

分类号： TN915

单位代码： 10335

密 级： 公开

学 号：

浙江大学

硕士学位论文



中文论文题目： **B5G大规模MIMO系统中高效能
混合波束成形设计**

英文论文题目： **Highly efficient hybrid beamforming design
in B5G massive MIMO systems**

申请人姓名： 施淑涵

指导教师： 蔡云龙

专业名称： 信息与通信工程

研究方向： 通信与网络

所在学院： 信息与电子工程学院

论文提交日期 2023.1

**B5G大规模MIMO系统中高效能
混合波束成形设计**



论文作者签名： 施淑涵

指导教师签名： 蔡云龙

论文评阅人1： 匿名

评阅人2： 匿名

评阅人3： 匿名

答辩委员会主席： 张宏纲 教授 之江实验室

委员1： 史治国 教授 浙江大学信电学院

委员2： 李 旻 研究员 浙江大学信电学院

委员3： 雷 鸣 副研究员 浙江大学信电学院

委员4： 赵明敏 副教授 浙江大学信电学院

答辩日期： 2023.3

浙江大学研究生学位论文独创性声明

本人声明所呈交的学位论文是本人在导师指导下进行的研究工作及取得的研究成果。除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果，也不包含为获得 浙江大学 或其他教育机构的学位或证书而使用过的材料。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示谢意。

学位论文作者签名：

施淑涵

签字日期：

2023年3月9日

学位论文版权使用授权书

本学位论文作者完全了解 浙江大学 有权保留并向国家有关部门或机构送交本论文的复印件和磁盘，允许论文被查阅和借阅。本人授权浙江大学可以将学位论文的全部或部分内容编入有关数据库进行检索和传播，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。

（保密的学位论文在解密后适用本授权书）

学位论文作者签名：

施淑涵

导师签名：

蔡云龙

签字日期：

2023年3月9日

签字日期：

2023年3月9日

致 谢

在浙江大学的学习生活接近尾声，衷心感谢这一路陪伴我的老师、同学以及家人们，是你们促使我不断进取成长。

感谢智能通信网络与安全研究所的各位老师。感谢赵民建教授春风化雨的潜移默化，赵老师渊博的学识见解与儒雅的个人风度时刻感染着我。感谢导师蔡云龙教授的指导与帮助，蔡老师耐心的指导与温和的敦促是我顺利完成硕士学位攻读的保障，蔡老师在科研生活中提出的宝贵意见让我受益匪浅。感谢刘安老师、李旻老师、赵明敏老师、邵红霞老师在学习与生活中的教导与关照。

感谢实验室的同学们。感谢胡棋昱师兄对我的无私指导与关照，感谢徐凯迪师兄、刘彦桢师兄、康凯师弟的帮助与关心，与你们同门让我受益颇丰。感谢和我共同进入实验室的程鹏远硕士、武梦雨硕士、罗群平硕士、王乾坤硕士、倪甫田硕士、邵雨航硕士、刘屹豪硕士、郑宇涛硕士、段伟骏硕士、陆旻硕士、张凤娇硕士、施之煜硕士、邱伏韬硕士、李文瑞硕士、杨蕊硕士、万雨博博士、胡智祥博士，感谢和大家共度的学习、成长岁月，祝大家未来一番坦途。

感谢好友陪伴。感谢吴怡芄师姐的支撑相伴，感谢江智慧、甘旭、吴静怡、张依、王小蕾的关爱陪伴，感谢黄棵柯、周江越、段瑞、曹之魏的关心守护，感谢你们长久以来让我体会到的快乐，感谢你们的接纳包容，祝大家往后皆顺心遂意。

最后，感谢父母对我的无条件支持与付出，真诚地向您们道一声辛苦与感谢。感谢家人长辈的关心与爱护，祝愿大家身体健康，长长久久。

施淑涵

2023年3月

摘 要

信息全球化的今天，无线网络的数据容量需求急速攀升。毫米波（Millimeter-Wave, mmWave）的可用频段资源远超现有的通信系统，缓解了频谱短缺问题，因而引起了广泛的研究关注。但高频段通信也存在其缺点，即信号的路径衰减很大，为其实际应用带来了挑战。大规模多输入多输出（Multiple-Input Multiple-Output, MIMO）技术能够结合波束成形技术形成高指向性信号，从而抑制干扰并带来空间复用增益，有效克服了信号衰减难题。混合波束成形技术在保持高性能增益的同时能够减少硬件开销，是第五代移动通信（The 5th Generation, 5G）背景下波束赋形的首选。如何针对大规模MIMO系统设计低开销高效能的混合波束成形方案是一个值得探究的问题。

本文针对上述问题对物理层波束成形的关键技术展开研究，考虑了两个典型场景。第一个是单小区混合波束成形设计，不同于传统的最小均方误差（Minimum Mean-Square Error, MMSE）通信收发机，本文从信号传输可靠性出发，直接基于误码率性能进行算法设计，并辅以深度展开神经网络（Neural Network, NN）进行优化，实现算法复杂度的降低。第二个是多小区协同用户调度和混合波束成形设计，着眼于多小区协作通信架构实际落地的诸多开销限制，对该场景下的低复杂度协同通信方案进行了深入研究。

具体的，针对第一个场景，本文基于最小化误码率（Minimum Symbol Error Rate, MSER）准则建模了混合收发机设计问题，并提出了一种基于MSER的迭代梯度下降（Gradient Descent, GD）算法来寻找原问题的驻点。为了减少迭代次数，本文基于上述GD算法提出了一种深度展开算法，将迭代算法展开为多层结构，其中引入了可训练参数以加速收敛并提高系统整体性能，并在训练阶段基于广义链式法则（Generalized Chain Rule, GCR）推导了相邻层梯度之间的关系。本文针对正交相移键控（Quadrature Phase Shift Keying, QPSK）和M元正交调幅（Quadrature Amplitude Modulated, QAM）信号提出了深度展开网络，并从理论上研究了其收敛性。此外，本文还分析了所提出的深度展开算法的传输能力、计算复杂度和泛化能力。仿真结果表明，深度展开NN性能显著优于传统的MMSE相关算法，并以大大降低的复杂度逼近迭代MSER算法的性能。

在第二个场景中，本文对多小区协同架构下的联合用户调度和混合波束成形设计提出

了解决方案。考虑到需尽可能地减少交互信息，降低反馈开销，本文首先对原始问题进行若干优化近似，并将其分解成两个子问题，通过迭代的方式对子问题进行求解。接着，为了平衡边缘用户容量和系统整体性能，本文提出了贪婪的比例公平算法求得用户调度策略。在固定该调度方案的情况下，设计了多种混合波束成形算法方案，并提出了低复杂度近似以进一步减少小区间协作量。仿真结果表明，本文提出的协同用户调度和混合波束成形算法有效抑制了小区间干扰，大幅提升了系统平均吞吐量。

本论文的研究成果为大规模MIMO系统中的混合收发机设计提供了一定的理论和实践基础，也为未来无线通信的进一步发展提供了一定的设计思路和理论支撑。

关键词：混合波束成形；深度展开网络；MSER；大规模MIMO；多小区协作；用户调度；干扰管理；机器学习

Abstract

With the globalization of information, the demand for data capacity of wireless networks is rising rapidly. The available frequency resources of millimeter-wave (mmWave) far exceed the existing communication systems, which alleviates the problem of spectrum shortage. Thus, the research of millimeter communication gets wide attention. But high frequency communication also has its shortcomings, that is, the serious path attenuation of the signal, which brings challenges to its practical application. Beamforming technology in large scale multiple input multiple output (MIMO) systems can form highly directional signals, which can suppress interference and bring spatial multiplexing gain. Thus, the problem of signal attenuation can be effectively solved. Hybrid beamforming can reduce hardware overhead while maintaining satisfied performance. Therefore, hybrid beamforming is the first choice in the 5th generation (5G). How to design a low-cost and efficient hybrid beamforming strategy for large-scale MIMO systems is a problem worth studying.

This paper focuses on the above problems and studies the key technologies of physical layer beamforming. Two typical scenarios are considered. The first one is the single cell hybrid beamforming design. Different from the traditional minimum mean square error (MMSE) communication transceiver, this paper directly designs the algorithms based on the bit error rate performance, which takes the reliability of signal transmission into consideration. Meanwhile, the deep unfolding neural network (NN) is utilized to reduce the computational complexity. The second scenario is the multi-cell coordinated user scheduling and hybrid beamforming design. Focusing on the cost overhead constraints of the actual implementation of multi-cell communication, the low complexity cooperative communication scheme is studied in this paper.

Specifically, for the first scenario, this paper mathematically formulates the problem of hybrid transceiver design under the minimum symbol error rate (MSER) optimization criterion and then develops an MSER-based iterative gradient descent (GD) algorithm to find the related stationary points. In order to accelerate the convergence, a deep-unfolding algorithm is proposed, where the iterative GD algorithm is unfolded into a multi-layer structure and several trainable parameters are introduced to improve the overall performance of the system. To implement the training stage, this

paper derives the relationship between adjacent layers' gradients based on the generalized chain rule (GCR). The deep-unfolding NN is developed for both quadrature phase shift keying (QPSK) and M-ary quadrature amplitude modulated (QAM) signals, and its convergence is investigated theoretically. Furthermore, the transfer capability, computational complexity, and generalization capability of the proposed deep-unfolding NN are analyzed. The simulation results show that the deep-unfolding NN significantly outperforms the traditional MMSE based algorithms and can approach the MSER iterative algorithms at a reduced complexity.

In the second scenario, the joint optimization of user scheduling and hybrid beamforming design under multi cell cooperative architecture is discussed in this paper. Considering the constraint of limited interactive information, the original problem is effectively approximated and is decomposed into two subproblems, which are solved iteratively. Then, in order to balance the capacity of edge users and the overall system performance, a greedy proportional fairness algorithm is proposed to obtain the user scheduling strategy. Several hybrid beamforming algorithms are designed with the fixed scheduling scheme. Specially, a low complexity approximation is proposed to further reduce the collaboration overhead. The simulation results show that the proposed joint user scheduling and hybrid beamforming scheme can effectively suppress inter-cell interference and greatly improve the average throughput of the system.

The research results in this paper provide a theoretical and practical basis for the design of hybrid transceiver in large-scale MIMO systems, as well as technical solutions and theoretical support for the further development of wireless communication in the future.

Keywords: Hybrid beamforming, deep-unfolding, MSER, massive MIMO, multi-cell coordination, user scheduling, interference management, machine learning.

插图

1-1	mmWave系统的混合波束成形结构.....	4
1-2	本文研究内容.....	8
2-1	LISTA算法结构图.....	16
2-2	JT模式结构图.....	19
2-3	DPS模式结构图.....	20
2-4	CS模式结构图.....	20
3-1	大规模MIMO系统下行链路系统模型.....	24
3-2	GD迭代算法结构图.....	28
3-3	深度展开神经网络结构图.....	30
3-4	CNN黑盒算法结构图.....	36
3-5	深度展开算法收敛性能.....	40
3-6	不同算法的SER性能($R_{r,k} = 4, D = 3$).....	41
3-7	不同算法的收敛性能.....	41
3-8	不完美CSI下的SER性能.....	43
3-9	迁移学习能力.....	43
3-10	16-QAM信号的SER性能.....	45
3-11	迁移学习能力.....	45
4-1	信道反馈完美下的小区平均和边缘吞吐量.....	61
4-2	Type I反馈下的小区平均和边缘吞吐量.....	62
4-3	Type II反馈下的小区平均和边缘吞吐量.....	63
4-4	贪婪初始化调度下的小区平均和边缘吞吐量.....	64
4-5	小区平均和边缘吞吐量与迭代次数关系.....	64
4-6	2RB EZF方案的小区平均和边缘吞吐量.....	65

4-7	5RB EZF方案的小区平均和边缘吞吐量	65
4-8	不交互信息方案的小区平均和边缘吞吐量	66
4-9	整体优化和矩阵分解方案的小区平均和边缘吞吐量	66
4-10	干扰不近似方案的小区平均和边缘吞吐量	67
4-11	2 bit量化模拟波束成形矩阵的小区平均和边缘吞吐量	68
4-12	优化2 bit量化模拟波束成形矩阵的小区平均和边缘吞吐量	68

表 格

3-1	不同算法的SER性能与SNR和迭代次数/层数的关系	42
3-2	不同规模MIMO系统的SER性能	42
3-3	不同训练样本数下的SER性能	42
3-4	不同算法的CPU运行时间	44
3-5	深度展开算法的泛化性能	44
3-6	SER性能与迭代次数/层数的关系	44
4-1	仿真参数	58
4-2	Proposed-HBF算法对基线算法的平均增益	60
4-3	Proposed-HBF算法对基线算法的边缘增益	61
4-4	Type I反馈时Proposed-HBF算法对基线算法的平均增益	62
4-5	Type I反馈时Proposed-HBF算法对基线算法的边缘增益	62
4-6	Type II反馈时Proposed-HBF算法对基线算法的平均增益	63
4-7	Type II反馈时Proposed-HBF算法对基线算法的边缘增益	63

缩写、符号清单、术语表

缩略词	英文全称	中文全称
5G	The 5th Generation	第五代移动通信
AD	Analog-Digital	数模
B5G	Beyond 5G	超5G
BCD	Block Coordination Descent	块坐标下降
BN	Batch Normalization	批标准化
BP	Back Propagation	后向传播
BPSK	Binary Phase Shift Keying	二进制相移键控
BS	Base Station	基站
CBF	Coordinated Beamforming	协作波束成形
CNN	Convolutional Neural Network	卷积神经网络
CoMP	Coordinated Multi-Point	多点协作
CS	Coordinated Schedule	协作调度
CSI	Channel State Information	信道状态信息
DFT	Discrete Fourier Transform	离散傅里叶变换
DNN	Deep Neural Network	深度神经网络
DPS	Dynamic Point Selection	动态节点选择
FD	Fully-Digital	全数字
FDD	Frequency Division Duplexing	频分双工
FP	Forward Propagation	前向传播
GCR	Generalized Chain Rule	广义链式法则
GD	Gradient Descent	梯度下降
ISTA	Iterative Shrinkage and Thresholding Algorithm	迭代收缩阈值算法
JP	Joint Processing	联合处理
JT	Joint Transmission	联合传输

缩略词	英文全称	中文全称
LISTA	Learned Iterative Shrinkage and Thresholding Algorithm	可学习迭代收缩阈值算法
MIMO	Multiple-Input Multiple-Output	多输入多输出
MISO	Multiple-Input Single-Output	多输入单输出
MMSE	Minimum Mean-Square Error	最小均方误差
mmWave	Millimeter-Wave	毫米波
MO	Manifold Optimization	流形优化
MSE	Mean-Square Error	均方误差
MSER	Minimum Symbol Error Rate	最小化误符号率
NN	Neural Network	神经网络
OMP	Orthogonal Matching Pursuit	正交匹配追踪
PDF	Probability Density Function	概率密度函数
PE-AltMin	Phase Extraction Alternate Minimizing	相位提取交替最小化
QAM	Quadrature Amplitude Modulated	正交调幅
QPSK	Quadrature Phase Shift Keying	正交相移键控
RB	Resource Block	资源块
RNN	Recurrent Neural Network	循环神经网络
RF	Radio Frequency	射频
SER	Symbol Error Rate	误码率
SGD	Stochastic Gradient Descent	随机梯度下降
SINR	Signal-to-Interference-Plus-Noise Ratio	信干噪比
SNR	Signal-to-Noise Ratio	信噪比
SVD	Singular Value Decomposition	奇异值分解
WMMSE	Weighted Minimum Mean-Square Error	加权最小化均方误差

目 次

致谢	I
摘要	II
Abstract.....	IV
插图	VI
表格	VIII
缩写、符号清单、术语表.....	IX
目次	
1 绪论.....	1
1.1 研究背景和意义	1
1.1.1 波束成形技术与MSER准则概述	1
1.1.2 深度展开算法概述	2
1.1.3 多小区干扰管理问题	3
1.2 国内外研究现状及分析	4
1.2.1 混合波束成形与MSER准则研究现状	4
1.2.2 深度展开算法研究现状	5
1.2.3 多小区干扰管理研究现状	6
1.3 论文的主要内容与结构安排	8
1.3.1 主要研究结论及创新点	8
1.3.2 内容安排	10
2 混合波束成形关键技术.....	11
2.1 mmWave波束成形技术	11
2.1.1 mmWave传输特性	11
2.1.2 基于MSER的波束成形技术	13
2.1.3 深度展开算法模型	15
2.2 多小区干扰管理策略	17

2.2.1	联合处理方案	18
2.2.2	协作调度方案	19
2.2.3	协作波束成形方案	21
2.3	本章小结	22
3	基于MSER的混合波束成形设计	23
3.1	系统模型	23
3.2	基于MSER准则的GD迭代算法	25
3.2.1	MSER准则	25
3.2.2	GD迭代算法	26
3.3	深度展开神经网络	29
3.3.1	前向传播	29
3.3.2	后向传播	30
3.4	性能分析	32
3.4.1	收敛性分析	32
3.4.2	CNN黑盒算法	35
3.4.3	复杂度分析	36
3.4.4	泛化能力分析	37
3.4.5	M -QAM信号拓展	37
3.5	仿真结果	38
3.5.1	仿真设置	38
3.5.2	深度展开算法收敛性能	39
3.5.3	QPSK信号SER性能	39
3.5.4	16-QAM信号SER性能	44
3.6	本章小结	45
4	多小区协同用户调度和混合波束成形设计	47
4.1	系统模型	47
4.2	整体算法描述	48
4.2.1	问题建模	48
4.2.2	整体算法	49
4.3	用户调度设计	50
4.4	混合波束成形设计	51
4.4.1	干扰迫零	51

4.4.2	干扰迫零的低复杂度近似	54
4.4.3	整体优化和矩阵分解	56
4.4.4	接收波束成形矩阵设计	58
4.5	仿真结果	58
4.5.1	仿真设置	58
4.5.2	性能表现	60
4.6	本章小结	68
5	工作总结和展望	70
5.1	工作总结	70
5.2	进一步展望	71
	参考文献	72
	附录	77
A.1	第三章可训练参数的梯度	77
	攻读硕士学位期间参研项目和主要成果	78

1 绪论

1.1 研究背景和意义

1.1.1 波束成形技术与MSER准则概述

随着信息全球化的进程加快，无线网络的数据容量需求迅速攀升，毫米波（Millimeter-Wave, mmWave）远超现有通信系统的可用频段资源被投以巨大关注，毫无疑问，它能够缓解频谱短缺难题，但其缺点同样瞩目，即信号的路径衰减很大，为其实际应用带来了挑战。幸运的是，大规模多输入多输出（Multiple-Input Multiple-Output, MIMO）技术能够通过形成定向波束大幅提高信号质量并抑制干扰，同时，mmWave的短波长使其能够在小尺寸内实现大规模天线阵列，从而带来大量空间复用增益，克服信号衰减的问题。

波束成形技术是智能天线的核心，其设计直接影响着天线的增益、干扰抑制等性能。从处理信号的实现形式角度进行划分，波束成形技术可以被分为数字波束成形技术、模拟波束成形技术和混合波束成形技术。从数学领域的视角来看，无论是数字波束成形还是模拟波束成形，本质上都是对多路相同信号的幅度、时延、频率和相位做出合理调整，形成的多路信号被送至多路天线，由相异的天线阵元独立辐射后，在所处空间内叠加成目标方向图。数字波束成形和模拟波束成形技术的差别主要在于对各路信号的幅度、时延、频率和相位做出调整的实际过程是在数字域还是模拟域上。在不同域上调整的实现难度、精度改进、功耗控制、占用面积、成本等方面均有差异。数字波束成形技术和模拟波束成形技术出现在前，但在传统的全数字（Fully-Digital, FD）波束成形架构中，每个天线单元都需要专用射频（Radio Frequency, RF）链，到了第五代移动通信（The 5th Generation, 5G）时代，发射机和接收机均采用大规模天线阵列，无法承受每个天线都连接一个RF链的高成本及能耗。模拟波束成形虽结构简单，但其处理精度又受到硬件设备的限制。因此，数字和模拟兼备的混合波束成形技术逐步出现在大众的视野中。混合波束成形结合了两者的优势，将低维数字处理与模拟预处理相结合，是目前公认的降低大规模MIMO系统中硬件开销和训练成本的最有前途的方法之一。

传统的通信收发机通常将均方误差（Mean-Square Error, MSE）作为优化性能指标，

从数字通信性能角度来看，这并非最合适的度量。在数字通信中，误码率（Symbol Error Rate, SER）是最常用的数据传输质量指标，也是衡量信息传输可靠性的重要指标。在某些场景中，最小均方误差（Minimum Mean-Square Error, MMSE）准则确实会直接自动实现SER的最小化，但这种情况较少出现，尤其是在信道矩阵为非满秩的情况下。例如，当发射天线数多于接收天线数时，信道矩阵为不可逆，此时MMSE不再使得SER最小化。在最近几十年，随着对通信可靠性的要求越来越高，最小化误码率（Minimize Symbol Error Rate, MSER）的概念和准则已经引起了重视，并在无线通信领域得到了一定的应用。

1.1.2 深度展开算法概述

MSER相关算法通常伴随着高复杂度计算，尤其是在采用大规模MIMO技术的无线通信系统中，系统规模的增大会带来许多算法方面的问题，通常需要大量迭代来达到收敛。而在超5G（Beyond 5G, B5G）背景下的应用场景和用户需求要求能够利用实时信息优化网络运行，以提供高质量的服务。基于以上高吞吐、自适应的需求，深度学习算法对复杂映射的处理能力引起了关注。与传统算法不同，深度学习算法从训练样本中提取有效信息并自适应地训练网络模型。深度学习神经网络通常由一系列线性计算层和激活函数堆叠而成，如自编码器，卷积神经网络，生成对抗网络等，其结构中包括大量参数，因此能够学习难以准确推导的复杂映射。当训练数据足够多时，该自适应性使得深度网络能够克服传统算法模型的不足。此外，许多神经网络训练平台对特殊操作（如卷积）进行了高度优化，同时可支持并行处理、硬件加速，这些特点大大加速了深度学习算法在训练过程中的执行速度。更重要的是，深度学习网络中的层数通常远小于迭代算法中所需的迭代次数，因此，深度学习解决方案在通信领域备受关注。

但经典深度学习模型也存在显而易见的缺点，即缺乏可解释性。现有深度学习算法研究偏向于将通用的网络架构用于不同场景和问题，并完全通过端到端训练学习映射关系，其中间过程通常被视为黑盒，难以可视化和解释。相比之下，传统迭代算法则是高度可解释的，因为它们是通过建模问题背后的物理过程并利用领域中的先验知识来设计推导的。可解释性在理论和实践中都是一个重要维度，它通常是概念理解和推动知识发展的关键，因此，缺乏可解释性会严重限制传统的深度学习算法。除此之外，深度学习网络有时过度依赖于训练数据的数量和质量。在无法获得大量高质量训练样本的情况下，深度学习网络的性能会显著下降，甚至可能比传统算法更差。因此，将先验知识与网络参数相结合以寻求可解释、可推广和高性能的深度学习架构仍然是一个非常重要的挑战。

深度展开模型的出现为迭代算法与神经网络模型的结合构建了桥梁。深度展开模型指由非线性迭代算法展开而成的一类深度学习模型，通常由多个重建模块组成，每一个模块对应非线性迭代算法中的一次迭代。有许多非线性迭代算法被展开成了深度展开模型，包括近似消息传递^[1]、交替方向乘子法^[2]等。深度展开算法中的可训练参数传递给网络参数，并通过反向传播来训练网络，因此模型参数可以从训练集中提取有效特征并得到良好训练。通过这种方式，深度展开模型在保持经典深度学习算法高性能的同时拥有优化模型驱动算法的可解释性，在各个领域都有着良好的表现。但同样的，深度展开网络需要的模型参数总数往往很大，会给硬件带来一定的压力。此外，如何有效利用先验知识和迭代算法的结构进行网络设计以最大化提高性能增益也亟待讨论。本文针对单小区MIMO系统考虑了基于MSER准则的混合波束成形方案，并采用深度展开模型进行收敛速度优化，使其能满足高速实时通信要求。

1.1.3 多小区干扰管理问题

传统的波束成形算法研究通常侧重于单小区场景，例如当前的权值算法只考虑如何将波束更好地对准小区内的调度用户，并没有考虑到对邻区的干扰。在实际中，由于基站和移动设备的密集部署，大规模MIMO系统的通信性能会受到强烈的共信道干扰。由于无线信道的广播性质，发射方的发射功率不仅用于将信息传递到目标接收方，同时也会在无意中对其他接收方产生干扰。在某些场景下，这种单小区波束成形设计方案对小区内调度用户的速率提升还没有对邻区用户造成的速率下降多，从而导致整体性能下降。干扰管理已日益成为当今大规模MIMO通信系统中的重点问题，更是在无线网络和有线网络中实现有效频率复用的一项关键技术。

在LTEAdvanced等标准化工作中，已考虑通过用户调度、波束成形和功率分配等手段实现多小区干扰管理^[3]。然而，大多数现有研究只侧重于其一进行设计。在实际系统中，多小区干扰通常同时与多种因素密切相关，系统性能的提升需要多维度联合优化，但目前来说，多种方案联合优化仍是一个具有挑战性的问题。对于无限蜂窝网络来说，在一个扇区内选择最佳活跃用户集本质上是一个组合问题，同时会引入离散变量。此外，固定用户调度时的波束成形设计和功率分配优化是一个众所周知的非凸问题。在多小区基站（Base Station, BS）协作中，多个BS的多天线被认为构成了一个大天线阵列，来自多个BS的天线需要联合发射信号和接收用户信号进行设计，因此多个用户的数据流必须在多个BS之间共享，这要求高容量回程通信资源，而该要求在实际通信中难以实现。因此，多小区协同用户调度与波束成形设计问题在优化设计和具体实现时都具有很大挑战。本文对该问题给出了有效的解决方案。

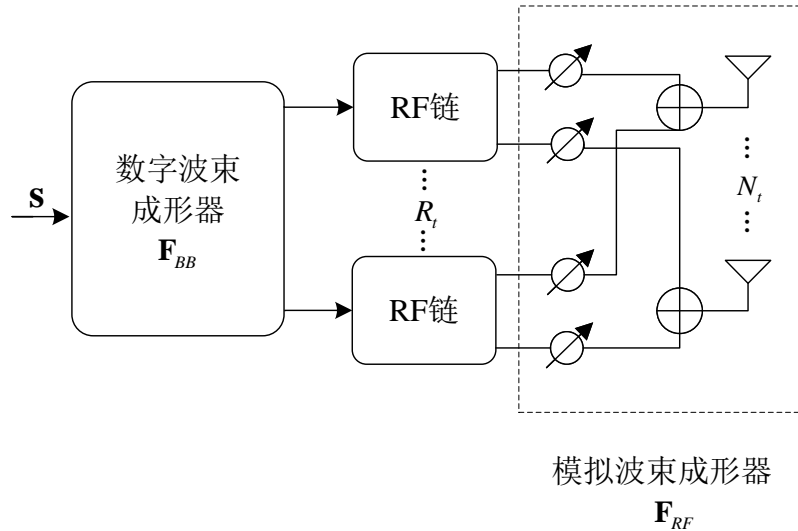


图 1-1 mmWave系统的混合波束成形结构

1.2 国内外研究现状及分析

近几年，工业界和学术界关于波束成形技术的研究已经取得了一定进展。如前所述，5G时代通常采用混合波束成形架构，面向不同的无线通信系统场景，学界已提出了多种有效的混合波束成形算法。本节将主要介绍近年来在单小区混合波束成形设计、其与深度展开算法相结合以及多小区波束成形设计方面的相关工作。

1.2.1 混合波束成形与MSER准则研究现状

mmWave丰富的频谱资源有效缓解了频谱短缺问题，但其高频率也导致了信号的路径衰减很大，为其实际应用带来了挑战。大规模MIMO技术能够通过形成定向波束大幅提高系统容量，同时mmWave由于波长很小，可以在很小的尺寸内集成大量天线，从而结合波束成形技术获得大幅空间增益，有效弥补了信号衰减损失。然而，在传统的FD波束成形架构中，发射机和接收机均采用大规模天线阵列，且每个天线单元都需要专用RF链，而RF链的造价高，功耗大，很难实现每个天线都连接一个RF链。因此，混合波束成形策略广受关注，该技术能在显著减少RF链数量的同时仍可达到近乎FD波束成形算法的性能。在混合数模（Analog-Digital, AD）波束成形架构中，每个天线都连接了一个移相器，这使得模拟端也能够进行相位、幅度等波束成形处理，因此一个RF链可以连接多根天线，从而达到减少RF链数量的目的^[4-15]。其具体结构如图1-1所示。

混合波束成形技术在概念上依赖于将波束成形矩阵分解为低维数字波束成形矩阵和高维模拟波束成形矩阵，其中模拟波束成形矩阵的元素受制于移相器施加的恒模约束。

为了减少RF链的数量，Zhang、Sudarshan等人在文献[5, 6]中提出了基于天线选择的混合波束形成算法。为了进一步提高其性能，Kin、Ayach等人在文献[4, 7]中利用mmWave的信道特性开发了稀疏空间预编码技术。此外，文献[8]的作者证明，具有RF链数量为数据流数量两倍的混合AD波束形成算法具有接近FD波束形成算法的性能。受上述发现的启发，Ayach等人在文献[7, 9–15]中提出了用于混合波束形成的复杂优化算法。在文献[7]中，Ayach等人利用信道的稀疏性提出了一种基于正交匹配追踪（Orthogonal Matching Pursuit, OMP）的优化算法。在此基础上，文献[9–11]的作者开发了基于MMSE准则的混合收发机架构。在文献[12]中，Yu等人将原问题转化为矩阵分解问题，并设计了一种基于流形优化（Manifold Optimization, MO）的混合波束形成算法，其中恒模约束被视为黎曼流形。在文献[13]中，He等人提出了一种基于码本的混合波束形成设计，以此来最大限度地提高系统的频谱效率。文献[14]的作者开发了一种基于一般特征分解法的两阶段优化算法，并且将此算法和MO算法结合，进一步拓展到了宽带场景^[15]。

然而，大多数现有研究中的混合波束形成设计都是基于MMSE准则的，但在数字通信中，SER是更能衡量通信可靠性的指标。仿真分析和理论证明显示即使均方误差性能达到最优，误码率性能却不一定被优化到最小，例如在信道矩阵不满秩的情况下，信道矩阵为不可逆，此时MMSE不再使得SER最小化。鉴于此，最近有不少学者基于MSER准则设计了若干有效的波束形成算法^[16–20]。文献[16]和文献[17]的作者提出了一种基于MSER的自适应降秩接收波束形成器来有效提高系统性能。Shao等人在文献[18]中提出了一种基于单比特MSER优化准则的波束成形矩阵，以达到简化RF链的目的。文献[19]的作者设计了一种干扰辅助波束成形矩阵，用于最小化系统中最坏情况用户的SER。作为进一步拓展，Nguyen等人在文献[20]中基于不当信号对 K 对MIMO干扰信道设计了MSER波束成形矩阵。然而，MSER准则本身会带来高维矩阵求逆或分解等高复杂度计算，同时伴有非凸的约束条件，这都使得现有的优化算法在实际实现中具有很高的难度。

1.2.2 深度展开算法研究现状

为了降低传统算法的计算复杂度同时不损失系统性能，研究人员最近将注意力转向了机器学习相关算法。这些算法被广泛应用于各个领域，如信道解码^[21]、端到端通信^[22, 23]和信道估计等^[24]。经过训练的神经网络（Neural Network, NN）能够有效学习系统输入和输出之间的映射^[25–30]，表现出良好的性能。该思路的最早期尝试之一出现在文献[25]中，Sun等人基于迭代加权MMSE（Weighted MMSE, WMMSE）算法训练NN，并用该网络实现了系统的功率分配。文献[26]的作者Lee等人提出了一种两阶段训练机制，应用卷积神经网络（Convolutional Neural Network, CNN）来最大化和速率，并通过无监督学习进一

步提高系统性能。在文献[27]中, Liang等人采用了若干个全连接深度神经网络(Deep Neural Network, DNN)的集成架构来优化发射功率分配。文献[28]的作者Elbir等人将联合天线选择和混合波束成形设计问题建模成了一个分类问题, 并提出了深度CNN解决方案。在文献[29]中, 深度学习被用于联合优化压缩信道和混合波束成形矩阵。在文献[30]中, Sidharth等人受GoogleNet的启发设计了一种新的神经网络结构, 该网络使用并行复数卷积块进行混合波束成形设计。

在上述研究中, 网络通常被视为黑盒, 外界只能明确其输入和输出, 对中间过程的可解释性及控制都较为缺乏, 性能也无法得到保障。此外, 在大规模MIMO系统中, 上述算法方案需要高维的训练样本, 这会导致较长的训练时间和较高的训练开销。文献[31]中, Hershey等人提出了一种模型驱动的网络用以克服这些问题, 该网络被称为深度展开神经网络, 它通常将迭代算法展开为多层神经网络, 并引入一组可训练参数来加速收敛, 同时提高系统性能。文献[32]和文献[33]的作者应用这种方法展开了梯度下降(Gradient Descent, GD)算法用于数据检测。Xu等人在文献[34]和文献[35]中基于归一化最小和速率算法设计了一种深度展开方案来解码极性码。在文献[36]中, Ito等人提出了一种基于深度展开的稀疏信号恢复算法。在文献[37]中, Balatsoukas等人采用了深度展开算法来自动优化基于一比特数模转换器的预编码器。文献[38]的作者设计了基于共轭GD优化算法的深度展开神经网络, 用以实现恒包络预编码。在文献[39]中, He等人将迭代离散估计算法展开为多层神经网络, 并提出了有限字母预编码器。在文献[40]中, Hu等人推导了矩阵的广义链式法则(Generalized Chain Rule, GCR), 并提出了一种基于WMMSE优化算法的深度展开神经网络。

1.2.3 多小区干扰管理研究现状

上述混合波束成形设计均集中在单小区场景内, 只考虑了如何将波束更好地对准小区内的调度用户, 并没有考虑到对邻区的干扰。当考虑多小区共用时频资源时, 干扰被认为是限制无线网络性能的最关键因素之一。现有研究中已出现多种干扰管理方案, 总体可分为两类——干扰利用和干扰管理^[41, 42]。前者主要思想为利用小区间的信息来解码信号, 通常这类系统的BS间共享信道状态信息(Channel State Information, CSI)和小区内用户信号等数据。文献[43]的作者Shamai等人首次研究了多小区协作下行链路信道, 并将脏纸编码应用于单入单出系统的理想回程网络。对于MIMO干扰利用的首次研究为文献[44], Zhang等人提出了BS协作联合传输方案来减轻同信道干扰。然而, 干扰利用相关方案在应用中具有很大挑战, 它要求较高的容量回程通信和BS间同步信息, 在实际中, 系统很难满足其要求。而干扰抑制则是通过功率分配、波束形成和用户调度等方法减少

来自相邻小区信号的影响,通常无需BS协作及用户数据共享。Farrokhi等人在文献[45]中首次考虑了多小区场景下的联合发射信号波束形成和功率控制问题,并提出了一种基于上行链路-下行链路对偶性的迭代算法,以此来优化波束形成向量和功率分配方案。在文献[46]中,Dahrouj等人从拉格朗日理论出发,基于文献[45]中发现的对偶性解决了多小区下行链路中所有BS的协同波束成形问题。在文献[47]中,Botella等人考虑了多小区宽带码分多址系统的联合功率控制和最优波束形成算法设计问题,并提出了两种不同的波束成形方法来抑制干扰及提高系统容量。此外,在文献[48]中,Cao等人将MIMO系统中多址空间调制的预编码设计问题建模为无约束问题,并基于原始对偶最优性理论提出了一种新颖有效的预编码算法。

