

# 基于Massive MIMO的5G下行链路信道估计与性能优化研究

房亮亮

民航机场建设集团华北有限公司 北京 101300

**摘要:** Massive MIMO作为5G核心关键技术,通过在基站部署数十至数百根天线,显著提升频谱效率、能量效率和用户容量。其性能高度依赖对信道状态信息(CSI)的精确获取,即信道估计。本文聚焦5G TDD系统下行链路信道估计,首先介绍Massive MIMO原理及其带来的机遇与挑战;其次深入分析导频污染这一关键瓶颈,并对比最小二乘(LS)与最小均方误差(MMSE)等经典估计算法的原理、优劣及性能差异;最后探讨导频调度、压缩感知和深度学习等前沿优化策略。研究表明,综合运用先进算法与优化手段可有效缓解导频污染、提升估计精度,充分释放Massive MIMO潜力,为5G高效运行提供支撑。

**关键词:** 5G; Massive MIMO; 下行链路; 信道估计; 导频污染; 性能优化

## 引言

随着移动互联网、物联网和工业4.0的迅猛发展,5G通信技术应运而生,致力于实现超高速率、超低时延与高可靠连接。其中,Massive MIMO作为5G核心关键技术,由Thomas L. Marzetta于2010年提出,通过在基站部署数十至数百根天线,利用空间自由度形成定向窄波束,显著提升频谱效率、容量与干扰抑制能力,理论上可使系统容量随天线数线性增长。然而,其性能高度依赖于对下行链路信道状态信息(CSI)的精确获取。只有准确估计CSI,基站才能实施有效预编码,实现能量聚焦与干扰消除。因此,信道估计精度直接决定系统性能上限。本文聚焦5G Massive MIMO下行链路信道估计,系统梳理其基础理论,深入剖析导频污染等核心挑战,对比主流估计算法,并探讨包括导频优化、压缩感知与深度学习在内的前沿优化策略,为提升信道估计性能提供理论参考与实践路径。

## 1 Massive MIMO 基础理论与下行链路模型

### 1.1 Massive MIMO基本原理

Massive MIMO的核心特征是基站配备大量天线( $M$ 根,  $M \gg 1$ ),同时服务少量单天线用户( $K$ 个,  $K \ll M$ )。在TDD模式下,系统利用信道互易性,通过上行导频信号估计下行信道,避免了FDD中高开销的CSI反馈。当 $M$ 趋于无穷大时,系统呈现两大关键特性:一是信道硬化,即用户等效信道增益趋近确定常数,削弱随机衰落影响,使链路更可预测;二是有利传播(Favorable Propagation),不同用户信道向量趋于正交,多用户干扰自然抑制<sup>[1]</sup>。得益于这两点,即使采用简单的线性预编码

或检测算法(如MRT、ZF、MMSE),也能逼近最优性能,显著降低信号处理复杂度,为Massive MIMO的实用化奠定理论基础。

### 1.2 下行链路系统模型

考虑一个多小区TDD Massive MIMO系统,包含 $L$ 个小区,每个小区有一个配备 $M$ 根天线的基站和 $K$ 个单天线用户。在每个相干时间间隔 $T_c$ 内,系统工作分为三个阶段:上行导频训练、上行数据传输和下行数据传输。我们重点关注下行数据传输阶段。第 $l$ 个小区的基站向其服务的 $K$ 个用户发送经过预编码的数据符号。用户 $k$ 接收到的信号 $y_{lk}$ 可以表示为:

$$y_{lk} = \sqrt{\rho_d} h_{lk}^H w_{lk} s_{lk} + \sqrt{\rho_d} \sum_{i \neq k} h_{lk}^H w_{li} s_{li} + \sqrt{\rho_d} \sum_{j \neq l} \sum_{i=1}^K h_{jlk}^H w_{ji} s_{ji} + n_{lk}$$

其中:

$\rho_d$ 是下行归一化发射功率。

$h_{jlk} \in C^{M \times 1}$ 是从第 $j$ 个小区基站到第 $l$ 个小区用户 $k$ 的信道向量。

$w_{ji} \in C^{M \times 1}$ 是第 $j$ 个小区基站用于服务其第 $i$ 个用户的预编码向量。

$s_{ji}$ 是发送给第 $j$ 个小区第 $i$ 个用户的符号。

$n_{lk}$ 是加性高斯白噪声(AWGN)。

从公式可见,用户 $k$ 不仅受到本小区期望信号(第一项)的影响,还受到本小区其他用户的多用户干扰(第二项)以及来自其他 $L-1$ 个小区的同频干扰(第三项)。而所有这些信号处理的前提,都是基站拥有准确的 $h_{lk}$ 估计值。

