

基于深度学习的智能超表面通信信道估计研究

答辩人：肖健

指导老师：谢文武 副教授

学科方向：信息与通信工程

信息科学与工程学院

2022年5月



答辩主要内容

1 研究背景与意义

2 研究主要内容

2.1 基于多任务学习的联合信道估计

2.2 基于多尺度监督学习的渐近信道重建

2.3 基于深度压缩感知的级联信道估计

3 研究总结与展望

1 研究背景与意义

6G 愿景

1G → 5G (1980s-2020)

现代移动通信的发展就是如何更好的适应无线信道的随机性和不确定性



通过增加电磁波覆盖强度改善终端用户体验和增加数据速率

· 天线越来越多——Massive MIMO

· 基站越来越密集——超密集网络

· 频段越来越高——Sub-6G/毫米波/太赫兹



6G (2020-2030)

关键性能指标进一步提升^[1]

· 绿色通信 (双碳战略)

· 万物互联——万物智联

· 内生节能和内生智能

功耗瓶颈

5G基站平均功耗是4G基站的3倍

覆盖范围却只有4G的1/3左右

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

2018年4G电费：240亿元—> 5G电费：2160亿元；2019三大运营商利润之和为1384亿元^[2]

[1] 《6G无线智能无处不在的关键驱动与研究挑战》,6G 白皮书, 2019, 芬兰



1 研究背景与意义

智能超表面 (RIS)


电磁超材料在通信中的应用 (Metamaterial—>Metasurface)

信息超材料单元的
物理基础

三极管、MEMS、石墨烯、
温敏器件、光敏器件



普通环境漫反射



硬件成本低——信息超材料[3] (PIN管, 变容管)
运行成本低——低功耗, 近似无源 (控制电路)
部署成本低——二维轻薄表面

一种新的通信范式——从适应无线环境到重构无线环境[2]

[2] Liaskos C, Nie S, Tsiolaridou A, et al. A new wireless communication paradigm through software-controlled metasurfaces[J]. IEEE Communications Magazine, 2018, 56(9): 162-169.

1 研究背景与意义

智能超表面通信信道估计

RIS信号模型

$$\cdot Y = (G \text{diag}(\theta)h + d)s + W = (H\Theta + d)s + W \quad (1)$$

· θ 表示RIS单元的反射系数, $H = G \text{diag}(h) \in \mathbb{C}^{M \times N}$ 表示级联信道(基站-RIS-用户)

优化目标: 设计最优的 θ 使得通信容量最大

$$\max_{\theta} \|H\Theta + d\|^2 \quad s.t. |\theta_n| = 1, n = 1, \dots, N \quad (2)$$

信道估计: 根据 Y 求得级联信道 H 和直射信道 d

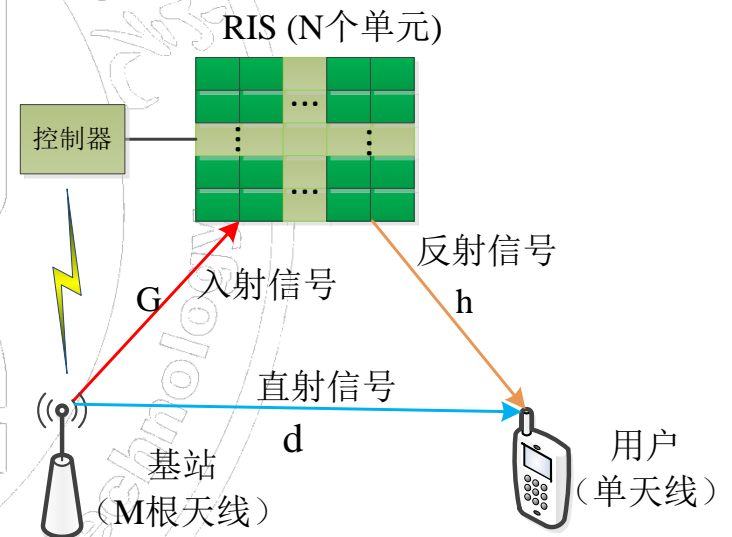
基于导频的最小二乘估计

$$Y = H\Theta \rightarrow \hat{H} = (\Theta^H \Theta)^{-1} \Theta^H Y, \quad \text{Req: } Q \geq N \quad (3)$$


RIS信道估计难点

RIS不具备信号处理功能—信道估计只能在终端执行

RIS单元数 N 较多—级联信道维度高, 导频开销 Q 大



基于AI模型设计一个端到端的广义信道估计器^[3] ($Y \rightarrow H$)



[3] Dai L, Jiao R, Adachi F, et al. Deep Learning for Wireless Communications: An Emerging Interdisciplinary Paradigm[J]. IEEE Communications Magazine, 2020.