在多用户系统中,合理的用户调度可以有效抑制干扰并带来系统增益,如复用增益、多用户分集增益、用户之间的公平性等。文献[3]的作者介绍了多种MIMO系统的用户调度算法,并讨论了如何在频率资源复用和多用户分集增益之间取得平衡。在文献[49]中,Choi等人理论分析了路径损耗、阴影、用户位置和同信道干扰等因素对多小区协同调度及多用户分集增益的影响,并证明了用户调度可实现广义上的多用户分集增益。在文献[50]中,Kelly等人考虑了和速率和公平性之间的权衡,并提出了一种在实践中被广泛应用的调度方法——比例公平算法。在文献[51]中,Kiani等人提出了功率匹配调度以最大化系统容量。

上述文献大部分单独考虑了波束成形设计或用户调度设计,显然将两者联合优化设计能在抑制小区间干扰上表现出更好的性能,但这非常具有挑战性。固定用户调度时的波束成形设计已经是高度非凸问题,而用户调度又会引入额外的离散变量,并将波束成形矩阵耦合在一起,因此难以求得联合优化问题的全局最优解,现有研究大多转而求其次优解。文献[52]的作者设计了一种基于聚类的自适应反馈波束成形,并采用了改进的比例公平算法以满足服务质量要求。在文献[53]中,Han等人提出了一种用于多输入单输出(Multiple-Input Single-Output, MISO)网络的联合波束成形和用户调度算法。在所提算法中,首先基于空间信道相关信息对用户进行分组,并用比例公平算法贪婪地调度用户,然后采用分步波束成形方法来抑制干扰并获得空间复用增益。对于大规模MIMO系统中受小区间干扰影响的小区边缘用户,文献[54, 55]的作者提出了新的联合优化算法方案。在文献[54]中,Yang等人基于空间维度设计了小区边缘感知迫零波束成形算法,该算法在抑制小区间干扰和提高数据速率方面均表现良好。文献[55]的作者Ni等人在此基础上提出了具有块对角化的边缘感知迫零波束成形算法,并通过两层异构网络中的空间自由度来抑制干扰。

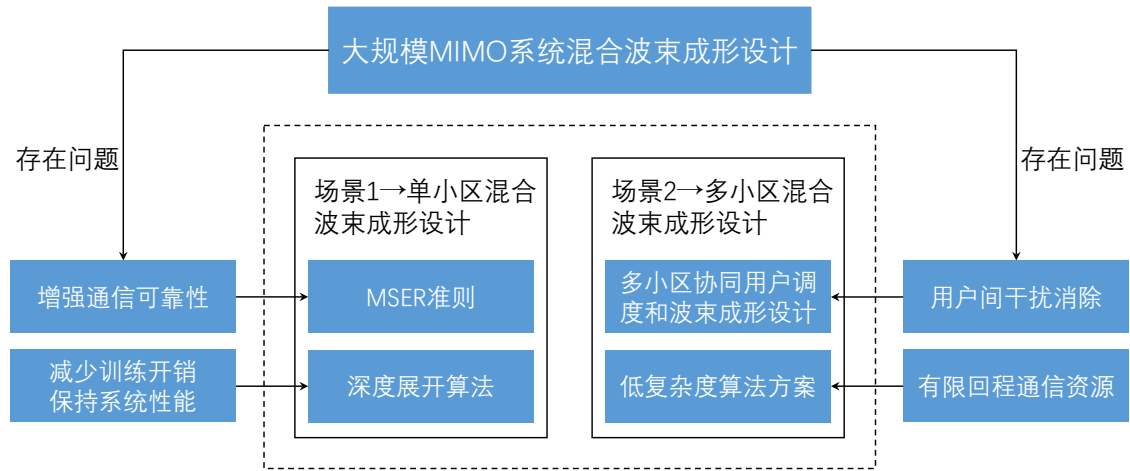


图 1-2 本文研究内容

1.3 论文的主要内容与结构安排

如前所述，关于大规模MIMO系统中高效能混合波束成形设计的关键技术仍面临许多挑战。比如在无线通信系统中，高频段的射频链路十分昂贵，因此通常采用混合波束成形架构，而混合波束成形矩阵优化是一个非凸的问题。出于进一步增强通信可靠性的目的，现有研究采用的MMSE相关方案并非最优解，MSE的最小化在大多数场景下无法实现误码率的最小化，但直接采用MSER准则会带来高度非凸的目标函数，对它求解极具困难。此外，为了满足现代高速通信系统的实时计算要求，需对传统算法的收敛速度进行优化，深度展开网络是一个备受关注的切入点。它结合了模型驱动算法的可解释性和传统迭代算法的高性能，能在大幅减少训练开销的情况下保持优良性能，但如何设计一个参数量小同时性能表现优异的有效网络也仍需继续思考。另外，多小区协同混合波束成形设计存在很多非理想因素，而大部分现有研究都将其忽略。例如，多个小区之间的协调需要大容量回程通信资源，在实际中考虑到链路开销，需要尽可能地减少小区间信息交互。另外，就问题设计本身来说，小区间干扰的存在导致问题结构具有非凸性，使问题求解难度很高。同时，用户调度需要与混合波束成形联合优化以尽可能地发挥多小区协同增益，但这会导致问题中包含离散变量，使该问题十分具有挑战性。上述提到的所有问题本身也是大规模MIMO通信系统中的关键问题，对上述问题提出解决策略对于大规模MIMO系统的发展具有启发意义。

1.3.1 主要研究结论及创新点

针对上述问题，本文对B5G大规模MIMO系统中的高效能混合波束成形设计进行了一系列研究，如图1-2所示。具体而言，论文对两个典型的场景进行了研究。第一个场景是

基于MSER准则的单小区混合波束成形设计，结合深度展开网络进行算法优化。第二个场景则是多小区协同用户调度和混合波束成形设计，考虑有限交互信息约束，提出有效的算法设计波束成形矩阵和资源分配方案，通过对通信与计算资源的联合优化分配提高系统吞吐率。主要研究结论及创新点如下：

1. 基于MSER的GD迭代算法

为了解决大规模MIMO系统中基于MSER准则的混合AD收发机设计问题，本文提出了一种GD迭代算法。由于目标函数和模拟波束形成矩阵恒模约束的高度非凸性，解决该问题非常具有挑战性。因此本文首先通过核密度估计和单位模矩阵的参数表示将原问题转化为无约束问题，随后设计了一种基于无约束MSER的GD迭代算法求得原问题驻点。此算法有效提高了大规模MIMO系统的误码率性能，进一步保障了无线通信系统的传输可靠性。

2. 基于MSER的深度展开算法

上述GD算法需要大量迭代来达到收敛，无法满足5G时代的实时计算要求。为了加速收敛，同时保证混合AD收发机的系统性能，本文基于上述迭代算法架构提出了一种基于MSER的深度展开神经网络。在该网络中，迭代算法被展开为多层结构，并引入了一组可训练参数以减少训练开销。由于用于训练神经网络的现有平台（例如Pytorch或Tensorflow）无法处理积分形式的损失函数，本文提出了一种用于计算梯度闭式解的更准确高效的新方法，该方法首先基于链式法则推导相邻层梯度之间的递归关系，然后基于此计算可训练参数的梯度。本文还为所提出的深度展开算法的收敛性提供了理论分析，该分析思路也可应用于其他深度展开神经网络。得到以下结论：所提出的深度展开神经网络的性能显著优于传统的深度学习网络的性能，前者性能可逼近基于MSER的GD迭代算法的性能，但其迭代次数远小于GD算法，这意味着该深度展开算法的计算复杂度得到了有效降低。

3. 多小区协同用户调度和波束成形设计

本文针对多小区协同架构下的联合用户调度和混合波束成形设计提出了解决方案。考虑到有限回程通信约束，本文首先对原始问题进行近似优化，并将其分解成两个子问题，通过迭代的方式对子问题进行求解。接着，本文提出了贪婪的比例公平算法求得用户调度策略。在固定该调度方案的情况下，本文设计了多种混合波束成形算法方案，并提出了低复杂度近似以进一步减少小区间协作量。此算法为多小区协同通信方案的联合优化提供了又一思路。

1.3.2 内容安排

本论文一共分为五章，每个章节的内容安排如下：

第一章为绪论，介绍了论文的研究背景与意义，概述了大规模MIMO系统中混合波束成形技术及其发展过程中遇到的挑战，并简要介绍了混合波束成形技术与MSER准则、深度展开算法与多小区干扰管理在通信中的研究现状，同时给出了论文的主要研究内容和结构安排。

第二章介绍了波束成形的关键技术，包括全数字波束成形和混合波束成形。随后给出了MSER准则下的波束成形设计数学模型和深度展开网络的设计原理及通用框架。最后概述了多小区干扰管理策略，并介绍了联合处理（Joint Processing, JP）与协作调度/波束成形（Coordinated Schedule / Coordinated Beamforming, CS / CBF）两种方案。

第三章研究了大规模MIMO系统中基于MSER的混合波束成形设计问题。首先提出了一种基于MSER准则的GD迭代算法，并将其展开为多层架构。然后在此基础上提出了一种深度展开算法，并对该算法的收敛性、复杂度及泛化能力进行了理论分析。最后对算法进行了仿真验证。

第四章研究了多小区协同架构下的联合用户调度和混合波束成形设计问题。首先将原问题进行优化近似，并分解为两个子问题。接着分别提出了两个子问题的解决方案，具体为采用贪婪的比例公平算法求解用户调度问题，并设计了多种混合波束成形算法提高信号的抗干扰能力。最后通过仿真进行了性能分析。

第五章是全文的总结和展望部分，总结了本论文的研究内容和成果，并对未来的研究方向进行了展望。

2 混合波束成形关键技术

本章由mmWave波束成形技术出发，分别介绍了mmWave传输特性及不同波束成形策略，并从通信可靠性角度出发，给出了基于MSER准则的波束成形设计问题模型。随后，为了降低传统通信算法的计算开销，本章提出了深度展开算法的通用框架并给出了切实的训练实现策略。最后，本章考虑了多小区架构下的协同通信方案，从JP和CS / CBF两个维度介绍了不同的干扰管理方法。

2.1 mmWave波束成形技术

频谱资源是无线通信的基础资源，日益增加的终端设备和通信需求使得常规频谱资源短缺，因此毫米波波段的空闲频谱资源开始获得广泛关注，学界和工业界对高频段通信的研究也进入快速发展阶段。高频段资源虽然可以弥补频谱拥挤，但其穿墙能力弱，导致了信号的路径衰减很大，移动通信系统的网络有效覆盖范围也随之减小。幸运的是，大规模MIMO技术能够提供空间增益和复用增益，并结合定向波束成形技术实现目标信号的增强，有效消除了共信道干扰。同时，mmWave由于波长很短，可以在有限空间内集成大量天线，进一步提高了大规模MIMO系统的信道容量和频谱效率。与此同时，5G时代对信号传输可靠性的要求也日益增高，传统MMSE波束成形架构无法保障误码率性能，MSER相关算法已引起重视。本节将简要介绍mmWave传输特性和波束成形技术，后者包括数字波束成形技术、模拟波束成形技术和混合波束成形技术，并给出了基于MSER准则的波束成形算法建模。为了加速传统算法的收敛性能，本节在最后对深度展开模型进行了介绍，描述了其设计原理并提出了通用框架。

2.1.1 mmWave传输特性

mmWave信道在时域和频域都是稀疏的，其稀疏性是后续波束成形算法设计的基础之一。

考虑mmWave通信系统的下行链路，其接收端的接收信号功率与发射端的发射信号功率比值为：

$$\frac{P_r}{P_t} = \frac{G_r G_t}{PL}, \quad (2.1)$$

其中， P_r 为接收信号功率， P_t 为总发射信号功率， G_r 表示接收端天线增益， G_t 表示发射端天线增益， PL 为毫米波路径损耗。研究表明， G_t 与发射端天线数成正比， PL 与收发机之间的距离 d 、发射波长 λ 和路径损耗系数 n 有关，而路径损耗系数是与天线特性及硬件设备有关的常系数，代表了系统的总体衰减或损耗。 PL 的表达式为

$$PL = 16\pi^2 \left(\frac{d}{\lambda}\right)^n. \quad (2.2)$$

由上式可知，弥补路径损耗可从增大发射功率、增加天线阵列增益与提高接收信号强度等方面考虑。

如前所述，mmWave信号的路径损耗很大且绕射能力差，导致了其路径稀疏，因此mmWave信道具有稀疏性且包含了通信环境的几何信息。通常采用Saleh-Valenzuela (S-V) 信道模型来描述mmWave信道^[56]。S-V模型的时变脉冲响应为

$$h(t) = \sum_{l=1}^L a_l e^{j\phi_l(t)} \delta(t - \tau_l), \quad (2.3)$$

其中， a_l 、 ϕ_l 和 τ_l 分别表示第 l 径的时变幅度、相位和时延， $L = N_{cl} N_{ray}$ 、 N_{cl} 和 N_{ray} 分别为散射簇和射线径的数目。假设MIMO系统中配备 N_t 个发射天线和 N_r 个接收天线，则频域的时变信道冲激响应为

$$\mathbf{H}(t, f) = \sqrt{\frac{N_t N_r}{L}} \sum_{l=1}^L \alpha_l e^{j2\pi(v_l t - \tau_l f)} \mathbf{a}_r(\theta_{r,l}, \phi_{r,l}) \mathbf{a}_t(\theta_{t,l}, \phi_{t,l})^H, \quad (2.4)$$

其中， α_l 是对应多径分量的信道增益，包含大尺度衰落和小尺度衰落。 τ_l 和 v_l 分别为多径分量的时延和多普勒频移。假设信道为广义平稳非相关散射，则多普勒频移很小，表达式可简化为

$$\mathbf{H}(f) = \sqrt{\frac{N_t N_r}{L}} \sum_{l=1}^L \alpha_l e^{-j2\pi\tau_l f} \mathbf{a}_r(\theta_{r,l}, \phi_{r,l}) \mathbf{a}_t(\theta_{t,l}, \phi_{t,l})^H. \quad (2.5)$$

若宽带足够小，则时延也可省略，最终窄带S-V信道模型为

$$\mathbf{H} = \sqrt{\frac{N_t N_r}{N_{cl} N_{ray}}} \sum_{i=1}^{N_{cl}} \sum_{j=1}^{N_{ray}} \alpha_{i,j} \mathbf{a}_r(\phi_{i,j}^r, \theta_{i,j}^r) \mathbf{a}_t(\phi_{i,j}^t, \theta_{i,j}^t)^H, \quad (2.6)$$

其中， $\alpha_{i,j}$ 为第 i 簇第 j 径信道的增益， $\phi_{i,j}^r$ 、 $\theta_{i,j}^r$ 、 $\phi_{i,j}^t$ 和 $\theta_{i,j}^t$ 分布表示到达和离开的方位角及仰角。当天线排列为均匀线性阵列时， $\phi = 0$ ， $\mathbf{a}_{ULA}(\theta) = \frac{1}{\sqrt{N}} [1, e^{j\pi \sin \theta}, \dots, e^{j\pi(N-1) \sin \theta}]^T$,

为了使上式表达更清晰，部分下标被省略。当天线为线性平面阵列时， $\mathbf{a}_{UPA}(\phi, \theta) = \frac{1}{\sqrt{N}} [1, \dots, e^{j\pi(m \sin \phi \sin \theta + n \cos \theta)}, \dots, e^{j\pi[(N_X-1) \sin \phi \sin \theta + (N_Z-1) \cos \theta]}]^T$ ，其中上式假设天线阵列放置在X-Z平面， N_X 和 N_Z 分别为X轴和Z轴上的天线元素数量，放置在其余平面的表达式类似可得。

2.1.2 基于MSER的波束成形技术

波束成形技术是指通过对多路相同信号的幅度、时延、频率和相位进行调整，形成多路信号，并将其送至多路天线，由相异的天线阵元独立辐射后，在所处空间内叠加成目标方向图。波束成形技术能对期望方向上的信号加强干涉，对其余方向上的信号减弱干涉，从而使目标信号以高度定向的方式传输至接收端，有效提高了接收信号功率，保障了信号质量，是无线通信系统中抑制干扰和提升系统速率的关键技术之一。

波束成形技术可分类三类：数字波束成形、模拟波束成形和混合AD波束成形。数字波束成形和模拟波束成形技术的差别主要在于对各路信号进行参数调整的实际过程是在数字域还是模拟域上。传统的MIMO系统多采用数字波束成形技术，它能够对幅度和相位同时进行处理，操作精度高，且支持多路信号的并行处理。但到了大规模MIMO系统中，发射机和接收机均采用大规模天线阵列，而数字波束成形要求每个天线单元都配备专用的RF链，由于RF链的造价高，功耗大，很难实现每个天线都连接一个RF链，因此FD波束成形难以推广到5G系统中。而模拟波束成形则是通过移相器来完成天线幅度或相位的调整，其硬件设备简单，一个移相器可连接多路信号，也因此会在容量上受到限制。且模拟波束成形完全依赖于硬件设备，其处理精度上限会受制于硬件精度，从而导致性能受到影响。混合波束成形技术吸收了上述两者的优势，将可调幅调相的模拟波束成形和基带的数字波束成形相结合，大大降低了硬件成本及复杂度，但其性能可逼近FD波束成形，因此混合波束成形策略广受关注。

波束成形技术主要致力于提高通信系统的信干噪比（Signal-to-Interference-Plus-Noise Ratio, SINR）以优化信号质量，而此问题是一个众所周知的非凸问题，无法保证其全局最优解。文献[57]将原问题转化为MMSE问题并提出了基于WMMSE交替优化的波束成形解决方案，该算法综合考虑了误码率与系统速率，并找到了系统容量的某一局部最优解，使其在上述两个方面均取得较好性能。事实上，传统的通信收发机通常采用MSE作为性能指标，在某些场景中，MMSE准则确实会直接自动最小化误码率，但更多情况下并非如此，比如在信道矩阵秩不足的情况下，当发射天线数多于接收天线时，信道矩阵为不可逆，此时MMSE不再使得SER最小化。在最近几十年，随着对通信可靠性的要求越来越高，

MSER的概念和准则已经引起了关注，并在无线通信领域得到了一定的应用。下面将简单介绍**MSER**准则下的波束成形问题建模。

考虑最简单的场景，假设系统中有 K 个用户和一个**BS**，**BS**处配备 N_t 个天线，每个用户处有 N_r 个天线。假设基站给用户发射的信号为单数据流，且均为二进制相移键控（**Binary Phase Shift Keying**, **BPSK**）调制，记给第 k 个用户发射的信号为 $b_k, 1 \leq k \leq K$ ，则发射信号向量为 $\mathbf{b} \triangleq [b_1, b_2, \dots, b_K]^T$ 。设发射端波束成形矩阵为 \mathbf{P} ，信道矩阵为 \mathbf{H} ，接收波束成形向量为 \mathbf{w} ，则经过信道后的信号为

$$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{n} = \mathbf{HPb} + \mathbf{n}. \quad (2.7)$$

接收机输出信号为

$$y = \mathbf{w}^H \bar{\mathbf{x}} + \mathbf{w}^H \mathbf{n} = \bar{y} + e. \quad (2.8)$$

其中， \mathbf{n} 为均值为0，方差为 $E[\mathbf{nn}^H] = \sigma_n^2 \mathbf{I}_{N_r}$ 的高斯白噪声。不失一般性地设第一个用户为目标用户，则 b_1 的恢复信号 \hat{b}_1 为

$$\hat{b}_1 = \begin{cases} +1, & \text{if } \Re\{y_1\} \geq 0 \\ -1, & \text{if } \Re\{y_1\} < 0. \end{cases} \quad (2.9)$$

对于给定的 b_1 ，共存在 $N_b = 2^{K-1}$ 种可能的发射序列组合，定义所有可能的发射符号向量的无噪声分量集合为

$$\mathcal{X} \triangleq \{\mathbf{b}^q, 1 \leq q \leq N_b\}. \quad (2.10)$$

同理，定义接收机输出信号的无噪声分量集合为 $\mathcal{Y} \triangleq \{\bar{y}^q = \mathbf{w}^H \mathbf{HPb}^q, 1 \leq q \leq N_b\}$ ，则其实部集合为

$$\mathcal{Y}_R \triangleq \{\Re\{\bar{y}^q\} = \Re\{\mathbf{w}^H \mathbf{HPb}^q\}, 1 \leq q \leq N_b\}. \quad (2.11)$$

由于系统的加性噪声服从于高斯分布，在给定 b_1 时，根据全概率公式，接收机输出信号实部的概率密度函数（**Probability Density Function**, **PDF**）为

$$f(\Re\{y\}|b_1) = \frac{1}{N_b \sqrt{2\pi \mathbf{w}^H \mathbf{HPP}^H \mathbf{H}^H \mathbf{w} \sigma_n^2}} \sum_{q=1}^{N_b} e^{-\frac{|\Re\{y\} - \Re\{\bar{y}^q\}|^2}{2\mathbf{w}^H \mathbf{HPP}^H \mathbf{H}^H \mathbf{w} \sigma_n^2}}, \quad (2.12)$$

其中， $\Re\{\bar{y}^q\} \in \mathcal{Y}_R$ 。对**PDF**积分可得 b_1 的**SER**为

$$\mathcal{P}_e(b_1) = \frac{1}{N_b \sqrt{2\pi}} \sum_{q=1}^{N_b} \int_{\frac{\text{sgn}(b_1) \Re\{\bar{y}^q\}}{\sqrt{\mathbf{w}^H \mathbf{HPP}^H \mathbf{H}^H \mathbf{w} \sigma_n^2}} e^{-s^2} ds. \quad (2.13)$$

基于上述推导，基于MSER的波束成形设计问题可建模为

$$\{\mathbf{P}, \mathbf{w}\} = \arg \min_{\{\mathbf{P}, \mathbf{w}\}} \sum_{k=1}^K \tilde{\mathcal{P}}_e(b_k). \quad (2.14)$$

由于目标函数和约束条件的高度非凸性，式(2.14)难以求得全局最优解，第3章中提出了一种GD迭代算法来求得原问题的驻点。

2.1.3 深度展开算法模型

在过往研究中，MSER相关算法未投入广泛使用的一个重要原因是其目标函数结构复杂，需要大量迭代才能达到收敛，无法适应高速实时通信要求。近年深度学习算法的发展为该问题打开了突破口，其在建立复杂映射方面的优越表现在学界和业界引起广泛关注。但随着相关研究的深入，学者发现深度展开网络在某些问题上并不能取得令人满意的性能，或者说深度学习网络的性能无法保障，并且其性能上限难以提升。事实上传统深度学习算法完全通过端到端的学习方法建立起输入与输出之间的映射关系，其性能受到训练数据质量的密切影响，在无法获得高质量大规模训练样本时，深度学习网络的性能表现甚至可能不如传统算法。而传统算法则是利用现实问题背后隐含的物理过程及领域先验知识建立问题的数学模型，并通过合适的优化算法得到模型的解决方案，因此传统算法难以处理复杂的映射关系，也经常无法求得问题的全局最优解。幸运的是，深度展开算法的出现为这类问题提供了解决方案，它有效结合了这两种策略，将领域先验知识与网络可训练参数相融合，在保持深度学习网络建立复杂映射能力的同时以可解释的方式获得求解策略，能以大幅减少的训练成本达到传统算法的优秀性能表现。

最早的深度展开算法雏形出现在Gregor等人的工作中^[58]，该论文通过端到端神经网络训练提高稀疏编码中迭代收缩阈值算法（Iterative Shrinkage and Thresholding Algorithm, ISTA）的计算效率，并设计了可学习ISTA（Learned ISTA, LISTA）方案，其算法结构如图2-1所示。可以看到，ISTA的每次迭代包含一个线性操作和一个非线性软阈值操作，后者模拟了常规深度学习网络中的ReLU激活函数。在图中，(a)子图与(b)子图之间的箭头代表了ISTA中一次迭代与LISTA中单层网络的对应性。因此，若将每次迭代一一映射到单层网络，并将这些网络层堆叠在一起，即形成了一个深度网络，而网络的每次执行相当于ISTA进行了多次迭代。ISTA展开为多层网络后，可应用反向传播从训练样本中提取信息并以此训练网络参数，即图中的 \mathbf{W}_e 和 \mathbf{W}_l 。Gregor等人通过仿真验证了LISTA与ISTA达到相近性能所需的时间缩小了20倍，大大减少了训练开销，同时保证了性能表现，为解决稀疏编码问题提供了一个有效的算法方案。事实上，在LISTA中，由于相同的参数在不




图 2-1 LISTA算法结构图

同层之间共享，生成的多层网络在架构上类似于循环神经网络（Recurrent Neural Network, RNN）。受LISTA启发，后续研究将网络结构拓展为不同层采取不同参数，下面将给出深度展开网络的通用框架。

设计深度展开网络包括三个核心步骤：设计迭代算法、嵌入可训练模块和理论分析。大部分现有工作将止步于前两个部分，事实上，由于在网络中引入了可训练模块导致了深度展开网络与原始迭代算法在架构上存在差异，即使传统迭代算法已有强大的理论支持，深度展开网络的收敛性仍很难证明。本文在3.4节中对深度展开算法的收敛性提供了理论分析，在本小节主要探讨前两个部分。

假设优化问题被建模为

$$\begin{aligned} \min_{\mathbf{X}} \quad & g(\mathbf{X}; \mathbf{Z}) \\ \text{s.t.} \quad & \mathbf{X} \in \mathcal{S}, \end{aligned} \quad (2.15)$$

其中， $g: \mathbb{C}^{m \times n} \rightarrow \mathbb{R}$ 为目标函数， $\mathbf{X} \in \mathbb{C}^{m \times n}$ 为优化变量， \mathcal{S} 是其可行域， \mathbf{Z} 是问题中的随机参数。为了解决该问题，一个迭代算法被提出。迭代算法即重复执行某些操作，将其迭代步骤表示为

$$\mathbf{X}^{t+1} = G_t(\mathbf{X}^t; \mathbf{Z}), \quad (2.16)$$

其中， $G_t(\cdot)$ 为第 t 迭代中变量 \mathbf{X}^t 到变量 \mathbf{X}^{t+1} 之间的映射函数。为了减少计算复杂度，引入可训练参数 λ ，同时由于 \mathbf{Z} 服从随机分布，需对 \mathbf{Z} 取期望，则原问题可转化为

$$\begin{aligned} \min_{\mathbf{X}} \quad & \mathbb{E}_{\mathbf{Z}} \{g(\mathbf{X}; \lambda, \mathbf{Z})\} \\ \text{s.t.} \quad & \mathbf{X} \in \mathcal{S}. \end{aligned} \quad (2.17)$$

将迭代算法中的每次迭代映射到单层神经网络中，并将有限层堆叠在一起，即实现了将迭代算法展开到深度网络中。事实上，经过良好训练的可学习参数通常在性能上表现优异，因此深度展开网络的一层可对应迭代算法中的若干次迭代。将被展开的深度网络表示

为

$$\mathbf{X}^{l+1} = \mathcal{G}_l(\mathbf{X}^l; \boldsymbol{\lambda}^l, \mathbf{Z}), \quad (2.18)$$

其中, $\mathcal{G}_l(\cdot)$ 深度展开网络第 l 层的更新规则, \mathbf{X}^l 和 \mathbf{X}^{l+1} 分别为第 l 层网络的输入和输出, \mathbf{Z} 为输入网络的固定参数, $\boldsymbol{\lambda}^l$ 为第 l 层网络中的可训练参数。在网络的训练阶段, 可通过后向传播 (Back Propagation, BP) 训练参数 $\boldsymbol{\lambda}^l$ 。由于现有神经网络训练平台可处理的函数类型有限, 本小节提出了一种更准确有效的计算梯度闭式解的新算法框架。简单来说, 该方法首先根据GCR推导变量 \mathbf{X} 相邻层梯度之间的递归关系, 随后基于此计算 $\boldsymbol{\lambda}^l$ 的梯度。推导 \mathbf{X}^{l+1} 与 \mathbf{X}^l 梯度之间的递归关系需进行如下操作

$$\text{Tr}(\mathbf{G}^{l+1} d\mathbf{X}^{l+1}) = \text{Tr}(\mathbf{G}^{l+1} \circ \mathcal{J}(\mathbf{X}^l; \boldsymbol{\lambda}^l, \mathbf{Z}) d\mathbf{X}^l), \quad (2.19)$$

其中, \mathbf{G}^{l+1} 和 \mathbf{G}^l 分别为 \mathbf{X}^{l+1} 和 \mathbf{X}^l 的反向梯度, $\mathcal{J}(\mathbf{X}^l; \boldsymbol{\lambda}^l, \mathbf{Z})$ 表示与 \mathbf{X}^l 、 $\boldsymbol{\lambda}^l$ 和 \mathbf{Z} 相关的某些矩阵运算操作表达式, 通常由 $\mathcal{G}_l(\cdot)$ 计算得到。随后, 可得到所需的梯度递推关系为

$$\mathbf{G}^l = \mathbf{G}^{l+1} \circ \mathcal{J}(\mathbf{X}^l; \boldsymbol{\lambda}^l, \mathbf{Z}). \quad (2.20)$$

再对更新规则两边关于 $\boldsymbol{\lambda}^l$ 和 \mathbf{X}^l 及 \mathbf{X}^{l+1} 进行同样的操作, 即可得到变量和可训练参数梯度之间的关系, 随后应用GCR即可得到每一层中可训练参数 $\boldsymbol{\lambda}$ 的梯度, 最后采用随机梯度下降 (Stochastic GD, SGD) 算法即可使参数得到训练。

与传统的通用神经网络相比, 深度展开网络中包含的参数数量显著减少, 且不同网络层中的参数值允许不同, 有效提高了收敛速率, 减小了训练开销。同时, 深度展开网络通常基于传统迭代算法设计, 充分利用了传统算法的结构优势, 这一设计准则使其能够同时兼备高度可解释性、可推广性和高性能。

2.2 多小区干扰管理策略

传统混合波束成形技术通常集中在单小区场景内, 而忽略了邻区的干扰影响。随着终端设备的增加和频谱的大量复用, 干扰成为限制无线网络性能的主要因素之一。特别地, 在多小区场景中, 为了缓解频谱短缺问题, 相邻小区处于同频组网模式, 即被分配以相同的频谱资源, 这在提高频谱效率的同时会带来严重的小区间干扰, 极大限制了小区边缘用户的性能表现, 进而导致系统整体性能下降。为了在提升中心用户速率的同时控制小区间干扰抬升, 保证用户之间的公平性, 3GPP组织引入了多点协作 (Coordinated Multi-Point, CoMP) 传输技术进行干扰管理^[59]。CoMP技术的核心思想是多个小区基站共同协作来实现某个用户的数据传输, 其中会涉及到不同基站间的信息共享。CoMP技术打破了小区的

界限，实现了多个小区共同为用户服务，充分考虑了边缘用户的性能受限问题，被视为提升无限蜂窝网络整体性能的关键技术之一。而根据基站间协作及信息共享的程度可以把CoMP技术分为JP和CS / CBF。

在JP模式中，不同BS之间共享CSI和各自用户的全部数据。在这种场景中，网络被看成是一个整体，所有BS相当于联合组成了一个虚拟的大BS，该大BS的多天线分布在不同地点，从而消除了小区间的物理限制。此时，多个BS处于完全相同的时频资源中，以完全协作的形式进行通信。该多小区系统等价于一个多用户MIMO系统，各BS通过各自的反馈链路获取交换信息后进行协作编译码，用户数据在所有链路中传输。JP模式能够最大限度地发挥多小区协作优势，对干扰的抑制效果显著。但这种策略依赖于低时延协同链路和极高容量的回程通信资源，其联合编译码算法的计算复杂度通常也较高，在实际部署中具有较大挑战。

而CS / CBF模式则只共享CSI，不共享用户数据信息，不同BS从用户反馈链路获得直连信道和干扰信道的CSI，根据调度策略或编译码方案决定各自小区内用户的信号传输，进而实现系统总体容量最大化。在该场景中，用户调度及波束成形方法仍然由各BS协作确定，协作调度可实现给互相干扰严重的用户分配不同的时频资源，获得相同时频资源的用户则可通过协作波束成形技术进行干扰迫零。和JP模式相比，CS / CBF模式对反馈链路和信息交互的要求大大降低，有效节省了系统开销。

2.2.1 联合处理方案

如上所述，JP模式在各协作BS间共享CSI及用户信息，以最大化协作增益。而根据数据信息传输是否同时进行，又可将JP模式分为联合传输（Joint Transmission, JT）和动态节点选择（Dynamic Point Selection, DPS）。

在JT协作机制中，不同协作BS将本地CSI和用户数据信息均发送至中央处理节点，并通过中央处理节点实现信息的完全共享，其结构如图2-2所示。该模式本质上相当于多个分布式天线阵列的单小区MIMO系统，用户接收到的来自其余小区的信号不再为干扰，反而可以为用户调度及波束成形策略提供有用信息，进而提升系统整体容量。各协作BS可以相干或不相干地为目标用户提供服务。相干传输是指在中央处理节点进行联合波束成形并同步传输至用户，非相干传输则在各小区分别进行波束成形设计。中央处理节点可将所有协作BS的天线看作为一个整体，这样即可应用单小区MIMO波束成形算法进行设计，以下给出JT模式的系统模型。




图 2-2 JT模式结构图

假设共有 K 个小区参与协作，记合集 $\mathcal{K} = \{1, 2, \dots, K\}$ 。 K 个BS通过反馈链路连接至中央处理节点，并由其进行集中式调度。设每个BS配备 N_t 个天线，每个小区内用户天线数为 N_r ，发送给每个用户的数据信息为 $\mathbf{s}_k, k \in \mathcal{K}$ ，则用户 k 的接收信号为

$$\mathbf{y}_k = \mathbf{H}_k \sum_{i=1}^K \mathbf{W}_i \mathbf{s}_i + \mathbf{n}_k, \quad (2.21)$$

其中， $\mathbf{H}_k \triangleq [\mathbf{h}_{k,1}, \dots, \mathbf{h}_{k,j}, \dots, \mathbf{h}_{h,K}]$ ， $\mathbf{h}_{k,j}$ 为从基站 j 到用户 k 的信道矩阵， \mathbf{W}_i 为信号 \mathbf{s}_i 的波束成形矩阵， \mathbf{n}_k 为加性高斯白噪声。

DPS模式在数据传输阶段区别于JT模式，其结构如图2-3所示。在该模式下，中央处理节点在当前子帧中预先根据不同协作BS到目标用户的CSI判断其信道质量的优劣，并基于此选择一个BS进行数据传输，其余未选中的BS则处于沉默状态，无法接收到共享信息。通过只给信道质量良好的BS共享数据，该模式可以降低系统的反馈开销并提高用户的接收信号功率。

2.2.2 协作调度方案

CS / CBF模式只需协作波束信息，而无需共享用户数据，这大大降低了链路开销和计算复杂度，其结构如图2-4所示。通常，协作小区数目的增加能有效提升系统整体性能，这是由于协作小区数越多，得以利用的信道信息也越多，因此系统的资源利用率也越高。但小区数的增加同时会导致资源分配策略复杂化，此时可通过CS方案避免将同一时频资源分配给相互干扰严重的用户，从而降低干扰，改善系统平均吞吐量。

