基于真实超大规模MIMO信道，通过导频分配和子阵选择提升频谱效率

Gabriel Avanzi Ubiali、Taufik Abrão、José Carlos Marinello

arXiv:2304.03873v1 [cs.IT] 8 Apr 2023

摘要

5G及后续通信的主要要求包括提供统一且高质量的服务质量，这可通过超大规模MIMO系统在拥挤场景中实现。另一项要求是在拥挤或极度拥挤的机器类通信（mMTC）中支持不断增加的连接用户数量。在此类场景中，导频分配（PA）对于减少导频污染并进而提高频谱效率（SE）至关重要。我们提出一种基于遗传算法（GA）的新型准最优、低复杂度迭代导频分配策略，适用于超大规模MIMO系统。该基于遗传算法的功率分配流程通过考虑种群中每个候选个体的信道估计归一化均方误差（NMSE），使服务质量更加均衡。仿真结果表明，所提出的迭代流程能够使用户设备的平均信道估计归一化均方误差最小化。第二种流程是子阵（SA）选择。在超大规模MIMO系统中，用户设备通常靠近某个子阵天线子集，因此只需由特定子阵为其提供服务，即可达到足够的数据速率。因此，我们研究了一种子阵选择流程，通过设定每个子阵可服务的用户设备最大数量，使系统具备可扩展性。由此，根据导频分配决策形成子阵集群。此外，我们为超大规模MIMO引入了一种适当的信道模型，该模型考虑了具有距离相关存在概率的确定性视距分量，以及与之结合的随机空间相关瑞利非视距衰落分量。所开展的仿真与分析基于这一适用的信道模型，并采用关于导频污染和相关信道的现实假设。

本研究部分获得巴西国家科学技术发展委员会（CNPq）资助，资助项目编号为310681/2019-7和163568/2021-9（奖学金）；另有部分经费来自巴西巴拉那州隆德里纳州立大学（UEL）。G. A. Ubiali和T. Abrão任职于巴西巴拉那州隆德里纳州立大学电气工程系，地址：Rod. Celso Garcia Cid - PR445, s/n, Campus Universitário, Po.Box10.011. CEP: 86057-970。电子邮箱：g.avanziubiali@gmail.com；taufik@uel.br。J. C. Marinello任职于巴西巴拉那州科内利乌普罗科皮奥联邦技术大学电气工程系。邮编：86300-000。电子邮箱：jcmarinello@utfpr.edu.br。

索引词

超大规模天线阵列、非平稳信道、信道模型、频谱效率、导频分配、子阵选择

I. 引言

实现无线网络高数据速率的主要赋能技术之一是大规模多输入多输出 (mMIMO)。AP 天线处大量的信道观测值提高了阵列增益，也增强了利用空间域在上行链路 (UL)中区分目标信号与干扰信号，以及在下行链路 (DL)中进行定向信号传输的能力。实际上，靠近某个 AP（即位于小区中心区域）的用户设备能够体验到较高的数据速率；然而，距离所有 AP 都相对较远的用户设备（即位于小区边缘区域）可能会因信噪比 (SNR)较低，以及小区间干扰而面临较差的服务质量 (QoS)。小区间干扰源于相邻小区用户设备对导频序列的复用，也源于 AP 无法消除其他小区用户设备造成的干扰，因为它只估计自身所服务用户设备的信道。

因此，尽管当前蜂窝网络能够实现较高的峰值数据速率，但由于小区内数据速率变化显著，服务质量可能不稳定。然而，支付、导航和娱乐都依赖无线连接，因此无线接入理应无处不在。对于未来的移动网络而言，在覆盖区域内提供更加均匀的高速率，比提高峰值速率更为重要。借助大规模天线阵列维度，即所谓的<风格 id='1'>超大规模</风格>MIMO（XL-MIMO）网络，可以实现更加均匀的高速率；此类网络能够覆盖体育场和购物中心等人口密集的大面积区域。XL-MIMO网络能够实现中等至较高的宏分集增益，并缩短用户设备到最近接入点天线的平均距离，从而使整个小区范围内的服务质量更加均匀。

超大规模MIMO天线阵列被划分为子阵列 (SA)配置。由于每个用户设备在物理上仅靠近一部分子阵列，因此让所有子阵列为所有用户设备提供服务的配置既不切实际，也没有必要。限制为每个用户设备提供服务的子阵列集合可能会对服务质量产生负面影响，但如果审慎地进行SA选择，系统仍能提供适当的频谱效率，同时降低计算复杂度，并减少子阵列与CPU之间需要传输的信令和控制数据量。此外，SA选择过程对于超大规模MIMO系统至关重要，以确保

可扩展性，即，确保随着用户设备数量不断增长，复杂度不会趋于无穷大。

掌握用户设备–服务天线信道响应对于相干处理至关重要。估计信道的最高效方法是采用时分双工方案，此时只需在上行链路中发送导频。根据用户设备的移动性，归一化相干块的大小可能小于用户设备的数量。在这种情况下，用户设备之间必须复用彼此正交的导频序列。大多数超大规模MIMO论文都假设信道估计完美 [1]–[6], ，这并不现实。在上行导频传输期间，估计误差有两个来源：背景噪声和来自共享导频的用户设备的信号。后者会导致所谓的相干干扰。本文在分析中考虑不完美的信道估计，以获得更符合实际的数值仿真结果。

超大规模MIMO信道可描述为确定性的视距（LoS）路径与随机非视距（NLoS）分量的组合。由于视距出现的概率较低，通常不会针对郊区和城市宏蜂窝场景分别建模视距分量；实际上，这种建模仅适用于城市微蜂窝场景 [7]。大规模多输入多输出研究论文通常只考虑非视距信道分量。另一方面，无蜂窝大规模多输入多输出论文通常只考虑视距或非视距分量。然而，由于城市地区的传播环境存在不确定性，无法准确判断是否存在视距链路 [8], ，因此需要采用概率视距模型。此外，视距分量对总信道功率的贡献相当显著 [9], ，因为它对应的传播距离更短，且信号衰减随距离增加的速度较慢。尤其是在超大规模多输入多输出系统中，用户设备与基站天线阵列之间的距离可能远小于超大规模阵列的长度，因此不应忽略视距概率。本文引入了一种现实的信道模型，其中包含一个确定性的视距分量，其存在概率取决于距离，以及一个空间相关的非视距分量。此外，还考虑了不同链路之间的阴影衰落相关性。

根据移动性，相干块的大小可能小于用户设备的数量。在这种情况下，必须在用户设备之间重复使用相互正交的导频，并可将导频恰当地分配给用户设备，以限制导频污染 [10]。最简单、最直接的方法是随机分配导频。然而，这种方法无法避免位置相近的用户设备被分配到同一导频，从而导致严重干扰并降低系统性能。与此相反，穷举搜索会尝试所有可能的分配方案

并从中选出最佳方案，但其计算复杂度会随着活跃用户设备数量的增加而呈组合式增长。因此，实践中只能采用次优方法。一种方法是每次针对一个用户设备优化效用函数，对每个用户设备处理一次，或迭代直至收敛 [10]。一些次优算法遵循一条黄金法则：位置相近的用户设备不应分配到相同的导频。

关于蜂窝大规模多输入多输出系统的研究通常认为，同一小区内的两个用户设备会被分配相互正交的导频序列。如果导频复用因子为 1，则相邻小区中共享导频的用户设备可能会降低小区边缘用户设备的性能。在这种情况下，只需贪心地分配最佳导频，即分配对小区边缘用户设备造成的导频污染最小的导频，就能合理缓解导频污染问题即 [11]。在 [12], 中，针对多小区大规模多输入多输出系统的导频分配问题，采用了一种深度强化学习 （DRL）方案。利用用户的距离和到达角（AoA）信息定义代价函数，以表示导频污染效应。DRL 算法通过跟踪环境变化、学习近乎最优的导频分配策略，找到有效的导频分配方案，其性能可与通过穷举搜索实现的最优（预知信息）功率分配相媲美。

然而，由于超大规模多输入多输出系统的典型应用中用户设备密度增加且导频资源稀缺，导频分配、网络接入和用户调度等关键任务变得颇具挑战性 [13]。在我们的研究中，我们考虑一种用户密集的超大规模MIMO场景：覆盖区域内的用户设备数量多于正交导频序列的数量，这代表了导频资源稀缺的情形。贪心算法会先将正交导频随机分配给部分用户设备，然后逐一为其余用户设备分配导频，以尽量减少导频污染。文献 [2], [13]–[15] 研究了超大规模MIMO中的随机接入和导频分配问题，假设信道为不相关瑞利衰落，且不进行子阵选择。具体而言，文献 [13], 提出了一种联合随机接入与调度协议，利用用户设备与超大规模MIMO链路中形成的不同可见区域（VR），并尝试将可见区域不重叠的用户设备安排在同一有效载荷数据导频资源上。与我们的工作不同，我们聚焦于导频分配问题，针对概率视距/非视距超大规模MIMO信道模型，基于启发式进化遗传算法（GA）方法开发了一种高效的功率分配算法（PA），并在分析中考虑采用子阵选择，使接收合并具有可扩展性。

本工作的贡献有三方面。

i) 我们提出了一种符合实际的超大规模MIMO空间相关信道模型，因为非相关信道只会在极其严格的物理要求下出现。由于超大规模MIMO天线并非集中部署，用户设备有时会非常靠近某些子阵，因此信道建模必须由若干非视距链路和一条视距链路组成，并为其出现设定距离相关概率。据我们所知，所有关于超大规模MIMO的研究都只考虑了这两种组成部分中的一种。

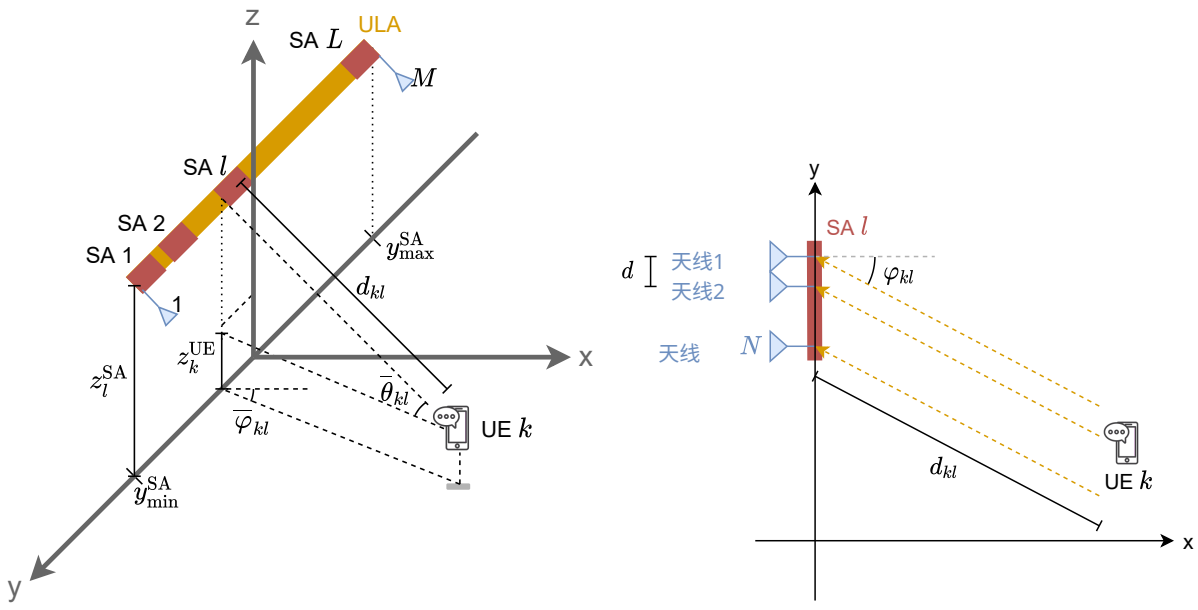
ii) 我们提出了一种适用于高密度超大规模MIMO系统的基于遗传算法的导频分配策略，通过尽可能接近最优导频分配方案来缓解导频污染；该方案旨在最小化所有活跃用户设备的信道估计值的平均归一化均方误差 （NMSE）。

iii) 我们提供了大量数值结果，证实了所提出的超大规模MIMO系统子阵列选择和导频分配方法的有效性与效率，并通过考虑视距和非视距信道分量，探究了高密度场景。本文的所有分析和结果均基于以下现实假设：信道估计不完美、采用可扩展的接收合并器，以及进行适当的子阵列选择；后者对于实现超大规模子阵列的可扩展性也至关重要。

