

# 基于自适应压缩感知的大规模 MIMO-OFDM 系统信道估计方法

胡奕旻, 齐丽娜

(南京邮电大学通信与信息工程学院, 江苏 南京 210003)

**摘要:** 大规模多输入多输出 (MIMO, multiple-input multiple-output) 是物联网 (IoT, Internet of things) 中为多种机器类设备高效提供连接服务的解决方案, 而高效的连接服务需要准确的信道估计。针对大规模 MIMO 系统的下行信道估计中导频开销大和估计归一化均方误差 (NMSE, normalized mean square error) 性能较差的问题, 以压缩感知 (CS, compressed sensing) 理论为基础, 在结合信道空间域共同稀疏性的同时, 利用相邻时隙差分信道冲激响应 (CIR, channel impulse response) 的稀疏性更低的特点, 大大减少了导频发送的数量。在重构算法上, 提出了一种二阶段差分估计算法, 将一组连续相关时隙内的信道估计分为两个阶段, 并结合自适应压缩感知的思想以实现快速准确的 CIR 估计。仿真结果表明, 所提出的二阶段差分信道估计算法不仅在估计的 NMSE 性能、数据传输速率上相比已有的基于 CS 的多重测量向量 (MMV, multiple measurement vector) 算法有显著的提高, 而且在运行时间复杂度上也有一定的降低。

**关键词:** 物联网; 大规模多输入多输出; 压缩感知; 信道估计; 稀疏度自适应; 差分信道冲激响应

中图分类号: TN929.5

文献标识码: A

doi: 10.11959/j.issn.2096-3750.2021.00227

## Channel estimation method of massive MIMO-OFDM system based on adaptive compressed sensing

HU Yiyang, QI Lina

College of Telecommunications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

**Abstract:** Massive multiple-input multiple-output (MIMO) is a solution for efficiently providing connection services for a variety of machine equipment in the Internet of things (IoT), and efficient connection services require accurate channel estimation. Aimed at the problems of high pilot overhead and poor performance of normalized mean square error (NMSE) estimation in downlink channel estimation of massive MIMO systems, based on the compressed sensing (CS) theory, the common sparsity of the channel space domain was combined while using the feature of lower sparsity of adjacent time slot differential channel impulse response (CIR), which led to a significant reduction in pilot overhead. In the reconstruction algorithm, a two-stage differential estimation algorithm, which divided the channel estimation in consecutive time slots with time correlation into two stages, was proposed and the idea of adaptive compressed sensing was combined to achieve fast and accurate CIR estimate. The simulation results show that the proposed two-stage differential channel estimation algorithm not only has a significant improvement in the estimated NMSE performance and data transmission rate compared to the existing CS-based multiple measurement vector (MMV) algorithm, but also show a certain reduction in runtime complexity.

**Key words:** Internet of things, massive MIMO, compressed sensing, channel estimation, sparsity adaptive, differential CIR

### 1 引言

物联网 (IoT, Internet of things) 要实现 “任何

地方、任何时间、任何物体” 的互联, 无线通信技术是其中不可或缺的重要条件<sup>[1]</sup>。现如今, 5G 移动通信系统已经大规模商用, 无线通信技术的发展也

收稿日期: 2020-08-11; 修回日期: 2021-02-07

项目基金: 国家自然科学基金资助项目 (No.61471201)

Foundation Item: The National Natural Science Foundation of China (No.61471201)

为物联网的实现提供了坚实的基础。大规模多输入多输出 (MIMO, multiple-input multiple-output) 系统是下一代无线系统的关键技术<sup>[2]</sup>, 通过在基站上部署大量天线, 可以获得更高的通信容量和频谱效率。现如今随着终端通信设备的多样化, 人们对于信息传输的效率和质量也有了愈来愈高的需求。而信道估计则是各种终端能否准确恢复发射信号的基础。

为了充分利用大规模 MIMO 系统的空间自由度, 在波束成形和功率分配中, 发送端信道状态信息 (CSIT, channel state information at the transmitter) 的获取尤为重要。在时分双工 (TDD, time division duplexing) 系统中, 由于导频开销一般只与用户数量成比例, 所以上行链路的信道状态信息 (CSI, channel state information) 可以更容易地获得, 再利用信道的互易性<sup>[3]</sup>, 可以直接在下行链路中获得 CSI。但是, 这种方式不能应用在频分双工 (FDD, frequency division duplexing) 系统中。传统的 FDD 信道估计方式是在基站发送导频数据, 接收端用户利用最小二乘 (LS, least square) 法估计出下行链路的 CSI<sup>[4]</sup>, 但这种方式需要消耗大量的导频资源, 尤其当基站天线数庞大时<sup>[5]</sup>, 这种方式不太现实。

在最近的研究中, 信道稀疏性<sup>[6]</sup>成为了大规模 MIMO 系统中重要的特征, 基于压缩感知 (CS, compressed sensing) <sup>[7]</sup>的方法可以利用接收到的少量观测值恢复出 CIR, 这大大减少了导频开销。在常见的单收发系统中, 可以运用正交匹配追踪 (OMP, orthogonal matching pursuit) 算法<sup>[8]</sup>、子空间追踪 (SP, subspace pursuit) 算法<sup>[9]</sup>等估计 CSI, 估计性能相比于传统的 LS 算法有很大提升, 但是需要预知信道的稀疏度。稀疏度自适应匹配追踪<sup>[10]</sup> (SAMP, sparsity adaptive matching pursuit) 算法不需要预知信道稀疏度, 但会存在过估计的问题。

