

学校代码 10543
分类号 TN92

学 号 811911120077
密 级 公开



湖南理工学院

Hunan Institute of Science and Technology

硕士学位论文

基于深度学习的智能超表面通信 信道估计研究

学位申请人 肖健

指导教师 谢文武 副教授

学科专业 信息与通信工程

培养单位 信息科学与工程学院

2022年5月20日

**Research on Deep Learning-Based Channel Estimation for
Reconfigurable Intelligent Surface-Aided Communication Systems**

Candidate _____ XIAO Jian _____

Supervisor _____ Associate Professor XIE Wenwu _____

Program _____ Information and Communication Engineering _____

Degree _____ Master degree in Engineering _____

University _____ Hunan Institute of Science and Technology _____

Date _____ 2022-5-20 _____

学位论文原创性声明

本人郑重声明，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。尽我所知，除了论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，也不包含为获得湖南理工学院或其他教育机构的学位或证书而使用过的材料。与我共同工作的同志对本研究所作的贡献均已在论文中作了明确的说明。

申请学位论文与资料若有不实之处，本人承担一切相关责任。

作者签名： 肖健 日期： 2022 年 5 月 20 日

学位论文授权使用授权书

本学位论文作者和指导教师完全了解湖南理工学院有关保留、使用学位论文的规定：即学校有权保留并向国家有关部门或机构送交学位论文的复印件和电子版；本人允许本学位论文被查阅和借阅；学校可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用复印、缩印或其它手段保存和汇编本学位论文。

保密论文待解密后适应本声明。

作者签名： 肖健

导师签名： 谢子武

日期： 2022 年 5 月 20 日

日期： 2022 年 5 月 20 日

摘 要

目前第五代（The 5th Generation, 5G）无线网络的主流关键物理层技术是在 6 GHz 以下频段运行的 Massive MIMO 通信系统, 而最初被视为 5G 网络三大关键技术之一的毫米波通信, 因高频电磁波固有的严重路径损耗特性而尚未被广泛应用。若沿用传统思路通过增加电磁波覆盖强度来改善毫米波通信性能将会带来更高的硬件成本和能源消耗。智能超表面（Reconfigurable Intelligent Surface, RIS）提供了一种符合成本效益并且以可持续的方式增强通信的潜在方案。通过调整亚波长单元的反射系数, RIS 可以控制电磁波的电磁参数以实现被动波束赋形, 而被动波束赋形的有效设计要求获得通信链路的准确信道信息。由于无源 RIS 没有配备射频链路, 不具备信号处理能力, 并且 RIS 所集成的大量反射单元使得发射机-RIS-接收机通信链路的级联信道呈现出高维特性, 因此 RIS 信道估计难度相对于传统通信系统更大。受人工智能技术强大的非线性映射能力激励, 本文构建深度学习模型来实现 RIS 辅助的毫米波通信系统信道估计, 具体包括:

首先, 考虑到引入 RIS 辅助通信后基站需要同时估计直射链路和级联链路的信道信息, 本文提出了基于多任务学习（Multi-task Learning, MTL）的联合信道估计方案。由于级联信道维度远大于直射信道维度, 需要估计更多的信道参数, 使得两者估计难度存在差异, 因此设计了一个基于同方差任务不确定性的可学习联合损失函数来平衡两个信道估计子任务的训练。同时, 将深度残差收缩网络结构引入多任务网络的共享层中以实现自适应的软阈值化, 从而缓解通信噪声的干扰, 提高低信噪比下信道估计精度。仿真结果展示了 MTL 的估计精度优于传统的信道估计方法, 且较已有的基于单任务学习的信道估计方案网络训练开销显著降低。

其次, 考虑到在上述的联合信道估计工作中没有降低级联信道估计的导频开销, 本工作则沿用基于超分辨率（Super-Resolution, SR）重建的信道估计思路, 通过激活少量 RIS 单元, 获得低维信道矩阵, 然后设计了基于多尺度监督学习的拉普拉斯宽残差网络（Laplacian Wide Residual Network, LapWRes）实现级联信道的渐近式重建。网络骨架模仿拉普拉斯金字塔架构, 纵向可以分为特征提取分支和信道重构分支, 横向则可以分为多个不同尺度的信道上采样块。特征提取分支采用可以保留更多原始特征的宽激活残差块来提取信道的高频信息, 而信道重构分支则采用残差学习方式将信道的高频信息与低频信息进行融合。仿真结果表明 LapWRes 可以大幅度减少导频开销, 并且信道重建精度高于已有的 SR 信道估计网络。

最后, 考虑到第二项工作虽然减少了级联信道估计的导频开销, 但是需要首先获取低维信道矩阵作为网络输入, 从而增加了信道估计操作复杂度。本工作基于深度压缩感知思

想，提出了一种不需要信道预估计且自适应不同导频长度的端到端模型。该方案采用 U 型网络（U-shaped Network, U-Net）作为网络骨架，在编码器和解码器之间的设计跳跃连接来融合不同尺度和语义的特征。与此同时，在 U-Net 内部引入残差学习形成 ResU-Net 结构来改善 U-Net 的特征提取能力。仿真结果表明 ResU-Net 对不同导频长度和相位量化误差具有良好的泛化性和鲁棒性，在较少的导频开销下较传统算法和其他的端到端网络可以获得更高的估计精度。

关键词：智能超表面；信道估计；多任务学习；残差学习；深度压缩感知

Abstract

At present, massive multi-input multi-output (Massive MIMO) operating in the sub-6 GHz bands is the key technology in the physical layer of the 5th Generation (5G) wireless networks. However, millimeter wave (mmWave) communication, originally envisioned as one of three pivotal technologies in the 5G networks, has not been widely adopted due to the severe path loss of high-frequency electromagnetic waves. If we follow the traditional idea to improve the performance of mmWave communication by increasing the coverage intensity of electromagnetic wave, it will bring higher hardware cost and energy consumption. Reconfigurable intelligent surface (RIS) offers a potential solution to enhance communication in a cost-effective and sustainable manner. By adjusting the reflection coefficient of sub-wavelength units, RIS can control the electromagnetic parameters of electromagnetic waves to achieve the passive beamforming, while the effective design of passive beamforming depends on the accurate channel information of communication links. Since RIS is not equipped with radio frequency links to perform signal processing, and the dimension of transmitter-RIS-receiver cascaded channel is high-dimensional for RIS with a large number of reflection units. Hence, the channel estimation of RIS communication is more difficult than traditional communication system. Motivated by the powerful non-linear mapping ability of artificial intelligence, we construct deep learning models to realize the channel estimation for RIS-aided mmWave communication system in this thesis, specifically including:

Firstly, considering that the base station needs to estimate direct channel and cascaded channel simultaneously for RIS-aided communication system, we propose a joint channel estimation scheme based on multi-task learning (MTL). Since the dimension of cascaded channel is much larger than direct channel, more channel parameters need to be estimated for cascaded channel, which cause the difficulty of both channel estimation is different. Consequently, we design a learnable joint loss function to balance the training of two channel estimation subtasks based on homoscedastic uncertainty. Moreover, the deep residual shrinkage network architecture is introduced into the shared layer of multi-task network to realize the self-adaptive soft thresholding, which can release the interference of communication noise and improve the channel estimation accuracy under lower signal to noise ratio. Simulation results present that the estimation accuracy of MTL outperforms the traditional channel estimation scheme, and the network training overhead is significantly lower than the existing channel estimation scheme based on single task learning.

Secondly, considering that the pilot overhead of the cascaded channel estimation is not reduced in the above joint channel estimation scheme, we follow the channel estimation ideas based on super-resolution (SR) reconstruction. By activating a few of RIS elements to obtain the partial low-dimensional channel matrix, a multi-scale supervised learning-based Laplacian wide residual network (LapWRes) is designed to realize the progressive reconstruction of cascaded channel. The backbone of network imitates the structure of Laplacian pyramid. The network can be divided vertically into feature extraction branches and channel reconstruction branches, while it can be divided horizontally into multiple channel reconstruction blocks at different scales. By stacking wide activation residual blocks, the feature extraction branch can extract more high frequency information. Meanwhile, the channel reconstruction branch uses residual learning to fuse the high frequency information and low frequency information of the channel. Simulation results present that the LapWRes can significantly reduce the pilot overhead of channel estimation, and the estimation performance is superior to the existing channel estimation model based on SR network.

Lastly, considering although the second work reduces the pilot overhead of the cascaded channel estimation, it needs to obtain the low-dimensional channel matrix as the input of network first, thus increasing the operational complexity of channel estimation. In this work, a deep compression sensing-based end-to-end model without channel pre-estimation is proposed, which can adapt to different pilot lengths. We use U-shaped network (U-Net) as the network backbone to improve the reconstruction accuracy of cascaded channel matrix, where the different scales and semantics features are fused by designing skip connections between encoders and decoders. To future improve the feature extraction ability of U-Net, residual learning is introduced into the vanilla U-Net to form ResU-Net architecture. Simulation results show that ResU-Net has good generalization and robustness for different pilot lengths and phase quantization errors. Compared with traditional algorithms and other end-to-end networks, ResU-Net can obtain higher estimation accuracy with less pilot overheads.

Key Words: Reconfigurable intelligent surface; channel estimation; multi-task learning; residual learning; deep compressed sensing

目 录

摘 要.....	I
Abstract.....	III
目 录.....	V
第 1 章 绪 论	1
1.1 研究背景.....	1
1.2 研究现状.....	3
1.2.1 经典信道估计	4
1.2.2 半被动信道估计.....	5
1.2.3 稀疏信道估计.....	5
1.2.4 智能信道估计.....	6
1.3 论文主要内容.....	7
1.4 论文结构安排.....	9
第 2 章 智能超表面通信信道估计基础	10
2.1 智能超表面辅助通信系统.....	10
2.1.1 信道模型.....	10
2.1.2 信号模型.....	12
2.2 传统信道估计方案.....	13
2.2.1 基于最小二乘的信道估计方案.....	13
2.2.2 基于压缩感知的信道估计方案.....	15
2.3 基于深度学习的信道估计方案.....	17
2.3.1 基本深度学习模型.....	17
2.3.2 端到端信道估计模型.....	20
2.3.3 后处理信道估计模型.....	21
2.4 本章小结.....	23
第 3 章 基于多任务学习的联合信道估计方案	24
3.1 多任务学习.....	24
3.2 残差收缩网络.....	25
3.2.1 可学习的软阈值化.....	25
3.2.2 通道注意力残差收缩块.....	26
3.3 多任务网络模型.....	28

3.4 性能指标与损失函数.....	29
3.5 实验结果与分析.....	30
3.6 本章小结.....	33
第 4 章 基于多尺度监督学习的级联信道估计方案	34
4.1 低分辨率信道估计.....	34
4.2 拉普拉斯金字塔.....	35
4.3 多尺度渐近式重建网络.....	35
4.3.1 特征提取分支.....	36
4.3.2 信道重构分支.....	38
4.4 实验结果与分析.....	39
4.5 小结.....	42
第 5 章 基于深度压缩感知的级联信道估计方案	43
5.1 深度压缩感知.....	43
5.1.1 模型驱动信道估计.....	43
5.1.2 纯数据驱动信道估计.....	44
5.2 相位量化与数据处理.....	45
5.3 ResU-Net 网络模型.....	46
5.3.1 编码器-解码器架构.....	46
5.3.2 长短跳跃连接.....	48
5.4 实验结果与分析.....	49
5.5 本章小结.....	51
结 语.....	53
研究总结.....	53
研究展望.....	54
参考文献	56
攻读硕士学位期间主要研究成果	66
致 谢.....	67

第1章 绪论

1.1 研究背景

无线移动通信大约每十年更新一代，从早期的模拟通信系统发展到现在的第五代（The 5th-Generation, 5G）移动通信系统，无线移动通信走过了近 40 年的发展历程。从无线通信发展的关键使能技术上看，从 1G 发展到 5G，本质上都是通过增加电磁波强度来实现通信性能的提升，然而这种通信设计理念会带来越来越高的硬件成本和能源消耗^[1]。以 5G 的关键技术中大规模多输入多输出（Massive Multi-Input Multi-Output, Massive MIMO）、毫米波通信和超密集组网技术为例^[1,2]，Massive MIMO 需要大量的有源天线/射频链路来实现高频谱效率，这将显著增加通信设备的硬件成本和信号处理复杂度。毫米波通信得益于其巨大的可用带宽以实现大容量传输，但是高频段电磁波的穿透性和绕射能力差，导致信号传播的路径损耗严重，因此毫米波通信系统需要更昂贵的天线/射频链路和复杂的阵列信号处理来补偿高路径损耗。超密集组网是通过增加更多基站来提高网络覆盖和容量的有效手段，然而随着小蜂窝基站、无线接入点（Access Point, AP）、中继和分布式主动天线等活动节点的不断增加，网络整体能耗和部署/维护成本将大幅增加。此外，网络过于密集还会导致系统内/系统间干扰更严重、资源管理复杂、回程要求高等实际问题。除了现有 5G 技术的上述缺点外，实现超大容量、超可靠的无线通信的最大瓶颈还在于随机且不可控的无线传播环境，这将导致不确定的信道衰落和信号衰减与失真。

2020-2030 年被认为是 6G 正式开发的十年，相对于 5G 的关键性能指标（Key Performance Indicators, KPIs），6G 通信场景下的 KPIs 将进一步提高^[3]，具体如表 1-1 所示。

表 1-1 5G 与 6G KPIs 比较

KPI	5G	6G	提升倍数
峰值速率	20 Gbps	1Tbps	50
体验速率	0.1 Gbps	1 Gbps	10
最大频谱效率	100 bps/Hz	200 bps/Hz	2
最大带宽	1 GHz	100 GHz	100
最大连接密度	100 万/km ²	1000 万/km ²	10
能效	100 bits/J	200 bits/J	2
时延	1 ms	0.1 ms	10
移动性	500 km/h	1000 km/h	2

如果再沿用过去的通信系统设计思路，通过增加电磁波覆盖强度来满足 6G 场景下的新

需求，将带来难以负担的硬件成本和能耗，而绿色通信和可重构的无线环境是未来无线网络的两个重要发展目标^[4,5]。智能超表面（Reconfigurable Intelligent Surface, RIS）由于其从微波到可见光的宽频率范围内具有调节电磁波的能力，已成为了 6G 中被积极探索的新兴范式^[6-8]。RIS 由大量亚波长单元的电磁表面，每个单元的电磁响应可以自由调控，如振幅、相位、极化和频率。图 1-1 为 RIS 承担传统中继角色辅助的无线通信系统^[8]，基站首先获取通信链路的信道信息，根据信道信息计算 RIS 的被动波束赋形预编码矩阵，然后通过控制器调控 RIS 反射单元的相移，使得通过 RIS 反射的信号和基站对用户的直射信号保持相同的相位叠加，从而显著地增强用户所接收的信号。相对于前述的已有 5G 技术，RIS 不需要配置射频链路去主动地接收/发射/处理信号，而是利用自身独特的电磁特性去反射信号，因此 RIS 增强通信系统的能耗较低，主要来源于反射单元的控制电路。此外，RIS 的物理结构基础为电磁超材料，可以由二极管，三极管或光敏器件等相对廉价的电子元件实现，因此 RIS 的硬件成本也低于传统的基站或中继。




图 1-1 RIS 辅助无线通信系统

RIS 能够有效增强通信的关键在于如何设计 RIS 单元的反射系数，然而反射系数的调整又取决于通信链路的信道环境，因此 RIS 通信系统首先需要获得准确的信道信息。由于无源 RIS 没有配备射频链路，不具备信号处理功能，因此信道估计只能在发射机或接收机实现。文献[9]验证了当 RIS 上的电磁单元数较多时，才能优于传统中继的性能，而反射单元数的增加相应的提高了基站-RIS-用户通信链路的级联信道矩阵维度，因此 RIS 辅助的通信系统信道估计比传统通信系统更加困难。针对引入 RIS 至无线通信系统而产生的高维信道估计问题，高效的信道估计算法设计是 RIS 通信的重要基础。

随着人工智能（Artificial Intelligence, AI）技术的发展，AI 与无线通信的融合成为新的研究热点，展现了超越传统通信算法性能的巨大潜力，并且也被视为驱动 B5G（Beyond

5G)/6G 通信网络的关键技术之一^[10,11]。深度学习模型可以从原始数据中提取特征并通过构建一个具有大量可学习参数的网络模型在原始输入数据和期望输出之间构建非线性映射。相较于基于专家知识和数学模型的传统通信算法，深度学习模型对无线信道数据的损坏/缺失具有一定的鲁棒性，并且其能够从数据中学习一种稳定的特征模式，而这些特征模式可以适应环境的变化被新的通信数据所更新。从长远来看，这比传统的基于模型的优化具有更低的计算复杂度。由于具有并行处理能力，基于深度学习的解决方案显著减少了运行时间。而传统优化方法和信号处理算法的并行实现较为麻烦。因此深度学习在无线通信物理层系统设计中相对于基于优化的技术展现出明显优势^[12]。

AI 在 RIS 辅助通信系统中的应用也具有广阔前景，由于 RIS 辅助的 6G 无线网络已经过于复杂，难以单独采用基于传统模型的方法来优化其部署、运营和维护，也很难为 RIS 建立精确和易于处理的模型来解释它们的物理和电磁特性，AI 则为如何最大限度利用 RIS 赋能无线网络的潜力提供了一种有效的方法^[13]。另一方面，部署、编程和控制 RIS 辅助无线网络的计算复杂性随着网络到基础设施和用户到网络交互的增加而显著增加。这需要更高效和按需应变的智能网络来处理复杂的部署规划、实时可编程和动态控制服务供应^[14]。

1.2 研究现状

目前针对 RIS 辅助通信系统的信道估计问题，围绕着不同的设计角度已经大量的相关研究成果^[15]，如图 1-2 所示。

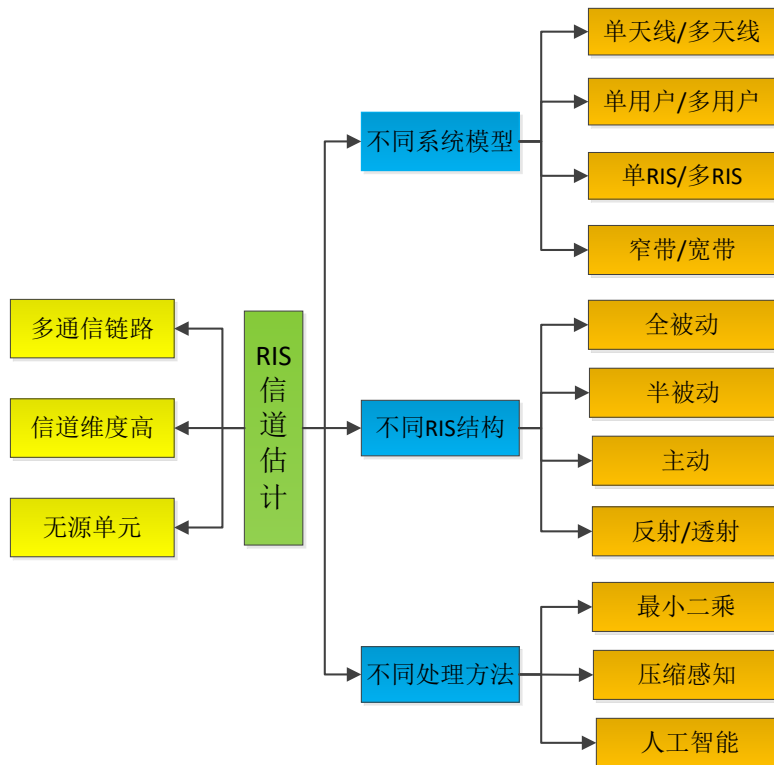


图 1-2 研究现状框图

已有工作考虑了不同的系统模型,如单用户/多用户,单 RIS/多 RIS 和窄带/宽带等等;不同的 RIS 结构,如全被动/半被动/主动;和不同的信号处理方法,如最小二乘(Least Square, LS),压缩感知和机器学习等等。本文将主要从信号处理方法角度概述目前 RIS 辅助通信系统信道估计的研究现状。

1.2.1 经典信道估计

LS 算法作为最经典的信道估计算法之一,因其设计思路简单并且计算复杂度低,已被广泛应用于传统通信系统,该信道估计思路也可以扩展到 RIS 通信系统。文献[16]针对 RIS 通信系统提出了基于 ON/OFF 反射协议的信道估计方法,通过依次打开 RIS 的每个单元,其他反射单元保持关闭状态,利用 LS 估计 RIS 每个单元所对应的级联信道,循环得到完整的级联信道。由于在信道估计阶段的每一个时隙内,只有一个 RIS 单元反射信号,因此信道估计精度较低。针对 ON/OFF 协议的不足,文献[17]提出基于离散傅里叶变换(Discrete Fourier Transform, DFT)的 RIS 反射协议,在每个时隙内 RIS 反射向量被设计为 DFT 矩阵的一个列向量,文献[18]证明对于 LS 算法 DFT 协议可以取得最优的信道估计精度。由于 LS 算法受通信噪声影响大,在低信噪比(Signal to Noise Ratio, SNR)下性能不佳,因此文献[19]提出了基于最小均方误差(Minimum Mean Square Error, MMSE)的最优信道估计方案,然而由于 RIS 通信中的级联信道包括发射机-RIS 和 RIS-接收机两条通信链路,因此其信道分布不遵循高斯分布,MMSE 算法无法给出闭式解,求解时需要已知信号的先验数据分布,实际应用存在困难。文献[20]基于线性最小均方误差(Linear MMSE, LMMSE)算法给出了信道估计的闭式解,由于信道分布不符合高斯分布且在接收端直射信号和反射信号叠加,因此对于级联信道估计和直射信道估计 LMMSE 方案都是次优的。

上述工作都是将发射机-RIS-接收机的反射通信链路作为一体化的级联信道进行估计,文献[21]和文献[22]考虑了发射机-RIS 信道和 RIS-接收机信道的交替估计,利用并行因子(Parallel Factor, PARAFAC)张量模型去展开分解接收的导频信号,并给出了基于 Khatri-Rao 因子分解的闭式解和基于双线性交替 LS 的迭代求解方法。事实上该信道估计思路来源于传统中继辅助的协作通信系统信道估计方法^[23],此时不可避免将存在信道尺度模糊性现象,需要设计额外的归一化因子来消除信道模糊性。

对于上述经典信道估计算法存在一个共同的缺点,就是求解 LS 问题时将受到满秩条件的约束,要求导频时隙数必须大于或等于 RIS 单元数,而如前文所述 RIS 单元数往往需要很大才能满足通信系统要求,因此相应要求的导频开销很大,从而导致降低了通信效率。因此围绕着如何降低导频开销,许多工作提供了不同的设计思路,包括:在 RIS 表面嵌入有源主动单元的半被动信道估计,探索 RIS 信道稀疏性的稀疏信道估计和利用人工智能技术的智能信道估计算法。

1.2.2 半被动信道估计

在早期的 RIS 原型设计中，所有反射单元均采用无源的电磁超材料设计，RIS 后端表面仅安装了简易的控制电路来配置 RIS 相位。然而在后续的研究中，考虑到全被动 RIS 辅助通信系统中信道信息获取难度太大，因此提出了在 RIS 表面上加入主动感知单元专门用于信道估计^[24]，该主动单元配置了射频链路具有信号处理能力，可以接收基站/用户所发射的导频信号来估计信道信息。该信道估计设计思想称之为半被动信道估计，基于该思路衍生了许多相关工作。

文献[25]提出基于到达方向角 (Direction-of-Arrival, DOA) 的 RIS 辅助多用户 Massive MIMO 系统的信道估计算法，通过在 RIS 上配置有限的射频链路，来分别实现基站-RIS 和 RIS-用户两条链路的信道估计。文献[26]考虑 RIS 辅助的太赫兹通信，通过在 RIS 嵌入少量主动感应单元，设计了一种改进的稀疏贝叶斯学习算法来估计信道路径的角度去重构完整信道，并根据信道变化的快慢特征设计一种高效的数据传输策略。为避免多跳信道估计中的信道模糊性，文献[27]将 RIS 辅助的多天线正交频分复用 (Orthogonal Frequency Division Multiplexing, OFDM) 系统中的级联信道问题分解为发射机-RIS 信道估计和 RIS-接收机信道估计两个子问题，通过将训练序列建模为多维的 Canonical Ployadic 分解张量，设计了代数算法去解决该张量补全问题，来恢复信道的多径参数。文献[28]提出一种新的混合 RIS 硬件架构，RIS 反射单元的输出被连接到一个射频链路，通过该射频链路收集到导频信号，然后采用交替优化算法在 RIS 侧实现显式的基带信道估计。

虽然半被动信道估计方式可以有效的降低信道估计复杂度，但是在 RIS 上部署有源器件同时，也要配置缆线或者电源，在一定程度上限制 RIS 的场景应用多样性，与此同时也增加了 RIS 辅助通信系统的能耗。

1.2.3 稀疏信道估计

由于无线信道往往在某个变化域存在稀疏性，因此基于压缩感知的稀疏信道估计思想已经被广泛应用^[29]。实现 RIS 稀疏信道估计的基础则是首先需要寻找到 RIS 信道稀疏表示。考虑到较高频率的大量可用带宽，通信在毫米波甚至太赫兹波段。将是不可避免的趋势，而对于高频段的电磁波则存在天然的稀疏性。如前文所述，毫米波通信的主要障碍包括其对阻塞的敏感性、有限的覆盖范围和严重的路径损耗，RIS 辅助的毫米波通信将有很大潜力将会成为 6G 主流的通信方案之一^[30]，基于压缩感知的 RIS 信道估计方案也被广泛应用于 RIS 辅助的毫米波通信系统。

文献[31]指出由于基站与反射面往往安置在相近高度，电磁波的散射较少，信道径数有限，RIS 辅助的多用户 MIMO 系统级联信道存在共同的行-列块稀疏性，提出了一种交替优化的算法去恢复稀疏信道矩阵。文献[32]针对 RIS 辅助的毫米波 Massive MIMO 系统，并考