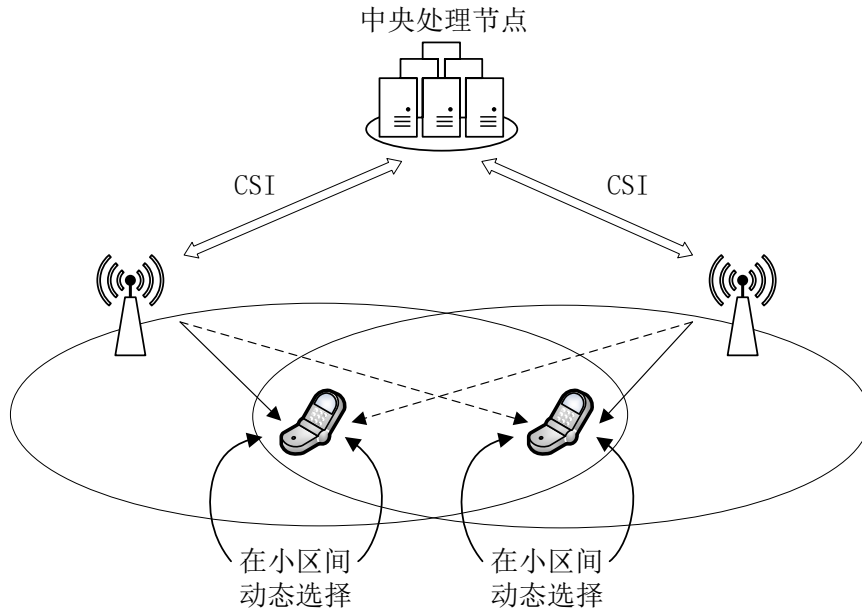


图 2-3 DPS模式结构图




图 2-4 CS模式结构图

CS是指基于某种规则协调各小区，使其按照协调顺序进行数据传输。蜂窝网络中相邻的协作小区或扇区可被划分为新的簇，同一簇内的多基站天线可进行联合传输，其组合可被视为分布式多天线阵列，从而实现簇内协作。簇的划分可分为三类：静态划分、动态划分及混合划分。静态划分方式将各协作BS以固定的划分标准分为不同的簇，而不考虑信道等因素随着时间的变化特性。该方法无法适应快速变化的信道或用户位置分布，对同频干扰的抑制效果有限，但通常只需要较小的通信开销。动态划分则能够自适应地进行协作小区选择，以用户为中心，每个用户选择若干适于协作的小区作为同一簇，动态调整小区

簇。该方法能够更有效地提高小区边缘用户的速率，进而提升系统容量，但作为代价，该方法需要更高的计算开销。混合划分首先选定了划分区域，随后在该区域中进行协作簇的划分，并通过用户反馈信息抉择最优簇。

综合考虑系统开销和性能表现，文献[50]提出了一种被广泛使用的协作调度算法——比例公平算法，该算法兼顾了系统吞吐量和用户公平性，在多小区协作场景下表现良好。假设无限蜂窝网络已被划分为 N 个簇，对每个协作簇内的用户进行调度策略。扇区内信道质量较差的用户由于长时间未被选中而容量降低，比例公平算法提高了这类用户被服务的概率使其成为优先调度用户，并按下式选择下一时隙内的用户 k^* ：

$$k^* = \arg \max_k \frac{r_k}{R_k}, k = 1, 2, \dots, N, \quad (2.22)$$

其中， r_k 为用户 k 的瞬时速率， R_k 为时间平均速率。

2.2.3 协作波束成形方案

CBF技术可让各协作BS根据本地状态及接收到的交互信息设计本小区用户的波束成形矩阵，以抑制小区内多用户干扰，增强系统的空间复用增益。当BS获得理想CSI时，迫零CBF算法可完全消除干扰^[60]。假设协作簇内BS数量为 B ，每个BS配备 N_t 个天线，同一时频资源服务 K 个用户，每个用户有 N_r 个接收天线。将服务于用户 k 的BS记为 b_k ，假设BS向用户 k 发射的信号 x_k 为单数据流，则用户 k 的接收信号为

$$y_k = \mathbf{H}_{b_k,k} \mathbf{p}_{b_k,k} x_k + \sum_{i=1, i \neq k}^K \mathbf{H}_{b_k,k} \mathbf{p}_{b_k,i} x_i + \sum_{c=1, j \neq b_k}^B \mathbf{H}_{c,k} \sum_{j=1}^K \mathbf{p}_{c,j} x_j + \mathbf{n}_k, \quad (2.23)$$

其中， $\mathbf{H}_{b_k,k}$ 表示基站 b_k 到用户 k 的信道矩阵， $\mathbf{p}_{b_k,k}$ 表示基站 b_k 分配给用户 k 的波束成形向量， \mathbf{n}_k 为用户 k 的加性高斯白噪声。式(2.23)中的三项分别表示目标信号、小区内干扰信号及小区间干扰信号。在迫零CBF策略中， $\mathbf{p}_{b_k,k}$ 满足以下要求

$$\begin{cases} \bar{\mathbf{H}}_{b_k} \mathbf{p}_{b_k,k} = \mathbf{0} \\ \text{Tr}(\mathbf{p}_{b_k,k}^H \mathbf{p}_{b_k,k}) = 1, \end{cases} \quad (2.24)$$

其中， $\bar{\mathbf{H}}_{b_k} \triangleq [\mathbf{H}_{b_k,1}^H, \dots, \mathbf{H}_{b_k,k-1}^H, \mathbf{H}_{b_k,k+1}^H, \dots, \mathbf{H}_{b_k,K}^H, \dots, \mathbf{H}_{b_k,BK}^H]^H$ 为基站 b_k 对除目标用户以外的所有用户的合成干扰信道矩阵。可通过矩阵分解对问题(2.24)进行求解，以下给出两种经典求解算法。

(1) 广义矩阵求逆算法^[61]

$$\mathbf{p}_{b_k,k} = \tilde{\mathbf{H}}_{b_k}^\dagger(:, 1), \quad (2.25)$$

其中, $\tilde{\mathbf{H}}_{b_k}^\dagger = \tilde{\mathbf{H}}_{b_k}^H (\tilde{\mathbf{H}}_{b_k} \tilde{\mathbf{H}}_{b_k}^H)^{-1}$, $\tilde{\mathbf{H}}_{b_k} \triangleq [\mathbf{H}_{b_k,k}^H, \bar{\mathbf{H}}_{b_k}^H]^H$ 的第一行为与目标用户的直连信道, 其余行为干扰信道。通过对 $\tilde{\mathbf{H}}_{b_k}$ 求伪逆得到的第一列即为用户 k 的波束成形向量, 该向量落在干扰矩阵的零空间内。但此方法要求 $N_t \geq B \cdot K \cdot N_r$, 即发射天线数需大于所有用户的接收天线数总和。

(2) 块对角化算法^[60]

$$\mathbf{p}_{b_k,k} = \bar{\mathbf{V}}_{b_k}^{(0)} \mathbf{V}_{b_k}^{(1)}, \quad (2.26)$$

其中, $\bar{\mathbf{V}}_{b_k}^{(0)}$ 为 $\bar{\mathbf{H}}_{b_k}$ 零奇异值对应的右奇异向量, 即

$$\bar{\mathbf{H}}_{b_k} = \bar{\mathbf{U}}_{b_k} \bar{\Delta}_{b_k} (\bar{\mathbf{V}}_{b_k}^{(1)} \bar{\mathbf{V}}_{b_k}^{(0)})^H. \quad (2.27)$$

$\mathbf{V}_{b_k}^{(1)}$ 则是 $\mathbf{H}_{b_k,k} \bar{\mathbf{V}}_{b_k}^{(0)}$ 最大奇异值对应的右奇异向量, 即

$$\mathbf{H}_{b_k,k} \bar{\mathbf{V}}_{b_k}^{(0)} = \mathbf{U}_{b_k,k} \Delta_{b_k,k} \mathbf{V}_{b_k,k}^H = \mathbf{U}_{b_k,k} \Delta_{b_k,k} (\mathbf{V}_{b_k,k}^{(1)} \mathbf{V}_{b_k,k}^{(0)})^H. \quad (2.28)$$

此时 $\bar{\mathbf{V}}_{b_k}^{(0)}$ 同样落在 $\bar{\mathbf{H}}_{b_k}$ 的零空间内。该方法要求 $N_t \geq (BK - 1)N_r$, 即发射天线数需大于干扰用户的总接收天线数。同广义矩阵求逆算法相比, 块对角化算法在消除干扰后对目标用户进行了波束成形设计, 更有效地进行了能量分配以提高接收信号质量。

但以上算法均需要完美的CSI反馈信息, 这在实际中是不可能实现的。事实上, 从系统级性能出发, CoMP技术能够改善用户公平性, 实现平均容量的增加, 但协作方案的实际实现必须考虑诸多现实因素, 如信道误差、有限信息交互及通信开销等等。另外, 以上干扰管理技术都是针对单一资源进行设计, 而在实际系统中, 多小区干扰通常与用户调度策略及波束成形策略相耦合, 系统性能的进一步提升需要考虑多维资源联合优化。在第4章中, 提出了多小区协同用户调度和波束成形方案, 并设计了低复杂度算法, 以较低的计算开销和有限的回程通信实现了边缘用户容量及系统平均容量的提升。

2.3 本章小结

本章从大规模MIMO系统的单小区波束成形技术出发, 分别介绍了mmWave传输特性及不同波束成形策略, 并从通信可靠性角度出发, 给出了基于MSER准则的问题建模。为了降低计算复杂度, 使MSER算法能适应高速实时通信系统, 考虑了以深度展开模型进行传统算法的优化, 并提出了深度展开算法的通用框架。为了解决现有神经网络训练平台的计算限制, 第2.1.3小节给出了一种准确有效的计算梯度闭式解的新算法框架, 该算法使深度学习网络能得到良好训练。随后考虑了多小区MIMO场景, 从联合优化和协作处理两个方面介绍了多小区干扰管理方案并给出了经典算法解决方案。

3 基于MSER的混合波束成形设计

在大规模MIMO系统中，使用混合AD波束成形可以在无需为每个天线单元提供专用RF链的情况下获得高方向增益，这大大降低了硬件成本和功耗。虽然大规模MIMO系统的收发机设计通常采用MMSE准则，但直接最小化符号错误率可以获得更好的误码率性能，从而进一步提升通信可靠性。

本章首先基于MSER准则建模了混合AD收发机的设计问题，并设计了一种基于MSER准则的GD迭代算法来寻找原问题的驻点。随后，本章提出了一种深度展开算法，将GD迭代算法展开为多层结构，并引入了可训练参数以加速收敛，同时提高系统整体性能。本章针对正交相移键控（Quadrature Phase Shift Keying, QPSK）和M元正交调幅（Quadrature Amplitude Modulated, QAM）信号提出了深度展开神经网络，并从理论上研究了其收敛性。此外，本章还分析了所提出的深度展开神经网络的传输能力、计算复杂度和泛化能力。仿真结果表明，所提出的深度展开算法性能显著优于传统的MMSE相关算法，并在低复杂度的前提下逼近迭代MSER算法的性能。

本章内容安排如下。3.1节介绍了系统模型。3.2节针对QPSK调制信号给出了基于MSER准则的GD迭代算法。3.3节提出了基于GD算法的深度展开神经网络。3.4节分析了所提算法的收敛性、计算复杂度以及泛化能力。3.5节给出实验结果并验证所提算法的有效性。最后，3.6节给出了本章小结。

3.1 系统模型

考虑大规模MIMO系统的下行链路，如图3-1所示。考虑的系统由K个用户和一个BS组成。BS有 N_t 个发射天线和 R_t ($R_t \ll N_t$)个RF链，用户 $k \in \mathcal{K} \triangleq \{1, \dots, K\}$ 有 $N_{r,k}$ 个接收天线和 $R_{r,k}$ ($R_{r,k} \leq N_{r,k}$)个RF链，且满足 $N_t \gg \sum_{k=1}^K N_{r,k}$ ， $R_t \geq \sum_{k=1}^K R_{r,k}$ 。BS的发射信号为 $\mathbf{s} \triangleq [\mathbf{b}_1^T, \mathbf{b}_2^T, \dots, \mathbf{b}_K^T]^T \in \mathbb{C}^{D \times 1}$ ，满足独立同分布。用户k接收到的信号为 $\mathbf{b}_k \triangleq [b_{1,k}, \dots, b_{D_k,k}]^T \in \mathbb{C}^{D_k \times 1}$ ，满足均值为零且 $\mathbb{E}[\mathbf{b}_k \mathbf{b}_k^H] = \mathbf{I}$ ，其中 D_k ($D_k \leq R_{r,k}$)为用户k接收信号的长度，定义数据流总长度为 $D = \sum_{k=1}^K D_k$ 。在本章中，将考虑QPSK信号

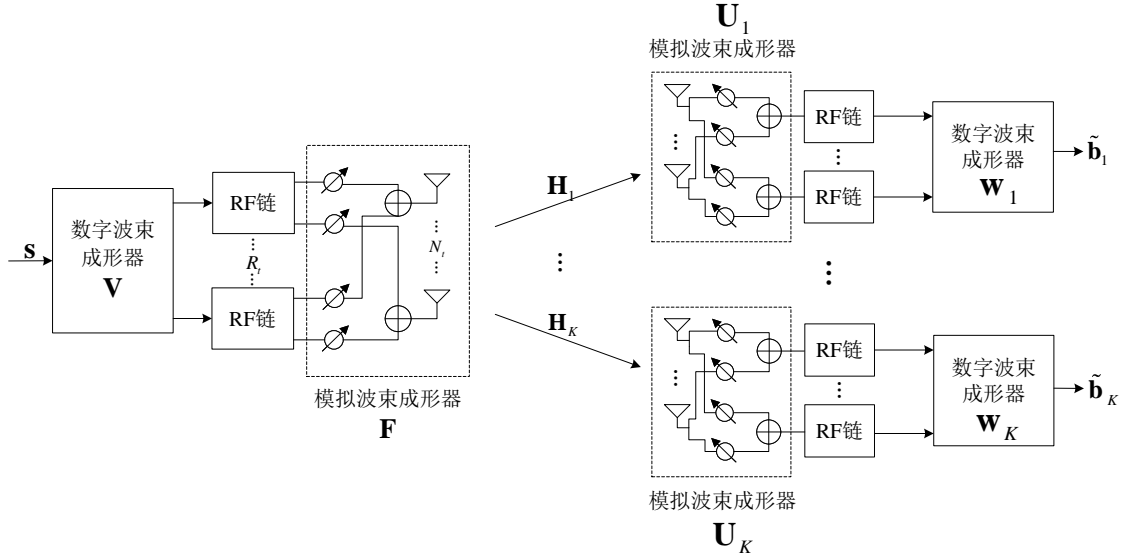


图 3-1 大规模MIMO系统下行链路系统模型

和 M -QAM 信号，但可以较为容易地拓展到其他调制信号。对 QPSK 信号来说， \mathbf{b}_k 的实部和虚部将从 $\{\pm 1\}$ 中随机选择，对于 M -QAM 信号，其实部与虚部将随机从 $\{F_m + jF_n : 1 \leq m, n \leq \sqrt{M}\}$ 中选取，其中 M 为平方数，且 $F_n = 2n - \sqrt{M} - 1$ 。发射信号首先经过数字波束成形矩阵 $\mathbf{V} \triangleq [\mathbf{P}_1, \dots, \mathbf{P}_K] \in \mathbb{C}^{R_t \times D}$ ，其中 $\mathbf{P}_k \in \mathbb{C}^{R_t \times D_k}$ 为用户 k 的发射波束成形矩阵。数字波束成形器的输出信号随后经过 RF 链并被模拟波束成形矩阵 $\mathbf{F} \in \mathbb{C}^{N_t \times R_t}$ ， $|\mathbf{F}_{m,n}| = 1$ 处理。发射功率约束为

$$\mathbb{E}\{\|\mathbf{FV}\mathbf{s}\|^2\} = \|\mathbf{FV}\|^2 = P_T, \quad (3.1)$$

其中， P_T 为总发射功率。用户 k 的接收信号为

$$\mathbf{y}_k = \mathbf{H}_k \mathbf{FV}\mathbf{s} + \mathbf{n}_k = \mathbf{H}_k \mathbf{F} \sum_{k=1}^K \mathbf{P}_k \mathbf{b}_k + \mathbf{n}_k, \quad (3.2)$$

其中， $\mathbf{H}_k \in \mathbb{C}^{N_{r,k} \times N_t}$ 为 BS 和用户 k 之间的信道矩阵，且满足

$$\mathbf{H}_k = \sqrt{\frac{N_t N_{r,k}}{N_C N_R}} \sum_{i=1}^{N_C} \sum_{j=1}^{N_R} \alpha_{i,j} \mathbf{a}_r(\theta_{i,j}^r) \mathbf{a}_t(\theta_{i,j}^t)^H, \quad (3.3)$$

其中 $\alpha_{i,j}$ 为第 i 簇第 j 径信道的增益， $\mathbf{a}_r(\theta_{i,j}^r) \triangleq \frac{1}{\sqrt{N_{r,k}}} [1, e^{j\pi \sin \theta_{i,j}^r}, \dots, e^{j\pi(N_r-1) \sin \theta_{i,j}^r}]^T$ 和 $\mathbf{a}_t(\theta_{i,j}^t) \triangleq \frac{1}{\sqrt{N_t}} [1, e^{j\pi \sin \theta_{i,j}^t}, \dots, e^{j\pi(N_t-1) \sin \theta_{i,j}^t}]^T$ 分别为发射和接收天线阵列对应的归一化响应向量， $\theta_{i,j}^r$ 和 $\theta_{i,j}^t$ 分布表示到达角和离开角， $\mathbf{n}_k \in \mathbb{C}^{N_{r,k} \times 1}$ 为复加性高斯白噪声。

与 BS 类似，位于用户 k 处的混合 AD 接收机由模拟接收波束形成矩阵 $\mathbf{U}_k \in \mathbb{C}^{R_{r,k} \times N_r}$ 和数字接收波束成形矩阵 $\mathbf{W}_k \triangleq [\mathbf{w}_{1,k}, \dots, \mathbf{w}_{D_k,k}] \in \mathbb{C}^{R_{r,k} \times D_k}$ 组成，其中， $\mathbf{w}_{i,k} \in \mathbb{C}^{R_{r,k} \times 1}$ 且 $i \in$

$\mathcal{D}_k \triangleq \{1, \dots, D_k\}$ 。则用户 k 处的输出信号 $\tilde{\mathbf{b}}_k \triangleq [\tilde{b}_{1,k}, \dots, \tilde{b}_{D_k,k}]^T \in \mathbb{C}^{D_k \times 1}$ 可表示为

$$\tilde{\mathbf{b}}_k = \mathbf{W}_k^H \mathbf{U}_k \mathbf{y}_k = \mathbf{W}_k^H \mathbf{U}_k (\mathbf{H}_k \mathbf{F} \sum_{k=1}^K \mathbf{P}_k \mathbf{b}_k + \mathbf{n}_k), \quad (3.4)$$

则接收机 k 处发射信号的估计为

$$\hat{\mathbf{b}}_k = \mathcal{Q}\{\tilde{\mathbf{b}}_k\}, \quad (3.5)$$

其中， $\mathcal{Q}\{\cdot\}$ 为给定调制方式时恢复信号的判定规则。

3.2 基于MSER准则的GD迭代算法

在本节中，将以QPSK信号为例进行问题建模，但可较容易地拓展到其他调制方式。由于目标函数和约束条件的高度非凸性，本节设计了一种基于MSER准则的GD迭代算法来寻找原问题的驻点。

3.2.1 MSER准则

以QPSK信号为例，用户 k 恢复信号 $\mathbf{b}_k = [b_{1,k}, \dots, b_{D_k,k}]^T$ 的判定规则为

$$\Re\{\hat{b}_{i,k}\} = \begin{cases} +1, & \text{if } \Re\{\tilde{b}_{i,k}\} \geq 0 \\ -1, & \text{if } \Re\{\tilde{b}_{i,k}\} < 0, \end{cases} \quad \Im\{\hat{b}_{i,k}\} = \begin{cases} +1, & \text{if } \Im\{\tilde{b}_{i,k}\} \geq 0 \\ -1, & \text{if } \Im\{\tilde{b}_{i,k}\} < 0. \end{cases} \quad (3.6)$$

对于给定的符号 $b_{i,k}$ ，存在 $N_b = 4^{D-1}$ 种用户间干扰符号 $\{b_{i,k'}, i \in \mathcal{D}_{k'}, k' \in \mathcal{K}, k' \neq k\}$ 和自干扰符号 $\{b_{i',k}, i' \in \mathcal{D}_k, i' \neq i\}$ 。定义所有可能的发射符号向量组合为

$$\mathcal{X} \triangleq \{\mathbf{s}^1, \mathbf{s}^2, \dots, \mathbf{s}^{N_b}\}, \quad (3.7)$$

其中，某个可能的发射符号被定义为 $\mathbf{s}^q = [(b_1^q)^T, (b_2^q)^T, \dots, (b_K^q)^T]^T$, $q \in \mathcal{N}_b \triangleq \{1, \dots, N_b\}$ 。则用户 k 处混合接收机输出信号的无噪声分量的第 i 个元素来自于集合

$$\mathcal{Y}_{i,k} \triangleq \{\bar{b}_{i,k}^q = \mathbf{w}_{i,k}^H \mathbf{U}_k \mathbf{H}_k \mathbf{F} \mathbf{V} \mathbf{s}^q, q \in \mathcal{N}_b\}. \quad (3.8)$$

由于接收机处的加性噪声服从于高斯分布，在给定 $b_{i,k}$ 的情况下，根据全概率公式，混合接收机输出信号的实部的PDF为

$$f(x|b_{i,k}) = \frac{1}{N_b \sqrt{2\pi \mathbf{w}_{i,k}^H \mathbf{U}_k \mathbf{H}_k \mathbf{F} \mathbf{V} \mathbf{V}^H \mathbf{F}^H \mathbf{H}_k^H \mathbf{U}_k^H \mathbf{w}_{i,k} \sigma_n^2}} \sum_{q=1}^{N_b} e^{-\frac{|x - \Re\{\bar{b}_{i,k}^q\}|^2}{2\mathbf{w}_{i,k}^H \mathbf{U}_k \mathbf{H}_k \mathbf{F} \mathbf{V} \mathbf{V}^H \mathbf{F}^H \mathbf{H}_k^H \mathbf{U}_k^H \mathbf{w}_{i,k} \sigma_n^2}}, \quad (3.9)$$

其中, $\bar{b}_{i,k}^q \in \mathcal{Y}$ 。由于 N_b 的值很大, 在实际中不可能遍历所有的发射符号向量组合, 输出信号的PDF通常基于随机采样样本来近似计算。特别地, 根据核密度估计方法^[62], 将从 \mathcal{X} 中随机选取 J 个不同的发射符号向量, 索引为 q_j , $j \in \{1, \dots, J\}$, 并使用常量内核宽度 ϱ 来替换 $\sqrt{\mathbf{w}_{i,k}^H \mathbf{U}_k \mathbf{H}_k \mathbf{F} \mathbf{V} \mathbf{V}^H \mathbf{F}^H \mathbf{H}_k^H \mathbf{U}_k^H \mathbf{w}_{i,k}} \sigma_n$ 以降低计算复杂度, 参数 ϱ 与噪声的方差相关, 并根据仿真确定^[62]。接收机输出信号实部的真实PDF的核估计为

$$f(x|b_{i,k}) = \frac{1}{J\sqrt{2\pi\varrho}} \sum_{j=1}^J e^{-\frac{|x - \Re\{\bar{b}_{i,k}^{q_j}\}|^2}{2\varrho^2}}. \quad (3.10)$$

接收机输出信号虚部的PDF同理可得。则 $b_{i,k}$ 的SER为

$$\mathcal{P}_e(b_{i,k}) = \mathcal{P}_e^R(b_{i,k}) + \mathcal{P}_e^I(b_{i,k}) - \mathcal{P}_e^R(b_{i,k})\mathcal{P}_e^I(b_{i,k}), \quad (3.11)$$

其中, $\mathcal{P}_e^R(b_{i,k}) \triangleq \text{Prob}\{\Re\{\hat{b}_{i,k}\} \neq \Re\{b_{i,k}\}\}$ 以及 $\mathcal{P}_e^I(b_{i,k}) \triangleq \text{Prob}\{\Im\{\hat{b}_{i,k}\} \neq \Im\{b_{i,k}\}\}$ 分别为SER的实部和虚部。基于(3.10)可得

$$\mathcal{P}_e^R(b_{i,k}) = \frac{1}{J\sqrt{\pi}} \sum_{j=1}^J \int_{-\infty}^{-\frac{\Re\{\bar{b}_{i,k}^{q_j}\} - \Re\{b_{i,k}\}}{\sqrt{2\varrho}}} e^{-s^2} ds, \quad (3.12)$$

$$\mathcal{P}_e^I(b_{i,k}) = \frac{1}{J\sqrt{\pi}} \sum_{j=1}^J \int_{-\infty}^{-\frac{\Im\{\bar{b}_{i,k}^{q_j}\} - \Im\{b_{i,k}\}}{\sqrt{2\varrho}}} e^{-s^2} ds. \quad (3.13)$$

根据文献[63], $\mathcal{P}_e^R(b_{i,k})\mathcal{P}_e^I(b_{i,k})$ 的值通常很小, 为了降低计算复杂度可舍弃, 则只需考虑 $\tilde{\mathcal{P}}_e(b_{i,k}) \triangleq \mathcal{P}_e^R(b_{i,k}) + \mathcal{P}_e^I(b_{i,k})$, 仿真证明近似上界 $\tilde{\mathcal{P}}_e(b_{i,k})$ 与真实值 $\mathcal{P}_e(b_{i,k})$ 非常接近。本章的目标是通过联合优化波束形成矩阵 $\{\mathbf{P}_k, \mathbf{W}_k, \mathbf{U}_k, \mathbf{F}\}$ 来最小化所有用户的SER的近似上界, 可建模为

$$\min_{\substack{\{\mathbf{P}_k, \mathbf{W}_k, \\ \mathbf{U}_k, \mathbf{F}\}}} \sum_{k=1}^K \sum_{i=1}^{D_k} \tilde{\mathcal{P}}_e(b_{i,k}) \triangleq \sum_{k=1}^K \sum_{i=1}^{D_k} (\mathcal{P}_e^R(b_{i,k}) + \mathcal{P}_e^I(b_{i,k})) \quad (3.14a)$$

$$\text{s.t.} \quad \|\mathbf{F}\mathbf{V}\|^2 = P_T, \quad (3.14b)$$

$$|[\mathbf{F}]_{m,n}| = 1, |[\mathbf{U}_k]_{m,n}| = 1, \quad \forall k, m, n, \quad (3.14c)$$

其中, 式(3.14b)和式(3.14c)分别为发射功率约束和恒模约束。

3.2.2 GD迭代算法

由于目标函数和约束条件的高度非凸性, 本小节提出了一种GD迭代算法来求解原问题的驻点。为了满足恒模约束(3.14c), 定义模拟波束成形相位矩阵 $\boldsymbol{\theta}_{U_k} \triangleq \angle \mathbf{U}_k$ 和 $\boldsymbol{\theta}_F \triangleq \angle \mathbf{F}$,

则 \mathbf{U}_k 和 \mathbf{F} 可分别被表示为 $\mathbf{U}_k = \exp(j\boldsymbol{\theta}_{U_k})$, $\mathbf{F} = \exp(j\boldsymbol{\theta}_F)$, 其中, $\exp(\cdot)$ 为对每个元素操作。同时, 为了满足发射功率约束, 在每一轮迭代的最后对总的数字发射波束成形矩阵 $\mathbf{V} = [\mathbf{P}_1, \dots, \mathbf{P}_K]$ 进行标准化操作, 至此, 原问题可被转化成无约束问题:

$$\min_{\{\mathbf{P}_k, \mathbf{W}_k, \boldsymbol{\theta}_{U_k}, \boldsymbol{\theta}_F\}} \sum_{k=1}^K \sum_{i=1}^{D_k} \tilde{\mathcal{P}}_e(b_{i,k}) \triangleq \sum_{k=1}^K \sum_{i=1}^{D_k} (\mathcal{P}_e^R(b_{i,k}) + \mathcal{P}_e^I(b_{i,k})). \quad (3.15)$$

对目标函数求导可知, $\nabla \tilde{\mathcal{P}}_e(b_{i,k}) \triangleq \nabla \mathcal{P}_e^R(b_{i,k}) + \nabla \mathcal{P}_e^I(b_{i,k})$, 其中, $\nabla \mathcal{P}_e^R(b_{i,k})$ 和 $\nabla \mathcal{P}_e^I(b_{i,k})$ 分别表示梯度的实部和虚部。分别对目标函数求关于 $\{\mathbf{P}_k, \mathbf{W}_k, \mathbf{U}_k, \mathbf{F}\}$ 的导数, 可得梯度实部分别为

$$\nabla_{\mathbf{P}_k^*} \mathcal{P}_e^R = -\frac{1}{J\sqrt{2\pi}\varrho} \sum_{j=1}^J e^{-\frac{|\Re\{\tilde{b}_{i,k}^{q_j}\}|^2}{2\varrho^2}} \Re\{b_{i,k}\} \mathbf{F}^H \mathbf{H}_k^H \mathbf{U}_k^H \mathbf{W}_k (\mathbf{b}_k^{q_j})^H, \quad (3.16)$$

$$\nabla_{\mathbf{W}_{i,k}^*} \mathcal{P}_e^R = -\frac{1}{J\sqrt{2\pi}\varrho} \sum_{j=1}^J e^{-\frac{|\Re\{\tilde{b}_{i,k}^{q_j}\}|^2}{2\varrho^2}} \Re\{b_{i,k}\} \mathbf{U}_k \mathbf{H}_k \mathbf{F} (\mathbf{V}_s^{q_j}), \quad (3.17)$$

$$\nabla_{\mathbf{U}_k^*} \mathcal{P}_e^R = -\frac{1}{J\sqrt{2\pi}\varrho} \sum_{j=1}^J e^{-\frac{|\Re\{\tilde{b}_{i,k}^{q_j}\}|^2}{2\varrho^2}} \Re\{b_{i,k}\} \mathbf{w}_{i,k} (\mathbf{V}_s^{q_j})^H \mathbf{F}^H \mathbf{H}_k^H, \quad (3.18)$$

$$\nabla_{\mathbf{F}^*} \mathcal{P}_e^R = -\frac{1}{J\sqrt{2\pi}\varrho} \sum_{j=1}^J e^{-\frac{|\Re\{\tilde{b}_{i,k}^{q_j}\}|^2}{2\varrho^2}} \Re\{b_{i,k}\} \mathbf{H}_k^H \mathbf{U}_k^H \mathbf{w}_{i,k} (\mathbf{V}_s^{q_j})^H, \quad (3.19)$$

定义 $\nabla_{\mathbf{W}_k^*} \mathcal{P}_e^R \triangleq [\nabla_{\mathbf{W}_{1,k}^*} \mathcal{P}_e^R, \dots, \nabla_{\mathbf{W}_{D_k,k}^*} \mathcal{P}_e^R]$ 。梯度的虚部同理可得。

对SER关于模拟相位矩阵 $\boldsymbol{\theta}_{U_k}$ 和 $\boldsymbol{\theta}_F$ 求导, 可得其梯度为

$$\begin{aligned} \nabla_{\boldsymbol{\theta}_{U_k}} \mathcal{P}_e^R &= \Re\{\nabla_{\mathbf{U}_k} \tilde{\mathcal{P}}_e \circ j\mathbf{U}_k - \nabla_{\mathbf{U}_k^*} \tilde{\mathcal{P}}_e \circ j\mathbf{U}_k^*\} \\ &= -\nabla_{\mathbf{U}_k} \mathcal{P}_e^R \circ \mathbf{U}_k^I - \nabla_{\mathbf{U}_k} \mathcal{P}_e^I \circ \mathbf{U}_k^R + \nabla_{\mathbf{U}_k^*} \mathcal{P}_e^R \circ (\mathbf{U}_k^I)^* + \nabla_{\mathbf{U}_k^*} \mathcal{P}_e^I \circ (\mathbf{U}_k^R)^*, \end{aligned} \quad (3.20)$$

$$\begin{aligned} \nabla_{\boldsymbol{\theta}_F} \mathcal{P}_e^R &= \Re\{\nabla_{\mathbf{F}} \tilde{\mathcal{P}}_e \circ j\mathbf{F} - \nabla_{\mathbf{F}^*} \tilde{\mathcal{P}}_e \circ j\mathbf{F}^*\} \\ &= -\nabla_{\mathbf{F}} \mathcal{P}_e^R \circ \mathbf{F}^I - \nabla_{\mathbf{F}} \mathcal{P}_e^I \circ \mathbf{F}^R + \nabla_{\mathbf{F}^*} \mathcal{P}_e^R \circ (\mathbf{F}^I)^* + \nabla_{\mathbf{F}^*} \mathcal{P}_e^I \circ (\mathbf{F}^R)^*. \end{aligned} \quad (3.21)$$

基于MSER准则对混合波束成形矩阵进行联合优化, 其梯度更新表达式为

$$\mathbf{P}_k^{t+1} = \mathbf{P}_k^t - \mu_P \nabla_{\mathbf{P}_k^*} \tilde{\mathcal{P}}_e, \quad (3.22)$$

$$\mathbf{W}_k^{t+1} = \mathbf{W}_k^t - \mu_W \nabla_{\mathbf{W}_k^*} \tilde{\mathcal{P}}_e, \quad (3.23)$$

$$\boldsymbol{\theta}_{U_k}^{t+1} = \boldsymbol{\theta}_{U_k}^t - \mu_{\theta_U} \nabla_{\boldsymbol{\theta}_{U_k}} \tilde{\mathcal{P}}_e, \quad (3.24)$$

$$\boldsymbol{\theta}_F^{t+1} = \boldsymbol{\theta}_F^t - \mu_{\theta_F} \nabla_{\boldsymbol{\theta}_F} \tilde{\mathcal{P}}_e, \quad (3.25)$$

