

基于噪声抑制的智能反射面辅助通信系统的信道估计研究

叶中付^{1,2}, 郭佳愉^{1,2}, 于润祥^{1,2}, 黄心月^{1,2}

(1. 中国科学技术大学电子工程与信息科学系, 合肥 230022; 2. 语音及语言信息处理国家工程研究中心, 合肥 230022)

摘要: 针对用户设备到基站(Base station, BS)的视距通信受阻时智能反射面(Intelligent reflecting surface, IRS)辅助通信系统的信道估计任务, 提出了一种基于潜在特征空间噪声抑制的神经网络, 可以实现精确的信道估计。该神经网络将变分自编码器(Variational auto-encoder, VAE)模型和UNet模型相结合, 能够在进行信道估计的同时对输入信号中的噪声进行处理。首先, VAE模型的输入是纯净的基站接收信号, 以最小化估计的纯净的基站接收信号与其真实值之间的误差为目标, 使VAE模型的编码器映射出一个特征向量, 作为纯净接收信号的潜在表示。其次, 固定VAE模型部分, 使用纯净的基站接收信号作为UNet模型的输入对整个神经网络进行训练, 在此过程中, VAE模型学习到的纯净潜在特征向量有助于UNet模型的编码器学习到纯净的特征表示。接着, 该特征被UNet模型的解码器解码以实现信道估计任务。最后, 在估计阶段仅需利用UNet模型部分即可。仿真实验结果表明, 本文所提出的信道估计方法可以有效抑制特征空间中的噪声信息, 能以更低的时间复杂度更准确地估计出信道信息。

关键词: 智能反射面; 信道估计; 噪声抑制; 变分自编码器; UNet模型

中图分类号: TN928 **文献标志码:** A

Channel Estimation in Intelligent Reflecting Surface-Assisted Communication Systems with Noise Suppression

YE Zhongfu^{1,2}, GUO Jiayu^{1,2}, YU Runxiang^{1,2}, HUANG Xinyue^{1,2}

(1. Department of Electronic Engineering and Information Science, University of Science and Technology of China, Hefei 230022, China; 2. National Engineering Research Center of Speech and Language Information Processing, Hefei 230022, China)

Abstract: In channel estimation tasks for intelligent reflecting surface (IRS)-assisted communication systems when line-of-sight communication between user equipment and base station (BS) is blocked, this paper proposes a neural network based on noise suppression in the latent feature space, which can realize accurate channel estimation. The neural network combines the variational auto-encoder (VAE) and UNet to reduce the noise in the input signal while performing channel estimation. Firstly, the VAE model takes noise-free BS received signals as input, with the objective of minimizing the error between the estimated noise-free BS received signals and their true value, so that the encoder of the VAE model maps a feature vector as a potential representation of the pure received signal. Secondly, the VAE model part is fixed. The

基金项目: 国家自然科学基金(62071206)。

收稿日期: 2024-05-21; **修订日期:** 2025-04-26

entire network is trained using noisy BS received signals as input to the UNet model, in which the noise-free latent feature vectors learned by the VAE assist the encoder of the UNet model in learning noise-free feature representations. Subsequently, the pure feature representations are fed into the decoder of the UNet model to achieve the channel estimation task. Finally, during the estimation phase, only the UNet model part is utilized, which effectively reduces computational complexity. The results of simulation experiments demonstrate that the proposed channel estimation method can effectively suppress noisy information in the feature space, and can estimate the channel information more accurately with lower time complexity.

