p(\{\mathbf{X}^i\}_{i=1}^d | \{\gamma_k\}_{k=1}^K) = \prod_{i=1}^d \prod_{k=1}^K \mathcal{CN}(\mathbf{X}^i(:, k) | \mathbf{0}, \gamma_k^{-1} \mathbf{I}), \quad (7)$$

$$p(\mathbf{G}) = \prod_{k=1}^K \mathcal{CN}(\mathbf{G}(:, k) | \mathbf{0}, \eta_k^{-1} \mathbf{I}). \quad (8)$$

本文对惩罚参数  $\gamma_k$  添加了 gamma 分布的先验信息, 来加强因子矩阵的列稀疏性<sup>[28]</sup>:

$$p(\{\gamma_k\}_{k=1}^K | \boldsymbol{\nu}_\gamma) = \prod_{k=1}^K \text{gamma}(\gamma_k | \delta, \delta) = \prod_{k=1}^K \gamma_k^{\delta-1} \exp(-\delta \gamma_k), \quad (9)$$

$$p(\{\eta_k\}_{k=1}^K | \mathbf{z}_\eta) = \prod_{k=1}^K \text{gamma}(\eta_k | \delta, \delta) = \prod_{k=1}^K \eta_k^{\delta-1} \exp(-\delta \eta_k), \quad (10)$$

其中  $\gamma_k^{-1}$  可以解释为  $\mathbf{X}^i$  上每一列的能量, 自然参数  $\mathbf{z}_\gamma = [-\delta \mathbf{1}_K; (\delta-1) \mathbf{1}_K]$ , 和  $\mathbf{z}_\eta = [-\delta \mathbf{1}_K; (\delta-1) \mathbf{1}_K]$ . 注意到对 gamma 先验积分后, 式 (9) 和 (10) 的边缘概率分布是学生  $t$  分布, 其在零值处达到峰值, 并具有重拖尾特性, 从而可以促进稀疏性. 此外, gamma 超先验分布 (9) 与高斯先验分布 (8) 共轭. 这种共轭性可以保证变分推理存在闭式解.

最后, 由于加性噪声  $\mathcal{W}$  的元素服从高斯白噪声分布, 问题 (6) 中误差平方和可以理解为似然函数的负对数, 由下式给出:

$$p(\mathcal{Y} | \{\mathbf{X}^i\}_{i=1}^d, \mathbf{G}, \beta) \propto \exp\left(-\beta \sum \|\mathcal{Y} - [\mathbf{X}^1, \mathbf{X}^2, \dots, \mathbf{X}^d, \mathbf{G}]\|_F^2\right), \quad (11)$$

其中噪声精度  $\beta$  服从 gamma 分布, 即  $p(\beta | \mathbf{z}_\beta) \propto \beta^{\delta-1} \exp(-\delta\beta)$ , 自然参数  $\mathbf{z}_\beta = [-\delta; (\delta-1)]$ .

接下来, 令  $\Theta = \{\{\mathbf{X}^i\}_{i=1}^d, \mathbf{G}, \beta, \{\gamma_k, \eta_k\}_{k=1}^K\}$ , 则所有的未知变量  $\Theta$  和  $\mathcal{Y}$  的联合概率密度函数由下式给出:

$$\begin{aligned} p(\Theta, \mathcal{Y}) &= p(\mathcal{Y} | \{\mathbf{X}^i\}_{i=1}^d, \mathbf{G}, \beta) p(\{\mathbf{X}^i\}_{i=1}^d | \{\gamma_k\}_{k=1}^K) \times p(\beta | \mathbf{z}_\beta) p(\{\gamma_k\}_{k=1}^K | \mathbf{z}_\gamma) \\ &\propto \exp\left\{-\beta \|\mathcal{Y} - [\mathbf{X}^1, \mathbf{X}^2, \dots, \mathbf{X}^d, \mathbf{G}]\|_F^2 - \sum_{i=1}^d \text{Tr}(\Lambda \mathbf{X}^i \mathbf{H} \mathbf{X}^i) - \text{Tr}(\Lambda \mathbf{G} \mathbf{G}) + (\prod_{i=1}^{d+1} \tau_i M) \ln \beta \right. \\ &\quad \left. - \delta\beta - \sum_{k=1}^K \delta \gamma_k + (\delta-1) \ln \beta + (N+\delta-1) \sum_{k=1}^K \ln \eta_k - \sum_{k=1}^K \delta \eta_k + \left(\sum_{i=1}^d \tau_i + \delta - 1\right) \sum_{k=1}^K \ln \gamma_k\right\}, \quad (12) \end{aligned}$$

其中  $\Lambda = \text{diag}(\gamma_1, \dots, \gamma_K) \in \mathbb{C}^{K \times K}$ . 式 (12) 中已经给出了概率模型  $p(\Theta, \mathcal{Y})$ , 贝叶斯推理的下一个目标则是从张量数据  $\mathcal{Y}$  中学习模型参数  $\Theta$ , 那么我们需要先求得未知模型参数的后验分布, 即  $p(\Theta | \mathcal{Y})$ . 注意到最大化后验概率  $p(\Theta | \mathcal{Y}) = p(\Theta, \mathcal{Y}) / p(\mathcal{Y})$  类似于求解问题 (6). 但是问题 (6) 是不能学习正则化项参数的.

### 3.1.2 基于变分推理的智能算法

经过化简后, 联合概率密度模型 (12) 依然很复杂, 尤其是求解多重积分来计算后验分布通常很困难. 为了解决这个问题, 本文采用了变分推理方法, 它可以建立如下的变分分布  $Q(\Theta)$  去接近真实的后验  $p(\Theta | \mathcal{Y})$ . 为了达成这一目标, 要求  $Q(\Theta)$  是使 KL (Kullback-Leibler) 散度最小的解, 即

$$\underset{Q(\Theta)}{\text{minimize}} \text{KL}(Q(\Theta) | p(\Theta | \mathcal{Y})) \triangleq \underset{Q(\Theta)}{\text{minimize}} -\mathbb{E}_{Q(\Theta)} \left\{ \ln \frac{p(\Theta | \mathcal{Y})}{Q(\Theta)} \right\}. \quad (13)$$