虑了宽带中存在多径时延差情况，通过假设基站与 RIS 位置固定，两者之间的信道可以由基站与 RIS 的空间几何关系算出，将级联信道估计转化为只估计 RIS 与用户之间的信道。然后基于毫米波的稀疏特性，使用压缩感知算法进行求解。文献[33]利用 Katri-Rao 和 Kronecker 乘积的性质，推导出级联信道的一种稀疏表示，从而将级联信道估计问题转化为一个稀疏信号恢复问题，大幅度减少了信号开销。文献[34]利用多用户角度域级联信道的共同稀疏性，提出了基于双结构正交匹配追踪(Orthogonal Matching Pursuit, OMP)的信道估计方案。文献[35]利用慢衰落信道分量信息和隐藏信道稀疏性信息，提出了一种基于近似消息传递(Approximate Message Passing, AMP)的级联信道分解算法。文献[36]利用毫米波信道在角度域的低秩特征，提出了一种两阶段信道估计框架，在每个阶段设计了多维的 DOA 估计方案去获得信道参数。文献[37]提出了基于原子范数最小化(Atomic Norm Minimization, ANM)的信道参数估计方案，相较于 OMP 算法，可以获得更高的信道估计精度。文献将[38]信道估计问题转化为一个存在固定秩约束的非凸优化问题，提出了一种基于交替最小化和流形优化的高效算法来推导局部最优解。文献[39]提出了一种两步级联信道估计协议，第一步先估计出粗糙的信道角度域信息去设计鲁棒的上行波束训练，在第二步设计低复杂度的自适应格点匹配算法来估计精确的信道状态信息。

由于并不是所有场景下 RIS 信道都具有稀疏性，如当前移动通信系统普遍采用的低频段，并且压缩感知的计算复杂度较高，能否在实际通信场景下较短的信道相干时间内完成信道估计存在挑战。

1.2.4 智能信道估计

近年来，AI 在无线通信物理层的应用取得了丰富的成果，无论是在局部的通信模块优化，如调制解调，编码解码，信号检测以及波束成形等等，还是在整体通信系统设计，如 OFDM 接收机和端到端通信等等^[10,12,40]。目前 AI 也已被应用于在多种通信场景下的信道估计任务中，如 OFDM, MIMO-OFDM 和毫米波 Massive MIMO 等系统，利用数据驱动的深度机器学习模型来提高信道估计精度和降低导频开销被证明是可行的^[41]。

文献[42]首次将深度学习应用于 RIS 辅助通信系统的信道估计中，首先基于 ON/OFF 的 RIS 反射协议去设计数据集，然后结合卷积层和全连接层构建信道估计网络实现从导频符号到信道矩阵的映射。该作者基于同样的思想在文献[43]提出了一种联邦学习的信道估计框架，网络利用用户本地数据集进行训练，仅需将模型参数传送至基站聚合，相对于文献[42]的集中式学习可以减少巨大的数据传输开销。文献[44]首先使用 LS 算法估计出一个含噪的信道矩阵，然后使用深度残差网络(Residual Network, ResNet)获得去噪后的精确信道矩阵。进一步地，文献[45]将文献[44]的网络替代为更先进的图像去噪网络—残差密集网络(Residual Dense Network, RDN)，提高了信道估计精度。文献[46]采样相似的信道估计思路，设计深度复值降噪网络去改善基于压缩感知的信道估计性能。

借鉴计算机视觉 (Computer Vision, CV) 领域中的超分辨率 (Super-Resolution, SR) 重建网络, 文献[47]首先通过首先打开部分 RIS 单元得到低维级联信道矩阵, 然后应用 SRCNN (Super-Resolution Convolutional Neural Network) 来上采样获得高维级联信道。文献[48]考虑局部的级联信道估计, 如发射机-RIS 信道或 RIS-接收机信道, 通过在 RIS 嵌入部分有源元件来获取初始信道。由于 SRCNN 网络结构比较简单, 使得高维信道复原能力有限, 因此引入基于残差学习的 EDSR (Enhanced Deep Residual SR Network) 模型来改善信道估计性能。文献[49]在基于单元分组的信道估计策略基础上, 设计深度学习模型去消除单元分组策略引起的信道干扰, 并实现从部分信道来外推全信道矩阵。文献[50]考虑了 RIS 增强的高速移动用户通信, 此时由于多普勒频偏的影响, 信道呈现出快时变特性。为了减少导频开销以满足极小的信道相干时间, 设计了级联的时域外推网络和天线域外推网络来估计时变的级联信道。

1.3 论文主要内容

由于 RIS 被动波束赋形依赖信道估计的准确性, 而 RIS 的无源特性和信道的高维特征使其信道估计面临着极大的挑战。受益于基于数据驱动的深度神经网络模型的强大非线性拟合能力, 本文利用深度学习解决 RIS 辅助通信系统的高维信道估计问题去改善信道估计精度并降低所需的导频开销, 主要内容包括:

(1) 考虑到 RIS 通信系统中的级联信道维度较高, 相较于直射信道估计难度更大, 因此已有的工作中主要关注 RIS 通信中的级联信道估计, 往往采用两阶段信道估计策略^[51], 即通过依次关闭和打开 RIS 来实现级联信道与直射信道的分开估计。该方案存在着三个缺点: 首先直射信道的估计误差将会传播至级联信道; 其次, 频繁打开 RIS 会带来额外的控制开销, 事实上在早期的信道估计研究中假设当 RIS 关闭时, 通信信道就可以恢复成原始的直射信道的表述是不严谨的, 因为即使 RIS 关闭时将会成为一个散射体去影响电磁波传播, 文献[52]提出一种可以实现完美吸波的控制电路设计, 这种特殊的配置将会带来一定的控制开销; 最后, 直射信道估计和级联信道估计分别需要独立的信号处理时隙。文献[17,18]提出了基于 DFT 协议的联合信道估计方案, 虽然避免了误差传播, 但是 LS 作为线性算法, 其估计性能是有限的。文献[42]使用两个神经网络去分别估计直射信道和级联信道, 虽然提高了信道估计精度, 但是在一个终端内集成两个网络会带来大量的神经网络训练开销和存储开销, 特别是对于大量的移动设备和物联网设备, 其计算资源和内存资源是有限的。

基于上述不足, 本文提出基于多任务学习 (Multi-task Learning, MTL) 的联合信道估计方案, 通过共享相同的导频信号, 级联信道和直射信道被同时估计, 在整个信道估计阶段, RIS 可以始终保持打开状态, 因此避免了冗余的训练开销和控制开销。与此同时, 引入可学习的多任务损失函数来平衡网络中不同子任务的训练^[53]。考虑到低 SNR 下通信噪声

对信道估计性能的影响,引入深度残差收缩网络(Deep Residual Shrinkage Network, DRSN)实现可学习的软阈值化来提高信道估计精度^[54]。

(2)在第一项工作中采用 MTL 避免了直射信道估计开销,但是并没有降低 RIS 级联信道估计的导频开销,因此在本工作及后续工作则关注低导频开销下的级联信道估计。利用 SR 网络将低维信道直接上采样到高维信道,而避免使用导频估计高维信道,可以有效的减少导频开销。已有工作往往将 SR 网络的上采样操作往往都置于网络的底部(预上采样)或者顶部(后上采样),然后将局部的级联信道矩阵单步上采样到完整信道,如文献[47,55]使用的 SRCNN 在网络输入处进行插值上采样,文献[48,56]使用的 EDSR 在网络的输出部分进行上采样。为了极大限度的降低导频开销,通过导频得到的信道矩阵将会远小于完整的级联信道矩阵,所以 SR 网络的上采样因子将会较大。此时若使用已有工作中的单步上采样方式,将会降低信道重建精度。

为充分利用级联信道在 RIS 上的空间域相关性,本文受基于拉普拉斯金字塔的图像重建启发^[57],提出了基于多尺度监督学习的级联信道渐近式重建方案,并设计了拉普拉斯宽残差网络(Laplacian Wide Residual Network, LapWRes)。LapWRes 包含特征提取分支和信道重建分支的双路架构去分别学习信道的高频和低频信息,其中宽激活残差块被嵌入到 LapWRes 的特征提取分支去增强网络提取深层抽象特征的能力^[58]。不同于已有的单步上采样方式,LapWRes 由多个信道重构块组成,低维的导频信道矩阵按照一定的倍数逐次上采样到完整级联信道,并在每一个上采样阶段都设计损失函数,最后合并为一个多尺度监督损失函数。

(3)由于第二项工作依然沿用已有的基于 SR 的信道估计思想,即意味着信道估计需要分为两步:首先使用较少的导频矩阵去获取一个信道初值,然后将其输入到 SR 网络去获得完整信道。这种两步估计思路也体现在其他基于深度学习的信道估计工作,如文献[43,44]使用残差网络去提高 LS 信道估计精度,文献[45]使用复值去噪网络去提高基于压缩感知的信道估计精度。然而深度学习模型在设计之初被认为是一个完全的端到端模型,区别于传统智能算法需要设计特征工程去人工提取特征。根据目前许多基于深度学习的信道估计的相关工作,通过利用传统算法获得的信道估计初值作为网络输入,确实可以提升信道估计精度并加快网络收敛速度,也被称之为知识驱动^[59]。然而这种方案带来了更多的操作复杂度,对于未来通用的智能通信系统,该模型的在线部署存在难度。与此同时,若初始信道估计误差较大时,将会严重影响后续网络的估计性能。

为解决上述不足,本文进一步提出了基于深度压缩感知的 RIS 级联信道估计方案,该方案不需要去利用传统算法计算信道估计初值。与此同时,考虑到已有神经网络无法自适应不同导频长度,本文利用深度压缩感知思想对输入导频数据进行预处理^[60],使得在固定导频长度训练下的网络,可以应用于不同导频长度的通信场景。考虑到毫米波信道的稀疏性,所提出的网络以编码器-解码器为原型架构,先将输入数据压缩为一个尺寸小但是通道

数大的特征图，再将其重构为级联信道。受语义分割领域的 U 型网络（U-shaped network, U-Net）启发^[61]，利用 U-Net 中的跳跃连接来融合不同尺度特征图的语义信息，实现高精度的信道重构，并在编码器和解码器内部引入残差网络来加深网络的深度设计了 ResU-Net（Residual U-Net）结构^[62]，可以有效提高信道估计精度。

1.4 论文结构安排

论文围绕着 RIS 辅助通信系统中的信道估计问题进行展开，针对 RIS 信道估计的特点并结合深度学习的数据驱动优势，提出了系列的智能信道估计模型。全文分为六章，结构安排如下：

第一章为绪论，首先介绍了下一代无线通信系统所面临的关键性挑战，RIS 有可能成为解决这些挑战的潜在低成本方案，然而 RIS 通信中的信道估计是一个亟待解决的基础性问题。然后从四个方面介绍现有 RIS 通信系统中信道估计的研究进展，引出了深度学习驱动无线信道估计任务的研究动机。最后简要阐述了本文所研究的三项工作和行文结构。

第二章首先介绍了 RIS 辅助毫米波通信的系统模型和信道模型；然后介绍了已有的两种经典信道估计方案—LS 算法和压缩感知算法，并简要分析了两种方案各自所存在的不足；最后介绍了智能信道估计的基本研究思路和设计方法，以及几种常用于无线信道估计的深度神经网络模型。

第三章针对已有深度学习模型将直射信道和级联信道分开考虑，产生了冗余的计算复杂度并占用了额外的存储资源的缺点，提出了基于 MTL 的联合信道估计方案，其中不再需要为直射信道估计分配额外的导频。MTL 在保证 RIS 信道估计准确度的前提下，降低了深度学习模型的训练开销和存储开销。与此同时，介绍了基于注意力机制的 DRSN 结构，并将其引入至所设计的多任务网络中。

第四章针对级联信道估计导频开销过大问题，改进了已有基于 SR 的信道估计模型，提出了基于多尺度监督学习的级联信道重构网络。采用渐近式重建思想，设计以宽残差激活块为基本单元的 LapWRes 模型，相对于已有的单步重建网络，可以取得更高的信道估计精度和网络收敛速度。

第五章针对第四章工作需要人工计算信道初值作为网络输入的不足，提出了一种基于 ResU-Net 的级联信道估计模型，该模型通过对导频数据进行简单的预处理，便可以使网络在测试阶段兼容不同导频长度，而不需要修改网络输入层来适应不同的导频长度所引起的输入数据维度变化。与此同时，相较于传统数学模型，ResU-Net 对于 RIS 反射单元的相位量化误差具有更好的鲁棒性。

第2章 智能超表面通信信道估计基础

2.1 智能超表面辅助通信系统

考虑一个 RIS 辅助的多用户上行毫米波通信系统，图 2-1 为通信环境的 3 维几何模型。假设基站位于 yz 平面，RIS 位于 xz 平面， K 个单天线用户随机分布于 xyz 几何空间。基站和 RIS 分别配备 M 根天线和 N 个反射单元，并且天线和反射单元排列方式均为均匀平面阵列（Uniform Planar Array, UPA），即 $M = M_1 \times M_2$ ， $N = N_1 \times N_2$ 。为建模一个真实且动态的通信环境并根据毫米波的传播特性，假设每条通信链路存在随机数量的散射体，而多个散射体又组成为随机的簇^[63]，令 (c, s) ($1 \leq c \leq C, 1 \leq s \leq S$) 表示第 c 个簇中的第 s 个散射体，每条信道都包含视距（Line of Sight, LoS）分量和非视距（Non-LoS, NLoS）分量。

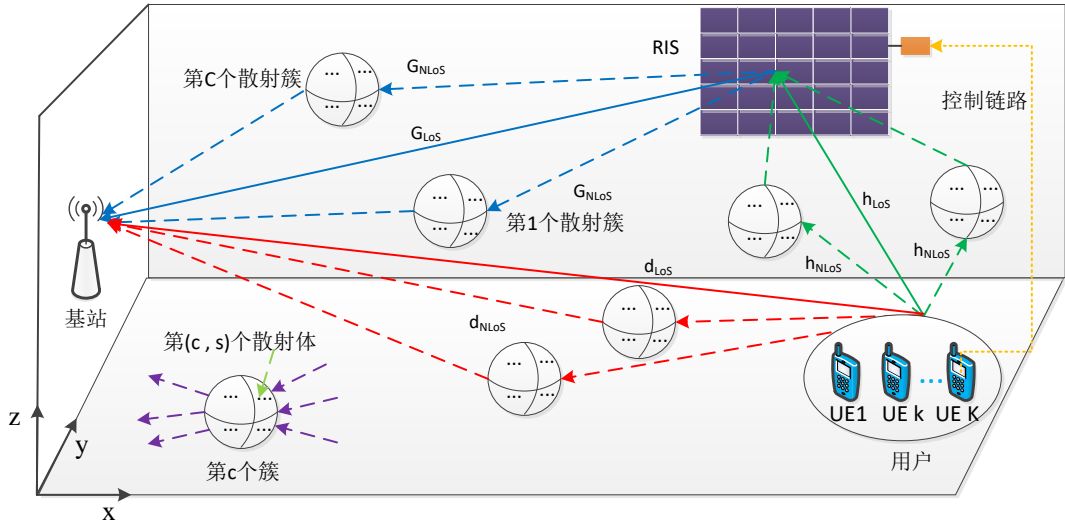


图 2-1 RIS 辅助的多用户毫米波通信系统

2.1.1 信道模型

遵循第三代合作伙伴计划（The 3rd Generation Partnership Project, 3GPP）协议标准^[64]，采用分簇统计 MIMO 信道模型来建模 RIS 辅助的毫米波通信系统^[65]。假设 \bar{C} ， \tilde{C} 和 \hat{C} 分别表示 RIS-基站，用户-RIS 和用户-基站通信链路中散射簇的数量； \bar{S}_c ， \tilde{S}_c 和 \hat{S}_c 分别表示第 c 个簇的散射径数。 $\mathbf{G} \in \mathbb{C}^{M \times N}$ ， $\mathbf{h} \in \mathbb{C}^{N \times 1}$ 和 $\mathbf{d} \in \mathbb{C}^{N \times 1}$ 分别表示 RIS-基站，用户-RIS 和用户-基站信道。信道 $\mathbf{G} = \mathbf{G}_{\text{LoS}} + \mathbf{G}_{\text{NLoS}}$ 中的 NLoS 分量 \mathbf{G}_{NLoS} 可以表示为：

$$\mathbf{G}_{\text{NLoS}} = \bar{\gamma} \sum_{c=1}^{\bar{C}} \sum_{s=1}^{\bar{S}_c} \bar{\beta}_{c,s} \sqrt{r_e(\alpha_{c,s}^{G_t})} \mathbf{L}_{c,s}^{G_r} \mathbf{a}_1(\phi_{c,s}^{G_r}, \alpha_{c,s}^{G_r}) \mathbf{a}_2^T(\phi_{c,s}^{G_t}, \alpha_{c,s}^{G_t}) \quad (2-1)$$

其中, $(\bullet)^T$ 表示矩阵转置, $\bar{\gamma} = \sqrt{1/\sum_{c=1}^{\bar{C}} \bar{S}_c}$ 为分簇信道模型中的归一化因子^[64], $\bar{\beta}_{c,s} \sim \mathcal{CN}(0,1)$ 服从复高斯分布, 表示第 (c, s) 个散射路径的复数路径增益。 $r_e(\alpha_{c,s}^{G_i})$ 为 RIS 单元的辐射方向图

$$r_e(\alpha_{c,s}^{G_i}) = 2(2q+1)\cos^{2q}(\alpha_{c,s}^{G_i}) \quad (2-2)$$

其中, 采用反射阵列天线设计中常用的 $\cos q$ 模式来建模 RIS 单元辐射^[66], q 决定了单元的增益。

采用 5G 路径损耗模型去建模 $L_{c,s}^{G_r}$ ^[67], 其普遍适用于各种通信环境, 如城区微蜂窝 (Urban Microcellular, UMi) 和室内热点 (Indoor Hotspot, InH) 场景。

$$L_{c,s} = -20\log_{10}\left(\frac{4\pi}{\lambda}\right) - 10n\left(1+b\left(\frac{f-f_0}{f_0}\right)\right)\log_{10}(d_{c,s}) - X_\sigma \quad (2-3)$$

其中, $d_{c,s}$ 为第 (c, s) 条散射路径的总长度^[65], n 为路径损耗指数, b 为系统参数, f_0 为固定的参考频率 (路径损耗模型中所有频率的质心)。 $X_\sigma \sim \mathcal{N}(0, \sigma^2)$ 为阴影衰落因子^[68]。

$\phi_{c,s}^{G_r}(\alpha_{c,s}^{G_r})$ 和 $\phi_{c,s}^{G_i}(\alpha_{c,s}^{G_i})$ 分别代表 (c, s) 路径在基站的到达方位角 (仰角) 和 RIS 的离开方位角 (仰角)。对于给定的参考簇 c , 其离开方位角 $\phi_{c,s}^{G_i}(s=1, \dots, \bar{S}_c)$ 被假设遵循拉普拉斯分布 $\phi_{c,s}^{G_i} \sim \mathcal{L}(\phi_c^{G_i}, \sigma_\phi)$, 其中 $\phi_c^{G_i} \sim \mathcal{U}[-\pi/2, \pi/2]$ 服从角度在 $[-\pi/2, \pi/2]$ 范围内的均匀分布^[69], 角度扩展被设为 $\sigma_\phi = 5^\circ$ ^[70]。相似的, 离开仰角 $\alpha_{c,s}^{G_i}(s=1, \dots, \bar{S}_c)$ 被假设遵循条件拉普拉斯分布 $\alpha_{c,s}^{G_i} \sim \mathcal{L}(\alpha_c^{G_i}, \sigma_\alpha)$, 其中 $\alpha_c^{G_i} \sim \mathcal{U}[-\pi/4, \pi/4]$ ^[65], 角度扩展 $\sigma_\alpha = 5^\circ$ 。 $\mathbf{a}(\phi, \alpha)$ 表示天线阵列的 UPA 响应^[71]

$$\mathbf{a}(\phi, \alpha) = \left[1 \dots e^{j2\pi d(x\sin\alpha + y\sin\phi\cos\alpha)/\lambda} \dots e^{j2\pi d((n_1-1)\sin\alpha + (n_2-1)\sin\phi\cos\alpha)/\lambda} \right] \quad (2-4)$$

其中, $0 \leq x \leq n_1 - 1$, $0 \leq y \leq n_2 - 1$ 。 λ 表示载波波长, d 表示天线间距, 一般取 $\lambda/2$ 。对于基站天线, $n_1 = M_1$, $n_2 = M_2$; 对于 RIS 反射单元, 则 $n_1 = N_1$, $n_2 = N_2$ 。

采用泊松分布去建模簇的数量 $C(\bar{C}, \tilde{C}, \hat{C}) \sim \max\{P(\lambda_p), 1\}$ ^[63], 其中 λ_p 根据通信频段确定, 对于目前广泛使用的毫米波频段 28 GHz 和 73 GHz, λ_p 分别取 1.8 和 1.9。每个簇的散射数量服从 1~30 的均匀分布^[72], 即 $S_c(\bar{S}_c, \tilde{S}_c, \hat{S}_c) \sim \mathcal{U}[1, 30]$ 。

相似的, RIS-基站信道中的 LoS 分量 \mathbf{G}_{LoS} 可以表示为

$$\mathbf{G}_{\text{LoS}} = \sqrt{r_e(\alpha_{\text{LoS}}^{G_i})} L_{\text{LoS}}^{G_r} e^{j\eta} \mathbf{a}_1(\phi_{\text{LoS}}^{G_r}, \alpha_{\text{LoS}}^{G_r}) \mathbf{a}_2^T(\phi_{\text{LoS}}^{G_i}, \alpha_{\text{LoS}}^{G_i}) \quad (2-5)$$

其中, $r_e(\alpha_{\text{LoS}}^{G_i}) = 2(2q+1)\cos^{2q}(\alpha_{\text{LoS}}^{G_i})$ 为 RIS 单元的辐射方向图。 $L_{\text{LoS}}^{G_r}$ 和表示第 (c, s) 条散射径的路径损耗。 $\phi_{\text{LoS}}^{G_r}(\alpha_{\text{LoS}}^{G_r})$ 和 $\phi_{\text{LoS}}^{G_i}(\alpha_{\text{LoS}}^{G_i})$ 分别代表 (c, s) 路径在基站的到达方位角 (仰角) 和 RIS 的离开方位角 (仰角)。 η 表示随机的相位因子服从均匀分布 $\mathcal{U}[0, \pi/2]$ 。

用户 k -RIS 信道 \mathbf{h}_k 可以表示为

$$\begin{aligned}
\mathbf{h}_k = & \underbrace{\sqrt{r_e(\boldsymbol{\alpha}_{\text{LoS}}^{r,k}) L_{\text{LoS}}^{r,k}} e^{j\eta} \mathbf{a}(\phi_{\text{LoS}}^{r,k}, \alpha_{\text{LoS}}^{r,k}) \mathbf{a}_2^T(\phi_{\text{LoS}}^{r,k}, \alpha_{\text{LoS}}^{r,k})}_{\mathbf{h}_{k,\text{LoS}}} \\
& + \underbrace{\tilde{\gamma} \sum_{c=1}^{\tilde{C}} \sum_{s=1}^{\tilde{S}_c} \tilde{\beta}_{c,s} \sqrt{r_e(\boldsymbol{\alpha}_{c,s}^{r,k}) L_{c,s}^{r,k}} \mathbf{a}(\phi_{c,s}^{r,k}, \theta_{c,s}^{r,k}) \mathbf{a}_2^T(\phi_{c,s}^{r,k}, \alpha_{c,s}^{r,k})}_{\mathbf{h}_{k,\text{NLoS}}}
\end{aligned} \quad (2-6)$$

其中, $\tilde{\gamma} = \sqrt{1/\sum_{c=1}^{\tilde{C}} \tilde{S}_c}$, $\tilde{\beta}_{c,s} \sim \mathcal{CN}(0,1)$, $r_e(\boldsymbol{\alpha}^{r,k}) = 2(2q+1)\cos^{2q}(\alpha^{r,k})$ 。 $L_{\text{LoS}}^{r,k}$ 和 $L_{c,s}^{r,k}$ 分别表示第 k 个用户到 RIS 的第 (c,s) 条散射径和 LoS 路径的路径损耗。 $\eta \sim \mathcal{U}[0, \pi/2]$, $\phi_{c,s}^{r,k}(\alpha_{c,s}^{r,k})$ 代表 (c,s) 路径 RIS 的到达方位角 (仰角), $\phi_{\text{LoS}}^{r,k}(\alpha_{\text{LoS}}^{r,k})$ 代表 LoS 路径 RIS 的到达方位角 (仰角)。

用户 k -基站的直射信道 \mathbf{d}_k 为

$$\begin{aligned}
\mathbf{d}_k = & \underbrace{\sqrt{L_{\text{LoS}}^{d,k}} e^{j\eta} \mathbf{a}(\phi_{\text{LoS}}^{d,k}, \alpha_{\text{LoS}}^{d,k}) \mathbf{a}_2^T(\phi_{\text{LoS}}^{d,k}, \alpha_{\text{LoS}}^{d,k})}_{\mathbf{d}_{k,\text{LoS}}} \\
& + \underbrace{\tilde{\gamma} \sum_{c=1}^{\tilde{C}} \sum_{s=1}^{\tilde{S}_c} \tilde{\beta}_{c,s} \sqrt{L_{c,s}^{d,k}} \mathbf{a}(\phi_{c,s}^{d,k}, \theta_{c,s}^{d,k}) \mathbf{a}_2^T(\phi_{c,s}^{d,k}, \alpha_{c,s}^{d,k})}_{\mathbf{d}_{k,\text{NLoS}}}
\end{aligned} \quad (2-7)$$

其中, $\tilde{\gamma} = \sqrt{1/\sum_{c=1}^{\tilde{C}} \tilde{S}_c}$, $\tilde{\beta}_{c,s} \sim \mathcal{CN}(0,1)$, $\eta \sim \mathcal{U}[0, \pi/2]$ 服从均匀分布。 $L_{\text{LoS}}^{d,k}$ 和 $L_{c,s}^{d,k}$ 分别表示 (c,s) 路径和 LoS 路径的路径损耗。 $\phi_{c,s}^{d,k}(\alpha_{c,s}^{d,k})$ 代表 (c,s) 路径基站的到达方位角 (仰角)。 $\phi_{\text{LoS}}^{d,k}(\alpha_{\text{LoS}}^{d,k})$ 代表 LoS 路径基站的到达方位角 (仰角)。

2.1.2 信号模型

令 $\boldsymbol{\theta} = [\beta_1 e^{j\theta_1}, \beta_2 e^{j\theta_2}, \dots, \beta_N e^{j\theta_N}]^T \in \mathbb{C}^{N \times 1}$ 表示 RIS 的反射向量, 其中 β_n 和 θ_n ($n=1, 2, \dots, N$) 分别表示 RIS 第 n 个单元的反射幅度和相位。 本文仅考虑调整相位的被动 RIS, 因此 $\beta_n \in \{0, 1\}$ 仅控制 RIS 单元的打开和关闭, 而 $\theta_n \in [0, 2\pi]$ 控制施加于入射电磁波的相移。 由于实际硬件的限制, 难以实现控制 RIS 实现完美的打开 (ON) 和关闭 (OFF), 因此 β_n 被建模为^[17]

$$\beta_n = \begin{cases} 1 - \epsilon_1 & \text{ON} \\ 0 + \epsilon_0 & \text{OFF} \end{cases} \quad (2-8)$$