Key words: intelligent reflecting surface (IRS); channel estimation; noise suppression; variational auto-encoder (VAE); UNet model

引言

近年来,智能反射面(Intelligent reflecting surface, IRS)辅助无线通信系统作为一种潜在的技术,被视为第6代移动通信(The sixth-generation mobile communication, 6G),为未来无线通信提供经济高效的高速数据传输服务的解决方案,受到广泛关注^[1-4]。具体而言,IRS是由大量低成本并可重置的近无源反射元件组成的平面,每个反射元件可实现对入射信号进行幅度和相位可控的反射^[5]。与传统的中继站或者分布式天线系统相比,IRS可以方便灵活地部署在建筑外或内墙上,且其中的反射元件所需要的运行功率很小。此外,在不可控的、动态的传输环境中,当用户设备(User equipment, UE)到基站(Base station, BS)的通信信道受到障碍物阻碍时,传统无线传输通信技术的性能可能会受到影响,因为其需要被动适应信道。然而,IRS通过高度可控的元件进行主动反射,并能修改信号传输的无线信道,实现了从适应信道到改变信道的转变^[6]。IRS能带来增强信号覆盖、增强抗信道扰动、提升频谱效率、降低能耗及延长通信距离等多重益处,因此在无线通信、雷达探测和信号处理等领域得到了广泛应用^[7-9]。

为了能够完全实现IRS带来的最优传输性能,需要准确知道信道状态信息(Channel state information, CSI),当信道估计质量不佳时,IRS无法充分发挥自身潜力。一方面,由于成本和功耗的限制,传统的IRS通常为被动模式,无法分别获取从UE到IRS以及从IRS到BS的信道状态信息,所以一般需要估计UE-IRS-BS的级联信道(Cascaded channel, CC);另一方面,对于具有大量无源元件的IRS,需要估计的级联信道参数数量也相应庞大,随之而来的是算法时间复杂度的骤升,这使得在降低时间开销的前提下准确地估计信道参数成为一个挑战。

为了解决这些问题,近期的研究开始集中在新的信道估计技术和算法,其中有研究致力于开发半主动或主动的IRS元件^[10-11],但这些元件也大大增加了系统的硬件成本和功耗,与引入IRS的初衷相违背。同时,现有的最小二乘(Least squares, LS)估计和线性最小均方误差(Least minimum mean square error, LMMSE)估计^[12]与最优估计结果相比仍有较大的性能差距^[13]。一些初步工作解决了有关IRS辅助通信系统设计的技术问题,例如文献[14]通过联合优化BS发射波束形成和IRS相移矩阵设计,研究了IRS增强型单用户系统的接收功率最大化问题。在文献[15]中,考虑IRS辅助单用户下行链路系统,在没有IRS和CSI的相关先验信息下,通过引入导频提出了一种实用的低复杂度IRS相移矩阵设计方法。而后,文献[16]提出了一种缩短正交频分复用(Orthogonal frequency division multiplexing, OFDM)符号持续时间的快速信道估计方案和一种对不断变化的IRS反射系数进行时域采样的信道估计方案,来降低导频开销和信道估计复杂度。近年来,由于深度学习卓越的学习和预测能力,许多学者研究了基于深度学习的IRS辅助通信系统的信道估计问题。文献[17]利用OFDM中相邻子载波之间的相关性,将初步估计的相邻子载波的信道矩阵同时输入到卷积神经网络(Convolutional neural network, CNN)中,得到了一种基于空间频率CNN(Spatial-frequency CNN, SF-CNN)的信道估计算法。

文献[18]中提出一种跳跃连接注意力(Skip-connection attention, SC attention)网络来估计级联信道信息。由于注意力机制可被用于增加神经网络在图像恢复任务中的感受野大小,且基于深度学习的信道估计任务可视为图像恢复中去噪任务的延拓,所以自注意层也可用来增加信道估计的感受野大小,使得信道估计任务的性能更加优越。