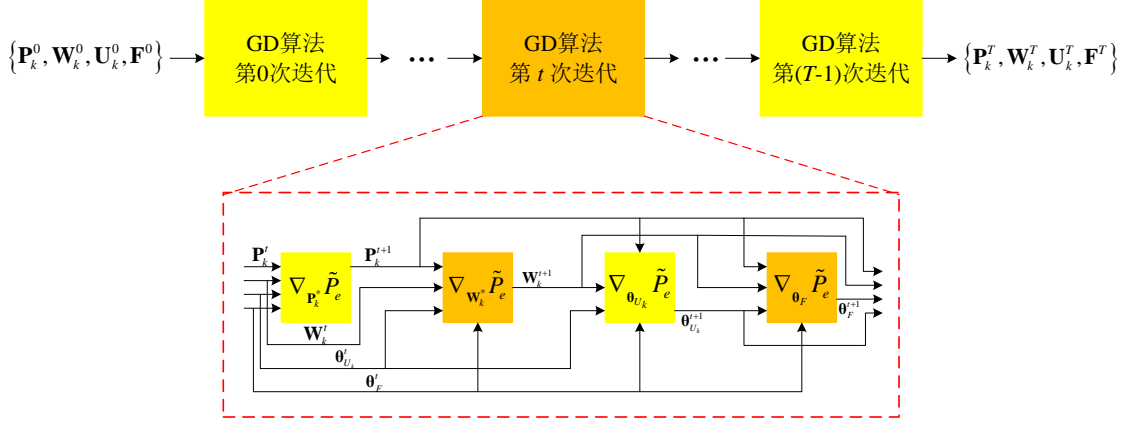


图 3-2 GD迭代算法结构图

Algorithm 3.1 联合混合AD收发机设计的GD迭代算法

- 1: 初始化误差精度 ϵ , 总迭代次数 T , 样本数 J 以及步长 $\{\mu_P, \mu_W, \mu_{\theta_U}, \mu_{\theta_F}\}$ 。初始化迭代索引 $t = 0$ 。
- 2: 初始化 \mathbf{P}_k 以满足发射功率约束, 初始化 $\{\mathbf{W}_k, \boldsymbol{\theta}_{U_k}, \boldsymbol{\theta}_F\}$ 。
- 3: **repeat**
- 4: 对 $\forall k \in \mathcal{K}$, 固定 $\{\mathbf{W}_k^t, \boldsymbol{\theta}_{U_k}^t, \boldsymbol{\theta}_F^t\}$, 根据式(3.22)更新 \mathbf{P}_k^{t+1} 。
- 5: 对 $\forall k \in \mathcal{K}$, 固定 $\{\mathbf{P}_k^{t+1}, \boldsymbol{\theta}_{U_k}^t, \boldsymbol{\theta}_F^t\}$, 根据式(3.23)更新 \mathbf{W}_k^{t+1} 。
- 6: 对 $\forall k \in \mathcal{K}$, 固定 $\{\mathbf{P}_k^{t+1}, \mathbf{W}_k^{t+1}, \boldsymbol{\theta}_F^t\}$, 根据式(3.24)更新 $\boldsymbol{\theta}_{U_k}^{t+1}$ 。
- 7: 固定 $\{\mathbf{P}_k^{t+1}, \mathbf{W}_k^{t+1}, \boldsymbol{\theta}_{U_k}^{t+1}\}$, 根据式(3.25)更新 $\boldsymbol{\theta}_F^{t+1}$ 。
- 8: 根据式(3.26)标准化 \mathbf{P}_k^{t+1} 以满足发射功率约束。
- 9: 更新迭代索引: $t = t + 1$ 。
- 10: **until** 目标函数收敛或 $t > T$ 。

其中, $\{\mu_P, \mu_W, \mu_{\theta_U}, \mu_{\theta_F}\}$ 为迭代步长, t 为迭代索引。波束形成矩阵交替更新, 直到满足指定的收敛法则。基于MSER的GD迭代算法结构图如图3-2所示。

为了满足发射功率约束(3.14b), 需要在每一轮迭代结束时对数字发射波束形成矩阵 \mathbf{V} 进行标准化操作, 具体操作如下:

$$\mathbf{V} \leftarrow \frac{\sqrt{P_T}}{\|\mathbf{FV}\|} \mathbf{V}. \quad (3.26)$$

GD迭代算法具体过程如Algorithm 3.1所示。首先算法处于训练模式, 此时发射符号序列已知, 训练完成后将转换为预测模式, 此时使用恢复信号进行计算。

3.3 深度展开神经网络

基于MSER的传统GD迭代算法通常收敛速度很慢，需要大量迭代。此外，在不完美的信道状态下，其性能会受损。为了解决这些问题，本节提出了一种深度展开神经网络来联合设计混合AD收发机，该网络可以有效减少迭代层数，同时保持较好的性能。所提出的神经网络结构受GD迭代算法的启发，将迭代算法展开为多层结构，并在前向传播（Forward Propagation, FP）中引入了部分可训练参数。在训练阶段，根据BP中的GCR推导出相邻层梯度之间的关系，并逐层计算可训练参数的梯度，使用SGD法更新这些参数。在测试阶段，使用已经训练好的参数计算混合波束形成矩阵，具体过程将在下述章节详细介绍。

3.3.1 前向传播

本小节将充分利用GD迭代算法的结构来设计深度展开神经网络。在GD算法的迭代过程中，步长 $\{\mu_P, \mu_W, \mu_{\theta_U}, \mu_{\theta_F}\}$ 对SER性能影响显著，且没有固定的选择依据，通常根据经验或仿真确定，因此，引入 $\{\alpha_{P_k}^l, \alpha_{W_k}^l, \alpha_{\theta_{U_k}}^l, \alpha_{\theta_F}^l\}$ 为可训练学习率，其中， $l \in \{0, \dots, L-1\}$ ， L 为网络总层数。在深度展开网络中，将使用上述学习率来代替迭代算法中的训练步长。此外，在GD算法中，式(3.9)中的 $\sqrt{\mathbf{w}_{i,k}^H \mathbf{U}_k \mathbf{H}_k \mathbf{F} \mathbf{V} \mathbf{V}^H \mathbf{F}^H \mathbf{H}_k^H \mathbf{U}_k^H \mathbf{w}_{i,k} \sigma_n}$ 被定义为了常数内核宽度 ρ ，该近似可能会造成性能损失，因此，引入可训练参数 $\{\rho_{P_k}^l, \rho_{W_k}^l, \rho_{U_k}^l, \rho_F^l\}$ 来分别代替迭代算法(3.16)–(3.19)中的 ρ 。同时，为了增加参数自由度，引入可训练偏置矩阵参数 $\{\mathbf{O}_{P_k}^l, \mathbf{O}_{W_k}^l, \mathbf{O}_{\theta_{U_k}}^l, \mathbf{O}_{\theta_F}^l\}$ 。则深度展开网络的更新规则为

$$\mathbf{P}_k^{l+1} = \mathbf{P}_k^l - \alpha_{P_k}^l \circ \nabla_{\mathbf{P}_k^*} \tilde{\mathcal{P}}_e^l + \mathbf{O}_{P_k}^l, \quad (3.27)$$

$$\mathbf{W}_k^{l+1} = \mathbf{W}_k^l - \alpha_{W_k}^l \circ \nabla_{\mathbf{W}_k^*} \tilde{\mathcal{P}}_e^l + \mathbf{O}_{W_k}^l, \quad (3.28)$$

$$\boldsymbol{\theta}_{U_k}^{l+1} = \boldsymbol{\theta}_{U_k}^l - \alpha_{\theta_{U_k}}^l \circ \nabla_{\boldsymbol{\theta}_{U_k}} \tilde{\mathcal{P}}_e^l + \mathbf{O}_{\theta_{U_k}}^l, \quad (3.29)$$

$$\boldsymbol{\theta}_F^{l+1} = \boldsymbol{\theta}_F^l - \alpha_{\theta_F}^l \circ \nabla_{\boldsymbol{\theta}_F} \tilde{\mathcal{P}}_e^l + \mathbf{O}_{\theta_F}^l, \quad (3.30)$$

其中， $\{\alpha_{P_k}^l, \mathbf{O}_{P_k}^l\} \in \mathbb{C}^{R_t \times D_k}$ ， $\{\alpha_{W_k}^l, \mathbf{O}_{W_k}^l\} \in \mathbb{C}^{R_r, k \times D_k}$ ， $\{\alpha_{\theta_{U_k}}^l, \mathbf{O}_{\theta_{U_k}}^l\} \in \mathbb{C}^{R_r, k \times N_{r,k}}$ ， $\{\alpha_{\theta_F}^l, \mathbf{O}_{\theta_F}^l\} \in \mathbb{C}^{N_t \times R_t}$ 和 $\{\nabla_{\mathbf{P}_k^*} \tilde{\mathcal{P}}_e^l, \nabla_{\mathbf{W}_k^*} \tilde{\mathcal{P}}_e^l, \nabla_{\boldsymbol{\theta}_{U_k}} \tilde{\mathcal{P}}_e^l, \nabla_{\boldsymbol{\theta}_F} \tilde{\mathcal{P}}_e^l\}$ 分别表示第 l 层各波束成形矩阵的梯度。

基于MSER的深度展开神经网络结构如图3-3所示。与图3-2相比，该网络将GD迭代算法展开为由 L 个连续层组成的多层结构。红色实心矩形（中间）中的放大部分表示该网络中各层的细节，其中 $\mathcal{P}(\vartheta)$ ， $\mathcal{W}(\vartheta)$ ， $\mathcal{U}(\vartheta)$ 和 $\mathcal{F}(\vartheta)$ 分别为对应波束成形矩阵的更新规则(3.27)–(3.30)。对于每次更新，红色虚线矩形（底部）中的放大图说明了是如何使用可

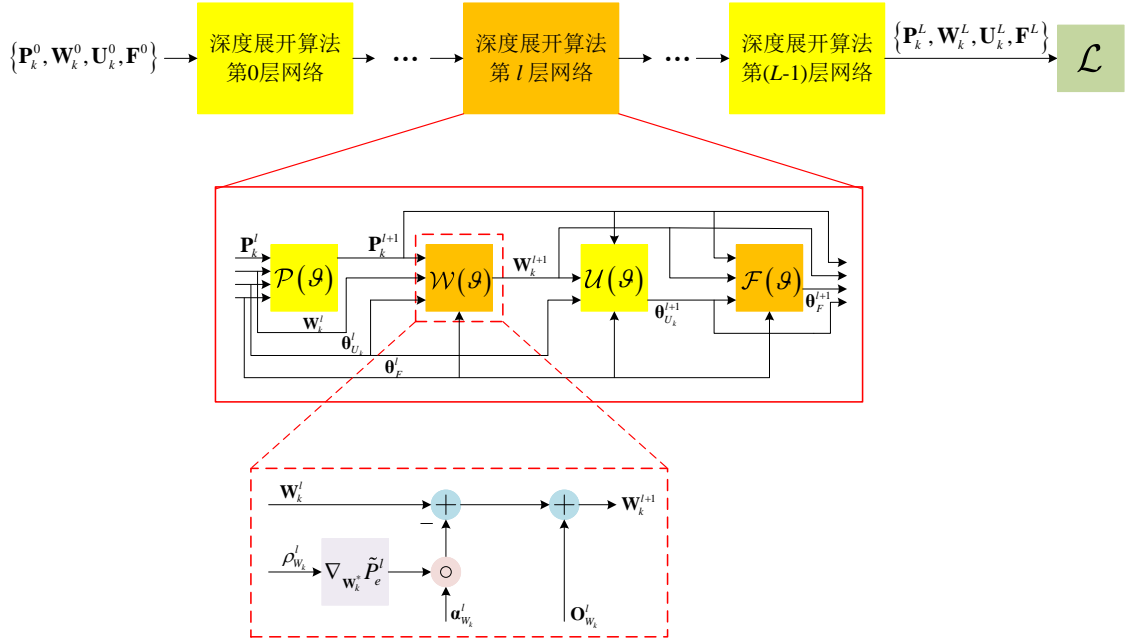


图 3-3 深度展开神经网络结构图

训练参数 α_X^l , ρ_X^l 和 \mathbf{O}_X^l 的, 其中, $X \in \{P_k, W_k, \theta_{U_k}, \theta_F\}$ 。最后一层的波束形成矩阵为 NN 输出, 并传到损失函数中, 定义最后一层 θ_F^l 的迭代规则采用无参数表达式(3.25)。

由于信道矩阵 \mathbf{H}_k 是随机选取的, 因此最终损失函数包含了在信道矩阵集合上的期望运算 $\mathbb{E}_{\mathbf{H}}$ 。图3-3右上角的损失函数 \mathcal{L} 修改为

$$\mathcal{L} = \sum_{k=1}^K \mathbb{E}_{\mathbf{H}} \left\{ \frac{1}{J\sqrt{\pi}} \sum_{i=1}^{D_k} \sum_{j=1}^J \left(\int_{-\infty}^{\frac{\Re\{b_{i,k}^{q_j}\} \Re\{b_{i,k}\}}{\sqrt{2\rho}}} e^{-s^2} ds + \int_{-\infty}^{\frac{\Im\{b_{i,k}^{q_j}\} \Im\{b_{i,k}\}}{\sqrt{2\rho}}} e^{-s^2} ds \right) \right\}. \quad (3.31)$$

如第3.2节所述, 在每一层中, $\mathbf{V} = [\mathbf{P}_1, \dots, \mathbf{P}_K]$ 均需按照式(3.26)进行标准化, 以此满足功率约束及避免梯度爆炸。

3.3.2 后向传播

由于通用的神经网络训练平台(例如Pytorch或Tensorflow)无法处理积分形式的处理损失函数, 本小节提出了一种更准确有效的计算梯度闭式解的新方法。简单来说, 该方法在BP中根据GCR推导相邻层梯度之间的递归关系, 并由此计算可训练参数的梯度。

定义 $\{\mathbf{G}_{P_k}^l, \mathbf{G}_{W_k}^l, \mathbf{G}_{U_k}^l, \mathbf{G}_{U_k}^{l*}, \mathbf{G}_F^l, \mathbf{G}_{F^*}^l\}$ 分别为对应波束成形矩阵在第 l 层的反向梯度, 通过取式(3.31)的导数, 可得 \mathbf{F}^L 和 $(\mathbf{F}^*)^L$ 在最后一层的反向梯度为

$$\mathbf{G}_F^L = (\nabla_{\mathbf{F}} \tilde{\mathcal{P}}_e^L)^H, \quad \mathbf{G}_{F^*}^L = (\nabla_{\mathbf{F}^*} \tilde{\mathcal{P}}_e^L)^H. \quad (3.32)$$

分别对式(3.20)和式(3.21)两边取导, 可以看到 $\mathbf{G}_{\theta_{U_k}}^l$ 和 $\mathbf{G}_{\theta_F}^l$ 分别由 $\{\mathbf{G}_{U_k}^l, \mathbf{G}_{U_k}^{l*}\}$ 和 $\{\mathbf{G}_F^l, \mathbf{G}_{F^*}^l\}$ 构成, 具体表达式为

$$\mathbf{G}_{\theta_{U_k}}^l = \mathbf{G}_{U_k}^l \circ j\mathbf{U}_k^T - \mathbf{G}_{U_k}^{l*} \circ j\mathbf{U}_k^*, \quad (3.33)$$

$$\mathbf{G}_{\theta_F}^l = \mathbf{G}_F^l \circ j\mathbf{F}^T - \mathbf{G}_{F^*}^l \circ j\mathbf{F}^*. \quad (3.34)$$

为了求得可训练参数的梯度, 需先求出第 $(l+1)$ 层和第 l 层中混合波束成形矩阵梯度之间的递归关系以及波束成形矩阵和可训练参数梯度之间的关系。为此, 对式(3.27)–(3.30)两边取导数, 并应用微分法则。以式(3.27)为例, 基于2.1.3中的梯度求解方法, 省略索引 i 、 q_j 和 t , 可得

$$\begin{aligned} \text{Tr} \{ \mathbf{G}_{P_k}^{l+1} d\mathbf{P}_k^{l+1} \} &= \frac{1}{J} \sum_{j=1}^J \text{Tr} \{ \mathbf{G}_{P_k}^{l+1} d\mathbf{P}_k^l - b_k^H B \mathbf{G}_{P_k}^{l+1} \circ (\boldsymbol{\alpha}_{P_k}^l)^T (\mathbf{F}^l)^H \mathbf{H}_k^H (\mathbf{U}_k^l)^H \mathbf{W}_k^l \circ \\ & [b_k (\mathbf{W}_k^l)^H \mathbf{U}_k^l \mathbf{H}_k \mathbf{F}^l d\mathbf{P}_k^l + \mathbf{D}^H (\mathbf{U}_k^l)^H d\mathbf{W}_k^l + \mathbf{C} (\mathbf{W}_k^l)^H \mathbf{U}_k^l \mathbf{H}_k d\mathbf{F}^l \\ & + \mathbf{D} (\mathbf{W}_k^l)^H d\mathbf{U}_k^l + \mathbf{H}_k^H (\mathbf{U}_k^l)^H \mathbf{W}_k^l \mathbf{C}^H d(\mathbf{F}^H)^l + \mathbf{W}_k^l \mathbf{D}^H d(\mathbf{U}_k^H)^l] + \\ & b_k^H A \mathbf{G}_{P_k}^{l+1} \circ (\boldsymbol{\alpha}_{P_k}^l)^T (\mathbf{F}^l)^H \mathbf{H}_k^H (\mathbf{U}_k^l)^H d\mathbf{W}_k^l + b_k^H A \mathbf{H}_k^H (\mathbf{U}_k^l)^H \mathbf{W}_k^l \mathbf{G}_{P_k}^{l+1} \\ & \circ (\boldsymbol{\alpha}_{P_k}^l)^T d(\mathbf{F}^H)^l + b_k^H A \mathbf{W}_k^l \mathbf{G}_{P_k}^{l+1} \circ (\boldsymbol{\alpha}_{P_k}^l)^T (\mathbf{F}^l)^H \mathbf{H}_k^H d(\mathbf{U}_k^H)^l \}, \end{aligned} \quad (3.35)$$

其中 $A \triangleq \frac{\Re\{b_k\}}{\sqrt{2\pi\rho_{P_k}^l}} e^{-\frac{|\Re\{\bar{b}_k\}|^2}{2(\rho_{P_k}^l)^2}}$, $B \triangleq A \frac{\Re\{b_k\}}{(\rho_{P_k}^l)^2}$, $\mathbf{C} \triangleq \sum_{i=1}^{D_k} \mathbf{p}_{i,k}^l b_{i,k}$ 以及 $\mathbf{D} \triangleq \mathbf{H}_k \mathbf{F}^l \mathbf{C}$ 。对式(3.28)–(3.30)进行同样操作, 可得相邻层中各种梯度的所有递归关系。以 $\mathbf{G}_{P_k}^l$ 为例, 为得到 $\mathbf{G}_{P_k}^l$ 的表达式, 只需将带 $d\mathbf{P}_k^l$ 的项单独罗列整理, 其系数即为 $\mathbf{G}_{P_k}^l$:

$$\begin{aligned} \mathbf{G}_{P_k}^l &= -\frac{1}{J} \sum_{j=1}^J \left(b_k^H B \mathbf{G}_{P_k}^{l+1} \circ (\boldsymbol{\alpha}_{P_k}^l)^T (\mathbf{F}^l)^H \mathbf{H}_k^H (\mathbf{U}_k^l)^H \circ \mathbf{W}_k^l \mathbf{E} - B \mathbf{G}_{W_k}^{l+1} \circ (\boldsymbol{\alpha}_{W_k}^l)^T \mathbf{U}_k^l \mathbf{D} \right. \\ & \circ \mathbf{E} + b_k A \left[\mathbf{G}_F^{l+1} \circ (\boldsymbol{\alpha}_{\theta_F}^l)^T \mathbf{H}_k^T (\mathbf{U}_k^{l+1})^T (\mathbf{W}_k^l)^H \right]^T - b_k A \mathbf{G}_{W_k}^{l+1} \circ (\boldsymbol{\alpha}_{W_k}^l)^T \mathbf{U}_k^l \mathbf{H}_k \mathbf{F}^l \\ & + b_k A \left[(\mathbf{F}^l)^T \mathbf{H}_k^T \mathbf{G}_{U_k}^{l+1} \circ (\boldsymbol{\alpha}_{\theta_{U_k}}^l)^T (\mathbf{W}_k^l)^H \right]^T - B \mathbf{D}^T \mathbf{G}_{U_k}^{l+1} \circ (\boldsymbol{\alpha}_{\theta_{U_k}}^l)^T (\mathbf{W}_k^l)^H \circ \mathbf{E} \\ & - B \mathbf{C}^H \mathbf{G}_{F^*}^{l+1} \circ (\boldsymbol{\alpha}_{\theta_F}^l)^T \mathbf{H}_k^H (\mathbf{U}_k^{l+1})^H \mathbf{W}_k^l \circ \mathbf{E} - B \mathbf{D}^H \mathbf{G}_{U_k}^{l+1} \circ (\boldsymbol{\alpha}_{\theta_{U_k}}^l)^T \mathbf{W}_k^l \circ \mathbf{E} \\ & \left. - B \mathbf{C}^T \mathbf{G}_F^{l+1} \circ (\boldsymbol{\alpha}_{\theta_F}^l)^T \mathbf{H}_k^T (\mathbf{U}_k^{l+1})^T (\mathbf{W}_k^l)^H \circ \mathbf{E} \right) + \mathbf{G}_{P_k}^{l+1}, \end{aligned} \quad (3.36)$$

其中, $\mathbf{E} \triangleq b_k (\mathbf{W}_k^l)^H \mathbf{U}_k^l \mathbf{H}_k \mathbf{F}^l$ 。 $\{\mathbf{G}_{P_k}^l, \mathbf{G}_{W_k}^l, \mathbf{G}_{U_k}^l, \mathbf{G}_{U_k}^{l*}, \mathbf{G}_F^l, \mathbf{G}_{F^*}^l\}$ 均同理可得。

对式(3.27)–(3.30)两边关于可训练参数 $\{\boldsymbol{\alpha}_X^l, \rho_X^l, \mathbf{O}_X^l\}$, $X \in \{P_k, W_k, \theta_{U_k}, \theta_F\}$ 进行同样的操作, 可以得到 \mathcal{L} 关于波束成形矩阵和可训练参数梯度之间的递推关系, 应用GCR即可推导得到每一层中可训练参数的梯度。 $\{\nabla_{\boldsymbol{\alpha}_X} \tilde{\rho}_e^l, \nabla_{\rho_X} \tilde{\rho}_e^l, \nabla_{\mathbf{O}_X} \tilde{\rho}_e^l\}$ 的具体表达式在附录A.1中给出。采用SGD算法更新可训练参数, 具体为 $\boldsymbol{\alpha}_{P_k}^{l,t+1} = \boldsymbol{\alpha}_{P_k}^{l,t} - \mu_{\boldsymbol{\alpha}_{P_k}}^t \nabla_{\boldsymbol{\alpha}_{P_k}^l} \tilde{\rho}_e^l$, 其中,

Algorithm 3.2 深度展开神经网络训练过程

- 1: 随机生成训练集 $\{\mathcal{X}, \mathcal{H}\}$ 。初始化误差精度 ϵ ，网络层数 L ，批尺寸 N ，最大迭代次数 I_{\max} 以及样本数 J 。初始化迭代索引 $t = 0$ 。随机初始化波束成形矩阵、可训练参数和步长。
- 2: **repeat**
- 3: **前向传播**: 从 $\{\mathcal{X}, \mathcal{H}\}$ 中随机选取 J 个样本 $\{\mathbf{s}, \mathbf{H}_k, \forall k\}$ ，根据式(3.27)–(3.30)计算 $\{\boldsymbol{\theta}_F^l, \mathbf{F}^l, l = 1, \dots, L-1\}$ 和 $\{\mathbf{P}_k^l, \mathbf{W}_k^l, \boldsymbol{\theta}_{U_k}^l, \mathbf{U}_k^l, l = 1, \dots, L, \forall k\}$ 。
- 4: 根据式(3.25)计算 $\boldsymbol{\theta}_F^L$ ，根据 $\boldsymbol{\theta}_F^L$ 计算 \mathbf{F}^L 。将 $\{\mathbf{P}_k^L, \mathbf{W}_k^L, \mathbf{U}_k^L, \mathbf{F}^L\}$ 代入式(3.31)。
- 5: **后向传播**: 计算最后一层的梯度 $\{\mathbf{F}^L, (\mathbf{F}^L)^*\}$ 并根据式(3.34)计算 $\boldsymbol{\theta}_F^L$ 。随后根据第2.1.3小节计算 $\{\mathbf{P}_k^l, \mathbf{W}_k^l, \mathbf{U}_k^l, (\mathbf{U}_k^l)^*, \boldsymbol{\theta}_{U_k}^l, l = L, \dots, 0, \forall k\}$ 和 $\{\mathbf{F}^l, (\mathbf{F}^l)^*, \boldsymbol{\theta}_F^l, l = L-1, \dots, 0\}$ 的梯度。最后根据附录A.1计算可训练参数的梯度。
- 6: 计算一批中的平均梯度，并根据SGD方法更新可训练参数。
- 7: 更新迭代索引: $t = t + 1$ 。
- 8: **until** 验证集中的损失函数收敛或 $t > I_{\max}$ 。

$\mu_{\alpha_{P_k}}^t$ 为第 t 次迭代时 $\alpha_{P_k}^l$ 的步长，该步长随着迭代次数 t 衰减。为了避免BP中的梯度消失问题，需对 $\{\mathbf{G}_{P_k}^l, \mathbf{G}_{W_k}^l, \mathbf{G}_{U_k}^l, \mathbf{G}_{U_k}^{l*}, \mathbf{G}_F^l, \mathbf{G}_{F^*}^l\}$ 采取归一化操作。以 $\mathbf{G}_{P_k}^l$ 为例，其归一化规则为

$$\mathbf{G}_{P_k}^l \leftarrow \frac{K \mathbf{G}_{P_k}^l}{\sum_k \|\mathbf{G}_{P_k}^l\|}. \quad (3.37)$$

可训练参数采取随机初始化，波束成形矩阵 $\{\mathbf{P}_k^0, \mathbf{W}_k^0, \boldsymbol{\theta}_{U_k}^0, \boldsymbol{\theta}_F^0\}$ 的初始化基于传统的信道对准方法^[7]。深度展开神经网络的训练过程可概括为**Algorithm 3.2**。

3.4 性能分析

在本节中，首先证明了所提出的深度展开神经网络的收敛性。随后提出了一个联合优化混合AD波束成形矩阵的CNN作为对比算法。此外，本节还分析了所提方案的计算复杂性和泛化能力。最后，深度展开网络被扩展到 M -QAM调制信号。

3.4.1 收敛性分析

一般来说，大多数现有的深度展开神经网络都没有收敛保证。由于在网络中引入了可训练参数，以及深度展开网络与原始迭代算法之间的结构差异，即使所参考的传统迭代算法已有强大的理论支持，深度展开网络的收敛性仍很难证明。本小节对深度展开网络的收敛性进行了理论分析。

定理 3.1. (深度展开网络收敛性分析): 总能找到一组参数, 使得深度展开网络中一层的性能可逼近GD迭代算法中多次迭代的性能。因此:

- 1) 深度展开网络中若干层的性能可逼近GD迭代算法的最终性能;
- 2) 深度展开网络可收敛到驻点, 且层数远小于GD迭代算法。

证明: 以两层为例, 如第3.2节中所述, \mathbf{P}_t 与 \mathbf{P}_{t+2} 之间的映射如下:

$$\begin{aligned} \mathbf{P}_{t+2} = & \mathbf{P}_t - \mu_P A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2\sigma^2}} \Re\{b\} \mathbf{F}_t^H \mathbf{H}^H \mathbf{U}_t^H \mathbf{W}_t (\mathbf{b}^{q_j})^H \\ & - \mu_P A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2\sigma^2}} \Re\{b\} \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{W}_{t+1} (\mathbf{b}^{q_j})^H. \end{aligned} \quad (3.38)$$

其中, 为了表述更清楚, 省略了索引 k 和 i 。

同样的, 在深度展开网络中, \mathbf{P}_l 和 \mathbf{P}_{l+1} 间的映射为

$$\mathbf{P}_{l+1} = \mathbf{P}_l - \boldsymbol{\alpha}_P^l \circ \left(A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2(\sigma_P^l)^2}} \Re\{b\} \mathbf{F}_l^H \mathbf{H}^H \mathbf{U}_l^H \mathbf{W}_l (\mathbf{b}^{q_j})^H \right) + \mathbf{O}_P^l. \quad (3.39)$$

基于此, 下文将证明深度展开网络中一层的性能可以逼近GD算法中两次迭代的性能。假设两个算法的初始值相同, 即 $\mathbf{P}_l = \mathbf{P}_t$, 则只需证明 $\|\mathbf{P}_{t+2} - \mathbf{P}_{l+1}\|^2 < \varepsilon$, $\varepsilon > 0$ 。

- 场景1 (确定性信道): 当信道矩阵 \mathbf{H} 是固定的或仅非常缓慢地改变时, 需证明对于给定的 \mathbf{H} , 存在参数 $\boldsymbol{\alpha}_X$, ρ_X 和 \mathbf{O}_X 使得 $\|\mathbf{P}_{t+2} - \mathbf{P}_{l+1}\|^2 < \varepsilon$ 成立。通过对比式(3.38)和式(3.39), 可较容易地发现这么一组参数:

$$\boldsymbol{\alpha}_P^l = \mu_P \mathbf{1}^{R_t \times D_k}, \quad (3.40a)$$

$$\mathbf{O}_P^l = -\mu_P A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2\sigma^2}} \Re\{b\} \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{W}_{t+1} (\mathbf{b}^{q_j})^H,$$

$$\rho_P^l = \varrho, \quad (3.40b)$$

其中, $\mathbf{1}^{R_t \times D_k}$ 是元素全部为1的 $R_t \times D_k$ 维矩阵。

- 场景2 (服从固定分布的信道): 当信道矩阵 \mathbf{H} 服从某种固定分布时, 需证明存在参数 $\boldsymbol{\alpha}_X$, ρ_X 和 \mathbf{O}_X 使得下述不等式成立:

$$\mathbb{E}_{\mathbf{H}} \left\{ \|\mathbf{P}_{t+2} - \mathbf{P}_{l+1}\|^2 \right\} \leq \varepsilon. \quad (3.41)$$

为了简化问题, 设 $\boldsymbol{\alpha}_P^l = \mu_P \mathbf{1}^{R_t \times D_k}$, $\rho_P^l = \varrho$, 则需证明

$$\mathbb{E}_{\mathbf{H}} \left\{ \left\| \mathbf{O}_P - \mu_P A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2\varrho^2}} \Re\{b\} \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{W}_{t+1} (\mathbf{b}^{q_j})^H \right\|^2 \right\} \leq \varepsilon. \quad (3.42)$$

变量 \mathbf{F}_{t+1} , \mathbf{U}_{t+1} 和 \mathbf{W}_{t+1} 均与 \mathbf{P}_t 有关, 为了简化表达过程, 只展开 \mathbf{W}_{t+1} , 式(3.42) 的左边可转化成:

$$\begin{aligned} & \mathbb{E}_{\mathbf{H}} \left\{ \left\| \mathbf{O}_P - \mu_P A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2\varrho^2}} \Re\{b\} \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{W}_{t+1} (\mathbf{b}^{q_j})^H \right\|^2 \right\} \\ &= \mathbb{E}_{\mathbf{H}} \left\{ \left\| \mathbf{O}_P - \mu_P A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2\varrho^2}} \Re\{b\} \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{W}_t (\mathbf{b}^{q_j})^H \right. \right. \\ & \quad + \mu_P \mu_W A^2 \sum_{j=1}^J \sum_{m=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2 + |\Re\{\bar{b}^{q_m}\}|^2}{2\varrho^2}} \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{U}_t \mathbf{H} \mathbf{F}_t \sum_{k'=1}^K \mathbf{P}_t \mathbf{b}^{q_m} (\mathbf{b}^{q_j})^H \\ & \quad - \mu_P^2 \mu_W A^3 \sum_{j=1}^J \sum_{m=1}^J \sum_{n=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2 + |\Re\{\bar{b}^{q_m}\}|^2 + |\Re\{\bar{b}^{q_n}\}|^2}{2\varrho^2}} \Re\{b\} \\ & \quad \left. \left. \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{U}_t \mathbf{H} \mathbf{F}_t \mathbf{F}_t^H \mathbf{H}^H \mathbf{U}_t^H \mathbf{W}_t (\mathbf{b}^{q_n})^H \sum_{k'=1}^K \mathbf{b}^{q_m} (\mathbf{b}^{q_j})^H \right\|^2 \right\} \\ & \leq \mathbb{E}_{\mathbf{H}} \left\{ \left\| \mathbf{O}_P - \mu_P A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2\varrho^2}} \Re\{b\} \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{W}_t (\mathbf{b}^{q_j})^H \right\|^2 \right\} \\ & \quad + \mathbb{E}_{\mathbf{H}} \left\{ \sum_{j=1}^J \sum_{m=1}^J \sum_{k'=1}^K \left\| \mu_P \mu_W A^2 e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2 + |\Re\{\bar{b}^{q_m}\}|^2}{2\varrho^2}} \right\|^2 \left\| \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \right\|^2 \left\| \mathbf{U}_t \mathbf{H} \mathbf{F}_t \right\|^2 \right. \\ & \quad \left. \left\| \mathbf{P}_t \mathbf{b}^{q_m} (\mathbf{b}^{q_j})^H \right\|^2 \right\} + \mathbb{E}_{\mathbf{H}} \left\{ \sum_{j=1}^J \sum_{m=1}^J \sum_{n=1}^J \sum_{k'=1}^K \left\| \mu_P^2 \mu_W A^3 e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2 + |\Re\{\bar{b}^{q_m}\}|^2 + |\Re\{\bar{b}^{q_n}\}|^2}{2\varrho^2}} \right\|^2 \right. \\ & \quad \left. \left\| \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \right\|^2 \left\| \mathbf{U}_t \mathbf{H} \mathbf{F}_t \right\|^4 \left\| \mathbf{W}_t (\mathbf{b}^{q_n})^H \mathbf{b}^{q_m} (\mathbf{b}^{q_j})^H \right\|^2 \right\}, \end{aligned} \quad (3.43)$$

其中第一个等式基于式(3.23)和式(3.17)得到, 第二个不等式则是基于绝对值不等式得到。在式(3.43)中, $\mu_P A \sum_{j=1}^J e^{-\frac{|\Re\{\bar{b}^{q_j}\}|^2}{2\varrho^2}} \Re\{b\} \mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H \mathbf{W}_t (\mathbf{b}^{q_j})^H$ 为关于 \mathbf{H} 的函数, 其均值可由 $\mathbb{E}\{\mathbf{H}\}$ 计算得到。设该均值为 γ , 根据大数定理, 当信道 \mathbf{H} 的样本数足够

多时，式(3.43)可简化为

$$\begin{aligned}
& \mathbb{E}_{\mathbf{H}} \left\{ \|\mathbf{P}_{t+2} - \mathbf{P}_{t+1}\|^2 \right\} \\
& \leq \mathbb{E}_{\mathbf{H}} \left\{ \sum_{j=1}^J \sum_{m=1}^J \sum_{k'=1}^K \left\| \mu_P \mu_W A^2 e^{-\frac{|\Re\{\tilde{\mathbf{b}}^{qj}\}|^2 + |\Re\{\tilde{\mathbf{b}}^{qm}\}|^2}{2e^2}} \right\|^2 \|\mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H\|^2 \|\mathbf{U}_t \mathbf{H} \mathbf{F}_t\|^2 \right. \\
& \quad \left. \|\mathbf{P}_t \mathbf{b}^{qm} (\mathbf{b}^{qj})^H\|^2 \right\} + \mathbb{E}_{\mathbf{H}} \left\{ \sum_{j=1}^J \sum_{m=1}^J \sum_{n=1}^J \sum_{k'=1}^K \left\| \mu_P^2 \mu_W A^3 e^{-\frac{|\Re\{\tilde{\mathbf{b}}^{qj}\}|^2 + |\Re\{\tilde{\mathbf{b}}^{qm}\}|^2 + |\Re\{\tilde{\mathbf{b}}^{qn}\}|^2}{2e^2}} \right\|^2 \right. \\
& \quad \left. \|\mathbf{F}_{t+1}^H \mathbf{H}^H \mathbf{U}_{t+1}^H\|^2 \|\mathbf{U}_t \mathbf{H} \mathbf{F}_t\|^4 \|\mathbf{W}_t (\mathbf{b}^{qn})^H \mathbf{b}^{qm} (\mathbf{b}^{qj})^H\|^2 \right\} = \varepsilon.
\end{aligned} \tag{3.44}$$

不等式右边与 \mathbf{H} 无关，可被设为常数 ε 。

两种场景均则已得证深度展开网络一层的性能可逼近GD迭代算法两层的性能。由此可得，当深度展开网络具有更复杂的结构或参数得到更好的训练后，其一层性能可以逼近GD算法更多次迭代的性能，因此，所提出的深度展开网络可逼近GD算法的最终性能。此外，GD传统算法已被证明收敛到驻点，由此可得所提出的深度展开神经网络也能够收敛到驻点，且层数远低于传统迭代算法。