其中, $\epsilon_1, \epsilon_0 \geq 0$ 表示控制 ON/OFF 模式下的真实误差。 相似的, RIS 相移 θ_n 也存在控制误差, 如相位量化误差, 在后续章节中将分析其对信道估计的影响。

假设用户传输 T 个导频符号用于信道估计, 基站在 $t(1 \leq t \leq T)$ 时刻对于第 $k(1 \leq k \leq K)$ 个用户的接收信号可以表示为

$$\mathbf{y}_{t,k} = (\mathbf{G} \text{diag}(\boldsymbol{\theta}_{t,k}) \mathbf{h}_k + \mathbf{d}_k) s_{t,k} + \mathbf{w}_{t,k} = (\mathbf{G} \text{diag}(\mathbf{h}_k) \boldsymbol{\theta}_{t,k} + \mathbf{d}_k) s_{t,k} + \mathbf{w}_{t,k} \quad (2-9)$$

其中， $\text{diag}(\cdot)$ 表示向量对角化或者对角矩阵向量化， $\Theta_{t,k} = \text{diag}(\theta_{t,k})$ 。 $s_{t,k}$ 表示第 k 个用户发送的导频信号， $\mathbf{w}_{t,k} \sim \mathcal{CN}(0, \sigma^2)$ 表示加性高斯白噪声。由于 RIS 是无源的，信道 \mathbf{G} 和信道 \mathbf{h} 不能在 RIS 处分开估计，只能在用户或者基站侧估计。令 $\mathbf{H}_k = \mathbf{G}\text{diag}(\mathbf{h}_k)$ 表示第 k 个用户信号经过 RIS 反射到基站的级联信道，则 $\mathbf{y}_{t,k} = (\mathbf{H}_k \theta_{t,k} + \mathbf{d}_k) s_{t,k} + \mathbf{w}_{t,k}$ 。

2.2 传统信道估计方案

2.2.1 基于最小二乘的信道估计方案

当不同用户采用正交导频传输策略时^[19,22,31]，单用户信道估计可以简单的扩展到多用户，因此本节以单用户为例阐述已有的 RIS 信道估计思路。首先定义相关符号如下：

$$\Phi = \begin{bmatrix} 1 & \theta_{1,1} & \cdots & \theta_{1,K} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \theta_{T,1} & \cdots & \theta_{T,K} \end{bmatrix} \in \mathbb{C}^{T \times (N+1)}, \quad \mathbf{Y} = \begin{bmatrix} \mathbf{y}_1 \\ \vdots \\ \mathbf{y}_T \end{bmatrix}, \quad \mathbf{W} = \begin{bmatrix} \mathbf{w}_1 \\ \vdots \\ \mathbf{w}_T \end{bmatrix}, \quad \mathbf{Z} = \begin{bmatrix} \mathbf{d} \\ \mathbf{v}_1 \\ \vdots \\ \mathbf{v}_N \end{bmatrix} \quad (2-10)$$

其中 $\mathbf{v}_n = \mathbf{H}_{1:M,n} \in \mathbb{C}^M$ ，即 $\mathbf{H} = [\mathbf{v}_1, \cdots, \mathbf{v}_n, \cdots, \mathbf{v}_N]$ 。

结合 (2-9) 与 (2-10) 可以得到

$$\begin{aligned} \begin{bmatrix} \mathbf{y}_1 \\ \vdots \\ \mathbf{y}_T \end{bmatrix} &= \begin{bmatrix} s_1 [\mathbf{I}_M, \theta_{1,1} \mathbf{I}_M, \cdots, \theta_{1,N} \mathbf{I}_M] \\ \vdots \\ s_T [\mathbf{I}_M, \theta_{T,1} \mathbf{I}_M, \cdots, \theta_{T,N} \mathbf{I}_M] \end{bmatrix} \begin{bmatrix} \mathbf{d} \\ \mathbf{v}_1 \\ \vdots \\ \mathbf{v}_N \end{bmatrix} + \begin{bmatrix} \mathbf{n}_1 \\ \vdots \\ \mathbf{n}_T \end{bmatrix} \\ &= \text{diag}([s_1 \mathbf{1}_M, \cdots, s_T \mathbf{1}_M]) (\Phi \otimes \mathbf{I}_M) \mathbf{Z} + \mathbf{N} \end{aligned} \quad (2-11)$$

其中， \mathbf{I}_M 表示 $M \times M$ 单位矩阵， $\mathbf{1}_M$ 表示 M 维全 1 向量。

令 $\mathbf{X} = \text{diag}([s_1 \mathbf{1}_M, \cdots, s_T \mathbf{1}_M])$ ； $\Psi = \Phi \otimes \mathbf{I}_M$ ， \otimes 表示克罗内克积； $\mathbf{F} = \mathbf{X}\Psi$ ；将式 (2-11) 转化为一个线性测量模型

$$\mathbf{Y} = \begin{bmatrix} \mathbf{y}_1 \\ \vdots \\ \mathbf{y}_T \end{bmatrix} = \mathbf{X}\Psi\mathbf{Z} + \mathbf{N} = \mathbf{F}\mathbf{Z} + \mathbf{W} \quad (2-12)$$

根据古典线性回归模型假设，线性 LS 估计器为待求的信道信息 \mathbf{Z} 的最小无偏方差估计器[18]，即

$$\hat{\mathbf{Z}} = \text{argmin} \|\mathbf{F}\mathbf{Z} - \mathbf{Y}\|_2^2 = (\mathbf{F}^H \mathbf{F})^{-1} \mathbf{F}^H \mathbf{Y} \quad (2-13)$$

其中， $(\cdot)^{-1}$ 表示矩阵求逆。

MVU 估计器的协方差为

$$C_{\hat{z}} = \sigma^2 (\mathbf{F}^H \mathbf{F})^{-1} \quad (2-14)$$

对于线性测量模型 (2-12)，MVU 估计器可以高效获得更低的克拉美罗界 (Cramér-Rao Bound, CRB)。根据式 (2-14)，其协方差矩阵不取决于未知信道信息 \mathbf{Z} ，也不取决于期待信号 \mathbf{FZ} 的强度和相位，只取决于系统矩阵 \mathbf{F} 和噪声方差 σ^2 。因此 RIS 的反射向量设计，对于信道估计具有重要影响。目前常用的 RIS 反射协议有 ON/OFF 协议和 DFT 协议。

对于 ON/OFF 协议，RIS 反射单元仅存在打开和关闭两种状态，即反射系数 $\theta_{t,n} \in \{0, 1\}$ ($t=1, 2, \dots, T; n=1, 2, \dots, N$)。首先将 RIS 全部关闭，估计直射信道，此时接收信号为 $\mathbf{y}_t^d = \mathbf{d}s_t + \mathbf{w}_t$ 。假设 $T_d = 1$ 个导频用于直射信道估计，则 LS 估计的直射信道为 $\hat{\mathbf{d}} = \mathbf{y}^d s^{-1}$ 。假设 T_c 个导频用于级联信道估计，通过依次打开单个 RIS 单元，保持其他单元关闭，重复 N 次估计出 N 个反射单元所对应的级联信道。在第 t 个时隙，RIS 反射系数可以表示为 $\boldsymbol{\theta}_t = [0, \dots, 0, \theta_{n=t} = 1, 0, \dots, 0]$ ，则接收信号为

$$\mathbf{y}_t = (\mathbf{H}\boldsymbol{\theta}_t + \mathbf{d})s_t + \mathbf{w}_t = (\mathbf{v}_t + \mathbf{d})s_t + \mathbf{w}_t \quad (2-15)$$

采用 LS 算法得到级联信道 \mathbf{H} 的第 n 列

$$\mathbf{v}_n = \mathbf{y}_t s_t^{-1} - \hat{\mathbf{d}} \quad (2-16)$$

重复 N 次的相同计算方法后，则可以得到最终得信道估计值 $\hat{\mathbf{H}}$ ，整个信道估计过程的计算复杂度为 $O(MT)$ 。根据文献 [18] 的推导，ON/OFF 协议的 MVU 估计方差为

$$\begin{aligned} C_{\hat{z}} &= \sigma^2 \left((\boldsymbol{\Theta} \otimes \mathbf{I}_M)^H \mathbf{X}^H \mathbf{X} (\boldsymbol{\Theta} \otimes \mathbf{I}_M) \right)^{-1} = \sigma^2 \left((\boldsymbol{\Theta}^H \boldsymbol{\Theta} \otimes \mathbf{I}_M) \right)^{-1} \\ &= \sigma^2 (\boldsymbol{\Theta}^H \boldsymbol{\Theta})^{-1} \otimes \mathbf{I}_M = \sigma^2 \begin{bmatrix} 1 & -\mathbf{1}_N^T \\ -\mathbf{1}_N & \mathbf{E}_N + \mathbf{I}_N \end{bmatrix} \otimes \mathbf{I}_M \end{aligned} \quad (2-17)$$

其中， $(\cdot)^H$ 表示矩阵的共轭转置， \mathbf{E}_N 表示 $N \times N$ 全 1 矩阵， $\boldsymbol{\Theta} = \begin{bmatrix} 1 & \mathbf{0}_N^T \\ \mathbf{1}_N & \mathbf{I}_N \end{bmatrix}$ 。根据式 (2-17)

可以看到 MVU 估计方差与 RIS 单元数有关，而每个单元的估计方差为

$$\text{var} \left(\begin{bmatrix} \hat{\mathbf{d}} \\ \hat{\mathbf{v}}_n \end{bmatrix}_m \right) = \sigma^2, \quad \text{var} \left(\begin{bmatrix} \hat{\mathbf{v}}_n \end{bmatrix}_m \right) = 2\sigma^2 \quad (2-18)$$

由于 ON/OFF 协议在一个时隙内，只有一个 RIS 单元反射信号，而每个单元的信道估计方差等价于 σ^2 ，因此其估计方差将会累加。与此同时，根据式 (2-16)，直射信道估计误差也会传播到级联信道估计。

对于 DFT 协议，RIS 反射系数为一个 DFT 矩阵，令 $[\mathbf{F}_{T,T}]_{t,n} = e^{-j2\pi(t-1)(n-1)/T}$ 表示 $T \times T$ 的 DFT 矩阵，则 $\boldsymbol{\Theta} = \mathbf{F}_{T,N+1}$ 满足 $\boldsymbol{\Theta}^H \boldsymbol{\Theta} = \mathbf{F}_{T,N+1}^H \mathbf{F}_{T,N+1} = \mathbf{I}_{N+1}$ ，则 $\boldsymbol{\Theta}$ 为 \mathbf{F} 的前 $N+1$ 列。此时的 MVU 估计方差为 [18]

$$C_{\hat{z}} = \sigma^2 (\Theta^H \Theta)^{-1} \otimes \mathbf{I}_M = \sigma^2 (\mathbf{F}_{T,N+1}^H \mathbf{F}_{T,N+1})^{-1} \otimes \mathbf{I}_M = \frac{\sigma^2}{T} \mathbf{I}_{M(N+1)} \quad (2-19)$$

相应的每个单元的估计方差为

$$\text{var}\left(\left[\hat{\mathbf{d}}\right]_m\right) = \text{var}\left(\left[\hat{\mathbf{v}}_n\right]_m\right) = \sigma^2 / T \quad (2-20)$$

显然DFT协议的估计误差明显低于ON/OFF协议，并且文献[18]已经证明DFT协议为MVU估计器的最优估计方案。此时信道 \mathbf{Z} 的LS解可以表示为

$$\hat{\mathbf{Z}} = (\mathbf{F}^H \mathbf{F})^{-1} \mathbf{F}^H \mathbf{Y} = \frac{1}{T} (\Theta \otimes \mathbf{I}_M)^H \mathbf{X}^H \mathbf{Y} = \frac{1}{T} \text{vec}\left(\text{mat}\left(\text{diag}(\mathbf{X}^*) \odot \mathbf{Y}\right) \mathbf{F}_{T,K+1}^*\right) \quad (2-21)$$

其中， $\text{mat}(\cdot)$ 表示 $MN \times 1$ 向量转 $M \times N$ 矩阵， \odot 表示哈达玛积， $\text{vec}(\cdot)$ 表示矩阵向量化。

由于引入了DFT，该信道估计的计算复杂度为 $O(MT \log T)$ 。令 $\hat{\mathbf{Z}} = \mathbf{Z} + \mathbf{W}$ ， $\mathbf{W} \sim \mathcal{CN}\left(0, \sigma^2 (\mathbf{F}^H \mathbf{F})^{-1}\right)$ 表示其估计误差。DFT协议下信道估计的均方误差为^[20]

$$MSE_{\hat{z}} = \frac{M(N+1)}{T_p} \sigma^2 \quad (2-22)$$

虽然上述方案证明了将RIS反射系数设计成DFT矩阵可以获得更高的估计精度，然而由于通信噪声的存在，LS信道估计器本身为次优的，作为一种线性算法，其性能上限是有限的。因此传统通信领域一些改进的LS算法也被相关工作引入，例如利用信道统计特征和噪声方差的LMMSE算法，此时求解的信道可以表示为

$$\hat{\mathbf{Z}}_{\text{lmmse}} = \mathbf{C}_{zz} \mathbf{F}^H (\mathbf{F} \mathbf{C}_{zz} \mathbf{F}^H + \sigma^2 \mathbf{I}_{MT})^{-1} \mathbf{Y} \quad (2-23)$$

其中， $\mathbf{C}_{zz} = \mathbf{E}[\mathbf{Z}\mathbf{Z}^H]$ ， $\mathbf{E}[\cdot]$ 表示数据期望值。

然而，由于RIS辅助通信系统中的级联信道由两部分信道乘积构成，与此同时基站的接收信号由直射信号和反射信号两部分叠加，导致信道与信号均不属于高斯分布，因此LMMSE算法的性能与理想的MMSE估计仍存在差距。需要注意的是，对于LS算法成立的条件为 Θ 应存在伪逆，因此要求 $T = T_c + T_d \geq N + 1$ 。如前文所述，对于无源的RIS，其需要配置大量的反射单元，才能实现与传统中继相当的增强通信性能，即 N 非常大，因此LS算法将要求大量的导频开销。在有限的信道相干时间内，LS算法难以满足信道估计的实时性要求并且降低了数据传输效率。

2.2.2 基于压缩感知的信道估计方案

通过挖掘无线信道的内在稀疏性，压缩感知被广泛应用信道估计，特别是对于高频通信，如毫米波和太赫兹^[73]，其稀疏性是天然形成的。首先，由于毫米波频率高，在传输过程中更高的频率意味着更高的路径损耗，通信环境中的障碍物会大幅降低毫米波通信传输的能量，因此其散射是有限的，表现出明显LoS传播。毫米波信道矩阵中只有LoS信道和有限的几条路径存在能量，即其在信道矩阵中的单元值较大，而其余单元位置几乎为零。

其次，对于 RIS 辅助的毫米波通信系统，RIS 需要被部署在较高的建筑物上去实现大范围的通信覆盖，并且基站本身也被建设在高塔上，此时基站和 RIS 附近只存在少量的散射体，因此 RIS-基站和用户-RIS 的通信链路中只有少数有效的到达角和离开角路径，即级联信道矩阵 \mathbf{H} 只在少数列/行向量中具有非零元素，这种稀疏结构不同于传统的 Massive MIMO 通信系统的行稀疏或者列稀疏，而是呈现出行-列块稀疏性^[31]。

假设经过 T_c 个导频传输且每个导频符号 $s_t = 1$ ，将式 (2-9) 写成矩阵形式，基站的接收信号可以表示为

$$\mathbf{Y} = \mathbf{H}\boldsymbol{\Theta} + \mathbf{W} \quad (2-24)$$

其中， $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{T_c}] \in \mathbb{C}^{M \times T_c}$ ， $\boldsymbol{\Theta} = [\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots, \boldsymbol{\theta}_{T_c}] \in \mathbb{C}^{N \times T_c}$ ， $\mathbf{W} = [\mathbf{n}_1, \mathbf{n}_2, \dots, \mathbf{n}_{T_c}] \in \mathbb{C}^{M \times T_c}$ 。

当 $T_c < N$ 时，式 (2-24) 为欠定方程，若直接采用 LS 算法则存在不唯一解，无法正常求解级联信道 $\hat{\mathbf{H}}$ 。如果级联信道 \mathbf{H} 在某个变化域 ϕ 是 k 稀疏的，即 $\tilde{\mathbf{H}} = \phi\mathbf{H}$ 只有 $k(k \ll M \times N)$ 个非零值。此时， \mathbf{H} 可以由测量值 \mathbf{Y} 通过求解最优的零范数或 1 范数问题精确重构^[74]

$$\min_{\tilde{\mathbf{H}}} \|\tilde{\mathbf{H}}\|_p \quad s.t. \quad \|\mathbf{Y} - \phi\tilde{\mathbf{H}}\boldsymbol{\Theta}\|_p \leq \xi \quad (2-25)$$

其中， $\|\cdot\|_p$ 表示 p 范数， ξ 限制了数据中的噪声量， p 被设置为 0 或 1 去刻画的 $\tilde{\mathbf{H}}$ 的稀疏性。

文献[51]提出对于 RIS 辅助的通信系统的级联信道在角度域具有明显稀疏性。通过使用虚拟角度域表征， \mathbf{H} 能够被表示为

$$\mathbf{H} = \mathbf{U}_M \tilde{\mathbf{H}} \mathbf{U}_N^T \quad (2-26)$$

其中， $\tilde{\mathbf{H}} \in \mathbb{C}^{M \times N}$ 表示角度域级联信道， $\mathbf{U}_M \in \mathbb{C}^{M \times M}$ 和 $\mathbf{U}_N^T \in \mathbb{C}^{N \times N}$ 分别表示基站和 RIS 的字典矩阵。

将式 (2-26) 代入式 (2-24) 得 $\mathbf{Y} = \mathbf{U}_M \tilde{\mathbf{H}} \mathbf{U}_N^T \boldsymbol{\Theta} + \mathbf{N}$ 。令 $\tilde{\mathbf{Y}} = (\mathbf{U}_M^H \mathbf{Y})^H \in \mathbb{C}^{T_c \times M}$ ， $\tilde{\mathbf{W}}_k = (\mathbf{U}_M^H \mathbf{W}_k)^H \in \mathbb{C}^{T_c \times M}$ 和 $\tilde{\boldsymbol{\Theta}} = (\mathbf{U}_N^T \boldsymbol{\Theta})^H \in \mathbb{C}^{T_c \times N}$ 分别作为观测矩阵，噪声矩阵和传感矩阵，则式 (2-24) 可以改写为经典的压缩感知模型

$$\tilde{\mathbf{Y}} = \tilde{\boldsymbol{\Theta}} \tilde{\mathbf{H}} + \tilde{\mathbf{W}} \quad (2-28)$$

当构建完压缩感知模型后，目前常用匹配追踪^[31-34]，消息传递^[35]和原子范数^[37]来从观测信号中恢复稀疏信道 $\tilde{\mathbf{H}}$ 。以经典的 OMP 算法为例^[75]，阐述式 (2-28) 的稀疏信道 $\tilde{\mathbf{H}}$ 求解过程，如表 2-1 所示，需要注意的是如前所述 RIS 通信中的级联信道稀疏性具有明显块分布特征，因此单纯的移植 OMP 算法会存在明显的性能损失^[31,33,34]。

压缩感知算法可以大幅度减少信道估计的导频开销，即 $T \ll N$ ，然而由于采用迭代贪婪方法去逼近求解，压缩感知算法的计算复杂度较高，难以用于实时信道估计。此外，文献[76]认为目前还没有一种理论可以确切的证明压缩感知模型能得到信道最稀疏的表征，特别是对于一些复杂的通信场景，其稀疏度是未知的并且动态的，此时基于压缩感知的信道

估计性能是不稳定的。

表 2-1 基于 OMP 的稀疏信道重构

输入：观测矩阵 $\tilde{\mathbf{Y}}$ ，传感矩阵 $\tilde{\mathbf{\Theta}}$ 和稀疏度 k

输出：估计的稀疏级联信道 $\hat{\mathbf{H}}$ ，真实值与估计值的残差 \mathbf{R}

1: 参数初始化:

$\mathbf{R}_0 = \tilde{\mathbf{Y}}$ ，迭代次数 $i=1$ ，支撑集合 $\Lambda = \emptyset$ ，原子指标集合 $\mathbf{J} = \emptyset$

2: 计算相关系数 g_i ，并将 g_i 的绝对值的最大值对应的索引值存入 \mathbf{J} 中

$$g_i = \tilde{\mathbf{\Theta}}^T r_{i-1}, \quad \mathbf{J}_i = \arg \max_{j=1,2,\dots,MN} |g_i(j)|$$

3: 更新支撑集 Λ

$$\Lambda_i = \Lambda_{i-1} \cup \mathbf{J}_i$$

4: 应用 LS 算法求解 $\tilde{\mathbf{Y}} = \tilde{\mathbf{\Theta}}\tilde{\mathbf{H}} + \tilde{\mathbf{W}}$

$$\hat{\mathbf{H}} = \arg \min_{\mathbf{H} \in \mathbb{R}^{\Lambda}} \|\tilde{\mathbf{Y}} - \tilde{\mathbf{\Theta}}_{\Lambda}\tilde{\mathbf{H}}\|_2 = (\tilde{\mathbf{\Theta}}_{\Lambda}^H \tilde{\mathbf{\Theta}}_{\Lambda})^{-1} \tilde{\mathbf{\Theta}}_{\Lambda}^H \tilde{\mathbf{Y}}$$

5: 更新残差 \mathbf{R}_i

$$\mathbf{R}_i = \tilde{\mathbf{Y}} - \tilde{\mathbf{\Theta}}_{\Lambda}\hat{\mathbf{H}}$$

6: 判断迭代条件

$i = i + 1$ ，如果 $i > k$ 停止迭代，否则返回步骤 2

2.3 基于深度学习的信道估计方案

通过学习大量通信数据的内部特征，深度学习可以构建强大的非线性映射关系，实现精确的信道估计。目前基于深度学习的 RIS 辅助通信系统的信道估计研究可以分为两类，如图 2-2 所示。一类是直接使用神经网络去构建从接收的导频信号到信道矩阵的端到端模型^[42,43]；另一类是首先使用通信领域已有的信道估计算法去获得一个信道初值，然后再使用神经网络去改善信道估计精度^[44-50]。




图 2-2 智能信道估计框架

2.3.1 基本深度学习模型

随着深度学习的发展及其在各个交叉领域的应用，针对不同的任务，涌现了多种多样的深度神经网络结构，然而其基本结构可以分为多层感知机 (Multilayer Perceptron, MLP)^[77]，卷积神经网络 (Convolutional Neural Network, CNN)^[78]，循环神经网络 (Recurrent Neural

Network, RNN) [79], 以及最近兴起的由纯注意力机制组成的网络, 如 Transformer[80]。目前在信道估计领域, 基于前三种网络架构设计的网络模型居多, 而注意力机制更多的作为辅助结构附加于这三种网络结构中[81], 因此接下来将简要介绍前三种网络结构, 其具体结构如图 2-3。

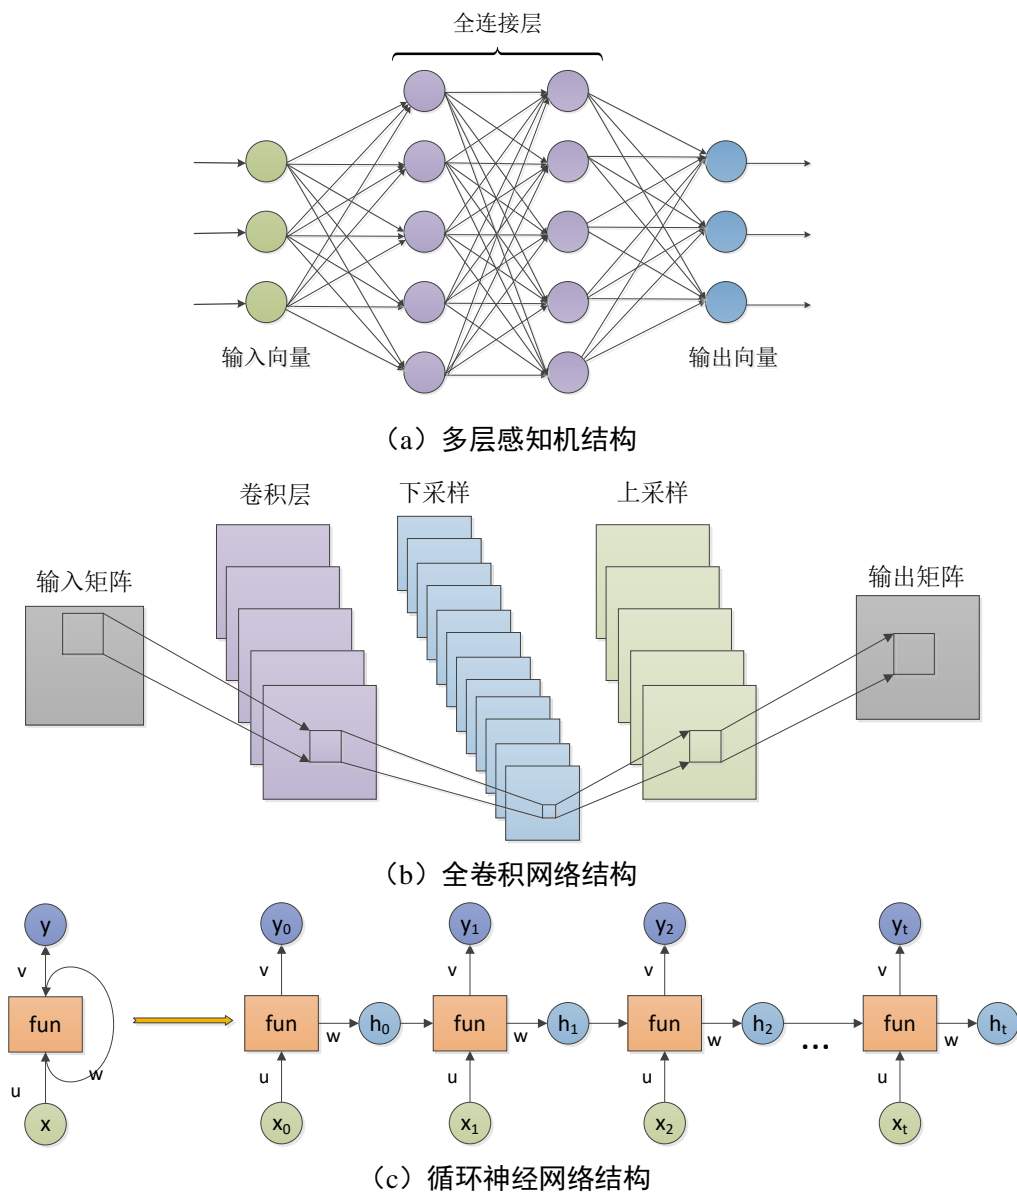


图 2-3 基本神经网络结构

(a) MLP

如图 2-3 (a) 所示, MLP 由多个全连接的线性层组成, 相邻网络层的神经元之间的传递函数可以表示为

$$x_j^{l+1} = \sigma \left(\sum_{i=1}^n w_{ij} x_i^l + b_j^{l+1} \right) \quad (2-28)$$

