

混合智能反射表面结构辅助的毫米波通信信道估计

傅友华^{1,2}, 陈栋^{1,2}

(1. 南京邮电大学电子与光学工程学院微电子学院, 江苏 南京 210023;
2. 射频集成与微组装技术国家地方联合工程实验室, 江苏 南京 210023)

摘 要: 为应对毫米波通信加入智能反射表面 (IRS) 进行辅助通信导致系统变复杂难以获得信道状态信息 (CSI) 这一挑战, 采用了混合智能反射表面结构, 即 IRS 由大量无源元件和有限的射频 (RF) 链构成, 其中有限的 RF 链用来估计基站/终端和 IRS 之间的信道。基于该结构, 提出一种信道估计方案。该方案根据有限的 RF 链, 首先使用一种改进的多信号分类算法对信道的离开角和到达角同时进行估计, 然后提出一种复数并联深度神经网络对路径增益进行估计。通过将所提方案和其他方法进行仿真比较, 证明了所提方案的优越性。

关键词: 混合智能反射表面; 毫米波; 信道估计; 多信号分类算法; 深度神经网络

中图分类号: TN928

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021197

Channel estimation for hybrid intelligent reflecting surface structure assisted mmWave communications

FU Youhua^{1,2}, CHEN Dong^{1,2}

1. College of Electronic and Optical Engineering & College of Microelectronics, Nanjing University of Posts and Telecommunications, Nanjing 210023, China
2. National and Local Joint Engineering Laboratory of RF Integration and Micro-Assembly Technology, Nanjing 210023, China

Abstract: When adding intelligent reflecting surface (IRS) for assist communication in millimeter wave communication, the system becomes complicated and difficult to obtain channel state information (CSI). To solve these challenges, a hybrid intelligent reflecting surface structure was adopted, that is, the IRS was composed of a large number of passive elements and the limited radio frequency (RF) chains, where the limited RF chains were used to estimate the channel between the base station/terminal and the IRS. Based on the structure, a channel estimation scheme was proposed, which was based on the limited RF chains. First, an improved multiple signal classification algorithm was used to estimate the departure angle and arrival angle of the channel at the same time, and then a complex parallel deep neural network was proposed to estimate the path gain. Through simulation and comparison between the proposed scheme and other methods, the superiority of the proposed scheme is proved.

Keywords: hybrid intelligent reflecting surface, millimeter wave, channel estimation, multiple signal classification algorithm, deep neural network

1 引言

5G 通信系统使用大规模多输入多输出 (MIMO, multiple input multiple output) 技术来补偿毫米波传播损耗^[1], 但是大规模 MIMO 系统所带来的高功耗

为其实际实现带来了挑战^[2]。同时也引起了导频污染, 从而影响信道估计的准确性。文献[3]提出了基于干扰消除的信道估计方案。为了进一步提高系统性能, 使用智能反射表面 (IRS, intelligent reflecting surface) 进行辅助通信。IRS 由大量的无源反射元

收稿日期: 2021-07-09; 修回日期: 2021-09-23

基金项目: 国家自然科学基金资助项目 (No.61771257)

Foundation Item: The National Natural Science Foundation of China (No.61771257)

件组成平面，一方面通过智能调整幅度和相位，达到能够重新配置传播环境的效果^[4]；另一方面通过控制传播环境，提高无线通信的频谱效率和能量效率^[5-7]。但由于加入了 IRS 使信道变得复杂，因此给信道估计带来一定的难度，主要是 IRS 的无源特性使得难以分别估计基站 (BS, base station) 到 IRS 之间的信道和 IRS 到移动站 (MS, mobile station) 之间的信道。

为了克服上述困难，有一些研究对 IRS 进行了设计。文献[8]提出了一种新的 IRS 硬件结构，在无源反射元件中随机分布有源反射元件，然后提出基于压缩感知 (CS, compressed sensing) 和深度学习 (DL, deep learning) 的信道估计方案。但是该方案一方面所提的 CS 算法需要大量的有源元件来提升性能并且没有充分利用信道的稀疏性，从而导致成本和复杂度的增加；另一方面所提的神经网络在训练输出时没有考虑相位的作用，而实际的数据都是复数，降低了信道估计的准确性。文献[9-10]提出了一种基于开关状态控制的信道估计策略，其中每个时隙只打开一个 IRS 元件，使用户的反射信道可以在不受其他 IRS 元件反射信号干扰的情况下进行信道估计。但是该方案需要对每一个反射元件的幅度进行单独控制，导致成本增加。

还有一些研究提出级联信道估计的方案。文献[11]提出了一种深度去噪神经网络辅助 CS 宽带信道估计方法，以降低训练开销。文献[12]提出了一种基于稀疏矩阵分解和完备矩阵的算法。虽然文献[11-12]采用的级联信道估计的方案确实便于信道的估计，但都有一个限制，就是难以分别得到 BS-IRS 信道和 IRS-MS 信道的单独信息。对于这一点，文献[13]建立张量模型并利用其代数结构，提出了 2 种对 2 个信道进行单独估计的简单有效的算法，但由于算法中存在伪逆运算，会出现结果发散或者收敛缓慢的情况，从而降低了信道估计的准确性。