为了求解问题 (13), 平均场近似被广泛用来提供问题 (13) 的可行解<sup>[29]</sup>, 该方法假设变分概率密度函数可以用完全分解的形式表示, 即  $Q(\Theta) = \prod_{j=1}^J Q(\Theta_j)$ , 其中  $\Theta_j \in \Theta$  是  $\Theta$  的一部分, 并且满足  $\bigcup_{j=1}^J \Theta_j = \Theta$  且  $\bigcap_{j=1}^J \Theta_j = \emptyset$ ,  $J$  是子集的数目. 通过因式分解, 表达式 (13) 可以化简为

$$\underset{Q(\{\Theta_j\}_{j=1}^J)}{\text{minimize}} -\mathbb{E}_{\{Q(\Theta_j)\}_{j=1}^J} \left\{ \ln \left( \frac{p(\Theta | \mathcal{Y})}{\prod_{j=1}^J Q(\Theta_j)} \right) \right\}. \quad (14)$$

从  $\{Q(\Theta_j)\}_{j=1}^J$  的因式分解结构可以看出, 我们可以使用块坐标下降来获得 (14) 的次优解. 具体而言, 通过固定变分  $\{Q(\Theta_i)\}_{i \neq j}$ ,  $Q(\Theta_j)$  可根据下式获得:

$$\underset{Q(\Theta_j)}{\text{minimize}} \int Q(\Theta_j) \left( -\mathbb{E}_{\prod_{i \neq j} Q(\Theta_i)} \ln p(\Theta, \mathcal{Y}) + \ln Q(\Theta_j) \right) d\Theta_j. \quad (15)$$

问题 (15) 的最优解可以由下式给出 [29]:

$$Q^\dagger(\Theta_j) = \frac{\exp(\mathbb{E}_{\Pi_{i \neq j} Q(\Theta_i)} \ln p(\Theta, \mathcal{Y}))}{\int \mathbb{E}_{\Pi_{i \neq j} Q(\Theta_i)} \ln p(\Theta, \mathcal{Y}) d\Theta_j}, \quad \forall j. \quad (16)$$

根据表达式 (16), 本文将在 3.2 小节中推导每个变分概率密度函数的闭合形式的后验更新表达式, 即  $Q^\dagger(\Theta_j)$ .

### 3.2 因子矩阵学习

首先, 本文需要推导每个变分概率密度函数的更新方程  $Q(\mathbf{X}^i)$ , 其均值矩阵是从激活设备传输的数据消息的估计值 [30]. 将式 (12) 带入式 (16) 并保留与  $\mathbf{X}^i$  相关的项, 可对变分概率密度函数  $Q(\mathbf{X}^i)$  做出如下推导:

$$\begin{aligned} Q^\dagger(\mathbf{X}^i) &\propto \exp \left\{ \mathbb{E} \left[ -\beta \|\mathcal{Y} - [\mathbf{X}^1, \mathbf{X}^2, \dots, \mathbf{X}^d, \mathbf{G}]\|_F^2 - \text{Tr}(\Lambda \mathbf{X}^{i,H} \mathbf{X}) \right] \right\} \\ &\propto \exp \left\{ -\text{Tr} \left( \underbrace{\mathbf{X}^i \mathbb{E}[\beta] \mathbb{E} \left[ \left( \underset{j=1, j \neq i}{\diamond} \mathbf{X}^j \diamond \mathbf{G} \right)^T \left( \underset{j=1, j \neq i}{\diamond} \mathbf{X}^j \diamond \mathbf{G} \right)^* \right]}_{(\boldsymbol{\Sigma}^i)^{-1}} + \mathbb{E}[\Lambda] \right. \right. \\ &\quad \left. \left. \times \mathbf{X}^{i,H} - \mathbf{X}^i (\boldsymbol{\Sigma}^i)^{-1} \left[ \underbrace{\mathbb{E}[\beta] \mathcal{Y}(i) \left( \underset{j=1, j \neq i}{\diamond} \mathbb{E}[\mathbf{X}^i] \diamond \mathbb{E}[\mathbf{G}] \right)^* \boldsymbol{\Sigma}^i}_{\mathbf{M}^i} - \mathbf{M}^i (\boldsymbol{\Sigma}^i)^{-1} \mathbf{X}^{i,H} \right]^H \right) \right\}. \quad (17) \end{aligned}$$

通过观察上式可以发现, 变分概率密度函数  $Q^\dagger(\mathbf{X}^i)$  ( $1 \leq i \leq d$ ) 服从正态分布  $\mathcal{CN}_{N \times K}(\mathbf{X}^i | \mathbf{M}^i, \mathbf{1}_{\tau_i} \otimes \boldsymbol{\Sigma}^i)$ , 其均值矩阵为  $\mathbf{M}^i$ , 协方差为  $\mathbf{1}_{\tau_i} \otimes \boldsymbol{\Sigma}^i$ .

一旦式 (17) 中的矩阵  $\mathbf{M}^i$  被推导出, 我们便可以获得传输消息的估计值.  $\mathbf{M}^i$  中除了  $\boldsymbol{\Sigma}^i$ , 其他的项可以直接算出. 根据性质  $(\odot_{j=1}^d \mathbf{A}^j)^T (\odot_{j=1}^d \mathbf{A}^j)^* = \odot_{j=1}^d \mathbf{A}^{j,T} \mathbf{A}^{j,*}$  可知 [28], 式 (17) 中  $(\boldsymbol{\Sigma}^i)^{-1}$  的因子矩阵的期望可以化简为

$$\mathbb{E} \left[ \left( \underset{j=1, j \neq i}{\diamond} \mathbf{X}^j \diamond \mathbf{G} \right)^T \left( \underset{j=1, j \neq i}{\diamond} \mathbf{X}^j \diamond \mathbf{G} \right)^* \right] = \underset{j=1, j \neq i}{\diamond} \mathbb{E} [\mathbf{X}^{j,T} \mathbf{X}^{j,*}] \odot \mathbb{E} [\mathbf{G}^T \mathbf{G}^*], \quad (18)$$

其中  $\odot_{j=1, j \neq i}^d \mathbf{A}^j = \mathbf{A}^d \odot \dots \odot \mathbf{A}^{i+1} \odot \mathbf{A}^{i-1} \odot \mathbf{A}^1$  是多重哈达玛积. 式 (18) 右侧第一个和第二个期望项可以分别由下式给出:

$$\mathbb{E} [\mathbf{X}^{j,T} \mathbf{X}^{j,*}] = \mathbf{M}^{j,T} \mathbf{M}^{j,*} + \tau_j \boldsymbol{\Sigma}^j, \quad (19)$$

$$\mathbb{E} [\mathbf{G}^T \mathbf{G}^*] = \mathbf{M}_G^T \mathbf{M}_G^* + M \boldsymbol{\Sigma}_G. \quad (20)$$

获得  $Q(\mathbf{X}^i)$  的表达式后, 我们可以用相似的方法推理出  $Q^\dagger(\mathbf{G})$  服从正态分布  $\mathcal{CN}_{N \times K}(\mathbf{G} | \mathbf{M}_G, \mathbf{1}_M \otimes \boldsymbol{\Sigma}_G)$ , 其均值矩阵为  $\mathbf{M}_G$ , 协方差为  $\mathbf{1}_M \otimes \boldsymbol{\Sigma}_G$ . 这里的均值矩阵给出了包含物体信息矩阵的最小均方差估计. 具体表达式总结在了第 3.5 小节的算法 1 中.