鉴于以上分析,针对UE到BS直接通信受阻的情况,本文提出了一种基于潜在特征空间噪声抑制的智能反射面辅助通信系统的信道估计方法。该神经网络包含2部分功能,一部分是基于变分自编码器(Variational auto-encoder, VAE)模型提取输入纯净信号的潜在特征,另一部分是基于UNet模型估计信道参数。VAE将纯净的BS接收信号作为模型的输入,最小化所估计的纯净的BS接收信号与其真实值之间的归一化均方误差(Normalized mean square error, NMSE)。VAE模型中的编码器输出一个特征向量,作为纯净接收信号的潜在表示;而后固定VAE模型部分,将BS接收的纯净信号作为UNet模型的输入,训练整个神经网络,通过利用VAE模型学习到的纯净信号的潜在表示信息,使得UNet模型的编码器可以学习到纯净接收信号的潜在表示,达到噪声抑制的效果,并提高后续解码器进行信道估计的准确度。在最后的估计阶段,仅需利用UNet模型进行信道估计,可有效降低信道估计的时间成本。在本文的仿真实验部分,将提供相应结果和分析,以验证所提算法在基于IRS辅助信道估计方面的有效性。

1 IRS辅助通信系统模型

本文考虑单个UE和BS之间进行视距(Line-of-sight, LOS)通信受阻时借助于IRS辅助的上行通信系统。其中一个具有 N 个无源反射单元的IRS部署在BS和UE之间用于辅助通信,基站和用户设备分别具有 M 根天线和1根天线。本通信系统以毫米波信号为例,假设所有涉及的信道都是准静态频率选择性衰落信道,这保证了信道在用于信道估计的传输时隙内保持大致不变。IRS到BS的信道记为 $H_1 \in \mathbb{C}^{M \times N}$,其中共有 P 条IRS-BS的信道路径,包括1条LOS路径和 $P-1$ 条非视距(Non LOS, NLOS)路径;UE到IRS的信道记为 $h_2 \in \mathbb{C}^{N \times 1}$,其中共有 Q 条UE-BS的信道路径,包括1条LOS路径和 $Q-1$ 条NLOS路径;UE到BS的直接信道记为 $d \in \mathbb{C}^{M \times 1}$,由于干扰物的阻挡,不存在LOS通信,但是存在 L 条NLOS路径。具体通信模型如图1所示。

本文假设BS端天线设计为均匀线性阵列(Uniform linear array, ULA)结构,IRS端的反射单元设计为 $N_1 \times N_2$ 的均匀平面阵列(Uniform plane array, UPA), N_1 和 N_2 分别为横纵元素的数量,并且满足 $N = N_1 \times N_2$ 。因此,IRS到BS的通信链路 H_1 可以建模为

$$H_1 = \sqrt{\frac{MN}{P}} \sum_{p=1}^P \alpha_p \mathbf{a}_r(\psi_p) \mathbf{a}_i^H(\theta_p, \phi_p) \quad (1)$$

式中: ψ_p 为BS端第 p 条路径的到达角(Angle of arrival, AOA), θ_p 和 ϕ_p 分别为IRS端第 p 条路径出发角(Angle of departure, AOD)的方位角和仰角; $\alpha_p \in \mathbb{C}$ 表示第 p 条路径衰落系数,并满足 $\alpha_1 \sim \text{CN}(0, \sigma_{\text{LOS}}^2)$ 、 $\alpha_p \sim \text{CN}(0, \sigma_{\text{NLOS}}^2)$, $p = 2, 3, \dots, P$;通信链路中包括1条($p=1$)LOS路径和 $P-1$ 条($p=2, 3, \dots, P$)NLOS路径; $\mathbf{a}_r(\psi_p)$ 和 $\mathbf{a}_i(\theta_p, \phi_p)$ 分别为BS接收端的方向矢量和IRS发射端的方向矢量,那么方向矢量分别表示为

$$\mathbf{a}_r(\psi_p) = \frac{1}{\sqrt{M}} \left[1, e^{j \frac{2d}{\lambda} \pi \cos \psi_p}, \dots, e^{j \frac{2d}{\lambda} (M-1) \pi \cos \psi_p} \right]^T \quad (2)$$

$$\mathbf{a}_i(\theta_p, \phi_p) = \mathbf{a}_{N_1}(u_p) \otimes \mathbf{a}_{N_2}(v_p) \quad (3)$$