## 2 Massive MIMO 信道估计的核心挑战: 导频污染

尽管TDD模式下的信道互易性为下行链路信道估计提供了便利，但在多小区场景中，它也引入了一个致命的瓶颈——导频污染（Pilot Contamination）。

### 2.1 导频污染的成因

在TDD系统中，信道估计发生在上行导频训练阶段。每个小区的K个用户需要在同一时间、同一频带上发送正交的导频序列（长度为 $\tau$ ，且 $\tau \geq K$ ）给其服务基站。由于整个网络可用的正交导频序列数量有限（受限于信道相干时间 $T_c$ ），当小区数量L很大时，必然会出现不同小区的用户复用相同的导频序列的情况。假设第1个小区的用户k和第j个小区（ $j \neq 1$ ）的用户k'使用了完全相同的导频序列。那么，第1个小区的基站在接收导频信号时，无法区分这两个信号，其接收到的信号将是两个用户信道的叠加。这导致基站对 $h_{jk}$ 的估计值中混入了来自 $h_{j'k}$ 的干扰成分。这种由非正交导频复用引起的、无法通过增加基站天线数M来消除的干扰，就是导频污染。

### 2.2 导频污染的严重影响

导频污染的存在从根本上破坏了Massive MIMO的理想特性：（1）信道硬化失效：信道增益不再收敛到确定值，而是包含了来自其他小区的随机干扰项。（2）用户间正交性丧失：不同小区使用相同导频的用户之间产生了强相关性，导致严重的小区间干扰（Inter-Cell Interference, ICI）<sup>[2]</sup>。（3）系统容量饱和：随着M的增加，有用信号和干扰信号以相同的速率增长，导致信干噪比（SINR）和系统总容量趋于一个有限值，无法再获得线性增益。可以说，导频污染是限制Massive MIMO在密集组网环境下性能提升的最主要障碍。

## 3 主流信道估计算法分析与性能比较

为了在存在噪声和潜在导频污染的情况下尽可能准确地估计信道，研究人员提出了多种算法。其中，最小二乘（LS）和最小均方误差（MMSE）是最为基础和经典的两种线性估计算法。

### 3.1 最小二乘（LS）算法

LS算法的目标是找到一个信道估计值，使得观测到的接收信号与根据该估计值重构的信号之间的欧氏距离（平方误差）最小。对于单小区场景，假设用户k发送的导频序列为 $\phi_k$ （满足 $\phi_k^2 = \tau$ ），基站接收到的导频信号为 $Y = \sum_{i=1}^K h_i \phi_i^H + N$ 。则LS信道估计为：

$$\hat{h}_k^{LS} = \frac{1}{\tau} Y \phi_k$$

优点是计算极其简单，不需要任何关于信道或噪声的先验统计信息。缺点是对噪声极为敏感。其估计误差

的均方误差（MSE）会随着噪声功率的增大而线性增加。在低信噪比（SNR）环境下，性能急剧恶化。此外，LS算法无法区分导频污染和噪声，会将两者一并放大。

### 3.2 最小均方误差（MMSE）算法

MMSE算法在最小化估计误差的同时，还考虑了信道和噪声的统计特性（如信道协方差矩阵 $R_k = E[h_k h_k^H]$ 和噪声方差 $\sigma^2$ ），旨在使估计误差的均方值最小。其信道估计表达式为：

$$\hat{h}_k^{MMSE} = R_k \Phi (\Phi^H R \Phi + \sigma^2 I)^{-1} Y^H$$

其中 $\Phi = [\phi_1, \dots, \phi_k]$ ， $R = \text{diag}(R_1, \dots, R_k)$ 。

优点是充分利用了信道的先验知识，在相同条件下，其MSE性能显著优于LS算法，尤其是在低SNR区域。它能更有效地抑制噪声。缺点是计算复杂度远高于LS，特别是矩阵求逆操作，其复杂度为 $O(K^3)$ 。更重要的是，它需要准确获知每个用户的信道协方差矩阵 $R_k$ ，这在实际系统中可能难以精确获取。虽然MMSE能更好地处理噪声，但对于导频污染，其性能提升也相对有限。

### 3.3 性能仿真对比

通过MATLAB等工具进行仿真实验可以直观地看到两种算法的性能差异。在无导频污染的单小区场景下，随着SNR的增加，MMSE的MSE始终低于LS。在低SNR（如0dB）时，MMSE的性能优势非常明显；而在高SNR（如20dB以上）时，两者的性能差距逐渐缩小，因为此时噪声不再是主要影响因素。然而，在存在导频污染的多小区场景中，无论SNR高低，两种算法的性能都会出现明显的平台期（饱和），这正是导频污染效应的直接体现。