本文使用混合 (无源/有源) IRS 结构，即 IRS 上有限的无源元件各配备一条射频 (RF, radio frequency) 链，并将该结构应用于毫米波通信系统。为避免出现上述难以区分 IRS 前后 2 个信道的问题，本文提出了一种基于改进的多信号分类算法和复数并联深度神经网络的信道估计方案，该方案只需要少量的有源元件就可以实现对 BS-IRS 信道和 IRS-MS 信道的单独估计，从而降低成本。具体来

说，该方案包括离开角、到达角和信道增益估计，传统的多信号分类算法只能对到达角进行估计，为了实现离开角和到达角的同时估计，使用了改进的多信号分类算法；对于信道增益估计，提出了一种复数并联深度神经网络，将实部和虚部分开估计从而不会丢失相位信息，并且在输出处加入阈值判断，进一步提高估计的准确性。仿真结果也验证了所提方案的有效性。

2 系统模型和信道模型

2.1 系统模型

本文考虑的是下行混合 IRS 结构辅助的毫米波通信系统。IRS 由 N_{IRS} 个无源反射元件组成，并且都能独立地调整相位和幅度，然后从中选择 N_{RF} 个元件各配备一条 RF 链呈加号形状阵列，其中 $N_{\text{RF}} \ll N_{\text{IRS}}$ 。由于存在 N_{RF} 个有源元件，因此 IRS 有 2 种操作模式^[8]：接收模式和反射模式。在接收模式中，有源元件用来估计信道；在反射模式中，有源元件和无源元件一样都只将相移附加到入射信号上，然后反射它们。因此，可以通过控制器在这 2 种模式之间切换 IRS 的操作模式。该系统的发射端和接收端都配有多根天线，即 BS 和 MS 分别配置 M 根和 N 根天线。此时通信系统有 2 种传播路径，分别为 BS 直接到 MS、BS 通过 IRS 到 MS。在这 2 种路径上存在 3 种信道，分别为 BS 直接到 MS 的信道 L 、BS 到 IRS 的信道 H_1 、IRS 到 MS 的信道 H_2 。当直达路径被障碍物阻塞时，就使用 IRS 提供的路径，这可以帮助毫米波进行传输。本文假设直达路径被障碍物阻塞，故使用混合 IRS 结构辅助的毫米波通信系统，模型如图 1 所示。

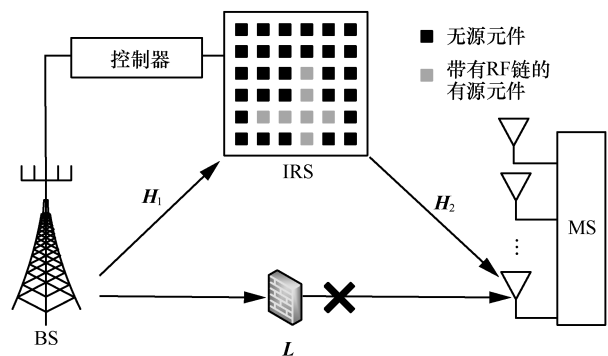


图 1 混合 IRS 结构辅助的毫米波通信系统模型

假设混合 IRS 结构辅助的毫米波通信信道的训练阶段由 T 个连续的时间帧组成，每个时间帧包含

Q 个时隙。因此在时间帧 t 中的第 $q(q \in \{1, \dots, Q\})$ 个时隙时, MS 处的接收信号的模型为

$$y_{t,q} = \mathbf{H}_2 \Phi \mathbf{H}_1 \mathbf{x}_{t,q} + \mathbf{n}_{t,q} \quad (1)$$

其中, $\mathbf{H}_1 \in \mathbb{C}^{N_{\text{IRS}} \times M}$ 是 BS 与 IRS 之间的信道, $\mathbf{H}_2 \in \mathbb{C}^{N \times N_{\text{IRS}}}$ 是 IRS 与 MS 之间的信道; $\Phi = \text{diag} \cdot ([a_1 e^{j\theta_1}, \dots, a_n e^{j\theta_n}, \dots, a_{N_{\text{IRS}}} e^{j\theta_{N_{\text{IRS}}}}]^T) \in \mathbb{C}^{N_{\text{IRS}} \times N_{\text{IRS}}}$ 是 IRS 上元件的相移矩阵, $a_n (n \in \{1, \dots, N_{\text{IRS}}\})$ 是幅度, $\theta_n \in (0, 2\pi]$ 是相位, 为了降低研究的复杂度, 本文只研究相位变化, 幅度都取 1, 即 $a_n = 1 (n \in \{1, \dots, N_{\text{IRS}}\})$; $\mathbf{x}_{t,q} \in \mathbb{C}^{M \times 1}$ 是在时间帧 t 中第 q 个时隙处发送的导频符号向量; $\mathbf{n}_{t,q} \in \mathbb{C}^{N \times 1}$ 是加性白高斯噪声 (AWGN, additive white Gaussian noise) 向量。

通过式(1)可以得出在整个时间帧 t 上 MS 处的接收信号, 表达式为

$$\mathbf{Y}_t = \mathbf{H}_2 \Phi \mathbf{H}_1 \mathbf{X} + \mathbf{N}_t \quad (2)$$

其中, $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_Q] \in \mathbb{C}^{M \times Q}$ 是在整个时间帧 t 上的导频符号信号, $\mathbf{N}_t = [\mathbf{n}_{t,1}, \dots, \mathbf{n}_{t,Q}] \in \mathbb{C}^{N \times Q}$ 是加性白高斯噪声矩阵。