本文其余部分安排如下。第二节介绍针对超大规模MIMO提出的信道模型。第三节讨论超大规模MIMO系统模型，介绍上行导频和数据传输的信号模型，以及所采用的信道估计器和接收合并器。第四节介绍超大规模MIMO中的导频分配策略及所采用的子阵列选择算法。最后，第五节给出支持本文研究发现的数值结果，第六节则给出总结与结论。

II. 超大规模MIMO信道模型

我们考虑一个包含 M 根天线的均匀线性阵列（ULA）超大规模MIMO（XL-MIMO）天线阵列，该阵列被划分为 L 个子阵列（SA），每个子阵列包含 N 根天线，且满足 $M = LN$，服务于 K 个用户设备（UE）。每个子阵列中的天线间距为 d。如果 N 较小，则每个子阵列都具有空间平稳性，即，其中的 N 根天线都将经历视距路径分量存在或不存在的相同情况。每个子阵列都连接到一个中央处理单元（CPU），负责子阵列列协作。第 l 个子阵列和第 k 个用户设备的高度分别表示为 z_l^{SA} 和 z_k^{UE}，而 d_{kl} 表示第 k 个用户设备到第 l 个子阵列的第一根天线的距离。图 1 展示了超大规模MIMO天线阵列（黄色条），并标出了给定用户设备 k 与给定子阵列 l之间视距路径对应的方位角和仰角，该路径以红色条表示。



（a）超大规模MIMO系统的三维视图　　（b）第 l 个子阵和第 k 个用户设备在平面 $z=0$ 上的投影

图1：超大规模MIMO的三维表示，展示了（a）均匀线性阵列，以及用户设备 k 与子阵 l 之间视距路径对应的方位角和仰角；（b）天线间距 d（位于子阵 l 内）以及用户设备 k 与子阵 l 之间的距离。

该　　具有视距和非视距分量的相关信道模型可表示为　　：

$$\mathbf{h}_{kl} = \alpha_{kl}\mathbf{h}_{kl}^{\mathrm{LoS}} + \mathbf{h}_{kl}^{\mathrm{NLoS}}, \tag{1}$$

其中$\mathbf{h}_{kl}^{\mathrm{LoS}}$，$\mathbf{h}_{kl}^{\mathrm{NLoS}}$，$\mathbf{h}_{kl} \in \mathbb{C}^N$分别表示用户设备与子阵之间的视距信道向量、非视距信道向量以及概率性视距/非视距信道向量，而 α_{kl} 是一个伯努利随机变量，用于指示第 k 个用户设备与第 l 个子阵之间是否存在视距分量（存在时为 $\alpha_{kl}=1$，不存在时为 $\alpha_{kl}=0$）。

第 k个用户设备与第 l 个子阵之间的视距信道向量表示为 [8]

$$\mathbf{h}_{kl}^{\mathrm{LoS}} = \sqrt{G_k G_l}\frac{z_k^{\mathrm{UE}} z_l^{\mathrm{SA}}}{4\pi d_{kl}}\sqrt{\mathcal{X}_{kl}^{\mathrm{LoS}}}e^{-j2\pi\frac{d_{kl}}{\lambda}}\mathbf{a}(\overline{\varphi}_{kl},\overline{\theta}_{kl}), \tag{2}$$

其中，G_k 和 G_l 分别表示第 k个用户设备和第 l个子阵的天线增益；$\lambda = c/f$为波长，即 c 光速、f 载波频率；$\mathcal{X}_{kl}^{\mathrm{LoS}}$为视距分量的阴影衰落；$\mathbf{a}(\varphi_{kl},\theta_{kl})$为对应视距射线的均匀线性阵列阵列响应向量。第 k个用户设备与第 l个子阵之间视距路径的方位角和仰角分别表示为φ_{kl} 和 θ_{kl}。阵列响应向量作为

用户设备 k 与子阵 l之间视距方位角和仰角的函数（分别为 φ_{kl}和 θ_{kl}），可表示为 $\overline{\quad}$
$\overline{\quad}$

$$\mathbf{a}(\overline{\varphi}_{kl},\overline{\theta}_{kl})=\left[1,e^{-j2\pi\frac{d}{\lambda}\frac{\sin(\overline{\varphi}_{kl})}{\cos(\overline{\theta}_{kl})}},\ldots,e^{-j2(N-1)\pi\frac{d}{\lambda}\frac{\sin(\overline{\varphi}_{kl})}{\cos(\overline{\theta}_{kl})}}\right]^{\mathrm{T}},\tag{3}$$

其中， d 是第 l个子阵内的天线间距，见图1b。实际上，式（3）中的阵列响应向量 $\mathbf{a}(\cdot,\ \cdot)$计入了到达同一均匀线性子阵（ULSA）中不同天线的信号之间的相位差。当方位角不为零时，也就是波前不与均匀线性阵列（ULA）平行时，就会出现这些变化。

近场与远场。关于超大规模MIMO阵列，一个重要观察是，波前传播可能呈球面，这是因为部分用户相对于整个超大规模MIMO阵列可能处于近场距离范围内，也就是 $d_{kl}\ll d_{\mathrm{Rayl}}$，其中 d_{Rayl} 为瑞利距离 [16]。此外，这种情况下，不同子阵的传播距离也会不同。另一方面，由于子阵孔径相较于用户设备与子阵之间的传播距离较小，因此可以认为，从各子阵的角度来看，所有用户都处于远场传播范围内，波前相对于子阵可视为平面波。这意味着，同一子阵中两根天线之间的传播距离差异可以忽略不计，因此同一子阵内所有天线单元对应的大尺度衰落（LSF）系数几乎相同。然而，即使是这种可忽略的距离差异，也足以造成这些天线之间的相位差。式（3）中的阵列响应向量计入了这些相位差。

每个超大规模MIMO ULSA 中视距分量的大尺度衰落信道增益由归一化迹确定

$$\beta_{kl}^{\mathrm{LoS}}=\frac{1}{N}||\mathbf{h}_{kl}^{\mathrm{LoS}}||^2=\underbrace{\frac{G_kG_l(z_k^{\mathrm{UE}}z_l^{\mathrm{SA}})^2}{(4\pi)^2}}_{\beta_0}\frac{\mathcal{X}_{kl}^{\mathrm{LoS}}}{d_{kl}^2}=\frac{\beta_0}{d_{kl}^2}\mathcal{X}_{kl}^{\mathrm{LoS}},\tag{4}$$

其中， β_0 是参考距离为 1 m 时的平均信道增益， β_0/d_{kl}^2 是视距分量的路径损耗。将（4）代入（2）可得

$$\mathbf{h}_{kl}^{\mathrm{LoS}}=\sqrt{\beta_{kl}^{\mathrm{LoS}}}e^{-j2\pi\frac{d_{kl}}{\lambda}}\mathbf{a}(\overline{\varphi}_{kl},\overline{\theta}_{kl}).\tag{5}$$

另一方面，非视距分量描述了实际的空间相关多径环境。非视距信道向量可表示为 B条物理信号路径的叠加，每条路径均以平面波形式从特定的方位角和仰角 $\varphi_{kl}^{(b)}$ 及 $\theta_{kl}^{(b)}$ [17]到达 ULSA：

$$\mathbf{h}_{kl}^{\mathrm{NLoS}}=\sum_{b=1}^{B}g_{kl}^{(b)}\mathbf{a}(\varphi_{kl}^{(b)},\theta_{kl}^{(b)}),\tag{6}$$

其中， $g_{kl}^{(b)}$ 是一个均值为零、方差为 $\mathbb{E}\{|g_{kl}^{(b)}|^2\}$的独立同分布复随机变量，用于表示第 b条物理非视距路径的增益和相位旋转； $\varphi_{kl}^{(b)}$ 和 $\theta_{kl}^{(b)}$ 分别是 UE k 与 SA l之间第 b条非视距路径形成的 SA 方位角和仰角。

非视距大尺度衰落系数可计算为

$$\beta_{kl}^{\text{NLoS}} = \frac{1}{N}\mathbb{E}\{||\mathbf{h}_{kl}^{\text{NLoS}}||^2\} = \sum_{b=1}^{B}\mathbb{E}\{|g_{kl}^{(b)}|^2\}, \tag{7}$$

并表示为

$$\beta_{kl}^{\text{NLoS}} = \frac{\beta_0}{d_{kl}^{\gamma}}\mathcal{X}_{kl}^{\text{NLoS}}, \tag{8}$$

其中， γ 是非视距分量的路径损耗指数， $\mathcal{X}_{kl}^{\text{NLoS}}$是非视距分量的阴影衰落。根据大数定律， B 条随机非视距路径之和趋近于正态分布 [17]:

$$\mathbf{h}_{kl}^{\text{NLoS}} \sim \mathcal{N}_{\mathbb{C}}(\mathbf{0}, \mathbf{R}_{kl}), \tag{9}$$

其 由以下元素构成的半正定空间相关矩阵$\mathbf{R}_{kl}$:

$$[\mathbf{R}_{kl}]_{m,n} = \beta_{kl}^{\text{NLoS}} \int\int e^{j2(m-n)\pi\frac{d}{\lambda}\frac{\sin(\varphi)}{\cos(\theta)}} f_{kl}(\varphi,\theta)d\varphi d\theta, \tag{10}$$

其中， $f_{kl}(\varphi,\ \theta)$是 φ 和 θ的联合概率密度函数（jPDF），它取决于视距链路的方位角和仰角（φ_{kl} 和 θ_{kl}）以及角度标准差（$\sigma_\varphi \geq 0$ 和 $\sigma_\theta \geq 0$）。 φ 和 θ 的积分区间分别为 $[-180°, 180°]$ 和$(-90°,\ 90°)$。与 [10], 中一样，我们也考虑联合高斯分布:

$$f_{kl}(\varphi,\theta) = \frac{1}{2\pi\sigma_\varphi\sigma_\theta}\exp\left\{-\frac{(\varphi-\overline{\varphi}_{kl})^2}{2\sigma_\varphi^2} - \frac{(\theta-\overline{\theta}_{kl})^2}{2\sigma_\theta^2}\right\}. \tag{11}$$

式(9)和(10)的证明见附录A。从(10)可知，$\text{tr}(\mathbf{R}_{kl}) = N\beta_{kl}^{\text{NLoS}}$，这与式(7)中的定义一致。

分离大尺度衰落和小尺度衰落后，非视距信道向量可表示为

$$\mathbf{h}_{kl}^{\text{NLoS}} = \sqrt{\beta_{kl}^{\text{NLoS}}}\cdot\ddot{\mathbf{h}}_{kl}, \tag{12}$$

其中，$\ddot{\mathbf{h}}_{kl}$ 表示遵循复正态分布的空间相关小尺度瑞利衰落 [10], [17], [18]。注意，式（10）中的二重积分计算了$\mathbb{E}\left\{e^{j2(m-n)\pi\frac{d}{\lambda}\sin(\varphi)\cos(\theta)}\right\}$关于根据式（11）中的联合概率密度函数分布的随机定位多径分量的结果。