### 3.3 超参数学习

接下来, 本小节推断表征张量数据  $\mathcal{Y}$  低秩性的参数  $\eta_k$  和  $\gamma_k$ . 整理表达式 (12) 和 (16) 并删除独

立于  $\eta_k$  的项, 可以得到

$$Q^\dagger(\{\eta_k\}_{k=1}^K) \propto \exp \left\{ \mathbb{E} \left[ -\text{Tr}(\mathbf{A}\mathbf{G}^H\mathbf{G}) - \sum_{k=1}^K \delta\eta_k + (N + \delta - 1) \sum_{k=1}^K \ln \eta_k \right] \right\}, \quad (21)$$

上式可以重新表述为  $Q^\dagger(\{\eta_k\}_{k=1}^K) = \prod_{k=1}^K Q^\dagger(\eta_k)$ , 并且满足以下条件:

$$Q^\dagger(\eta_k) \propto \exp \left\{ -\eta_k \underbrace{\mathbb{E} [\mathbf{G}(:, k)^H \mathbf{G}(:, k) + \delta]}_{a_{\eta_k}} + \underbrace{(N + \delta - 1)}_{b_\eta} \ln \eta_k \right\}. \quad (22)$$

通过观察式 (22), 可以知道最优的  $Q^\dagger(\eta_k)$  服从形式为  $\text{gamma}(\eta_k | a_{\eta_k}, b_\eta)$  的 gamma 分布. 对  $a_{\eta_k}$  求期望, 可以得到

$$a_{\eta_k} = \mathbf{M}_G(:, k)^H \mathbf{M}_G(:, k) + M \Sigma_G(k, k) + \delta. \quad (23)$$

接下来, 参数  $\eta_k$  的期望值可以由  $\mathbb{E}(\eta_k) = b_\eta / a_{\eta_k}$  给出, 其中  $b_\eta = N + \eta$ . 然后, 本小节继续推断模型参数  $Q(\gamma)$ . 用相似的方法, 最优  $Q^\dagger(\gamma_k)$  为形式是  $\text{gamma}(\gamma_k | a_{\gamma_k}, b_\gamma)$  的 gamma 分布, 且满足  $a_{\gamma_k} = \mathbb{E}[\sum_{i=1}^d \mathbf{X}^i(:, k)^H \mathbf{X}^i(:, k) + \delta]$  和  $b_\gamma = L \sum_{i=1}^d \tau_i + \delta$ . 此处,  $\mathbb{E}[\mathbf{X}^i(:, k)^H \mathbf{X}^i(:, k)] = \mathbf{M}(:, k)^i \mathbf{M}(:, k)^i + \tau_i \Sigma^i(k, k)$ . 然后我们可以通过  $\mathbb{E}(\gamma_k) = b_\gamma / a_{\gamma_k}$  计算超参数的期望值  $\gamma_k$ . 最后,  $\beta$  的后验分布通过以下等式更新:

$$Q^\dagger(\beta) \propto \underbrace{((\prod_{i=1}^{d+1} \tau_i M) L + \delta - 1) \ln \beta - \beta \mathbb{E} [\|\mathcal{Y} - [\mathbf{X}^1, \mathbf{X}^2, \dots, \mathbf{X}^d, \mathbf{G}]\|_F^2 + \delta]}_{a_\beta}. \quad (24)$$

通过比较式 (24) 与 gamma 分布的函数形式, 易得  $Q^\dagger(\beta) = \text{gamma}(\beta | a_\beta, b_\beta)$ . 最后, 本小节展开弗罗贝尼乌斯范数来计算式 (24) 中的  $a_\beta$ , 结果如下所示:

$$\begin{aligned} \mathbb{E} [\|\mathcal{Y} - [\mathbf{X}^1, \mathbf{X}^2, \dots, \mathbf{X}^d, \mathbf{G}]\|_F^2] &= \text{Tr} \left( \underset{i=1}{\overset{d}{\circlearrowleft}} (\mathbf{M}^{i,H} \mathbf{M}^{i,*} + \tau_i \Sigma^i)^H \times (\mathbf{M}_G^H \mathbf{M}_G + M \Sigma_G) \right. \\ &\quad \left. + \|\mathcal{Y}(d+1)\|_F^2 - \mathbf{M}_G \left( \underset{i=1}{\overset{d}{\circlearrowleft}} \mathbf{M}^i \right)^T \mathcal{Y}(d+1)^H - \mathcal{Y}(d+1) \left( \underset{i=1}{\overset{d}{\circlearrowleft}} \mathbf{M}^i \right)^* \mathbf{M}_G^H \right). \end{aligned} \quad (25)$$

式 (25) 的右侧是利用式 (19) 和 (25) 的结果而获得的.

**注释1** 在迭代过程中, 模型复杂性参数的平均值, 即  $\mathbb{E}(\eta_k)$  和  $\mathbb{E}(\gamma_k)$  分别由等式  $\mathbb{E}(\eta_k^{t+1}) = b_\eta / a_{\eta_k}^{t+1}$  和  $\mathbb{E}(\gamma_k^{t+1}) = b_\gamma / a_{\gamma_k}^{t+1}$  学习而得到. 由于  $\mathbb{E}(\eta_k^{-1})$  和  $\mathbb{E}(\gamma_k^{-1})$  的物理意义是表征了  $\mathbf{G}$  和  $\mathbf{X}^i$  每一列的能量, 那么如果某个  $\mathbb{E}(\eta_k)$  或者  $\mathbb{E}(\gamma_k)$  足够大, 则表示其对应的  $\mathbf{G}$  或者  $\mathbf{X}^i$  的列可以安全地被修剪除掉. 然后, 每个因子矩阵中剩余的非零列的数量便等于系统中激活设备的数量<sup>[31]</sup>.