此时, IRS 上配备 RF 链的元件处的接收信号可以写为

$$\begin{aligned} \bar{\mathbf{H}}_1 &= \mathbf{G} \mathbf{H}_1 \\ \mathbf{Y}_t^{\text{IRS}} &= \bar{\mathbf{H}}_1 \mathbf{X} + \mathbf{N}_t^{\text{IRS}} \end{aligned} \quad (3)$$

其中, \mathbf{G} 是一个 $N_{\text{RF}} \times N_{\text{IRS}}$ 的选择矩阵, 用于选择 IRS 上的主动元件; $\bar{\mathbf{H}}_1 \in \mathbb{C}^{N_{\text{RF}} \times M}$ 是 BS 到 IRS 上的 N_{RF} 个主动元件的信道; $\mathbf{N}_t^{\text{IRS}} \in \mathbb{C}^{N_{\text{RF}} \times Q}$ 是加性白高斯噪声矩阵。

2.2 信道模型

由于毫米波信道的散射路径有限, 因此其信道模型具有丰富的几何特征, 故每个散射路径都应该根据几何信道模型来决定单个传播路径。在此模型下, BS-IRS 之间的信道和 IRS-MS 之间的信道可以分别表示为

$$\mathbf{H}_1 = \sqrt{\frac{MN_{\text{IRS}}}{L_1}} \sum_{l_1=1}^{L_1} \alpha_{l_1} a_{\text{IRS}}(\gamma_{l_1}, \phi_{l_1}) a_{\text{BS}}^H(\theta_{l_1}) \quad (4)$$

$$\mathbf{H}_2 = \sqrt{\frac{NN_{\text{IRS}}}{L_2}} \sum_{l_2=1}^{L_2} \beta_{l_2} b_{\text{MS}}(\theta'_{l_2}) b_{\text{IRS}}^H(\gamma'_{l_2}, \phi'_{l_2}) \quad (5)$$

其中, L_1 和 L_2 分别是信道 \mathbf{H}_1 和信道 \mathbf{H}_2 上的散射路

径数, $\alpha_{l_1} \sim \mathcal{CN}(0, \sigma_{l_1}^2)$ 是第 l_1 条路径上的路径增益, $\beta_{l_2} \sim \mathcal{CN}(0, \sigma_{l_2}^2)$ 是第 l_2 条路径上的路径增益。之前的部分文献为了研究简单, 令 IRS 采用均匀线性阵列 (ULA, uniform linear array) 结构, 但是这不符合实际情况, 因此本文 IRS 采用均匀方形阵列 (UPA, uniform square array) 结构, BS 和 MS 处则采用 ULA 结构, 则信道 \mathbf{H}_1 中天线阵列的响应向量分别为

$$\begin{aligned} a_{\text{IRS}}(\gamma_{l_1}, \phi_{l_1}) &= \\ & \frac{1}{\sqrt{N_{\text{IRS}}}} \left[1, \dots, e^{j\frac{2\pi}{\lambda} d (m \sin(\gamma_{l_1}) \sin(\phi_{l_1}) + n \cos(\phi_{l_1}))}, \dots, \right. \\ & \left. e^{j\frac{2\pi}{\lambda} d ((\sqrt{N_{\text{IRS}}}-1) \sin(\gamma_{l_1}) \sin(\phi_{l_1}) + (\sqrt{N_{\text{IRS}}}-1) \cos(\phi_{l_1}))} \right]^T \end{aligned} \quad (6)$$

$$a_{\text{BS}}(\theta_{l_1}) = \frac{1}{\sqrt{M}} \left[1, \dots, e^{j\frac{2\pi}{\lambda} d m \sin(\theta_{l_1})}, \dots, e^{j\frac{2\pi}{\lambda} d (M-1) \sin(\theta_{l_1})} \right]^T \quad (7)$$

其中, λ 是毫米波波长; d 是天线阵列之间的间距或 IRS 上元件之间的间距, 通常取 $\lambda/2$; γ_{l_1} 和 ϕ_{l_1} 分别是第 l_1 条路径上 IRS 处的方位角和仰角, θ_{l_1} 是第 l_1 条路径上 BS 处的离开角。

为了使结构更加紧凑, 可以进行如下变化

$$\boldsymbol{\alpha} = \sqrt{\frac{MN_{\text{IRS}}}{L_1}} [\alpha_1, \alpha_2, \dots, \alpha_{L_1}] \quad (8)$$

$$\mathbf{A}_{\text{BS}} = [a_{\text{BS}}(\theta_1), a_{\text{BS}}(\theta_2), \dots, a_{\text{BS}}(\theta_{L_1})] \quad (9)$$

$$\mathbf{A}_{\text{IRS}} = [a_{\text{IRS}}(\gamma_1, \phi_1), a_{\text{IRS}}(\gamma_2, \phi_2), \dots, a_{\text{IRS}}(\gamma_{L_1}, \phi_{L_1})] \quad (10)$$

通过式(8)~式(10)可以将式(4)改写成

$$\mathbf{H}_1 = \mathbf{A}_{\text{IRS}} \text{diag}(\boldsymbol{\alpha}) \mathbf{A}_{\text{BS}}^H \quad (11)$$

信道 \mathbf{H}_2 和信道 \mathbf{H}_1 类似, 故可将式(5)改写成

$$\mathbf{H}_2 = \mathbf{B}_{\text{MS}} \text{diag}(\boldsymbol{\beta}) \mathbf{B}_{\text{IRS}}^H \quad (12)$$