式中: λ 为毫米波波长, d 为阵元之间的间距,通常取波长的一半,“ $\otimes$ ”表示克罗内克积运算,假设 $u_p \triangleq \pi \sin \phi_p$ 、 $v_p \triangleq \pi \cos \theta_p$,那么




图1 智能反射面辅助单用户设备和基站通信的上行链路系统示意图

Fig.1 Schematic diagram of the uplink system for IRS-assisted single UE and BS communication

$$\begin{cases} \mathbf{a}_{N_1}(u_p) \triangleq \frac{1}{\sqrt{N_1}} \left[1, e^{j\frac{2d}{\lambda}u_p}, \dots, e^{j\frac{2d}{\lambda}(N_1-1)u_p} \right]^T \\ \mathbf{a}_{N_2}(v_p) \triangleq \frac{1}{\sqrt{N_2}} \left[1, e^{j\frac{2d}{\lambda}v_p}, \dots, e^{j\frac{2d}{\lambda}(N_2-1)v_p} \right]^T \end{cases} \quad (4)$$

UE到IRS的通信链路 $\mathbf{h}_2$ 可以表示为

$$\mathbf{h}_2 = \sqrt{\frac{N}{Q}} \sum_{q=1}^Q \beta_q \mathbf{a}_r(\vartheta_q, \varphi_q) \quad (5)$$

式中: ϑ_q 和 φ_q 分别为UE-IRS之间第 q 条路径IRS端AOA的方位角和仰角; $\beta_q \in \mathbb{C}$ 表示第 q 条路径衰落系数,并满足 $\beta_1 \sim \text{CN}(0, \sigma_{\text{LOS}}^2)$ 、 $\beta_q \sim \text{CN}(0, \sigma_{\text{NLOS}}^2)$, $q = 2, 3, \dots, Q$; $\mathbf{a}_r(\vartheta_q, \varphi_q)$ 为IRS接收端的方向矢量,其与IRS-BS信道中IRS发射端的方向矢量式(式(3))定义类似。通信链路中包括1条($q=1$)LOS路径和 $Q-1$ 条($1 < q \leq Q$)NLOS路径。UE到BS的直接信道 $\mathbf{d}$ 可以表示为

$$\mathbf{d} = \sqrt{\frac{M}{L}} \sum_{l=1}^L \gamma_l \mathbf{a}_r(\zeta_l) \quad (6)$$

式中: γ_l 表示第 l 条路径衰落系数,并满足 $\gamma_l \sim \text{CN}(0, \sigma_{\text{NLOS}}^2)$, $l = 1, 2, \dots, L$; $\mathbf{a}_r(\zeta_l)$ 为BS接收端的方向矢量,其与IRS-BS信道中BS接收端的方向矢量式(式(2))的定义类似。

因此,UE-IRS-BS通道的端到端上行链路信道 $\mathbf{G}$ 可以写为

$$\mathbf{G} = \mathbf{H}_1 \mathbf{W} \mathbf{h}_2 = \mathbf{H}_1 \text{diag}(\mathbf{w}) \mathbf{h}_2 = \mathbf{H}_1 \text{diag}(\mathbf{h}_2) \mathbf{w} \quad (7)$$

式中: $\mathbf{W} = \text{diag}(\mathbf{w})$ 表示IRS的相移矩阵, $\text{diag}(\cdot)$ 表示对矢量进行对角化操作。

$$\mathbf{w} = [\omega_1, \omega_2, \dots, \omega_N]^T = [\ell_1 e^{j\tilde{\omega}_1}, \ell_2 e^{j\tilde{\omega}_2}, \dots, \ell_N e^{j\tilde{\omega}_N}]^T \quad (8)$$