在实际的超大规模MIMO面板场景中，由于不同**子阵列**的**天线**间距离足够远，我们假设其他**子阵列**的信道向量彼此独立分布，即对于 $l \neq j$，有 $\mathbb{E}\{\ddot{\mathbf{h}}_{kl}\ddot{\mathbf{h}}_{kj}^{\mathrm{H}}\} = \mathbf{0}_{N\times N}$，其中（.）$^{\mathrm{H}}$ 表示厄米特算子。

与 F_{kl} 和 F_{ij} （阴影）之间的相关性。阴影衰落可以建模为对数正态随机变量，在 dB 标度下表示为 $F_{kl} = 10\log_{10}(\mathcal{X}_{kl})$，其分布为 [19]

$$F_{kl} \sim \mathcal{N}\left[0, \sigma_{\mathrm{SF}}^2(1-e^{-d_{kl}/\delta})^2\right]. \tag{13}$$

注意，式（13）中的随机变量 F_{kl} 的方差随距离增加，并在 $d_{kl} >> \delta$时收敛于 σ_{SF}^2，其中 δ 表示去相关距离。阴影衰落通常被建模为相互独立的链路，然而在实际情况中，邻近链路会呈现空间相关的阴影衰落，因为信号会受到传播环境中几乎相同的一组物体的影响。忽略此类相关性会导致高估超大规模多输入多输出系统中的分集增益，并可能造成网络性能的显著差异 [19]。F_{kl} 与 F_{ij} 之间的互相关为：

$$\mathbb{E}\{F_{kl}F_{ij}\} = \frac{\sigma_{\mathrm{SF}}^2}{2}\frac{(1-e^{-d_{kl}/\delta})(1-e^{-d_{ij}/\delta})}{\sqrt{(1+e^{-d_{kl}/\delta})(1+e^{-d_{ij}/\delta})}}(e^{-d_{kj}/\delta}+e^{-d_{il}/\delta}+e^{-D_{ki}^{\mathrm{UE}}/\delta}+e^{-D_{lj}^{\mathrm{SA}}/\delta}). \tag{14}$$

其中，d_{kl} 表示第 k个用户设备与第 l个子阵之间的距离，D_{ki}^{UE}表示用户设备 k 与用户设备 i之间的距离，D_{lj}^{SA}表示子阵 l 与子阵 j [19]之间的距离，[20]。注意，第 k 个用户设备距离第 i个用户设备越近，它们的阴影衰落 F_{kl} 和 F_{ij}之间的相关性就越强。同样，第 l个子阵距离第 j个子阵越近，F_{kl} 与 F_{ij} 之间的相关性就越强。

最后，根据 (1) 和 (9)，信道向量服从均值为 复正态分布 $\mathbf{h}_{kl} = \alpha_{kl}\mathbf{h}_{kl}^{\mathrm{LoS}}$ 、协方差矩阵为 协方差矩阵

$$\begin{aligned}
\mathbb{C}\mathrm{ov}(\mathbf{h}_{kl}) &= \mathbb{E}\{\mathbf{h}_{kl}\mathbf{h}_{kl}^{\mathrm{H}}\} - \bar{\mathbf{h}}_{kl}\bar{\mathbf{h}}_{kl}^{\mathrm{H}} \\
&= \mathbb{E}\{(\bar{\mathbf{h}}_{kl}+\mathbf{h}_{kl}^{\mathrm{NLoS}})(\bar{\mathbf{h}}_{kl}+\mathbf{h}_{kl}^{\mathrm{NLoS}})^{\mathrm{H}}\} - \bar{\mathbf{h}}_{kl}\bar{\mathbf{h}}_{kl}^{\mathrm{H}} \\
&= \mathbb{E}\{\mathbf{h}_{kl}^{\mathrm{NLoS}}(\mathbf{h}_{kl}^{\mathrm{NLoS}})^{\mathrm{H}}\} \\
&= \mathbf{R}_{kl},
\end{aligned} \tag{15}$$

使得

$$\mathbf{h}_{kl} \sim \mathcal{N}_{\mathbb{C}}(\bar{\mathbf{h}}_{kl}, \mathbf{R}_{kl}). \tag{16}$$

注意，由于$\mathbf{h}_{kl}^{\mathrm{NLoS}}$ 是零均值向量，因此其相关矩阵也是$\mathbf{R}_{kl}$。事实上，如式（15）所示，$\mathbf{h}_{kl}$ 的协方差矩阵也是$\mathbf{R}_{kl}$；然而，由于它是非零均值向量，其相关矩阵为$\mathbf{R}_{kl}+\mathbf{h}_{kl}\mathbf{h}_{kl}^{\mathrm{H}}$。

$\mathbf{h}_{kl}$和$\mathbf{R}_{kl}$均描述宏观传播效应，即即路径损耗和阴影衰落，而式（16）中的分布则描述小尺度衰落。如果用户设备 k 与子阵 l之间存在视距路径，则称子阵 l 位于用户设备k的可见区域（VR）内。否则，由于信号仅通过非视距路径传播，接收功率会弱得多，此时称子阵 l 不在用户设备 k的可见区域内。

最后，概率性的视距/非视距大尺度衰落信道增益定义为

$$\beta_{kl} = \frac{1}{N}\mathbb{E}\{||\mathbf{h}_{kl}||^2\}, \tag{17}$$

并将 (1) 代入 (17)，同时回顾 $||\mathbf{h}_{kl}^{\text{LoS}}||^2 = N\beta_{kl}^{\text{LoS}}$和 $\mathbb{E}\{||\mathbf{h}_{kl}^{\text{NLoS}}||^2\} = \text{tr}(\mathbf{R}_{kl}) = N\beta_{kl}^{\text{NLoS}}$，得到

$$\beta_{kl} = \alpha_{kl}\beta_{kl}^{\text{LoS}} + \beta_{kl}^{\text{NLoS}}. \tag{18}$$

在以下各节中，我们将介绍超大规模MIMO系统模型以及功率分配和子阵选择的流程。图2展示了这些流程所涉及操作的概览：首先，根据信道统计（信道均值和协方差矩阵）为 K 用户设备分配导频。其次，同样根据信道统计执行子阵选择。第三，在每个相干块中，根据导频决策以及上行导频传输期间接收的信号估计瞬时信道。第四，根据信道统计、导频决策（这是获得信道估计协方差矩阵所必需的）以及信道估计值计算合并向量。第五，根据合并向量以及上行数据传输期间均匀线性阵列接收的信号，估计用户设备发送的信号。最后，在评估系统性能时，我们可以根据公式 (35)，结合信道估计值、信道统计、导频决策、SA 集群和合并向量计算信干噪比。

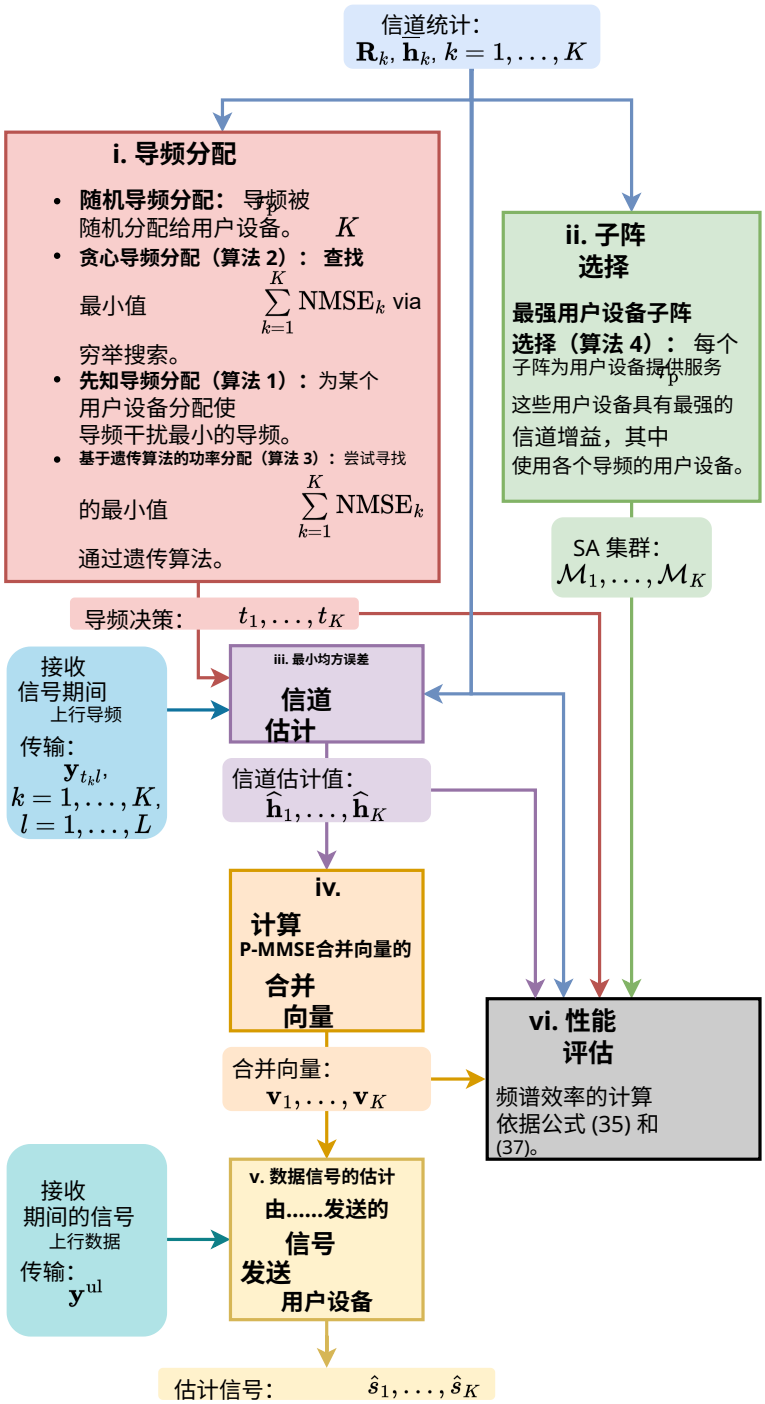


图 2：系统运行阶段：*i*) 导频分配（比较了四种方法）；*ii*) 子阵选择；*iii*) 信道估计；*iv*) 合并向量的计算；*v*) 信号估计；*vi*) SE 计算。

III. 超大规模MIMO系统模型

A. 上行导频传输

导频是τ_{p}维向量，我们最多只能找到τ_{p} 个彼此正交的序列。包含τ_{p} 个正交导频序列的集合 $\boldsymbol{\phi}_1, \ldots, \boldsymbol{\phi}_{\tau_{\mathrm{p}}} \in \mathbb{C}^{\tau_{\mathrm{p}}}$定义如下：

$$\boldsymbol{\phi}_i^{\mathrm{H}} \boldsymbol{\phi}_j = \begin{cases} \tau_{\mathrm{p}}, & \text{if } i = j, \\ 0, & \text{if } i \neq j. \end{cases} \tag{19}$$

每个相干块都需要进行一次信道估计。因此，每个相干块中必须预留τ_{p} 个样本用于上行导频信令，但相干块的有限长度带来了约束 $\tau_{\mathrm{p}} \leq \tau_{\mathrm{c}}$，其中 τ_{c} 是一个相干块中可传输的符号（样本）数。通常， $K \gg \tau_{\mathrm{c}}$ 使得无法为所有用户设备分配彼此正交的导频。因此，两个或更多用户设备可能会被分配相同的导频。我们将分配给用户设备 k 的导频索引记为 $t_k \in \{1, \ldots, \tau_{\mathrm{p}}\}$，并将使用与用户设备 k相同导频（包括其自身）的用户设备集合定义为：

$$\mathcal{P}_k = \{i : t_i = t_k, i = 1, \ldots, K\} \subset \{1, \ldots, K\}. \tag{20}$$