2 研究主要内容

2.1 基于多任务学习的联合信道估计方案

研究动机

传统两阶段信道估计:

1. 关闭超表面所有单元, 估计直射信道: N_d 个时隙
2. 打开所有单元, 从接收到的信号中减去直射信号, 估计级联信道: N_c 个时隙

该方法存在的缺点

1. 时隙开销: $N_c + N_d$
2. 能量开销: 控制器需要频繁打开和关闭反射单元
3. 误差传播: 直射信道估计误差会蔓延到级联信道估计

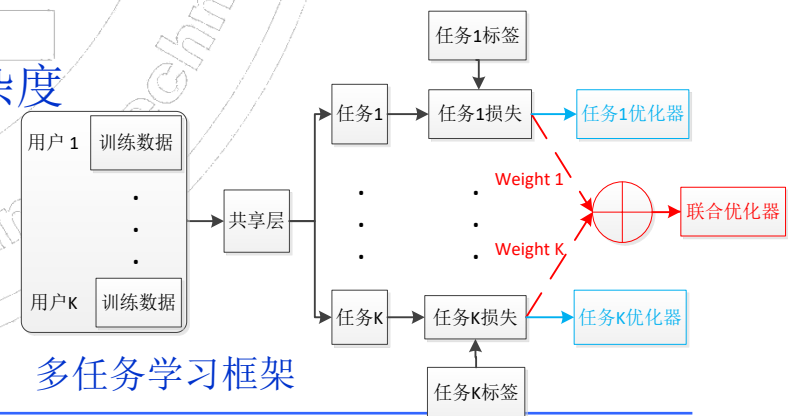
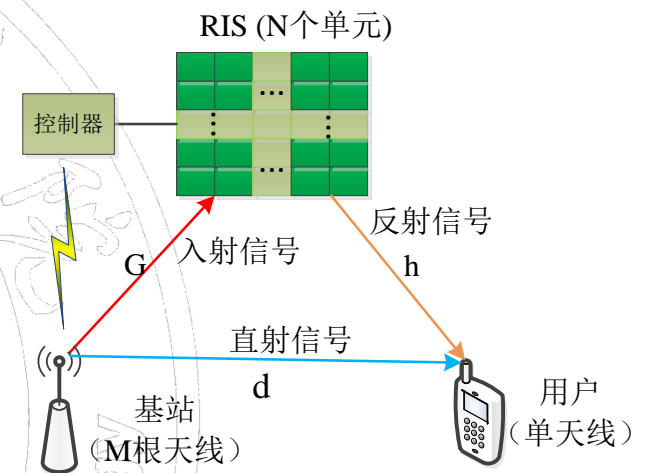
单任务学习 (STL) —— 两个独立的神经网络分别估计直射信道和级联信道^[4]

研究思路

一个网络解决两个信道估计 —— 降低计算和存储复杂度

多任务学习 (MTL)

- 网络底层共享 —— 公用知识库
- 网络高层独立 —— 专用知识
- 具有更好的泛化能力



多任务学习框架

[4] 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.

2 研究主要内容

2.1 基于多任务学习的联合信道估计方案

软阈值化^[5]

信号去噪—根据阈值进行特征收缩

$$y = \begin{cases} x - \tau & x > \tau \\ 0 & -\tau \leq x \leq \tau \\ x + \tau & x < -\tau \end{cases}$$

如何确定一个合适的阈值 τ

注意力机制


受人类视觉更关注重要区域启发
对于神经网络中的特征图

$$\mathbf{F} \in \mathbb{R}^{F_C \times M \times N}$$

评估各个特征通道 F_C 的重要程度
赋予各个特征通道合适的权重

利用神经网络设计滤波器

网络根据输入数据自适应学习一个阈值 τ
设计跳跃连接保留原始数据特征



通道注意力残差块 (RSBU-CW)



2 研究主要内容

2.1 基于多任务学习的联合信道估计方案

仿真参数设置

通信链路仿真平台：MATLAB2018a，深度学习开发平台：Pytorch 1.0

信道建模：遵循3GPP标准，5G毫米波信道模型^[6]


数据集设置：基站天线数：64，RIS单元数：256，用户数：6

网络超参数：训练周期数100，批量处理数64，优化器Adam


仿真结果

评价指标—归一化均方误差 (NMSE) $NMSE = E[\|(\hat{\mathbf{H}}_k - \mathbf{H}_k)\|_F^2 / \|\mathbf{H}_k\|_F^2]$

直射信道估计性能



级联信道估计性能



不同网络模型训练开销

算法	MTL	STL-ON	STL-OFF
参数量(K)	316.55	204+278	204x2
内存(MB)	1.21	0.78+1.06	0.78x2
运算次数(G)	3.28	3.06+2.63	3.06+0.012

MTL相对于传统算法可以获得更高的估计精度，相对于STL的训练开销更低

[6] 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.