式中: $\omega_n (n=1, 2, \dots, N)$ 表示反射系数, ℓ_n 和 $\tilde{\omega}_n \in [0, 2\pi)$ 分别是反射幅度和反射相位。为了实现低成本、低复杂度的 RIS 辅助通信系统, RIS 反射系数的幅值 ℓ_n 设为 1。UE-IRS-BS 的级联信道记为

$$\mathbf{C} = \mathbf{H}_1 \text{diag}(\mathbf{h}_2) \in \mathbf{C}^{M \times N} \quad (9)$$

那么此时待估计的信道矩阵可表示为

$$\mathbf{H} = [\mathbf{d}, \mathbf{C}] \in \mathbf{C}^{M \times (N+1)} \quad (10)$$

简便起见, 文中模型将 BS 端天线设计为 ULA 结构, IRS 端反射单元设计为 UPA 结构, 但是本文所提的 IRS 辅助通信系统的信道估计方案同样适用于 BS 或 IRS 为其他阵型的情况。

2 IRS 辅助通信系统的信道估计方案

2.1 信道探测

在探测过程中, 导频信号在 IRS 辅助下从 UE 发送到 BS 接收。在第 k 个时隙, BS 的接收信号为

$$\mathbf{y}(k) = \mathbf{H} \tilde{\mathbf{w}}(k) x(k) + \mathbf{n}(k) \in \mathbf{C}^{M \times 1} \quad (11)$$

式中: $\tilde{\mathbf{w}}(k) = [1, \mathbf{w}^T(k)]^T$, $x(k)$ 表示 UE 发送的导频信号, $\mathbf{n}(k)$ 表示 BS 接收的噪声矢量。简便起见, 将 $x(k)$ 设为 1, $\mathbf{n}(k)$ 服从 $\text{CN}(0, \sigma_n^2 \mathbf{I}_M)$ 的复高斯分布, σ_n^2 为噪声功率, $\mathbf{I}_M$ 表示 $M \times M$ 的单位矩阵。经过 K 个时隙后, BS 的接收信号表示为

$$\mathbf{Y} = \mathbf{Z} + \mathbf{N} = \mathbf{H} \tilde{\mathbf{W}} + \mathbf{N} \in \mathbf{C}^{M \times K} \quad (12)$$

式中:

$$\begin{cases} \mathbf{Y} = [\mathbf{y}(1), \mathbf{y}(2), \dots, \mathbf{y}(K)] = \mathbf{Y}_{\text{rm}} + j\mathbf{Y}_{\text{im}} \\ \mathbf{N} = [\mathbf{n}(1), \mathbf{n}(2), \dots, \mathbf{n}(K)] = \mathbf{N}_{\text{rm}} + j\mathbf{N}_{\text{im}} \\ \tilde{\mathbf{W}} = [\tilde{\mathbf{w}}(1), \tilde{\mathbf{w}}(2), \dots, \tilde{\mathbf{w}}(K)] = \tilde{\mathbf{W}}_{\text{rm}} + j\tilde{\mathbf{W}}_{\text{im}} \end{cases} \quad (13)$$

上述均为复数形式的矩阵, $\mathbf{Z} = \mathbf{H} \tilde{\mathbf{W}} = \mathbf{Z}_{\text{rm}} + j\mathbf{Z}_{\text{im}}$ 代表理想情况下纯净的 BS 接收信号。由文献 [15] 可知, $\tilde{\mathbf{W}}$ 通常被设计为如下的离散傅里叶变换 (Discrete Fourier transformation, DFT) 矩阵形式

$$\tilde{\mathbf{W}} = \begin{bmatrix} 1 & 1 & \dots & 1 \\ 1 & W_{N+1} & \dots & W_{N+1}^{K-1} \\ 1 & \vdots & \ddots & \vdots \\ 1 & W_{N+1}^N & \dots & W_{N+1}^{N(K-1)} \end{bmatrix} \in \mathbf{C}^{(N+1) \times K} \quad (14)$$