文献[11]提出了联合正交匹配追踪 (JOMP, joint orthogonal matching pursuit) 算法, 根据用户信道角度域的共同稀疏性, 先估计出所有用户信道矩阵的联合稀疏位置, 再分别估计矩阵中每一个用户的私有稀疏位置, 减小了估计误差, 但是由于采用的是 OMP 算法, 运算时间较长, 且需要预知信道的稀疏度。文献[12]在 JOMP 的基础上, 提出了结构化联合子空间追踪 (SJSMP, structured joint subspace matching pursuit) 算法, 在私有稀疏位置的估计阶段采用了 SP 算法, 相比于 OMP 算法, 加速了运算

速度, 但是提升了估计的均方误差, 同时还是需要信道稀疏度作为前提。

文献[13]运用了 MIMO 信道的时空联合稀疏性, 提出了自适应结构化子空间追踪 (ASSP, adaptive structured subspace pursuit) 算法, 通过将 CIR 矩阵重排, 运用时空联合稀疏性估计得到信道的 CIR, 提高了估计的准确性, 但估计速度较慢。文献[14]在 ASSP 的基础上, 利用时域训练序列获得大致的 MIMO 信道估计, 并将其作为 ASSP 算法的初始稀疏度, 以此降低算法的运行时间, 提高估计的归一化均方误差 (NMSE, normalized mean square error) 性能。

在文献[15]中, 提出了一种基于结构化 CS 的差分联合信道训练和反馈方案, 用户直接将接收到的导频反馈至基站, 在基站处使用 CS 算法估计 CSI, 同时利用两个连续 CIR 之间的时间相关性减少导频的数量; 除此之外, 提出了结构化—压缩采样匹配追踪 (S-CoSaMP, structured-compressed sampling matching pursuit) 算法来进行 CIR 的恢复。因为相邻 CIR 做差分之后稀疏度很低, 所以能够很大程度上减少发送的导频数量, 但是在开始时隙的 CSI 估计中, 假设稀疏度已知, 这在实际中很难实现, 并且在差分 CIR 的估计中, S-CoSaMP 算法会在原子预选时选出两倍稀疏度大小的块索引, 这在稀疏度很小时增大了误差。

在文献[16]中, 利用大规模 MIMO 系统子信道的联合稀疏性, 提出了块稀疏自适应匹配追踪 (BSAMP, block sparsity adaptive matching pursuit) 算法, 通过设置阈值及寻找最大后向差分位置对支撑集原子快速初步选择, 同时考虑了观测矩阵非正交性造成的能量弥散, 提高算法的估计性能; 通过正则化对原子进行二次筛选, 以提高算法的稳定性。

本文在文献[15-16]的基础上, 提出一种二阶段差分算法, 在相干时间内的第一个时隙中, 增大导频数量, 使用改进的 ASSP 算法自适应地得到该时隙下的 CSI, 通过在迭代开始时增大稀疏度变化步长, 加快估计速率, 并修改了 ASSP 算法的停止条件, 使之适用于单时隙块 CIR 的信道恢复。在信道相关时间内的后 2~3 个时隙, 采用结构化子空间追踪 (SSP, structured subspace pursuit) 算法<sup>[17]</sup>进行差分 CIR 的估计。与 S-CoSaMP 相比, SSP 算法可以在导频数少、稀疏度低的情况下控制原子初选的

数量、提高计算效率和估计性能。仿真结果表明，所提出的二阶段差分算法可以在未知稀疏度情况下提升信道估计的 NMSE 和数据传输速率，并且可以降低运算的复杂度。

## 2 系统模型

本文考虑一个正交频分复用 (OFDM, orthogonal frequency division multiplexing) 调制的大规模 FDD-MIMO 系统, 在基站处配置有  $M$  根天线, 在接收端具有  $U$  个用户, 每个用户配置单根天线。一个 OFDM 符号的子载波数为  $N$ , 天线传输导频符号为  $\mathbf{c}_i \in \mathbb{C}^{P \times 1}, i=1,2,\dots,M$ , 其中  $P$  是导频数, 基于结构化的思想<sup>[13]</sup>, 对于接收端的某个用户, 导频观测向量可以表示为

$$\mathbf{y}_\Omega = \sum_{i=1}^M \mathbf{C}_i(\mathbf{F}_L)_\Omega \mathbf{h}_i + \mathbf{n}_\Omega \quad (1)$$

其中,  $\mathbf{C}_i = \text{diag}\{\mathbf{c}_i\}$ ,  $\mathbf{F}_L \in \mathbb{C}^{N \times L}$  是  $N \times N$  傅里叶变换矩阵的前  $L$  列组成的子矩阵,  $L$  代表信道长度, 即  $L$  个信道抽头。  $(\mathbf{F}_L)_\Omega$  取  $\mathbf{F}_L$  中导频子载波对应的索引集合相应的行, 导频位置集合在子载波索引  $\{1,2,\dots,N\}$  中随机选取。  $\mathbf{h}_i = [h_i(1), h_i(2), \dots, h_i(L)]^T$  是 BS 处第  $i$  根天线到某个用户的 CIR。考虑到实际物理信道的传输特性<sup>[17]</sup>, 信道的稀疏大小  $K$  远小于信道长度  $L$ , 即信道中往往只具有少量的非零值。  $\mathbf{n}_\Omega = [n_1, n_2(2), \dots, n_p]^T$  代表独立同分布的高斯白噪声, 可以写成

$$\mathbf{y}_\Omega = \Phi \mathbf{h} + \mathbf{n}_\Omega \quad (2)$$

其中,

$$\Phi = [\Phi_1, \Phi_2, \dots, \Phi_M] = [\mathbf{C}_1(\mathbf{F}_L)_\Omega, \mathbf{C}_2(\mathbf{F}_L)_\Omega, \dots, \mathbf{C}_M(\mathbf{F}_L)_\Omega] \in \mathbb{C}^{P \times ML} \quad (3)$$