3.4.2 CNN黑盒算法

为了与所提的深度展开算法形成对比，本小节基于文献[23]中的NN结构设计了CNN黑盒算法来解决混合AD收发机的设计问题，具体来说是由4个CNN组成的复合结构，其网络整体结构图如图3-4所示。图3-4顶部的虚线矩形框代表发射机侧，框中的两个网络“P_NN”和“ θ_F _NN”分别表示数字发射波束形成矩阵 \mathbf{P}_k 和模拟发射波束形成相位矩阵 θ_F ，原始符号向量 \mathbf{b}_k 在经过这两个波束成形器后被转换为预编码信号。底部的虚线矩框代表接收机侧，网络“W_NN”和“ θ_U _NN”分别表示数字接收波束形成矩阵 \mathbf{W}_k 和模拟接收波束形成相位矩阵 θ_U ，接收信号 \mathbf{y}_k 经过这两个波束成形器后产生 $\tilde{\mathbf{b}}_k$ 。在训练阶段，SER通过将原始信号 \mathbf{b}_k 与检测信号 $\hat{\mathbf{b}}_k$ 比较而得，损失函数为SER函数(3.15)。由于常规的神经网络训练平台（例如Tensorflow）不能直接处理复数矩阵，因此信道矩阵 $\mathbf{H}_k \in \mathbb{C}^{N_r \times N_t}$ 被转换为 $2 \times N_r \times N_t$ 维实数张量 $\tilde{\mathbf{H}}_k$ 。“ θ_F _NN”和“ θ_U _NN”的输入是 $\tilde{\mathbf{H}}_k$ 和 \mathbf{b}_k ，其输出用于生成低维等效信道 \mathbf{H}_{eq} ，并成为“P_NN”和“W_NN”的输入。

每个CNN由卷积层、池化层、全连接层和批标准化（Batch Normalization, BN）层组成。为了同时兼顾训练开销和系统性能，本小节选用了相对简单的网络结构，其中每

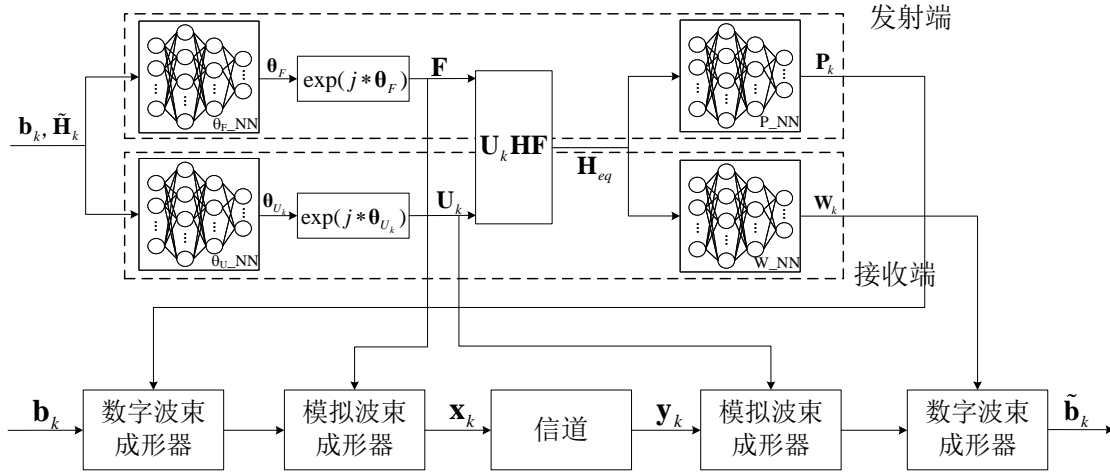


图 3-4 CNN黑盒算法结构图

个CNN的层数设置为17。为了满足发射功率约束，“P-NN”的输出需要进行归一化，具体如式(3.26)。

在训练阶段，用SGD算法更新CNN的参数，而在测试阶段，仅包含FP。

3.4.3 复杂度分析

本小节对深度展开网络及CNN黑盒算法的计算复杂度进行分析。首先从参数维度入手，深度展开网络中每层引入的参数数量为 $2(3K + KN_tD + KN_{r,k}D + KR_{r,k}N_{r,k} + R_tN_t)$ 。由于和模拟发射波束形成矩阵 \mathbf{F} 相关的参数 $\{\alpha_{\theta_F}^L, \rho_F^L, \rho_{FH}^L, \mathbf{O}_{\theta_F}^L\}$ 在最后一层中并未使用，因此深度展开网络的参数总维度为 $2KL(3 + N_tD + N_{r,k}D + R_{r,k}N_{r,k}) + 2(L - 1)R_tN_t$ 。而在CNN黑盒算法中，训练参数仅在卷积层和全连接层中产生，因此参数维度为这两个部分的参数总和。卷积层中涉及到的参数数量为 $\sum_{l=1}^{L_c} K_l C_{l-1} C_l$ ，其中， L_c 为卷积层层数， K_l 为卷积核大小， C_l 第 l 层中的通道数。全连接层中的参数总数为 $K^2 N_t N_{r,k} F_{in} F_{out}$ ，其中， F_{in} 和 F_{out} 分别为全连接层的输入及输出维度。

基于上述分析可给出所设计算法的计算复杂度。首先，GD迭代算法的计算复杂度为 $\mathcal{O}(TJS(KN_tD + KN_{r,k}D + KR_{r,k}N_{r,k} + R_tN_t))$ ，其中， T 和 S 分别为迭代层数及测试集大小。而CNN黑盒算法的计算复杂度则为 $\mathcal{O}(\sum_{l=2}^{L_c} L_c^2 K_l C_{l-1} C_l + K^2 N_t N_{r,k} F_{in} F_{out} + KN_tD + KN_{r,k}D + KR_{r,k}N_{r,k} + R_tN_t)$ ，其中， $L_c \triangleq (C_{in} - K_l + 2P)/S_t + 1$ ， C_{in} 为卷积层的输入大小， P 为填充大小， S_t 为滑动步长。深度展开算法在测试阶段的计算复杂度为 $\mathcal{O}(LJS(KN_tD + KN_{r,k}D + KR_{r,k}N_{r,k} + R_tN_t))$ ，其中， L 为网络层数。通常在实际中， $L \ll T$ ，这意味着与传统GD迭代算法相比，深度展开算法可以有效地降低计算复杂性。此外，和CNN黑盒算法相比，深度展开算法的参数维度与计算复杂度均大大降低。

3.4.4 泛化能力分析

所提的深度展开算法具有较好的泛化能力，具体表现在如果已经训练了一个较大维度的深度展开网络，则可以直接用于实现较小维度的网络，而不需要再重新训练。假设原始较大规模网络的维度为 $(N_{t0}, N_{r,k0}, K_0)$ ，较小规模网络的维度为 $(N_{t1}, N_{r,k1}, K_1)$ ，且 $N_{t0} \leq N_{t1}$ ， $N_{r,k0} \leq N_{r,k1}$ 以及 $K_0 \leq K_1$ ，则在测试阶段，仅需输入 $\{\mathbf{H}_k, k \leq K_1\}$ ，同时令 $\{\mathbf{H}_k = \mathbf{0}, K_1 < k \leq K_0\}$ ，并令 \mathbf{H}_k 中对应的行向量和列向量均为 $\mathbf{0}$ ，即可直接得到输出，而无需重新训练一个输入维度为 $(N_{t1}, N_{r,k1}, K_1)$ 的网络。

3.4.5 M -QAM信号拓展

所提出的深度展开算法还可以扩展到高阶调制方案，如 M -QAM信号。在这种情况下，恢复信号的判定规则为

$$\begin{aligned} \Re\{\hat{b}_{i,k}\} &= \begin{cases} F_1, & \text{if } \Re\{\tilde{b}_{i,k}\} \leq c_{i,k}(F_1 + 1) \\ F_m, & \text{if } c_{i,k}(F_m - 1) < \Re\{\tilde{b}_{i,k}\} \leq c_{i,k}(F_m + 1), 2 \leq m \leq \sqrt{M} - 1 \\ F_{\sqrt{M}}, & \text{if } \Re\{\tilde{b}_{i,k}\} > c_{i,k}(F_{\sqrt{M}-1}), \end{cases} \\ \Im\{\hat{b}_{i,k}\} &= \begin{cases} F_1, & \text{if } \Im\{\tilde{b}_{i,k}\} \leq c_{i,k}(F_1 + 1) \\ F_n, & \text{if } c_{i,k}(F_n - 1) < \Im\{\tilde{b}_{i,k}\} \leq c_{i,k}(F_n + 1), 2 \leq n \leq \sqrt{M} - 1 \\ F_{\sqrt{M}}, & \text{if } \Im\{\tilde{b}_{i,k}\} > c_{i,k}(F_{\sqrt{M}-1}), \end{cases} \end{aligned} \quad (3.45)$$

其中， $c_{i,k} \triangleq \mathbf{w}_{i,k}^H \mathbf{U}_k \mathbf{H}_k \mathbf{F} \mathbf{p}_{i,k}$ 。通常来说， $c_{i,k}$ 是一个复值，需要对 $c_{i,k}$ 进行如式(3.46)的相位旋转来保证其为正实数。

$$\mathbf{p}_{i,k} \leftarrow \frac{c_{i,k}}{|c_{i,k}|} \mathbf{p}_{i,k}, \quad \mathbf{w}_{i,k} \leftarrow \frac{c_{i,k}}{|c_{i,k}|} \mathbf{w}_{i,k}, \quad \mathbf{U}_k \leftarrow \frac{c_{i,k}}{|c_{i,k}|} \mathbf{U}_k, \quad \mathbf{F} \leftarrow \frac{c_{i,k}}{|c_{i,k}|} \mathbf{F}, \quad (3.46)$$

当调制方式为 M -QAM时，发射信号 \mathbf{s} 的有效序列总数为 $N_b = M^{D-1}$ 种，因此，与QPSK调制信号类似，随机选取 J 个不同的发射信号向量，并定义 $\tilde{b}_{i,k}$ 的无噪声分量为 $\bar{b}_{i,k}$ ，则SER表达式为

$$\mathcal{P}_e^R = \frac{\varphi}{J\sqrt{\pi}} \sum_{j=1}^J \int_{-\infty}^{\frac{c_{i,k}(\Re\{b_{i,k}\}-1) - \Re\{\bar{b}_{i,k}^{q_j}\}}{\sqrt{2e}}} e^{-s^2} ds, \quad (3.47)$$

$$\mathcal{P}_e^I = \frac{\varphi}{J\sqrt{\pi}} \sum_{j=1}^J \int_{-\infty}^{\frac{c_{i,k}(\Im\{b_{i,k}\}-1) - \Im\{\bar{b}_{i,k}^{q_j}\}}{\sqrt{2e}}} e^{-s^2} ds, \quad (3.48)$$

其中, $\varphi \triangleq \frac{2\sqrt{M}-2}{\sqrt{M}}$ [63]。

针对 M -QAM 调制信号, 其 GD 迭代算法的推导与 QPSK 调制信号步骤完全相同, 向量更新也与式(3.22)–(3.25) 类似, 其中只有梯度表达式需略作修改。针对 M -QAM 信号的深度展开网络也与 QPSK 信号场景类似, 其引入的可训练参数可参考 QPSK 信号场景。为了简洁起见, 省略了这两种算法方案的具体细节。第 3.5 节中的仿真结果验证了针对 M -QAM 信号的深度展开网络的有效性。

3.5 仿真结果

本节讨论所提出算法的性能, 首先简单介绍仿真设置及所提出的算法方案与对比算法, 随后验证深度展开算法训练阶段的收敛性, 最后分别针对 QPSK 信号和 M -QAM 信号将所提的 GD 迭代算法以及深度展开算法与 CNN 黑盒算法及其余文献中的传统算法进行多方面的性能比较。

3.5.1 仿真设置

考虑如图 3-1 的多用户 MIMO 系统下行链路传输。BS 配备有 $N_t = 64$ 个发射天线元件和 $R_t = 8$ 个 RF 链。考虑 $K = 2$ 个用户, 其中每个用户有 $N_{r,k} = 8$ 个接收天线和 $R_{r,k} = 4$ 个 RF 链。BS 对每个用户发送 $D_k = 3$ 个数据流, 均由 QPSK 信号或 M -QAM 信号组成。BS 和用户之间的信道矩阵基于式(3.3)中给出的模型生成。

用于训练深度展开网络的数据集包含随机生成的 500 个信道矩阵, 并使用发射符号和接收符号分别作为真实信号和目标信号。在训练阶段, 式(3.31)中的期望用式(3.15)中损失函数的平均值来近似。在深度展开网络中, 将批尺寸设置为 $N = 20$, 网络层数设置为 $L = 15$ 。

在性能评估时, 随机生成 1000 个信道矩阵作为测试集。对于 GD 迭代算法, 使用随机选择的初始值将其运行 50 次, 并保留最佳结果作为其性能上界。考虑以下算法作为比较:

- **GD:** 基于第 3.2 节提出的 GD 迭代算法交替优化波束形成矩阵。
- **OMP:** 基于文献[7]中的 OMP 算法设计近似最优混合波束形成矩阵来逼近最优无约束波束形成矩阵。
- **MO:** 基于文献[12]中的 MO 算法交替优化混合波束形成矩阵。
- **CNN 黑盒算法:** 基于第 3.4.2 小节中提出的 CNN 黑盒算法联合优化混合波束形成矩阵。

- **深度展开算法:** 基于第3.3节中提出的深度展开算法联合优化混合波束形成矩阵。

3.5.2 深度展开算法收敛性能

图3.5(a)展示了当信噪比 (Signal-to-Noise Ratio, SNR) 为20dB时, 批尺寸 N 对深度展开算法收敛性能的影响。可以看到, 当选择较小的批尺寸时, 收敛速度较快, 且收敛后的最终SER较小, 而较大的批尺寸则能够使收敛后的SER波动较小。事实上, 随着批尺寸的减少, 梯度向量中引入了额外的随机性, 能够有效防止神经网络陷入局部最优。同时考虑收敛速度与训练速度, 本文选择了 $N = 20$ 作为训练集中的批尺寸。图3.5(b)给出了当SNR=20dB时, 深度展开网络所选择的步长, 即 $\{\mu_{\alpha_X}, \mu_{\rho_X}, \mu_{O_X}\}$, 对SER性能的影响。具有更大步长的网络通常仅需更少的迭代次数来达到收敛, 但同时会导致收敛后的最终SER更大。在本文中, 为了兼顾系统性能和收敛速度, 选择了随迭代次数衰减的步长 $0.02 \times 0.5^{\lfloor \frac{k}{10} \rfloor}$ 。图3.5(c)描述了网络层数 L 对算法收敛性能的影响。如图所示, 层数增加会使收敛速度减慢, 并对收敛后的最终SER造成影响。随着 L 从6增加到18, 最终SER逐渐降低, 直到达到下限, 随后又开始增加。实际上, 随着 L 的进一步增加, 梯度误差逐层累积, 梯度消失的影响也更加显著, 这都会导致SER重新增加。

3.5.3 QPSK信号SER性能

图3-6给出了在大规模MIMO系统下行链路传输中所提出的深度展开算法和对比基准算法的SER性能比较。结果表明, 所提出的基于MSER的相关算法在SER方面显著优于现有的MMSE相关算法。此外, 深度展开算法在设计时充分利用了GD迭代算法的结构并引入了若干有效的可训练参数, 因此其性能明显优于CNN黑盒算法, 并可逼近基于MSER的GD混合波束成形算法的性能。还可以看到, CNN黑盒算法在低SNR下性能比基于MMSE的MO算法更差, 而在高SNR情况下则相反, 其原因在于低SNR时数据受到噪声的高度影响, CNN中的参数无法得到有效训练, 因此性能表现较差, 相反, 在高SNR时网络可以有效提取特征及训练参数, 并且是直接基于MSER准则设计的, 因此在SER性能上可以优于基于MMSE的MO算法。

图3-7描述了所提出的深度展开算法和GD迭代算法的收敛性能。与GD迭代算法相比, 深度展开算法显著提高了收敛速度并减小了训练负担。综合考虑计算复杂性和收敛性能, 选取 $L = 15$ 层作为网络层数。

表3-1展示了所提出的深度展开算法、GD迭代算法和CNN黑盒算法的最终稳态SER性能与SNR的关系。在本表中强调从迭代次数/层数的维度进行比较。可以看到, 与CNN黑

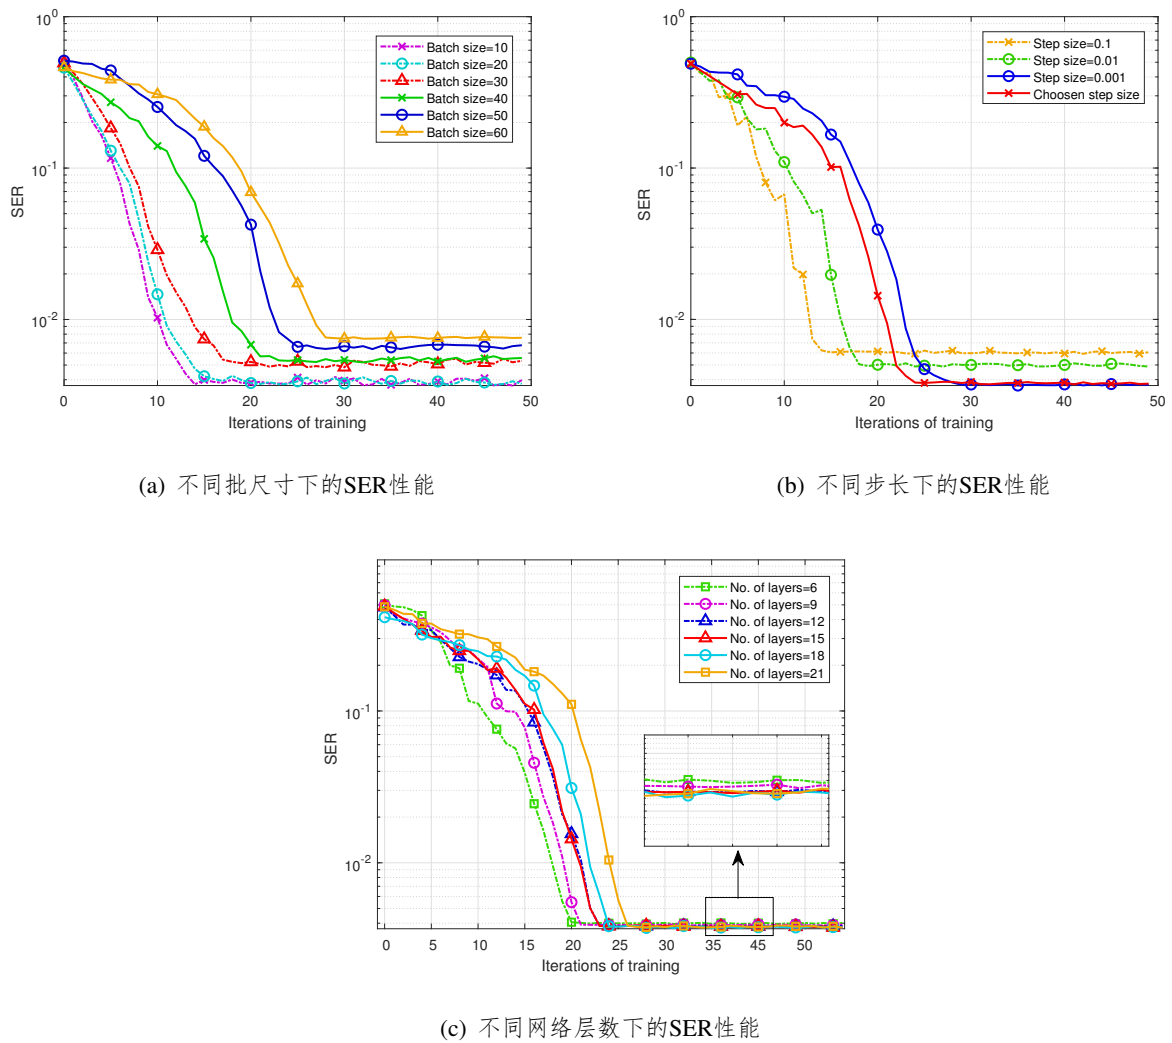


图 3-5 深度展开算法收敛性能

盒算法相比，所提出的深度展开网络能以更少的层数达到相似甚至更好的性能，而GD算法则需要远远大于上述两种算法的迭代次数才能达到同等性能水平。因此，在测试阶段，与GD迭代算法相比，两种NN方案的计算复杂性大大降低。

表3-2给出了不同规模MIMO系统的SER性能，即当 $\text{SNR} = 20\text{dB}$ 时，改变用户数 K 与接收RF链数 $R_{R,K}$ 。表中深度展开算法的百分比由深度展开算法的SER除以GD迭代算法的SER计算得到（下述所有表中的百分比均同样得到）。CNN黑盒算法的百分比同理可得。从表中观察可得，深度展开算法和GD迭代算法之间的性能差距随着 K 的增加而略有增加。此外，CNN对比算法与深度展开算法的SER差距也随着 K 的增加而增大。造成该现象的原因是多用户干扰随着用户数的增加而增大，继而阻碍了神经网络从训练数据中提取有效特征。尽管如此，所提出的深度展开算法总是能逼近基于MSER的GD迭代算法的性能。

表3-3描述了当 $\text{SNR} = 20\text{dB}$ 时，两种NN算法的SER性能与训练集样本数的关系。比较




图 3-6 不同算法的SER性能($R_{r,k} = 4, D = 3$)




图 3-7 不同算法的收敛性能

可得，深度展开算法所需的训练样本数要远远少于CNN黑盒算法，因为前者的结构是在传统GD算法的基础上开发的，并充分利用了传统算法的优势。

图3-8说明了在不完美CSI的情况下，不同算法SER性能与SNR的关系。信道估计误差为 $\mathbf{H}_k = \bar{\mathbf{H}}_k + \sigma_h \Delta \mathbf{K}_k, \forall k \in \mathcal{K}$ ，其中 \mathbf{H}_k 是完美信道矩阵， $\bar{\mathbf{H}}_k$ 为其估计值， $\sigma_h \Delta \mathbf{K}_k$ 是估计误差， $\Delta \mathbf{K}_k$ 是均值为零、方差遵循复高斯分布的随机矩阵，而 σ_h^2 则为估计误差方差。为简单起见，假设 $\forall k, \sigma_h^2$ 均相同。可以看到，SER性能随着误差方差 σ_h^2 的增加而减小。此外，所提出的深度展开算法性能表现最优，其次是基于基于MSER的GD迭代算法和基于MMSE的GD迭代算法。仿真结果表明，与其他算法方案相比，所提出的深度展开算法对信道不确定性具有更强的鲁棒性。

表 3-1 不同算法的SER性能与SNR和迭代次数/层数的关系

	GD迭代算法 500次迭代	CNN 黑盒算法 17层网络	深度展开算法 15层网络
SNR = 5 dB	4.11×10^{-2}	5.92×10^{-2}	4.27×10^{-2}
SNR = 15 dB	1.06×10^{-2}	1.51×10^{-2}	1.09×10^{-2}
SNR = 25 dB	1.09×10^{-3}	1.54×10^{-3}	1.11×10^{-3}

表 3-2 不同规模MIMO系统的SER性能

$(K, R_{r,k})$	(1, 4)	(2, 4)	(3, 2)	(4, 2)
GD迭代算法	1.15×10^{-3}	3.64×10^{-3}	6.83×10^{-3}	1.56×10^{-2}
深度展开算法	98.43%	97.85%	97.07%	95.86%
CNN黑盒算法	73.14%	70.48%	68.52%	65.02%

表 3-3 不同训练样本数下的SER性能

训练样本数	5000	10000	15000	20000	25000	30000	35000	40000
CNN黑盒算法	66.03%	70.48%	72.55%	73.61%	74.13%	74.21%	74.36%	74.36%
训练样本数	100	200	300	400	500	600	700	800
深度展开算法	92.83%	95.04%	96.21%	97.37%	97.85%	97.94%	98.02%	98.02%

图3-9通过不同信道模型下的SER性能展示了所提出算法方案的迁移学习能力。具体而言，在仿真中首先使用mmWave信道作为训练集训练网络，然后将信道模型转变为高斯信道。重新训练网络时，前10层的参数固定不变，只有剩余层的参数可以被重新训练。结果表明，迁移后的深度展开网络和GD迭代算法之间的性能差距要显著小于迁移后的CNN黑盒网络与GD算法之间的性能差距。由此可得，所提出的深度展开算法在迁移学习方面具有更好的表现。这是因为它可以有效应用从旧场景中提取的信息，并能快速适应新场景，从而大大减少训练时间。

表3-4给出了不同系统规模下两种NN算法方案的计算复杂性，具体体现为训练阶段和测试阶段的CPU运行时间。从结果中可以看到，训练阶段和测试阶段的CPU运行时间都随着 N_t 和 K 的增加而增加。显然，与CNN相比，深度展开网络需要的训练时间更少，这证明了深度展开算法可以有效地加快收敛速度并减少训练开销。由于深度展开算法引入




图 3-8 不完美CSI下的SER性能




图 3-9 迁移学习能力

的可训练参数远小于传统NN算法，且其梯度在BP中以闭式解的形式进行计算，因此与使用“tensorflow”平台计算反向梯度的CNN相比，其效率得到大大提升。此外，深度展开算法和CNN黑盒算法之间的CPU运行时间差距也随着 N_t 和 K 的增加而增加，且训练时间远大于测试时间，其原因是训练阶段的计算更复杂，而测试阶段只有FP过程。

表3-5展示了所提出的深度展开算法的泛化能力。在仿真中首先训练具有 $N_t = 128$ 、 $R_t = 32$ 、 $N_r = 16$ 、 $R_r = 4$ 、 $K = 8$ 以及 $D_k = 3$ 的大规模网络，然后用此大规模网络测试具有较少用户数 K 和发射天线数 N_t 的小规模系统的SER性能。结果表明，将此大规模网络用于测试具有较小 K 和 N_t 场景的性能损失很小，从而说明了所提出的深度展开算法具有较强的泛化能力。

表 3-4 不同算法的CPU运行时间

(N_t, K, R_r)	训练阶段的CPU运行时间 (分钟)		测试阶段的CPU运行时间 (秒)	
	深度展开算法	CNN黑盒算法	深度展开算法	CNN黑盒算法
(64, 2, 4)	5.35	8.73	0.01	0.01
(64, 3, 2)	12.46	21.58	0.01	0.1
(128, 4, 8)	84.45	130.79	0.07	0.11
(128, 5, 6)	95.73	200.46	0.10	0.13
(128, 6, 5)	109.48	242.35	0.14	0.17
(128, 7, 4)	129.63	295.43	0.17	0.22
(128, 8, 4)	162.86	360.15	0.24	0.28

表 3-5 深度展开算法的泛化性能

$N_t \backslash K$	8	6	4	2
	128	98.04%	98.45%	98.93%
64	—	—	96.94%	97.52%

表 3-6 SER性能与迭代次数/层数的关系

	GD迭代算法	CNN黑盒算法	深度展开算法
	500次迭代	17层	15层
SNR = 25 dB	9.8×10^{-3}	1.36×10^{-2}	1.01×10^{-2}

3.5.4 16-QAM信号SER性能

图3-10展示了16-QAM调制信号时不同算法的SER性能。与QPSK信号类似，16-QAM调制信号的MSER相关算法的性能优于MMSE相关算法。同时，深度展开算法的SER性能可逼近基于MSER的GD混合波束形成算法，尤其是随着SNR的增加，这两种算法之间的性能差距逐渐减小。此外，所提出的深度展开算法在较低SNR时显著优于CNN算法。表3-6给出了SNR=25dB的SER性能与迭代次数/层数的关系。可以看到，深度展开算法在实现与GD迭代算法几乎相同的性能时能够显著减少迭代次数，降低计算复杂度。上述结果均表明，所提出的深度展开算法对于16-QAM信号仍然有效，由此可见，该算法仍可适用于其他高阶调制信号。




图 3-10 16-QAM信号的SER性能

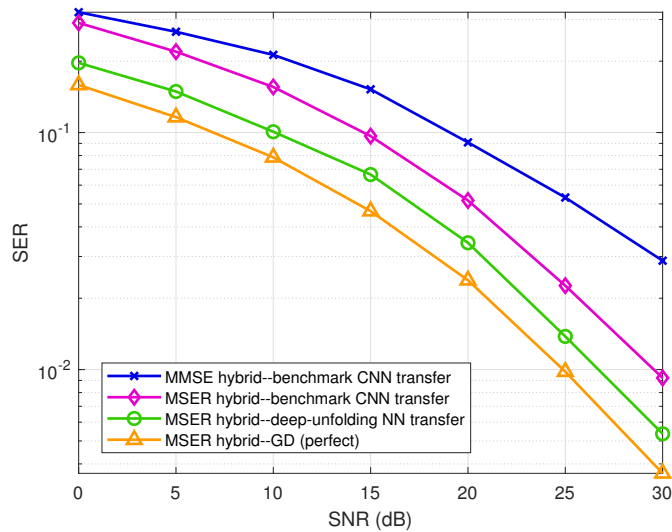


图 3-11 迁移学习能力

图3-11描述了所提出的算法在16-QAM信号时的迁移能力。可以看到，在改变信道模型后，深度展开算法和GD迭代算法之间的性能差距要远小于CNN黑盒算法与GD迭代算法间的性能差距。由此可得，与CNN网络相比，所提出的深度展开神经网络具有更好的迁移学习能力。

3.6 本章小结

本章主要考虑了基于MSER准则的大规模MIMO系统的混合AD收发机设计问题。由于目标函数和约束条件的高度非凸性，本章首先开发了基于MSER的GD迭代算法来寻找问题

驻点。为了降低计算复杂度并提高系统性能，将上述GD迭代算法展开为多层结构，并引入了一组可训练参数，由此提出了深度展开算法。另外，为了训练网络，本章基于GCR推导了相邻两层之间梯度的递推关系。本章分别针对QPSK信号和M-QAM信号设计了深度展开算法，并理论分析了其收敛性。同时，为了提供对比基准，本章提出了基于MSER准则的CNN黑盒算法。仿真结果表明，与CNN黑盒算法相比，所提出的深度展开算法表现出更好的SER性能，并在逼近GD迭代算法性能的同时有效降低了计算复杂度，减少了训练开销。

4 多小区协同用户调度和混合波束成形设计

传统的混合波束成形设计研究通常集中在单小区场景，例如当前的权值算法只考虑如何将波束更好地对准小区内的调度用户，并没有考虑到对邻区的干扰。当考虑多小区共用时频资源时，有些波束在提升小区内调度用户的速率的同时，也会增大对邻区用户的干扰。在某些场景下，这种单小区混合波束成形设计方案对小区内调度用户的速率提升还没有对邻区用户造成的速率下降多，从而导致整体性能下降。因此本章针对多小区协同用户调度和混合波束成形进行设计，在提升用户功率的同时有效控制小区间干扰抬升，从而提升小区平均容量性能。

多小区协同用户调度和混合波束成形设计主要涉及以下一些关键问题：1. 小区间干扰的存在导致问题结构具有非凸性，2. 用户调度与混合波束成形需要联合设计以尽可能多地挖掘多小区协同所带来的增益，而这也导致问题中包含离散变量，3. 多个小区之间的协调需要大容量回程通信资源，需要尽可能降低小区间的信息交互。因此，该问题在优化设计方面具有很大的挑战，在具体实现过程中也有一定困难。

本章内容安排如下。4.1节介绍了多小区协同用户调度和混合波束成形架构的系统模型。4.2节给出了问题建模及整体算法。4.3节设计了用户调度算法。4.4节描述了混合波束成形最优设计并给出了低复杂度近似。4.5节给出实验结果并验证所提算法的有效性。最后，4.6节给出了本章小结。

4.1 系统模型

考虑一个多小区多用户系统的下行链路。假设系统中共有 B 个BS，每个BS配备 N_T 根天线和 R_T 个RF链，总用户数为 K ，其中每个用户配备 N_R 根天线。假设第 b 个BS服务的用户集合为 \mathcal{U}_b ，服务的用户数量为 $K_b = |\mathcal{U}_b|$ 。那么，如果用户 $k \in \{1, \dots, K\}$ 被第 b_k 个BS服务，则其在第 n 个资源块（Resource Block, RB）接收到的信号可以表示为¹

¹注意，此处的RB是可以分配给用户的最小资源单元，聚合了一定的时间和频率资源。在本章中，一个RB包含15个子载波，以4个RB为单位服务一组用户。假设系统中一个小区中共有 N 个RB。此处为表述方便，1个RB其实表示由4个RB组成的资源集合。

$$\mathbf{y}_k^n = \underbrace{\mathbf{H}_{b_k,k}^n \mathbf{T}_{b_k} \mathbf{f}_{b_k,k}^n d_k^n}_{\text{有用信号}} + \underbrace{\sum_{\substack{i \neq k \\ b_i = b_k}} \mathbf{H}_{b_k,k}^n \mathbf{T}_{b_k} \mathbf{f}_{b_k,i}^n d_i^n}_{\text{小区内干扰}} + \underbrace{\sum_{c \neq b_k} \sum_{i: b_i = c} \mathbf{H}_{c,k}^n \mathbf{T}_c \mathbf{f}_{c,i}^n d_i^n}_{\text{小区间干扰}} + \mathbf{n}_k^n, \quad (4.1)$$

其中, $\mathbf{H}_{b,k}^n \in \mathbb{C}^{N_R \times N_T}$ 表示第 b 个 BS 和被第 n 个资源块服务的用户 k 之间的信道矩阵, 可以通过用户反馈再重构得到, $\mathbf{T}_b \in \mathbb{C}^{N_T \times R_T}$ 是第 b 个 BS 的模拟波束成形矩阵, $\mathbf{f}_{b,k}^n \in \mathbb{C}^{R_T \times 1}$ 是第 b 个 BS 分配给第 n 个 RB 上的用户 k 的数字波束成形向量, d_k^n 表示被第 n 个 RB 服务的用户 k 的数据流, $\mathbf{n}_k^n \in \mathbb{C}^{N_R \times 1}$ 是第 n 个 RB 上的加性高斯白噪声, 其均值为 $\mathbf{0}$, 方差为 $\sigma_k^2 \mathbf{I}$, 服从复高斯分布。

经过用户 k 接收端的线性滤波器处理后, d_k^n 的估计值可以表示为

$$\begin{aligned} \hat{d}_k^n &= (\mathbf{w}_k^n)^H \mathbf{y}_k^n \\ &= (\mathbf{w}_k^n)^H \mathbf{H}_{b_k,k}^n \mathbf{T}_{b_k} \mathbf{f}_{b_k,k}^n d_k^n + \sum_{\substack{i \neq k \\ b_i = b_k}} (\mathbf{w}_k^n)^H \mathbf{H}_{b_k,k}^n \mathbf{T}_{b_k} \mathbf{f}_{b_k,i}^n d_i^n \\ &\quad + \sum_{c \neq b_k} \sum_{i: b_i = c} (\mathbf{w}_k^n)^H \mathbf{H}_{c,k}^n \mathbf{T}_c \mathbf{f}_{c,i}^n d_i^n + (\mathbf{w}_k^n)^H \mathbf{n}_k^n, \end{aligned} \quad (4.2)$$