式中: $W_{N+1} = e^{j\frac{\pi}{N+1}}$ 。由式 (12) 和式 (14) 可知, 本文研究的目标是根据已知的 DFT 矩阵, 从 BS 接收信号 $\mathbf{Y}$ 中恢复信道矩阵 $\mathbf{H}$ 。考虑到 IRS 辅助通信系统模型中的加性噪声影响了信道状态信息的精确恢复, 本文提出了基于潜在特征空间噪声抑制的方法来进行信道估计。

2.2 基于潜在特征空间噪声抑制的神经网络结构

本算法构建的基于潜在特征空间噪声抑制的信道估计神经网络主要包括 VAE 模型和 UNet 模型两部分, 利用 VAE 模型提取纯净的接收信号的潜在特征表示, 利用 UNet 模型来估计信道参数。VAE 模型的输入是 2.1 节中所述的纯净的 BS 接收信号 $\mathbf{Z}$, 经过 VAE 的编码器后输出复数形式的潜在特征表示 $\mathbf{P}_1 = \mathbf{P}_{1\text{rm}} + j\mathbf{P}_{1\text{im}}$, 然后经过 VAE 的解码器后输出估计的复数形式的纯净的 BS 接收信号 $\hat{\mathbf{Z}} = \hat{\mathbf{Z}}_{\text{rm}} + j\hat{\mathbf{Z}}_{\text{im}}$; UNet 模型的输入是 BS 接收信号 $\mathbf{Y}$, 经过 UNet 的编码器后输出复数向量 $\mathbf{P}_2 = \mathbf{P}_{2\text{rm}} + j\mathbf{P}_{2\text{im}}$, 然后经过 UNet 的解码器后输出估计的信道矩阵 $\hat{\mathbf{H}}$ 。

如图 2 所示, VAE 模型是一种自监督学习模型, 主要由基于卷积神经网络的编码器和镜像表示的解码器构成。编码器的结构包括 4 个二维卷积块、全连接块 1 和全连接块 2, 将纯净的 BS 接收信号 $\mathbf{Z}$ 作

为输入信号映射到低维特征空间中的均值 μ 和标准差 σ 后,进行重参数化输出纯净潜在特征向量 P_1 ;解码器的结构包括全连接块3和4个二维反卷积块,将复数形式的潜在特征向量 P_1 解码为输入的纯净接收信号的估计 $\hat{Z}$ 。二维卷积块包括1个卷积核大小为 5×2 、步长为 $(2,1)$ 的二维卷积层、1个批归一化层和1个修正线性单元(Rectified linear unit, ReLU)激活函数。4个卷积块的通道维数分别为32、64、64和64。全连接块1和2各有2个Dropout层、全连接层、批归一化层和ReLU激活函数交替组成的神经网络结构;全连接块3包括全连接层、批归一化层、ReLU激活函数和全连接层,再经过1个批归一化层处理后进行维度转换;二维反卷积块包括1个卷积核大小为 5×2 、步长为 $(2,1)$ 的二维反卷积层、1个批归一化层和1个ReLU激活函数,每个二维反卷积层的输入由上一层的输出和对应二维卷积层的输出拼接构成。




图2 基于潜在特征空间噪声抑制的信道估计神经网络

Fig.2 Channel estimation neural network based on noise suppression in latent feature space

UNet模型主要包括编码器和解码器。编码器的结构包括4个二维卷积块和1个全连接块4,BS接收信号 Y 为带噪信号经过编码器后输出向量 P_2 ;解码器的结构包括1个全连接块5和4个二维反卷积块; P_2 经过解码器后最终输出估计的信道矩阵 $\hat{H}$ 。全连接块4的结构与全连接块1和2的结构一致,全连接块5的结构与全连接块3一致。