$\sqrt{p_k}\boldsymbol{\phi}_{t_k}$ 的元素由用户设备 k 在相干块开始时通过τ_{p} 个连续采样发送，其中 p_k 是用户设备 k的上行链路发射功率。随后，在整个导频传输期间，子阵 l 处接收到的信号 $\mathbf{Y}_l^{\mathrm{p}} \in \mathbb{C}^{N \times \tau_{\mathrm{p}}}$ 为

$$\mathbf{Y}_l^{\mathrm{p}} = \sum_{i=1}^{K} \sqrt{p_i} \mathbf{h}_{il} \boldsymbol{\phi}_{t_i}^{\mathrm{T}} + \mathbf{N}_l^{\mathrm{p}}, \tag{21}$$

whe其中，$\mathbf{N}_l^{\mathrm{p}} \in \mathbb{C}^{N \times \tau_{\mathrm{p}}}$是接收机噪声，其元素独立同分布，服从 $\mathcal{N}_{\mathbb{C}}(\mathbf{0}, \sigma_{\mathrm{n}}^2)$。

此外，通过将接收信号 $\mathbf{Y}_l^{\mathrm{p}}$ 乘以导频 $\boldsymbol{\phi}_{t_k}$的归一化共轭，可以消除来自非共享导频用户设备的干扰，从而得到处理后的接收导频信号 $\mathbf{y}_{t_k l}^{\mathrm{p}} \in \mathbb{C}^N$，该信号是估计$\mathbf{h}_{kl}$的充分统计量：

$$\mathbf{y}_{t_k l}^{\mathrm{p}} = \mathbf{Y}_l^{\mathrm{p}} \boldsymbol{\phi}_{t_k}^* = \sqrt{p_k} \tau_{\mathrm{p}} \mathbf{h}_{kl} + \sum_{i \in \mathcal{P}_k \setminus \{k\}} \sqrt{p_i} \tau_{\mathrm{p}} \mathbf{h}_{il} + \mathbf{n}_{t_k l}^{\mathrm{p}}, \tag{22}$$

其中 $\mathbf{n}_{t_k l}^{\mathrm{p}} = \mathbf{N}_l^{\mathrm{p}} \boldsymbol{\phi}_{t_k}^* \sim \mathcal{N}_{\mathbb{C}}(\mathbf{0}, \tau_{\mathrm{p}} \sigma_{\mathrm{n}}^2 \mathbf{I}_N)$。

B. 信道估计

可根据观测$\mathbf{y}_{t_k l}^{\mathrm{p}}$获得信道估计值。最小均方误差估计器利用统计信息即信道均值和协方差矩阵，部分

消除来自共享导频的用户设备的干扰。根据接收信号$\mathbf{y}^{\mathrm{p}}_{t_k l}$，$\mathbf{h}_{kl}$ 的最小均方误差估计定义为 [21]:

$$\widehat{\mathbf{h}}_{kl} = \overline{\mathbf{h}}_{kl} + \sqrt{p_k}\mathbf{R}_{kl}\boldsymbol{\Psi}^{-1}_{t_k l}\left(\mathbf{y}^{\mathrm{p}}_{t_k l} - \overline{\mathbf{y}}^{\mathrm{p}}_{t_k l}\right), \tag{23}$$

其中

$$\boldsymbol{\Psi}_{t_k l} = \frac{1}{\tau_{\mathrm{p}}}\mathrm{Cov}(\mathbf{y}^{\mathrm{p}}_{t_k l}) = \sum_{i\in\mathcal{P}_k} p_i\tau_{\mathrm{p}}\mathbf{R}_{il} + \sigma^2_{\mathrm{n}}\mathbf{I}_N, \tag{24}$$

and

$$\overline{\mathbf{y}}^{\mathrm{p}}_{t_k l} = \sqrt{p_k}\tau_{\mathrm{p}}\overline{\mathbf{h}}_{kl} + \sum_{i\in\mathcal{P}_k\setminus\{k\}} \sqrt{p_i}\tau_{\mathrm{p}}\overline{\mathbf{h}}_{il}. \tag{25}$$

假设统计分布（均值向量和协方差矩阵）已完全已知，因为它们在数百个信道相干块内保持不变。实际中，可以使用样本均值和样本协方差矩阵对其进行估计。

$\widehat{\ }$由此得到的估计误差 $\boldsymbol{\varepsilon}_{\mathbf{h}_{kl}} = \mathbf{h}_{kl} - \mathbf{h}_{kl}$ 可建模为协方差矩阵为 [21] 的零均值随机变量，其中

$$\mathbf{C}_{kl} = \mathbf{R}_{kl} - p_k\tau_{\mathrm{p}}\mathbf{R}_{kl}\boldsymbol{\Psi}^{-1}_{t_k l}\mathbf{R}_{kl}. \tag{26}$$

$\widehat{\ }$估计值 $\mathbf{h}_{kl}$ 和估计误差 $\boldsymbol{\varepsilon}_{\mathbf{h}_{kl}}$ 是相互独立的随机变量，其分布为 [21]

$$\widehat{\mathbf{h}}_{kl} \sim \mathcal{N}_{\mathbb{C}}\left(\overline{\mathbf{h}}_{kl}, \mathbf{R}_{kl} - \mathbf{C}_{kl}\right), \tag{27}$$

$$\boldsymbol{\varepsilon}_{\mathbf{h}_{kl}} \sim \mathcal{N}_{\mathbb{C}}\left(\mathbf{0}_N, \mathbf{C}_{kl}\right). \tag{28}$$

信道估计精度由信道估计值 [10]的归一化均方误差（NMSE）定义。$\mathbf{h}_k$ 的归一化均方误差$\widehat{\ }$可计算为

$$\mathrm{NMSE}_k = \frac{\mathbb{E}\{||\boldsymbol{\varepsilon}_{\mathbf{h}_k}||^2\}}{\mathbb{E}\{||\mathbf{h}_k||^2\}} = \frac{\mathbb{E}\{\boldsymbol{\varepsilon}^{\mathrm{H}}_{\mathbf{h}_k}\}\mathbb{E}\{\boldsymbol{\varepsilon}_{\mathbf{h}_k}\} + \sum_{l=1}^{L}\mathrm{tr}(\mathbf{C}_{kl})}{N\sum_{l=1}^{L}\beta_{kl}}, \tag{29}$$

其中 $\boldsymbol{\varepsilon}_{\mathbf{h}_k} = [\boldsymbol{\varepsilon}_{\mathbf{h}_{k1}}{}^{\mathrm{T}} \ldots, \boldsymbol{\varepsilon}_{\mathbf{h}_{kL}}{}^{\mathrm{T}}]^{\mathrm{T}}$是用户设备 k的整体信道估计误差向量。项 $\mathbb{E}\{||\boldsymbol{\varepsilon}_{\mathbf{h}_k}||^2\}$ 是信道估计值 $\widehat{\mathbf{h}}_k$的均方误差（MSE）。

C. 上行数据传输

在上行数据传输期间，第 i个用户设备以功率$p_i = \mathbb{E}\{|s_i|^2\}$发送信号 $s_i \in \mathbb{C}$，子阵列接收来自 K 个用户设备所发送信号的叠加。在第 l个子阵处接收到的信号$\mathbf{y}^{\mathrm{ul}}_l \in \mathbb{C}^N$ 表示为

$$\mathbf{y}^{\mathrm{ul}}_l = \sum_{i=1}^{K}\mathbf{h}_{il}s_i + \mathbf{n}^{\mathrm{u}}_l, \tag{30}$$

其中，$\mathbf{h}_{il} \in \mathbb{C}^N$ 表示第 k个用户设备与第 l个子阵之间的信道向量，$\mathbf{n}_l^{\mathrm{u}} \sim \mathcal{N}_{\mathbb{C}}(\mathbf{0}, \sigma_{\mathrm{n}}^2 \mathbf{I}_N)$表示上行数据传输期间的独立加性噪声。

我们定义集合 $\mathcal{M}_k$，其中包含服务第 k 个用户设备的子阵列；并定义对角矩阵 $\mathbf{D}_{kl} \in \mathbb{C}^{N \times N}$，用于指示第 l 个子阵是否为第 k 个用户设备提供服务：

$$\mathbf{D}_{kl} = \begin{cases} \mathbf{I}_N, & \text{if } l \in \mathcal{M}_k, \\ \mathbf{0}_N, & \text{if } l \notin \mathcal{M}_k. \end{cases} \tag{31}$$

如果 $\alpha_{kl} = 1$ 且 $\alpha_{kj} = 0$，即，如果用户设备 k 与子阵 l 之间存在视距，但与子阵 j之间不存在视距，那么合适的 SA选择方案很可能会优先选择子阵 l 而非 j 来服务用户设备 k。

此外，我们定义一个接收合并向量$\mathbf{v}_{kl} \in \mathbb{C}^N$，供子阵 l 在服务用户设备 k时使用；并定义集体合并向量$\mathbf{v}_k = [\mathbf{v}_{k1}^{\mathrm{T}} \dots \mathbf{v}_{kL}^{\mathrm{T}}]^{\mathrm{T}}$。集体上行链路数据信号$\mathbf{y}^{\mathrm{ul}} \in \mathbb{C}^{LN}$ 表示为

$$\mathbf{y}^{\mathrm{ul}} = \begin{bmatrix} \mathbf{y}_1^{\mathrm{ul}} \\ \vdots \\ \mathbf{y}_L^{\mathrm{ul}} \end{bmatrix} = \sum_{i=1}^{K} \mathbf{h}_i s_i + \mathbf{n}, \tag{32}$$

其中，$\mathbf{h}_i = [\mathbf{h}_{i1}^{\mathrm{T}} \dots \mathbf{h}_{1L}^{\mathrm{T}}]^{\mathrm{T}} \in \mathbb{C}^{LN}$是第 i 个用户设备的集体信道，而$\mathbf{n} = [\mathbf{n}_1^{\mathrm{T}} \dots \mathbf{n}_l^{\mathrm{T}}]^{\mathrm{T}} \in \mathbb{C}^{LN}$是沿所有子阵列天线的集体噪声向量。

为了获得对 s_k 的估计，CPU 计算有效接收合并向量 $\mathbf{D}_k \mathbf{v}_k$（其中 $\mathbf{D}_k = \mathrm{diag}(\mathbf{D}_{k1}, \dots, \mathbf{D}_{kL})$）与服务子阵列处接收的上行链路数据信号之间的内积：

$$\widehat{s}_k = \mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \mathbf{y}^{\mathrm{ul}} \tag{33}$$

$$= \mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \widehat{\mathbf{h}}_k s_k + \mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \boldsymbol{\varepsilon}_{\mathbf{h}_k} s_k + \sum_{\substack{i=1 \\ i \neq k}}^{K} \mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \mathbf{h}_i s_i + \mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \mathbf{n}. \tag{34}$$

请注意，期望信号 $\mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \mathbf{h}_k s_k$ 在方程（34）中被分成两部分：基于估计信道的期望信号 $\mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \widehat{\mathbf{h}}_k s_k$，以及基于未知信道的期望信号 $\mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \boldsymbol{\varepsilon}_{\mathbf{h}_k} s_k$。只有第一部分可用于信号检测。第二部分没有用处，因为我们只知道估计误差的分布，因此在计算用户设备 k 的瞬时有效上行链路信干噪比时，将其视为干扰或噪声，结果为

$$\mathrm{SINR}_k^{\mathrm{ul,c}} = \frac{p_k |\mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \widehat{\mathbf{h}}_k|^2}{\sum\limits_{\substack{i=1 \\ i \neq k}}^{K} p_i |\mathbf{v}_k^{\mathrm{H}} \mathbf{D}_k \widehat{\mathbf{h}}_i|^2 + \mathbf{v}_k^{\mathrm{H}} \mathbf{Z}_k \mathbf{v}_k + \sigma_{\mathrm{n}}^2 ||\mathbf{D}_k \mathbf{v}_k||^2}, \tag{35}$$