### 3.4 物体感知

在恢复数据的过程中, 我们获得了包含物体信息的兴趣矩阵的估值, 即  $\hat{\mathbf{G}}(:, k) = \mathbf{A}_k \mathbf{z}$ . 本小节在此数据基础上, 首先为每个设备构造一个稀疏训练矢量  $\mathbf{x}_k \in \mathbb{C}^L$ . 然后, 我们可以得到如下训练集:

$$\mathbf{R} = \sum_{k=1}^{K_a} \hat{\mathbf{G}}(:, k) \mathbf{x}_k^H = \sum_{k=1}^{K_a} \mathbf{A}_k \mathbf{z} \mathbf{x}_k^H = \underbrace{[\mathbf{A}_1, \dots, \mathbf{A}_{K_a}]}_{\mathbf{A}} \underbrace{\begin{bmatrix} \mathbf{z} \mathbf{x}_1^H \\ \vdots \\ \mathbf{z} \mathbf{x}_{K_a}^H \end{bmatrix}}_{\mathbf{C}}. \quad (26)$$



这里  $L$  为字典学习训练集长度. 接下来, 通过协同解决以下优化问题来获得中间参量  $\mathbf{A} \in \mathbb{C}^{M \times K_a D}$  和  $\mathbf{C} \in \mathbb{C}^{K_a D \times L}$  的估值.

$$\underset{\mathbf{A}, \mathbf{C}}{\text{minimize}} \frac{1}{2} \sum_{l=1}^L \|\mathbf{R}(:, l) - \mathbf{A}\mathbf{C}(:, l)\|_2^2 + \lambda \sum_{l=1}^L \|\mathbf{C}(:, l)\|_1, \quad (27)$$

其中  $\lambda$  为惩罚参数, 问题 (27) 是字典学习问题, 字典学习旨在估计线性表示的学习数据, 即学习由跨度定义的线性子空间的一组矢量, 这些矢量构成了一个字典. 当稀疏信号恢复中的测量矩阵未知时, 测量矩阵可以看成是未知的字典. 解决这个问题的一种自然的方法是在两个变量之间交替, 最小化其中一个变量, 同时保持另一个变量不变<sup>[32]</sup>. 在获得  $\hat{\mathbf{A}}$  后, 本小节可以通过求解以下问题从  $\hat{\mathbf{G}}$  恢复出  $\mathbf{z}$ :

$$\underset{\mathbf{z}}{\text{minimize}} \frac{1}{2} \|\mathbf{G} - \bar{\mathbf{A}}\mathbf{z}\|_2^2 + \|\mathbf{z}\|_1, \quad (28)$$

其中  $\bar{\mathbf{A}} = [\hat{\mathbf{A}}_1^T, \dots, \hat{\mathbf{A}}_{K_a}^T]^T \in \mathbb{C}^{K_a M \times D}$ . 在过去的研究中, 已经提出了许多用于字典学习问题 (27) 和稀疏信号恢复问题 (28) 的算法<sup>[32~34]</sup>. 在这项工作中, 本文采用文献 [32] 中的方法来求解问题 (27), 用文献 [34] 中的方法来求解问题 (28).

### 3.5 算法总结

每个变分概率密度函数的计算依赖于其他变分概率密度函数, 因此, 变分概率密度函数的所有参数都需要交替更新. 为清楚起见, 本文提出的联合激活设备检测和感知 (joint device activity detection and sensing, JDAS) 算法的伪代码总结在算法 1 中. 通过算法 1, 我们可以得到  $\{\mathbf{M}^{i, t+1}\}_{k=1}^K$  和  $\mathbf{M}_{\mathbf{G}}^{t+1}$ , 对应于数据  $\mathbf{x}_{i, k}, \forall i, k$  的估计, 以及包含物体信息的  $\mathbf{A}_k \mathbf{z}, \forall k$ . 注意基于格拉斯曼码本的星座图设计可以解决张量分解中的模糊性问题<sup>[35]</sup>. 本文与工作 [36] 不同. 主要体现在以下三方面. 首先它们的系统模型和目的不同. 文献 [36] 的目的是通信, 而本文首次提出了面向大规模接入的通信感知一体化架构, 目的是同时完成感知和通信. 其次, 它们的数学模型不同. 文献 [36] 为耦合张量模型, 而且包含较少的未知变量; 而本文为非耦合张量模型, 而且环境信息引入了更多、更高维的未知变量. 最后, 它们的求解方法不同. 文献 [36] 利用基于变分贝叶斯的张量分解技术, 一步到位地直接求解所有未知变量. 由于数学模型的差异, 文献 [36] 的方法无法直接应用到本文中. 因此本文利用大规模接入的偶发通信的特性和环境信息的稀疏特性, 首先结合了不同于文献 [36] 的先验分布模型, 利用贝叶斯张量分解得到激活设备发送来的数据、激活设备数目、包含信道信息和环境信息的中间变量, 然后利用字典学习和稀疏信号处理技术, 将环境信息从中间变量中提取出来.

### 3.6 性能分析

本小节将分析 JDAS 算法的计算复杂度、收敛性, 和唯一性. 在每次迭代中, 计算复杂度包含两部分. 第一部分来自于激活设备检测, 其计算复杂度以更新每个因子矩阵为主, 主要来自矩阵乘法, 其量级为  $\mathcal{O}((\sum_{i=1}^d \tau_i + M)K^3 + d \prod_{i=1}^d M \tau_i K^2)$ . 另一部分来自于感知, 其计算复杂度的量级为  $\mathcal{O}(MK_a DL)$ . 因此所提出的 JDAS 算法的计算复杂度为  $\mathcal{O}((\sum_{i=1}^d \tau_i + M)K^3 + d \prod_{i=1}^d M \tau_i K^2 + MK_a DL)$ , 这里  $K$  为激活设备数目估值的初始值. 可以看出, 所提算法的复杂度主要取决于激活设备数量、数据的长度和字典学习的采样训练数目. 由于大规模随机接入中激活设备数目少、传输数据包小, 并且字典学习采样数目有限, 所提算法的计算复杂度在可控范围之内, 适用于实际应用.