其中, x_i^l 表示神经网络第 l 层第 i 个神经元, w_{ij} 表示神经元 x_i^l 和 x_j^{l+1} 之间的连接权值, b_j^{l+1} 为

相应的偏置， $\sigma(\cdot)$ 为激活函数。

在早期的基于深度学习的无线通信物理层算法设计中，MLP 主要用于信号检测领域^[82]，相较于传统算法可以取得更高的性能提升。由于 MLP 要求输入数据为向量形式，而对于 CV 中的图像和视频数据，或者对于 MIMO 系统中存在的多天线发射/接收信号和信道矩阵，需要将这些高维数据展开成向量再输入到 MLP 中，这个过程可能会丢失数据的空间信息，并且网络中将存在包含大量神经元的全连接层，而全连接层的缺点之一就是存在由于网络层采用密集连接导致的参数冗余。以 VGG-16 为例^[83]，网络中最后一个卷积层将输出 $7 \times 7 \times 512$ 的特征图，当使用包含 4096 个神经元的全连接层去进行后续运算时，其将带来巨大的参数量为 $7 \times 7 \times 512 \times 4096 = 102760448$ 。对于整个 16 层网络而言，仅三层的全连接网络占据整个网络参数量的 80%。参数过大将使得网络训练效率更低，难度更大，并且也容易造成网络的过拟合。因此对于高维信道矩阵而言，使用多层感知机去实现信道估计任务是存在难度的。

(b) CNN

考虑到 MLP 难以对具有空间结构的数据进行处理，CNN 的神经元采用 3 维的卷积核结构，将其与输入数据进行二维卷积去提取数据的局部特征，如图 2-3 (b) 所示。为避免出现 MLP 中大量冗余参数，CNN 采用稀疏连接和权值共享来降低网络的参数数量，并使得网络对于数据一定程度上的形变，缩放和噪声干扰具有鲁棒性。CNN 中卷积层可以表示为

$$x_j^{l+1} = \sigma \left(\sum_{i=M_j} x_i^l * k_{ij}^{l+1} + b_j^{l+1} \right) \quad (2-29)$$

其中， x_i^l 为 CNN 第 l 层的局部感受野中第 i 个特征图， M_j 为 x_j^{l+1} 对应的局部感受野， $*$ 表示卷积运算， k_{ij}^{l+1} 为 x_i^l 为 x_j^{l+1} 之间的连接权重，将其称之为卷积核， b_j^{l+1} 为偏置。

由于 CNN 对提取空间数据特征存在优势，其已经被广泛应用于 OFDM 系统的时频域信道估计^[55,56]，Massive MIMO 系统和 RIS 辅助通信系统中的空间域信道估计^[47-50]。然而，对于高速移动场景下的无线信道而言，由于多普勒频移的影响，将呈现出快时变特性，此时根据导频得到的信道信息不能直接用于数据传输阶段。而 CNN 主要针对单个数据样本进行处理，无法建模不同样本数据之间的相关性，难以根据导频信道信息来预测出数据传输阶段的信道信息，因此其应用范围存在局限性。

(c) RNN

在 MLP 和 CNN 中，数据在网络的层与层之间传递，而每个网络层之间的神经元节点是独立的。对于一些特殊的应用场景，如对于时变信道估计，需要利用导频处所估计的信道预测出数据处的信道，此时要求网络具有时序建模能力。RNN 可以被视为具有记忆能力的 MLP，其记忆能力的长短可根据实际需要确定。如图 2-3 (c) 所示，当前时刻网络层的输入数据既包括原始数据又含有前一时间网络层的输出。第 t 时刻的输出向量 o_t 和隐藏状

态向量 h_t 可以分别表示为

$$\begin{aligned} o_t &= \sigma(vh_t) \\ h_t &= \sigma(ux_t + wh_{t-1}) \end{aligned} \quad (2-30)$$

其中, x_t 表示原始输入数据, u, v, w 均分别表示网络层的权值。

在原始 RNN 结构中引入门机制去控制数据流的传递, 使得网络可以学习长序列数据的长期依赖信息, 则可以改进为常用的长短期记忆网络 (Long Short Term Memory, LSTM) 和具有较高计算效率的门控循环网络 (Gate Recurrent Unit, GRU)。在已有研究中, LSTM 和 GRU 主要用于用户处于高速移动状态下的时变信道估计估计^[84], 然而 RNN 网络本质上仍然由全连接层组成, 并且相对于 MLP, 还引入了更多的密集连接, 因此其较高的计算复杂度难以满足实时信道估计。事实上, 目前常用的谷歌翻译软件也仅使用 7-8 层 LSTM。

2.3.2 端到端信道估计模型

对于端到端信道估计模型, 神经网络的输入数据为导频信号, 输出数据为信道矩阵。具体而言, 基于深度学习的信道估计算法设计包含两部分: 数据集设计和网络设计。对于数据集设计, 不同于 CV 中图像数据或自然语言处理 (Natural Language Processing, NLP) 中的文字可以用实数矩阵或向量来表示, 信号或者信道矩阵均为复数形式。虽然复值神经网络已被提出处理一些特有任务, 但是其本质仍然是将复数的实部和虚部由不同的网络层进行分开运算, 由于引入了更多的网络层, 所以计算复杂度较高。因此在目前的智能信道估计工作中, 广泛采用将复数信号的实部和虚部进行分离再拼接成一个实数矩阵。以本文考虑的系统模型为例, 则输入的信号数据 \mathbf{I} 的维度为 $M \times T \times 2$, 输出的信道数据 \mathbf{O} 维度为 $M \times N \times 2$, 其中第三个维度的 2 个通道数据分别对应信号/信道数据的实部和虚部, 即 $\mathbf{I}_{m,t,1} = \text{Re}(\mathbf{Y}_{m,t})$, $\mathbf{I}_{m,t,2} = \text{Im}(\mathbf{Y}_{m,t})$ 和 $\mathbf{O}_{m,n,2} = \text{Im}(\mathbf{H}_{m,n})$, $\mathbf{O}_{m,n,1} = \text{Re}(\mathbf{H}_{m,n})$, 其中 $\text{Re}(\cdot)$ $\text{Im}(\cdot)$ 分别为求取数据的实部和虚部, 并且 $m = 1, 2, \dots, M$; $t = 1, 2, \dots, T$; $n = 1, 2, \dots, N$ 。在文献[42]中还额外考虑了将接收信号绝对值作为输入数据的第三个维度, 即 $\mathbf{I}_{m,t,3} = |\mathbf{Y}_{m,t}|$ 。

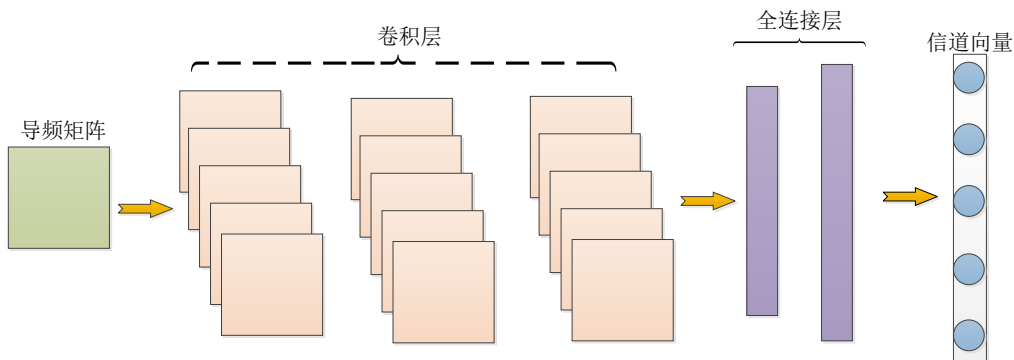


图 2-4 端到端信道估计网络

对于网络设计, 本文将文献[42]作为基线模型进行阐述, 其为将深度学习应用于 RIS 通信系统的信道估计的代表性工作。信道估计网络模型如图 2-4 所示, 其整体网络架构与早

期的图像分类模型相似，如 AlexNet^[85]和 VGGNet^[83]，网络骨架由卷积层和全连接层组成。

利用接收的导频信号设计输入数据，将导频的实部，虚部和模分别作为输入数据的三个维度。首先使用 3 个卷积层去提取输入矩阵的空间信息，再使用 2 个全连接网络进行拟合，其最后一层的全连接层神经元个数需要匹配级联信道矩阵的单元个数。输出数据为将信道矩阵展开的信道向量 $\text{vec}(\mathbf{O}) = [\text{Re}(\text{vec}(\mathbf{H}_k)), \text{Im}(\text{vec}(\mathbf{H}_k))] \in \mathbb{R}^{2MN \times 1}$ 。

对于上述的信道估计模型，存在两个不足，首先如 2.3.1 节所述，对于高维信道矩阵，引入全连接层将使得网络参数量大幅度增加。其次，在设计输入数据时，要求的导频开销与 LS 相同，即文献[42]下行信道估计时导频数量为级联信道矩阵单元个数 $M \times N$ 。这两点不足将会影响该模型的在真实通信系统的实际部署。因此在本文的研究中，将采用全卷积网络结构来降低导频开销和网络训练开销^[86]。

2.3.3 后处理信道估计模型

为了进一步提高估计精度和网络收敛速度，已有工作使用神经网络作为一个信道估计后处理模型，主要分为两类：第一类是借鉴用于图像去噪的深度学习模型，将这些模型用于通过传统算法所得到的信道估计初值，来进一步去除通信系统噪声的影响^[44-46]。第二类则借鉴图像 SR 的思想，首先使用较少的导频信号去获得一个局部的低维信道矩阵，然后再使用 SR 网络模型来获得完整的信道矩阵，该思想早期用于 OFDM 通信系统^[55,56]，现在已经推广到 RIS 通信系统^[47-49]。下面介绍两种典型的去噪和 SR 网络，分别为 DnCNN（Denoising Convolutional Neural Network）^[87]和 VDSR（Very Deep Super-Resolution Network）^[88]，如图 2-5 所示。

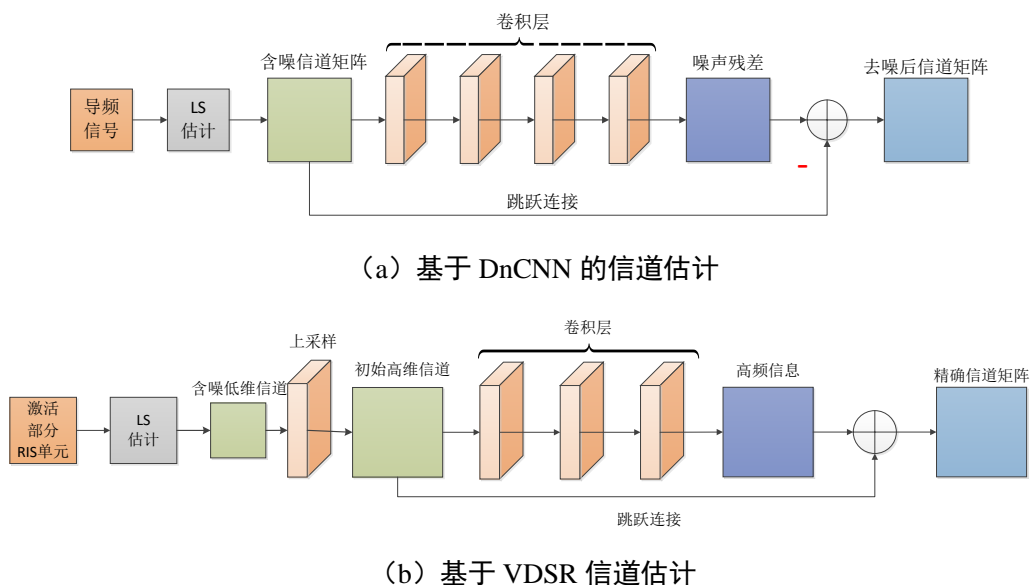


图 2-5 后处理信道估计网络

假设两种模型均采用 LS 算法作为初始信道估计方法，相对于第一种方案，第二种方案

利用超分思想，只需要开启部分 RIS 单元去估计一个低维的信道初值作为网络输入，因此可以降低导频开销。DnCNN 和 VDSR，两种网络结构相似，都采用残差学习思想^[62]。一般来说神经网络参数越多则就有越好的表征能力，但是当神经网络到达一定深度以后再一味地增加层数，并不能带来进一步地性能提高，反而容易网络的梯度消失或爆炸。文献[62]设计了一种 ResNet 结构去解决深层网络训练问题，其基本残差单元如图 2-6 所示。




图 2-6 残差单元

x 为网络输入值， $F(x)$ 是经过两个网络层的输出，称为残差。在进入第二层激活函数之前， $F(x)$ 与 x 相加，即残差块的输出 $H(x) = F(x) + x$ 。假设整个网络有 I 个残差块，且考虑跳跃连接与激活函数均为直接映射，则网络的最终输出为

$$x_I = x_0 + \frac{\partial}{\partial x} \sum_{i=0}^{I-1} F(x_i) \quad (2-31)$$

当采用梯度下降法更新网络参数时，采用链式法则，损失函数 L 对输入数据的求导为

$$\frac{\partial L}{\partial x_0} = \frac{\partial L}{\partial x_I} \frac{\partial x_I}{\partial x_0} = \frac{\partial L}{\partial x_I} \left(1 + \frac{\partial}{\partial x_0} \sum_{i=0}^{I-1} F(x_i, w_i) \right) \quad (2-32)$$

因为式 (2-32) 的梯度中存在常数 1，就可以避免网络在训练过程中发生梯度消失；其次，由于另外一项为累加和形式，则在一定程度上可以缓解网络出现梯度爆炸；最后，梯度结果的乘法系数为 $\partial L / \partial x_I$ ，则可以将网络深层梯度传递到浅层。为避免网络层数过深时出现网络退化现象，ResNet 只需要令 $F(x) = 0$ ，就能实现冗余层恒等映射，而神经网络的初始化参数值往往接近于 0，因此令网络层实现 $F(x) = 0$ 比实现 $H(x) = x$ 更加容易。

图 2-5 (a) 所示的 DnCNN 则采用残差学习思想，并没有直接利用大量的卷积层实现从含噪信道映射到干净信道矩阵，而是让网络去学习输入数据中的噪声，再利用残差结构去得到期待的信道矩阵，该思想有助于网络训练的稳定并提高去噪效果。图 2-5 (b) 中的 VDSR 应用残差学习的原因则是对于 SR 任务，原始输入数据与目标输出数据往往具有相似的低频成分，而随着网络层数的加深，网络将会学到越来越多的高频信息，因此通过利用残差学习实现高频信息和低频信息的融合将有利于最终的信道重建，提高网络收敛速度。

DnCNN 和 VDSR 作为早期的图像去噪模型和超分模型，其性能是有限的，近年来已经涌现了许多更先进的图像去噪模型，如 FFDNet (Fast and Flexible Denoising Network)^[89] 和 CBDNet (Convolutional Blind Denoising Network)^[90]，和图像超分模型，如 EDSR^[91] 和

RCAN (Residual Channel Attention Network) [92], 而这些模型也已经被许多学者应用到无线通信系统的信道估计领域^[20,45,48]。

2.4 本章小结

本章首先介绍了一个基本的 RIS 辅助的无线通信系统模型, 其中具体阐述了毫米波 RIS 的信道建模。然后介绍 3 种目前常用的 RIS 信道估计思路以及它们所存在的不足, 包括经典的 LS 估计, 基于压缩感知的稀疏信道估计和基于深度学习的智能信道估计方案。本文将从这些已存在的工作出发, 提出新的 RIS 信道估计算法。并且上述信道估计方案也将作为基线方案与后续本文所提出的算法在信道估计性能上进行比较。

第3章 基于多任务学习的联合信道估计方案

对于一般的 RIS 辅助通信系统包含用户-基站的直射链路和用户-RIS-基站的反射链路，已有工作采用两个独立的神经网络通过交替关闭/开启所有 RIS 单元来实现直射信道估计和级联信道估计^[42]。由于两个基于单任务学习（Single-task Learning, STL）的信道估计网络是独立训练和部署的，因此通信设备存在较大的训练开销，包括内存和计算复杂度。此外，由于直射信道估计时的导频数据较少，因此文献[42]所提出的信道估计模型的直射信道估计性能优势不明显。为解决上述问题，本文采用 MTL 思想在相同的信道相干时间内实现直射信道和级联信道的联合估计。

3.1 多任务学习

MTL 是一种推导迁移学习方法^[93]，多个任务之间共享部分网络层，使得它们可以在学习过程中共享所学到的信息，从而更好的完成各自的任务，相关联的 MTL 比 STL 可以取的更好的泛化效果。当 RIS 单元处于打开状态时，根据式 (2-9)，基站的接收信号包括直接信号和反射信号。因此从数据驱动的角度，可以设计一个端到端的 MTL 模型，同时实现从导频信号到直射信道和级联信道的映射，避免 STL 中由于仅支持一对一映射所产生的额外训练开销。

图 3-1 为一个典型的低层共享的 MTL 框架^[94]，每个任务通过更新共享层中的公共权值参数来影响其他任务。网络权重共享发生在较低的层次上，即相关的任务通过一个共同的低层次表示而耦合在一起，形成一种共享知识库，每个任务都以自己独特的方式构建在共享的低层次表示之上，而在网络的最后输出部分，则针对不同的子任务训练权值不同的网络输出层。

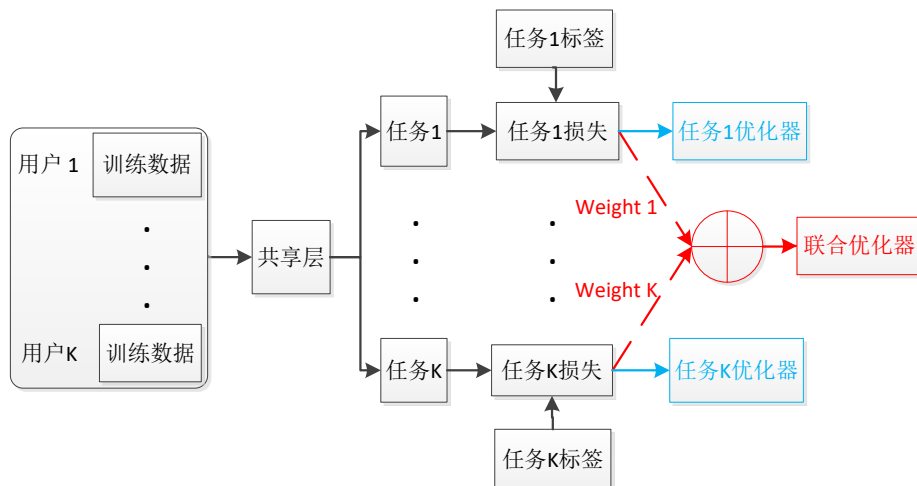


图 3-1 多任务学习框架

MTL 有两种学习方式，一种是交替训练，通过单独优化每个子任务的代价函数来使得每个子任务达到最优；另一种是联合训练，将损失函数进行加权合并使得全局最优。图 3-1 中红色虚线部分表示联合训练方式，蓝色实线部分表示交替训练方式。多任务网络联合训练时，损失函数一般形式为：

$$L_{\text{joint}} = \sum_k^K \beta_k L_k \quad (3-1)$$

其中， L_k 为第 k 个任务的损失函数， β_k 为每个任务损失函数的加权值。

当采用联合训练时，MTL 的性能在一定程度上依赖于每个任务损失之间的相对权重 β_k ，手动确定 β_k 需要花费大量的时间。如果将 β_k 作为一个固定的超参数，则其不会随着网络训练的进行而自动调整，很难实现最优的效果。对于 RIS 通信系统，由于级联信道矩阵维度远高于直射信道矩阵维度，所以不同链路的信道估计相对难度不同，因此本文使用文献[53]中的通过任务依赖不确定性来推导一个可以自动优化 β_k 的多任务损失函数。 K 个任务的联合损失函数为

$$L_{\text{joint}}(\mathbf{W}, \sigma_1, \sigma_2, \dots, \sigma_K) \approx \sum_{k=1}^K \frac{1}{\sigma_k^2} L_k(\mathbf{W}) + \log \sigma_k^2 \quad (3-2)$$

其中， σ_k 为网络中第 k 个子任务的观测噪声参数，表示输出数据中的噪声量。 $L_k(\mathbf{W})$ 为子任务损失函数。

式 (3-2) 中 σ_k 为一个网络可学习的参数，随着网络训练自动调整。大的 σ_k 表示对应任务不确定性大，所以会降低 $L_k(\mathbf{W})$ 对网络总损失的影响，小的 σ_k 表示对应任务不确定性小，所以增大 $L_k(\mathbf{W})$ 的影响。 $\log \sigma_k^2$ 表示对损失函数的惩罚，一旦 σ_k 太大时，损失函数将变成一个常数。这个损失是平滑可微的，并且可以使得任务权重不会收敛到零。

3.2 残差收缩网络

3.2.1 可学习的软阈值化

由于无线通信环境存在的噪声干扰，通信信号去噪是接收机在解码信号之前需要进行的步骤之一，常用的去噪方法为设计相应的滤波器去滤除噪声而保留有用信号。然而，传统滤波器设计方法往往基于专家知识去人工确定，在复杂的信号传输场景下其性能是不稳定的。深度学习技术为滤波器设计提供了一种新的思路，即深度学习可以使用梯度下降算法自动学习一个合适的滤波器。软阈值化一直是信号去噪的关键步骤之一^[95]，可以表示为

$$y = ST(x, \tau) \begin{cases} x - \tau & x > \tau \\ 0 & -\tau \leq x \leq \tau \\ x + \tau & x < -\tau \end{cases} \quad (3-3)$$

本中的冗余信息含量经常是不同的，因此借鉴 CV 中的注意力机制^[96]，使用神经网络自适应地根据每个样本数据学习到单独的阈值 τ ，注意这里采用通道注意力机制，即每个样本的每个通道都有单独的阈值 τ 。该部分对应图 3-2 中的上方部分引入的一个第二个跳跃连接，在跳跃连接内部通过注意力机制来学习一个最优的阈值 τ 。

注意力机制原理为模仿人类的视觉特性，人类观察物体上往往会将关注于物体的局部关键特征。具体实现可以分为两步：首先扫描目标的全局信息，然后增强局部的有用特征并抑制其余的无用信息。RSBU-CW 的网络结构设计受 SENet (Squeeze-and-Excitation Network)^[97]启发，即在经典 ResNet 结构中的嵌入注意力模块去学习一组软阈值化所需要阈值 τ ，再将其去处理残差路径输出的特征图，来实现有用特征增强，具体步骤如下

(a) 全局信息压缩向量化

假设 RSBU-CW 的输入数据为 $F_0 \in \mathbb{R}^{M \times N \times C_0}$ ，其中 C_0 表示特征图的通道数， F_0 经过残差主路径的两个卷积层得到特征图 $F_1 \in \mathbb{R}^{M \times N \times C_1}$ 。在包含注意力机制的跳跃连接分支中， F_1 首先取绝对值再经过一个全局池化层降维为 $F_2 \in \mathbb{R}^{1 \times 1 \times C_1}$ ，即对应图 3-2 中的 Absolute GAP。

$$F_{2,c} = \underset{i,j}{\text{average}} |F_{1,i,j,c}| \quad (3-5)$$

其中， $i=1,2,\dots,M; j=1,2,\dots,N; c=1,2,\dots,C_1$ 。通过利用全局池化整合特征图的全局特征，最终得到一个特征向量表征。

(b) 自适应阈值学习

将上一步得到的全局向量 F_2 经过两层神经元个数均为 C_1 的全连接层的非线性映射，得到特征向量 $F_3 \in \mathbb{R}^{C_1}$ 。最后使用 Sigmoid 函数把输出数据限制在 $[0, 1]$ 的范围，去获得尺度因子 $\alpha_c \in \mathbb{R}^{C_1}$ 。Sigmoid 函数可以表示为

$$\text{Sigmoid}(z) = \frac{1}{1 + e^{-z}} \quad (3-6)$$

通过上述的全连接层结构以非线性映射方式学习到一组尺度因子 α_c ，其对应着特征图的每一个通道。在经典的注意力网络中，如 SENet，直接将尺度因子 α_c 与原始特征图 F_1 的 C_1 个通道数据相乘去作为下一级网络的输入。通过利用网络学习特征图通道之间的相关性来训练出尺度因子，让网络自动从所有的特征图中专注于学习对目标任务更有用的特征。

不同于 SENet，RSBU-CW 中的注意力机制是去学习软阈值化中的一个非负阈值 τ ，且根据式 (3-4)，当 τ 大于网络特征图绝对值的最大值时，输出信号 y 将置为 0。为避免该问题，阈值 $\tau \in \mathbb{R}^{C_1}$ 被表示为

$$\tau = \alpha_c \times \underset{i,j}{\text{average}} |F_{1,i,j,c}| = \alpha_c F_{2,c} \quad (3-7)$$