2 研究主要内容

2.2 基于多尺度监督学习的渐近式信道估计方案


·系统模型—只考虑级联信道

$$y_t = G \text{diag}(\theta_t) h s_t + w_t = (H\Theta_t) s_t + w_t$$

研究动机—减少导频开销

研究思路


超分辨重建 (SR) 思想



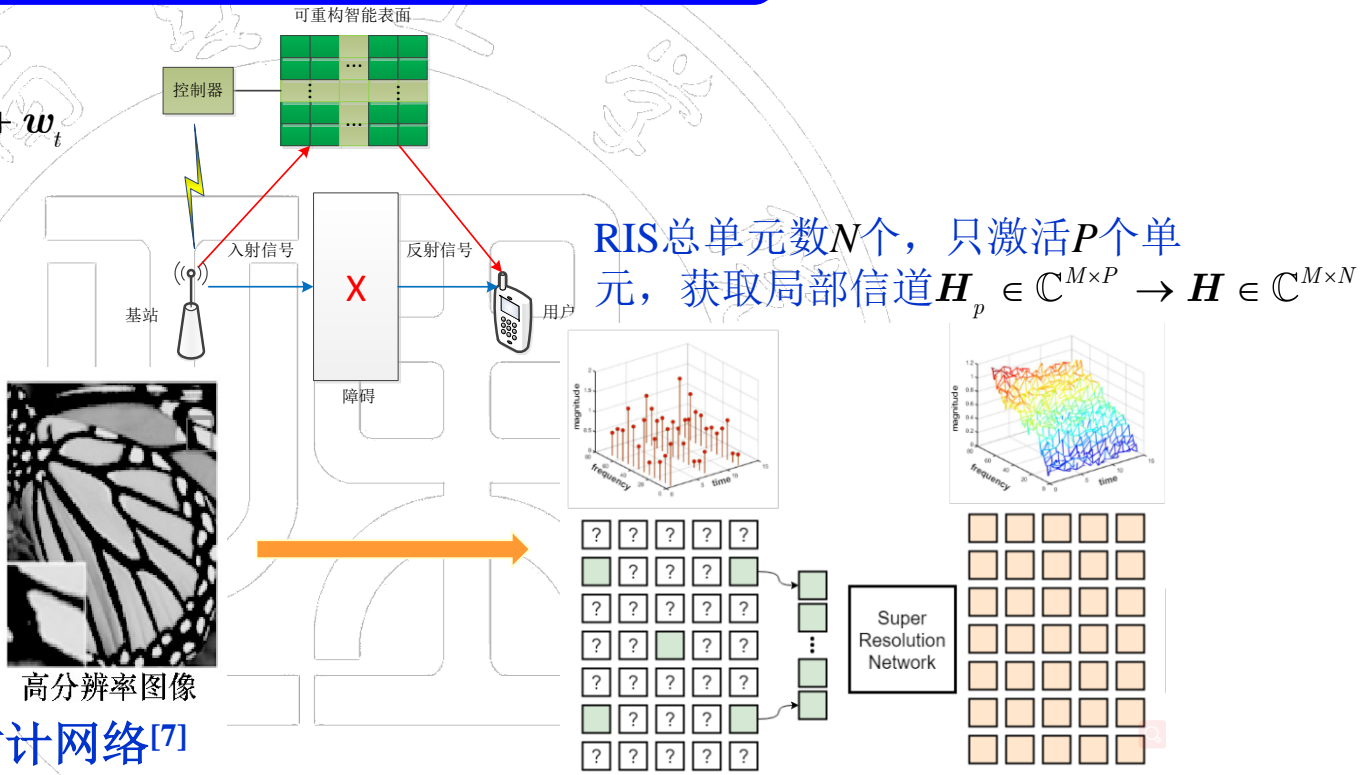
低分辨率图像

高分辨率图像

·已有工作所设计的SR信道估计网络^[7]



单步上采样层置于网络前端或后端^[7]
 前端：初始重构误差太大
 后端：高上采样倍数性能受限



RIS总单元数 N 个，只激活 P 个单元，获取局部信道 $H_p \in \mathbb{C}^{M \times P} \rightarrow H \in \mathbb{C}^{M \times N}$

[7] 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.