接下来, 本文讨论所提算法的收敛特性. 观察 (13) 中的 KL 散度, 可以发现当  $\{Q(\Theta_j)\}_{i \neq j}$  固定时, 式 (13) 关于单个  $Q(\Theta_j)$  是凸的. 这保证了式 (13) 中的 KL 散度在迭代中的单调减小. 此外, 所提

**算法 1** 联合激活设备检测和感知 (joint device activity detection and sensing, JDAS) 算法**Require:**  $\mathcal{Y}$  和迭代次数  $T$ ;1: 初始化  $M_G^0, \{M^{i,0}\}_{i=1}^d, \Sigma_G^0, \{\Sigma^{i,0}\}_{i=1}^d, a_\beta^0, \{a_{\eta_k}^0, a_{\gamma_k}^0\}_{k=1}^K$ ;2: **for**  $t = 1 : T$  **do**3: 更新  $Q(G)^{t+1}$  的参数:

$$\Sigma_G^{t+1} = \left( \frac{a_\beta^t}{b_\beta} \underset{j=1}{\overset{d}{\odot}} \left( (M^{j,t})^H M^{j,t} + \tau_j \Sigma^{j,t} \right)^* + \text{diag} \left( \frac{b_\gamma}{a_{\gamma_1}^t}, \dots, \frac{b_\gamma}{a_{\gamma_K}^t} \right) \right)^{-1}, \quad (29)$$

$$M_G^{t+1} = \frac{a_\beta^t}{b_\beta} \mathcal{Y}(d+1) \left( \underset{j=1}{\overset{d}{\odot}} M^{i,t} \right)^* \Sigma_G^{t+1}; \quad (30)$$

4: 更新  $Q(X^i)^{t+1}$  的参数:

$$\Sigma^{i,t+1} = \left( \frac{a_\beta^t}{b_\beta} \underset{j=1, j \neq i}{\overset{d}{\odot}} \left( (M^{j,t})^H M^{j,t} + \tau_j \Sigma^{j,t} \right)^* \odot (M_G^{t,H} M_G^t + M \Sigma_G^t)^* + \text{diag} \left( \frac{b_\gamma}{a_{\gamma_1}^t}, \dots, \frac{b_\gamma}{a_{\gamma_K}^t} \right) \right)^{-1}, \quad (31)$$

$$M^{i,t+1} = \frac{a_\beta^t}{b_\beta} \mathcal{Y}(i) \left( \underset{j=1, j \neq i}{\overset{d}{\odot}} M^{i,t} \odot M_G^t \right)^* \Sigma^{i,t+1}; \quad (32)$$

5: 更新  $Q(\eta_k)^{t+1}$  的参数:

$$a_{\eta_k}^{t+1} = (M_G^t(:, k))^H M_G^t(:, k) + M \Sigma_G^{t+1}(k, k) + \delta; \quad (33)$$

6: 更新  $Q(\gamma_k)^{t+1}$  的参数:

$$a_{\gamma_k}^{t+1} = \sum_{i=1}^d (M^{i,t}(:, k))^H M^{i,t}(:, k) + \tau_i \Sigma^{i,t}(k, k) + \delta; \quad (34)$$

7: 更新  $Q(\beta)^{t+1}$  的参数:

$$a_\beta^{t+1} = \mathcal{L}^{t+1} + \delta, \quad (35)$$

其中  $\mathcal{L}^{t+1}$  是通过计算式 (25) 得到的;8: 设备检测: 输出  $\hat{X}^{i,t+1}$  和  $\hat{G}^{t+1}$ ;9: **end for**10: 通过求解问题 (27) 得到  $\hat{A}$  和  $\hat{C}$ ;11: 图像恢复: 通过求解问题 (28) 得到  $\hat{z}$ .

出算法的激活设备检测部分是块坐标下降优化策略的一个实例, 因此其能够在每次迭代中降低目标函数的值, 这可以保证检测算法收敛到式 (13) 中目标函数的平稳点. 而问题 (28) 中稀疏信号恢复收敛的必要条件是  $K_a M$  大于环境的稀疏度, 因为基站配备大规模天线阵列是未来 6G 无线通信的发展趋势, 而且感知的物体大小有限, 所以这个条件很容易得到保障.

最后我们考虑张量分解的唯一性. 唯一性是所提出的张量分解问题的一个关键问题. 根据张量分解分析可知 [28], 本文张量 (11) 分解的唯一性条件是  $\sum_{i=1}^{d+1} \varpi_i \leq 2K_a + d$ , 这里  $\varpi_i$  是每个因子矩阵的 Kruskal 秩. 在本文的问题中, 每个因子矩阵都是列满秩, 因此, 唯一性条件可以很容易地实现.

## 4 仿真结果

本节通过仿真验证前述理论分析结果的正确性. 参数设置如表 1 所示. 设备检测误差用误包率 (packet error rate, PER) 来衡量, 它的定义为  $\text{PER} = \frac{\bar{K}_a}{K_a}$ , 这里  $\bar{K}_a$  为错误解码的消息的数量. 本文用估计的物体信息和实际物体信息之间的均方误差 (mean square error, MSE) 来评估感知的准确性, 它的具体定义为  $\text{MSE} = \frac{1}{N_c} \|\hat{z} - z_0\|_2^2$ , 其中  $z_0$  为环境中真实的物体信息. 如图 2 所示, 本文用小方块表示点云在空间中的散射系数. 点云大小设置为  $8 \times 8 \times 8$ , 其中任意第  $j$  个散射系数的取值范围是

表 1 仿真参数设置

Table 1 Simulation parameters

| Parameter                        | Value      | Parameter                                | Value     |
|----------------------------------|------------|--|-----------|
| Total devices                    | $K = 1000$ | Number of bits transmitted by the device | $B = 360$ |
| Frequency of transmission signal | 30 GHz     | Bandwidth                                | 2 GHz     |
| Number of BS/device-object paths | 3          | Number of BS antennas                    | 256       |