## 4 基于Massive MIMO的信道估计性能优化策略

为了突破导频污染的限制并进一步提升信道估计性能，学术界和工业界提出了多种创新的优化策略。

### 4.1 导频调度与分配优化

既然导频污染源于导频序列的复用，最直接的思路就是优化导频的分配方案，以减轻污染程度。（1）基于大尺度衰落的导频分配：核心思想是让信道条件（主要由大尺度衰落决定）差异最大的用户复用同一组导频。例如，可以让一个小区中心的用户与相邻小区边缘的用户共享导频，因为前者接收本小区基站的信号很强，而后者接收相邻小区基站的干扰信号很弱，从而有效降低相互间的污染<sup>[3]</sup>。（2）智能导频分配（SPA）：利用图论或博弈论等方法，将导频分配问题建模为一个优化问题，目标是全网的最小化总导频污染或最大化系统总容量。

### 4.2 利用信道稀疏性的压缩感知方法

在毫米波 (mmWave) 频段或具有明确散射体的环境中,无线信道在角度域或延迟域往往呈现出稀疏特性,即只有少数几个路径分量具有显著的能量。压缩感知 (Compressed Sensing, CS) 理论指出,对于稀疏信号,可以用远少于奈奎斯特采样定理要求的测量值来精确重构原始信号。基于此,可以设计专门的稀疏信道估计算法,如正交匹配追踪 (OMP)、广义近似消息传递 (GAMP) 等。这些算法通过在稀疏域 (如角度域) 进行估计,不仅能以更少的导频开销获得高精度的信道估计,还能在一定程度上抑制非稀疏的导频污染噪声,展现出优于传统LS/MMSE的性能。

#### 4.3 基于深度学习的信道估计

近年来,深度学习 (Deep Learning, DL) 凭借其强大的非线性拟合和特征提取能力,在无线通信领域掀起了研究热潮。对于信道估计问题,可以将接收的导频信号作为神经网络的输入,将真实的信道响应作为标签,通过大量数据训练一个端到端的映射函数。常用的网络结构包括卷积神经网络 (CNN)、循环神经网络 (RNN) 以及更先进的Transformer等。DL方法的优势在于:(1) 无需显式信道模型:它能自动从数据中学习信道的复杂时空相关性,对模型失配具有较强的鲁棒性。(2) 潜在的高性能:在特定场景下,经过充分训练的DL模型可以逼近甚至超越传统最优估计算法的性能<sup>[4]</sup>。(3) 在线学习能力:部分模型可以适应信道的动态变化。当然,DL方法也面临着训练数据获取困难、模型泛化能力、以及在线推理的计算开销等挑战。

#### 4.4 利用极化域自由度

双极化天线 (Dual-Polarized Antenna) 在Massive MIMO中被广泛应用。它能在同一物理位置上提供两个正

交的极化维度 (如 $\pm 45^\circ$ ),相当于在不增加天线物理尺寸的情况下,成倍地增加了空间自由度。研究表明,通过精心设计极化相关的导频序列和预编码方案,可以利用极化域的隔离度来区分复用相同时频资源的用户,从而有效缓解导频污染。

### 5 结语

Massive MIMO是支撑5G及未来6G网络的关键技术,而精准的下行链路信道估计是释放其性能潜力的基础。本文系统分析了导频污染这一核心挑战,并对LS、MMSE等经典估计算法进行了深入比较。研究表明,单一算法难以彻底解决该问题,未来优化需多维度融合:在物理层,可结合信道稀疏性、极化特性等先验信息设计高效算法;在网络层,通过智能导频调度与资源管理从源头抑制污染;同时,深度学习等人工智能技术正为信道估计提供全新范式,有望实现性能突破。通过持续的理论创新与工程实践,Massive MIMO将有效克服信道估计难题,为5G用户提供极致通信体验。

### 参考文献

- [1]杨静,杨萌涵,宋燧,等.面向大规模MIMO系统的广义近似消息传递稀疏信道估计方法[J/OL].无线电通信技术,1-9[2026-04-28].
- [2]仇桐同.大规模MIMO天线阵列信道模型及其性能研究[D].南京信息工程大学,2021.DOI:10.27248/d.cnki.gnjqc.2021.000901.
- [3]韩达.5G通信系统中的大规模天线阵列设计与优化[J].集成电路应用,2024,41(02):306-307.
- [4]刘佩,许建霞,李昌振,等.“数字信号处理”赋能无蜂窝大规模MIMO系统信道估计性能分析[J].重庆理工大学学报(自然科学),2026,40(01):248-254.