2.3 训练过程

对模型的训练过程主要分为2个阶段:首先,利用VAE模型提取纯净的接收信号的潜在特征;其次,使用UNet模型估计信道参数。初始阶段,通过对VAE模型进行训练,目标是 minimized 估计的纯净的

BS接收信号 $\hat{Z}$ 与其真实值 Z 之间的均方误差,重点在于让编码器能够准确地映射出纯净信号的潜在特征表示。在此基础上,固定VAE模型参数不变,进而训练整个模型,使得UNet模型的编码器能够学习这些纯净的潜在特征。UNet模型接收纯净的BS接收数据 Y 作为输入,通过VAE模型的辅助,迫使UNet模型的编码器学习到纯净的潜在特征向量,从而对噪声进行有效的抑制,显著提高了后续解码器在信道估计方面的准确度。

训练过程的第1阶段,纯净的BS接收信号 Z 从VAE模型的编码器输入,并经由解码器恢复,此无监督学习的目标是缩小输出与输入之间的差距。为了避免自编码器复制原始数据进行输出这类的事情,本文利用VAE模型以增强模型的泛化能力。对VAE模型而言,编码器处理的是原始数据 Z ,而解码器的输入并不是直接的编码器的输出,而是经编码器后生成的潜在表征。VAE模型的编码器将原始数据所携带的所有特征信息的分布编码为类高斯分布的形式,并分别输出实部的均值 μ_{re} 和标准差 σ_{re} 以及虚部的均值 μ_{im} 和标准差 σ_{im} 。接着,在基于这些参数构建的高斯分布上进行随机采样,并将采样结果送入解码器。解码器最终输出与原始数据特征结构一致的结果作为VAE模型的最终输出。鉴于随机采样操作本身是不可导的,为了使得神经网络可以正常进行反向传播,本研究利用文献[18]中的重参数化技巧,使得VAE模型的编码器输出潜在特征向量输入到解码器中。输出的复数形式的潜在特征向量 P_1 表示为

$$P_1 = \chi \odot \exp(\sigma) + \mu \quad (15)$$

式中: $\mu = \mu_{\text{re}} + j\mu_{\text{im}}$, $\sigma = \sigma_{\text{re}} + j\sigma_{\text{im}}$, χ 是从标准正态分布中抽取的随机数,“ $\odot$ ”表示对应元素相乘。最终VAE模型输出估计的纯净的BS接收信号 $\hat{Z}$ 。利用变分推断和Kullback-Ledibler(KL)散度计算得到这一训练阶段损失函数为

$$\text{Loss}_1 = \frac{\|Z - \hat{Z}\|_{\text{F}}^2}{M \times (N + 1)} - 0.5 \sum_{i=1}^I (\exp(\sigma[i]) - (1 + \sigma[i]) + \mu^2[i]) \quad (16)$$

式中: $\|\cdot\|_{\text{F}}^2$ 为Frobenius范数, $\sigma[i]$ 和 $\mu[i]$ 分别是标准差 σ 和均值 μ 的向量元素, I 为纯净的潜在特征向量 P_1 的维数。式(16)的第1项为利用均方误差计算的重构误差(Reconstruction error, RE);第2项为KL散度误差。通过这一流程对VAE模型进行训练,直至获得一组训练完好的变分自编码器模型参数。

在训练过程的第2阶段,保持之前训练好的VAE模型参数不变,集中训练UNet模型。此阶段的目标是使UNet模型的编码器的输出向量 P_2 能够学习VAE模型编码器输出的纯净的潜在特征向量 P_1 的特征,并期望解码器预测的信道矩阵 $\hat{H}$ 尽可能地接近真实的信道矩阵 H 。因此,这一训练阶段损失函数为

$$\text{Loss}_2 = \frac{\|H - \hat{H}\|_{\text{F}}^2}{\|H\|_{\text{F}}^2} + \frac{\|P_1 - P_2\|_{\text{F}}^2}{I} \quad (17)$$