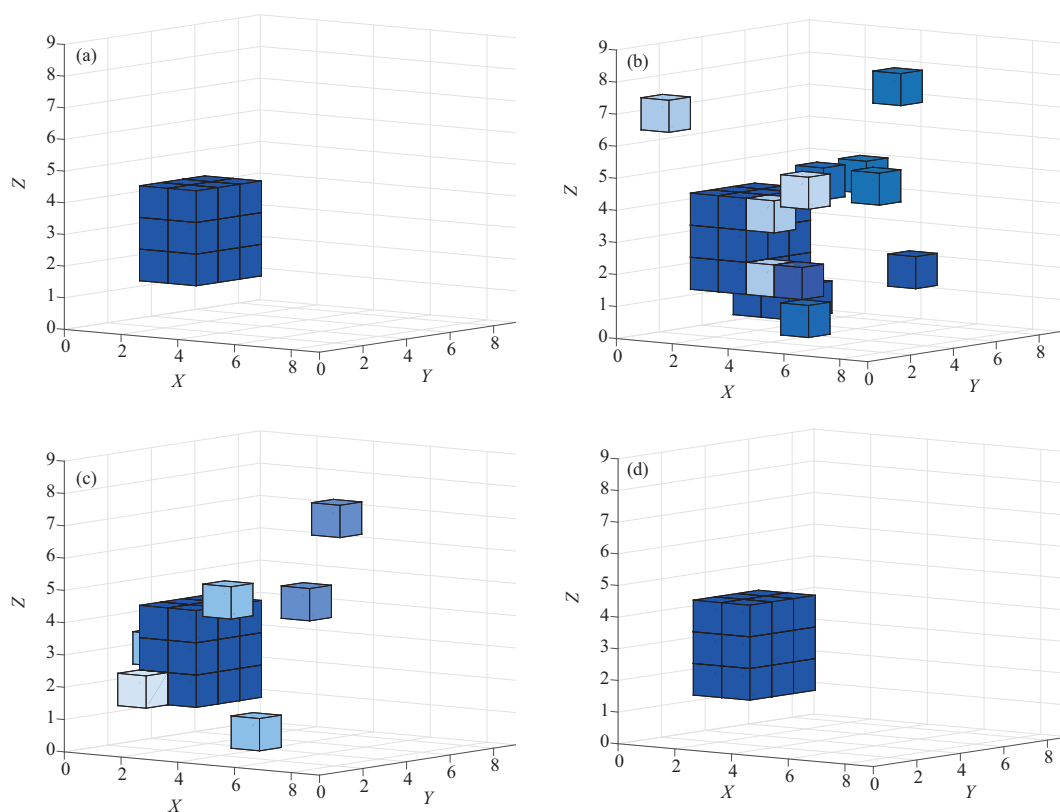


图 2 (网络版彩图) 原始环境散射体分布 (a) 和不同发射功率条件下的感知结果 ((b)~(d) 的发射功率分别为 0 dBm, 6 dBm 和 12 dBm)

Figure 2 (Color online) The original environment scatterer distribution (a) and the sensing results under different transmit power conditions (the transmit power of (b)~(d) are 0 dBm, 6 dBm, and 12 dBm, respectively)

$z_j \in [0, 1]$ . 本文假设整个成像区域的位置是已知的, 但是不知道散射体具体处于哪个位置. 信道信息按照文献 [26] 中的设置生成.

环境散射体的真实分布如图 2(a) 所示, 其中  $d = 2$ . 当算法收敛过后, 得到的感知结果如图 2(b)~(d) 所示. 图 2(b)~(d) 中的发射功率分别设置为 0 dBm, 6 dBm 和 12 dBm. 可以看出当发射功率为 0 dBm 时, 感知结果非常模糊, 目标物体的形状只能勉强区分. 当发射功率增高时, 被错误识别的散射体数目逐渐减少, 直到发射功率达到 12 dBm 时, 可以清楚地看出目标的形状. 这是因为低的发射功率会影响激活设备检测的准确性, 进而影响到了感知结果的准确性.

图 3 显示了秩估计的平均值随迭代次数的变化. 这里真实的秩, 即设备激活数目为 20, 其中  $d = 2$ . 可以看出, 只需要几次迭代就可以使所提出的算法收敛, 得到准确的秩估计值并且这些值保持平稳不

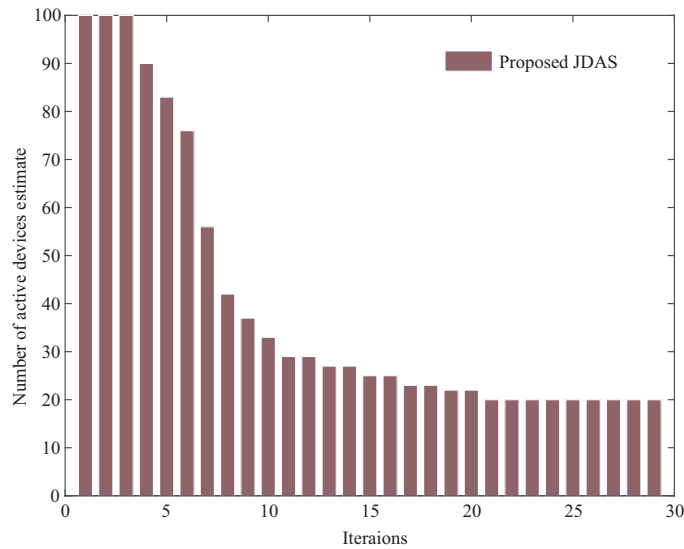


图 3 (网络版彩图) 张量秩估计值随迭代次数的变化

Figure 3 (Color online) The tensor rank estimate versus number of iterations

变. 这是因为收敛过后, 激活设备的正则化参数在下一迭代中会保持不变, 而其他设备所对应的正则化参数的值通过阈值处理会被剪除掉.

激活设备数量与 MSE 之间的权衡关系在图 4 中展示, 这里发射功率为 10 dBm. 可以看出, 当激活设备数量少时, 随着激活设备数量的增加, 感知精度显著提高. 当环境感知精度达到一定值之后, 激活设备数量的进一步增加导致数据恢复精度的降低, 因此环境感知的准确性也略有下降. 注意到  $d = 2$  的 JDAS 算法的 MSE 低于  $d = 4$  的情况. 这可以通过每个活动设备的自由度数, 即 DoF 来解释. 由于  $\tau_i$  维度的格拉斯曼码本中的变量具有  $\tau_i - 1$  自由度<sup>[35]</sup>, 因此所考虑模型中的激活设备的总自由度可以定义为  $\text{DoF}(K_a) = K_a \sum_{i=1}^d (\tau_i - 1)$ . 这样, 固定激活设备数目  $K_a$  后, 可以看到  $d = 4$  时的可用自由度低于  $d = 2$  时的情况, 这使得  $d = 2$  更适合面向大规模接入的通信感知一体化系统.