而  $\mathbf{h} = [h_1^T, h_2^T, \dots, h_M^T]^T \in \mathbb{C}^{ML \times 1}$  代表基站所有天线到单个用户的聚合 CIR。根据天线之间的空间公共稀疏性<sup>[13]</sup>, 将聚合 CIR 向量  $\mathbf{h}$  进行重新排列得到等效的聚合向量  $\mathbf{d}$ , 表示为

$$\mathbf{d} = [d_1^T, d_2^T, \dots, d_L^T]^T \in \mathbb{C}^{ML \times 1} \quad (4)$$

其中  $d_l = [h_1(l), h_2(l), \dots, h_M(l)]^T \in \mathbb{C}^{M \times 1}, l=1,2,\dots,L$ , 同样  $\Phi$  可以被重排为  $\Psi$ , 得到

$$\Psi = [\Psi_1, \Psi_2, \dots, \Psi_L] \in \mathbb{C}^{P \times ML} \quad (5)$$

其中,  $\Psi_l = [\Phi_1^{(l)}, \Phi_2^{(l)}, \dots, \Phi_M^{(l)}] \in \mathbb{C}^{P \times M}$ , 于是, (5)可

以被重写为

$$\tilde{\mathbf{y}}_\Omega = \Psi \mathbf{d} + \tilde{\mathbf{n}}_\Omega \quad (6)$$

由于 MIMO 信道的空间公共稀疏性, 等效 CIR 向量  $\mathbf{d}$  具有结构化稀疏性。图 1 展示了聚合 CIR 向量  $\mathbf{h}$  到等效 CIR 向量  $\mathbf{d}$  的重排过程。




图1 结构化 CIR 重排示意图

在实际的无线通信系统中, 当用户的移动速度不是很快时, 假设为  $v=64 \text{ km/h}$ , 系统载波频率为  $f_c=2 \text{ GHz}$ ,  $c$  为光速, 则系统的最大多普勒频移  $f_m=vf_c/c=119 \text{ Hz}$ , 根据系统相干时间和最大多普勒频移之间的关系, 即

$$T_c = \frac{1}{4f_m} \quad (7)$$

可得系统相干时间  $T_c \approx 2 \text{ ms}$ , 一般的单个时隙持续时间约为  $\tau = 0.5 \text{ ms}$ , 为方便建立模型, 假设一个时隙对应一个 OFDM 符号, 则在连续约  $T = 4$  个时隙内, 信道抽头位置变化较为缓慢, 有一至两个信道抽头位置发生改变, 即表现出时间相关性<sup>[15]</sup>。本文的 OFDM 符号时隙如图 2 所示。




图2 OFDM 符号时隙

假设一个快衰落的大规模 MIMO 信道, 其中 CIR 在时隙到时隙之间变化, 但保持在一个时隙中不改变。则信道 CIR  $\{\mathbf{d}^{(t)}\}_{t=1}^T$  在连续  $T$  个时隙中展现出时间相关性。根据文献<sup>[15,18]</sup>, 可以将动态变化的信道建模为

$$\mathbf{d}^{(t)} = \mathbf{q}^{(t)} \circ \mathbf{a}^{(t)} \quad (8)$$

其中,  $\mathbf{q}^{(t)}(l) \in \{0,1\}$ ,  $l$  表示 CIR 的第  $l$  个位置,  $\mathbf{a}^{(t)}(l) \in \mathbb{C}$ ,  $\circ$  是哈达玛积。根据文献<sup>[15]</sup>, 可以将  $\{\mathbf{q}^{(t)}(l)\}_{t=1}^T$  用一阶马尔可夫过程表示, 于是有传递概率  $p_{10} = \Pr\{\mathbf{q}^{(t+1)}(l)=1 | \mathbf{q}^{(t)}(l)=0\}$  和  $p_{01} = \Pr\{\mathbf{q}^{(t+1)}(l)=0 | \mathbf{q}^{(t)}(l)=1\}$ , 在相干时间持续的第一个时隙中有初