2 研究主要内容

2.2 基于多尺度监督学习的渐近式信道估计方案

拉普拉斯宽残差网络 (LapWRes)

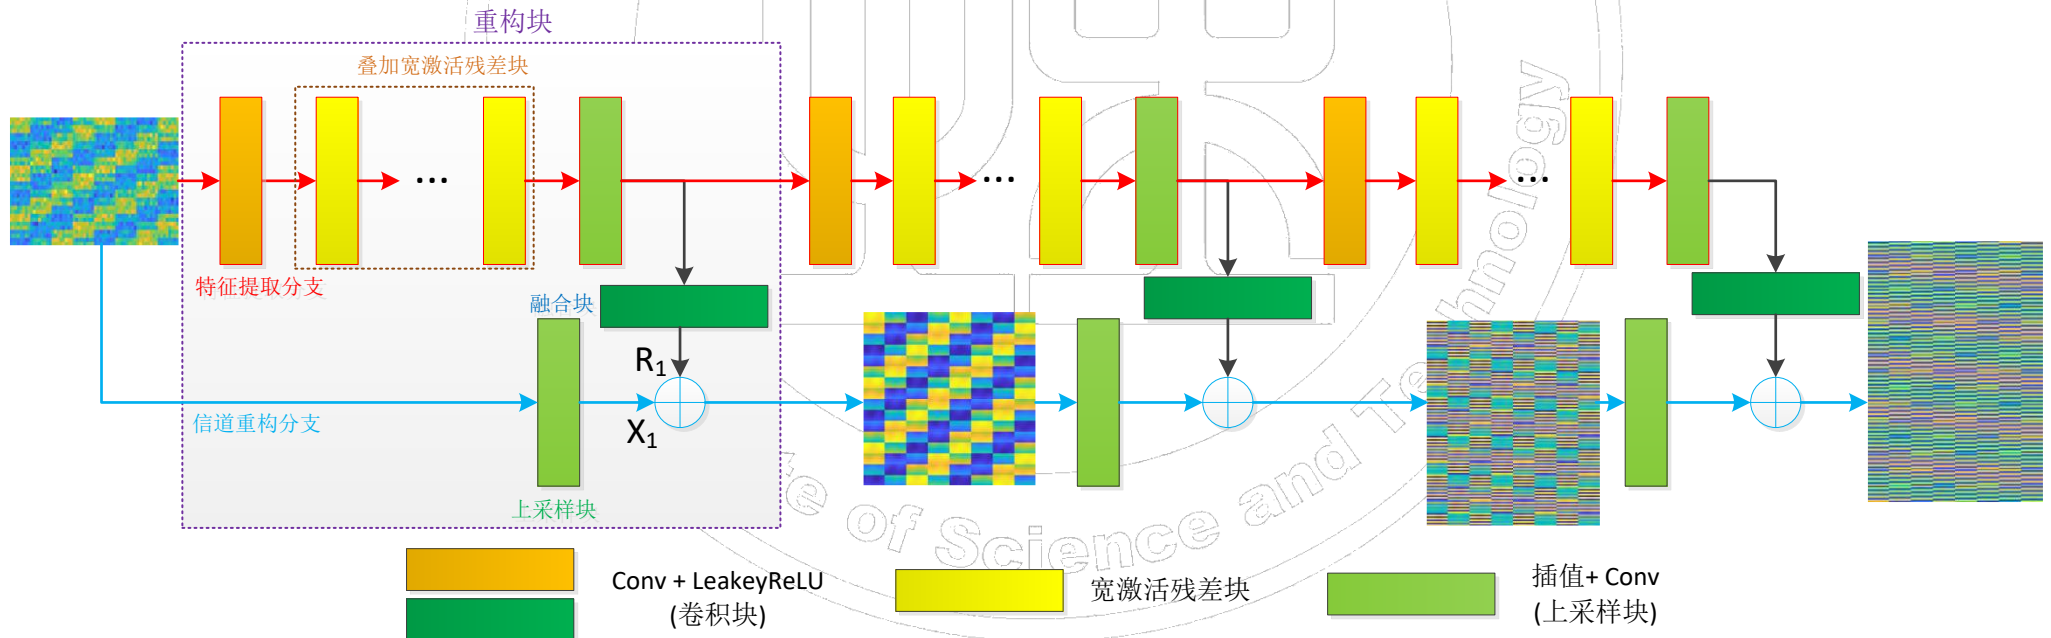
拉普拉斯金字塔[8]

横向：分为多个不同尺度的信道重构块——渐近式重建

纵向：特征提取分支和信道重构分支

特征提取分支由多个宽激活残差块组成，提取信道的高频信息 R_i

信道重构分支将信道低频信息 X_i 与高频信息进行融合，即 $\hat{H}_i = X_i + R_i$



[8]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.