图 5 绘制了 PER 与物体大小的关系, 这里系统参数设置为  $d = 2$ , 发射功率为 10 dBm. 这里我们用非零点云占总点云的比例来表征物体的大小. 从图中可以看出, 随着物体的增大, 激活设备检测的准确率逐渐下降, 这是因为物体越大, 非零散射系数越多, 导致信号的路径损耗越加严重, 从而使得基站接收信噪比降低, 误包率也逐渐增加. 当物体尺寸超过一定范围后, 基站接收的信号过于微弱, 使得通信中断, 感知精度也会大大下降. 同时, 基站天线数目越大, 误包率越小, 这是因为天线数目越高, 张量的维度越大, 更容易满足张量分解唯一性的条件. 可见面向大规模接入通感一体化适用于感知物体大小在一定范围内、基站配备大规模天线阵列、少量激活设备激活的大规模机器通信场景.

## 5 结论

在未来多样化的无线通信应用场景中, 感知是其重要组成部分. 在面向大规模免授权随机接入系统中, 本文设计了联合激活设备检测和物体成像感知的框架. 进一步, 本文利用大规模随机接入的偶发通信的特性和环境信息的稀疏特性, 设计了联合激活设备检测和感知算法. 理论分析表明, 所提出的算法收敛速度快且计算复杂度较低. 值得注意的是大规模接入为物体成像感知提供了硬件网络设备和频谱资源, 大大节省了硬件和频谱开销. 因此, 本文提出的通信感知一体化架构与算法将为未来

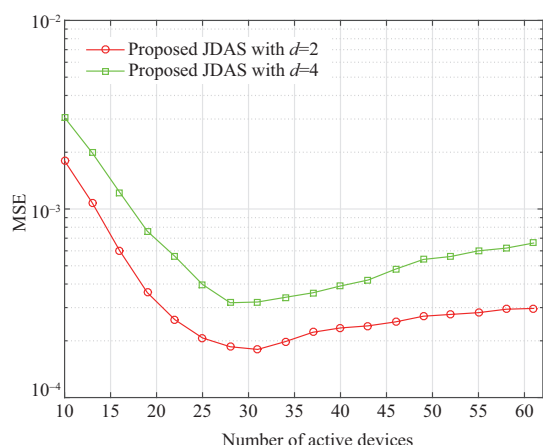


图 4 (网络版彩图) 激活设备数量与 MSE 之间的权衡关系

Figure 4 (Color online) The trade-off relationship between the number of active devices and MSE

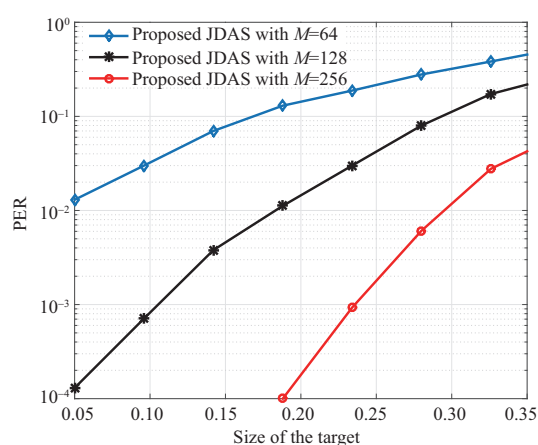


图 5 (网络版彩图) 物体大小与 PER 之间的权衡关系

Figure 5 (Color online) The trade-off relationship between the size of object and PER

新的无线通信技术提供有价值的参考。为尽可能减小系统所面临的无线信号传播过程中信号衰落的影响,下一步可针对提升接收信号信噪比的具体方案进行深入研究,比如,在基站端设计宽波束赋形技术、引入智能反射面调整无线环境等。

## 参考文献

- 1 Wang L S, McGeehan J P, Williams C, et al. Application of cooperative sensing in radar-communications coexistence. *IET Commun*, 2008, 2: 856–868
- 2 Saruthirathanaworakun R, Peha J M, Correia L M. Opportunistic sharing between rotating radar and cellular. *IEEE J Sel Areas Commun*, 2012, 30: 1900–1910
- 3 Tan B, Chen Q, Chetty K, et al. Exploiting WiFi channel state information for residential healthcare informatics. *IEEE Commun Mag*, 2018, 56: 130–137
- 4 Daniels R C, Yeh E R, Heath R W. Forward collision vehicular radar with IEEE 802.11: feasibility demonstration through measurements. *IEEE Trans Veh Technol*, 2017, 67: 1404–1416
- 5 Shao X D, You C S, Ma W Y, et al. Target sensing with intelligent reflecting surface: architecture and performance. *IEEE J Sel Areas Commun*, 2022, 40: 2070–2084
- 6 Watts C M, Lancaster P, Pedross-Engel A, et al. 2D and 3D millimeter-wave synthetic aperture radar imaging on a PR2 platform. In: *Proceedings of the International Conference on Intelligent Robots and Systems (IROS)*, 2016. 4304–4310
- 7 Appleby R, Anderton R N. Millimeter-wave and submillimeter-wave imaging for security and surveillance. *Proc IEEE*, 2007, 95: 1683–1690
- 8 Watts C M, Pedross-Engel A, Smith D R, et al. X-band SAR imaging with a liquid-crystal-based dynamic metasurface antenna. *J Opt Soc Am B*, 2017, 34: 300–306
- 9 IMT-2030 (6G) Promotion Group. White paper on 6G vision and candidate technologies. 2021. <https://www.free6gtraining.com/2021/07/chinas-imt-2030-6g-promotion-group.html>
- 10 Xiao H, Chen W, Fang J, et al. A grant-free method for massive machine communication with backward activity level estimation. *IEEE Trans Signal Process*, 2020, 68: 6665–6680
- 11 Shao X D, Chen X M, Zhong C J, et al. Exploiting simultaneous low-rank and sparsity in delay-angular domain for millimeter-wave/terahertz wideband massive access. *IEEE Trans Wireless Commun*, 2022, 21: 2336–2351