其中， $i=1,2,\dots,M; j=1,2,\dots,N; c=1,2,\dots,C_1$ 。

(c) 软阈值化

在 RSBU-CW 的残差主路径中，根据基于注意力机制所得到的阈值 τ 对 F_1 进行软阈值化，如式 (3-3)。RSBU-CW 最终的输出可以表示为

$$F_o = F_0 + ST(F_1, \tau) \quad (3-8)$$

3.3 多任务网络模型

数据集设计与文献[42]类似，即使用 2.2.1 节的 RIS 反射协议去获取导频数据。但是本文不需要为直射链路和反射链路单独设计数据集和网络，而是在数据集生成阶段，始终保持所有 RIS 单元处于激活状态，省略了直射信道估计时需要关闭 RIS 的步骤。将基站接收的导频信号作为输入数据，直射信道和级联信道矩阵作为两个任务的标签数据。考虑 RIS 辅助的多用户上行通信系统，每个用户发送互相正交的导频信号进行信道估计。假设 $\mathbf{Y}_k = [y_{k,1}, y_{k,2}, \dots, y_{k,T_c}] \in \mathbb{C}^{M \times T_c}$ 表示基站在 T_c 个时隙所接收的第 k 个用户的导频信号。取 $T_c = N$ ，根据 2.3.1 节的数据处理方式，则输入数据为 $\hat{\mathbf{Y}}_k$ 的实数化表示 $\bar{\mathbf{Y}}_k \in \mathbb{R}^{M \times N \times 2}$ ，其中 2 通道代表接收导频信号的实部和虚部。两个子任务的标签数据分别为 $\hat{\mathbf{d}}_k$ 的实数化表示 $\bar{\mathbf{d}} \in \mathbb{R}^{M \times 2}$ 和 $\hat{\mathbf{H}}_k$ 的实数化表示 $\bar{\mathbf{H}} \in \mathbb{R}^{M \times N \times 2}$ 。采用文献[98,99]的数据归一化方法对接收信号与信道矩阵归一化。

本文提出的 MTL 网络结构如图 3-3 所示，在 MTL 模型的共享层中，使用一个基线卷积块 (CBR) 提取底层特征，CBR 由卷积层、批量归一化 (Batch Normalization, BN)^[100] 层和 LeakyReLU 激活层组成。BN 层在网络的数据流传递过程中对数据标准化，可以在一定程度上稳定深层网络的训练并避免过拟合，具体计算流程为：

(a) 求解每批次输入数据 $x \in \mathbb{R}^{B \times W \times H \times C}$ 的均值和方差

$$\mu_i = \frac{1}{BWH} \sum_{b=1}^B \sum_{w=1}^W \sum_{h=1}^H x_{b,w,h,i} \quad (3-9)$$

$$\sigma_i^2 = \frac{1}{BWH} \sum_{b=1}^B \sum_{w=1}^W \sum_{h=1}^H (x_{b,w,h,i} - \mu_i)^2 \quad (3-10)$$

其中， B ， W ， H ， C 分别表示输入数据的批处理大小，宽度，高度和通道数。

(b) 对批次数据进行归一化

$$\hat{x}_{b,w,h,i} \leftarrow \frac{x_{b,w,h,i} - \mu_i}{\sqrt{\sigma_i^2 + \xi}} \quad (3-11)$$

其中， ξ 为正则化参数。

(c) 对数据进行尺度变换

$$y_{b,w,h,i} = \gamma \hat{x}_{b,w,h,i} + \beta \quad (3-12)$$

其中， γ 和 β 为可学习的参数。

不同于图像数据的像素值为正数，通信信号与信道系数有正有负，采用 ReLU 激活函数

可能会丢失数据的有效特征，因此采用对负值数据也可以激活的 LeakyReLU 函数

$$LeakyReLU(x) = \begin{cases} x & x \geq 0 \\ \frac{x}{a} & x < 0 \end{cases} \quad (3-13)$$

其中， a 是 $(1, +\infty)$ 区间内的固定参数，称为泄露值，实验中一般取 $a = 0.2$ 。

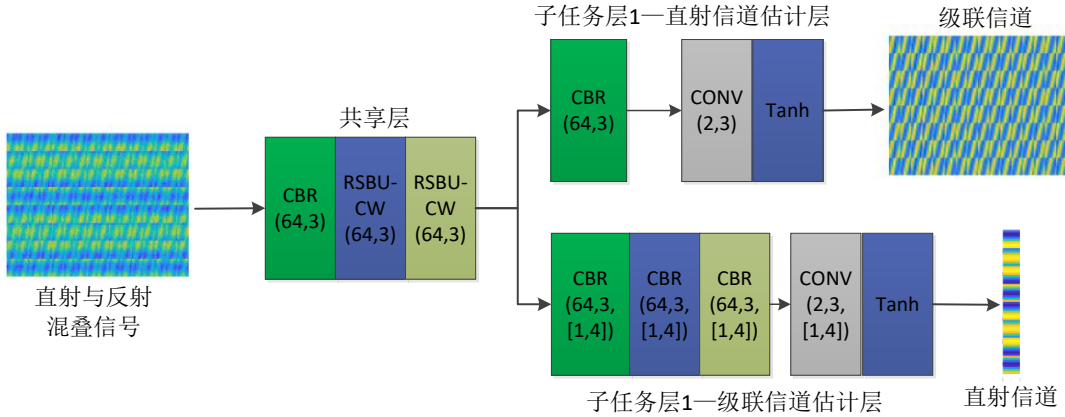


图 3-3 多任务信道估计网络模型

随后，共享层堆叠两个 RSBU-CW 模块去学习深层特征，并缓解通信噪声的对信道估计的干扰。级联信道估计由子任务层 1 完成，首先使用一个 CBR 去从共享网络层的输出中学习级联信道的专有特征，然后使用一个带有 2 个卷积核的卷积层去降低输出的通道维数，使其满足信道矩阵维度，即 $\mathbb{R}^{M \times N \times 64} \rightarrow \mathbb{R}^{M \times N \times 2}$ 。由于直射信道维度小于接收信号的数据维度，所以在子任务层 2 中，我们采用卷积核滑动步长为 $[d_1, d_2]$ 的卷积层来降低特征图的尺寸，则子任务层 2 所需的卷积层数为 $L = \log_{d_2}^N$ 。后文的仿真实验中 $N = 256, d_1 = 1, d_2 = 4$ ，因此子任务层 2 使用 4 个滑动步长为 $[1, 4]$ 的卷积层进行降维，与子任务层 1 类似，最后一个卷积层的卷积核数量为 2 来匹配信道矩阵维度，因此数据维度变化为 $\mathbb{R}^{M \times N \times 64} \rightarrow \mathbb{R}^{M \times 1 \times 2}$ 。在网络最后的输出时使用 Tanh 激活函数来约束输出数据的范围与数据归一化操作相对应 [98,99]。

3.4 性能指标与损失函数

若将信道矩阵视为图像，则信道估计任务与 CV 中的图像重建具有相似性，但是信道估计任务与图像重建也存在不同点^[101]，首先，信道矩阵相对于图像具有更明显的结构性特征，如 OFDM 系统的时频域相关性，MIMO 系统的天线空间域相关性。其次，信道估计与图像复原的评价指标也不一样，对于信道估计，一个好的性能评价指标为欧式距离或者 SNR，目前广泛使用归一化均方误差（Normalized Mean Squared Error, NMSE）作为信道估计的评价指标，即

$$\text{NMSE} = E[\|(\hat{\mathbf{H}}_k - \mathbf{H}_k)\|_F^2 / \|\mathbf{H}_k\|_F^2] \quad (3-14)$$

其中， \mathbf{H}_k 表示真实信道， $\hat{\mathbf{H}}_k$ 表示估计出的信道， $\|\cdot\|_F$ 表示 Frobenius 范数。

图像质量的评价是感性和多元的，在图像重建早期的研究中，图像峰值信号比（Peak Signal-to-Noise Ratio, PSNR）作为图像质量评价指标，这与欧式距离是相似的，然而在后续的研究中发现欧式距离和 SNR 被认为是较差的图像质量度量^[102]，如 PSNR 仅仅针对图像的像素点误差，未考虑人眼对目标的某部分区域特性更敏感，如空间频率和亮度，且一个区域的感知往往会被其邻近区域特征影响。因此进一步提出了一些基于感知相似度的评价指标，如 LPIPS (Learned Perceptual Image Patch Similarity)^[103]，因此目前图像质量的评价一般是结合多个指标的。

对于损失函数的选取，由于信道估计与图像复原都属于回归任务，最常用的损失函数为 L2 损失（最小平方误差）和 L1 损失（最小绝对值误差）。由于图像的感知特性，所以对于图像复原中的损失函数中还会额外加入感知损失。而对于信道估计，虽然 L2 损失可以直接与 NMSE 指标相联系，但是已有研究表明，使用 L2 损失函数会产生模糊的图像^[104]，对于信道估计也同样存在这个现象^[56]，因此本文采用 L1 损失作为多任务网络模型训练时的损失函数。结合 3.1 节的多任务联合损失函数，最终的损失函数为

$$L_{\text{joint}}(w, \sigma_1, \sigma_2) \approx \frac{1}{\sigma_1^2} L_1(w) + \frac{1}{\sigma_2^2} L_2(w) + \log \sigma_1^2 + \log \sigma_2^2 \quad (3-15)$$


其中， $L_1(w) = \left| \bar{\mathbf{d}}_k - f_1(f(\bar{\mathbf{Y}}_k)) \right|$, $L_2(w) = \left| \bar{\mathbf{H}}_k - f_2(f(\bar{\mathbf{Y}}_k)) \right|$ 分别表示直射信道和级联信道估计的 L1 损失，其中 $f_s(\cdot)$ 和 $f_i(\cdot)$ 分别表示共享层和第 i 个子任务层的网络映射函数。

3.5 实验结果与分析


仿真实验采用 MATLAB2018a 作为通信链路仿真平台，PyTorch 1.10 作为深度学习开发平台。仿真通信系统中考虑 $K = 6$ 个用户，基站天线数 $M = 64$ ，RIS 单元数 $N = 256$ 。毫米波频段设置为 28 GHz 和 73 GHz。考虑一个户外通信场景 UMi 环境下的路径损耗模型，对于式(2-3)中的 NLoS 分量信道参数 $n = 3.19$, $b = 0$, $\sigma = 8.2$ dB, LoS 分量信道参数 $n = 1.98$, $\sigma = 3.1$ dB。每个用户生成 5×10^3 对样本，因此总样本数为 3×10^4 ，按照 60%，20%，20% 的比值随机分为训练集、测试集和验证集，其中训练集的 SNR 范围为 [0, 5, ..., 30] dB。网络训练时采用自适应矩估计（Adaptive Moment Estimation, Adam）优化算法^[105]，批量大小设置为 32，训练周期数为 100。本文将已有的 LS、LMMSE、OMP 和 STL 方案作为对比的信道估计算法。

图 3-4 比较了所提出的 MTL 和已有算法的直射信道和级联信道估计的 NMSE 性能。其中 LS 算法包括 ON/OFF 协议和 DFT 协议，即对应图 3-4 (a) 中的 LS-ON/OFF 和 LS-DFT。对于 LS-ON/OFF，直射信道和级联信道分开估计，其中 $T_d = 1$, $T_c = N$ 。对于 LS-DFT，直

射信道和级联信道联合估计, $T = N + 1$ 。STL-OFF 表示估计直射信道时, RIS 处于关闭状态, 而估计级联信道时激活 RIS, 即与文献[42]采用相同的设计思想。STL-ON 和 MTL 则估计直射信道和级联信道时 RIS 均处于激活状态, 即级联信道估计和直射信道估计使用相同的接收导频信号, 即 $T = N$ 。STL 使用两个独立的网络去分别估计直射信道和级联信道, 其网络结构与 MTL 的两个分支网络结构相同。当估计级联信道时, STL-OFF 和 STL-ON 的性能是一样的, 因为使用了相同的输入数据, 因此图 3-4 (b) 中统一记为 STL。



(a) 直射信道估计



(b) 级联信道估计

图 3-4 不同算法的信道估计性能

MTL 的估计精度在大多数 SNR 范围内都优于其他方案, 仅在高 SNR 下劣于 LS 算法。根据 2.2.1 节的分析, 在 RIS 辅助通信系统中信道估计性能与 RIS 反射协议和估计器有关。

虽然 DFT 协议已被证明是最优的反射协议，但传统的 LS 和 LMMSE 估计器是次优的。对于稀疏信道估计方案，由于本文信道建模时分簇 MIMO 信道模型的稀疏性是可变的，且稀疏度 k 较大，因此 OMP 算法的估计性能有限。随着 SNR 的提高，MTL 方案与 LS 方案的性能差距逐渐缩小。信道估计可视为一个高维数据回归任务，而数据驱动的神经网络则可视为一个通用函数逼近器。LS 的估计误差实质上来源于噪声的求逆，当噪声足够小，如 SNR 大于 20 dB 时，神经网络的信道逼近误差将大于 LS 算法。STL-ON 在估计直射信道时，虽然没有反射信号的干扰，但是由于直射信道估计使用的导频较少，因此神经网络的输入信息较少，所以 STL-ON 的直射信道估计精度低于 STL-OFF。然而，输入数据的维数越大，则网络的计算开销也就越大。表 3-1 统计了 STL 和 MTL 的模型参数量，所占内存和浮点运算次数，可以看到 STL-ON 的运算量远高于 STL-OFF。MTL 的 NMSE 性能与 STL 相似，对于直射信道估计更加精确。由于 STL 需要两个独立的网络分别来估计直射信道和级联信道，因此 STL 的总参数和计算复杂度都大于 MTL。

表 3-1 不同网络模型训练开销

算法	MTL	STL-ON	STL-OFF
可训练参数量(K)	316.55	204.24+278.36	204.24x2
内存(MB)	1.21	0.78+1.06	0.78x2
浮点运算次数(G)	3.28	3.06+2.63	3.06+0.012

图 3-5 比较了 MTL 共享层中不同网络架构下的 NMSE 性能。




图 3-5 不同共享层网络结构的信道估计性能

CNN 和 ResNet 具有相似的信道估计精度，而 DRSN 架构在较低 SNR 下可以获得较高的估计精度。DRSN 在经典残差单元中引入了可学习的软阈值化操作，可以在网络的训练中抑制输入数据中噪声对 MTL 信道估计模型的影响。

在 2.1.1 节的 RIS 辅助毫米波通信系统信道建模中,在不同的通信频段下,分簇 MIMO 信道模型中簇 C 的分布和通信链路的路径损耗模型 L 的参数会发生改变。图 3-6 则展示了 MTL 模型可以在不同的频段下稳定的实现信道估计,其中 MTL 模型仅在 28 GHz 的通信数据集进行线下训练,在线测试时可以直接用于 73 GHz。这得益于经过大量数据训练得到的神经网络模型对于输入数据的扰动具有一定程度的鲁棒性。




图 3-6 不同通信频段下的信道估计性能

3.6 本章小结

本章针对已有基于 STL 的 RIS 信道估计工作将直射信道和级联信道分开估计所产生的冗余训练开销,提出了基于 MTL 的联合信道估计方案。在整个信道估计过程中,始终保持 RIS 所有单元处于激活状态,根据 RIS 信号模型,构建 MTL 网络实现从接收的导频信号同时映射到直射信道和级联信道。与此同时,利用注意力机制原理实现自适应的软阈值化,设计了多任务残差收缩网络。仿真结果展示了所提出算法较传统信道估计方案可以获得更高的信道估计精度,较 STL 网络则明显减少了训练开销。

第4章 基于多尺度监督学习的级联信道估计方案

在第三章中, 本文利用 MTL 实现了 RIS 通信系统的联合信道估计, 虽然避免了单独的直射信道估计操作, 但是对于高维的级联信道, 仍然需要大量的导频开销。因此本章提出一种可以大幅度减少级联信道估计所需导频开销的深度信道估计模型。其基本思想仍然采用基于 SR 网络的信道外推思想^[47-50,55,56], 但不同的是, 本文提出一种基于多尺度监督学习的渐近式信道重建策略, 相对于已有工作中所采用的单步重建, 如 SRCNN^[47,55]和 EDSR^[48,56], 本文所设计的网络模型可以获得更高的信道估计精度。

4.1 低分辨率信道估计

在设计 RIS 的单元结构时, RIS 的反射单元相互集成的非常接近, 因此在给定的通信环境下, 相邻单元的信道高度相关, 称为 RIS 天线域的空间相关性^[49]。基于这种空间相关性, 可以将级联信道估计分为两部分去完成: 首先打开部分 RIS 单元, 估计局部的级联信道, 然后利用 SR 网络去上采样得到完整信道矩阵。与已有基于 SR 的 RIS 信道估计工作类似^[47-50], 本节假设通信系统中直射链路被完全阻碍仅考虑级联信道估计。

定义整个 RIS 反射单元集合为 $\mathcal{N} \triangleq \{1, 2, \dots, N\}$, 在进行低分辨率信道估计阶段, 假设只以 $k = 2^S, (0 \leq S \leq \log_2^N)$ 为间隔打开 p 个单元, 即打开单元的子集为

$$\mathcal{P} \triangleq \{1, k+1, \dots, (p-1) \times k + 1\} \left(p = \left\lfloor \frac{N-1}{k} + 1 \right\rfloor \right) \quad (4-1)$$

遵循文献[47]的低维信道获取方法, 采用 LS-ON/OFF 算法估计低分辨率的初始信道矩阵 $H_{LS} \in \mathbb{C}^{M \times p}$ 。根据 2.2.1 节的 LS-ON/OFF 算法介绍, 在每一个时隙仅打开子集 \mathcal{P} 的第 $i (1 \leq i \leq p)$ 个单元且反射系数 θ_i 设置为 1, 而其他单元保持关闭状态。基站的接收信号可以表示为 $\mathbf{y}_i = \mathbf{H}_i^{\mathcal{P}} \mathbf{s}_i$, 其中 $\mathbf{H}_i^{\mathcal{P}}$ 表示级联信道 $\mathbf{H}^{\mathcal{P}}$ 的第 i 列。采用 LS 算法可以获得估计信道 $\hat{\mathbf{H}}_i^{\mathcal{P}} = \mathbf{y}_i \mathbf{s}_i^{-1}$, 通过串行的打开子集 \mathcal{P} 中每个反射单元, 并采用相似的估计方法, 则可以得到级联信道 $\mathbf{H}_i^{\mathcal{P}}$ 的所有 N 列, 即 $\hat{\mathbf{H}}^{\mathcal{P}} = [\hat{\mathbf{H}}_1^{\mathcal{P}}, \hat{\mathbf{H}}_2^{\mathcal{P}}, \dots, \hat{\mathbf{H}}_N^{\mathcal{P}}]$ 。

当得到一个低维信道初值后, 则可以应用 SR 网络来实现完整的信道重建。文献[55, 56]分别应用 SRCNN 和 EDSR 的 OFDM 信道估计, 相似的, 文献[47, 48]将 SRCNN 和 EDSR 扩展到 RIS 辅助的通信系统。然而在上述工作中, 信道的重构是在网络的前端或后端进行单步重建实现的, 例如文献[47, 55]在网络的输入层或文献[48, 56]在网络的输出层进行上采样, 当尺度因子较大时, 完整信道的重构难度会增加。在传统的级联信道估计中, 利用空间相关性提出了一些降维信道估计思想, 如单元分组^[106]。在 SR 中也有类似的思想, 如拉普拉斯金字塔超分辨率网络 (Laplacian Pyramid Super-Resolution Network, LapSRN)^[57], 这激

励本文通过利用多尺度监督学习来以一种从低维渐近到高维的方式逐步重构级联信道。

为构造多尺度的信道重建数据集，网络的标签数据为不同尺度的级联信道矩阵，并被设计为一个集合，即 $\mathcal{H} = \{\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_S\}$ ，其中 $\mathbf{H}_s \in \mathbb{C}^{M \times 2^s P}$ ($1 \leq s \leq S$) 并且 $\mathbf{H}_s = \mathbf{H} \in \mathbb{C}^{M \times N}$ 。最后所有信道数据被实数化表示，即输入数据 $\bar{\mathbf{H}}^P \in \mathbb{R}^{M \times P \times 2}$ ，标签数据 $\bar{\mathcal{H}} = \{\bar{\mathbf{H}}_1, \bar{\mathbf{H}}_2, \dots, \bar{\mathbf{H}}_S\}$ ，其中 $\bar{\mathbf{H}}_s \in \mathbb{R}^{M \times 2^s P \times 2}$ 。

4.2 拉普拉斯金字塔

基于 SR 的信道估计方法可以看作为用神经网络实现信道插值和滤波，类似于传统信道估计方法中的非线性插值和维纳滤波。通过将信道矩阵视为 2 通道的实值图像矩阵去进行上采样，可以引入图像缩放技术中实现图像多尺度表达的图像金字塔来帮助信道重建。图像金字塔的底部为高分辨率的图像，金字塔顶部则为低分辨率图像，是一组按照分辨率大小从上到下依次排列的图像集合。金字塔层级越高，则图像分辨率越低，即图像尺寸越小。4.1 节所获得初始低维信道矩阵，则可以视为图像金字塔顶端。目前常用的图像金字塔有高斯金字塔和拉普拉斯金字塔^[107]。

高斯金字塔是由金字塔底部的原始分辨率图像依次向下采样得到金字塔顶部的低分辨率图像。由于高斯金字塔在下采样的过程中会丢失图像的高频信息，而拉普拉斯金字塔则可以弥补该不足，其基本思想和残差学习相似，即在高斯金字塔的基础上，将金字塔每一层图像减去其上一层图像上采样后的图像得到图像残差，通过记录这种残差来完整恢复出金字塔每一层下采样前的图像。假设对于图像 I ，构建一个 S 层的高斯金字塔 $\mathcal{G}(I) = [I_0, I_1, \dots, I_S]$ ，其中 I_s ($0 \leq s \leq S$) 表示金字塔第 s 层图像， $I_0 = I$ 。拉普拉斯金字塔第 s 层可以表示为

$$\mathcal{L}_s(I) = \mathcal{G}_s(I) - u(\mathcal{G}_{s+1}(I)) = I_s - u(I_{s+1}) \quad (4-2)$$

其中， $u(I_{s+1})$ 表示 I_{s+1} 的上采样图像，金字塔最顶层的拉普拉斯金字塔系数即为该层的图像，即 $\mathcal{L}_S(I) = I_S$ 。

在拉普拉斯金字塔的图像缩放中，当得到 $\mathcal{L}_s(I)$ 和 I_{s+1} 时，则可以恢复第 s 层的图像

$$I_s = u(I_{s+1}) + \mathcal{L}_s(I) \quad (4-3)$$

目前拉普拉斯金字塔结构已被广泛应用于多种视觉任务中，包括纹理合成和语义分割等领域^[107]。受文献[57]启发，本文提出了基于拉普拉斯金字塔的级联信道重构模型，其中上采样操作 $u(\cdot)$ 和拉普拉斯系数 $\mathcal{L}_s(I)$ 均由神经网络实现，在此基础上嵌入了改进的宽激活残差模块来提高网络性能。

4.3 多尺度渐近式重建网络

图 4-1 为本文提出的 LapWRes，其中金字塔层数 $S = 3$ ，实际中可以根据具体的上采样

倍数进行调整。网络整体结构从横向上看可以分为两路分支——特征提取分支和信道重构分支，从纵向上看由多个重构块组成，在每个重构块内实现一次信道上采样，而两路分支网络则用于融合特征图的高频信息和低频信息。

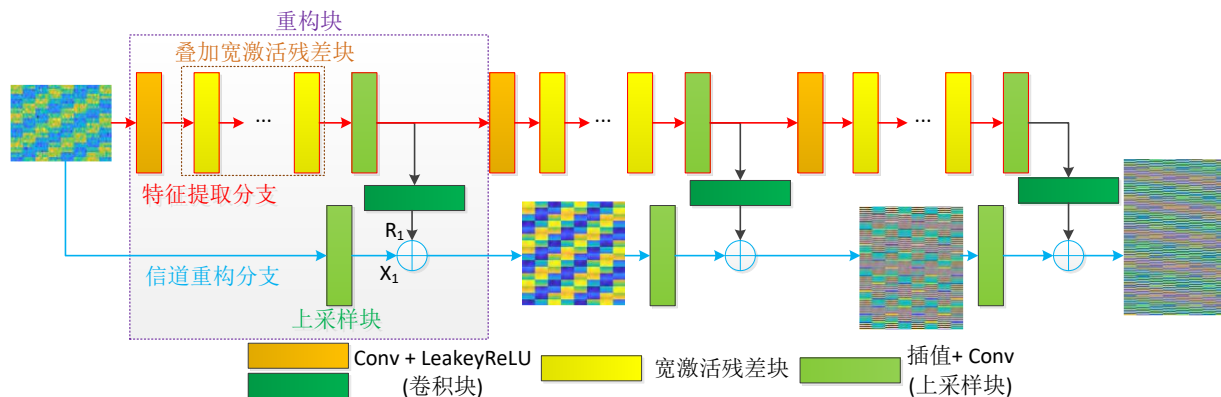


图 4-1 拉普拉斯宽残差网络模型

4.3.1 特征提取分支

LapSRN 在特征提取分支上采用堆叠的卷积层，随着卷积层的增加，其性能提升是有限的，且容易出现梯度消失或爆炸问题，如对于 8 倍上采样，5 层卷积层就可以得到最优的超分精度^[57]。本文则引入残差学习对于 LapSRN 的特征提取网络上进行改进。文献[91]认为最简单的提高 SR 网络性能的方式就是增加参数的数量。对于 CNN，一般来说通过增加网络深度或者网络宽度可以能够提升网络性能。假设网络层数为 B ，每一层的卷积核个数为 F ，则该网络大概要占 $O(BF)$ 内存和 $O(BF^2)$ 的参数。当计算资源有限时，增加网络深度比增加卷积核个数更能够最大化模型的容量^[91]。对于深层网络的设计，残差学习是目前的最稳定的网络架构，因此在最初的 EDSR 网络结构中连续堆叠了 32 个残差块。然而在后续的研究中，文献[92]发现当 EDSR 中堆叠的残差块个数达到一定程度，例如大于 7 个时，对于超分性能的改善非常有限，原因在于所堆叠的大量残差块虽然增强了网络对于数据的表征能力，但是这种深度网络中的表征能力并没有得到充分利用，因此提出了利用注意力机制对网络中特征图的不同通道加以不同的权重来增加不同通道间的特征差异性，从而提高网络表征能力的 RCAN 网络结构。由于 RCAN 的设计理念是去更好的利用深层网络的表征能力，因此它的的网络规模将远超过于相同场景下的 EDSR。对于通信系统的信道估计而言，受硬件设备与实时通信要求的限制，必须考虑网络性能与复杂度的平衡，因此本文结合上述工作提出了用于 RIS 级联信道估计的 LapWRes 结构。

LapWRes 的特征提取分支中采用残差结构提取特征，但不同于 EDSR 和 RCAN 中的残差结构，本文借鉴文献[58]提出的宽激活思路，将原来 EDSR 中的残差块修改为 WDSR (Wide Activation Super-Resolution) 架构中的漏斗型残差块，具体如图 4-2 所示，WDSR 残差块中，前端卷积层的卷积核个数大于后端卷积层。