2 研究主要内容


2.2 基于多尺度监督学习的渐近式信道估计方案

多尺度损失函数


$$\mathcal{L}(H, \hat{H}; \theta) = \sum_{i=1}^I \rho(H_s^{(i)} - \hat{H}_s^{(i)}) = \sum_{i=1}^I \rho((H_s^{(i)} - L_s^{(i)}) - R_s^{(i)})$$

其中, $\rho(x) = \sqrt{x^2 + \varepsilon^2}$ 为Charbonnier惩罚函数, L1损失的可微形式

仿真结果



不同网络信道估计精度比较
LapWRes具有更高的信道估计精度



不同网络收敛速度比较
LapWRes具有更快的收敛速度

2 研究主要内容

2.3 基于深度压缩感知的级联信道估计方案

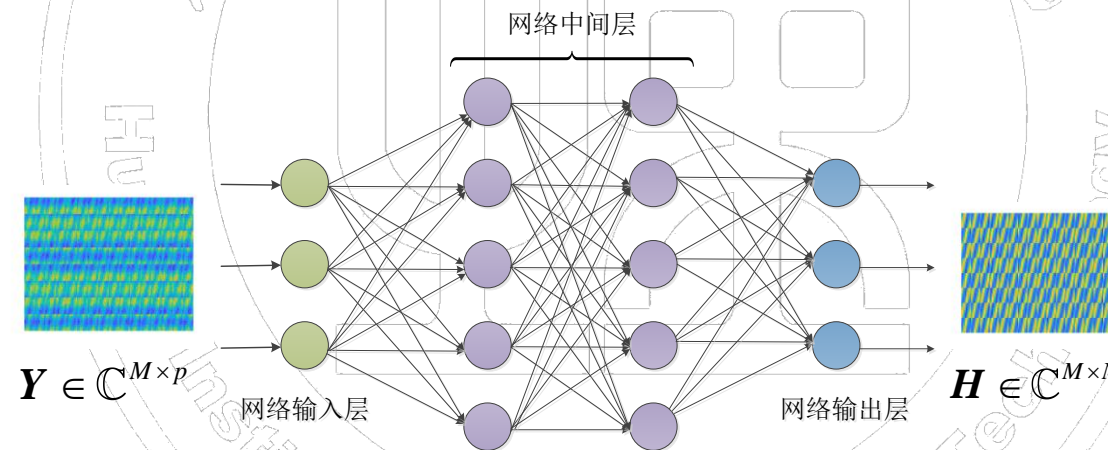
研究动机

基于SR（预处理）的信道估计方案缺点

需要首先获取低维信道作为输入——增加信道估计复杂度，初始低维信道需要保证一定精度

基于端到端信道估计模型缺点（ $Y \rightarrow H$ ）

对于静态神经网络，输入层节点需要匹配导频信号维度，无法自适应不同通信场景下的导频长度



基于数学模型的信道估计方案缺点

需要RIS反射相位先验，然而完美配置相位是不存在的^[9]（量化误差，硬件损伤）

LS算法 $\hat{H} = (\Theta^H \Theta)^{-1} \Theta^H Y$ B比特相位量化 $\left\{ 0, \frac{2\pi}{2^B}, \dots, (2^B - 1) \frac{2\pi}{2^B} \right\}$ 相位噪声 $\bar{\theta}_n \sim \mathcal{U} \left[\frac{-\pi}{2^B}, \frac{\pi}{2^B} \right]$

[9] 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.

2 硕士阶段研究情况

2.3 基于深度压缩感知的级联信道估计方案

基于压缩感知的信道估计


对于信号模型 $Y = H\Theta + W, Y \in \mathbb{C}^{M \times T}, \Theta \in \mathbb{C}^{N \times T}, W \in \mathbb{C}^{M \times T}$

$$\hat{H} = (\Theta^H \Theta)^{-1} \Theta^H Y, \text{ Req: } T \geq N$$


设计变化域 φ , 使得 $\tilde{H} = \varphi H$ 只有少量非零值^[10]

$$\min_{\tilde{H}} \|\tilde{H}\|_p \quad \text{s.t.} \quad \|Y - \varphi \tilde{H} \Theta\|_p \leq \xi$$

信道稀疏度不确定性, NP难问题



The spatial channel (non-sparse)



The angular channel (sparse)