始分布概率  $\mu^{(0)} = \Pr\{q^{(0)}(l) = 1\}$ 。当马尔可夫过程处于平稳时，令  $\mu = \Pr\{q^{(t)}(l) = 1\}$ ，根据文献[19]，可以建立关于  $a^{(t)}(l)$  的一阶自回归模型，即

$$a^{(t)}(l) = \rho a^{(t-1)}(l) + \sqrt{1 - \rho^2} w^{(t)}(l) \quad (9)$$

其中， $\rho$  是相关系数，由零阶贝塞尔函数给出， $\rho = J_0(2\pi f_m \tau)$ ，其中的  $f_m$  是最大多普勒频移， $\tau$  是时隙的持续时间，而  $w^{(t)}(l)$  是一个复高斯随机变量，有  $w^{(t)}(l) \sim \mathcal{CN}(0, \sigma_w^2)$ 。将接收的观测向量在相邻时隙做差分，可得

$$\begin{aligned} \Delta d^{(t)} &= d^{(t)} - d^{(t-1)} = \\ & q^{(t)} \circ (a^{(t)} - a^{(t-1)}) + (q^{(t)} - q^{(t-1)}) \circ a^{(t-1)} = \\ & q^{(t)} \circ [\sqrt{1 - \rho^2} w - (1 - \rho)a^{(t-1)}] + (q^{(t)} - q^{(t-1)}) \circ a^{(t-1)} \end{aligned} \quad (10)$$

当用户的移动速度不是很快的时候，相关系数  $\rho$  取值接近 1<sup>[20]</sup>，于是，式(10)可以写为

$$\Delta d^{(t)} = (q^{(t)} - q^{(t-1)}) \circ a^{(t-1)} \quad (11)$$

因为  $q^{(t)}$  变化速度较慢<sup>[21]</sup>，所以信道非零路径延迟的变化较缓慢。差分 CIR 的示意图如图 3 所示，在一个相关时间内，信道的非零抽头变化缓慢，且幅值改变微乎其微。因此，在相邻时隙可以得到差分 CIR，其稀疏性更好，以便于使用更少的导频去恢复信道信息，再利用前一个时隙的估计值加上差分估计值作为本时隙下信道 CIR 的估计值。

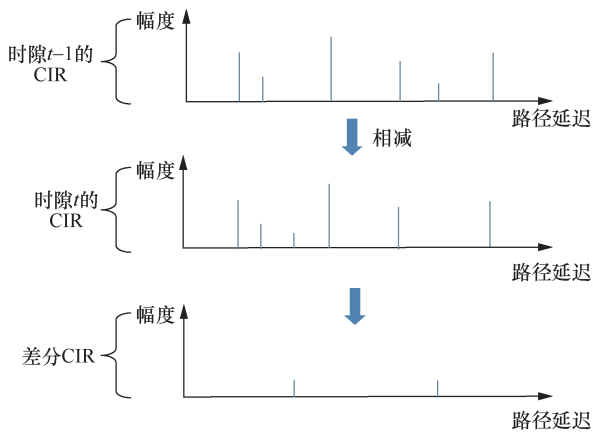


图3 相邻时隙差分 CIR 示意图

### 3 二阶段差分自适应估计算法思路

本文采用闭环反馈方案<sup>[15]</sup>，用户端接收到训练的导频符号之后，直接通过上行链路传回给基站，

在基站侧进行该时隙下的 CIR 估计得到 CSIT。这种方式可以避免接收端用户的计算复杂度，同时提高恢复性能。

由于 S-CoSaMP 算法需要预知信道的稀疏度，在实际中应用会存在限制，且估计的均方误差和运行时间可以继续改善。因此，本文提出二阶段差分估计算法，在初始时隙中使用改进的 ASSP 算法自适应地去估计 CIR。与 ASSP 算法不同，本文提出的改进 ASSP 算法只考虑在一个时隙中的块联合稀疏恢复。并且针对 ASSP 算法估计速度较慢的问题，在稀疏度更新阶段增设了一个判断条件，即当

$$\|r_F\|_2 > \varepsilon \|\hat{y}_\Omega^{(t)}\|_2 \quad (12)$$

此时增大稀疏度更新步长，令  $k = k + 2$ ，其中  $\varepsilon$  表示稀疏度更新大小阶段的一个阈值；否则， $k = k + 1$ ，这样可以使得残差距离观测向量较小时，增大稀疏度步长以快速接近真实稀疏度，加快了迭代的速度。另外在迭代停止条件上，设置为残差的能量小于噪声的能量<sup>[17]</sup>。为保证第一个时隙 CIR 估计的 NMSE 性能，减少误差累积，需适量增大第一个时隙发送的导频数量。因为差分 CIR 的稀疏度很低、迭代次数少，S-CoSaMP 算法在原子预选阶段时会选入两倍的信道稀疏度的块索引作为原子预选集，增大估计的误差，所以在差分 CIR 估计阶段使用 SSP 算法<sup>[17]</sup>，可以在稀疏度低、导频数较少时，防止引入过多错误的原子，提高估计的 NMSE 性能。

基于上述讨论，本文结合大规模 MIMO 信道的空时联合稀疏特点，提出了二阶段差分算法，在自适应估计信道的同时，可以改进 NMSE 估计性能和减少运算的时间复杂度。具体分为两个阶段，在阶段一，即相关时间内的初始时隙，采用改进的 ASSP 算法进行 CIR 估计，同时增加发送导频数量，以确保初始时隙的估计 NMSE 性能，减少后续误差的累积。在阶段二，即后续时隙的 CIR 恢复，采用差分的思想，并利用 SSP 算法进行信道估计，以在稀疏度很低时提升信道差分 CIR 的恢复准确度。

本文提出的二阶段差分算法具体过程如下。

**输入** 接收观测导频向量  $[\hat{y}_\Omega^{(1)}, \hat{y}_\Omega^{(2)}, \dots, \hat{y}_\Omega^{(T)}]$ ，测量矩阵  $[\Psi^{(1)}, \Psi^{(2)}, \dots, \Psi^{(T)}]$ 。