其中,

$$\boldsymbol{\beta} = \sqrt{\frac{NN_{\text{IRS}}}{L_2}} [\beta_1, \beta_2, \dots, \beta_{L_2}] \quad (13)$$

$$\mathbf{B}_{\text{MS}} = [b_{\text{MS}}(\theta'_1), b_{\text{MS}}(\theta'_2), \dots, b_{\text{MS}}(\theta'_{L_2})] \quad (14)$$

$$\mathbf{B}_{\text{IRS}} = [b_{\text{IRS}}(\gamma'_1, \phi'_1), b_{\text{IRS}}(\gamma'_2, \phi'_2), \dots, b_{\text{IRS}}(\gamma'_{L_2}, \phi'_{L_2})] \quad (15)$$

3 信道估计方案

对上述的混合 IRS 结构辅助的毫米波通信系统模型进行信道估计。由于 IRS 上存在有源元件，因此在接收模式下可以很容易地估计出 BS 到 IRS 上有源元件之间的信道 \hat{H}_1 。常见的信道估计是用最小二乘 (LS, least square) 法估计的，因此本文使用 LS 法对信道 \hat{H}_1 进行估计。其估计表达式为

$$\hat{H}_1 = Y_t^{\text{IRS}} X^H (X X^H)^{-1} \quad (16)$$

通过研究式(11)可以发现，信道 H_1 中包含阵列响应 A_{IRS} 、 A_{BS} 和路径增益 α 等信息，也就是说需要先估计上述信息才能得到信道 H_1 的估计。

3.1 H_1 信道的离开角/到达角估计

传统的多信号分类 (MUSIC, multiple signal classification) 算法^[14] 只能通过谱峰搜索来估计到达角，但实际上，一方面离开角也要估计，另一方面由于 IRS 采用了均匀方形阵列结构，到达角包括方位角和仰角 2 种信息，即 IRS 处的 L_1 条路径的阵列响应 A_{IRS} 中包含方位角和仰角这 2 种信息，此时传统的 MUSIC 算法已无法满足同时估计上述 3 种信息。为避免三维估计，所提的改进 MUSIC 算法将三维降至二维进行估计。根据 IRS 上配备 RF 链的有源元件呈加号排列，故可以分别用水平方向的均匀线性阵列估计方位角和垂直方向的均匀线性阵列估计仰角，此时在各个方向上只需估计 2 种信息。这里假设 N_{RF} 为奇数，水平阵列上元件数为 n_x ，垂直阵列上元件数为 $n_y = N_{\text{RF}} - n_x + 1$ 。故可以得到 IRS 在水平和垂直方向上的阵列响应向量

$$a_{\text{IRS}}^x(\gamma_l) = \frac{1}{\sqrt{n_x}} \left[1, e^{j\frac{2\pi}{\lambda}d\sin(\gamma_l)}, \dots, e^{j\frac{2\pi}{\lambda}d(n_x-1)\sin(\gamma_l)} \right]^T \quad (17)$$

$$a_{\text{IRS}}^y(\phi_l) = \frac{1}{\sqrt{n_y}} \left[1, e^{j\frac{2\pi}{\lambda}d\cos(\phi_l)}, \dots, e^{j\frac{2\pi}{\lambda}d(n_y-1)\cos(\phi_l)} \right]^T \quad (18)$$

在 IRS 处水平方向上， n_x 个配置 RF 链的有源元件组成的均匀线性阵列处的接收信号为

$$Y_{t,x}^{\text{IRS}} = A_{\text{IRS}}^x \text{diag}(\alpha) A_{\text{BS}}^H X + N_{t,x}^{\text{IRS}} \quad (19)$$

其中， $A_{\text{IRS}}^x = [a_{\text{IRS}}^x(\gamma_1), \dots, a_{\text{IRS}}^x(\gamma_{L_1}), \dots, a_{\text{IRS}}^x(\gamma_{L_1})]$ 。这时用传统的 MUSIC 算法仅能对到达角 γ_l 进行估计，但是不能估计出离开角 θ_l ，而所提的改进 MUSIC 算法可以使其通过空间谱分析同时估计出

每条路径的离开角和到达角。为了构造合适的方向矩阵，需要对式(19)进行向量化操作，其表达式为

$$y_x = \text{vec}(Y_{t,x}^{\text{IRS}}) = \underbrace{\left[(A_{\text{BS}}^H X)^T \otimes A_{\text{IRS}}^x \right]}_{\mathbf{W}} \text{vec}(\text{diag}(\alpha)) + \text{vec}(N_{t,x}^{\text{IRS}}) \quad (20)$$

其中， $\mathbf{W} \in \mathbb{C}^{Qn_x \times L_1}$ 为方向矩阵，包含离开角和到达角信息。然后就需要求出 y_x 的协方差矩阵并进行特征值分解，表达式为

$$R = E(y_x y_x^H) = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^H = \begin{bmatrix} \mathbf{U}_s & \mathbf{U}_n \end{bmatrix} \begin{bmatrix} \mathbf{A}_s & 0 \\ 0 & \mathbf{A}_n \end{bmatrix} \begin{bmatrix} \mathbf{U}_s^H \\ \mathbf{U}_n^H \end{bmatrix} = \mathbf{U}_s \mathbf{A}_s \mathbf{U}_s^H + \mathbf{U}_n \mathbf{A}_n \mathbf{U}_n^H \quad (21)$$