图 4-2 不同残差块结构

SR 任务特点在于输入的低分辨率信息与输出的高分辨率信息具有相似性，如图像的低频成分。因此 SR 网络的设计需要尽量将原始信息从网络底层传递到网络的顶部，即保证网络拥有高效的信息流传递。然而，网络模型中的激活函数在给网络引入非线性的同时，也会妨碍原始信息流的在网络中的传递^[108]。针对这一不足，WDSR 通过在激活函数前设计具有更多卷积核的卷积层来扩展原始信息的特征图数量，从而降低激活函数对网络信息流传递的限制。为保证网络结构比较的公平性，即 WDSR 和 EDSR 中两种残差块的计算开销相同，如图 4-2 所示，由于 WDSR 提高了激活函数前第一个卷积层的卷积核数量，相应地就需要降低第二个卷积层的卷积核数量。假设残差块第一个卷积层的卷积核数量为 w_1 ，卷积核尺寸为 $k_1 \times k_1$ ，而第二个卷积层的卷积核数量为 w_2 ，卷积核尺寸为 $k_2 \times k_2$ 。对于 EDSR 中的残差块 $w_1 = w_2$ 并且假设 $k = k_1 = k_2$ ，每个残差块包含两个卷积层，因此一个残差块的参数为 $2w_1^2k^2$ 。而 WDSR 在激活函数前的卷积层引入扩展因子 r ，即 $\hat{w}_1 = r\hat{w}_2$ ，因此一个残差块的参数为 $2r\hat{w}_2^2k^2$ 。当输入数据的维度确定后，网络的计算复杂度是参数量的常数倍。因此，在本文的实验对比中，令 $\hat{w}_2 = w_2 / \sqrt{r}$ 去保证 LapWRes 与 EDSR 比较的公平性。

此外，许多工作已表明 BN 不适合用于 SR 任务，因为其会破坏原始的数据分布，而低分辨率图像和高分辨率图像有着相似的空间分布，因此在 EDSR 中不存在归一化操作。然而缺少归一化层，容易使得网络训练时梯度下降的不稳定。因为本文采用不改变的数据分布的权重归一化 (Weight Normalization, WN) 方法^[109]。WN 和 BN 一样都属于对神经网络参数重写，但是不同于 BN 对网络某一层输入数据进行归一化来获得规范化的特征尺度，WN 将网络权值 w 从其方向和范数两个方面进行解耦，即

$$w = \frac{g}{\|v\|} v \quad (4-4)$$

其中， $w \in \mathbb{R}^k$ 为网络原始权值向量， g 为参数标量， $v \in \mathbb{R}^k$ 为重参数化后的参数向量，则 $v / \|v\|$ 为 w 的单位方向向量。

将 w 分解为 g 和 v 后，网络训练过程中 w 的优化转化为对 g 和 v 的优化。令 L 表示损失函数， $\nabla_w L$ ， $\nabla_g L$ 和 $\nabla_v L$ 分别表示 L 对 w ， g 和 v 的梯度，则

$$\nabla_g L = \nabla_g w \cdot (\nabla_w L)^T = \frac{\nabla_w L \cdot v^T}{\|v\|} \quad (4-5)$$

$$\nabla_v L = \nabla_v w \cdot \nabla_w L = \frac{\partial \frac{g \cdot v}{\|v\|}}{\partial v} \cdot \nabla_w L = \frac{g \cdot \|v\|}{\|v\|^2} \cdot \nabla_w L - \frac{g \cdot v \cdot \frac{\partial \|v\|}{\partial v}}{\|v\|} \cdot \nabla_w L \quad (4-6)$$

因为

$$\frac{\partial \|v\|}{\partial v} = \frac{\partial (v^T \cdot v)^{0.5}}{\partial v} = 0.5 \cdot (v^T \cdot v)^{-0.5} \cdot \frac{\partial (v^T \cdot v)}{\partial v} = \frac{v}{\|v\|} \quad (4-7)$$

所以

$$\nabla_v L = \frac{g}{\|v\|} \cdot \nabla_w L - \frac{g \cdot \nabla_w L}{\|v\|^2} \cdot v = \frac{g}{\|v\|} \cdot M_w \cdot \nabla_w L \quad (4-8)$$

其中， $M_w = I - w \cdot w^T / \|w\|^2$ 是一个投影到权值向量 w 补空间的投影矩阵。

根据式 (4-8) 可以看到， $\nabla_v L$ 在原始权值梯度 $\nabla_w L$ 上以尺度 $g / \|v\|$ 进行了缩放以及将梯度在 M_w 上投影，这两个特征会稳定模型的训练并加速网络的收敛。WN 的性能与训练的样本量无关，适用于小批量数据训练，相较于 BN，WN 引入的噪声量更少，而且空间存储开销和时间开销更小，计算速度更快。此外，WN 的自稳定特性使得由 WN 规范化的网络接受相对较大的学习率。基于 SR 的信道估计方案对网络训练的初始学习率较为敏感，因此学习率往往被设置的较小去避免梯度爆炸，如文献[56]的学习率设置为 10^{-3} ，然而较小的学习率容易导致网络出现过拟合，因此通过使用 WN 可以允许网络超参数设置时提高初始学习率。

对于第 $s(1 \leq s \leq S)$ 个重构块的特征提取分支，假设重构块的输入为 $F_{s-1} \in \mathbb{R}^{M \times 2^{s-1} p \times C_{s-1}}$ ，其中 C_{s-1} 表示数据的通道数，当 $C_{s-1=0} = 2$ ，输入数据即为原始局部信道矩阵。每个重构块均包含 7 个相同 WDSR 残差块去提取数据特征，每个残差块的第一个卷积层宽度为 128，第二个卷积层宽度为 32，卷积核尺寸全部为 3×3 ，所有卷积层后面都经过 WN 进行权重归一化，激活函数均使用 LeakyReLU。最后使用一个上采样块得到高分辨率信道矩阵 $F_s \in \mathbb{R}^{M \times 2^s p \times C_s}$ ，每个上采样块由在 RIS 单元域维度的 2 倍最近邻插值和卷积层实现。

4.3.2 信道重构分支

在第 s 个重构块的信道重构分支，原始低分辨率图像通过一个上采样块来得到与高分辨率图共同低频成分 \mathbf{X}_s （即高斯金字塔中的输出 I_s ）。使用带有两个卷积核的卷积层将特征提取分支的输出数据 F_s 的通道数降低，将其作为高分辨率信道的高频成分 \mathbf{R}_s （即拉普拉斯金字塔中的残差 $\mathcal{L}_s(I)$ ）。使用残差学习方式将两幅特征图进行融合，得到期待的高级联信道矩阵，即 $\hat{\mathbf{H}}_i = \mathbf{X}_i + \mathbf{R}_i$ 。将多个不同尺度的重构块从小到大进行级联，则得到最终的渐近式级联信道重建网络。

采用多尺度监督学习将每个重构块的损失函数进行集成作为统一的损失函数，从而对每个重构块输出的不同尺度信道矩阵进行监督。由于 L1 损失函数在零值处不稳定，因此采用文献[57]提出的 Charbonnier 损失函数，其为 L1 损失的可微形式^[110]，可以表示为

$$\mathcal{L}(\bar{\mathbf{H}}, \hat{\mathbf{H}}) = \sum_{i=1}^I \rho(\bar{\mathbf{H}}_i - \hat{\mathbf{H}}_i) = \sum_{i=1}^I \rho(\bar{\mathbf{H}}_i - \mathbf{X}_i - \mathbf{R}_i) \quad (4-9)$$

其中， $\rho(x) = \sqrt{x^2 + \varepsilon^2}$ 为 Charbonnier 惩罚函数， ε 为正则化参数。

这种多尺度损失函数设计与深度监督学习思想相似^[111]，通过在网络的中间层施加约束正则化，使得网络以一种从粗到细的方式重构高维的级联信道矩阵。与此同时，LapWRes，每个重构块的中间输出也是可以利用的，通过简单的裁剪和分离网络结构，使得网络可以调整不同上采样倍数的信道重建。

4.4 实验结果与分析

在本章的通信系统仿真参数配置中，为更好地展示智能信道估计模型可以适用于不同的通信场景，相较于第三章，本章考虑一个室内毫米波通信系统模型，其 RIS 系统模型参数主要体现在 AP，RIS 和用户位置范围将一定程度缩小，并且路径损耗模型参数也将发生改变^[67,112]，通信环境中的散射体数量也不一样。此时路径损耗模型为 InH 场景，NLoS 分量信道参数 $n=3.19$ ， $b=0.06$ ， $\sigma=8.2$ dB， $f_0=24.2$ GHz；LoS 分量信道参数 $n=1.73$ ， $b=0$ ， $\sigma=3.02$ dB。仿真生成的信道矩阵样本个数为 30000，生成训练集时 SNR 范围为 $[-10, 5, \dots, 30]$ dB。网络训练的优化器设置及相关超参数与 3.5 节一样。定义 $r = p/N = 1/k$ 表示初始信道估计中激活的 RIS 反射单元数占总单元数的比例。由于 LS-ON/OFF 算法的导频开销等于打开的反射单元数，因此 r 越小，则导频开销越低。在不作特殊说明下，仿真实验中 $r = 1/8$ 。

图 4-3 将 LapWRes 与其他信道估计模型中所采用的 SR 网络进行了对比，包括 SRCNN^[47] 和 EDSR^[48] 以及本文所改进的基线模型 LapSRN^[57]，其中 SRCNN1 是对 SRCNN 做的改进，将 SRCNN 输入层的单步上采样修改为其他网络模型所采用的以 2 倍上采样因子的渐近采样，即在网络输入层使用 3 个上采样块。为了公平的比较，基于残差结构 LapWRes 和 EDSR 具有相同数量的残差块。由于原始 SRCNN 首先将输入数据进行单步插值上采样到完整级联信道矩阵维度，这种简单的预上采样处理方式引入了许多人为上采样误差，使得后续网络的恢复效果有限，并且直接输入高维数据将使得网络的计算复杂度增加。SRCNN1 选择以一定的上采样因子逐次上采样到高维，在一定程度上减少了输入数据的上采样误差，因此其性能优于 SRCNN，然而相对于将上采样模块放在网络后端的 EDSR，其性能存在差距。EDSR 通过大量的残差块首先提取输入数据的有效特征，然后进行上采样，可以提高重建精度，这种网络设计思路目前也被广泛应用于 SR 任务。本文所提出的 LapWRes 则将上述

的上采样位置进行进一步优化，即将上采样模块从低维到高维分散的嵌入于网络内部，同时引入多尺度监督学习来实现渐近重建。此外，由于已有的 LapSRN 采用简单的堆叠卷积层导致网络的特征提取能力有限，因此本文将宽激活残差块引入至 LapSRN 的特征提取分支形成 LapWRes 模型，仿真结果展现了 LapWRes 在所有 SNR 范围内均可以取得更好的 NMSE 性能。




图 4-3 不同网络模型的信道估计性能

图 4-4 展现了不同网络模型的训练收敛情况，其中纵坐标为所有训练样本的平均损失函数数值。对于基于多尺度监督的 LapSRN 和 LapWRes 取最后一级重构块的损失函数。从实验结果可以看到 SRCNN 的收敛性能最差，而 LapSRN 的收敛速度低于 EDSR，但是 LapWRes 收敛速度快于 EDSR，并且最终的收敛精度也最好。




图 4-4 不同网络的收敛速度

在初始信道估计中，所选中的 RIS 单元集合 \mathcal{P} 中单元数数量 p 越少，导频开销越低，但低分辨率信道 $H_{LS} \in \mathbb{C}^{M \times p}$ 的维度也越低，则需要上采样倍数越高，因此完整级联信道的重建误差更大。图 4-5 展现了在不同的打开单元数比例 r 下，LapWRes 的信道估计精度。本文的 LapWRes 基线模型包含三个重构块，每个重构块的上采样倍数设置为 2，则其匹配的 RIS 打开单元比例 $r=1/8$ 。当 r 更少时，则在第一个重构块中的特征提取分支和信道重构分支添加上采样块，如 $r=1/16(1/32)$ 时，则对应添加 1 (2) 个上采样块。相反地，当 r 更大时，如在删除一个重构块来降低采样倍数。从图 4-5 可以看到在初始信道估计中选择更少的反射单元时，信道估计精度会下降，但即使在很少的导频开销下，LapWRes 的仍然可以保持较满意的信道估计性能。




图 4-5 不同激活单元比例下信道估计性能

图 4-6 可视化了 LapWRes 从底层到高层的第 s 个重构块输出的第一个通道数据。




图 4-6 LapWRes 第 s 个重构块的输出

每一幅图像均代表级联信道矩阵的实部，其中第一行为真实的级联信道矩阵，第二行为 LapWRes 每个重构块输出的信道矩阵，从左到右，信道矩阵的分辨率不断提高，即信道维度 $M \times N/8 \rightarrow M \times N$ 。从视觉上比较两者可以看到 LapWRes 在无论是在小尺度上的低分辨率信道还是大尺度上的高分辨信道都可以恢复出贴近真实标签的级联信道矩阵。

4.5 小结

本章提出了一种基于多尺度监督的渐近式级联信道重建网络模型，首先介绍了低分率信道估计结果的获取以及数据集的设计方法，然后介绍了拉普拉斯金字塔作为网络模型设计的主体结构，最后详细介绍了网络的具体设计，包括特征提取分支中的宽激活残差结构和信道重构分支的多尺度损失函数。实验结果验证所提出的 LapWRes 相较于其他网络模型可以获得更好的信道估计性能，即使在很低的导频开销下也可以取得满意的性能。

第 5 章 基于深度压缩感知的级联信道估计方案

第四章提出了基于多尺度监督学习的级联信道估计模型,将信道估计分为基于 LS 算法的局部信道估计和基于 SR 网络的完整信道重建两步执行。虽然该方案可以在减少导频开销的同时提高保证信道估计精度,然而该设计方案依然存在三个不足,首先两步操作在一定程度上增加了信道估计流程的复杂度,也不利于模型的在线部署;其次初始信道估计结果的准确性在一定程度上会影响网络的性能;此外,在不同通信场景下当导频长度发生变化以后,由于输入数据维度发生变化,需要修改模型的部分网络层并重新训练。对于未来通用智能通信系统,更适合使用端到端的解决方案,即使用神经网络直接通过导频信号来估计出信道矩阵。因此,本章结合深度压缩感知思想提出了基于 ResU-Net 的级联信道估计,在减少导频开销的同时,还可以自适应不同的导频长度。

5.1 深度压缩感知

本文 2.2.2 节介绍了经典的稀疏信道估计方案,并分析了传统压缩感知算法应用于信道估计时普遍存在的两个问题:(1) 真实通信系统中的信号难以找到一个变换域中去实现严格精确的稀疏性;(2) 由于采用计算复杂度较高的迭代重建策略去求解欠定方程组的信道矩阵,既不能保证全局最优也难以满足真实通信系统所要求的实时信道估计,特别是对于信道相干时间较短的通信场景。这两点成为了压缩感知在无线信道估计应用中的主要瓶颈。得益于人工智能技术的发展,基于深度学习模型的压缩感知重建方案相较于传统算法展现了新的优势^[113]。通过利用大量数据去学习信号的内在结构,可以避免求解原始信号精确的显式稀疏性。与此同时,依靠图像处理单元(Graphics Processing Unit, GPU)硬件支持可以实现神经网络端到端的并行计算,提高了信号矩阵运算的求解效率,相对于传统算法的大量迭代运算,神经网络在线推理时的信号重建速度更快。

5.1.1 模型驱动信道估计

早期的深度压缩感知相关工作主要应用于图像领域,已有工作将该思想扩展到无线通信系统的物理层算法设计^[114,115],其中主要有两种建模思路—纯数据驱动和先验知识与数据混合驱动(该思路应用于通信领域时,被称之为模型驱动^[116],为表达简洁,因此后文将沿用模型驱动名称)。纯数据驱动模型与典型的黑盒深度学习模型类似,即完全依赖神经网络去学习观测数据特征实现原始信号重建。模型驱动则利用了信号的先验知识来确定了基本重建框架,然后再利用神经网络从训练数据学习该先验知识。而在通信领域,这些先验知

识往往来自于通信领域的数学模型及传统通信算法设计思路^[116]。

基于模型驱动的深度压缩感知方法已应用在 Massive MIMO 系统中信道估计中，文献 [114]首次利用基于学习降噪的近似消息传递(Learned Denoising-based Approximate Message Passing, LDAMP)实现波束域毫米波信道估计，基于上述基本理念，后续涌现出了更多模型驱动信道估计的相关工作^[117,118]。该类算法的整体设计思路也被称之为深层展开^[41]，是将传统压缩感知算法的复杂迭代过程近似替换成神经网络，其中将网络的每一层替代一次或多次迭代过程。此外，原始压缩感知算法在迭代过程中的关键参数，如 OMP 算法中的索引值，也可以用神经网络所学习到的参数代替^[118]。

模型驱动在提高估计精度的同时，也使算法具有一定的可解释性。但该方法的缺陷也是直观的，即算法底层框架仍然为传统的压缩感知重建，而将其参数迭代过程替换为深层神经网络，因此其带来的计算复杂度远大于传统算法和纯数据驱动的方案。因此本文采用纯数据驱动的深度压缩感知方案去实现 RIS 辅助通信系统的级联信道估计。

5.1.2 纯数据驱动信道估计

纯数据驱动的深度压缩感知模型不依赖于任何先验知识，即输入数据为观测矩阵，输出数据为信道矩阵的端到端模型。目前主流的深度压缩感知网络都分为两个部分^[113]，即前部分为线性映射的初始重构，后部分为非线性映射的深度重构，如图 5-1 所示。

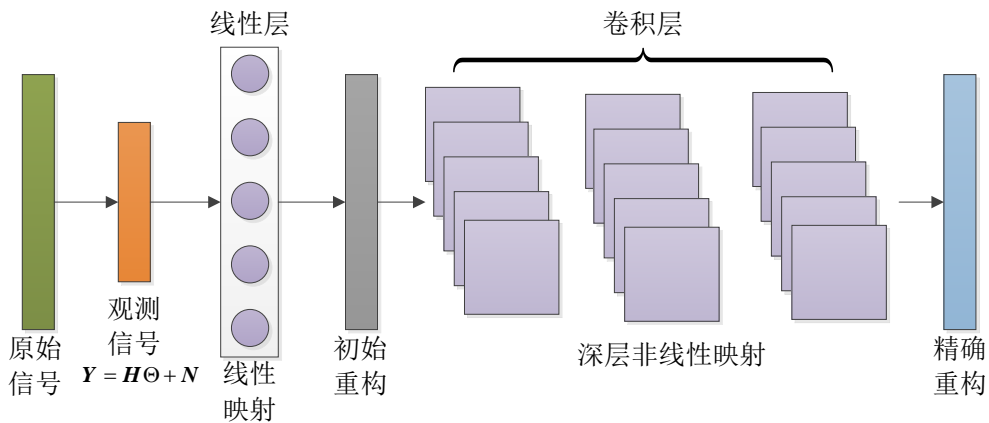


图 5-1 典型深度压缩感知网络模型

(a) 线性映射网络

假设压缩感知采样时间 T 远小于原始信号长度 N ，对于信道估计而言，即导频长度 $Q \ll N$ ，此时通过得到的观测信号 $\mathbf{Y} = \mathbf{H}\Theta + \mathbf{N} \in \mathbb{C}^{M \times Q}$ 去求解原始信道 $\mathbf{H} \in \mathbb{C}^{M \times N}$ 为一个 NP (Non-deterministic Polynomial) 难的欠定问题，但是利用神经网络可以估计一个初步的 $\mathbf{Y} \rightarrow \mathbf{H}$ 的映射矩阵。在第一部分，采用一个简单的线性映射神经网络 $F_1(\bullet)$ 去获得一个初步近似解 $\hat{\mathbf{H}}_1$

$$\hat{\mathbf{H}}_1 = F_1(\mathbf{W}_1, \bar{\mathbf{Y}}) = \mathbf{W}_1 \bar{\mathbf{Y}} \quad (5-1)$$

其中, $\mathbf{W}_1 \in \mathbb{C}^{N \times Q}$ 为一个线性映射矩阵, 即网络层的权值, $\bar{\mathbf{Y}} \in \mathbb{R}^{M \times Q \times 2}$ 为观测信号 \mathbf{Y} 的实数化表示。通过设计损失函数并采用梯度下降进行训练去学习一个线性映射函数使得 $\|\mathbf{H} - \mathbf{W}_1 \bar{\mathbf{Y}}\|_2$ 有最小误差, 即

$$L_1(\mathbf{W}_1) = \min_{\mathbf{W}_1 \in \mathbb{R}^{N \times Q}} (\|\mathbf{H} - \mathbf{W}_1 \bar{\mathbf{Y}}\|_2) \quad (5-2)$$

(b) 非线性映射网络

非线性映射网络则通过叠加大量的非线性映射网络层来进一步重构更加精确的信道矩阵。相对于第一部分常采用简单的线性映射层, 在该部分的网络结构设计则比较多样, 如文献[119]采用堆叠的卷积层和文献[120]采用残差结构等等。深度压缩感知网络整体的损失函数可以表示为

$$L(\mathbf{W}_1, \mathbf{W}_2) = \min_{\mathbf{W}_2} \|\mathbf{H} - F_2(F_1(\mathbf{W}_1, \bar{\mathbf{Y}}), \mathbf{W}_2)\|_2 \quad (5-3)$$

其中, $F_2(\bullet)$ 表示第二部分网络的非线性映射, \mathbf{W}_2 表示非线性映射权值。因此可以得到 $\hat{\mathbf{H}}_2 = F_2(F_1(\mathbf{W}_1, \bar{\mathbf{Y}}), \mathbf{W}_2)$ 为最终估计的级联信道矩阵。

5.2 相位量化与数据处理

在 RIS 辅助通信系统的信道估计阶段, 会按照先验约定的反射协议去配置 RIS 相位。由于硬件限制, RIS 在配置反射单元的相移时, 只能从有限数量的离散值中选择其相移, 因此在实际配置 RIS 相位时会产生量化噪声^[121]。假设相移的量化比特数为 b , 那么 RIS 可选择的离散相移集合为 $\{0, 2\pi/2^b, \dots, 2\pi(2^b - 1)/2^b\}$, 对于第 n 个 RIS 单元的相位量化噪声可以用均匀分布建模, 即 $\bar{\theta}_n \sim \mathcal{U}[-\pi/2^b, \pi/2^b]$ 。因此, RIS 真实的反射向量可以表示为 $\hat{\boldsymbol{\theta}} = [\beta_1 e^{j\hat{\theta}_1}, \beta_2 e^{j\hat{\theta}_2}, \dots, \beta_N e^{j\hat{\theta}_N}]$, 其中 $\hat{\theta}_i = \theta_i + \bar{\theta}_i (i=1, 2, \dots, N)$ 。此时基站的接收信号为

$$\mathbf{Y} = \mathbf{H} \hat{\boldsymbol{\theta}} + \mathbf{N} \quad (5-4)$$

其中, $\hat{\boldsymbol{\theta}} = \text{diag}(\hat{\boldsymbol{\theta}})$ 。

由于相位量化误差的影响, 基站接收的 RIS 反射信号发生改变, 基于数学模型的级联信道估计算法, 如 2.1.1 节所介绍的 LS 和 OMP 算法, 都需要使用反射矢量 $\hat{\theta}_i$ 的先验知识, 所以此时将引入新的信道估计误差, 特别是对于较低 RIS 反射相位量化。而基于端到端的深度学习的信道估计模型由于不需要显式的利用 $\hat{\theta}_i$ 求解信道信息, 因此可以在一定程度避免或者缓解相位量化误差的影响。

现有的以接收的导频信号作为输入数据的端到端信道估计网络中, 网络输入层神经元数量由导频长度决定。在设计训练数据集时, 往往固定了通信系统的导频长度, 因此在某个固定导频长度下所训练的网络模型, 在测试阶段时, 只能工作于与训练集相同的导频长度, 不适应不同的导频长度。事实上, 基于 SR 网络的信道估计同样存在该问题, 即当所

估计的低分辨率信道矩阵维度发生变化时，网络结构也需要进行调整去匹配不同的输入数据维度。实际通信系统中，对于不同的通信场景和性能要求，导频长度是可以进行实时调整。对于已有的信道估计模型，当我们针对不同的通信场景调整导频长度时，需要相应地改变输入层神经节点的数量以适应导频长度，然后重新训练信道估计模型，因此不能灵活的适用于不同的通信系统设置。

为实现信道估计模型可以兼容不同的导频长度，本文将纯数据驱动的深度压缩感知模型的线性映射网络层的权值 W_1 设计为固定的不可训练参数^[119]，该线性层的目的为使得不同输入数据维度都能匹配级联信道维度。根据 RIS 通信系统信号模型，线性层的网络权值固定为反射向量 Θ 的转置，即 $W_1 = \Theta^T$ 。实际上，权值固定的线性层的运算等价于常数矩阵乘法，因此本文直接将 $\tilde{Y} = Y\Theta^T \in \mathbb{C}^{M \times N}$ 作为网络的输入数据。利用该方法则可以针对不同长度的导频所导致的原始接收信号 Y 的维度变化时，但是网络输入数据的实数化表示 \bar{Y} 都可以保持相同维度为 $M \times N \times 2$ ，因此网络结构也可以保持不变。在本文后续的实验中 also 验证了固定导频训练的模型在测试时可以用于不同的导频长度。

5.3 ResU-Net 网络模型

针对 RIS 级联信道特性及 5.2 节数据预处理所带来的影响，本文提出了一种 ResU-Net 架构去实现端到端的级联信道重构。如图 5-2 所示，从总的网络模型来说，它具有两个特点：（1）采用编码器-解码器的网络骨架去挖掘输入数据潜在的稀疏性并抑制输入数据中所包含噪声；（2）结合 U-Net 和 ResNet 两种网络优势，设计长短跳跃连接去实现特征融合，形成 ResU-Net 结构。