**输出** 在相关时间的连续  $T$  个时隙中，CIR 估计值  $\{d\}_{t=1}^T$ 。

阶段一:

**步骤 1** 初始化。迭代索引  $i=1$ , 稀疏度估计值  $k=1$ , 块支撑集  $\Omega_{\text{block}} = \emptyset$ , 初始残差  $\mathbf{r}^{(1)} = \tilde{\mathbf{y}}_{\Omega}^{(1)}$ 。

**步骤 2** 计算相关性。记  $\mathbf{c} = \Psi^H \tilde{\mathbf{y}}_{\Omega}^{(1)}$ 。

**步骤 3** 原子集初选。 $\mathbf{z}(l) = \sum_{m=1}^M \mathbf{c}((l-1) \cdot M + m)$ ,  $l=1, 2, \dots, L$ , 选择  $L$  个值中最大的  $k$  个, 即  $S_i = \max\left(\left[\mathbf{z}(l)\right]_{l=1}^L, k\right)$ , 为选中的初始块索引集合, 有  $C_i = \Omega_{\text{block}} \cup S_i$ 。

**步骤 4** 原子集裁剪。求得初始块原子集对应的最小二乘结果  $\mathbf{g} = (\Psi_{C_k}^H)^{\dagger} \tilde{\mathbf{y}}_{\Omega}^{(1)}$ ,  $\dagger$  代表广义逆。选取其中最大的  $k$  个值, 其对应的块索引集合记作  $F$ 。

**步骤 5** 最小二乘。 $\hat{\mathbf{d}}_F^{(1)} = (\Psi_F^H)^{\dagger} \tilde{\mathbf{y}}_{\Omega}^{(1)}$ 。

**步骤 6** 计算残差。 $\mathbf{r}_F = \tilde{\mathbf{y}}_{\Omega}^{(1)} - \Psi_F \hat{\mathbf{d}}_F^{(1)}$ 。

**步骤 7** 更新稀疏度判断。如果满足迭代停止条件, 则第一个时隙 CIR 估计完成, 进入阶段二; 否则当  $\|\mathbf{r}_F\|_2 \geq \|\mathbf{r}^{i-1}\|_2$  时, 更新稀疏度。此时如果  $\|\mathbf{r}_F\|_2 > \varepsilon \|\tilde{\mathbf{y}}_{\Omega}^{(1)}\|_2$ , 则  $k = k + 2$ , 否则,  $k = k + 1$ , 返回步骤 2; 当  $\|\mathbf{r}_F\|_2 < \|\mathbf{r}^{i-1}\|_2$ , 稀疏度不更新, 令  $\Omega_{\text{block}} = F$ ,  $\mathbf{r}^{(i)} = \mathbf{r}_F$ ,  $i = i + 1$ , 返回步骤 2。

阶段二:

**步骤 8** 利用时间相关性, 得到两个相邻时隙在 BS 处接收到的导频之差, 有

$$\begin{aligned} \Delta \tilde{\mathbf{y}}_{\Omega}^{(t)} &= \tilde{\mathbf{y}}_{\Omega}^{(t)} - \tilde{\mathbf{y}}_{\Omega}^{(t-1)} = \\ &\Psi \left( \mathbf{d}^{(t)} - \mathbf{d}^{(t-1)} \right) + \tilde{\mathbf{n}}_{\Omega}^{(t)} - \tilde{\mathbf{n}}_{\Omega}^{(t-1)} = \\ &\Psi \Delta \mathbf{d}^{(t)} + \Delta \tilde{\mathbf{n}}_{\Omega}^{(t)} \end{aligned} \quad (13)$$

**步骤 9** 利用 SSP 算法计算得到差分 CIR  $\Delta \mathbf{d}^{(t)}$ , 于是该时隙下 CIR 可以估计得到

$$\mathbf{d}^{(t)} = \mathbf{d}^{(t-1)} + \Delta \mathbf{d}^{(t)} \quad (14)$$

**步骤 10** 判断  $t > T$ , 若是, 则该连续相关时间下的各个时隙 CIR 估计完成, 退出; 否则, 返回步骤 8,  $t = t + 1$ , 开始计算下个时隙的差分 CIR。

根据文献[17], 可以将改进的 ASSP 算法的退出条件设置为残差的能量小于噪声的能量, 即

$$\|\mathbf{r}_F\|_2^2 < \|\tilde{\mathbf{y}}_{\Omega}^{(1)}\|_2^2 / (10^{\lambda/10} + 1) \quad (15)$$