其中, $\mathbf{w}_k^n \in \mathbb{C}^{N_R \times 1}$ 是第 n 个 RB 上的用户 k 的接收波束成形向量。

4.2 整体算法描述

4.2.1 问题建模

本章的目标是设计多小区协同架构下的混合波束成形矩阵和对应的用户调度策略, 以此提升小区平均容量性能, 同时有效控制小区内和小区间干扰。所考虑的问题可以建模成如下形式:

$$\max_{\{\mathbf{f}_{b_k,k}^n, \mathbf{T}_{b_k}, \mathbf{w}_k^n, \mathcal{S}(b_k, n)\}} \sum_{k=1}^K \log(\bar{R}_{b_k, k}) \quad (4.3a)$$

$$R_{b_k, k} = \sum_{\{n: k \in \mathcal{S}(b_k, n)\}} \log(1 + \text{SINR}_{b_k, k}^n), \quad \forall b_k, \quad (4.3b)$$

$$\text{s.t.} \quad \text{Tr} \left(\mathbf{T}_{b_k} \left(\sum_{k \in \mathcal{U}_{b_k}} \mathbf{f}_{b_k, k}^n (\mathbf{f}_{b_k, k}^n)^H \right) \mathbf{T}_{b_k}^H \right) \leq P_t, \quad \forall b_k, \quad (4.3c)$$

$$|[\mathbf{T}_{b_k}]_{i,j}| = 1, \quad \forall b_k, i, j, \quad (4.3d)$$

其中, $\bar{R}_{b_k,k}$ 是用户 k 的时间平均速率, $R_{b_k,k}$ 是用户 k 的瞬时速率, P_t 是每个小区的发射功率上限, $\text{SINR}_{b_k,k}^n$ 为第 k 个用户在第 n 个资源块上的 SINR, 其表达式如下所示:

$$\text{SINR}_{b_k,k}^n = \frac{|(\mathbf{w}_k^n)^H \mathbf{H}_{b_k,k}^n \mathbf{T}_{b_k} \mathbf{f}_{b_k,k}^n|^2}{\sum_{\substack{i \neq k \\ b_i = b_k}} |(\mathbf{w}_k^n)^H \mathbf{H}_{b_k,k}^n \mathbf{T}_{b_k} \mathbf{f}_{b_k,i}^n|^2 + \sum_{c \neq b_k} \sum_{i: b_i = c} |(\mathbf{w}_k^n)^H \mathbf{H}_{c,k}^n \mathbf{T}_c \mathbf{f}_{c,i}^n|^2 + \sigma_k^2 \|\mathbf{w}_k^n\|^2}, \quad (4.4)$$

$\mathcal{S}(b_k, n)$ 表示基站 b_k 在第 n 个资源块上服务的用户集合。在问题(4.3)中, 包含了多小区混合波束成形和用户调度的联合优化, 分别对应 $\{\mathbf{f}_{b_k,k}^n, \mathbf{T}_{b_k}\}$ 和 $\mathcal{S}(b_k, n)$ 。

假设相邻小区之间的干扰较为严重, 而来自其余距离较远小区的干扰较轻微, 为了方便起见, 可将其近似为 0。在实际中, 由于考虑的是频分双工 (Frequency Division Duplexing, FDD) 系统, BS 端无法得知真实的信道信息, 因此主要通过用户反馈的信息作为代替。假设信道矩阵 $\mathbf{H}_{b_k,k}^n$ 的奇异值分解 (Singular Value Decomposition, SVD) 为 $\mathbf{H}_{b_k,k}^n = \mathbf{U}_{b_k,k}^n \Sigma_{b_k,k}^n (\mathbf{V}_{b_k,k}^n)^H$, 由于用户的反馈量有限, 采取如下近似: $\mathbf{H}_{b_k,k}^n \approx \mathbf{u}_{b_k,k}^n A_{b_k,k}^n (\mathbf{v}_{b_k,k}^n)^H$, 其中, $A_{b_k,k}^n$ 为最大奇异值, $\mathbf{u}_{b_k,k}^n$ 和 $\mathbf{v}_{b_k,k}^n$ 为对应的左、右奇异向量, 则可用最大奇异值对应的左奇异向量 $\mathbf{u}_{b_k,k}^n$ 作为接收波束成形向量 \mathbf{w}_k^n 。此时, 用户 k 与基站 b_k 之间的等效信道信息 $(\mathbf{w}_k^n)^H \mathbf{H}_{b_k,k}^n$ 可以表示为 $(\tilde{\mathbf{h}}_{b_k,k}^n)^H \triangleq A_{b_k,k}^n (\mathbf{v}_{b_k,k}^n)^H$, 而用户 k 与其他小区之间的等效信道信息 $(\mathbf{w}_k^n)^H \mathbf{H}_{c,k}^n$ 可写作 $(\tilde{\mathbf{h}}_{c,k}^n)^H \triangleq (\mathbf{u}_{b_k,k}^n)^H \mathbf{H}_{c,k}^n$ 。因此, $\text{SINR}_{b_k,k}^n$ 的表达式可以转化为

$$\text{SINR}_{b_k,k}^n = \frac{|(\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{f}_{b_k,k}^n|^2}{\sum_{\substack{i \neq k \\ b_i = b_k}} |(\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{f}_{b_k,i}^n|^2 + \sum_{c \in \mathcal{N}(b_k)} \sum_{i: b_i = c} |(\tilde{\mathbf{h}}_{c,k}^n)^H \mathbf{T}_c \mathbf{f}_{c,i}^n|^2 + \sigma_k^2 \|\mathbf{u}_{b_k,k}^n\|^2}, \quad (4.5)$$

其中, $\mathcal{N}(b_k)$ 表示与第 b_k 个小区相邻的小区。

为了减少小区间的信息交互, 考虑使用一个功率上界 \tilde{P}_c 来近似小区 c 对小区 b_k 的干扰, 则 $\text{SINR}_{b_k,k}^n$ 可被简化为

$$\text{SINR}_{b_k,k}^n = \frac{|(\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{f}_{b_k,k}^n|^2}{\sum_{\substack{i \neq k \\ b_i = b_k}} |(\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{f}_{b_k,i}^n|^2 + \sum_{c \in \mathcal{N}(b_k)} \tilde{P}_c + \sigma_k^2 \|\mathbf{u}_{b_k,k}^n\|^2}. \quad (4.6)$$

4.2.2 整体算法

可以看到, 经过上述近似之后, 问题(4.3) 仍然是非凸的, 并且同时包括离散变量和连续变量的优化, 寻找其全局最优解具有一定难度。因此, 本小节将原问题分解成两个子问题, 即用户调度问题和混合波束成形矩阵设计问题, 并通过迭代的方式求解这两个子问题, 以此得到原问题(4.3)的一个次优解。具体来说, 首先固定所有的波束成形矩阵/向量,

Algorithm 4.1 多小区协同用户调度和混合波束成形设计整体算法

-
- 1: 初始化用户调度方案和波束成形向量, 设定最大迭代次数 I_{max} 和误差精度 ϵ , 设当前迭代次数 $t = 0$ 。
 - 2: **while** $t < I_{max}$ 且两次迭代速率之差 $> \epsilon$ **do**
 - 3: **for** $b_k \in \{1, \dots, B\}$ **do**
 - 4: **for** $n \in \{1, \dots, N\}$ **do**
 - 5: **用户调度设计:** 根据第4.3节求得每个小区每个RB的用户调度方案 (需要知道的信息: 本小区的用户调度方案, 即 $\mathcal{S}(b_k, n)$)。
 - 6: **end for**
 - 7: **混合波束成形设计:** 根据第4.4节中的方案更新 $\{\mathbf{f}_{b_k, k}^n, \mathbf{T}_{b_k}\}$ (需要知道的信息: 本小区以及相邻小区的用户调度方案, 即 $\mathcal{S}(b_k, n), \mathcal{S}(\mathcal{N}(b_k), n)$)。
 - 8: 不同BS间交互本小区的用户调度方案, 即 $\mathcal{S}(b_k, n)$ 。
 - 9: **end for**
 - 10: **end while**
-

并用贪婪的比例公平算法求得用户调度策略, 然后, 不同BS之间交互用户调度信息, 并在固定该调度方案的情况下更新波束成形矩阵/向量, 按此方式迭代直至收敛。整体算法在Algorithm 4.1中给出。

4.3 用户调度设计

由于每个波束成形向量对本小区和相邻小区中的用户产生的干扰是关于波束成形向量的函数, 而与用户调度方案无关。因此, 在小区 b_k 的第 n 个RB中, 如果波束成形向量是固定的, 那么单独进行用户调度将不会影响系统中其他地方的干扰水平。基于此, 本节采用了一种简单的搜索算法以寻找一组最优用户, 使得这些用户在被第 n 个RB服务时的增益最大。本节提出了比例公平算法来实现用户调度, 该算法综合考虑了公平性和系统性能两方面, 其基本思想是在选择用户时考虑瞬时速率和时间平均速率的比值, 可将目标函数表示为 $\frac{r_{b_k, k}^n}{R_{b_k, k}}$ 。该算法针对每个波束成形向量 $\mathbf{f}_{b_k, u}^n, u \in \mathcal{U}_{b_k}$ 寻找使目标函数最大化的用户, 并将这一波束成形向量分配给该用户。根据上述思想寻找到的用户可以表示为

$$\tilde{\mathcal{S}}(b_k, n, \mathbf{f}_{b_k, u}^n) = \arg \max_k \frac{\tilde{r}_{b_k, k}^n(\mathbf{f}_{b_k, u}^n)}{R_{b_k, k}}, \quad (4.7)$$

其中, $\tilde{r}_{b_k, k}^n(\mathbf{f}_{b_k, u}^n)$ 是小区 b_k 中被第 n 个RB服务的用户 k 被分配到 $\mathbf{f}_{b_k, u}^n$ 时的瞬时速率, 其表达

式为

$$\tilde{r}_{b_k,k}^n(\mathbf{f}_{b_k,u}^n) = \log \left(1 + \frac{\left| (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{f}_{b_k,u}^n \right|^2}{\sum_{\substack{i \neq k \\ b_i = b_k}} \left| (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{f}_{b_k,i}^n \right|^2 + \sum_{c \in \mathcal{N}(b_k)} \tilde{P}_c + \sigma_k^2 \|\mathbf{u}_{b_k,k}^n\|^2} \right). \quad (4.8)$$

时间平均速率 $\bar{R}_{b_k,k}$ 的更新公式为

$$\bar{R}_{b_k,k} = \alpha \bar{R}_{b_k,k} + (1 - \alpha) R_{b_k,k}, \quad (4.9)$$

其中, $0 < \alpha < 1$ 。则基站 b_k 在第 n 个资源块上服务的用户集合 $\mathcal{S}(b_k, n)$ 为 $\{\tilde{\mathcal{S}}(b_k, n, \mathbf{f}_{b_k,u}^n), \forall u \in \mathcal{U}_{b_k}\}$ 。

4.4 混合波束成形设计

本节在固定用户调度方案的情况下设计混合波束成形矩阵。由于已知用户调度, 设计混合波束成形矩阵时只需考虑某个小区, 在此以 b_k 小区为例。

由于用户速率 \log 函数的导数为 $\frac{1}{R_{b_k,k}}$, 上一节中的用户调度策略本质上最大化了用户速率的 \log 函数, 因此可以把问题等价转化成加权和速率最大化问题:

$$\max_{\{\mathbf{f}_{b_k,k}^n, \mathbf{T}_{b_k}\}} \sum_{k \in \mathcal{U}_{b_k}} u_{b_k,k} R_{b_k,k} \quad (4.10a)$$

$$\text{s.t.} \quad \text{Tr} \left(\mathbf{T}_{b_k} \left(\sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} \mathbf{f}_{b_k,k}^n (\mathbf{f}_{b_k,k}^n)^H \right) \mathbf{T}_{b_k}^H \right) \leq P_t, \quad (4.10b)$$

其中, $u_{b_k,k} = \frac{1}{R_{b_k,k}}$ 。以下将给出两种方案对混合波束成形矩阵进行优化设计, 第一种方案的提出基于干扰迫零, 第二种方案则基于模拟和数字波束成形矩阵的整体优化和矩阵分解。

4.4.1 干扰迫零

首先将数字波束成形矩阵分解成两部分, 即 $\mathbf{F}_{b_k} \triangleq \mathbf{F}_{b_k}^1 \mathbf{F}_{b_k}^2$, 其中, $\mathbf{F}_{b_k}^1 \in \mathbb{C}^{R_T \times R_T}$, $\mathbf{F}_{b_k}^2 \triangleq [\mathbf{f}_{b_k,1}^{2,1}, \dots, \mathbf{f}_{b_k,1u}^{2,1}, \dots, \mathbf{f}_{b_k,1}^{2,N}, \dots, \mathbf{f}_{b_k,Nu}^{2,N}] \in \mathbb{C}^{R_T \times U_{b_k}}$, $n_u, n = \{1, \dots, N\}$ 表示第 n 个 RB 服务的用户数且满足 $\sum_{n=1}^N n_u = U_{b_k}$ 。利用模拟波束成形矩阵 \mathbf{T}_{b_k} 和 $\mathbf{F}_{b_k}^1$ 进行干扰消除, 随后利用 $\mathbf{F}_{b_k}^2$ 控制发射功率。

将小区 b_k 中第 n 个 RB 内和所有用户相连的直连信道集成矩阵 $\mathbf{H}_{b_k}^{1,n} \triangleq [\tilde{\mathbf{h}}_{b_k,1}^n, \dots, \tilde{\mathbf{h}}_{b_k,n_u}^n]^H \in \mathbb{C}^{n_u \times N_T}$ 。同样的, 把本小区对相邻小区边缘用户的交叉信道也集成矩阵 $\mathbf{H}_{b_k}^{2,n} \triangleq$

Algorithm 4.2 BCD算法

- 1: 随机初始化模拟预编码矩阵 \mathbf{T}_{b_k} 的相位, 设迭代次数 $t = 0$;
- 2: **repeat**
- 3: 固定 $\mathbf{T}_{b_k}^t$, 计算: $\mathbf{F}_{b_k}^{1,t} = (\mathbf{T}_{b_k}^t)^\dagger \mathbf{U}_{b_k}$;
- 4: 计算 $\mathbf{A} = \mathbf{I}_{N_t}$, $\mathbf{B} = \mathbf{F}_{b_k}^{1,t} (\mathbf{F}_{b_k}^{1,t})^H$, $\mathbf{C} = \mathbf{U}_{b_k} (\mathbf{F}_{b_k}^{1,t})^H$, $\mathbf{Q} = \mathbf{A} \mathbf{T}_{b_k}^t \mathbf{C}$;
- 5: $i = 1 \dots N_t$,
 $j = 1 \dots R_T$:
 $b = \mathbf{A}(i, j) \mathbf{T}_{b_k}^t(i, j) \mathbf{C}(i, j) - \mathbf{Q}(i, j) + \mathbf{B}(i, j)$,
 $x = b/|b|$,
 $\mathbf{Q} = \mathbf{Q} + (x - \mathbf{T}_{b_k}^t(i, j)) \mathbf{A}(:, i) \mathbf{C}(j, :)$,
 $\mathbf{T}_{b_k}^t(i, j) = x$;
- 6: $t = t + 1$;
- 7: **until** 迭代收敛

$[\tilde{\mathbf{h}}_{b_k,1}^n, \dots, \tilde{\mathbf{h}}_{b_k,c_u}^n]^H \in \mathbb{C}^{c_u \times N_T}$, 其中, c_u 是交叉信道的数量, 即基站 b_k 对相邻小区干扰较强的用户数目。干扰迫零算法设计的目标是通过优化 \mathbf{T}_{b_k} 和 $\mathbf{F}_{b_k}^1$ 尽量抑制 $\mathbf{H}_{b_k}^2$ 方向的能量, 同时最大化投影到 $\mathbf{H}_{b_k}^1$ 方向的能量。

令 $\tilde{\mathbf{H}}_{b_k}^2 = \frac{1}{N} \sum_{n=1}^N (\mathbf{H}_{b_k}^{2,n})^H \mathbf{H}_{b_k}^{2,n}$, 为了综合考虑不同RB上的干扰破零效果, 上式对不同RB的信道求取均值。将 $\tilde{\mathbf{H}}_{b_k}^2$ 进行特征分解得 $\tilde{\mathbf{H}}_{b_k}^2 = \mathbf{U}_{b_k}^2 \Sigma_{b_k}^2 (\mathbf{U}_{b_k}^2)^H$, 取最小的 L' 个特征值对应的特征向量组成 $\tilde{\mathbf{U}}_{b_k}^2$, 则 $\tilde{\mathbf{U}}_{b_k}^2 \in \mathbb{C}^{N_T \times L'}$, 其中 L' 可以通过实验或者仿真确定。再令 $\tilde{\mathbf{H}}_{b_k}^1 = \frac{1}{N} \sum_{n=1}^N (\tilde{\mathbf{U}}_{b_k}^2)^H (\mathbf{H}_{b_k}^{1,n})^H \mathbf{H}_{b_k}^{1,n} \tilde{\mathbf{U}}_{b_k}^2$, 将 $\tilde{\mathbf{H}}_{b_k}^1$ 进行特征分解 $\tilde{\mathbf{H}}_{b_k}^1 = \mathbf{U}_{b_k}^3 \Sigma_{b_k}^3 (\mathbf{U}_{b_k}^3)^H$, 取最大的 R_T 个特征值对应的特征向量组成 $\tilde{\mathbf{U}}_{b_k}^3$, $\tilde{\mathbf{U}}_{b_k}^3 \in \mathbb{C}^{L' \times R_T}$ 。令 $\mathbf{U}_{b_k} \triangleq \tilde{\mathbf{U}}_{b_k}^2 \tilde{\mathbf{U}}_{b_k}^3$, 可通过求解以下优化问题来设计 \mathbf{T}_{b_k} 和 $\mathbf{F}_{b_k}^1$:

$$\begin{aligned} \min_{\{\mathbf{T}_{b_k}, \mathbf{F}_{b_k}^1\}} \quad & \|\mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 - \mathbf{U}_{b_k}\|_F^2 \\ \text{s.t.} \quad & |[\mathbf{T}_{b_k}]_{i,j}| = 1, \quad \forall i, j. \end{aligned} \quad (4.11)$$

可以用块坐标下降 (Block Coordination Descent, BCD) 算法或相位提取交替最小化 (Phase Extraction Alternate Minimizing, PE-AltMin) 算法分解得到 \mathbf{T}_{b_k} 和 $\mathbf{F}_{b_k}^1$, 具体过程见Algorithm 4.2和Algorithm 4.3。

假设上述算法已通过优化 \mathbf{T}_{b_k} 和 $\mathbf{F}_{b_k}^1$ 将干扰抑制到一个较低的水平, 因此在设计 $\mathbf{F}_{b_k}^2$ 时

Algorithm 4.3 PE-AltMin算法

- 1: 随机初始化模拟预编码矩阵 \mathbf{T}_{b_k} 的相位，设迭代次数 $t = 0$;
- 2: **repeat**
- 3: 固定 $\mathbf{T}_{b_k}^t$ ，计算SVD分解： $\mathbf{U}_{b_k}^H \mathbf{T}_{b_k}^t = \mathbf{V}_1^t \boldsymbol{\Sigma}^t (\mathbf{V}_2^t)^H$;
- 4: 计算 $\mathbf{F}_{b_k}^{1,t} = \mathbf{V}_2^t (\mathbf{V}_1^t)^H$;
- 5: 固定 $\mathbf{F}_{b_k}^{1,t}$ ，取 $\angle \mathbf{T}_{b_k}^{t+1} = \angle (\mathbf{U}_{b_k} (\mathbf{F}_{b_k}^{1,t})^H)$;
- 6: $t = t + 1$;
- 7: **until** 迭代收敛

只需要考虑发送功率约束。在固定 \mathbf{T}_{b_k} 和 $\mathbf{F}_{b_k}^1$ 的情况下，优化问题可重新建模成

$$\begin{aligned} \min_{\{\mathbf{F}_{b_k}^2, v_{b_k,k}^n, z_{b_k,k}^n\}} \quad & \mathcal{W}(\mathbf{F}_{b_k}^2, v_{b_k,k}^n, z_{b_k,k}^n) \\ \text{s.t.} \quad & \left(\sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} \text{Tr} \left(\mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \mathbf{f}_{b_k,k}^{2,n} (\mathbf{f}_{b_k,k}^{2,n})^H (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \right) \right) \leq P_t, \end{aligned} \quad (4.12)$$

原加权和速率最大化问题已被等价转化为WMMSE问题，其目标函数 $\mathcal{W}(\mathbf{F}_{b_k}^2, v_{b_k,k}^n, z_{b_k,k}^n)$ 为

$$\mathcal{W}(\mathbf{F}_{b_k}^2, v_{b_k,k}^n, z_{b_k,k}^n) = \sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} u_{b_k,k} (z_{b_k,k}^n \mathbb{E}_{b_k,k}^n(\mathbf{f}_{b_k,k}^{2,n}, v_{b_k,k}^n) - \log(z_{b_k,k}^n)), \quad (4.13)$$

其中， $v_{b_k,k}^n$ 是虚拟接收波束成形矩阵， $z_{b_k,k}^n$ 是MSE权重， $\mathbb{E}_{b_k,k}^n(\mathbf{g}_{b_k,k}^n, v_{b_k,k}^n)$ 是MSE函数，其表达式如下

$$\begin{aligned} \mathbb{E}_{b_k,k}^n(\mathbf{f}_{b_k,k}^{2,n}, v_{b_k,k}^n) &= \mathbb{E} \left[(d_k^n - \hat{d}_k^n)(d_k^n - \hat{d}_k^n)^H \right] \\ &= 1 - v_{b_k,k}^n (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \mathbf{f}_{b_k,k}^{2,n} - (v_{b_k,k}^n)^H (\mathbf{f}_{b_k,k}^{2,n})^H (\mathbf{F}_{b_k}^1)^H (\mathbf{T}_{b_k})^H \tilde{\mathbf{h}}_{b_k,k}^n \\ &\quad + \sum_{i \in \mathcal{U}_{b_k}} |v_{b_k,k}^n|^2 (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \mathbf{f}_{b_k,i}^{2,n} (\mathbf{f}_{b_k,i}^{2,n})^H (\mathbf{F}_{b_k}^1)^H (\mathbf{T}_{b_k})^H \tilde{\mathbf{h}}_{b_k,k}^n + \sigma_k^2 |v_{b_k,k}^n|^2 \|\mathbf{u}_{b_k,k}^n\|^2. \end{aligned} \quad (4.14)$$

由上式可知，问题(4.12)中的三组优化变量 $\mathbf{F}_{b_k}^2$ 、 $v_{b_k,k}^n$ 和 $z_{b_k,k}^n$ 仅在目标函数中耦合，而约束条件只与变量 $\mathbf{F}_{b_k}^2$ 有关。可采用BCD算法对问题(4.12)进行求解，其主要思想是对 $\mathbf{F}_{b_k}^2$ 、 $v_{b_k,k}^n$ 和 $z_{b_k,k}^n$ 进行交替迭代优化，并在优化某个变量时固定其他变量的值。具体来讲， $v_{b_k,k}^n$ 和 $z_{b_k,k}^n$ 的最优解可分别通过下式求得

$$\min_{z_{b_k,k}^n} \mathcal{W} \Rightarrow z_{b_k,k}^n = (\mathbb{E}_{b_k,k}^n)^{-1} = 1 + \text{SINR}_{b_k,k}^n, \quad \forall k \in \mathcal{U}_{b_k}, \forall n: k \in \mathcal{S}(b_k, n), \quad (4.15)$$

$$\begin{aligned} \min_{v_{b_k,k}^n} \mathcal{W} \Rightarrow v_{b_k,k}^n = & \left(\sum_{i \in \mathcal{U}_{b_k}} (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \mathbf{f}_{b_k,i}^{2,n} (\mathbf{f}_{b_k,i}^{2,n})^H (\mathbf{F}_{b_k}^1)^H (\mathbf{T}_{b_k})^H \tilde{\mathbf{h}}_{b_k,k}^n \right. \\ & \left. + \sigma_k^2 \|\mathbf{u}_{b_k,k}^n\|^2 \right)^{-1} ((\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \mathbf{f}_{b_k}^{2,n})^H, \forall k \in \mathcal{U}_{b_k}, \forall n: k \in \mathcal{S}(b_k, n). \end{aligned} \quad (4.16)$$

另外, $\mathbf{F}_{b_k}^2$ 的优化子问题可以表示为

$$\begin{aligned} \min_{\mathbf{F}_{b_k}^2} \quad & \mathcal{W}(\mathbf{F}_{b_k}^2, v_{b_k,k}^n, z_{b_k,k}^n) \\ \text{s.t.} \quad & \sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} \text{Tr} \left(\mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \mathbf{f}_{b_k,k}^{2,n} (\mathbf{f}_{b_k,k}^{2,n})^H (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \right) \leq P_t, \end{aligned} \quad (4.17)$$

对功率约束条件引入拉格朗日乘子 λ_t 后, 问题(4.17)可转化为以下无约束问题

$$\min_{\{\mathbf{F}_{b_k}^2, \lambda_t\}} \bar{\mathcal{W}}(\mathbf{F}_{b_k}^2, v_{b_k,k}^n, z_{b_k,k}^n, \lambda_t), \quad (4.18)$$

其中,

$$\begin{aligned} \bar{\mathcal{W}}(\mathbf{F}_{b_k}^2, v_{b_k,k}^n, z_{b_k,k}^n, \lambda_t) = & \sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} u_{b_k,k} (z_{b_k,k}^n \mathbf{E}_{b_k,k}^n (\mathbf{f}_{b_k,k}^{2,n}, v_{b_k,k}^n) - \log(z_{b_k,k}^n)) \\ & + \lambda_t \left(\sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} \text{Tr} \left(\mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \mathbf{f}_{b_k,k}^{2,n} (\mathbf{f}_{b_k,k}^{2,n})^H (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \right) - P_t \right). \end{aligned} \quad (4.19)$$

问题(4.18)的解可以表示为

$$\begin{aligned} \mathbf{f}_{b_k,k}^{2,n} = & \left(\sum_{k \in \mathcal{U}_{b_k}} u_{b_k,k} z_{b_k,k}^n (v_{b_k,k}^n)^2 (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \tilde{\mathbf{h}}_{b_k,k}^n (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \right. \\ & \left. + \lambda_t (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1 \right)^{-1} u_{b_k,k} z_{b_k,k}^n (v_{b_k,k}^n)^* (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \tilde{\mathbf{h}}_{b_k,k}^n, \end{aligned} \quad (4.20)$$

其中, 拉格朗日乘子 λ_t 通过二分法搜索得到。通过上述算法可以得到数字波束成形矩阵为 $\mathbf{F}_{b_k} = \mathbf{F}_{b_k}^1 \mathbf{F}_{b_k}^2$ 。

4.4.2 干扰迫零的低复杂度近似

为了进一步降低计算复杂度, 节省链路开销, 本小节对上述干扰迫零算法提出了一种低复杂度近似。首先, 将 $\mathbf{F}_{b_k}^2$ 写作以下形式

$$\mathbf{F}_{b_k}^2 = (\mathbf{\Omega} + \lambda_t \mathbf{\Omega}_1)^{-1} \mathbf{M}, \quad (4.21)$$

其中, $\Omega = \sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} u_{b_k, k} z_{b_k, k}^n (v_{b_k, k}^n)^2 (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \tilde{\mathbf{h}}_{b_k, k}^n (\tilde{\mathbf{h}}_{b_k, k}^n)^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1$, $\Omega_1 = (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1$, $\mathbf{M} = \sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} u_{b_k, k} z_{b_k, k}^n v_{b_k, k}^{n,*} (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \tilde{\mathbf{h}}_{b_k, k}^n (\mathbf{i}_{b_k, k}^n)^H$ 。假设 Ω 的特征值分解为 $\Omega = \mathbf{Q} \Sigma \mathbf{Q}^H$, 取 Σ 中较大的前 J 个特征值, 对应地取 \mathbf{Q} 中的前 J 列组成 $\bar{\mathbf{Q}}$ 。同样的, 假设 Ω_1 的特征值分解为 $\Omega_1 = \mathbf{Q}_1 \Sigma_1 \mathbf{Q}_1^H$, 取 Σ_1 中较大的前 J_1 个, 并将其余特征值置零, 对应取 \mathbf{Q}_1 的前 J_1 列得到 $\bar{\mathbf{Q}}_1$, 其中 J 和 J_1 可以通过仿真经验设定。通过施密特正交化找到 $[\bar{\mathbf{Q}} \ \bar{\mathbf{Q}}_1]$ 的共同子空间 \mathbf{Q}' , 补全 \mathbf{Q}' 得到 $\bar{\mathbf{Q}} \triangleq [\mathbf{Q}' \ \mathbf{Q}_c]$, 补全方法为将 $\mathbf{I} - \mathbf{Q}'(\mathbf{Q}')^H$ 进行 SVD 分解, 分解的结果即为 $\mathbf{Q}_c \Sigma_2 \mathbf{Q}_c^H$ 。求解以下问题对 Ω 和 Ω_1 分别进行近似:

$$\min_{\Sigma} \|\bar{\mathbf{Q}} \bar{\Sigma} \bar{\mathbf{Q}}^H - \Omega\|_F^2, \quad (4.22)$$

$$\min_{\Sigma_1} \|\bar{\mathbf{Q}} \bar{\Sigma}_1 \bar{\mathbf{Q}}^H - \Omega_1\|_F^2, \quad (4.23)$$

由于上述两个问题可以用类似的方法求解, 本小节以解问题(4.22)为例对相应算法进行说明。首先, 问题(4.22)的目标函数可以等效表示为:

$$\begin{aligned} & \text{Tr} \left((\bar{\mathbf{Q}} \bar{\Sigma} \bar{\mathbf{Q}}^H - \Omega)^H (\bar{\mathbf{Q}} \bar{\Sigma} \bar{\mathbf{Q}}^H - \Omega) \right) \\ &= \text{Tr} \left(\bar{\mathbf{Q}} \bar{\Sigma}^H \bar{\Sigma} \bar{\mathbf{Q}}^H - \bar{\mathbf{Q}} \bar{\Sigma}^H \bar{\mathbf{Q}}^H \Omega - \Omega^H \bar{\mathbf{Q}} \bar{\Sigma} \bar{\mathbf{Q}}^H + \Omega^H \Omega \right) \\ &= \sum_i \sum_t q_{it} \lambda_{tt}^* \lambda_{tt} q_{it}^* - \sum_i \sum_t q_{it} \lambda_{tt}^* \beta_{ti} - \sum_i \sum_t \beta_{ti}^* \lambda_{tt} q_{it}^* + \Omega^H \Omega, \end{aligned} \quad (4.24)$$

其中, q_{it} 为矩阵 $\bar{\mathbf{Q}}$ 第 i 行第 t 列的元素, λ_{tt} 为 $\bar{\Sigma}$ 第 t 行第 t 列的元素, β_{ti} 为 $\bar{\mathbf{Q}}^H \Omega$ 第 i 行第 t 列的元素。利用问题(4.22)的一阶最优性条件, 通过对 λ_{tt}^* 求导并令结果为零可解得

$$\sum_i \sum_t q_{it} \lambda_{tt} q_{it}^* = \sum_i \sum_t q_{it} \beta_{ti}, \quad (4.25)$$

即

$$[\bar{\Sigma}]_{tt} = \frac{[\bar{\mathbf{Q}}^H \Omega \bar{\mathbf{Q}}]_{tt}}{[\bar{\mathbf{Q}}^H \bar{\mathbf{Q}}]_{tt}}, \quad (4.26a)$$

$$[\bar{\Sigma}_1]_{tt} = \frac{[\bar{\mathbf{Q}}^H \Omega_1 \bar{\mathbf{Q}}]_{tt}}{[\bar{\mathbf{Q}}^H \bar{\mathbf{Q}}]_{tt}}. \quad (4.26b)$$

因此, 求解 $\mathbf{F}_{b_k}^2$ 的过程(4.21)可以近似为

$$\mathbf{F}_{b_k}^2 = \bar{\mathbf{Q}} (\bar{\Sigma} + \lambda_t \bar{\Sigma}_1)^{-1} \bar{\mathbf{Q}}^H \mathbf{M}. \quad (4.27)$$

近似之后, $\mathbf{F}_{b_k}^2$ 的更新只包含对角矩阵求逆, 从而有效降低了计算复杂度。

值得注意的是, $\mathbf{F}_{b_k}^1$ 和 \mathbf{T}_{b_k} 是通过求解问题(4.11)得到的, 因此求得的解 $\mathbf{F}_{b_k}^1 \mathbf{T}_{b_k}$ 与 \mathbf{U}_{b_k} 较为接近, 而 $\mathbf{U}_{b_k} = \tilde{\mathbf{U}}_{b_k}^2 \tilde{\mathbf{U}}_{b_k}^3$, 且 $\tilde{\mathbf{U}}_{b_k}^2$ 与 $\tilde{\mathbf{U}}_{b_k}^3$ 均是酉矩阵, 因此 \mathbf{U}_{b_k} 也为酉矩阵, $\mathbf{U}_{b_k} \mathbf{U}_{b_k}^H$ 则为单

位阵。由此可得 $\Omega_1 = (\mathbf{F}_{b_k}^1)^H \mathbf{T}_{b_k}^H \mathbf{T}_{b_k} \mathbf{F}_{b_k}^1$ 也十分接近单位阵。对于式(4.26b), 无论 $\bar{\mathbf{Q}}$ 如何取值, $[\bar{\Sigma}_1]_{tt}$ 都十分接近于1, 即 $\bar{\Sigma}_1$ 也十分接近单位阵。结合以上分析可得, 无论 $\bar{\mathbf{Q}}$ 取何值, $\bar{\mathbf{Q}}\bar{\Sigma}_1\bar{\mathbf{Q}}^H$ 都十分接近 Ω_1 , 即两者都近似单位阵, 于是在得到 $\bar{\mathbf{Q}}$ 的过程中, 可以不考虑 Ω_1 , 而主要针对 Ω 进行设计, 即可令 $J = 0$, 而 J_1 则可以取一个较大值。

4.4.3 整体优化和矩阵分解

上述基于干扰破零思想进行波束成形设计所需要的小区间协作量较少, 但是这可能会导致一定的性能损失。在本小节中, 考虑采用WMMSE算法直接对问题(4.10)进行求解。具体地, 先将模拟和数字波束成形矩阵看成一个整体进行设计, 得到优化解之后再用OMP算法分解得到模拟和数字波束成形矩阵。

令 $\mathbf{G}_{b_k} \triangleq \mathbf{T}_{b_k} [\mathbf{f}_{b_k,1}^1, \dots, \mathbf{f}_{b_k,1_u}^1, \dots, \mathbf{f}_{b_k,1}^N, \dots, \mathbf{f}_{b_k,N_u}^N] = \mathbf{T}_{b_k} \mathbf{F}_{b_k} \in \mathbb{C}^{N_T \times U_{b_k}}$, 则 \mathbf{G}_{b_k} 中的某一系列 $\mathbf{T}_{b_k} \mathbf{f}_{b_k,k}^n$ 可以表示成 $\mathbf{g}_{b_k,k}^n$, 因此优化问题(4.10)可等价转化为以下WMMSE问题

$$\begin{aligned} \min_{\{\mathbf{G}_{b_k}, v_{b_k,k}^n, z_{b_k,k}^n\}} \quad & \mathcal{W}(\mathbf{G}_{b_k}, v_{b_k,k}^n, z_{b_k,k}^n) \\ \text{s.t.} \quad & \text{Tr} \left(\sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} \mathbf{g}_{b_k,k}^n (\mathbf{g}_{b_k,k}^n)^H \right) \leq P_t, \end{aligned} \quad (4.28)$$