其中

$$\mathbf{Z}_k = \sum_{i=1}^{K} p_i \mathbf{D}_k \mathbf{C}_i \mathbf{D}_k. \tag{36}$$

最后， $\tau_{\mathrm{u}}/\tau_{\mathrm{c}}$ 表示每个相干块中用于上行链路数据传输的比例，集中式运行下用户设备 k 的可实现的频谱效率可表示为

$$\mathrm{SE}_k^{\mathrm{ul,c}} = \frac{\tau_{\mathrm{u}}}{\tau_{\mathrm{c}}} \mathbb{E}\left\{\log_2\left(1+\mathrm{SINR}_k^{\mathrm{ul,c}}\right)\right\}. \tag{37}$$

D. 接收合并

部署 XL 天线阵列的一个重要影响是，影响 UE k 的干扰主要由其邻近区域内的用户设备 [10]产生。因此，我们将采用部分 MMSE（P-MMSE）进行接收合并，其定义如下:

$$\mathbf{v}_k = p_k \left(\sum_{i \in \mathcal{S}_k} p_i \mathbf{D}_k (\widehat{\mathbf{h}}_i \widehat{\mathbf{h}}_i^{\mathrm{H}} + \mathbf{C}_i) \mathbf{D}_k + \sigma_{\mathrm{n}}^2 \mathbf{I}_{LN} \right)^{-1} \mathbf{D}_k \widehat{\mathbf{h}}_k, \tag{38}$$

其中，只有由至少一个同时服务于 UE k 的子阵服务的用户设备才会纳入求逆矩阵即，索引属于集合

$$\mathcal{S}_k = \{ i : \mathbf{D}_k \mathbf{D}_i \neq \mathbf{0}_{LN} \}. \tag{39}$$

在 $\mathcal{S}_k$ 包含 K 个用户设备这一特殊情况下，向量 $\mathbf{v}_k$ 即为 MMSE 接收合并器。该合并器在最小化估计值 $\widehat{s}_k$的均方误差（MSE）方面是最优的，同时也能最大化第 k个用户设备的信干噪比（SINR），如式（35）所定义。P-MMSE 合并器无法达到最优频谱效率，但具有可扩展性，因为当 $K \to \infty$时，计算合并向量$\mathbf{v}_k$ 以及估计信道向量$\mathbf{h}_i$, $i \in \mathcal{S}_k$的计算复杂度都不会无限增长。

IV. 导频分配与子阵选择

根据移动性，归一化相干块的大小可能小于用户设备的数量，即 $\tau_{\mathrm{c}} < K$。相干块的有限长度意味着 $\tau_{\mathrm{p}} < \tau_{\mathrm{c}}$，因此，在用户设备过度密集、 $K > \tau_{\mathrm{c}}$的网络中，不可能为所有用户设备分配相互正交的导频，进而 $K > \tau_{\mathrm{p}}$。此外，也可能出现 $\tau_{\mathrm{p}} < K$的情况。因此，在用户密集场景中，我们可能需要在超大规模MIMO用户设备之间重复使用τ_{p}相互正交的导频。

如果用户设备 k 和 i 使用相同的导频，即， $t_k = t_i$，用户设备 i 很可能会比使用不同于 t_k的其他导频的用户设备对估计值 $\widehat{s}_k$ 造成更强的干扰。如果大尺度衰落信道增益 β_{kl} 强于 β_{il}，那么将估计s_k 而非 s_i的任务分配给此子阵可能更为合适。因此，每个子阵对每个导频序列只能估计一个用户设备的信号，即信道最强的用户设备，从而使每个用户设备由不同的

子阵列子集服务。这是可扩展性的充要条件，因为当 $K \to \infty$ [10]时，计算复杂度将保持有限。

然而，在某些情况下，第 k个用户设备的信道可能并非任一子阵中共享导频 t_k 的用户设备里最强的，因此 CPU 甚至不会处理其信号。因此，子阵选择不足以确保超大规模MIMO用户设备之间服务质量均衡，还需要采用导频分配策略。避免上述性能损害的一种可行方法，是为信道最差的用户设备分配专属正交导频。第四节 B 小节将讨论所提出的导频分配策略。

导频分配（PA）和子阵选择（SAS）策略都仅基于信道统计，而非瞬时信道实现；因此，无需在每个相干块中运行这两种算法。子阵选择的一种基本算法是先为所有用户设备分配导频，然后让每个子阵针对每个导频仅服务一个用户设备，即在已分配该导频的用户设备子集中，大尺度衰落信道增益[1] 最强的用户设备。请注意，每个子阵都可以在本地做出这些决策 [10]。

A. 导频污染效应

假设用户设备 k 和 i 使用相同的导频。直观而言，用户设备 i 距离天线阵列越近，其非视距大尺度衰落信道增益（β_{il}^{NLoS}）就越高，因此对 $\mathbf{h}_{kl}$ 的估计造成的干扰也越大。由 (26) 和 (29) 可知，归一化均方误差会随 β_{il}^{NLoS} 增大，而 β_{il}^{NLoS} 已隐含在 $\mathbf{\Psi}_{t_k l}^{-1}$ 中。此外，如果用户设备 k 靠近均匀线性阵列，尤其是在存在视距路径时，其对应的信道会更强；由于视距分量变化缓慢，相对估计误差会更小，因此假设该分量已被完美获知。另一方面，根据 (29)，对 $\mathbf{h}_k$ 进行估计的归一化均方误差与 $\sum_{l=1}^{L} \beta_{kl}$ 成反比。

此外，如果$\mathbf{R}_{kl}$ 可逆，则可写出关系式 [10]

$$\widehat{\mathbf{h}}_{il} = \bar{\mathbf{h}}_{il} + \sqrt{\frac{p_i}{p_k}} \mathbf{R}_{il} \mathbf{R}_{kl}^{-1} (\widehat{\mathbf{h}}_{kl} - \bar{\mathbf{h}}_{kl}). \tag{40}$$

注意，矩阵$\mathbf{R}_{kl}$ 和$\mathbf{R}_{il}$ 越相似，估计值$\widehat{}$ $\widehat{\mathbf{h}}_{kl}$ 和$\mathbf{h}_{il}$ 的相关性就越高。尽管信道 $\mathbf{h}_{kl}$ 和$\mathbf{h}_{il}$ 在统计上相互独立，但如果非视距信道在空间上不相关，即*i.e.*，则最小均方误差估计将完全相关，此时

[1]请注意，这是一种信道统计信息，我们假设其已知。事实上，我们假设算法能够获得完美的信道统计信息（信道协方差矩阵和信道均值），因为它们的变化速度远慢于信道实现的变化速度。

$\mathbf{R}_{kl} = \beta_{kl}^{\text{NLoS}}\mathbf{I}_N$ 和$\mathbf{R}_{il} = \beta_{il}^{\text{NLoS}}\mathbf{I}_N$，因为除一个缩放因子[10]外，它们将完全相同。

由于位置相近的两个用户设备 k 和 i具有近似相同的方位角和仰角，因此它们具有相似的空间相关特性，即，矩阵 $\mathbf{R}_{kl}$ 和 $\mathbf{R}_{il}$ 可能非常相似。因此，如果它们使用相同的导频，$\mathbf{h}_{kl}$ 和 $\mathbf{h}_{il}$ 的最小均方误差估计将相互相关； [10] 通过分析和数值结果证明，这会导致严重的导频污染。

B. 超大规模*MIMO*中的导频分配（功率分配）

导频分配（功率分配）是一个组合问题，共有 τ_{p}^K种可能的分配方式；在现实的 5G 大规模多输入多输出网络场景中，评估所有分配方式并不可行 [10]。因此，实用的次优导频分配算法通常会迭代地为用户设备分配导频。本研究考虑了以下导频分配技术。

随机导频分配：这是最简单直接的策略，即随机地为所有K 用户设备分配导频。该策略无法保证控制导频污染，但计算复杂度为零。

先知导频分配：可以采用穷举搜索，根据某个优化准则（例如， K 个用户设备的平均信道估计归一化均方误差）获得最佳导频分配方案。式 (29) 中给出的闭式表达式可用作代价函数，以评估每个候选方案。归一化均方误差可通过式 (29) 中的闭式表达式计算，因此代价函数为

$$\sum_{k=1}^{K} \frac{\sum_{l=1}^{L} \text{tr}(\mathbf{C}_{kl})}{N \sum_{l=1}^{L} \beta_{kl}} \tag{41}$$

由于我们考虑的是无偏的 MMSE 信道估计器，因此移除了式 (29) 中的项 $\varepsilon_{\mathbf{h}_{kl}}$ 。先知导频分配过程如算法 1 所示。然而，只有在可能的分配数量较少时，此方法才可行。该方法能够保证最优性，但由于存在 $(\tau_{\text{p}})^K$ 种可能的分配方式，因此不可行 [10]。

贪心导频分配：这是一种简单的导频分配策略，分两步进行：第一步，将 τ_{p} 个正交导频分配给 τ_{p} 个随机用户设备；第二步，依次为其余用户设备分配导频，以尽量减少导频污染。用户设备 k 在被分配导频 t 时所面临的导频污染，可以量化为已分配导频 t 的用户设备的非视距大尺度衰落信道增益之和。它只能被视为

算法 1 预知信息导频分配

输入： $\mathbf{R}_{kl}$, $\forall kl$。

1：初始化种群 $\mathbf{\Theta}_{\mathrm{G}}$，其各列包含所有 A_{G} 可能的导频分配候选方案。

2: **对于** $i = 1, \ldots,$ **K，执行**

$_K$3：根据公式 (29)，计算 $\frac{1}{N}\sum$归一化均方误差$_k$，假设导频按照矩阵 $\mathbf{\Theta}_{\mathrm{G}}$的第 i 列进行分配，并将其赋给代价向量$\mathbf{c}_{\mathrm{G}}$的第 i列。

4: **结束循环**

5：找到与$, \ldots, t_K$对应的导频；该列为 $\mathbf{\Theta}_{\mathrm{G}}$ 中与$\mathbf{c}_{\mathrm{G}}$最小元素相关联的列。

输出： 导频分配 t_1，$\ldots$，t_K

子阵 l_k 的大尺度衰落信道增益，其中定义为用户设备 k 的大尺度衰落信道增益最强的子阵，如算法2所示，或者所有L 子阵列的大尺度衰落信道增益之和。贪心算法不提供性能保证，但能有效避免位置相近的用户设备 [10]被分配相同的导频。

算法2：贪心导频分配

输入：大尺度衰落系数

1: **对** $k = 1, \ldots, \tau_{\mathrm{p}}$ **执行**2: $t_k \leftarrow k$3: **结束循环**4: **对** $k = \tau_{\mathrm{p}}, \ldots, K$ **执行**

5: $l_k \leftarrow$求最大值

β_{kl}k−16: $\tau \leftarrow$ 求最小值$_{l\in\{1,\ldots,L\}}$ $\sum_{\substack{i=1 \\ t_i=t}}^{} \beta_{il_k}^{\mathrm{NLoS}}$7:

$t_k \leftarrow \tau$8: **结束循环**

输出： 导频分配 t_1，$\ldots$，t_K

遗传算法（***GA***）功率分配。本文提出应用启发式遗传算法（GA）来解决超大规模MIMO网络中的功率分配问题。该算法在每次迭代中使用 A 个随机导频分配候选方案。这些候选方案是长度为 K的向量，其中第 k个条目是分配给第个用户设备的导频索引

。每个候选方案都根据代价函数进行评估。此处，为了进行公平比较，我们将采用与预知信息算法（穷举搜索）相同的代价函数，如式（41）所示，即， K 个用户设备之间的平均信道估计归一化均方误差。

使用种群中的 ϕ 个最佳候选项生成新种群的 A 个成员。从最佳候选项列表中随机选取 A 对候选项，以生成 A 个后代（即算法下一次迭代中的种群元素）。通过对相应的父代应用交叉算子来生成后代，交叉点在区间 $[2, \tau_{\mathrm{p}}]$内随机选取。随后应用变异算子，修改每个用户设备的导频。修改概率为 p_{mut}，这意味着用户设备 k 的导频从 t_k 变为另一个导频的概率为p_{mut}。具体而言，从 t_k 变为其他每个τ_{p} 的概率都相同。在每次迭代结束时，如果最佳候选项优于前一次迭代中的解，则更新该候选项。预设的迭代次数记为 N_{it}。基于遗传算法的功率分配启发式方法的伪代码见算法3。

分配导频后，中央处理单元（CPU）必须通知每个子阵（SA）由该子阵覆盖的每个用户设备所指定的导频。从前传流量的角度来看，这并不重要，因为导频决策根据信道统计而变化，而不是基于瞬时信道。

针对超大规模多输入多输出系统提出的基于遗传算法的功率分配是一种次优算法，因为它是一种迭代方法，在大幅缩小的搜索空间中搜索解，能够接近使用整个搜索空间的预知信息解。此外，启发式进化型基于遗传算法的导频分配方法在减少导频污染方面，有可能比贪婪功率分配方法——尤其是基于随机搜索的方法——取得更好的效果，因为前者在选择潜在候选项/解时融入了一定的智能，而不仅仅是评估代价函数。

C. 超大规模*MIMO*中的子阵选择

子阵选择与导频分配过程密切相关，并将在所有用户设备分配到导频后进行。为此，在算法 4 中，如 [10, 算法 4.1], 所示，每个子阵在每个导频上只服务一个用户设备，即使用该导频的用户设备中大尺度衰落（LSF）系数最大的用户设备。这在实际应用中很合理，因为每个子阵都可以在本地决定服务哪些用户设备。如果导频分配得当，每个用户设备都极有可能至少由一个子阵提供服务。

基于遗传算法的导频分配算法3

输入： A, ϕ, p_{mut}, N_{it}, $\mathbf{R}_{kl}$, $\forall kl$。**1：使用** A **个随机候选项初始化种群** Θ 。**2：根据式 (29) 计算** Θ**中每个候选项的代价，形成向量 c。3：按升序排列 c，并相应地重新排列** Θ **的各列。4：初始化** $c_{\text{best}} = c_1$ **和** $\boldsymbol{\theta}_{\text{best}} = \boldsymbol{\theta}_1$。**5：对于** $i = 2, \ldots, N_{\text{it}}$**，执行 6：对于** $a = 1, \ldots, A$**，执行 7：从种群** Θ **中随机选择** ϕ **个最佳候选项作为** $\boldsymbol{\theta}_a$ **的父代；8：在随机交叉点** $\in \{2, K\}$**处应用交叉算子。9：以概率** p_{mut}**在** $\boldsymbol{\theta}_a$ **中应用变异算子。10：根据式 (29) 计算** $\boldsymbol{\theta}_a$ **的代价函数，并将其赋给** c_a。**11：结束循环 12：按降序排列 c，并相应地重新排列** Θ **的各列。13：如果满足** $c_1 > c_{\text{best}}$**，则 14：更新** $c_{\text{best}} = c_1$ **和** $\boldsymbol{\theta}_{\text{GA}} = \boldsymbol{\theta}_1$。**15：结束条件判断 16：结束循环 输出：** $\boldsymbol{\theta}_{\text{GA}}$

V. 数值结果

本节基于蒙特卡洛仿真（MCS）给出数值结果，以展示不同导频分配策略和信道估计器对超大规模多输入多输出系统中估计精度和频谱效率的影响。包含L 个均匀间隔子阵列的天线阵列位于笛卡尔平面原点，长度为100 m，沿y轴延伸，如图1所示。每个子阵列包含 $N = 4$ 根天线，间距为半个波长。在每次MCS实现中， K 个用户设备随机分布在矩形区域内，该区域在x轴和y轴上的范围均为 $[\pm 100]$ m。表I列出了所采用的仿真参数值。

基于GA的PA算法也经过配置，以求得最小化平均归一化均方误差的近似最优解。停止条件基于迭代次数N_{it} ，种群中的候选解数量设为用户设备数量的两倍；

算法 4 最强用户设备子阵列选择

输入：大尺度衰落系数和导频分配 $t_1, \ldots, t_K$

初始化：设置 $\mathcal{M}_1 = \cdots = \mathcal{M}_K = \emptyset$。
对于 $l = 1, \ldots, L$，**执行** **对于** $t = 1, \ldots, \tau_{\mathrm{p}}$，**执行** $k \leftarrow \arg\max_{i \in \{1,\ldots,K\};\ t_i = t} \beta_{il}$
$\mathcal{M}_k \leftarrow \mathcal{M}_k \cup \{l\}$
结束循环 **结束循环**
输出： $\mathcal{M}_1 = \cdots = \mathcal{M}_K$

表 I：采用的仿真参数值

参数	**值**
子阵列数量：L	{25,50}
每个子阵列的天线数量：N	4
天线阵列高度：z_l^{SA}	10 m
用户设备高度：z_l^{UE}	1.5 米
非视距路径损耗衰减指数：γ	4
阴影衰落标准差：σ_{s}^2	3 dB（视距） 4 dB（非视距）
方位角标准差：σ_{φ}	10°
仰角标准差：σ_{θ}	10°
距离 1 m 处的信道增益中值：β_0	$8.9125 \cdot 10^{-4}$
阵列长度	100 m
波长：λ	12.5 cm
同一子阵中相邻天线间距：d	$\lambda/2$
每个SA中的天线数量：N	4
用户设备$_k$–子阵$_l$之间的视距概率：Pr($\alpha_{kl} = 1$)	式 (42)
用户设备发射功率：$p_1, .., p_K$	10 dBm
噪声功率：σ_{n}^2	-96 dBm
导频序列长度：τ_{p}	4
蒙特卡洛实现次数	1000

变异概率调整为 $p_{\mathrm{mut}} = 0.02$，最佳候选项的数量设置为受 $A/2$限制。基于GA的PA算法所采用的参数值列于表II中。将所提出的基于GA的导频分配方法与三种

不同的流程进行比较：a) genie-PA、b) greedy-PA 和 c) random-PA 方法。四种PA方法均采用相同的SA选择步骤。

表II：基于GA的PA算法仿真所采用的参数值

参数	**值**
迭代次数： N_{it}	15
种群中的候选解数量： A	$2K$
变异概率： p_{mut}	2%
最佳候选项数量： ϕ	$\lceil A/2 \rceil$

对于微城市场景，UE k 与SA l 之间存在视距的概率是二者距离的函数，并按照[22] 建模如下：

$$\Pr(\alpha_{kl}=1)=\min\left(\frac{18\text{ m}}{d_{kl}},1\right)\cdot\left[1-e^{-\frac{d_{kl}}{36\text{ m}}}\right]+e^{-\frac{d_{kl}}{36\text{ m}}}. \tag{42}$$

根据（42），当距离为 $d_{kl}\leq 18$ m时，传播始终处于视距条件下，即也就是说，$q=1$；而当距离为 $d_{kl}>18$ m时，视距概率呈指数衰减。结合公式（42）给出的视距概率以及阵列长度和小区尺寸的既定仿真参数，我们得到平均视距概率为36%。这代表了超大规模多输入多输出系统在微城市信道场景中运行时的预期状况。从可靠数值仿真的角度来看，在城市拥挤信道场景中，不能忽略视距分量，因为大多数用户设备都靠近基站阵列，而基站阵列的长度远大于共址大规模多输入多输出阵列。

A. 可达频谱效率

我们比较所提出的基于遗传算法的导频分配策略与第四节中提到的另外三种策略（随机、贪心和先知导频分配方法）所得到的信道估计归一化均方误差和每用户频谱效率。根据图2，系统运行包括以下步骤：导频分配、子阵选择（算法 4）、信道估计和接收合并。

首先回顾一下，先知导频分配和基于遗传算法的功率分配算法的任务都是找到使 K 用户设备之间的平均 信道估计归一化均方误差最小的导频分配方案；前者通过穷举搜索实现，后者则采用遗传算法方法。图3显示了平均信道估计归一化均方误差的累积分布函数（cdf），即，

归一化均方误差 $= \frac{1}{K}\sum_{k=1}^{K}$归一化均方误差$_k$，其中归一化均方误差$_k$ 根据公式（29）计算。仿真设置假定 $K = 6$、 $\tau_{\mathrm{p}} = 3$、 $L = 25$ 和 $N = 4$。根据图3，仿真证实，在每次信道实现中，先知策略和遗传算法策略确实都能获得最小的平均归一化均方误差值；此外还可以验证，基于遗传算法的导频分配策略具有较高效率，因为其性能与先知导频分配策略大致相同，但所需计算量更少（搜索空间更小）。

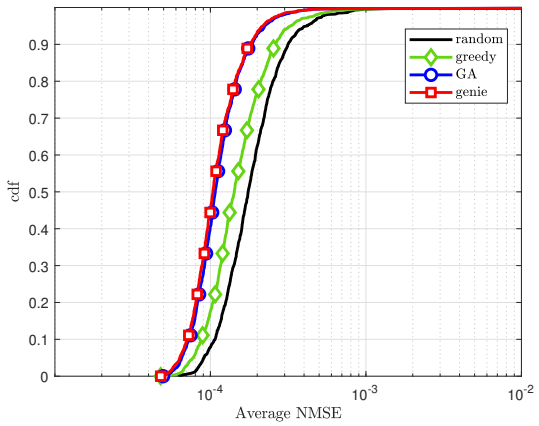
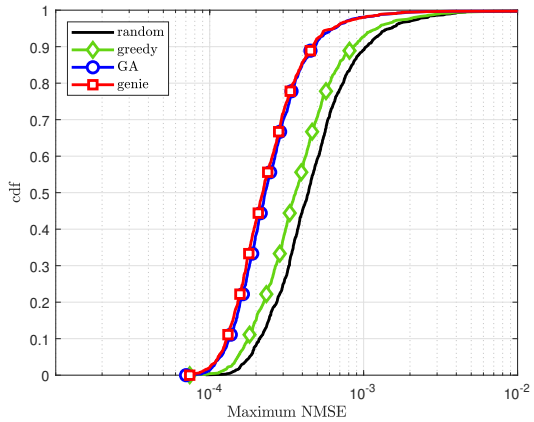