其中,  $\lambda$  代表信噪比, 单位为 dB。

## 4 仿真结果

为了验证本文提出的算法方案的优越性, 加入 CoSaMP, 进行了如下仿真, 并将文献[22-23]提出的卡尔曼滤波算法估计方案、文献[11]提出的 JOMP 估计方案、文献[15]提出的 S-CoSaMP 和差分 S-CoSaMP 方案进行对比。本文仿真实验所采用的环境为 AMD Ryzen 7 3700U, 2.30 GHz, 8 GB RAM, MATLAB2019a。车载通信作为物联网大场景下的重要组成部分, 选择信道模型为 ITU 扩展车载模型。其中仿真参数设置如下, 系统载波频率为  $f_c=2$  GHz, 系统带宽为  $f_s=10$  MHz, 信道长度  $L=64$ , 一个相关时间内 4 个时隙, 即  $T=4$ , 一个 OFDM 符号的子载波数为  $N=512$ , 天线数为  $M=32$ 。设置相干时间持续的第一个时隙中有初始分布概率  $\mu^{(1)}=0.1$ , 信道稀疏度为  $K=\mu^{(1)}L=6$ ,  $\mathbf{q}^{(t)}(l) \rightarrow \mathbf{q}^{(t+1)}(l)$  的传递概率为  $p_{01}=0.16$ , 使得相邻时隙之间的抽头变化数为  $Kp_{01}=1$ , 即差分 CIR 稀疏度为 2, 初始时隙的信道各抽头幅值  $\mathbf{a}^{(1)} \sim \text{CN}(0,1)$ , 导频占比  $\eta = P/N$ , 其中  $P$  表示子载波用于导频传输的数量。对于改进的 ASSP 算法, 其中稀疏度更新阈值  $\varepsilon$  控制着算法的执行速度及均方误差性能, 当  $\varepsilon$  值设置过大时, 如  $\varepsilon > 0.5$ , 则前期迭代步长一直很大, 可能会导致选择某些错误的原子从而使均方误差上升, 而  $\varepsilon$  值设置过小, 会导致收敛速度变慢, 和原始 ASSP 算法收敛速度接近, 所以经过多次仿真验证, 为改进的 ASSP 算法设置稀疏度更新阈值  $\varepsilon=0.3$ 。

图 4 对比了本文算法与相关文献提出算法的 NMSE 性能, 其中, S-CoSaMP 利用了结构稀疏性, NMSE 性能优于文献[22-23]提及的卡尔曼滤波和文献[11]基于 JOMP 的信道估计方案。差分 S-CoSaMP 算法由于利用了差分 CIR 更低的稀疏性, NMSE 性能要优于 S-CoSaMP 算法。另外, 本文提出的二阶段差分估计算法的估计 NMSE 性能最好, 因为在初始时隙中, 改进的 ASSP 算法运行在 ASSP 算法的框架下, 所以在一定程度上保证了估计的准确性, 同时也不必预知信道稀疏度。并且在差分 CIR 估计阶段, 由于 S-CoSaMP 算法每次原子预选时选出两倍稀疏度大小的原子, 因此会引入较大的误差, 所以通过使用 SSP 算法可以减少原子预选所造成的误差, 在稀疏度很低时减小了估计的 NMSE。




图 4 稀疏度为 7 时不同估计方法的 NMSE 与 SNR 关系比较<sup>[11,15,22-23]</sup>

在图 5 中，比较了 3 种估计方法在导频占比为 40% 和 70% 下的数据速率，可以看到，传统的 CoSaMP 估计性能最差，因为没有用到 MIMO 信道的时空联合稀疏性。另外，文献[15]中提出的差分 S-CoSaMP 估计方案在导频占比 40% 时，数据速率要低于本文提出的二阶段差分算法，约为 0.6 bit/(s·Hz)，这是因为在导频数较低时，在差分 CIR 的估计阶段，SSP 算法由于原子预选只选择了稀疏度个数的原子，减少了错误原子入选的可能，增大了估计的 NMSE 性能。在导频占比为 70% 时，两种算法的数据速率基本相似，意味着在更低的导频下使用二阶段差分算法可以取得比差分 S-CoSaMP 算法更高的数据速率。

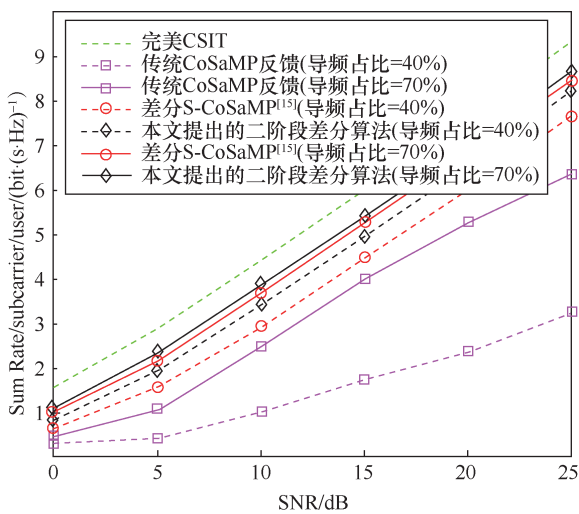


图 5 导频占比为 40% 和 70% 时不同估计方法下数据速率性能与 SNR 关系比较

图 6 显示了 S-CoSaMP、差分 S-CoSaMP 和本文提出的二阶段差分算法在不同稀疏度下的运行

时间对比，可以看到，运行时间 S-CoSaMP > 差分 S-CoSaMP > 二阶段差分估计算法。由于二阶段估计算法在开始时隙采用改进的 ASSP 算法去自适应估计 CIR，通过变速率增大稀疏度更新步长，所以加快了运行的速度。另外，在差分 CIR 估计阶段，SSP 算法只需迭代稀疏度大小的次数，相比 S-CoSaMP 减少了一半，再次加快了估计的速率。