深度压缩感知

线性映射网络——获得初步解, 无需满秩约束

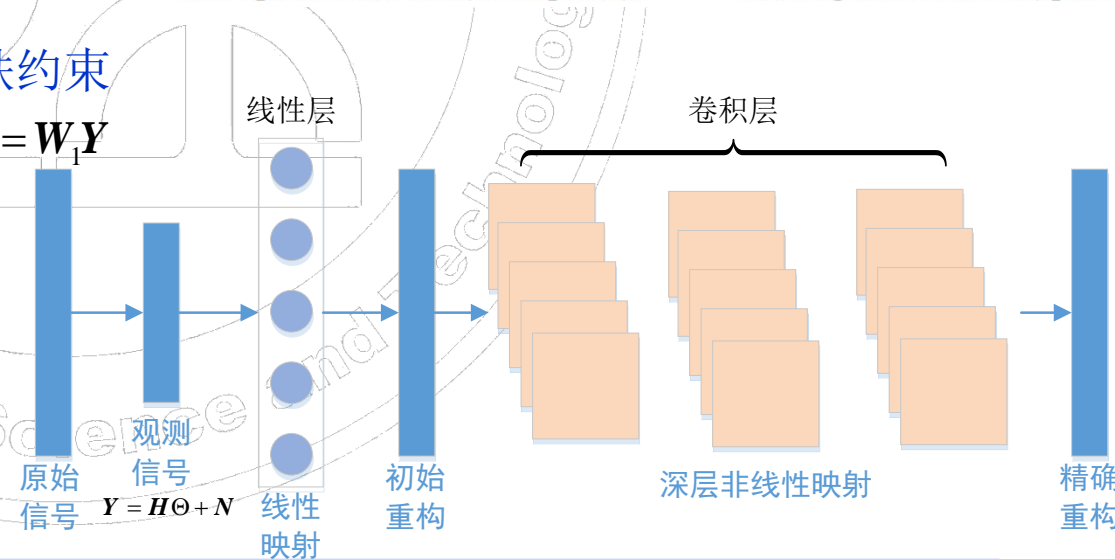
$$L_1(W_1) = \min_{W_1 \in \mathbb{R}^{N \times Q}} (\|H - W_1 Y\|_2) \rightarrow \hat{H}_1 = F_1(W_1, Y) = W_1 Y$$

$W_1 \in \mathbb{C}^{N \times Q}$ 为线性映射矩阵 (神经网络权值)

非线性映射网络——获取精确信道值

$$L_2(W_1, W_2) = \min_{W_2} \|H - F_2(F_1(W_1, Y), W_2)\|_2$$

W_2 为非线性映射矩阵权值



[10] Wei X, Shen D, Dai L. Channel Estimation for RIS Assisted Wireless Communications: Part I -- Fundamentals, Solutions, and Future Opportunities[J]. 2021.

2 研究主要内容

2.3 基于深度压缩感知的级联信道估计方案

·数据处理——兼容不同的导频长度

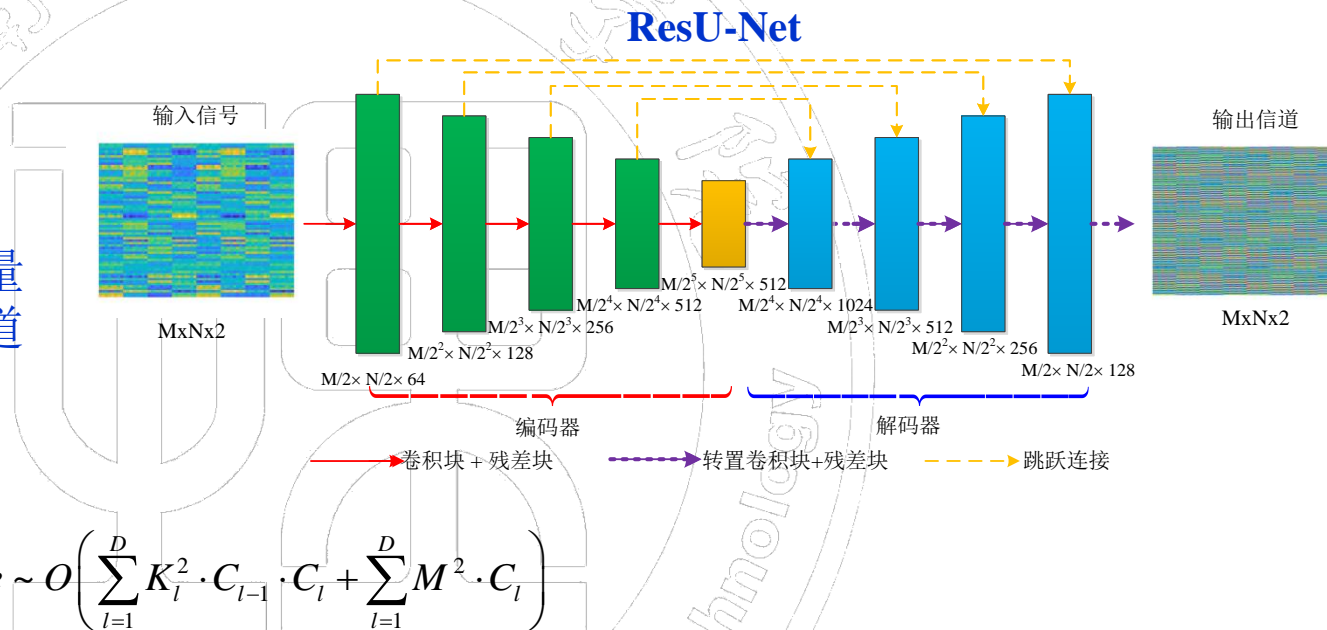
$$\bar{Y} = Y\Theta^T \in \mathbb{C}^{M \times N}$$