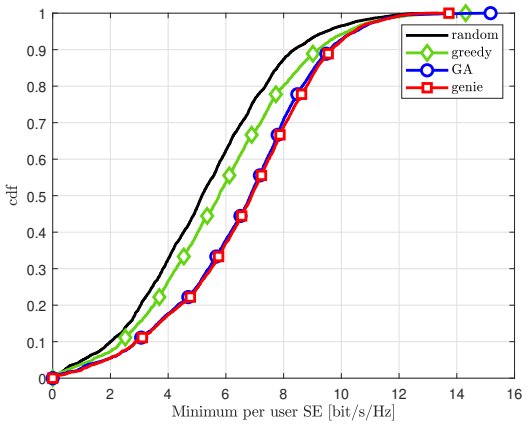
图 3： K 个用户设备的平均信道估计归一化均方误差的累积分布函数。

图 4a 和图 4b 分别展示了同时由超大规模MIMO阵列服务的 K 个用户设备中，每用户最大信道估计归一化均方误差的累积分布函数，以及每用户最低频谱效率的累积分布函数；这些指标代表每次信道实现中 K 个用户设备的最差情况。根据图 4b，先知导频分配策略通过穷举搜索找到使 K 个用户设备的平均信道估计归一化均方误差最小的导频分配方案，在最大化 K 个用户设备的每用户最低频谱效率方面取得了最佳结果。基于GA的PA算法取得了几乎相同的性能，因为该算法反复调整一个种群，并根据与先知导频分配相同的优化准则（即最小化平均信道估计归一化均方误差）选出最佳个体，但采用了更小的搜索空间。

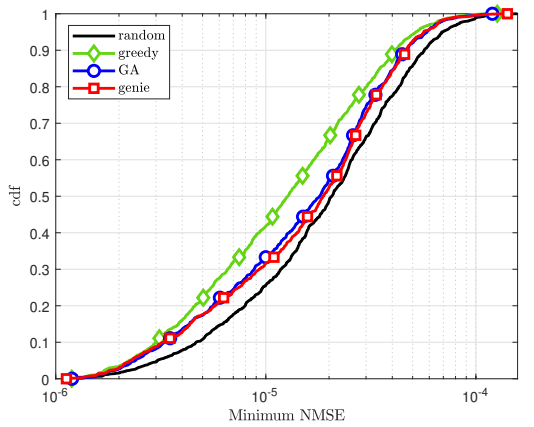
此外，可以看出，所提出的基于遗传算法的功率分配在所有信道实现中均优于随机和贪心功率分配，这意味着与这两种方法相比，该方法显著改善了信道条件较差的用户设备的性能。另一方面，根据图 4c 和图 4d，所提出的方法在信道条件非常好的用户设备上的表现不如贪心策略；图 4c 和图 4d 分别展示了 K 个用户设备中每用户最低信道估计归一化均方误差的累积分布函数，以及每用户最高频谱效率的累积分布函数。最后，图 4e 和图 4f 分别展示了每用户



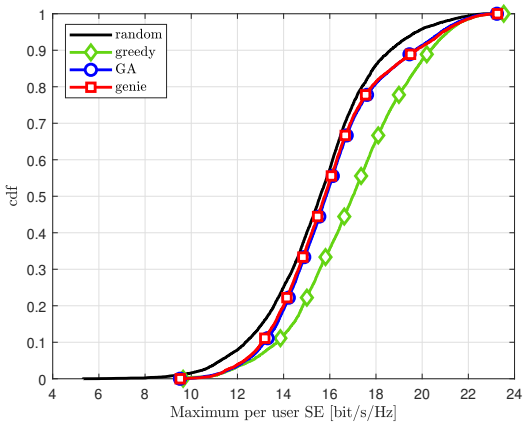
(a) K个用户设备中的最大信道估计归一化均方误差



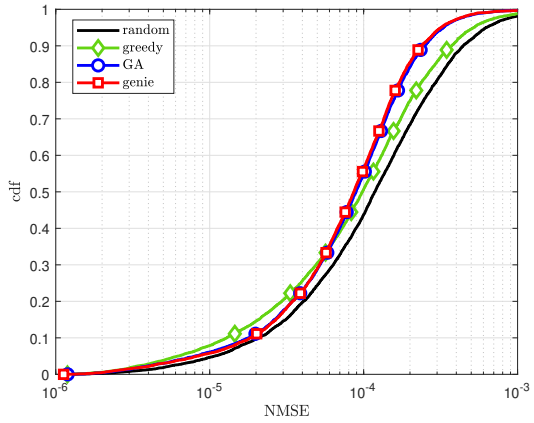
(b) 最低每用户频谱效率



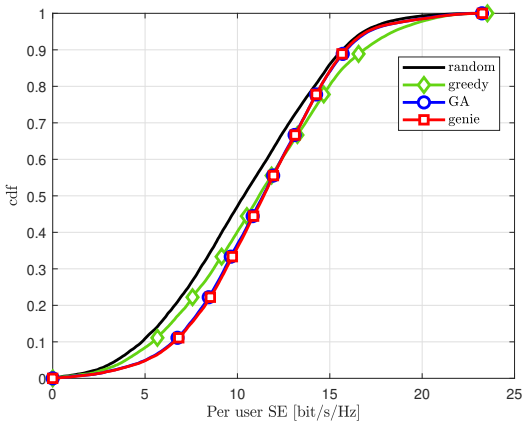
(c) K个用户设备中的最小信道估计归一化均方误差



(d) 最大每用户频谱效率



(e) 信道估计归一化均方误差 (NMSE_k)



(f) 每用户频谱效率

图4：考虑每个蒙特卡洛信道实现中最差的用户设备（a和b）、最佳用户设备（c和d）以及所有 K用户设备（e和f），并采用 $K = 6$、 $\tau_{\mathrm{p}} = 3$、 $L = 25$ 和 $N = 4$时，信道估计归一化均方误差和每用户频谱效率的累积分布函数。

信道估计归一化均方误差以及每用户频谱效率的累积分布函数，其中考虑了每次蒙特卡洛信道实现中的所有 K 用户设备。再次可以观察到，除了信道条件良好的用户设备外，基于遗传算法的功率分配优于随机和贪心策略。所提出的超大规模MIMO功率分配策略取得的成果符合超越5G网络的要求，因为与提高峰值数据速率相比，使服务质量更加均衡更为重要。最后，图5显示，所提出的功率分配策略也比随机和贪心策略实现了更高的总速率。图4和图5的仿真设置为 $K = 6$, $\tau_{\mathrm{p}} = 3$, $L = 25$ 和 $N = 4$。

进一步分析所达到的频谱效率，可以推断，更准确的信道估计值会带来更高的频谱效率。在计算一组用户设备的平均信道估计归一化均方误差时，信道条件最差的用户设备对平均归一化均方误差的影响远大于信道条件良好或中等的用户设备。因此，当合理分配导频以尽量降低平均信道归一化均方误差时（基于遗传算法的功率分配方案和理想导频分配方案即属此类），我们主要致力于提高信道条件最差的用户设备的频谱效率，这一点在图4中有所体现。

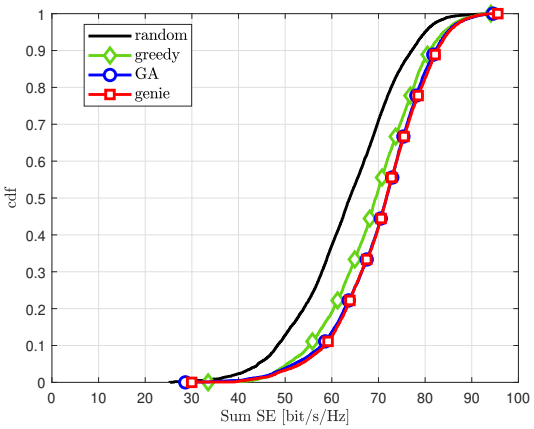
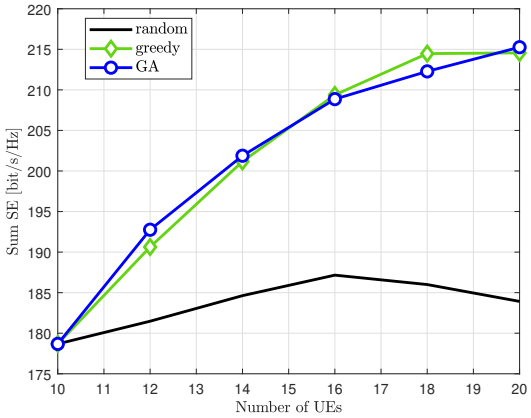


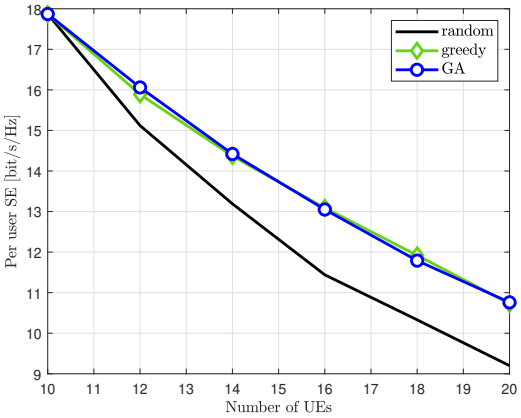
图5：总频谱效率的累积分布函数。

图6展示了在采用 $\tau_{\mathrm{p}} = 10$、 $L = 50$ 和 $N = 4$时，随着用户设备数量变化，总频谱效率、每用户频谱效率和每用户最低频谱效率的平均值。从图6c可以确认，与贪心策略相比，尤其是与随机功率分配策略相比，所提出的遗传算法方案能够有效提高 K 个用户设备中的最低频谱效率；但与贪心导频分配相比，它并未提高平均用户频谱效率和平均总频谱效率，仅优于随机方案。最后可以看出，基于遗传算法的功率分配适用于提高超大规模多输入多输出系统中服务质量的一致性，而信道估计归一化均方误差在性能—复杂度权衡方面具有良好前景，可用于评估每个候选方案在

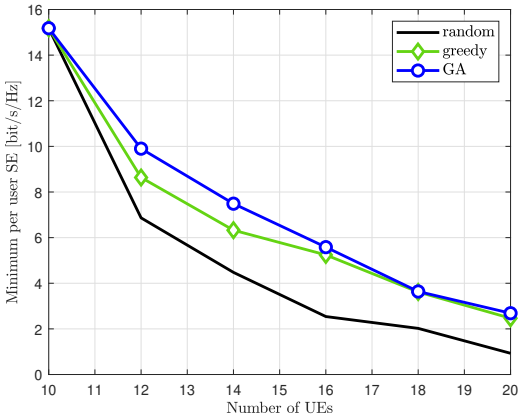
每次迭代中的种群。算法3进一步支持了这一合理推测：通过适当的导频分配和子阵列联合选择过程降低导频污染，进而减小信道估计误差，可以显著提高活跃用户设备的信干噪比。



(a) 平均总频谱效率



(b) 平均用户频谱效率



(c) 平均用户最低频谱效率

图6：a) 平均总频谱效率，b) 平均用户频谱效率，以及 c) 平均用户最低频谱效率与用户设备数量的关系。参数值： $\tau_{\mathrm{p}} = 10$、 $L = 50$ 和 $N = 4$。

VI. 结论

我们研究了在视距和非视距信道分量下，不同导频分配方案对提升超大规模MIMO系统服务质量均匀性的表现。在高密度超大规模MIMO系统中，采用恰当的导频分配策略至关重要，因为可用正交导频的数量远少于活跃用户设备的数量。因此，我们引入了一种现实的超大规模MIMO空间相关信道模型，并考虑到超大规模MIMO子阵列的天线并非共址，这意味着给定用户设备可能靠近