- 12 Yao J J, Zhang Z Y, Shao X D, et al. Concentrative intelligent reflecting surface aided computational imaging via fast block sparse Bayesian learning. In: Proceedings of the 93rd IEEE Vehicular Technology Conference (VTC2021-Spring), 2021. 1–6
- 13 Shao X D, Chen X M, Jia R D. A dimension reduction-based joint activity detection and channel estimation algorithm for massive access. *IEEE Trans Signal Process*, 2019, 68: 420–435
- 14 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. *IEEE Trans Signal Process*, 2020, 68: 764–779
- 15 Shao X D, Chen X M, Qiang Y Y, et al. Feature-aided adaptive-tuning deep learning for massive device detection. *IEEE J Sel Areas Commun*, 2021, 39: 1899–1914
- 16 Liu L, Yu W. Massive connectivity with massive MIMO-part I: device activity detection and channel estimation. *IEEE Trans Signal Process*, 2018, 66: 2933–2946
- 17 Qiang Y Y, Shao X D, Chen X M. A model-driven deep learning algorithm for joint activity detection and channel estimation. *IEEE Commun Lett*, 2020, 24: 2508–2512
- 18 Shao X D, Chen X M, Zhong C J, et al. A unified design of massive access for cellular Internet of Things. *IEEE Internet Things J*, 2019, 6: 3934–3947
- 19 Polyanskiy Y. A perspective on massive random-access. In: Proceedings of the IEEE International Symposium on Information Theory (ISIT), 2017. 2523–2527
- 20 Fengler A, Haghhighatshoar S, Jung P, et al. Non-Bayesian activity detection, large-scale fading coefficient estimation, and unsourced random access with a massive MIMO receiver. *IEEE Trans Inform Theor*, 2021, 67: 2925–2951
- 21 Fengler A, Caire G, Jung P, et al. Massive MIMO unsourced random access. 2019. ArXiv:1901.00828
- 22 Shao X D, Chen X M, Ng D W K, et al. Cooperative activity detection: sourced and unsourced massive random access paradigms. *IEEE Trans Signal Process*, 2020, 68: 6578–6593
- 23 Xie X Y, Wu Y P, Gao J Y, et al. Massive unsourced random access for massive MIMO correlated channels. In: Proceedings of IEEE Global Communications Conference, 2020. 1–6
- 24 Decurninge A, Land I, Guillaud M. Tensor-based modulation for unsourced massive random access. *IEEE Wireless Commun Lett*, 2020, 10: 552–556
- 25 Zhu L P, Zhang J, Xiao Z Y, et al. Millimeter-wave NOMA with user grouping, power allocation and hybrid beamforming. *IEEE Trans Wireless Commun*, 2019, 18: 5065–5079
- 26 Li X J, Fang J, Li H B, et al. Millimeter wave channel estimation via exploiting joint sparse and low-rank structures. *IEEE Trans Wireless Commun*, 2018, 17: 1123–1133
- 27 Zhao Q B, Zhang L Q, Cichocki A. Bayesian CP factorization of incomplete tensors with automatic rank determination. *IEEE Trans Pattern Anal Mach Intell*, 2015, 37: 1751–1763
- 28 Cheng L, Wu Y C, Poor H V. Probabilistic tensor canonical polyadic decomposition with orthogonal factors. *IEEE Trans Signal Process*, 2016, 65: 663–676
- 29 Wainwright M J, Jordan M I. Graphical models, exponential families, and variational inference. *FNT Machine Learn*, 2008, 1: 1–305
- 30 Kay S M. *Fundamentals of Statistical Signal Processing*. Upper Saddle River: Prentice Hall, 1993
- 31 Shao X, Cheng L, Chen X, et al. A Bayesian tensor approach to enable RIS for 6G massive unsourced random access. In: Proceedings of IEEE Global Communications Conference (GLOBECOM), 2021. 1–7
- 32 Lee H, Battle A, Raina R, et al. Efficient sparse coding algorithms. In: Proceedings of Advances in Neural Information Processing Systems, 2006. 19: 1–8
- 33 Spielman D A, Wang H, Wright J. Exact recovery of sparsely-used dictionaries. In: Proceedings of the 23rd International Joint Conference on Artificial Intelligence, 2013. 23: 3087–3090
- 34 Cai T T, Wang L. Orthogonal matching pursuit for sparse signal recovery with noise. *IEEE Trans Inform Theor*, 2011, 57: 4680–4688
- 35 Ngo K H, Decurninge A, Guillaud M, et al. Cube-split: a structured Grassmannian constellation for non-coherent SIMO communications. *IEEE Trans Wireless Commun*, 2019, 19: 1948–1964
- 36 Shao X D, Cheng L, Chen X M, et al. Reconfigurable intelligent surface-aided 6G massive access: coupled tensor modeling and sparse Bayesian learning. *IEEE Trans Wireless Commun*, 2022, 21: 10145–10161

# Integrated sensing and communication for massive access

Xiaodan SHAO<sup>1</sup>, Feng CHEN<sup>1\*</sup>, Tingzhi QIU<sup>1</sup>, Xiaoming CHEN<sup>2</sup> & Caijun ZHONG<sup>2</sup>

1. *College of Artificial Intelligence, Southwest University, Chongqing 400715, China;*

2. *College of Information Science and Electronic Engineering, Zhejiang University, Hangzhou 310027, China*

\* Corresponding author. E-mail: fengchenmit@swu.edu.cn

**Abstract** With the widespread application of the Internet-of-everything, the radio spectrum crunch has become a severe problem for wireless communications. To solve this problem, integrated sensing and communication (ISAC) has gradually become one of the key trends of sixth-generation (6G) wireless communication technology. ISAC requires the system to complete reliable multi-user communication and achieve accurate sensing, which is expected to significantly improve spectral efficiency. Moreover, massive random access with high reliability, low latency, and low cost is widely regarded as one of the key technologies of 6G wireless networks. Thus, this paper proposes an ISAC framework for massive random access, in which massive random access systems can utilize the same spectrum, hardware, and signal processing modules to provide object sensing services. In particular, active devices send unknown data to a base station (BS), and the data signal hits the object and results in signals bouncing off of objects before they arrive at the BS. This paper explores the characteristics of sporadic communication in massive access and sparsity in environmental information. Based on tensor modeling and decomposition, variational Bayesian inference, and dictionary learning techniques, an algorithm is proposed for object sensing and the detection of novel joint device activity. The accuracy and efficiency of the proposed active device detecting and imaging algorithm were verified by rigorous theoretical analysis and a large number of simulation results.

**Keywords** integrated sensing and communication, massive random access, tensor canonical polyadic decomposition, Bayesian learning, dictionary learning