图 6 SNR=10 dB，一个相关时间内不同估计方法的运行时间和稀疏度关系比较<sup>[15]</sup>

图 7 显示了在 SNR 为 10 dB 的条件下，稀疏度增大时，不同估计方法的 NMSE 变化，从图 7 中可以看出，随着稀疏度增大，S-CoSaMP 算法、差分 S-CoSaMP 以及二阶段差分算法的 NMSE 都在逐渐增大，其中，S-CoSaMP 算法没有利用系统时间相关特性，所以 NMSE 性能随着稀疏度变大而降低幅度变大。二阶段差分算法估计的 NMSE 性能在各个稀疏度下要优于差分 S-CoSaMP 算法，这是因为当稀疏度增大时，只是初始时隙需要估计的稀疏度变大，而差分 CIR 的稀疏度仍旧很低，SSP 算法能够展现出较 S-CoSaMP 算法的性能优势，同时改进的 ASSP 算法保证了初始时隙的估计 NMSE 性能，减少了误差的累积。

由系统模型分析可知，当用户移动速度改变时，会引起多普勒频移发生变化，从而会影响相关时隙间隔  $T$  的变化。图 8 显示了在 SNR 为 10 dB 的条件下，当相关时隙间隔  $T$  发生变化时，不同估计方法的 NMSE 变化情况。从图 8 中可以看出，随着相关时隙间隔增大，各算法的 NMSE 都呈现上升趋势。对于 S-CoSaMP 算法，其由于未利用到系统时间相关特性，所以 NMSE 性能最差，且随着时隙增

加, NMSE 增大较为平缓。差分 S-CoSaMP 算法和本文提出的二阶段差分算法都利用了时间相关性, 故 NMSE 性能较 S-CoSaMP 算法要好, 而本文提出的二阶段差分算法由于采用了自适应的估计思路和 SSP 算法减少了误差累积, 所以 NMSE 性能更好。另外, 随着相关时隙间隔变大, 差分运算的次数变多, 造成前一个时隙对于后一个时隙的先验误差累积也会变多, 所以差分 S-CoSaMP 算法和本文提出的二阶段差分算法的 NMSE 增大都较为快速。




图7 SNR=10 dB, 不同估计方法的 NMSE 与稀疏度关系比较图<sup>[15,22-23]</sup>




图8 SNR=10 dB, 不同估计方法的 NMSE 与相关时隙间隔 T 关系比较<sup>[15]</sup>

### 5 复杂度分析

根据文献[13]对于 ASSP 算法的平均单次迭代计算复杂度分析可知, 改进 ASSP 算法的平均单次迭代时间复杂度主要来自步骤 5 的 Moore-Penrose

矩阵求逆运算, 其时间复杂度为  $O(2P_1(Mk)^2 + (Mk)^3)$ , 其中  $P_1$  代表改进 ASSP 算法中发射的导频数量,  $M$  代表天线数量,  $k$  代表本次迭代的稀疏度估计值, 即选择原子数量大小。由于 S-SP 算法的大致流程与 ASSP 算法相似, 但是运行在已知稀疏度  $K$  下, 故有单次运行的时间复杂度  $O(2P_2(MK)^2 + (MK)^3)$ , 其中  $P_2$  是 S-SP 算法中的发射导频数量, 根据前文所述, 在阶段一中通过适当增加导频数量来尽可能保证初始时隙估计的准确性, 所以  $P_1$  略大于  $P_2$ 。考虑在连续相关时间的  $T$  个时隙中, 可以得到一次二阶段估计算法大致的平均单次运行时间复杂度为  $O(2P_1(Mk)^2 + (Mk)^3) + o(2P_2(T-1)(MK)^2 + (T-1)(MK)^3)$ 。文献[15]中差分 S-CoSaMP 算法由于单次迭代选择  $2K$  大小的原子, 其平均单次运行时间复杂度为  $O(2P_1(2MK)^2 + (2MK)^3) + O(2P_2(T-1)(2MK)^2 + (T-1)(2MK)^3)$ 。可见, 本文所提出的二阶段估计算法在运行时间复杂度上有一定的减小。

### 6 结束语

本文着眼于大规模 MIMO 系统的信道估计, 结合信道的空时相关性和结构化压缩感知, 在信道抽头位置变化不大的基础上, 将相邻时隙间的 CIR 做差分, 以得到稀疏度更低的信道向量, 从而大大减少发送的导频数量。在重构算法上, 提出了一种二阶段差分估计算法, 在相干时间的初始时隙中, 增大发送导频数量, 用改进的 ASSP 算法自适应地估计 CIR, 通过增设稀疏度更新条件, 加速了估计的速度; 在差分 CIR 估计阶段, 采用了 SSP 算法, 通过初选稀疏度大小的原子和回溯思想, 在差分 CIR 稀疏度很低时减少了误差。仿真结果表明, 所提出的二阶段差分估计算法在估计 NMSE 性能、数据传输速率以及算法的运行时间上优于相关的文献算法。另外车载通信作为物联网的一个重要课题, 本文的仿真针对车载场景的仿真结果也满足了在如今物联网大场景下信息传输的效率和质量。

### 参考文献:


[1] 余文科, 程媛, 李芳, 等. 物联网技术发展分析与建议[J]. 物联网学报, 2020, 4(4): 105-109.  
 YU W K, CHENG Y, LI F, et al. Analysis and suggestions on the development of IoT technology[J]. Chinese Journal on Internet of Things, 2020, 4(4): 105-109.  
 [2] CHOUDHURY P K, ABOU EL-NASR M. Massive MIMO toward