其中， \mathbf{U} 是特征值向量，可以分解为信号子空间 \mathbf{U}_s 和噪声子空间 \mathbf{U}_n ^[15-16]，分别由 L_1 个最大特征值 \mathbf{A}_s 和 $Qn_x - L_1$ 个小特征值 \mathbf{A}_n 所对应的特征向量组成。最后得到方向谱函数为

$$P(\theta, \gamma) = \frac{1}{\left[\left[a_{\text{BS}}^H(\theta) X \right]^T \otimes a_{\text{IRS}}^x(\gamma) \right]^H \mathbf{U}_n \mathbf{U}_n^H \left[\left[a_{\text{BS}}^H(\theta) X \right]^T \otimes a_{\text{IRS}}^x(\gamma) \right]} \quad (22)$$

通过搜索方向谱函数中的 L_1 个极点，就可以估计出 L_1 条路径上的 θ 和 γ 。在垂直方向上的估计和水平方向上的估计类似，同样可以用改进的 MUSIC 算法估计出 L_1 条路径上的仰角 ϕ 。最后可以得到 A_{BS} 和 A_{IRS} 的估计值 \hat{A}_{BS} 和 \hat{A}_{IRS} 。

3.2 H_1 信道的路径增益估计

路径增益 α 是信道 H_1 中重要的信息，可以通过信道 \hat{H}_1 对其进行估计。信道 \hat{H}_1 的表达式为

$$\hat{H}_1 = \mathbf{G} \hat{A}_{\text{IRS}} \text{diag}(\alpha) \hat{A}_{\text{BS}}^H + N_1 \quad (23)$$

其中， $\text{diag}(\alpha)$ 是所需要估计的路径增益矩阵， \hat{A}_{BS} 和 \hat{A}_{IRS} 分别是 BS 和 IRS 处 L_1 条路径的阵列响应估计值， $N_1 \in \mathbb{C}^{N_{\text{RF}} \times M}$ 是加性白高斯噪声矩阵。为了便于下面的估计，这里需要对信道 \hat{H}_1 进行向量化，其表达式为

$$\hat{h}_1 = \text{vec}(\hat{H}_1) = (\hat{A}_{\text{BS}}^H)^T \otimes (\mathbf{G} \hat{A}_{\text{IRS}}) \text{vec}(\text{diag}(\alpha)) + \text{vec}(N_1) = (\hat{A}_{\text{BS}}^H)^T \otimes (\mathbf{G} \hat{A}_{\text{IRS}}) \mathbf{D} + \text{vec}(N_1) \quad (24)$$

其中, $\hat{h}_1 \in \mathbb{C}^{MN_{\text{RF}} \times 1}$, $\mathbf{D} = \text{vec}(\text{diag}(\boldsymbol{\alpha})) \in \mathbb{C}^{L_1 \times 1}$, $\text{vec}(\mathbf{N}_1) \in \mathbb{C}^{MN_{\text{RF}} \times 1}$ 是加性白高斯噪声向量。根据式(24), 本文提出了一种基于深度神经网络 (DNN, deep neural network) 的方案对路径增益进行估计, 该方案相比于 LS 法, 一方面需要的先前估计信息较少, 只需要获得基站到 IRS 上有源元件之间的信道信息; 另一方面 LS 法涉及求伪逆的过程, 若矩阵不满秩则得不到唯一解, 最终导致估计结果出现错误。虽然增加 DNN 中的网络层数可以提高训练的效果, 但是会出现过拟合的问题, 同时也增加了训练复杂度。为了在这两点之间寻找一个折中方案, 对 DNN 的层数进行多次尝试, 最终在网络层数为四层时取得了训练效果和复杂度的平衡。如图 2 所示, 该深度神经网络共有四层, 输入层有 I 个神经元, 2 个隐藏层都有 A 个神经元, 输出层有 K 个神经元, 层与层之间是全连接结构。因此这个四层神经网络层与层之间的权重矩阵分别为 $\mathbf{W}_1 \in \mathbb{R}^{A \times I}$ 、 $\mathbf{W}_2 \in \mathbb{R}^{A \times A}$ 和 $\mathbf{W}_3 \in \mathbb{R}^{K \times A}$, 偏置向量分别为 $\mathbf{b}_1 \in \mathbb{R}^A$ 、 $\mathbf{b}_2 \in \mathbb{R}^A$ 和 $\mathbf{b}_3 \in \mathbb{R}^K$ 。为了提高神经网络的性能、缓解梯度耗散, 在 2 个隐藏层处都使用非线性的双曲正切激活函数 ($\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$)。




图 2 深度神经网络结构

根据实际情况, 处理的数据都为复数。之前的一些神经网络方案只是把实部和虚部分别提取出来, 都当成实数输入神经网络中, 最后的输出都为实数, 这就造成了复数的相位信息缺失。本文针对这一点提出一个使用多个 DNN 并联结构对实部和虚部分开估计的方案。根据神经网络和复数运算的性质, 可以得到

$$\begin{bmatrix} \Re(\hat{\mathbf{D}}) \\ \Im(\hat{\mathbf{D}}) \end{bmatrix} = \begin{bmatrix} \Re(\mathbf{W}, \mathbf{b}) & -\Im(\mathbf{W}, \mathbf{b}) \\ \Im(\mathbf{W}, \mathbf{b}) & \Re(\mathbf{W}, \mathbf{b}) \end{bmatrix} \begin{bmatrix} \Re(\hat{h}_1) \\ \Im(\hat{h}_1) \end{bmatrix} \quad (25)$$