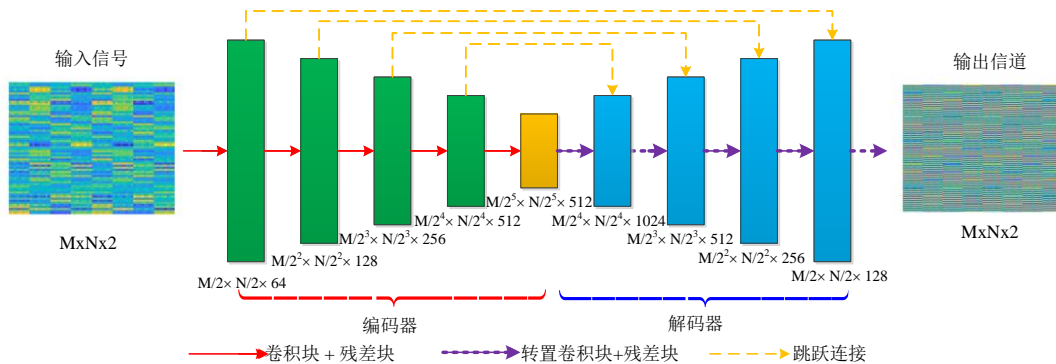


图 5-2 ResU-Net 网络模型

5.3.1 编码器-解码器架构

编码器-解码器架构作为一种经典的神经网络框架已经被广泛用于 NLP 领域的机器翻译^[122]，CV 领域的图像理解^[123]，以及通信领域的信道反馈和端到端通信^[10,128]。编码器-解码器架构实际上是在模拟人类对信息的认知过程，即编码器通过大量的网络层进行下采样

将输入数据提炼为一个低秩的向量或矩阵, 可以被认为是人类理解和记忆有效信息的过程, 并提炼信息通常会形成一个低秩的向量。相反地, 解码器则进行上采样将编码器的低秩信息恢复出来, 解码成目标数据, 可以被认为是人类回忆与运用有效信息的过程。

对于本文所研究的 RIS 信道估计而言, 在数据预处理阶段, 已预先通过数学运算提高导频矩阵的维数, 在一定程度上增加了网络的冗余特征, 与此同时数据维度越大也会增加相应的计算复杂度。因此, 本文应用了编码器-解码器架构, 首先使用编码器将输入数据压缩为一个尺寸较小但是通道数较多的特征图, 然后使用解码器从压缩特征图中恢复出所期待的级联信道矩阵。对于通信信道, 使用编码器来压缩输入数据, 不仅有利于提取有效特征, 而且在一定程度上也能抑制通信环境噪声及其他干扰, 如相位量化误差。

如图 5-2 所示, 在编码器阶段, 使用编码器块将尺寸为 $M \times N$ 的输入数据压缩为 $M/2^E \times N/2^E$, $E \leq \lfloor \log_2 M \rfloor$, 而在通道数上, 则从通道数为 2 的输入数据扩展到 512, 从而最终得到一个 $M/2^E \times N/2^E \times 512$ 的编码矩阵。每个编码器下采样块由一个卷积块和一个残差块组成。每个卷积块通过一个卷积核滑动步长为 2 的卷积层实现下采样, 然后后面跟随一个实例归一化层 (Instance Normalization, IN) 和 LeakyReLU 激活层。IN 被广泛应用于图像翻译与风格迁移领域^[125], 由于无线通信环境中信号传播的自然特性, 从图中可以看到输入数据和输出信道矩阵的风格是具有相似性的, 并且文献也提出了一种可以将信道估计视为图像翻译任务。IN 是 BN 的一个特例, BN 考虑整个批量数据的归一化, 即跨样本单通道, 容易造成每个样本所携带的独特细节丢失; 而 IN 只考虑单个样本的归一化, 即单样本单通道, 其适用于对每个样本中的单个像素点 (类比于信道矩阵的单个空间信息) 具有更高要求的场景。采用 IN 时, 式 (3-9) - (3-11) 中的 BN 表达式改写为

$$\mu_{b,i} = \frac{1}{WH} \sum_{w=1}^W \sum_{h=1}^H x_{b,w,h,i} \quad (5-5)$$

$$\sigma_{b,i}^2 = \frac{1}{WH} \sum_{w=1}^W \sum_{h=1}^H (x_{b,w,h,i} - \mu_{b,i})^2 \quad (5-6)$$

$$\hat{x}_{b,w,h,i} \leftarrow \frac{x_{b,w,h,i} - \mu_{b,i}}{\sqrt{\sigma_{b,i}^2 + \xi}} \quad (5-7)$$

编码器从外到内, 卷积层的滤波器个数为 $f_i^e = 64 \times 2^{i-1}$, ($i=1, 2, \dots, 4$), 其中 i 表示编码器块从外到内的序列号。综合信道估计精度和计算复杂度两部分考虑, 在设计 ResU-Net 的深度和宽度时, 即下采样块个数和卷积核个数时, 需要综合考虑网络的复杂度和信道估计精度。本文所提出的基线 ResU-Net 中, 编码器的深度 $E=5$ 且最大卷积核个数为 512, 即当 $i > 4$ 时, $f_i^e = 512$ 。每个编码块中的残差块的卷积核大小和个数与卷积块相同。残差块在残差主路径中包含两个卷积层, 而在跳跃连接中不存在卷积层, 为输入数据的恒等映射。


ResU-Net 的解码器的网络主体结构 with 编码器是对称的, 解码器块将维度为

$M/2^E \times N/2^E \times 512$ 的压缩特征恢复为 $M \times N \times 2$ ，其中每个解码器块由转置卷积块和残差块组成。每个转置卷积层的步长为 2 去进行特征图的上采样，滤波器个数 $f_i^d = 512/2^{i-1}$, ($i=1,2,\dots,4$)，其中 i 为解码器块从内到外的序号。由于在编码器的最后一层需要输出信道矩阵，因此最后一个转置卷积层的卷积核个数设置为 2，分别输出信道矩阵的实部和虚部。ResU-Net 编码器和解码器的数据维度变化被展示在图 5-2。

5.3.2 长短跳跃连接

在常规的编码器-解码器体系结构中，如自动编码器(Autoencoder, AE)，由于在编码器的特征压缩中存在有效信息损失，因此对于高维数据的重构性能受到限制。U-Net 是一种具有跳跃连接的独特编码器-解码器架构^[61]，虽然其最初被用于图像分割领域，但是 U-Net 高效的网络结构已被作为许多计算机任务的基线模型，包括图像去噪和重建，这启发了本文将 U-Net 应用于信道估计领域，通过在编码器和解码器之间设计跳跃连接，来弥补 AE 所固有的信息丢失缺陷。与此同时，在编码器和解码器内部还加入残差块^[62]，进一步增强特征信息的融合，将 U-Net 改进为 ResU-Net。

考虑到跳跃连接在 ResU-Net 中的相对位置关系，将前一种跳跃连接称之为长跳跃连接，其来自于原始 U-Net 结构；后一种跳跃连接称之为短跳跃连接，其来自于本文所引入的残差结构。两种跳跃连接具有不同的特征合并方式，如图 5-3 所示，其中短跳跃连接采用直接求和方式，长跳跃连接将特征图在通道数维度进行拼接。



(a) 编/解码器内部的短跳跃连接 (b) 编码器与解码器之间的长跳跃连接

图 5-3 两种特征融合方式的网络结构

短跳跃连接: 假设编码器第 i 个卷积块输出的特征图为 $F_i^c \in \mathbb{R}^{M/2^E \times N/2^E \times 2^{i+5}}$ ，其后面紧跟一个残差块形成短跳跃连接，假设第 i 个残差块的残差路径输出特征图为 $F_i^r \in \mathbb{R}^{M/2^E \times N/2^E \times 2^{i+5}}$ ，第 i 个编码块的输出为 $F_i^e = F_i^c + F_i^r \in \mathbb{R}^{M/2^E \times N/2^E \times 2^{i+5}}$ 。

长跳跃连接: 假设解码器第 i 个解码块输出的特征图为 $F_i^u = F_i^t + F_i^r \in \mathbb{R}^{M/2^{E-1} \times N/2^{E-1} \times 2^{10-i}}$ ，其中 F_i^t 和 F_i^r 分别代表转置卷积块和残差主路径的特征图。在输入第 $i+1$ 个上采样块之前，将其与编码器的第 i 个编码块的特征图进行拼接，即 $F_i^d = [F_i^e; F_i^u] \in \mathbb{R}^{M/2^{E-1} \times N/2^{E-1} \times 2^{11-i}}$ 。

长短跳跃连接采用特征拼接方式增加了数据维度来实现特征复用，来减少 ResU-Net

的编码器在特征压缩过程中的信息丢失。而短跳跃连接的特征求和方式，没有改变数据维度，但是可以改善网络层之间的信息流传递，可以使网络提取更高级的语义信息。一般来说，在选择特征融合方式时，特征求和用于两个特征图具有相似的数据分布或者是代表相似的语义信息，当两者数据分布不同，直接采用特征求和方式会破坏数据的分布，因此不利于后续网络的训练。而此时特征拼接采用增加通道数来保留两者所有的特征数据，增加了网络的容量，因此可以获得更好的性能。

在编码器和解码器内部中， $F_i^c - F_i^r$ 和 $F_i^l - F_i^r$ 是具有相似的语义信息，因此采用了特征求和的短跳跃连接。然而编码器与解码器之间的特征图， $F_i^e - F_i^d$ 所代表的语义信息是不同的，因此设计了特征拼接的长跳跃连接去融合不同尺度的语义信息，增强了解码器的重构能力。实际上，信道估计是一个低层次的回归任务，从浅层卷积层中提取的低层次语义信息可以帮助网络完成最终的任务。将长短跳跃连接进行结合，可以使得 ResU-Net 从输入数据中重构出更精确的级联信道，并加快网络收敛速度。

5.4 实验结果与分析

本节主要的仿真参数设置与 4.4 节相同，其中 RIS 的反射向量参考文献[126]的离散相移方案，从相移集合 $\{-1/\sqrt{N}, +1/\sqrt{N}\}$ 中随机选择。训练集导频长度固定为 $Q = 32$ ，SNR 范围为 $[0, 5, \dots, 30]$ dB，训练后的模型可以在不同的 SNR 和导频长度下进行测试。




图 5-4 不同算法的信道估计性能

图 5-4 比较了典型的传统算法和其他深度学习模型，其中 Oracle LS 为已知稀疏信道 \tilde{H} 支撑集的 OMP 算法。传统算法性能有限的原因已在 3.5 节进行了分析，而其他深度学习模型相对于 ResU-UNet 均存在不足。由于缺乏长跳跃连接，AE 的解码器无法使用编码器获得的低级特征，难以恢复准确的级联信道。而 U-Net 的编/解码器内部缺少短跳跃连接，因

此特征提取能力有限。ResU-Net 通过长跳跃连接融合不同尺度的特征图，并在编/解码器内部通过叠加残差块使学习到的特征更加精细。因此，ResU-Net 可以在少量的导频开销下获得优异的 NMSE 性能。

表 5-1 为不同算法下信道估计模块平均运行 200 次所统计的计算时间，所有算法运行硬件平台为 Xeon Silver 4210R 中央处理器 (Central Processing Unit, CPU) 和 Nvidia TITAN RTX GPU，软件平台为 Python3.7，其中使用 PyTorch 1.10 作为深度学习的开发框架。

表 5-1 不同算法的 CPU 和 GPU 的计算时间比较

算法	LS	Oracle LS	OMP	CNN	AE	U-Net	ResU-Net
导频长度	256(384)	64(128)	64(128)	32(···)	32(···)	32(···)	32(···)
CPU(ms)	22.5(30.3)	10.8(12.5)	1583(1812)	463	40.1	52.1	95.7
GPU(ms)	/	/	/	6.16	1.75	1.82	4.27

LS 估计器作为一种线性估计器，其运行速度本身是很快的，但是由于其需要的导频开销较大，从而增加了估计器的求逆运算时间。Oracle LS 算法由于假设已知 \mathbf{H} 的支撑集，可以快速执行，而基于迭代优化策略的 OMP 算法需要大量的计算时间。由于在 CNN 中所计算的特征图的大小始终保持在 $M \times N$ ，因此网络的计算复杂度和空间复杂度很高，运行时间最长。ResU-Net 相对于 AE 增加了跳跃连接，相对于 U-Net 增加了残差块，即引入了更多的网络层，因此计算复杂度相对较大。对于传统算法，LS 估计器和压缩感知算法的计算时间都随着导频长度的增加而增加。而对于深度学习模型，由于在数据预处理过程中，将输入数据的维数固定为 $M \times N \times 2$ ，因此对于不同模型的计算时间是相同的。与此同时，深度学习模型可以利用 GPU 的并行计算能力，加速神经网络的计算过程。相对于传统优化算法执行每次信道估计时需要重新迭代多次，而深度学习方案则可以直接使用已训练好的模型用于测试阶段每一次信道估计。值得注意的是，若当通信环境发生巨大变化时，深度学习模型可能需要进行在线微调以适应新的通信数据，文献[127]已提出相应的迁移学习方案。

图 5-5 比较了不同算法在不同导频长度下的 NMSE 性能，由于引入深度压缩感知结构对输入的接收信号进行了预处理，所有深度学习模型均仅在导频长度 $Q = 32$ 的数据集下训练，但是可以在直接在不同长度的导频下进行测试。随着导频长度的增加，压缩感知算法的性能会有所提高，但编码器-解码器网络架构在不同导频长度下的性能变化并不明显，在任意导频长度下，ResU-Net 均拥有最好的 NMSE 性能。

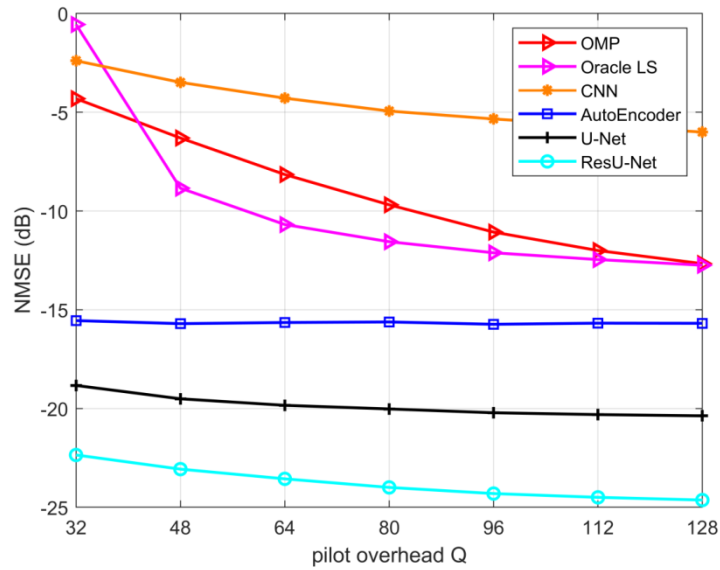


图 5-5 不同导频开销下信道估计性能

在图 5-6 中，基于数学模型的传统信道估计算法的 NMSE 性能在有量化误差的相移情况下显著降低。由于神经网络对输入数据的一些干扰（如量化噪声）具有鲁棒性，而编码器的下采样可以降低过拟合的风险，因此对于不同量化比特 b 的 RIS 反射相移，ResU-Net 优于 LS 和 Oracle LS 算法。

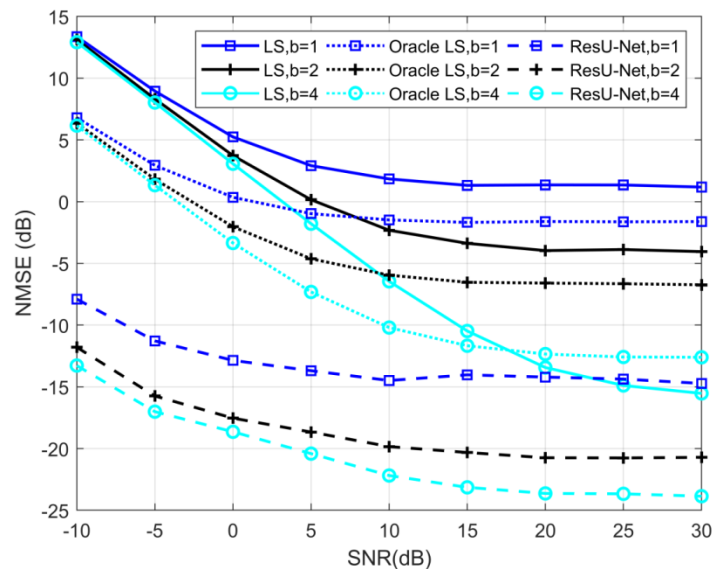


图 5-6 不同相位量化误差下的信道估计性能

5.5 本章小结

本章提出了一种通用的端到端信道估计网络模型，通过对导频数据进行简单的线性变换使得网络模型可以兼容不同长度的导频，避免网络重复训练，耗费计算资源。采用 U-Net 作为信道估计网络的骨架结构，通过将输入数据先压缩再重构来寻找信道的内在稀疏性并

一定程度上可以抑制噪声的影响。在 U-Net 的基础上，引入了残差结构形成了一种具有长短跳跃连接的编码器-解码器网络，即 ResU-Net，实验结果表明可以进一步提高估计精度，并且所提出的 ResU-Net 对于相位量化误差具有一定的鲁棒性。

结 语

研究总结

RIS 被认为是未来 6G 一种重要的绿色通信范式，而 AI 则为无线通信算法设计提供了新的思路。针对 RIS 信道存在多链路和维度高等特性，本文采用 AI 驱动的思想设计深度学习模型去实现 RIS 通信系统的信道估计，具体包括 3 个部分，如图 6-1 所示。

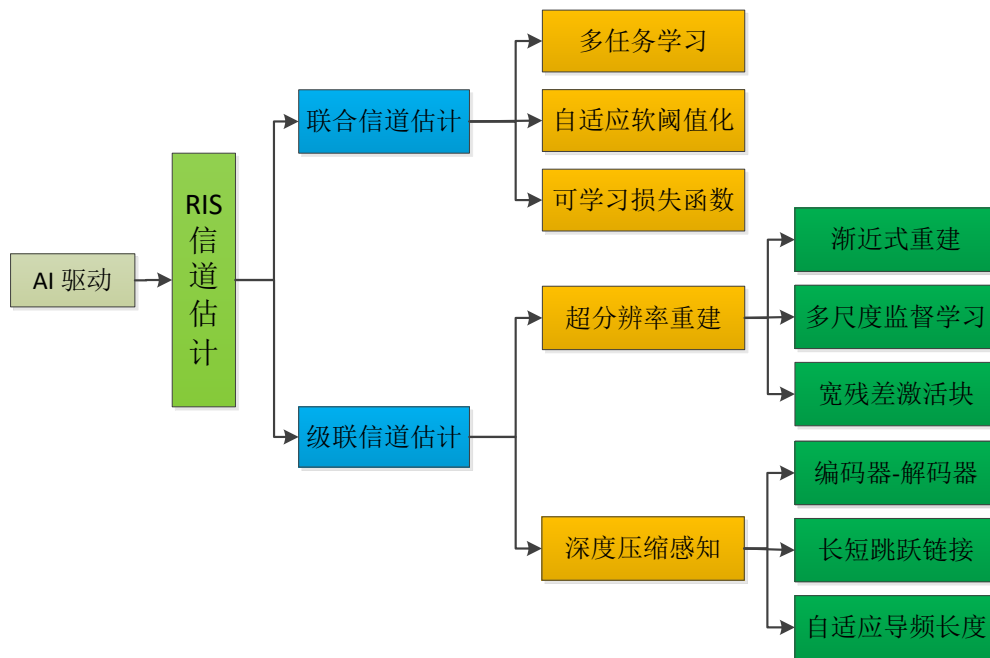


图 6-1 研究总结

(1) 当 RIS 承担传统中继角色去辅助无线通信系统时，通信系统存在多条通信链路包括直射链路和反射链路。由于无源 RIS 不能像传统中继配置射频链路来进行信号处理，因此信道估计需要由基站或者终端完成，且需要估计直射链路和反射链路两部分信道信息。目前已有的基于深度学习的解决方案为同时设计两个深度网络来分别执行直射信道估计和级联信道估计两个任务，这种方案会带来冗余的训练开销和存储开销。因此本文提出了基于 MTL 的联合信道估计方案，通过设计一个网络同时完成多条链路的信道估计任务。在所提出的方案中，引入了自适应的多任务联合损失函数来平衡两个任务的训练。此外，在网络的共享层引入融合了可学习的软阈值化的 DRSN 架构来改善低 SNR 的信道估计精度。

(2) 由于集成了大量反射单元的 RIS 导致级联信道呈现出高维特性，经典信道估计方案，如 LS 算法，将要求大量的导频开销。借鉴 CV 领域的 SR 网络和已有的基于 SR 的信道估计模型，本文提出了一种基于多尺度监督学习的渐近式信道重建网络 LapWRes，不同

于已有的单步单尺度重建网络，如 SRCNN 和 EDSR，LapWRes 以拉普拉斯金字塔为网络骨架搭建了级联了多个重构块的多尺度重建网络，在每个重构块中低维信道矩阵上采样到次高维信道，并执行设计损失函数进行监督。通过这种渐近式重建方式可以有效的提高信道估计度并加快网络收敛速度。

(3) 在第二项工作中，虽然可以有效的减少级联信道估计开销，然而网络模型要求以低维信道矩阵作为输入，这意味着需要额外设计算法去获得初始的低维信道矩阵。这种处理方式一定程度上增加了信道估计操作的复杂度，也难以兼容不同的通信场景。因此本文进一步提出了一种以编码器-解码器作为网络原型并包含长短跳跃连接的 ResU-Net 结构，通过对导频数据与 RIS 反射单元进行简单的矩阵运算，在大幅度减少导频开销的同时，还可以使得网络兼容不同的导频长度。当考虑实际情况下 RIS 反射向量往往存在量化误差时，基于数学模型信道估计方案的精度往往会明显降低，而 ResU-Net 可以保持更好的信道估计性能。

研究展望

根据目前 RIS 在无线通信系统的应用场景和发展潜力上看，本文所考虑的系统模型相对简单，而未来 RIS 在落地和普及阶段，信道可能会呈现出更加高维和动态特性，信道估计的难度将进一步提高，具体包括：

(1) 在未来实际工程应用中，由于 RIS 的覆盖范围有限，对于一些特定场景，如毫米波和太赫兹的区域性覆盖或者存在多个死角的通信环境，此时单个 RIS 可能无法满足通信性能要求，需要部署多个 RIS 或者分布式 RIS 来协作通信来弥补单个 RIS 的不足^[128,129]。图 6-2 为文献[129]考虑受室内环境限制—四边直角走廊，此时仅靠一个 RIS 无法完成将信号从 AP 反射到用户，此时需要配置两个 RIS 进行协同转发。

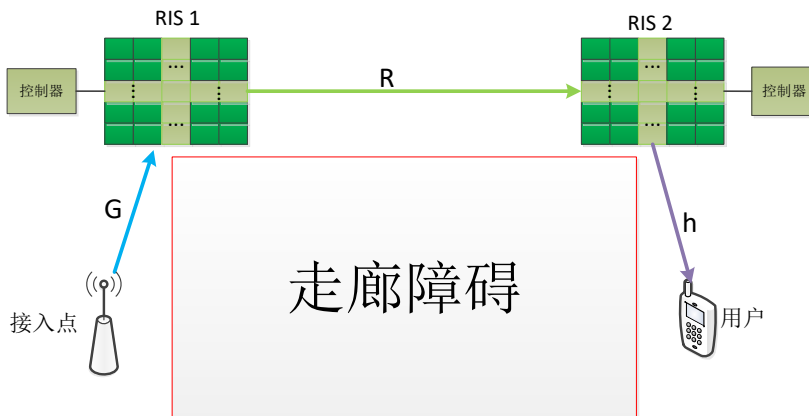


图 6-2 协作 RIS 通信系统

由于协作 RIS 反射链路包含了更多了反射通信链路，此时的信号模型将从式 (2-9) 变为 $Y = (G \text{diag}(\theta_1) R \text{diag}(\theta_2) h) s + W$ ，其中 θ_1 和 θ_2 分别表示 RIS 1 和 RIS 2 的反射相位。与

此同时,级联信道 \mathbf{H} 维度将从本文系统模型的 $\mathbf{H} \in \mathbb{C}^{M \times N}$ 提升至 $\check{\mathbf{H}} \in \mathbb{C}^{M \times N_1 \times N_2}$, 其中 N_1, N_2 分别 RIS 1 和 RIS 2 的单元数。对于神经网络而言,则加重了学习负担,因此需要设计网络模型容量更大,特征学习能力更强的网络结构。

(2) 若 RIS 服务的对象是处于高速移动状态的用户,则无线信道将出现严重的多普勒频移效应^[130],导致接收信号频率发生弥散。高速移动场景下 RIS 信号模型可以表示为 $\mathbf{Y} = e^{j2\pi f_d n T_c} (\mathbf{G} \text{diag}(\boldsymbol{\theta}_1) \mathbf{R} \text{diag}(\boldsymbol{\theta}_2) \mathbf{h}) \mathbf{s} + \mathbf{W}$, 其中 f_d 为多普勒频偏, T_c 为符号采样周期。用户移动速度越高,多普勒频移越大,信道呈现出快衰落,相干时间大幅度减短,此时需要更快地进行信道估计并设计更有针对性的导频帧结构^[131]。因此针对 RIS 辅助的高速移动通信场景,需要设计更加有效的信道估计算法。与此同时,已有文献还讨论了将 RIS 部署在一个移动平台上来辅助通信,如将 RIS 安装于无人机形成 360 度全方位增强通信^[132],此时多普勒频移将会扩展到从基站到 RIS 的通信链路。

因此,针对协作 RIS 系统的高维信道估计和高速场景下的快衰落信道估计,如何设计更高效的信道估计算法将是本文下一步研究方向,也是 RIS 未来在 6G 通信中实际落地的重要理论基础之一。

参考文献

- [1] 张平, 陶运铮, 张治. 5G 若干关键技术评述[J]. 通信学报, 2016, 37(07): 15-29.
- [2] Shafi M, Molisch A F, Smith P J, et al. 5G: A tutorial overview of standards, trials, challenges, deployment, and practice[J]. IEEE journal on selected areas in communications, 2017, 35(6): 1201-1221.
- [3] 张平, 牛凯, 田辉, 聂高峰, 秦晓琦, 戚琦, 张娇. 6G 移动通信技术展望[J]. 通信学报, 2019, 40(01): 141-148.
- [4] Mahapatra R, Nijssure Y, Kaddoum G, et al. Energy efficiency tradeoff mechanism towards wireless green communication: A survey[J]. IEEE Communications Surveys & Tutorials, 2015, 18(1): 686-705.
- [5] Liaskos C, Tsioliariidou A, Nie S, et al. On the network-layer modeling and configuration of programmable wireless environments[J]. IEEE/ACM Transactions on Networking, 2019, 27(4): 1696-1713.
- [6] 周儒雅, 唐万恺, 李潇, 金石. 基于可重构智能表面的移动通信简要综述[J]. 移动通信, 2020, 44(06): 63-69.
- [7] 朱政宇, 王梓暄, 徐金雷, 王忠勇, 王宁, 郝万明. 智能反射面辅助的未来无线通信: 现状与展望[J]. 航空学报, 2022, 43(02): 203-217.
- [8] Liu Y, Liu X, Mu X, et al. Reconfigurable intelligent surfaces: Principles and opportunities[J]. IEEE Communications Surveys & Tutorials, 2021, 23(3): 1546 - 1577.
- [9] Björnson E, Özdogan Ö, Larsson E G. Intelligent reflecting surface versus decode-and-forward: How large surfaces are needed to beat relaying?[J]. IEEE Wireless Communications Letters, 2019, 9(2): 244-248.
- [10] 尤肖虎, 张川, 谈晓思, 金石, 邬贺铨. 基于 AI 的 5G 技术——研究方向与范例[J]. 中国科学: 信息科学, 2018, 48(12): 1589-1602.
- [11] 张彤, 任奕璟, 闫实, 彭木根. 人工智能驱动的 6G 网络: 智慧内生[J]. 电信科学, 2020, 36(09): 14-22.
- [12] Dai L, Jiao R, Adachi F, et al. Deep learning for wireless communications: An emerging interdisciplinary paradigm[J]. IEEE Wireless Communications, 2020, 27(4): 133-139.
- [13] Zhang S, Li M, Jian M, et al. AIRIS: Artificial Intelligence Enhanced Signal Processing in Reconfigurable Intelligent Surface Communications[J]. arXiv preprint arXiv:2106.00171, 2021.