其目标函数 $\mathcal{W}(\mathbf{G}_{b_k}, v_{b_k,k}^n, z_{b_k,k}^n)$ 为

$$\mathcal{W}(\mathbf{G}_{b_k}, v_{b_k,k}^n, z_{b_k,k}^n) = \sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} u_{b_k,k} (z_{b_k,k}^n \mathbf{E}_{b_k,k}^n(\mathbf{G}_{b_k}, v_{b_k,k}^n) - \log(z_{b_k,k}^n)), \quad (4.29)$$

其MSE函数 $\mathbf{E}_{b_k,k}^n(\mathbf{g}_{b_k,k}^n, v_{b_k,k}^n)$ 的表达式如下

$$\begin{aligned} \mathbf{E}_{b_k,k}^n(\mathbf{G}_{b_k}, v_{b_k,k}^n) &= \mathbb{E} \left[(d_k^n - \hat{d}_k^n)(d_k^n - \hat{d}_k^n)^H \right] \\ &= 1 - v_{b_k,k}^n (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{g}_{b_k,k}^n - (v_{b_k,k}^n)^H (\mathbf{g}_{b_k,k}^n)^H \tilde{\mathbf{h}}_{b_k,k}^n + \sum_{i \in \mathcal{U}_{b_k}} |v_{b_k,k}^n|^2 (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{g}_{b_k,i}^n (\mathbf{g}_{b_k,i}^n)^H \tilde{\mathbf{h}}_{b_k,k}^n \\ &\quad + |v_{b_k,k}^n|^2 \sum_{c \neq (b_k)} \sum_{i: b_i \in c} (\tilde{\mathbf{h}}_{c,k}^n)^H \mathbf{g}_{c,i}^n (\mathbf{g}_{c,i}^n)^H \tilde{\mathbf{h}}_{c,k}^n + \sigma_k^2 |v_{b_k,k}^n|^2 \|\mathbf{u}_{b_k,k}^n\|^2. \end{aligned} \quad (4.30)$$

与干扰迫零算法类似, 问题(4.28)中的三组优化变量 \mathbf{G}_{b_k} 、 $v_{b_k,k}^n$ 和 $z_{b_k,k}^n$ 仅在目标函数中耦合, 而约束条件只与变量 \mathbf{G}_{b_k} 有关。因此, 采用BCD法对问题(4.28)进行求解, 即对 \mathbf{G}_{b_k} 、 $v_{b_k,k}^n$ 和 $z_{b_k,k}^n$ 进行交替迭代优化, 并在优化某个变量时固定其他变量的值。 $v_{b_k,k}^n$ 和 $z_{b_k,k}^n$ 的最优解为

$$\min_{z_{b_k,k}^n} \bar{\mathcal{W}} \Rightarrow z_{b_k,k}^n = (\mathbf{E}_{b_k,k}^n)^{-1} = 1 + \text{SINR}_{b_k,k}^n, \quad \forall k \in \mathcal{U}_{b_k}, \quad \forall n: k \in \mathcal{S}(b_k, n), \quad (4.31)$$

$$\begin{aligned} \min_{v_{b_k,k}^n} \bar{W} \Rightarrow v_{b_k,k}^n = & \left(\sum_{i \in \mathcal{U}_{b_k}} (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{g}_{b_k,k}^n (\mathbf{g}_{b_k,k}^n)^H \tilde{\mathbf{h}}_{b_k,k}^n + \sum_{c \neq (b_k)} \sum_{i: b_i \in c} (\tilde{\mathbf{h}}_{c,k}^n)^H \mathbf{g}_{c,i}^n (\mathbf{g}_{c,i}^n)^H \tilde{\mathbf{h}}_{c,k}^n \right. \\ & \left. + \sigma_k^2 \|\mathbf{u}_{b_k,k}^n\|^2 \right)^{-1} (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{g}_{b_k,k}^n, \forall k \in \mathcal{U}_{b_k}, \forall n: k \in \mathcal{S}(b_k, n). \end{aligned} \quad (4.32)$$

\mathbf{G}_{b_k} 的优化子问题可以表示为

$$\begin{aligned} \min_{\mathbf{G}_{b_k}} \quad & \mathcal{W}(\mathbf{G}_{b_k}, v_{b_k,k}^n, z_{b_k,k}^n) \\ \text{s.t.} \quad & \text{Tr} \left(\sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} \mathbf{g}_{b_k,k}^n (\mathbf{g}_{b_k,k}^n)^H \right) \leq P_t, \end{aligned} \quad (4.33)$$

分别对于干扰约束和功率约束引入拉格朗日乘子 λ_{b_k} 和 λ_t , 问题(4.33)可转化为以下无约束问题

$$\min_{\{\mathbf{G}_{b_k}, \lambda_{b_k}, \lambda_t\}} \bar{W}(\mathbf{G}_{b_k}, v_{b_k,k}^n, z_{b_k,k}^n, \lambda_{b_k}, \lambda_t), \quad (4.34)$$

其中, 目标函数 $\bar{W}(\mathbf{G}_{b_k}, v_{b_k,k}^n, z_{b_k,k}^n, \lambda_{b_k}, \lambda_t)$ 为

$$\begin{aligned} \bar{W}(\mathbf{G}_{b_k}, v_{b_k,k}^n, z_{b_k,k}^n, \lambda_{b_k}, \lambda_t) = & \sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} u_{b_k,k} z_{b_k,k}^n \left(E_{b_k,k}^n(\mathbf{G}_{b_k}, v_{b_k,k}^n) - \log(z_{b_k,k}^n) \right) \\ & + \lambda_t \left(\text{Tr} \left(\sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} \mathbf{g}_{b_k,k}^n (\mathbf{g}_{b_k,k}^n)^H \right) - P_t \right). \end{aligned} \quad (4.35)$$

问题(4.34)的解为

$$\begin{aligned} \mathbf{g}_{b_k,k}^n = & \left(\sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} u_{b_k,k} z_{b_k,k}^n (v_{b_k,k}^n)^2 \tilde{\mathbf{h}}_{b_k,k}^n (\tilde{\mathbf{h}}_{b_k,k}^n)^H + \lambda_t \mathbf{I} + \lambda_{b_k} \sum_{i: b_i \in \mathcal{N}(b_k)} \tilde{\mathbf{h}}_{b_k,i}^n (\tilde{\mathbf{h}}_{b_k,i}^n)^H \right)^{-1} \\ & \sum_{k \in \mathcal{U}_{b_k}} \sum_{n: k \in \mathcal{S}(b_k, n)} u_{b_k,k} z_{b_k,k}^n v_{b_k,k}^{n,*} \tilde{\mathbf{h}}_{b_k,k}^n. \end{aligned} \quad (4.36)$$

得到 \mathbf{G}_{b_k} 后, 只需要求解以下优化问题

$$\begin{aligned} \min_{\{\mathbf{T}_{b_k}, \mathbf{F}_{b_k}\}} \quad & \|\mathbf{T}_{b_k} \mathbf{F}_{b_k} - \mathbf{G}_{b_k}\|_F^2 \\ \text{s.t.} \quad & \|\mathbf{T}_{b_k} \mathbf{F}_{b_k}\|^2 \leq P_t, \\ & |[\mathbf{T}_{b_k}]_{i,j}| = 1, \quad \forall i, j. \end{aligned} \quad (4.37)$$

可通过 **Algorithm 4.2** 或 **Algorithm 4.3** 分解迭代得到 \mathbf{T}_{b_k} 和 \mathbf{F}_{b_k} 。

表 4-1 仿真参数

参数	数值
信道参考	3GPP TR 38.901 V14.1.0
频率	2.14 GHz
带宽	9MHz
载波数/载波间隔	12 / 30KHz
RB	25 (5 users / RB)
发射/接收天线数	32 / 4
RF链数	8
信道	3D NLOS
用户Rank	每用户1流
组网形式	7站21小区

4.4.4 接收波束成形矩阵设计

接收波束成形矩阵采用MMSE接收滤波器，所需信息由用户检测 $\text{SINR}_{b_k,k}^n$ 得到，假设检测到的信号分量为 $\mathbf{s}_{b_k,k}^n$ ，检测到的干扰分量为 $\mathbf{t}_{b_k,k}^n$ ，则接收波束成形矩阵的更新规则为

$$\mathbf{w}_k^n = (\mathbf{t}_{b_k,k}^n + \mathbf{s}_{b_k,k}^n)^{-1} \mathbf{s}_{b_k,k}^n. \quad (4.38)$$

4.5 仿真结果

4.5.1 仿真设置

本节对所提算法进行性能测试，表4-1给出了主要的仿真参数。

在式(4.6)中，为了降低复杂度，采用了功率上界 \tilde{P}_c 近似小区 c 对小区 b_k 的干扰，由于 \tilde{P}_c 在实际仿真中只出现在用户调度中，因此在确定 \tilde{P}_c 取值时主要考虑近似后的用户调度方案与不近似时的调度方案接近，并且尽可能减少小区间信息交互。在仿真中采用以下方法对 \tilde{P}_c 进行取值。首先在第 n 个RB下，将小区 b_k 内的用户分为三类并分别对 \tilde{P}_c 进行取值。

第一类用户为受到到其他小区 $c \in \mathcal{N}(b_k)$ 严重干扰，并且在干扰迫零波束成形时被选中自身和小区 c 的交叉信道进行干扰抑制，即其与小区 c 的交叉信道在第4.4.1小节中的 $\mathbf{H}_c^{2,n}$ 集合中。由于小区 c 到该用户的交叉信道信息已知，在结束干扰迫零波束成形后可计算出小区 c 对该用户的干扰，并将这一值来作为此类用户的 \tilde{P}_c 。

第二类用户是指在第 n 个RB下没参与干扰迫零，即 $\mathbf{H}_c^{2,n}$ 集合中没有选择该用户和其他小区的交叉信道，但却受到其他小区干扰较大的。在4.4.1小节中， $\mathbf{H}_{b_k}^{2,n}$ 所挑选的干扰信道是针对被调度用户的。然而在用户调度算法中，则针对每一个编码器计算了所有用户的速率值，无论该用户在上一时刻是否被调度，在当前时刻调度方案中都会参与计算。因此在未被调度的用户中，其受到的干扰有可能大于参与干扰迫零用户的干扰。若此类用户在下一时刻被调度，会严重影响系统整体速率，因此需将此类用户单独考虑。但这需要获取额外的信道信息，通常未被调度用户的交叉信道不易获取，因此可考虑该用户在之前时刻被调度时和其他小区的交叉信道。由于用户和基站的位置不变，可认为其信道信息的变化也较小。结束波束成形设计后，计算该类用户收到小区 b_k 的干扰值，并将其作为其 \tilde{P}_c 的值。

第三类用户是指除一二类用户之外的所有用户。可以认为这些用户受其他小区干扰较小，可将第一类用户 \tilde{P}_c 的平均值作为此类用户的 \tilde{P}_c 。值得注意的是，本章认为受到严重干扰影响的用户在进行干扰迫零后，其受到小区间干扰的大小与正常用户水平相当。

考虑以下算法进行性能比较：

- **对比基线Baseline-ZF**：模拟波束成形矩阵采用

$$\mathbf{T} = \begin{bmatrix} 1 & e^{j\pi\theta} & e^{j2\pi\theta} & e^{j3\pi\theta} & \dots & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & e^{j\pi\theta} & e^{j2\pi\theta} & e^{j3\pi\theta} & \dots & 0 \\ \dots & & & & & & & & & \\ 0 & 0 & 0 & 0 & 0 & \dots & 1 & e^{j\pi\theta} & e^{j2\pi\theta} & e^{j3\pi\theta} \end{bmatrix}^T, \quad (4.39)$$

数字波束成形矩阵采用迫零设计： $\mathbf{f}_{b_k}^n = \hat{\mathbf{H}}_{b_k}^n ((\hat{\mathbf{H}}_{b_k}^n)^H \hat{\mathbf{H}}_{b_k}^n)^{-1}$ ，其中， $\hat{\mathbf{H}}_{b_k}^n \triangleq [\mathbf{h}_{eq,1}^n, \dots, \mathbf{h}_{eq,n_u}^n]^H \in \mathbb{C}^{n_u \times N_t}$ ， $\mathbf{h}_{eq,k}^n = \tilde{\mathbf{h}}_{b_k,k}^n \mathbf{T}_{b_k}$ 。调度时采用比例公平原则，不考虑小区间干扰。

- **对比基线Baseline-WMMSE**：数字波束成形矩阵采用WMMSE算法设计，其余同上。

● **对比方案DBF**：用WMMSE算法设计FD波束成形矩阵，每个RB服务的用户数更多，设为10 users/RB。

● **对比基线Baseline-HBF**：首先用WMMSE算法设计FD波束成形矩阵，然后用Algorithm 4.2中的BCD算法将其分解为数字部分和模拟部分，为不考虑小区间干扰的混合波束成形设计。调度方案同上。

- **Proposed-HBF**：第4.4.1小节中提出的干扰迫零混合波束成形算法。

- **Low-complexity**：第4.4.2小节中提出的干扰迫零算法的低复杂度近似方案。

● **Proposed-TF**：采用第4.4.1小节中的干扰迫零算法设计模拟和数字波束成形矩阵，但是数字波束成形矩阵不分为两部分，即4.4.1中的 $\mathbf{F}_{b_k}^1$ 变为完整的数字波束成形矩阵 \mathbf{F}_{b_k} 。

表 4-2 Proposed-HBF算法对基线算法的平均增益

小区平均增益/ SNR	0	5	10	15	20	25	30
Baseline-ZF	1650%	871%	588%	394%	295%	218%	176%
Baseline-WMMSE	75%	71.79%	86.76%	70.43%	64.88%	61.43%	60.46%
Baseline-HBF	-4.09%	-0.81%	2.61%	7.78%	16.32%	25.87%	35.29%

• **Proposed-F:** 模拟波束成形矩阵采用式(4.39)中的 \mathbf{T} 固定, 数字波束成形矩阵采用第4.4.1小节中的干扰迫零算法。

• **Proposed (global):** 第4.4.3小节中提出的整体优化和矩阵分解算法。

• **Proposed (no interact):** 混合波束成形设计时不需要知道其他小区的调度方案, 无小区间交互, 即在干扰迫零中选择交叉信道 $\mathbf{H}_{b_k}^{2,n}$ 时, 不一定选择被调度的用户, 而是直接选择信道能量最大的 c_u 个用户。

• **2 bit量化模拟波束成形矩阵:** 使用 B bit量化模拟波束成形矩阵的相位角, 共有 2^B 个量化角度。采用均匀量化的方法, 即将区间 $[-\pi, \pi]$ 均匀划分为 2^B 个子区间, 对于落入某子区间的相位角, 用该子区间的中值来量化该相位角。在仿真中设 $B = 2$, 即将区间划分为 $[-\pi, -\pi/2), [-\pi/2, 0), [0, \pi/2), [\pi/2, \pi]$, 对应区间内的相位角分别用 $-3\pi/4, -\pi/4, \pi/4, 3\pi/4$ 来量化, 对应bit形式分别为00, 01, 10, 11。

• **Type I 反馈:** 用户端将等效信道信息 $\tilde{\mathbf{h}}_{b_k,k}^n$ 反馈给基站。采用离散傅里叶变换 (Discrete Fourier Transform, DFT) 矩阵作为码本 $\mathbf{C} \in \mathbb{C}^{N_t \times N_t}$, 从中选取与 $\tilde{\mathbf{h}}_{b_k,k}^n$ 最接近的一列作为其近似, 并将对应的列号反馈给基站。

• **Type II 反馈:** 用户端将等效信道信息 $\tilde{\mathbf{h}}_{b_k,k}^n$ 反馈给基站。采用DFT矩阵作为码本 $\mathbf{C} \in \mathbb{C}^{N_t \times N_t}$, 从中选取 L_c 列进行组合逼近 $\tilde{\mathbf{h}}_{b_k,k}^n$, 即 $\tilde{\mathbf{h}}_{b_k,k}^n = \sum_{i=1}^{L_c} p_i \mathbf{c}_i$, 其中 p_i 表示系数。挑选 L_c 列码本和计算系数 p_i 可由OMP算法进行求解。用户端将此 L_c 列码本对应的列号以及系数 p_i 量化后反馈给基站。

4.5.2 性能表现

4.5.2.1 信道反馈完美已知

图4-1展示了在基站距离为300、每小区15用户、每个RB服务5个用户, 信道信息完美反馈的情况下, 所提方案和基线方案的小区平均和边缘吞吐量对比。表4-2和表4-3分别给出了所提方案和基线方案相比, 所达到的系统平均增益及边缘增益。可以看出, 采用WMMSE进行数字波束成形设计的方案Baseline-WMMSE和所提的干扰

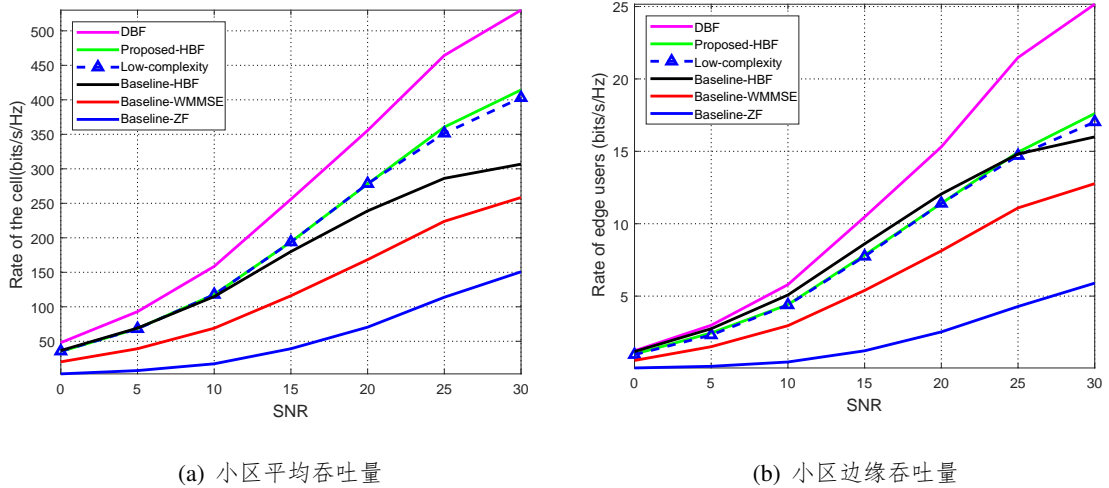


图 4-1 信道反馈完美下的小区平均和边缘吞吐量

表 4-3 Proposed-HBF算法对基线算法的边缘增益

小区边缘增益/ SNR	0	5	10	15	20	25	30
Baseline-ZF	2000%	1533%	877%	541%	356%	250%	200.3%
Baseline-WMMSE	81.2%	63.3%	49.15%	45.26%	40.73%	34.71%	38.88%
Baseline-HBF	-14.5%	-10.58%	-13.21%	-9.3%	-5.11%	1.21%	10.63%

迫零方案Proposed-HBF的小区平均/边缘吞吐量性能远优于使用ZF的方案下的性能，证明了WMMSE算法可带来容量增益。进一步对比所提方案Proposed-HBF和Baseline-WMMSE方案，可以看出发送功率增大，小区平均性能和边缘用户性能的差距逐渐增大。另外，随着发送功率的增大，所提方案的性能逐渐超过不考虑小区间干扰的HBF方案性能，分析是由于小区间干扰随着发送功率的增大而增大，因而Proposed-HBF方案对小区间干扰的抑制能力带来了显著的系统增益。与此同时，可以看到所提出的低复杂度方案的性能损失很小，十分逼近干扰迫零算法的性能，表明了近似矩阵求逆方案的有效性。

4.5.2.2 存在信道反馈误差

图4-2和图4-3分别描述了在Type I和Type II反馈条件下，所提方案Proposed-HBF和基线方案的小区平均和边缘吞吐量对比。表4-4—表4-7为这两种反馈下所提算法对比基线算法取得的具体性能增益。可以看出相比于图4-1中的完美信道，Type II反馈场景由于信道反馈带来了误差，并导致了系统总体吞吐量下降。但与其他基线方案相比，所提的Proposed-HBF方案性能较图4-1没有产生很明显的下降，这表明了所提方案在信道反馈




图 4-2 Type I反馈下的小区平均和边缘吞吐量

表 4-4 Type I反馈时Proposed-HBF算法对基线算法的平均增益

小区平均增益/ SNR	0	5	10	15	20	25	30
Baseline-ZF	326%	227%	180.9%	139%	123.6%	101.38%	85.7%
Baseline-WMMSE	58.33%	56.52%	49.75%	44.44%	48.19%	45.65%	43.11%
Baseline-HBF	-3.9%	-4.47%	-3.27%	-1.92%	5.13%	6.67%	7.58%

表 4-5 Type I反馈时Proposed-HBF算法对基线算法的边缘增益

小区边缘增益/ SNR	0	5	10	15	20	25	30
Baseline-ZF	284%	207%	168.1%	124.3%	114.3%	100.26%	88.23%
Baseline-WMMSE	51.5%	47.6%	37.5%	33.05%	45.32%	44.92%	48.21%
Baseline-HBF	-16.67%	-17.48%	-10.8%	-13.1%	-2.11%	0.15%	5.06%

存在误差的情况下，依然具有不错的性能增益。另外，图4-2中所有算法的整体性能均表现出明显损失，这是由于Type I反馈精确度较差，反馈信道存在很大误差，这也影响了所提算法对小区间干扰的抑制效果，进而影响了性能增益。

4.5.2.3 初始化调度方案

针对第 b_k 个小区，考虑第 n 个RB上的用户调度。假设开始时没有任何用户参与调度，调度方案为空白，在此基础上对每个波束成形向量 $\mathbf{f}_{b_k,u}^n$ ，寻找分配到该波束向量瞬时速率最大的用户，并将这一波束成形向量分配给该用户。通过这种策略不断迭代，直到完成第 b_k 个小区所有RB上的用户调度。 $\hat{r}_{b_k,k}^n(\mathbf{f}_{b_k,u}^n)$ 是小区 b_k 中被第 n 个RB服务的用户 k 被分配

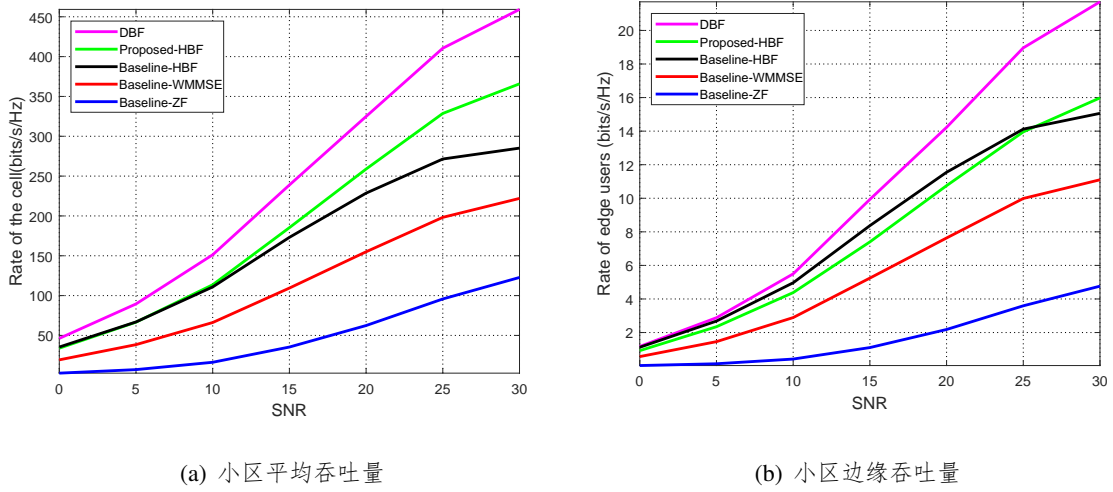


图 4-3 Type II反馈下的小区平均和边缘吞吐量

表 4-6 Type II反馈时Proposed-HBF算法对基线算法的平均增益

小区平均增益/ SNR	0	5	10	15	20	25	30
Baseline-ZF	1550%	842%	606%	428%	316%	245%	199%
Baseline-WMMSE	73.68%	72.89%	86.36%	69.72%	66.45%	65.65%	65.15%
Baseline-HBF	-4.23%	-0.04%	2.72%	6.93%	13.16%	21.07%	28.09%

表 4-7 Type II反馈时Proposed-HBF算法对基线算法的边缘增益

小区边缘增益/ SNR	0	5	10	15	20	25	30
Baseline-ZF	2000%	1692%	928%	563%	390%	289%	235%
Baseline-WMMSE	64.2%	62.1%	51.9%	41.06%	40.62%	40.08%	43.96%
Baseline-HBF	-17.5%	-11.18%	-11.21%	-10.3%	-6.11%	-1.21%	6.63%

到 $\mathbf{f}_{b_k,u}^n$ 时的瞬时速率，其表达式为

$$\tilde{r}_{b_k,k}^n(\mathbf{f}_{b_k,u}^n) = \log \left(1 + \frac{\left| (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{f}_{b_k,u}^n \right|^2}{\sum_{\substack{i \neq k \\ b_i = b_k}} \left| (\tilde{\mathbf{h}}_{b_k,k}^n)^H \mathbf{T}_{b_k} \mathbf{f}_{b_k,i}^n \right|^2 + \sum_{c \in \mathcal{N}(b_k)} \tilde{P}_c + \sigma_k^2 \|\mathbf{u}_{b_k,k}^n\|^2} \right). \quad (4.40)$$

由于是初始化调度，希望可以尽可能多的调度用户，因此在每个RB上不会重复调度某一用户。

图4-4给出了采用贪婪的初始化调度后各个方案的性能对比。其中为了减少小区间的信息交互，所提方案没有将波束成形设计和用户调度进行迭代，其他对比方案由于在设计波束成形矩阵时未考虑其他小区的干扰，因此保持迭代。可以看到，与随机调度方案对

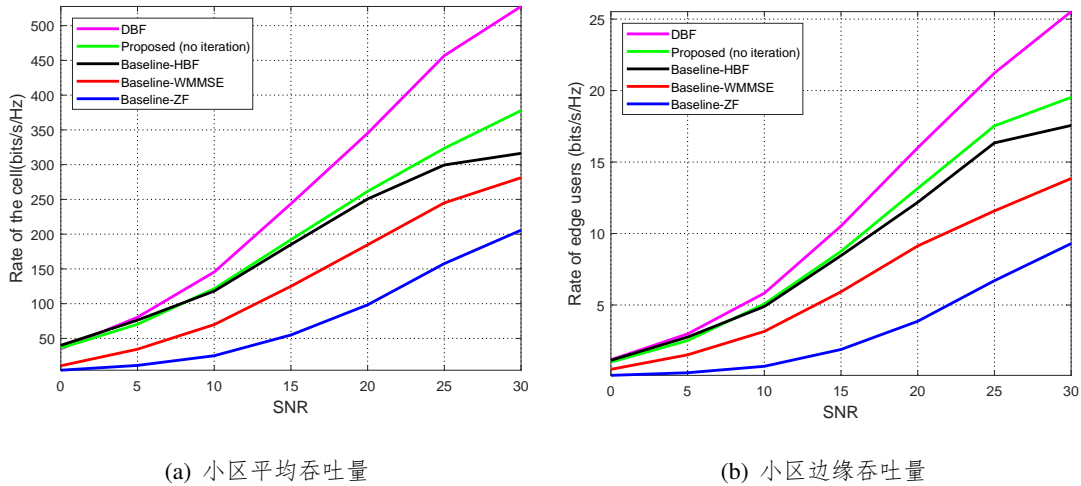


图 4-4 贪婪初始化调度下的小区平均和边缘吞吐量




图 4-5 小区平均和边缘吞吐量与迭代次数关系

比，贪婪的初始化调度方案能带来整体性能的提升。但是由于所提方案没有进行迭代优化，性能增益有所下降。

图4-5展示了所提的干扰迫零算法Proposed-HBF的性能与波束成形和用户调度设计交替迭代次数的关系。如图所示，随着迭代次数的增加，所提方案的性能逐渐提升。当迭代次数为5次时，性能增加不再明显，这表明了优化算法逐渐趋于收敛。

4.5.2.4 EZF方案

原干扰迫零方案直接对每个RB上的信道进行迫零处理。在Proposed-EZF方案中，考虑对若干个RB进行组合迫零处理。具体地，将若干个RB上的信道求和取平均作为这一组RB的等效信道 \mathbf{h}_{eq} ，然后针对等效信道进行迫零设计。在HBF-EZF方案中，首先

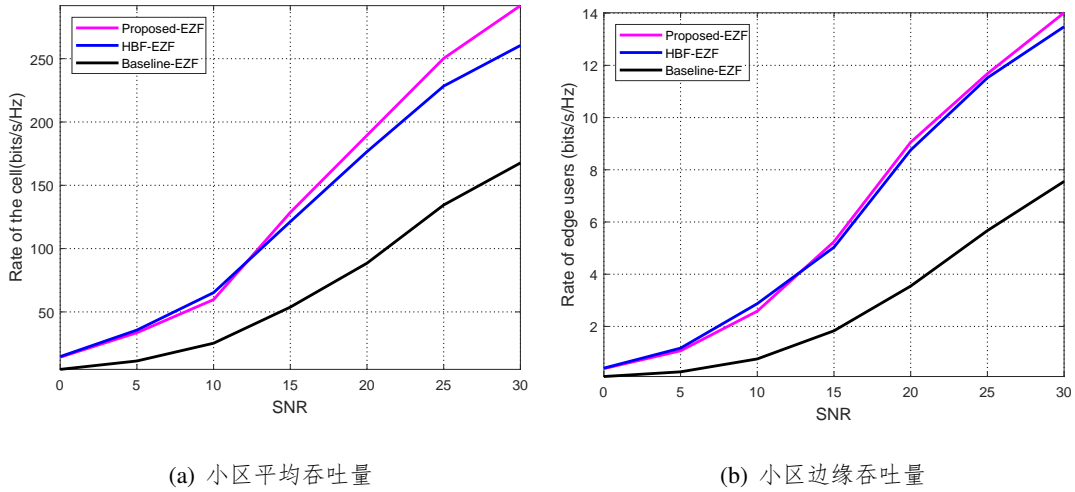


图 4-6 2RB EZF方案的小区平均和边缘吞吐量




图 4-7 5RB EZF方案的小区平均和边缘吞吐量

用EZF整体设计数字波束成形矩阵，然后将其分解为模拟和数字波束成形矩阵。

图4-6和图4-7分别描述了对不同数量的RB采用EZF方法后的性能对比，其中图4-6为对每2个RB取等效信道进行迫零处理，而图4-7则对每5个RB取了等效信道。在仿真中，所提方案Proposed-EZF只对数字波束成形矩阵采取EZF算法，模拟波束成形矩阵采用抑制小区间干扰的设计。从图4-6中可以看到，所提方案与基线方案相比获得了明显增益，说明模拟波束成形矩阵的设计有效抑制了小区间干扰，提高了系统性能。而观察4-7发现，与HBF-EZF方案对比，所提的干扰迫零方案Proposed-EZF并无太多性能增益，这是由于选择的RB组合数过多，导致了小区内干扰大于小区间干扰，成为主导的干扰因素，因此所提方案表现出与HBF-EZF相近的性能。

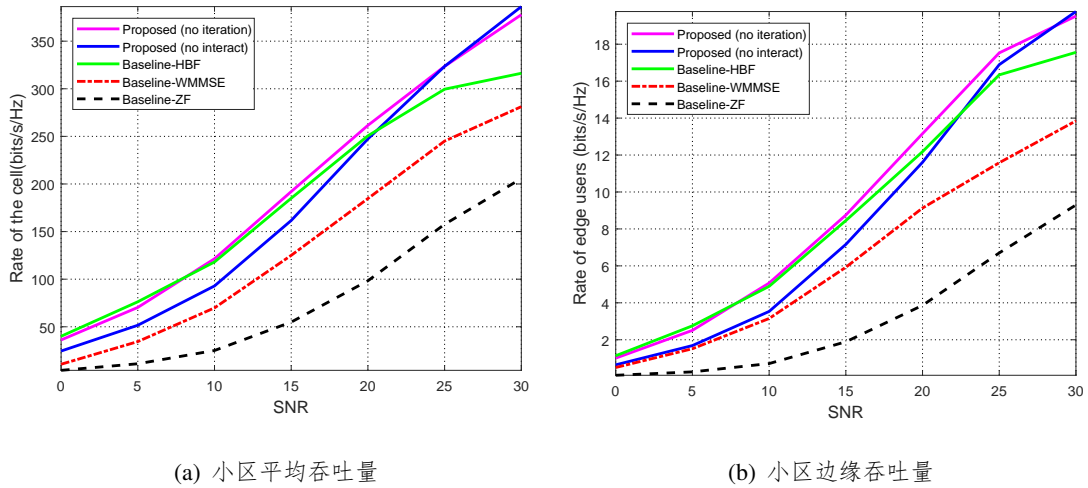


图 4-8 不交互信息方案的小区平均和边缘吞吐量

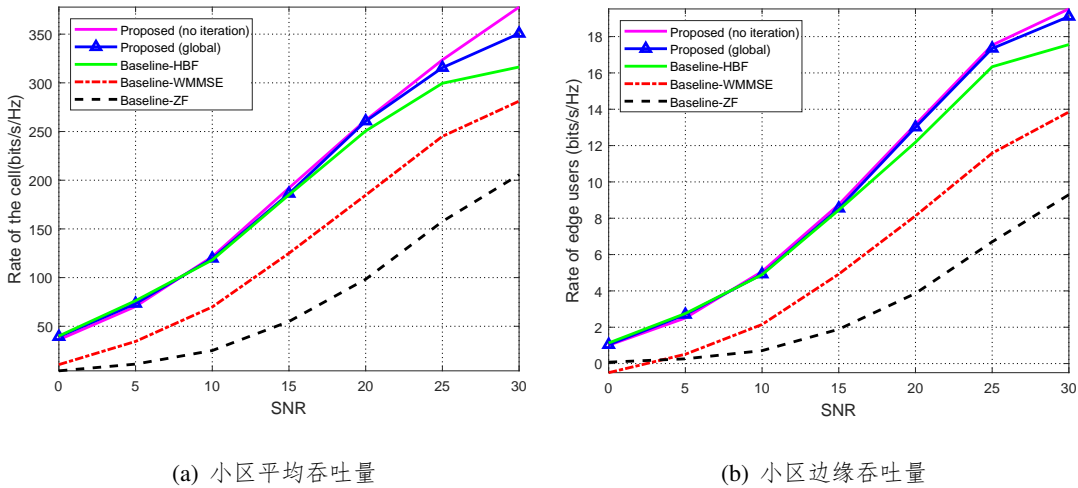


图 4-9 整体优化和矩阵分解方案的小区平均和边缘吞吐量

4.5.2.5 小区间不交互信息方案和整体优化方案

在第4.4.1小节的原始干扰迫零方案中，在选择本小区与相邻小区用户的交叉信道时，所选取的是本小区与相邻小区当前时刻被调度的用户的信道，这样就需要小区间调度方案的信息交互。为了进一步减少交互，考虑小区间不交互信息方案，即在选择信道时直接选取能量最强的交叉信道，而无需考虑当前时刻该用户是否被调度。在这种情况下，波束成形设计可以在每个小区内独立完成，不需要小区间进行交互信息。图4-8给出了该方案的系统性能。可以看到，小区间不交互方案Proposed (no interact) 在低信噪比时略有性能损失，在高信噪比时性能较好，在用户调度和波束成形设计不迭代的情况下甚至可以超过原方案Proposed (no iteration)。