其中, $\Re(\cdot)$ 和 $\Im(\cdot)$ 分别表示复数的实部和虚部。根据式(25), 所提出的复数并联神经网络的具体结构如图 3 所示。




图 3 复数并联深度神经网络结构

本文方案使用 ADAM 算法对神经网络进行训练, 目的是使路径增益矩阵 \mathbf{D} 的实部和虚部的损失函数达到最小, 其实部和虚部的损失函数分别为

$$\text{Loss}(\Re(\hat{\mathbf{D}})) = \frac{1}{PK} \sum_{p=1}^{P} \left\| \Re(\hat{\mathbf{D}})^{(p)} - \Re(\mathbf{D})^{(p)} \right\|_{\mathbb{F}}^2 \quad (26)$$

$$\text{Loss}(\Im(\hat{\mathbf{D}})) = \frac{1}{PK} \sum_{p=1}^{P} \left\| \Im(\hat{\mathbf{D}})^{(p)} - \Im(\mathbf{D})^{(p)} \right\|_{\mathbb{F}}^2 \quad (27)$$

其中, P 为训练样本的个数, $\Re(\mathbf{D})^{(p)}$ 和 $\Im(\mathbf{D})^{(p)}$ 分别为第 p 个样本的实部和虚部。所提神经网络只需要获得基站到 IRS 上有源元件之间的信道信息, 在输入层将实部和虚部分开输入, 再按式(25)进行组合, 通过与各层的权重矩阵和偏置向量进行计算, 得到输出层神经元的值并按照式(26)和式(27)所示的损失函数进行计算, 为使其达到最小, 通过 ADAM 算法不断优化迭代, 也就需要不断地更新权重矩阵和偏置向量, 当损失函数达到最小时输出结果。由于信道增益矩阵 \mathbf{D} 存在一些 0 元素, 但训练后的神经网络很难准确地估计出 0, 只会估计出很小的值。为了进一步降低误差, 在最后输出实部和虚部估计值处加入阈值判断, 阈值判断标准为

$$\Re(\hat{\mathbf{D}}_k) = \begin{cases} \Re(\hat{\mathbf{D}}_k), & |\Re(\hat{\mathbf{D}}_k)| > \lambda \\ 0, & |\Re(\hat{\mathbf{D}}_k)| \leq \lambda \end{cases}, k=1, 2, \dots, K$$

$$\mathfrak{I}(\hat{\mathbf{D}}_k) = \begin{cases} \mathfrak{I}(\hat{\mathbf{D}}_k), |\mathfrak{I}(\hat{\mathbf{D}}_k)| > \gamma \\ 0, |\mathfrak{I}(\hat{\mathbf{D}}_k)| \leq \gamma \end{cases}, k=1,2,\dots,K \quad (28)$$

其中, $\Re(\hat{\mathbf{D}}_k)$ 、 $\mathfrak{I}(\hat{\mathbf{D}}_k)$ 分别是输出向量 $\Re(\hat{\mathbf{D}})$ 、 $\mathfrak{I}(\hat{\mathbf{D}})$ 的第 k 个元素; λ 和 γ 是判断阈值, 在本文中的取值都为 0.001。

3.3 H_2 信道估计

根据上述方案可以得到信道 H_1 中 BS(IRS)处 L_1 条路径的阵列响应估计矩阵 $\hat{\mathbf{A}}_{\text{BS}}$ ($\hat{\mathbf{A}}_{\text{IRS}}$)和路径增益估计矩阵 $\hat{\mathbf{D}}$, 则可以得到信道 H_1 的估计值 $\hat{\mathbf{H}}_1$ 。在混合 IRS 结构的接收模式下, 对信道 H_1 进行了估计, 然后在反射模式下 MS 处只需要对信道 H_2 进行估计, 此时式(2)可以改写为

$$\begin{aligned} \bar{\mathbf{Y}}_t &= \mathbf{H}_2 \Phi_{\text{RF}} \mathbf{Y}_t^{\text{IRS}} + \mathbf{N}_t = \\ & \mathbf{B}_{\text{MS}} \text{diag}(\boldsymbol{\beta}) \mathbf{B}_{\text{IRS}}^H \Phi_{\text{RF}} \mathbf{Y}_t^{\text{IRS}} + \bar{\mathbf{N}}_t \end{aligned} \quad (29)$$

其中, $\bar{\mathbf{Y}}_t \in \mathbb{C}^{N \times Q}$ 是 MS 处的接收信号, 该信号是从 IRS 上有 RF 链的元件处反射而来的。对于信道 H_2 , 同样可以用上述的信道估计方案。由于离开角包括方位角和仰角, 依旧用配备 RF 链水平方向的均匀线性阵列和配备 RF 链垂直方向的均匀线性阵列分开估计。用改进 MUSIC 算法从水平方向和垂直方向对离开角和到达角进行估计, 最后可以得到阵列响应 \mathbf{B}_{MS} 的估计值 $\hat{\mathbf{B}}_{\text{MS}}$ 和阵列响应 \mathbf{B}_{IRS} 的估计值 $\hat{\mathbf{B}}_{\text{IRS}}$ 。对信道增益的估计用所提出的复数并联深度神经网络, 在对信道增益进行估计前, 先对接收信号 $\bar{\mathbf{Y}}_t$ 进行向量化处理, 其表达式为

$$\begin{aligned} \bar{\mathbf{y}}_t &= \text{vec}(\bar{\mathbf{Y}}_t) = \\ & \left[(\mathbf{B}_{\text{IRS}}^H \Phi_{\text{RF}} \mathbf{Y}_t^{\text{IRS}})^T \otimes \mathbf{B}_{\text{MS}} \right] \text{vec}[\text{diag}(\boldsymbol{\beta})] + \text{vec}(\bar{\mathbf{N}}_t) = \\ & \left[(\mathbf{B}_{\text{IRS}}^H \Phi_{\text{RF}} \mathbf{Y}_t^{\text{IRS}})^T \otimes \mathbf{B}_{\text{MS}} \right] \bar{\mathbf{D}} + \text{vec}(\bar{\mathbf{N}}_t) \end{aligned} \quad (30)$$