网络模型设计

编码器-解码器结构

编码器—压缩输入为特征向量
 解码器—从特征向量重构信道
 探索信道隐藏的稀疏性，
 抑制数据噪声干扰，
 减少计算/空间复杂度，

$$Time \sim O\left(\sum_{l=1}^D M_l^2 \cdot K_l^2 \cdot C_{l-1} \cdot C_l\right) \quad Space \sim O\left(\sum_{l=1}^D K_l^2 \cdot C_{l-1} \cdot C_l + \sum_{l=1}^D M^2 \cdot C_l\right)$$




跳跃连接——特征融合

长跳跃连接（拼接）^[10]——编码器与解码器之间

融合不同尺度语义信息

短跳跃连接（相加）——编/解码器内部

增加网络特征提取能力



[10] 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.




2 研究主要内容

2.3 基于深度压缩感知的级联信道估计方案

·仿真结果

不同算法信道估计性能



相较于传统算法和其他网络模型，在较少的导频开销下，ResU-Net可以取得更好的信道估计精度。

相对于压缩感知算法，ResU-Net的计算速度更快，且可以利用GPU并行计算来提高计算效率。

不同算法运行时间 (CPU—Xeon Silver 4210R, GPU—Nvidia TITAN RTX GPU)

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




2 研究主要内容

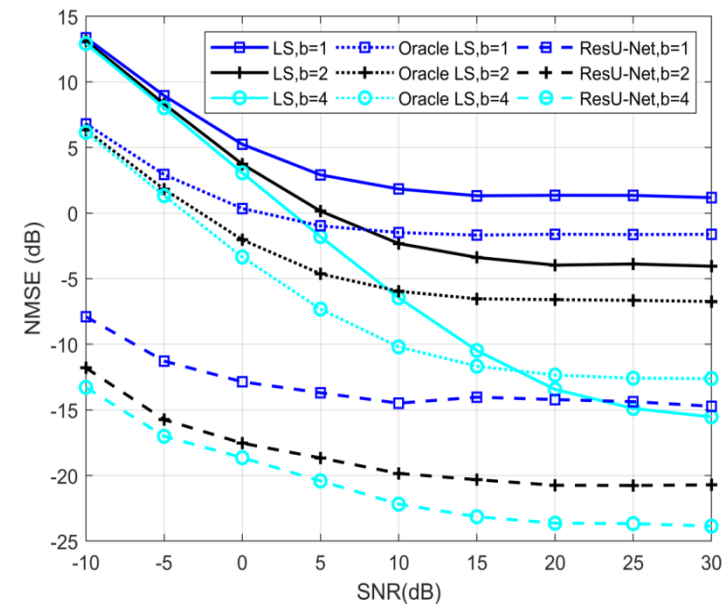
2.3 基于深度压缩感知的级联信道估计方案

·仿真结果

不同导频开销下信道估计性能



不同相位量化比特下信道估计性能



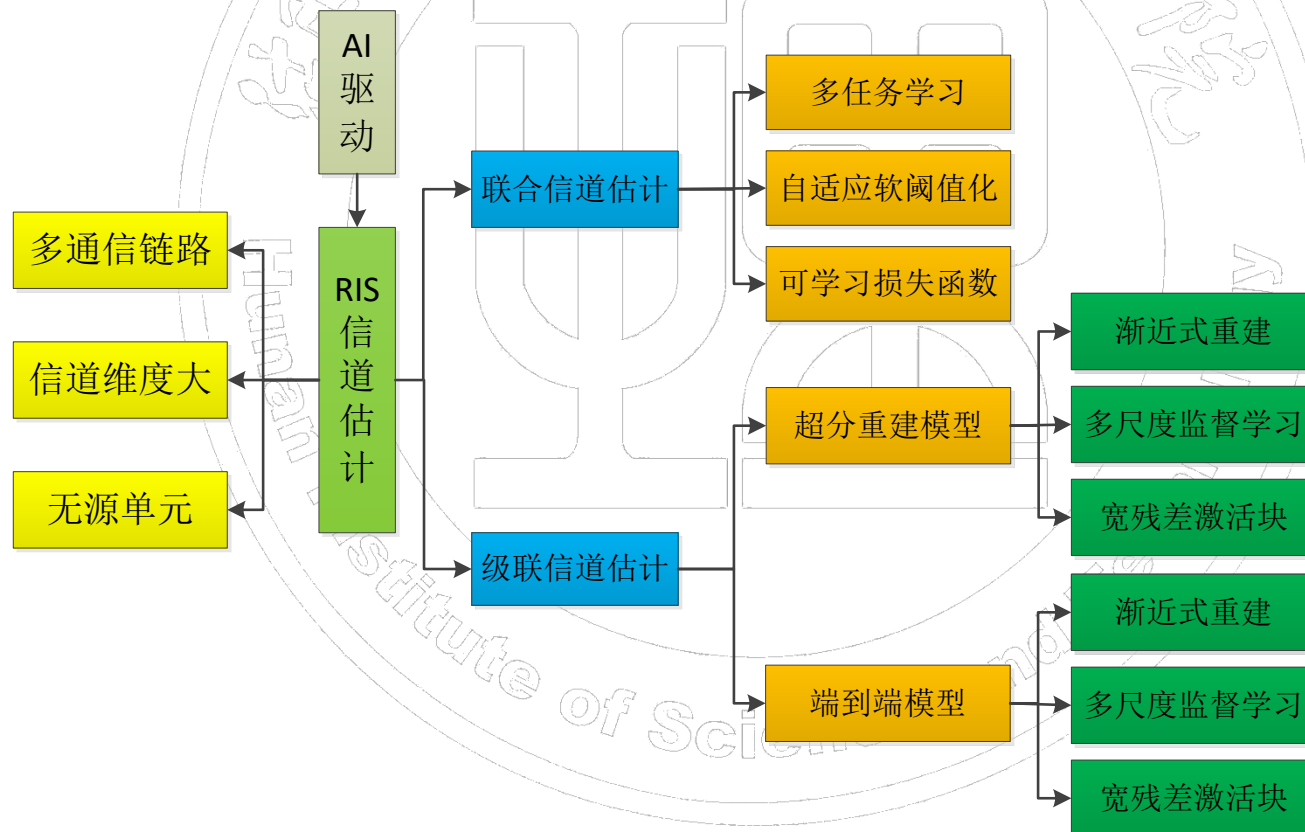
- 所有深度学习模型兼容任意导频长度场景，ResU-Net具有很好的泛化性
- 对于不同量化比特的相移，ResU-Net展现出更好的鲁棒性

ResU-Net同样适用于OFDM通信系统