图4-9展示了第4.4.3小节中整体优化和矩阵分解算法方案的性能表现。从图中可得，

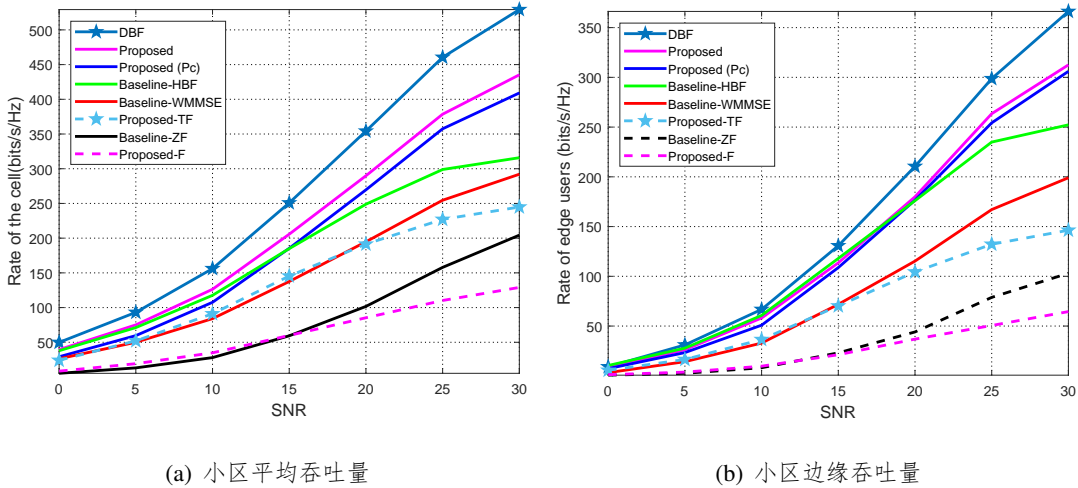


图 4-10 干扰不近似方案的小区平均和边缘吞吐量

在高信噪比时，整体优化方案性能明显优于基线方案，但是与所提出的干扰迫零方案相比却表现出了性能上的不足，原因是在将整体设计出的波束成形矩阵分解为模拟和数字波束成形矩阵时引入了较大的性能损失。

4.5.2.6 小区间干扰不近似

在图4-10中，Proposed (Pc) 曲线表示小区间干扰用 \tilde{P}_c 来近似，Proposed表示小区间干扰不近似。可以看到，精确计算小区间干扰的方案相比于将其近似为 \tilde{P}_c 的方案在性能上有所提升。Proposed-TF方案性能与基线迫零方案性能相比表现出明显提升。而Proposed-F方案则性能较差，这是由于抑制干扰自由度不够而导致的。

4.5.2.7 量化模拟波束成形矩阵

在图4-11中，2 bit表示该方案中模拟波束成形矩阵的相位角用2 bit量化。可以看到，所提方案在量化后仍有较为明显的性能增益。而Baseline-HBF方案性能则有明显的下降，分析是由于在整体设计波束成形矩阵时未考虑到模拟波束成形矩阵的离散相位约束，因而在后续分解成离散的模拟波束成形矩阵和数字波束成形矩阵时引入了性能损失。而所提的Proposed-HBF方案虽然在将 \mathbf{U} 分解成 \mathbf{T} 和 $\mathbf{F}_{b_k}^1$ 时也未考虑模拟波束成形矩阵的离散相位，但 $\mathbf{F}_{b_k}^2$ 的设计是基于离散相位后的 \mathbf{T} 进行的，因此性能损失较小。

图4-12也是模拟波束成形矩阵的相位角用2 bit量化后的性能曲线。两者区别之处在于量化方式不同，图4-11是通过分解算法得到完整的模拟波束成形矩阵之后进行量化，图4-12则是在分解算法的迭代过程中将模拟波束成形矩阵进行量化，即BCD分解算法每进

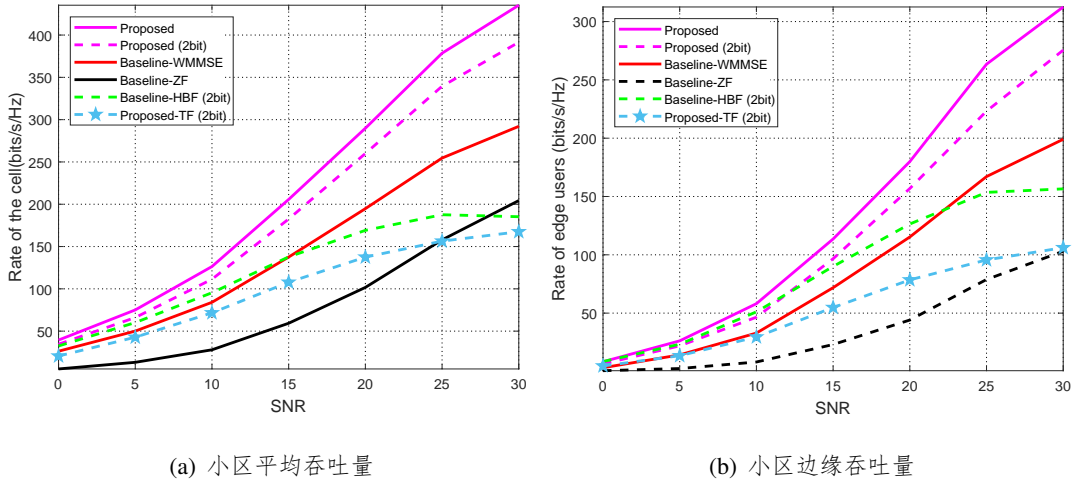


图 4-11 2 bit量化模拟波束成形矩阵的小区平均和边缘吞吐量

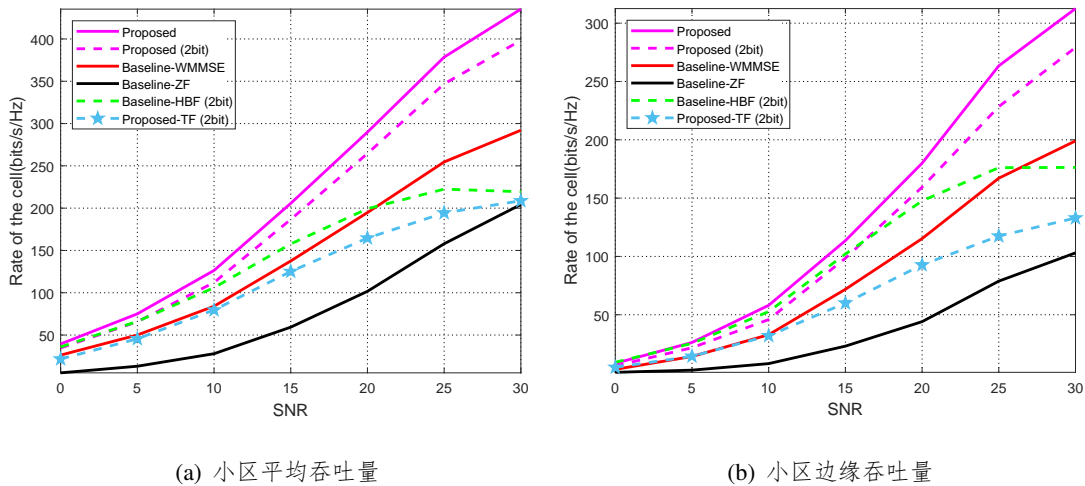


图 4-12 优化2 bit量化模拟波束成形矩阵的小区平均和边缘吞吐量

进行一次迭代，模拟波束成形矩阵就会被量化一次。可以看到，图4-12中优化量化方法的性能略有提升。

4.6 本章小结

本章主要考虑了多小区协同用户调度和混合波束成形联合设计问题。由于小区间干扰的存在导致问题结构具有非凸性，且调度方案的设计会引入离散变量，寻找其全局最优解十分具有挑战。因此，本章首先将原问题分解成两个子问题，即用户调度问题和混合波束成形矩阵设计问题，并通过迭代的方式交替优化以求得原问题的次优解。随后，分别针对这两个子问题给出了求解策略。其中，针对用户调度问题提出了综合考虑系统吞吐量和用户公平性的比例公平算法，针对波束成形设计则提出了抑制干扰的干扰迫零方案及整体优

化和矩阵分解方案。特别地，考虑到在实际部署中需要以有限的交互信息尽可能多地挖掘系统增益，本章设计了一种低复杂度近似方案。仿真结果表明，在存在信道反馈误差的情况下，所提算法仍能表现出明显的性能增益，且低复杂度近似方案的性能损失很小，证明了所提算法的有效性，能够提高边缘用户容量和小区平均吞吐量。

5 工作总结和展望

本章将对论文工作进行总结，并对未来的研究工作进行展望。

5.1 工作总结

本文主要研究了B5G大规模MIMO系统中的高效能混合波束成形设计。具体而言，论文对两个典型的场景进行了研究。第一个场景是基于MSER准则的单小区混合波束成形设计，结合深度展开神经网络进行了算法的进一步优化。第二个场景则是多小区协同用户调度和混合波束成形设计联合优化，提出了有效的资源分配策略和波束成形设计方案，以有限的回程通信资源实现了小区边缘用户性能的改善和系统整体吞吐率的提升。本文的主要贡献包括：

1. 从通信可靠性出发，本文提出了基于MSER的算法模型框架。针对大规模MIMO系统中基于MSER准则的混合AD收发机设计问题，本文提出了一种有效的GD迭代算法解决方案。特别地，由于目标函数和模拟波束形成矩阵恒模约束的高度非凸性，解决原问题非常具有挑战性。因此本文首先通过核密度估计和单位模矩阵的参数表示将原问题转化为无约束问题，随后设计了一种基于无约束MSER的GD迭代算法求得该问题驻点。分析结果表明，此算法明显优于传统的MMSE相关算法，有效提高了大规模MIMO系统的误码率性能，进一步保障了无线通信系统的传输可靠性。
2. 为了减少传统迭代算法的训练开销，同时不损害性能表现，本文提出了深度展开神经网络的设计思路及通用框架。同时，基于上述GD迭代算法结构，本文提出了一种基于MSER的深度展开神经网络。在该网络中，迭代算法被展开为多层结构，并引入了一组可训练参数以加快收敛，同时保证混合收发机的系统性能。由于现有的神经网络训练平台处理能力有限，本文提出了一种用于计算梯度闭式解的更准确高效的新方法，首先基于链式法则推导相邻层梯度之间的递归关系，然后基于此计算可训练参数的梯度，使深度展开网络能够得到切实有效的训练。本文还为深度展开算法的收敛性提供了理论证明，该分析思路也可应用于其他深度展开模型。结果表

明：所提出的深度展开算法性能显著优于传统的深度学习网络的性能，并且可逼近基于MSER的GD迭代算法性能。通过该方法，在保证性能表现的同时，有效提升了算法的收敛速率，大大减少了系统的训练开销。

3. 本文针对多小区协同架构下的联合用户调度和混合波束成形设计提出了解决方案。由于问题结构的非凸性和优化变量的高度耦合，寻找其全局最优解十分具有挑战。因此，本文首先对原始问题进行近似优化，并将其分解成两个子问题，通过迭代的方式交替优化以求得原问题的次优解。接着，考虑到系统容量和用户公平性的平衡，本文提出了贪婪的比例公平算法进行用户调度。在固定该调度方案的情况下，设计了多种混合波束成形算法方案来抑制干扰，并提出了低复杂度近似方案以进一步减少小区间协作量。分析结果表明，相较于传统算法，此算法在不理想反馈情况下仍能带来良好的协作增益，所提的低复杂度近似方案也表现优秀，以较低的通信开销有效提高了边缘用户容量和小区平均吞吐量。

5.2 进一步展望

大规模MIMO系统中混合波束成形技术的应用场景变化繁多，本文只选取了几个有代表性的核心技术进行探讨，但由于水平和时间的限制，仍有许多问题亟待进一步的改进和研究。

由于MSER准则的目标函数本身具有复杂结构，本文在设计基于MSER的混合收发机时只考虑了较为简单的理想情况。在实际应用中，必会出现诸多非理想因素，如不完美信道等。在未来研究中，可以进一步考虑在更为复杂场景中的MSER混合波束成形设计，例如，结合编码方式或信道估计进行设计，亦或者是将其延伸到多小区场景中。MSER准则在设计时具有较高的数理要求，在实现时的计算复杂度也较高，目前对这类算法的研究较少，寻找MSER算法的低复杂度优化在真实的复杂通信场景中具有进一步的现实意义。

在本文中，设计多小区协同用户调度和混合波束成形方案时假设通信过程中各用户位置固定不变。在实际通信环境中，用户位置通常是可移动的，信道环境、用户间干扰等都会随之改变。因此，未来研究可进一步考虑对可移动用户的协同设计。同时，由于用传统算法求取原问题的全局最优解十分具有挑战性，本文将原始问题拆分成了两个子问题，并且只求得了其次优解。因此，未来可考虑将深度展开算法应用于该问题，以获得更好的系统性能表现。随着模型驱动算法的不断发展，更先进的算法不断涌现，未来将本问题与更多更合适的算法相结合也是一个发展方向。

参考文献

- [1] Chris Metzler, Ali Mousavi, Richard Baraniuk. Learned d-amp: Principled neural network based compressive image recovery[J]. *Advances in Neural Information Processing Systems*, 2017. 30.
- [2] Jian Sun, Huibin Li, Zongben Xu, et al. Deep admm-net for compressive sensing mri[J]. *Advances in neural information processing systems*, 2016. 29.
- [3] W. Ajib, D. Haccoun. An overview of scheduling algorithms in mimo-based fourth-generation wireless systems[J]. *IEEE Network*, Sept.-Oct. 2005. 19(5):43–48.
- [4] Taeyoung Kim, Jeongho Park, Ji-Yun Seol, Suryong Jeong, Jaeweon Cho, Wonil Roh. Tens of gbps support with mmwave beamforming systems for next generation communications[C]//2013 IEEE Global Communications Conference (GLOBECOM). Dec. 2013:3685–3690.
- [5] Xinying Zhang, A.F. Molisch, Sun-Yuan Kung. Variable-phase-shift-based rf-baseband codesign for mimo antenna selection[J]. *IEEE Transactions on Signal Processing*, Nov. 2005. 53(11):4091–4103.
- [6] Pallav Sudarshan, Neelesh B. Mehta, Andreas F. Molisch, Jin Zhang. Channel statistics-based rf pre-processing with antenna selection[J]. *IEEE Transactions on Wireless Communications*, Dec. 2006. 5(12):3501–3511.
- [7] Omar El Ayach, Sridhar Rajagopal, Shadi Abu-Surra, Zhouyue Pi, Robert W. Heath. Spatially sparse precoding in millimeter wave mimo systems[J]. *IEEE Transactions on Wireless Communications*, Mar. 2014. 13(3):1499–1513.
- [8] Foad Sahrabi, Wei Yu. Hybrid digital and analog beamforming design for large-scale antenna arrays[J]. *IEEE Journal of Selected Topics in Signal Processing*, Apr. 2016. 10(3):501–513.
- [9] Minhyun Kim, Yong H. Lee. Mse-based hybrid rf/baseband processing for millimeter-wave communication systems in mimo interference channels[J]. *IEEE Transactions on Vehicular Technology*, Jun. 2015. 64(6):2714–2720.
- [10] Duy H. N. Nguyen, Long Bao Le, Tho Le-Ngoc. Hybrid mmse precoding for mmwave multiuser mimo systems[C]//2016 IEEE International Conference on Communications (ICC). May 2016:1–6.
- [11] Foad Sahrabi, Wei Yu. Hybrid digital and analog beamforming design for large-scale antenna arrays[J]. *IEEE Journal of Selected Topics in Signal Processing*, Sept. 2016. 10(3):501–513.
- [12] Xianghao Yu, Juei-Chin Shen, Jun Zhang, Khaled B. Letaief. Alternating minimization algorithms for hy-

- brid precoding in millimeter wave mimo systems[J]. *IEEE Journal of Selected Topics in Signal Processing*, Apr. 2016. 10(3):485–500.
- [13] Shiwen He, Jiaheng Wang, Yongming Huang, Björn Ottersten, Wei Hong. Codebook-based hybrid precoding for millimeter wave multiuser systems[J]. *IEEE Transactions on Signal Processing*, Oct. 2017. 65(20).
- [14] Jiaqi Cong, Xianchi Li, Yu Zhu. Hybrid precoding for multi-user mmwave systems based on mmse criterion[C]//2017 23rd Asia-Pacific Conference on Communications (APCC). Dec. 2017:1–5.
- [15] Tian Lin, Jiaqi Cong, Yu Zhu, Jun Zhang, Khaled Ben Letaief. Hybrid beamforming for millimeter wave systems using the mmse criterion[J]. *IEEE Transactions on Communications*, May 2019. 67(5):3693–3708.
- [16] Yunlong Cai, Rodrigo C. de Lamare. Adaptive linear minimum ber reduced-rank interference suppression algorithms based on joint and iterative optimization of filters[J]. *IEEE Communications Letters*, Apr. 2013. 17(4):633–636.
- [17] Yunlong Cai, Rodrigo C. de Lamare, Benoit Champagne, Boya Qin, Minjian Zhao. Adaptive reduced-rank receive processing based on minimum symbol-error-rate criterion for large-scale multiple-antenna systems[J]. *IEEE Transactions on Communications*, Nov. 2015. 63(11):4185–4201.
- [18] Mingjie Shao, Qiang Li, Wing-Kin Ma. One-bit massive mimo precoding via a minimum symbol-error probability design[C]//2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Apr. 2018:3579–3583.
- [19] Ka Lung Law, Christos Masouros. Symbol error rate minimization precoding for interference exploitation[J]. *IEEE Transactions on Communications*, Nov. 2018. 66(11):5718–5731.
- [20] Hieu Duy Nguyen, Rui Zhang, Sumei Sun. Improper signaling for symbol error rate minimization in k -user interference channel[J]. *IEEE Transactions on Communications*, Mar. 2015. 63(3).
- [21] Timothy Ohea, Jakob Hoydis. An introduction to deep learning for the physical layer[J]. *IEEE Transactions on Cognitive Communications and Networking*, Dec. 2017. 3(4):563–575.
- [22] Sebastian Dörner, Sebastian Cammerer, Jakob Hoydis, Stephan Ten Brink. Deep learning based communication over the air[J]. *IEEE Journal of Selected Topics in Signal Processing*, Feb. 2017. 12(1):132–143.
- [23] Peihao Dong, Hua Zhang, Geoffrey Ye Li. Framework on deep learning-based joint hybrid processing for mmwave massive mimo systems[J]. *IEEE Access*, Jun. 2020. 8:106023–106035.
- [24] David Neumann, Thomas Wiese, Wolfgang Utschick. Learning the mmse channel estimator[J]. *IEEE Transactions on Signal Processing*, Jun. 2018. 66(11):2905–2917.
- [25] Haoran Sun, Xiangyi Chen, Qingjiang Shi, Mingyi Hong, Xiao Fu, Nicholas D Sidiropoulos. Learning to optimize: Training deep neural networks for interference management[J]. *IEEE Transactions on Signal Processing*, Oct. 2018. 66(20):5438–5453.
- [26] Woongsup Lee, Minhoe Kim, Dong-Ho Cho. Deep power control: Transmit power control scheme based on convolutional neural network[J]. *IEEE Communications Letters*, Jun. 2018. 22(6):1276–1279.

- [27] Fei Liang, Cong Shen, Wei Yu, Feng Wu. Towards optimal power control via ensembling deep neural networks[J]. *IEEE Transactions on Communications*, Mar. 2019. 68(3):1760–1776.
- [28] Ahmet M Elbir, Kumar Vijay Mishra. Deep learning design for joint antenna selection and hybrid beamforming in massive mimo[C]//2019 IEEE International Symposium on Antennas and Propagation and USNC-URSI Radio Science Meeting. Jul. 2019:1585–1586.
- [29] Xiaofeng Li, Ahmed Alkhateeb. Deep learning for direct hybrid precoding in millimeter wave massive mimo systems[C]//2019 53rd Asilomar Conference on Signals, Systems, and Computers. Nov. 2019:800–805.
- [30] C Sidharth, Shrishail M Hiremath, Sarat Kumar Patra. Deep learning based hybrid precoding for mmwave massive mimo system using comceptnet[C]//2020 International Conference on Communication and Signal Processing (ICCSP). Jul. 2020:1317–1321.
- [31] John R Hershey, Jonathan Le Roux, Felix Weninger. Deep unfolding: Model-based inspiration of novel deep architectures[J]. *arXiv preprint arXiv:1409.2574*, Nov. 2014.
- [32] Vincent Corlay, Joseph J Boutros, Philippe Ciblat, Loc Brunel. Multilevel mimo detection with deep learning[C]//2018 52nd Asilomar Conference on Signals, Systems, and Computers. Oct. 2018:1805–1809.
- [33] Neev Samuel, Tzvi Diskin, Ami Wiesel. Learning to detect[J]. *IEEE Transactions on Signal Processing*, May 2019. 67(10):2554–2564.
- [34] Weihong Xu, Zhizhen Wu, Yeong-Luh Ueng, Xiaohu You, Chuan Zhang. Improved polar decoder based on deep learning[C]//2017 IEEE International workshop on signal processing systems (SiPS). Oct. 2017:1–6.
- [35] Weihong Xu, Xiaohu You, Chuan Zhang, Yair Be'ery. Polar decoding on sparse graphs with deep learning[C]//2018 52nd Asilomar Conference on Signals, Systems, and Computers. Oct. 2018:599–603.
- [36] Daisuke Ito, Satoshi Takabe, Tadashi Wadayama. Trainable ista for sparse signal recovery[J]. *IEEE Transactions on Signal Processing*, Jun. 2019. 67(12):3113–3125.
- [37] Alexios Balatsoukas-Stimming, Oscar Castañeda, Sven Jacobsson, Giuseppe Durisi, Christoph Studer. Neural-network optimized 1-bit precoding for massive mu-mimo[C]//2019 IEEE 20th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Jul. 2019:1–5.
- [38] Yunfeng He, Hengtao He, Chao-Kai Wen, Shi Jin. Model-driven deep learning for massive multiuser mimo constant envelope precoding[J]. *IEEE Wireless Communications Letters*, Nov. 2020. 9(11):1835–1839.
- [39] Hengtao He, Mengjiao Zhang, Shi Jin, Chao-Kai Wen, Geoffrey Ye Li. Model-driven deep learning for massive mu-mimo with finite-alphabet precoding[J]. *IEEE Communications Letters*, Oct. 2020. 24(10):2216–2220.
- [40] Qiyu Hu, Yunlong Cai, Qingjiang Shi, Kaidi Xu, Guanding Yu, Zhi Ding. Iterative algorithm induced deep-unfolding neural networks: Precoding design for multiuser mimo systems[J]. *IEEE Transactions on Wireless Communications*, Feb. 2020. 20(2):1394–1410.

- [41] David Gesbert, Stephen Hanly, Howard Huang, Shlomo Shamai Shitz, Osvaldo Simeone, Wei Yu. Multi-cell mimo cooperative networks: A new look at interference[J]. *IEEE journal on selected areas in communications*, Dec. 2010. 28(9):1380–1408.
- [42] Jeffrey G Andrews, Wan Choi, Robert W Heath. Overcoming interference in spatial multiplexing mimo cellular networks[J]. *IEEE Wireless Communications*, Dec. 2007. 14(6):95–104.
- [43] Shlomo Shamai, Benjamin M Zaidel. Enhancing the cellular downlink capacity via co-processing at the transmitting end[C]//*IEEE VTS 53rd Vehicular Technology Conference*, Spring 2001. Proceedings (Cat. No. 01CH37202). volume 3. May 2001:1745–1749.
- [44] Hongyuan Zhang, Huaiyu Dai. Cochannel interference mitigation and cooperative processing in downlink multicell multiuser mimo networks[J]. *EURASIP Journal on Wireless Communications and Networking*, Dec. 2004. 2004(2):1–14.
- [45] Farrokh Rashid-Farrokhi, KJ Ray Liu, Leandros Tassiulas. Transmit beamforming and power control for cellular wireless systems[J]. *IEEE Journal on selected areas in communications*, Oct. 1998. 16(8):1437–1450.
- [46] Hayssam Dahrouj, Wei Yu. Coordinated beamforming for the multicell multi-antenna wireless system[J]. *IEEE transactions on wireless communications*, May 2010. 9(5):1748–1759.
- [47] Carmen Botella, Gema Pinero, Alberto Gonzalez, Maria De Diego. Coordination in a multi-cell multi-antenna multi-user w-cdma system: A beamforming approach[J]. *IEEE Transactions on Wireless Communications*, Nov. 2008. 7(11):4479–4485.
- [48] Yuwen Cao, Tomoaki Ohtsuki, Tony QS Quek. Dual-ascent inspired transmit precoding for evolving multiple-access spatial modulation[J]. *IEEE Transactions on Communications*, Nov. 2020. 68(11):6945–6961.
- [49] Wan Choi, Jeffrey G Andrews. The capacity gain from intercell scheduling in multi-antenna systems[J]. *IEEE Transactions on Wireless Communications*, Feb. 2008. 7(2):714–725.
- [50] Frank P Kelly, Aman K Maulloo, David Kim Hong Tan. Rate control for communication networks: shadow prices, proportional fairness and stability[J]. *Journal of the Operational Research society*, May 1998. 49(3):237–252.
- [51] Saad G Kiani, David Gesbert. Optimal and distributed scheduling for multicell capacity maximization[J]. *IEEE Transactions on Wireless Communications*, Jan. 2008. 7(1):288–297.
- [52] Changxin Shi, Randall A Berry, Michael L Honig. Adaptive beamforming in interference networks via bi-directional training[C]//*2010 44th Annual Conference on Information Sciences and Systems (CISS)*. Mar. 2010:1–6.
- [53] Bin Han, Zheng Jiang, Lin Liang, Peng Chen, Fengyi Yang, Qi Bi. Joint precoding and scheduling algorithm for massive mimo in fdd multi-cell network[J]. *Wireless networks*, Jan. 2019. 25(1):75–85.

- [54] Howard H Yang, Giovanni Geraci, Tony QS Quek, Jeffrey G Andrews. Cell-edge-aware precoding for downlink massive mimo cellular networks[J]. IEEE Transactions on Signal Processing, Jul. 2017. 65(13):3344–3358.
- [55] Shanjin Ni, Junhui Zhao, Howard H Yang, Yi Gong. Enhancing downlink transmission in mimo hetnet with wireless backhaul[J]. IEEE Transactions on Vehicular Technology, Jul. 2019. 68(7):6817–6832.
- [56] Akbar Sayeed, John Brady. Beamspace mimo for high-dimensional multiuser communication at millimeter-wave frequencies[C]//2013 IEEE global communications conference (GLOBECOM). Dec. 2013:3679–3684.
- [57] Søren Skovgaard Christensen, Rajiv Agarwal, Elisabeth De Carvalho, John M Cioffi. Weighted sum-rate maximization using weighted mmse for mimo-bc beamforming design[J]. IEEE Transactions on Wireless Communications, Dec. 2008. 7(12):4792–4799.
- [58] Karol Gregor, Yann LeCun. Learning fast approximations of sparse coding[C]//Proceedings of the 27th international conference on international conference on machine learning. Jun. 2010:399–406.
- [59] Hussein Al Haj Hassan, Alexander Pelov, Loutfi Nuaymi. Integrating cellular networks, smart grid, and renewable energy: Analysis, architecture, and challenges[J]. IEEE access, Dec. 2015. 3:2755–2770.
- [60] Quentin H Spencer, A Lee Swindlehurst, Martin Haardt. Zero-forcing methods for downlink spatial multiplexing in multiuser mimo channels[J]. IEEE transactions on signal processing, Feb. 2004. 52(2):461–471.
- [61] Thomas Haustein, Clemens Von Helmolt, E Jorswieck, Volker Jungnickel, Volker Pohl. Performance of mimo systems with channel inversion[C]//Vehicular Technology Conference. IEEE 55th Vehicular Technology Conference. VTC Spring 2002 (Cat. No. 02CH37367). volume 1. Aug. 2002:35–39.
- [62] Sheng Chen, Ahmad K Samingan, Bernard Mulgrew, Lajos Hanzo. Adaptive minimum-ber linear multiuser detection for ds-cdma signals in multipath channels[J]. IEEE Transactions on signal processing, Jun. 2001. 49(6):1240–1247.
- [63] Sheng Chen, Andy Livingstone, H-Q Du, Lajos Hanzo. Adaptive minimum symbol error rate beamforming assisted detection for quadrature amplitude modulation[J]. IEEE Transactions on Wireless Communication, Apr. 2008. 7(4):1140–1145.

附录

A.1 第三章可训练参数的梯度

根据GCR法则对式(3.27)–(3.30)两边求导，可求得每一层网络中可训练参数的梯度如下，其中为了表示更清晰，下式省略网络层数索引 t 。

$$\begin{aligned}
\nabla_{\mathbf{o}_{P_k}} \tilde{\mathcal{P}}_e^l &= (\mathbf{G}_{P_k}^{l+1})^H, & \nabla_{\mathbf{o}_{W_k}} \tilde{\mathcal{P}}_e^l &= (\mathbf{G}_{W_k}^{l+1})^H, \\
\nabla_{\mathbf{o}_{\theta_{U_k}}} \tilde{\mathcal{P}}_e^l &= (\mathbf{G}_{U_k}^{l+1})^H \circ j\mathbf{U}_k^* - (\mathbf{G}_{U_k^*}^{l+1})^H \circ j\mathbf{U}_k, \\
\nabla_{\mathbf{o}_{\theta_F}} \tilde{\mathcal{P}}_e^l &= (\mathbf{G}_F^{l+1})^H \circ j\mathbf{F}^* - (\mathbf{G}_{F^*}^{l+1})^H \circ j\mathbf{F}, \\
\nabla_{\alpha_{P_k}} \tilde{\mathcal{P}}_e^l &= -(\mathbf{G}_{P_k}^{l+1})^H \circ (\nabla_{\mathbf{P}_k^H} \tilde{\mathcal{P}}_e^l)^H, & \nabla_{\alpha_{W_k}} \tilde{\mathcal{P}}_e^l &= -(\mathbf{G}_{W_k}^{l+1})^H \circ (\nabla_{\mathbf{W}_k^H} \tilde{\mathcal{P}}_e^l)^H, \\
\nabla_{\alpha_{\theta_{U_k}}} \tilde{\mathcal{P}}_e^l &= -(\mathbf{G}_{U_k}^{l+1})^H \circ j\mathbf{U}_k^* \circ (\nabla_{\mathbf{U}_k} \tilde{\mathcal{P}}_e^l)^H + (\mathbf{G}_{U_k^*}^{l+1})^H \circ j\mathbf{U}_k \circ (\nabla_{\mathbf{U}_k^*} \tilde{\mathcal{P}}_e^l)^H, \\
\nabla_{\alpha_{\theta_F}} \tilde{\mathcal{P}}_e^l &= -(\mathbf{G}_F^{l+1})^H \circ j\mathbf{F}^* \circ (\nabla_{\mathbf{F}} \tilde{\mathcal{P}}_e^l)^H + (\mathbf{G}_{F^*}^{l+1})^H \circ j\mathbf{F} \circ (\nabla_{\mathbf{F}^*} \tilde{\mathcal{P}}_e^l)^H, \\
\nabla_{\rho_{P_k}} \tilde{\mathcal{P}}_e^l &= \frac{1}{J\sqrt{2\pi}(\rho_{P_k}^l)^2} \sum_{j=1}^J \sum_{i=1}^{D_k} e^{-\frac{|\bar{b}_{i,k}^{qj}|^2}{2(\rho_{P_k}^l)^2}} \left(1 - \frac{|\bar{b}_{i,k}^{qj}|^2}{2(\rho_{P_k}^l)^2}\right) \mathbf{G}_{P_k}^{l+1} \circ (\alpha_{P_k}^l)^T \mathbf{F}^H \mathbf{H}_k^H \mathbf{U}_k^H \mathbf{w}_{i,k}, \\
\nabla_{\rho_{W_k}} \tilde{\mathcal{P}}_e^l &= \frac{1}{J\sqrt{2\pi}(\rho_{W_k}^l)^2} \sum_{j=1}^J \sum_{i=1}^{D_k} e^{-\frac{|\bar{b}_{i,k}^{qj}|^2}{2(\rho_{W_k}^l)^2}} \left(1 - \frac{|\bar{b}_{i,k}^{qj}|^2}{2(\rho_{W_k}^l)^2}\right) \mathbf{G}_{W_k}^{l+1} \circ (\alpha_{W_k}^l)^T \mathbf{U}_k \mathbf{H}_k \mathbf{F} \mathbf{P}_k \mathbf{b}_k, \\
\nabla_{\rho_{U_k}} \tilde{\mathcal{P}}_e^l &= \frac{1}{J\sqrt{2\pi}(\rho_{U_k}^l)^2} \sum_{j=1}^J \sum_{i=1}^{D_k} e^{-\frac{|\bar{b}_{i,k}^{qj}|^2}{2(\rho_{U_k}^l)^2}} \left(1 - \frac{|\bar{b}_{i,k}^{qj}|^2}{2(\rho_{U_k}^l)^2}\right) \mathbf{H}_k \mathbf{F} \mathbf{P}_k \mathbf{b}_k \mathbf{G}_{U_k}^{l+1} \circ (\alpha_{\theta_{U_k}}^l)^T \mathbf{w}_{i,k}, \\
\nabla_{\rho_F} \tilde{\mathcal{P}}_e^l &= \frac{1}{J\sqrt{2\pi}(\rho_F^l)^2} \sum_{j=1}^J \sum_{i=1}^{D_k} e^{-\frac{|\bar{b}_{i,k}^{qj}|^2}{2(\rho_F^l)^2}} \left(1 - \frac{|\bar{b}_{i,k}^{qj}|^2}{2(\rho_F^l)^2}\right) \mathbf{P}_k \mathbf{b}_k \mathbf{G}_F^{l+1} \circ (\alpha_{\theta_F}^l)^T (\mathbf{w}_{i,k}^H \mathbf{U}_k \mathbf{H}_k)^T.
\end{aligned} \tag{A.1}$$

攻读硕士学位期间参研项目和主要成果

学术论文：

- [1] **S. Shi**, Y. Cai, Q. Hu, B. Champagne, L. Hanzo, “Deep-Unfolding Neural-Network Aided Hybrid Beamforming Based on Symbol-Error Probability Minimization,” **IEEE Transactions on Vehicular Technology**, vol. 72, no. 1, pp. 529-545, Jan. 2023. (SCI, 已发表, 正文第三章, 第一作者)
- [2] Q. Hu, **S. Shi**, Y. Cai, G. Yu, “DDPG-Driven Deep-Unfolding With Adaptive Depth for Channel Estimation With Sparse Bayesian Learning,” **IEEE Transactions on Signal Processing**, vol. 70, no. 1, pp. 4665-4680, Sept. 2022. (SCI, 已发表, 第二作者)
- [3] Q. Hu, **S. Shi**, Y. Cai, G. Yu, “Sparse Bayesian Learning for Channel Estimation: A DDPG-Driven Deep-Unfolding Approach with Adaptive Depth,” **IEEE International Conference on Communications**, 2022, 1282-1287. (EI, 已发表, 第二作者)

科研项目：

- [1] 国家自然科学基金面上项目, “面向高效能毫米波通信系统的多尺度混合收发机方法研究”, No. 61971376.
- [2] 华为技术有限公司, “HBF架构下的多小区协同技术”。