其中, $\bar{\mathbf{y}}_t \in \mathbb{C}^{N_Q \times 1}$, $\bar{\mathbf{D}} = \text{vec}(\text{diag}(\boldsymbol{\beta})) \in \mathbb{C}^{L_2 L_2 \times 1}$, $\text{vec}(\bar{\mathbf{N}}_t) \in \mathbb{C}^{N_Q \times 1}$ 是加性白高斯噪声向量。将 $\Re(\bar{\mathbf{y}}_t)$ 和 $\mathfrak{I}(\bar{\mathbf{y}}_t)$ 作为复数并联深度神经网络的输入, 经过神经网络的训练可以得到信道增益 $\bar{\mathbf{D}}$ 的实部和虚部估计值分别为 $\Re(\hat{\mathbf{D}})$ 和 $\mathfrak{I}(\hat{\mathbf{D}})$ 。结合上述阵列响应的估计矩阵 $\hat{\mathbf{B}}_{\text{MS}}$ 和 $\hat{\mathbf{B}}_{\text{IRS}}$, 最终可以得到信道 H_2 的估计值 $\hat{\mathbf{H}}_2$ 。

4 仿真分析

为了测试所提方案的性能, 采用归一化均方误差 (NMSE, normalized mean square error) 来评价信道估计的精度, 表达式为

$$\text{NMSE}(\hat{\mathbf{H}}) = \frac{1}{R} \sum_{r=1}^R \frac{\|\mathbf{H}_r - \hat{\mathbf{H}}_r\|_{\text{F}}^2}{\|\mathbf{H}_r\|_{\text{F}}^2} \quad (31)$$

其中, R 表示蒙特卡罗运行的次数, $\hat{\mathbf{H}}_r$ 表示第 r 次完整信道估计的结果。本文仿真假设 $M=16$ 、 $N=4$ 、 $L_1=L_2=3$ 、 $Q=20$ 、 $T=50$ 、 $N_{\text{RF}}=5$ 、 $R=5000$ 。为了分析 IRS 上元件数量对信道估计的影响, 假设 $N_{\text{IRS}} \in \{16, 25, 36, 49\}$ 。

图 4 和图 5 分别是对信道 H_1 和信道 H_2 在 IRS 上元件数分别为 16 和 49 时的性能仿真, 其中水平和垂直方向上 RF 链的数目 $n_x=n_y=3$, 并和双线性交替最小二乘 (BALS, bilinear alternating least squares) [11] 算法估计的信道 H_1 和信道 H_2 的性能进行对比。仿真结果表明, 所提方案性能优于 BALS 算法。

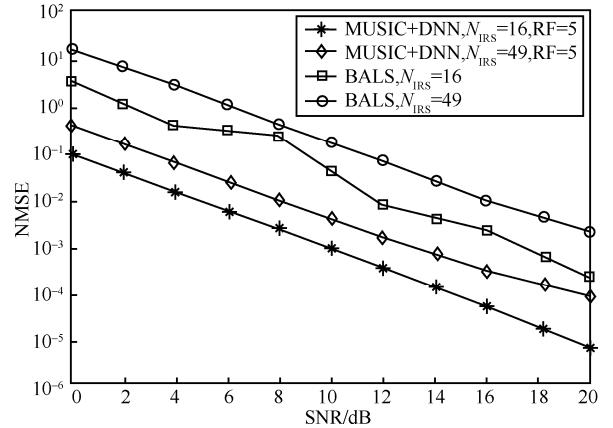


图 4 信道 H_1 的 NMSE 性能对比




图 5 信道 H_2 的 NMSE 性能对比

图 6 是对完整的信道 H 在 IRS 上元件数分别为 16、25、36、49 时的性能仿真，其中水平和垂直方向上 RF 链的数目 $n_x=n_y=3$ 。从图 6 可以看出，随着 IRS 上元件数的增加，其性能在下降，因为 IRS 上元件数增加时，需要估计的信道系数也会增加，即未知项增加。为了弥补这一点，可以增加导频符号序列的长度或者增加时间帧的数量。