工信部IMT2020 5G推进组 第二届无线通信AI大赛 AI-based Channel Estimation 赛道 第四名

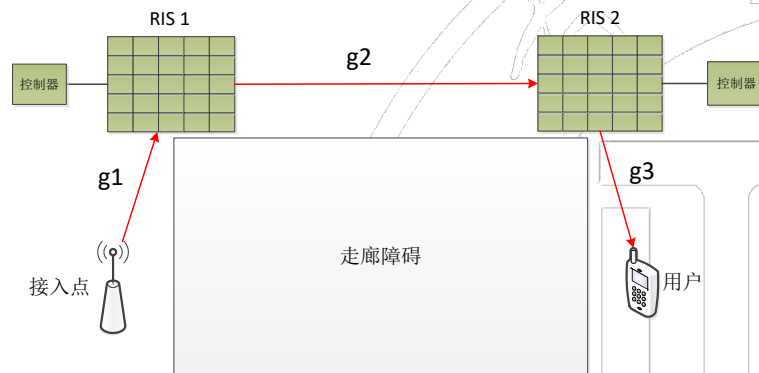
研究总结

本文针对RIS辅助的毫米波通信系统，提出基于深度学习的信道估计方案，包括：
 提出了基于多任务学习的联合信道估计模型，减少冗余训练开销和控制开销
 提出了基于多尺度监督学习的渐进式信道重建模型，降低级联信道估计开销
 提出了基于深度压缩感知的信道估计模型，对导频长度和RIS相位误差具有鲁棒性



研究展望

超高维信道估计——协作RIS通信系统





信号模型 $y_t = (g_1 \text{diag}(\theta_1) g_2 \text{diag}(\theta_2) g_3) s_t + w_t$

等效信道 $G = \text{diag}(g_1) g_2 \text{diag}(g_3)$

信道维度越高，所要求的信道估计网络容量越大

高速信道估计——RIS辅助的高铁/无人机/车联网通信系统



信道呈现出快时变特性，需要引入时序建模网络^[12] (LSTM)

北京东郊环形铁道已初步实验^[11]

BS: 基站 RIS: 智能超表面

[11] Zhang J, et al. RIS-Aided Next-Generation High-Speed Train Communications: Challenges, Solutions, and Future Directions[J]. IEEE Wireless Communications

[12] Yu J, et al. Deep Learning for Channel Tracking in IRS-Assisted UAV Communication Systems[J]. IEEE Transactions on Wireless Communications, 2022.



湖南理工学院
Hunan Institute of Science and Technology

敬请各位老师批评指正

谢谢