- 5G[J]. Journal of Electromagnetic Waves and Applications, 2020, 34(9): 1091-1094.
- [3] KULIKOV G V, TAMBOVSKII S S, SAVVATEEV Y I, et al. Algorithm for recovery of reciprocity of a wireless communications channel in MIMO systems[J]. Journal of Communications Technology and Electronics, 2019, 64(2): 133-139.
- [4] ALI A, MAGARINI M, PIRZADA N, et al. Direction of arrival and least square error technique used in massive MIMO for channel estimation[J]. International Journal of Mathematics and Computer Science, 2021, 16(2): 647-657.
- [5] 廖勇, 姚海梅, 花远肖. 一种基于深度学习的物联网信道状态信息获取算法[J]. 物联网学报, 2019, 3(1): 8-13.  
LIAO Y, YAO H M, HUA Y X. Channel state information acquisition algorithm based on deep learning for IoT[J]. Chinese Journal on Internet of Things, 2019, 3(1): 8-13.
- [6] AKBARPOUR-KASGARI A, ARDEBILIPOUR M. Massive MIMO-OFDM channel estimation via distributed compressed sensing[J]. IEEE Wireless Communications Letters, 2019, 8(2): 376-379.
- [7] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [8] 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.
- [9] JAYANTHI P N, RAVISHANKAR S. Model-based compressed sensing algorithms for MIMO-OFDM channel estimation[J]. International Journal of Engineering & Technology, 2018, 7(2): 5-9.
- [10] GE L J, ZHANG Y, CHEN G J, et al. Compression-based LMMSE channel estimation with adaptive sparsity for massive MIMO in 5G systems[J]. IEEE Systems Journal, 2019, 13(4): 3847-3857.
- [11] RAO X, LAU V K N. Distributed compressive CSIT estimation and feedback for FDD multi-user massive MIMO systems[J]. IEEE Transactions on Signal Processing, 2014, 62(12): 3261-3271.
- [12] ZHANG R Y, ZHAO H L, JIA S B, et al. Joint channel estimation algorithm based on structured compressed sensing for FDD multi-user massive MIMO[C]//Proceedings of IEEE 13th International Conference on Signal Processing (ICSP). Piscataway of IEEE, 2016: 1202-1207.
- [13] GAO Z, DAI L L, DAI W, et al. Structured compressive sensing based spatio-temporal joint channel estimation for FDD massive MIMO[J]. IEEE Transactions on Communications, 2016, 64(2): 601-617.
- [14] FAN Y J, LI H, SONG S S, et al. Structured compressed sensing-based time-frequency joint channel estimation for MIMO-OFDM systems[C]//Proceedings of 13th IEEE Conference on Industrial Electronics and Applications (ICIEA). Piscataway: IEEE Press, 2018: 2006-2010.
- [15] SHEN W Q, DAI L L, SHI Y, et al. Joint channel training and feedback for FDD massive MIMO systems[J]. IEEE Transactions on Vehicular Technology, 2016, 65(10): 8762-8767.
- [16] 戈立军, 郭徽, 李月, 等. 大规模 MIMO 系统稀疏度自适应信道估计算法[J]. 通信学报, 2017, 38(12): 57-62.  
GE L J, GUO H, LI Y, et al. Sparsity adaptive channel estimation algorithm based on compressive sensing for massive MIMO systems[J]. Journal on Communications, 2017, 38(12): 57-62.
- [17] GAO Z, DAI L L, WANG Z C. Structured compressive sensing based superimposed pilot design in downlink large-scale MIMO systems[J]. Electronics Letters, 2014, 50(12): 896-898.
- [18] ZHU X D, DAI L L, GUI G, et al. Structured matching pursuit for reconstruction of dynamic sparse channels[C]//Proceedings of IEEE Global Communications Conference: Wireless Communications. Piscataway: IEEE Press, 2015: 1-5.
- [19] BADDOUR K E, BEAULIEU N C. Autoregressive modeling for fading channel simulation[J]. IEEE Transactions on Wireless Communications, 2005, 4(4): 1650-1662.
- [20] KUO P H, KUNG H T, TING P G. Compressive sensing based channel feedback protocols for spatially-correlated massive antenna arrays[C]//Proceedings of IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2012: 492-497.
- [21] DAI L L, WANG J T, WANG Z C, et al. Spectrum- and energy-efficient OFDM based on simultaneous multi-channel reconstruction[J]. IEEE Transactions on Signal Processing, 2013, 61(23): 6047-6059.
- [22] NOH S, ZOLTOWSKI M D, SUNG Y, et al. Pilot beam pattern design for channel estimation in massive MIMO systems[J]. IEEE Journal of Selected Topics in Signal Processing, 2014, 8(5): 787-801.
- [23] CHOI J, LOVE D J, BIDIGARE P. Downlink training techniques for FDD massive MIMO systems: open-loop and closed-loop training with memory[J]. IEEE Journal of Selected Topics in Signal Processing, 2014, 8(5): 802-814.

## [作者简介]



胡奕旻 (1996- ), 男, 南京邮电大学通信与信息工程学院硕士生, 主要研究方向为移动通信、无线技术。



齐丽娜 (1979- ), 女, 南京邮电大学副教授、硕士生导师, 主要研究方向为无线通信与电磁兼容、移动通信与宽带无线技术等。