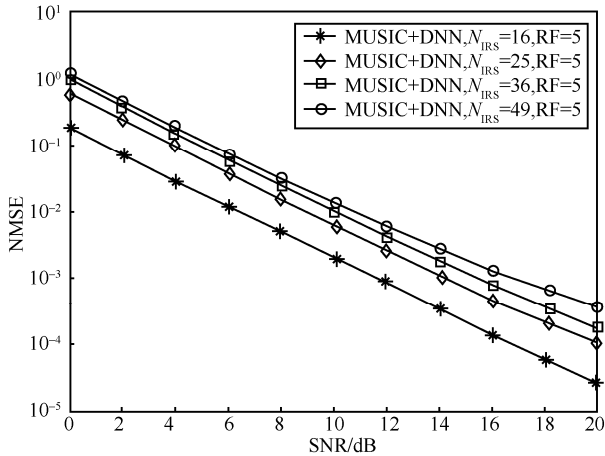


图 6 信道 H 在 IRS 上元件数不同时的 NMSE 性能对比

图 7 是本文提出的信道估计算法(MUSIC+DNN)、BALS 算法和 LS 算法在 $M_{IRS}=16$ 时的性能比较。从图 7 可以看出，本文提出的信道估计算法的性能优于其余 BALS 算法和 LS 算法。图 7 还比较了采用改进的 MUSIC 算法和传统 DNN 相结合的方案，通过比较可以发现，该方案信道估计的准确度低于本文所提方案，故可以证明本文所提的复数并联深度神经网络考虑相位因素确实可以提高信道估计的准确性。




图 7 所提方案与其他算法的 NMSE 性能对比

5 结束语


本文提出了一种混合 IRS 结构辅助的毫米波通信信道估计方案，通过在 IRS 上配备有限的 RF 链，对离开角、到达角和信道增益进行估计。传统的 MUSIC 算法只能对到达角进行估计，因此拓展出改进的 MUSIC 算法对离开角和到达角同时进行估计。然后提出复数并联深度神经网络对信道增益进行估计，该网络结构可以避免在对复数训练时出现相位缺失的情况。通过仿真证明了所提方案的可行性，并与其他算法进行对比也体现了所提方案的优越性。

参考文献:

- [1] HASSAN K, MASARRA M, ZWINGELSTEIN M, et al. Channel estimation techniques for millimeter-wave communication systems: achievements and challenges[J]. IEEE Open Journal of the Communications Society, 2020, 1: 1336-1363.
- [2] SUN B L, ZHOU Y Q, YUAN J H, et al. High order PSK modulation in massive MIMO systems with 1-bit ADCs[J]. IEEE Transactions on Wireless Communications, 2021, 20(4): 2652-2669.
- [3] SUN B L, ZHOU Y Q, YUAN J H, et al. Interference cancellation based channel estimation for massive MIMO systems with time shifted pilots[J]. IEEE Transactions on Wireless Communications, 2020, 19(10): 6826-6843.
- [4] WU Q Q, ZHANG R. Towards smart and reconfigurable environment: intelligent reflecting surface aided wireless network[J]. IEEE Communications Magazine, 2020, 58(1): 106-112.
- [5] BASAR E, RENZO M D, ROSNY J D, et al. Wireless communications through reconfigurable intelligent surfaces[J]. IEEE Access, 2019, 7: 116753-116773.
- [6] LIASKOS C, NIE S, TSIOLIARIDOU A, et al. A new wireless communication paradigm through software-controlled metasurfaces[J]. IEEE Communications Magazine, 2018, 56(9): 162-169.
- [7] YUAN X J, ZHANG Y J A, SHI Y M, et al. Reconfigurable-intelligent-surface empowered wireless communications: challenges and opportunities[J]. IEEE Wireless Communications, 2021, 28(2): 136-143.
- [8] TAHA A, ALRABEIAH M, ALKHATEEB A. Enabling large intelligent surfaces with compressive sensing and deep learning[J]. IEEE Access, 2021, 9: 44304-44321.
- [9] MISHRA D, JOHANSSON H. Channel estimation and low-complexity beamforming design for passive intelligent surface assisted MISO wireless energy transfer[C]/Proceedings of ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE Press, 2019:

- 4659-4663.
- [10] YANG Y F, ZHENG B X, ZHANG S W, et al. Intelligent reflecting surface meets OFDM: protocol design and rate maximization[J]. IEEE Transactions on Communications, 2020, 68(7): 4522-4535.
- [11] LIU S C, 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.
- [12] HE Z Q, YUAN X J. Cascaded channel estimation for large intelligent metasurface assisted massive MIMO[J]. IEEE Wireless Communications Letters, 2020, 9(2): 210-214.
- [13] ARAÚJO G T D, ALMEIDA A L F D. PARAFAC-based channel estimation for intelligent reflective surface assisted MIMO system[C]//Proceedings of 2020 IEEE 11th Sensor Array and Multichannel Signal Processing Workshop (SAM). Piscataway: IEEE Press, 2020: 1-5.
- [14] SCHMIDT R. Multiple emitter location and signal parameter estimation[J]. IEEE Transactions on Antennas and Propagation, 1986, 34(3): 276-280.
- [15] DASTGAHIAN M S, GHOMASH H K. MUSIC-based approaches for hybrid millimeter-wave channel estimation[C]//Proceedings of 2016 8th International Symposium on Telecommunications (IST). Piscataway: IEEE Press, 2016: 266-271.
- [16] GHAUCH H, KIM T, BENGTSSON M, et al. Subspace estimation and decomposition for large millimeter-wave MIMO systems[J]. IEEE Journal of Selected Topics in Signal Processing, 2016, 10(3): 528-542.

[作者简介]



傅友华 (1978-), 女, 贵州遵义人, 博士, 南京邮电大学副教授, 主要研究方向为 MIMO 无线通信、中继协作通信等。



陈栋 (1996-), 男, 江苏盐城人, 南京邮电大学硕士生, 主要研究方向为 MIMO 无线通信。