- [14]Elbir A M, Mishra K V. A survey of deep learning architectures for intelligent reflecting surfaces[J]. arXiv preprint arXiv:2009.02540, 2020.
- [15]Zheng B, You C, Mei W, et al. A survey on channel estimation and practical passive beamforming design for intelligent reflecting surface aided wireless communications[J]. arXiv preprint arXiv:2110.01292, 2021.
- [16]Mishra D, Johansson H. Channel estimation and low-complexity beamforming design for passive intelligent surface assisted MISO wireless energy transfer[C]// 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2019: 4659-4663.
- [17]Zheng B, Zhang R. Intelligent reflecting surface-enhanced OFDM: Channel estimation and reflection optimization[J]. IEEE Wireless Communications Letters, 2019, 9(4): 518-522.
- [18]Jensen T L, De Carvalho E. An optimal channel estimation scheme for intelligent reflecting surfaces based on a minimum variance unbiased estimator[C]// 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2020: 5000-5004.
- [19]Alwazani H, Kammoun A, Chaaban A, et al. Intelligent reflecting surface-assisted multi-user MISO communication: Channel estimation and beamforming design[J]. IEEE Open Journal of the Communications Society, 2020, 1: 661-680.
- [20]Kundu N K, McKay M R. Channel Estimation for Large Intelligent Surface Aided MISO Communications: From LMMSE to Deep Learning Solutions[J]. arXiv preprint arXiv:2011.07265, 2020.
- [21]Wei L, Huang C, Alexandropoulos G C, et al. Channel estimation for RIS-empowered multi-user MISO wireless communications[J]. IEEE Transactions on Communications, 2021, 69(6): 4144-4157.
- [22]de Araújo G T, De Almeida A L F, Boyer R. Channel estimation for intelligent reflecting surface assisted MIMO systems: A tensor modeling approach[J]. IEEE Journal of Selected Topics in Signal Processing, 2021, 15(3): 789-802.
- [23]Rong Y, Khandaker M R A, Xiang Y. Channel estimation of dual-hop MIMO relay system via parallel factor analysis[J]. IEEE Transactions on Wireless Communications, 2012, 11(6): 2224-2233.
- [24]Wu Q, Zhang S, Zheng B, et al. Intelligent reflecting surface-aided wireless communications: A tutorial[J]. IEEE Transactions on Communications, 2021, 69(5): 3313-3351.
- [25]Chen X, Shi J, Yang Z, et al. Low-complexity channel estimation for intelligent reflecting surface-enhanced massive MIMO[J]. IEEE Wireless Communications Letters, 2021, 10(5): 996-1000.

- [26] Jian M, Zhao Y. A modified off-grid sbl channel estimation and transmission strategy for ris-assisted wireless communication systems[C]//2020 International Wireless Communications and Mobile Computing (IWCMC). IEEE, 2020: 1848-1853.
- [27] Lin Y, Jin S, Matthaiou M, et al. Tensor-Based Algebraic Channel Estimation for Hybrid IRS-Assisted MIMO-OFDM[J]. IEEE Transactions on Wireless Communications, 2021, 20(6): 3770-3784.
- [28] Alexandropoulos G C, Vlachos E. A hardware architecture for reconfigurable intelligent surfaces with minimal active elements for explicit channel estimation[C]// 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2020: 9175-9179.
- [29] Gao Z, Dai L, Han S, et al. Compressive sensing techniques for next-generation wireless communications[J]. IEEE Wireless Communications, 2018, 25(3): 144-153.
- [30] 罗皓, 于秀兰, 张祖凡, 甘臣权. 5G 毫米波信道估计研究综述[J]. 电讯技术, 2021, 61(02): 254-262.
- [31] Chen J, Liang Y C, Cheng H V, et al. Channel estimation for reconfigurable intelligent surface aided multi-user MIMO systems[J]. arXiv preprint arXiv:1912.03619, 2019.
- [32] Wan Z, Gao Z, Alouini M S. Broadband channel estimation for intelligent reflecting surface aided mmWave massive MIMO systems[J]. arXiv preprint arXiv:2002.01629, 2020.
- [33] Wang P, Fang J, Duan H, et al. Compressed channel estimation for intelligent reflecting surface-assisted millimeter wave systems[J]. IEEE Signal Processing Letters, 2020, 27: 905-909.
- [34] Wei X, Shen D, Dai L. Channel Estimation for RIS Assisted Wireless Communications—Part II: An Improved Solution Based on Double-Structured Sparsity[J]. IEEE Communications Letters, 2021, 25(5): 1403-1407.
- [35] Liu H, Yuan X, Zhang Y J A. Matrix-calibration-based cascaded channel estimation for reconfigurable intelligent surface assisted multiuser MIMO[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(11): 2621-2636.
- [36] Ardah K, Gherekhloo S, de Almeida A L F, et al. TRICE: A channel estimation framework for RIS-aided millimeter-wave MIMO systems[J]. IEEE Signal Processing Letters, 2021, 28: 513-517.
- [37] He J, Wymeersch H, Juntti M. Channel estimation for RIS-aided mmWave MIMO systems via atomic norm minimization[J]. IEEE Transactions on Wireless Communications, 2021, 20(9): 5786-5797.
- [38] Lin T, Yu X, Zhu Y, et al. Channel estimation for intelligent reflecting surface-assisted

- millimeter wave MIMO systems[C]//GLOBECOM 2020-2020 IEEE Global Communications Conference. IEEE, 2020: 1-6.
- [39]Jia C, Cheng J, Gao H, et al. High-resolution channel estimation for intelligent reflecting surface-assisted mmwave communications[C]//2020 IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications. IEEE, 2020: 1-6.
- [40]桂冠, 王禹, 黄浩. 基于深度学习的物理层无线通信技术:机遇与挑战[J]. 通信学报, 2019, 40(02): 19-23.
- [41]李坤, 张静, 李潇, 金石. 人工智能辅助的信道估计最新研究进展[J]. 电信科学, 2020, 36(10): 46-55.
- [42]Elbir A M, Papazafeiropoulos A, Kourtessis P, et al. Deep channel learning for large intelligent surfaces aided mm-wave massive MIMO systems[J]. IEEE Wireless Communications Letters, 2020, 9(9): 1447-1451.
- [43]Elbir A M, Coleri S. Federated Learning for Channel Estimation in Conventional and IRS-Assisted Massive MIMO[J]. arXiv preprint arXiv:2008.10846, 2020.
- [44]C, Liu X, Ng D W K, et al. Deep residual learning for channel estimation in intelligent reflecting surface-assisted multi-user communications[J]. arXiv preprint arXiv:2009.01423, 2020.
- [45]Jin Y, Zhang J, Huang C, et al. Multiple Residual Dense Networks for Reconfigurable Intelligent Surfaces Cascaded Channel Estimation[J]. IEEE Transactions on Vehicular Technology, 2021, 71(2): 2134-2139.
- [46]Liu S, Gao Z, Zhang J, et al. Deep denoising neural network assisted compressive channel estimation for mmWave intelligent reflecting surfaces[J]. IEEE Transactions on Vehicular Technology, 2020, 69(8): 9223-9228.
- [47]Wang Y, Lu H, Sun H. Channel estimation in IRS-enhanced mmWave system with super-resolution network[J]. IEEE Communications Letters, 2021, 25(8): 2599-2603.
- [48]Jin Y, Zhang J, Zhang X, et al. Channel Estimation for Semi-Passive Reconfigurable Intelligent Surfaces With Enhanced Deep Residual Networks[J]. IEEE Transactions on Vehicular Technology, 2021, 70(10): 11083-11088.
- [49]Zhang S, Zhang S, Gao F, et al. Deep Learning Based RIS Channel Extrapolation with Element-grouping[J]. arXiv preprint arXiv:2105.06850, 2021.
- [50]Xu M, Zhang S, Ma J, et al. Deep Learning-based Time-varying Channel Estimation for RIS Assisted Communication[J]. IEEE Communications Letters, 2021, 26(1): 94-98.
- [51]Wei X, Shen D, Dai L. Channel estimation for RIS assisted wireless communications—part I: Fundamentals, solutions, and future opportunities[J]. IEEE Communications Letters, 2021,

- 25(5): 1398-1402.
- [52] Imani M F, Smith D R, del Hougne P. Perfect absorption in a metasurface-programmable complex scattering enclosure[J]. arXiv preprint arXiv:2003.01766, 2020.
- [53] Kendall A, Gal Y, Cipolla R. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 7482-7491.
- [54] Zhao M, Zhong S, Fu X, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2019, 16(7): 4681-4690.
- [55] Soltani M, Pourahmadi V, Mirzaei A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [56] Li L, Chen H, Chang H H, et al. Deep residual learning meets OFDM channel estimation[J]. IEEE Wireless Communications Letters, 2019, 9(5): 615-618.
- [57] Lai W S, Huang J B, Ahuja N, et al. Deep laplacian pyramid networks for fast and accurate super-resolution[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 624-632.
- [58] Yu J, Fan Y, Yang J, et al. Wide activation for efficient and accurate image super-resolution[J]. arXiv preprint arXiv:1808.08718, 2018.
- [59] Li D, Xu Y, Zhao M, et al. Knowledge-Driven Machine Learning and Applications in Wireless Communications[J]. IEEE Transactions on Cognitive Communications and Networking, 2021. DOI: 10.1109/TCCN.2021.3128597.
- [60] Mousavi A, Baraniuk R G. Learning to invert: Signal recovery via deep convolutional networks[C]//2017 IEEE international conference on acoustics, speech and signal processing (ICASSP). IEEE, 2017: 2272-2276.
- [61] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015: 234-241.
- [62] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [63] Hemadeh I A, Satyanarayana K, El-Hajjar M, et al. Millimeter-wave communications: Physical channel models, design considerations, antenna constructions, and link-budget[J]. IEEE Communications Surveys & Tutorials, 2017, 20(2): 870-913.
- [64] ETSI TR 138 901-2020, 5G. Study on channel model for frequencies from 0.5 to 100 GHz (V16.1.0; 3GPP TR 38.901 version 16.1.0 Release 16)[S].
- [65] Basar E, Yildirim I, Kilinc F. Indoor and outdoor physical channel modeling and efficient

- positioning for reconfigurable intelligent surfaces in mmWave bands[J]. IEEE Transactions on Communications, 2021, 69(12): 8600-8611.
- [66] Nayeri P, Yang F, Elsherbeni A Z. Reflectarray antennas: theory, designs, and applications[M]. Wiley, 2018.
- [67] Docomo N. ‘White paper on 5G channel model for bands up to 100 GHz[R]. Tech. Rep., 2016.[Online]. Available: <http://www.5gworkshops.com/5GCM.html>, 2016.
- [68] Rappaport T S, MacCartney G R, Samimi M K, et al. Wideband millimeter-wave propagation measurements and channel models for future wireless communication system design[J]. IEEE transactions on Communications, 2015, 63(9): 3029-3056.
- [69] Buzzi S, D'Andrea C. On clustered statistical MIMO millimeter wave channel simulation[J]. arXiv preprint arXiv:1604.00648, 2016.
- [70] El Ayach O, Rajagopal S, Abu-Surra S, et al. Spatially sparse precoding in millimeter wave MIMO systems[J]. IEEE transactions on wireless communications, 2014, 13(3): 1499-1513.
- [71] Balanis C A. Antenna theory: analysis and design[M]. John wiley & sons, 2015.
- [72] Samimi M K, Rappaport T S. Statistical channel model with multi-frequency and arbitrary antenna beamwidth for millimeter-wave outdoor communications[C]//2015 IEEE Globecom Workshops (GC Wkshps). IEEE, 2015: 1-7.
- [73] 弋浩凡, 官科, 何丹萍, 艾渤, 赖峥嵘, 钟章队. 太赫兹电波传播及信道特性[J]. 通信学报, 2022, 43(01): 34-48.
- [74] Donoho D L. Compressed sensing[J]. IEEE Transactions on information theory, 2006, 52(4): 1289-1306.
- [75] Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. IEEE Transactions on information theory, 2007, 53(12): 4655-4666.
- [76] Balevi E, Doshi A, Jalal A, et al. High dimensional channel estimation using deep generative networks[J]. IEEE Journal on Selected Areas in Communications, 2020, 39(1): 18-30.
- [77] Noriega L. Multilayer perceptron tutorial[M]. School of Computing. Staffordshire University, 2005.
- [78] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- [79] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(A02): 1-6.
- [80] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Advances in neural information processing systems. 2017: 5998-6008.
- [81] 刘紫燕, 马珊珊, 梁静, 朱明成, 袁磊. 注意力机制 CNN 的毫米波大规模 MIMO 系统信道估计算法[J]. 系统工程与电子技术, 2022, 44(01): 307-312.
- [82] Ye H, Li G Y, Juang B H. Power of deep learning for channel estimation and signal detection

- in OFDM systems[J]. *IEEE Wireless Communications Letters*, 2017, 7(1): 114-117.
- [83] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv preprint arXiv:1409.1556*, 2014.
- [84] Bai Q, Wang J, Zhang Y, et al. Deep learning-based channel estimation algorithm over time selective fading channels[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2019, 6(1): 125-134.
- [85] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. *Advances in neural information processing systems*, 2012, 25: 1097-1105.
- [86] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015: 3431-3440.
- [87] Zhang K, Zuo W, Chen Y, et al. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising[J]. *IEEE transactions on image processing*, 2017, 26(7): 3142-3155.
- [88] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks[C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016: 1646-1654.
- [89] Zhang K, Zuo W, Zhang L. FFDNet: Toward a fast and flexible solution for CNN-based image denoising[J]. *IEEE Transactions on Image Processing*, 2018, 27(9): 4608-4622.
- [90] Guo S, Yan Z, Zhang K, et al. Toward convolutional blind denoising of real photographs[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019: 1712-1722.
- [91] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]//*Proceedings of the IEEE conference on computer vision and pattern recognition workshops*. 2017: 136-144.
- [92] Zhang Y, Li K, Li K, et al. Image super-resolution using very deep residual channel attention networks[C]//*Proceedings of the European conference on computer vision (ECCV)*. 2018: 286-301.
- [93] Zhang Y, Yang Q. An overview of multi-task learning[J]. *National Science Review*, 2018, 5(1): 30-43.
- [94] Ruder S. An overview of multi-task learning in deep neural networks[J]. *arXiv preprint arXiv:1706.05098*, 2017.
- [95] Donoho D L. De-noising by soft-thresholding[J]. *IEEE transactions on information theory*, 1995, 41(3): 613-627.

- [96] Guo M H, Xu T X, Liu J J, et al. Attention Mechanisms in Computer Vision: A Survey[J]. arXiv preprint arXiv:2111.07624, 2021.
- [97] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 7132-7141.
- [98] Li X, Alkhateeb A, Tepedelenlioglu C. Generative adversarial estimation of channel covariance in vehicular millimeter wave systems[C]//2018 52nd Asilomar Conference on Signals, Systems, and Computers. IEEE, 2018: 1572-1576.
- [99] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//International conference on machine learning. PMLR, 2015: 448-456.
- [100] Xiao H, Tian W, Liu W, et al. ChannelGAN: Deep Learning based Channel Modeling and Generating[J]. IEEE Wireless Communications Letters, 2022, 11(3): 650-654.
- [101] Balevi E, Andrews J G. Wideband channel estimation with a generative adversarial network[J]. IEEE Transactions on Wireless Communications, 2021, 20(5): 3049-3060.
- [102] Chen L H, Bampis C G, Li Z, et al. Perceptually optimizing deep image compression[J]. arXiv preprint arXiv:2007.02711, 2020.
- [103] Zhang R, Isola P, Efros A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 586-595.
- [104] Zhao H, Gallo O, Frosio I, et al. Loss functions for image restoration with neural networks[J]. IEEE Transactions on computational imaging, 2016, 3(1): 47-57.
- [105] Kingma D P, Ba J. Adam: A method for stochastic optimization[J]. arXiv preprint arXiv:1412.6980, 2014.
- [106] Zheng B, You C, Zhang R. Intelligent reflecting surface assisted multi-user OFDMA: Channel estimation and training design[J]. IEEE Transactions on Wireless Communications, 2020, 19(12): 8315-8329.
- [107] Ghiasi G, Fowlkes C C. Laplacian pyramid reconstruction and refinement for semantic segmentation[C]//European conference on computer vision. Springer, Cham, 2016: 519-534.
- [108] Sandler M, Howard A, Zhu M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 4510-4520.
- [109] Salimans T, Kingma D P. Weight normalization: A simple reparameterization to accelerate training of deep neural networks[J]. Advances in neural information processing systems, 2016, 29: 901-909.

- [110] Bruhn A, Weickert J, Schnörr C. Lucas/Kanade meets Horn/Schunck: Combining local and global optic flow methods[J]. *International journal of computer vision*, 2005, 61(3): 211-231.
- [111] Wang L, Lee C Y, Tu Z, et al. Training deeper convolutional networks with deep supervision[J]. *arXiv preprint arXiv:1505.02496*, 2015.
- [112] Haneda K, Zhang J, Tan L, et al. 5G 3GPP-like channel models for outdoor urban microcellular and macrocellular environments[C]//2016 IEEE 83rd vehicular technology conference (VTC spring). IEEE, 2016: 1-7.
- [113] 曾春艳, 叶佳翔, 王志锋, 武明虎. 深度学习框架下压缩感知重建算法综述[J]. *计算机工程与应用*, 2019, 55(17): 1-8+19.
- [114] He H, Wen C K, Jin S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems[J]. *IEEE Wireless Communications Letters*, 2018, 7(5): 852-855.
- [115] 黄源, 何怡刚, 吴裕庭, 程彤彤, 隋永波, 宁曙光. 基于深度学习的压缩感知 FDD 大规模 MIMO 系统稀疏信道估计算法[J]. *通信学报*, 2021, 42(08): 61-69.
- [116] He H, Jin S, Wen C K, et al. Model-driven deep learning for physical layer communications[J]. *IEEE Wireless Communications*, 2019, 26(5): 77-83.
- [117] Ma X, Gao Z, Gao F, et al. Model-driven deep learning based channel estimation and feedback for millimeter-wave massive hybrid MIMO systems[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(8): 2388-2406.
- [118] Ma W, Qi C, Zhang Z, et al. Deep learning for compressed sensing based channel estimation in millimeter wave massive mimo[C]//2019 11th International Conference on Wireless Communications and Signal Processing (WCSP). IEEE, 2019: 1-6
- [119] Mousavi A, Baraniuk R G. Learning to invert: signal recovery via deep convolutional networks[C]//International Conference on Acoustics, Speech and Signal Processing, 2017: 2272-2276.
- [120] Yao H T, Dai F, Zhang D M, et al. DR2-Net: deep residual reconstruction network for image compressive sensing[C]// IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2017: 451-462.
- [121] Badiu M A, Coon J P. Communication through a large reflecting surface with phase errors[J]. *IEEE Wireless Communications Letters*, 2019, 9(2): 184-188.
- [122] 李亚超, 熊德意, 张民. 神经机器翻译综述[J]. *计算机学报*, 2018, 41(12): 2734-2755.
- [123] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. *自动化学报*, 2016,

- 42(9): 1300-1312.
- [124] 陈慕涵, 郭佳佳, 李潇, 等. 基于深度学习的大规模 MIMO 信道状态信息反馈[J]. 物联网学报, 2020, 4(1): 33-44.
- [125] Ulyanov D, Vedaldi A, Lempitsky V. Instance normalization: The missing ingredient for fast stylization[J]. arXiv preprint arXiv:1607.08022, 2016.
- [126] Wu Q, Zhang R. Beamforming optimization for wireless network aided by intelligent reflecting surface with discrete phase shifts[J]. IEEE Transactions on Communications, 2019, 68(3): 1838-1851.
- [127] Alves W, Correa I, González-Prelcic N, et al. Deep transfer learning for site-specific channel estimation in low-resolution mmWave MIMO[J]. IEEE Wireless Communications Letters, 2021, 10(7): 1424-1428.
- [128] Zheng B, You C, Zhang R. Double-IRS assisted multi-user MIMO: Cooperative passive beamforming design[J]. IEEE Transactions on Wireless Communications, 2021, 20(7): 4513-4526.
- [129] You C, Zheng B, Zhang R. Wireless communication via double IRS: Channel estimation and passive beamforming designs[J]. IEEE Wireless Communications Letters, 2020, 10(2): 431-435.
- [130] Huang Z, Zheng B, Zhang R. Transforming Fading Channel From Fast to Slow: IRS-Assisted High-Mobility Communication[J]. arXiv e-prints, 2020: arXiv: 2011.03147.
- [131] 李然, 武刚, 李岩. 智能反射表面无线通信的信道估计与帧结构设计[J]. 无线电通信技术, 2021, 47(01): 36-43.
- [132] Shang B, Shafin R, Liu L. UAV swarm-enabled aerial reconfigurable intelligent surface[J]. arXiv preprint arXiv:2103.06361, 2021.

攻读硕士学位期间主要研究成果

发表的学术论文：

- [1] Xie W, **Xiao J**, Zhu P, et al. Deep Compressed Sensing-Based Cascaded Channel Estimation for RIS-Aided Communication Systems[J]. IEEE Wireless Communications Letters, 2022, 11(4): 846-850. (中科院二区)
- [2] Xie W, **Xiao J**, Liang Y, et al. Multi-Task Learning-Based Channel Estimation for RIS Assisted Multi-User Communication Systems[J], IEEE Communication Letters. 2022, 26(3): 557-581. (中科院三区)
- [3] Xie W, **Xiao J**, Yang J, et al. Deep Learning-Based Modulation Detection for NOMA Systems[J], KSII Transactions on Internet and Information Systems. 2021, 15: 658-672. (中科院四区)

学科竞赛奖励：

- [1] “华为杯”第十七届中国研究生数学建模竞赛三等奖
- [2] “华为杯”第十八届中国研究生数学建模竞赛二等奖
- [3] 湖南省第四届研究生数学建模竞赛二等奖
- [4] 湖南省第五届研究生数学建模竞赛三等奖
- [5] IMT2020 第二届无线通信 AI 大赛 AI-based Channel Estimation 赛道第四名

专利成果：

- [1] [实用新型] 一种多功能智能通信基站. 公开号：CN209949438U, 排名第二

参与的科研项目：

- [1] 湖南省自然科学基金，《空时编码在 MIMO-NOMA 系统中的研究与应用》，排名第五，2020
- [2] 湖南省研究生科研创新项目，《基于空间调制 MISO-NOMA 系统物理层安全研究》，排名第二，2020

致 谢

就像云儿来了又去，风的誓言不断的许。

谢老师，天地自由任沙鸥，经卷不休劝顽猴。大三时第一次见到谢老师的小娃，那时他还在老师的搀扶下蹒跚学步，现在已经可以和谢老师在羽毛球场上互有来回了。余性本劣似顽猴，老师也给了我最大的自由，无论是大的科研选题亦或是日常的实验室学习，亦师亦友亦无所求。如今回头才发现，我的科研启蒙来自于谢老师在企业工作了十年的基带信号处理领域的宝贵经验。与此同时，感谢物联网与信号处理实验室的朱鹏老师，余超老师和彭鑫老师三年来的指导，也感谢本科毕业设计指导老师吴健辉教授的升学推荐。

谢同学，幸得比邻总如云，画眉深浅有人询。初入大学时，便听同乡吐槽：大学什么都不好，就学长学姐好！余深以为是，但后来觉得应该扩展为—同学好。研究生期间最自豪的一点就是我们实验室一直保持着轻松，有趣和积极的氛围。聚会时，吃肉喝酒，峡谷乱斗；组会时，东拼西凑，不分夜昼。只希望再会时，杯子碰在一起，都是梦想成真的声音。最后，感谢师兄胡胜，廖俭武，谢聪；同窗杨锦霞，陈威平，徐瑞任，韩政珂；及所有师弟师妹，对我研究生期间学习和生活上的帮助。

谢家人，来时至亲知隔生，重著衣裳静赴死。在南湖旁待的七年里，外公，爷爷，外婆先后去世，如今依然清晰记得和他们的最后一面，外公尤甚。明年父亲就 60 岁了，母亲 56 岁了，而我在 24 岁的年纪却还没对家庭承担起应尽的责任。求学以来一直在向家庭索取，甚至经常对家人逞骄。如今本该担当的年纪，却对未来彷徨不行，唯愿家人平安健康，能等到我有出息。

谢你，从此无心爱良夜，任它明月下西楼。

就像影子若即若离，南湖的故事还在继续。

2022.01.31 除夕
于盘龙村 棉花湾

答辩委员会成员

	姓 名	职 称	工 作 单 位
答辩主席	杨 亮	教 授	湖南大学
答辩委员会 成员	李宏民	教 授	湖南理工学院
	彭 鑫	教 授	湖南理工学院
	李春来	教 授	湖南理工学院
	朱 鹏	副教授	湖南理工学院
答辩秘书	王冬霞	讲 师	湖南理工学院