某些子阵，而远离其他子阵。因此，在大多数情况下，对于给定用户设备的信号检测而言，只有部分子阵是相关的。为此，我们采用了一种基于最强用户设备的简单子阵选择策略，在不影响频谱效率的前提下提升系统的可扩展性。我们将所提出的、面向基于子阵的超大规模MIMO系统的基于遗传算法的导频分配方法与另外三种方法进行了比较：a) 先知导频分配，在大多数实际应用场景中并不可行，因为它需要通过穷举搜索找到使信道估计误差最小的最佳方案；b) 贪心导频分配，这是一种低复杂度算法，已在文献中得到广泛应用；c) 随机导频分配，这是最简单的方法，并被视为频谱效率表现最差的基准。与贪心和随机导频分配方法相比，所提出的面向超大规模MIMO系统的基于遗传算法的导频分配策略显著提高了每用户频谱效率下限，并以可接受的计算复杂度取得了近乎最优的结果。这符合超越5G网络的需求：相比提升峰值数据速率，让服务质量更加均匀更为重要。此外，所提出的导频分配策略取得的总速率也高于随机和贪心策略。此外，通过信道估计归一化均方误差解析表达式评估遗传算法种群中的每个候选方案，这种方法在提升频谱效率方面表现出色，尤其是提升每用户频谱效率下限。

APPENDIX A
PROOF OF EQ. (9) AND (10)

为简化记号，我们将使用 $\mathbf{a}_{kl}^{(b)} = \mathbf{a}(\varphi_{kl}^{(b)},\ \theta_{kl}^{(b)})$ 和 $\mathbf{a}_{kl}^{(0)} = \mathbf{a}(\varphi_{kl},\ \theta_{\overline{kl}})$。首先，很容易发现，根据式（6）定义的 $\mathbf{h}_{kl}^{\mathrm{NLoS}}$ 是一个零均值随机向量，因为 $g_{kl}^{(b)}$ 与 $\mathbf{a}_{kl}^{(b)}$ 相互独立，因此不相关：

$$\mathbb{E}\{\mathbf{h}_{kl}^{\mathrm{NLoS}}\} = \sum_{b=1}^{B} \mathbb{E}\{g_{kl}^{(b)}\mathbf{a}_{kl}^{(b)}\} = \sum_{b=1}^{B} \underbrace{\mathbb{E}\{g_{kl}^{(b)}\}}_{0}\, \mathbb{E}\{\mathbf{a}_{kl}^{(b)}\} = 0.$$

其次，$\mathbf{h}_{kl}^{\mathrm{NLoS}}$ 的协方差矩阵计算如下

$$\begin{aligned}
\mathbf{R}_{kl} &= \mathbb{E}\{\mathbf{h}_{kl}^{\mathrm{NLoS}}(\mathbf{h}_{kl}^{\mathrm{NLoS}})^{\mathrm{H}}\} - \mathbb{E}\{\mathbf{h}_{kl}^{\mathrm{NLoS}}\}\mathbb{E}\{(\mathbf{h}_{kl}^{\mathrm{NLoS}})^{\mathrm{H}}\} \\
&= \mathbb{E}\Big\{\Big[\sum_{b=1}^{B} g_{kl}^{(b)}\mathbf{a}_{kl}^{(b)}\Big]\Big[\sum_{b=1}^{B} (g_{kl}^{(b)})^{*}(\mathbf{a}_{kl}^{(b)})^{\mathrm{H}}\Big]\Big\} - 0\cdot 0 \\
&= \sum_{b=1}^{B} \mathbb{E}\{|g_{kl}^{(b)}|^2\}\mathbb{E}\{\mathbf{a}_{kl}^{(b)}(\mathbf{a}_{kl}^{(b)})^{\mathrm{H}}\} + \\
&\quad \sum_{b=1}^{B}\sum_{\substack{b'=1 \\ b'\neq b}}^{B} \underbrace{\mathbb{E}\{g_{kl}^{(b)}(g_{kl}^{(b')})^{*}\}}_{0}\, \mathbb{E}\{\mathbf{a}_{kl}^{(b)}(\mathbf{a}_{kl}^{(b')})^{\mathrm{H}}\},
\end{aligned} \tag{43}$$

其中 $\mathbb{E}\{g_{kl}^{(b)}(g_{kl}^{(b')})^*\}=0$，因为 $g_{kl}^{(b)}$，$b=1,\ldots,B$ 是独立同分布的随机变量。由于阵列响应向量表示为 $[\mathbf{a}(\varphi,\theta)]_n=e^{-j2(n-1)\pi\frac{d}{\lambda}\sin(\varphi)\cos(\theta)}$，矩阵 $\mathbf{a}_{kl}^{(b)}(\mathbf{a}_{kl}^{(b)})^{\mathrm{H}}$ 可计算如下

$$[\mathbf{a}_{kl}^{(b)}(\mathbf{a}_{kl}^{(b)})^{\mathrm{H}}]_{m,n}=\exp\left(j2(m-n)\pi\frac{d}{\lambda}\frac{\sin(\varphi_{kl}^{(b)})}{\cos(\theta_{kl}^{(b)})}\right),$$

期望 $\mathbb{E}\{\mathbf{a}_{kl}^{(b)}(\mathbf{a}^{(b')}{}_{kl})^{\mathrm{H}}\}\}$，对于角度 $\varphi_{kl}^{(b)}$ 和 $\theta_{kl}^{(b)}$，在 $b=1,\ldots,B$ 中相同，并根据定义为

$$\begin{aligned}[\mathbb{E}\{\mathbf{a}_{kl}^{(b)}(\mathbf{a}_{kl}^{(b)})^{\mathrm{H}}\}]_{m,n}&=\int\int[\mathbf{a}_{kl}^{(b)}(\mathbf{a}_{kl}^{(b)})^{\mathrm{H}}]_{m,n}f_{kl}(\varphi,\theta)d\varphi d\theta\\&=\int\int e^{j2(m-n)\pi\frac{d}{\lambda}\frac{\sin(\varphi)}{\cos(\theta)}}f_{kl}(\varphi,\theta)d\varphi d\theta.\end{aligned}$$

因此，这一项可以从式（43）的总结中删去。最后，回想一下 $\beta_{kl}^{\mathrm{NLoS}}=\sum_{b=1}^{B}\mathbb{E}\{|g_{kl}^{(b)}|^2\}$:

$$[\mathbf{R}_{kl}]_{m,n}=\beta_{kl}^{\mathrm{NLoS}}\int\int e^{j2(m-n)\pi\frac{d}{\lambda}\frac{\sin(\varphi)}{\cos(\theta)}}f_{kl}(\varphi,\theta)d\varphi d\theta.$$

参考文献

[1] A. Amiri、C. N. Manchón 和 E. de Carvalho，“一种用于超大规模 MIMO 的基于消息传递的接收机”，载于*2019* 年 *IEEE* 第八届多传感器自适应处理计算进展国际研讨会 *(CAMSAP)*，2019 年，第 564–568 页。[2] O. S. Nishimura、J. C. Marinello 和 T. Abrão，“超大规模大规模 MIMO 系统中的一种基于授权的随机接入协议”，*IEEE Communications Letters*，第 24 卷，第 11 期，第 2478–2482 页，2020 年。[3] J. C. Marinello、T. Abrão、A. Amiri、E. de Carvalho 和 P. Popovski，“通过天线选择提高超大规模 MIMO 系统的能效”，*IEEE Transactions on Vehicular Technology*，第 69 卷，第 11 期，第 13 305–13318 页，2020 年。[4] X. Yang、F. Cao、M. Matthaiou 和 S. Jin，“超大规模大规模 MIMO 系统的上行传输”，*IEEE Transactions on Vehicular Technology*，第 69 卷，第 12 期，第 15 229–15243 页，2020 年。[5] H. Wang、A. Kosasih、C. Wen、S. Jin 和 W. Hardjawana，“用于超大规模大规模 MIMO 的期望传播检测器”，*IEEE Transactions on Wireless Communications*，第 19 卷，第 3 期，第 2036–2051 页，2020 年。[6] A. Amiri、C. N. Manchón 和 E. de Carvalho，“超大规模 MIMO 阵列中的非协调分布式处理”，*IEEE Wireless Communications Letters*，第 11 卷，第 1 期，第 81–85 页，2022 年。[7] 3GPP，“无线接入网技术规范组；多输入多输出 (MIMO) 仿真空间信道模型 (Release 16)”，第三代合作伙伴计划 (3GPP)，技术规范 (TS) 25.996，2020 年 7 月，版本 16.0.0。 [在线]。网址：https://portal.3gpp.org/desktopmodules/Specifications/ SpecificationDetails.aspx?specificationId=1382[8] S. Mukherjee 和 R. Chopra，“视距/非视距信道中无小区大规模 MIMO 系统的性能分析”，*IEEETransactions onVehicularTechnology*，第 71 卷，第 6 期，第 6410–6423 页，2022 年。[9] S. Elhoushy、M. Ibrahim 和 W. Hamouda，“无小区大规模 MIMO：综述”，*IEEE CommunicationsSurveysTutorials*，第 24 卷，第 1 期，第 492–523 页，2022 年。[10] Ö. T. Demir、E. Björnson 和 L. Sanguinetti，以用户为中心的无小区大规模 *MIMO* 基础，2021 年。[11] X. Zhu、Z. Wang、L. Dai 和 C. Qian，“大规模 MIMO 的智能导频分配”，*IEEE Communications Letters*，第 19 卷，第 9 期，第 1644–1647 页，2015 年。

[12] Y.Omid、S. M. Hosseini、S. M. Shahabi、M. Shikh-Bahaei 和 A. Nallanathan，“利用深度强化学习进行大规模 MIMO 系统中基于到达角的导频分配”，*IEEE Communications Letters*，第 25 卷，第 9 期，第 2948–2952 页，2021 年。[13] J. C. M. Filho、G. Brante、R. D. Souza 和 T. Abrão，“探索超大规模 MIMO 随机接入与调度中的非重叠可见区域”，*IEEE Transactions on Wireless Communications*，第 1–1 页，2022 年。[14] M. Cui 和 L. Dai，“超大规模 MIMO 的信道估计：远场还是近场？”*IEEE Transactionson Communications*，第 70 卷，第 4 期，第 2663–2677 页，2022 年。[15] O. S. Nishimura、J. C. M. Filho、T. Abrão 和 R. D. Souza，“面向高密度超大规模 MIMO 系统的类别限制功率控制随机接入协议中的公平性 ”，*IEEE Systems Journal*，第 1–9 页，2022 年。[16] J. D. Kraus，适用于各种应用的天线。McGraw Hill，2002 年。[17] L. Sanguinetti、E. Björnson 和 J. Hoydis，“迈向大规模 MIMO 2.0：理解空间相关性、干扰抑制和导频污染”，*IEEE Transactions on Communications*，第 68 卷，第 1 期，第 232–257 页，2020 年。[18] E. Björnson、J. Hoydis 和 L. Sanguinetti，“大规模 MIMO 网络：频谱、能量与硬件效率”，信号处理基础与趋势，第 11 卷，第 3–4 期，第 154–655 页，2017 年。 [在线]。网址：http://dx.doi.org/10.1561/2000000093[19] S. Lu、J. May 和 R. J. Haines，“相关阴影建模对无线传感器网络性能评估的影响”，载于*2015* 年 *IEEE* 第 *82* 届车辆技术会议 *(VTC2015-Fall)*，2015 年，第 1–5 页。[20] ——，“密集无线多跳网络中相关阴影衰落的高效建模”，载于*2014* 年 *IEEE* 无线通信与网络会议 *(WCNC)*，2014 年，第 311–316 页。[21] O. Ozdogan、E. Bjornson 和 E. G. Larsson，“空间相关莱斯衰落信道下的大规模 MIMO”，*IEEETransactions onCommunications*，第 67 卷，第 5 期，第 3234–3250 页，2019 年。[22] 3GPP，“无线接入网技术规范组；演进型通用陆地无线接入 (E-ULTRA)；E-ULTRA 物理层方面的进一步改进 (Release 9)”，第三代合作伙伴计划 (3GPP)，技术规范 (TS) 36.814，2017 年 3 月，版本 9.2.0。 [在线]。网址：https://portal.3gpp.org/desktopmodules/Specifications/SpecificationDetails.aspx?specificationId=2493