式中:第1项为预测的信道矩阵与真实信道矩阵 H 之间的归一化均方误差的结果,在图2中表示为NMSE($H, \hat{H}$);第2项为潜在特征向量 P_1 和 P_2 的均方误差,表示为MSE(P_1, P_2)。在VAE模型参数固定的情况下,通过梯度下降方法来最小化整体损失函数 Loss_2 ,进行模型的反向传播和训练。经过VAE模型输入纯净的BS接收信号 Z 、UNet模型输入BS接收数据 Y 后,对基于潜在特征空间噪声抑制的信道估计神经网络进行训练,直至获得训练完好的UNet模型参数。

在实际推理阶段,无需考虑VAE模型,仅将BS接收数据 Y 输入到训练完好的UNet模型来预测信道矩阵 $\hat{H}$ 。这一过程仅需利用UNet模型进行信道估计,可以有效地减少信道估计所需的时间。

3 仿真分析

本小节进行仿真分析来验证本文所提算法的有效性,并采用NMSE来评价信道矩阵 $\hat{H}$ 的估计精

度,即

$$\text{NMSE}(\hat{H}) = \frac{1}{R} \sum_{r=1}^R \frac{\|H^{(r)} - \hat{H}^{(r)}\|_F^2}{\|H^{(r)}\|_F^2} \quad (18)$$

式中: R 表示蒙特卡洛实验的次数, $\hat{H}^{(r)}$ 表示第 r 次算法对信道矩阵 $H^{(r)}$ 的估计结果。同样的,也可以利用式(18)对UE-IRS-BS的级联信道估计结果 $\hat{C}$ 和UE-BS的信道估计结果 $\hat{d}$ 进行评价。

假设BS端具有 $M=16$ 根天线,天线间距为半波长的ULA结构;IRS端是具有 $N_1=4, N_2=8$ 共32个反射单元的UPA结构,导频数量 $K=33$ 。RIS反射系数的幅值设为1,IRS导频矩阵 $\tilde{W}$ 被设置为DFT矩阵。信道模型采用典型的毫米波Saleh-Valenzuela(SV)模型,信道路径数目采用 $P=Q=L=3$ 进行建模,路径衰落系数均符合复高斯分布,并且 $\sigma_{\text{LOS}}^2=1, \sigma_{\text{NLOS}}^2=0.01$;AOA和AOD均遵循均匀分布 $\mathcal{U}\left[-\frac{\pi}{2}, \frac{\pi}{2}\right]$ 。信噪比计算为

$$\text{SNR} = E\left[\frac{\|Z\|_F^2}{\|N\|_F^2}\right] = E\left[\frac{\|H\tilde{W}\|_F^2}{\|N\|_F^2}\right] \quad (19)$$

此外,在本文的深度学习训练中利用Adam优化器对神经网络的权值进行优化,样本批量大小设置为64,训练过程持续400个周期。初始学习率被设置为 $l_r=1 \times 10^{-3}$,在经历4个训练周期后每2个训练周期学习率衰减0.99。训练集包括96 000个样本,信噪比从 $-10 \sim 15$ dB,间隔5 dB。在估计信道过程中,即测试集中,每种信噪比水平下用于估计的样本数为4 000。

为了评估本文所提算法的性能,本文采用LS算法、LMMSE算法^[12]、SF_CNN算法^[17]和SC_attention算法^[18]作为本文所提出算法(Proposed)的对比算法,用式(18)来作为信道估计精度的评价结果。表1在线模型复杂度分析比较了在估计信道参数时所有基于深度学习算法的基线的在线模型参数量和计算复杂度乘积累加(Multiply accumulates, MACs)和参数量。可以看出,本文所提算法

表1 在线模型复杂度分析

Table 1 Online model complexity analysis

在线模型	MACs/(G·s ⁻¹)	参数量/10 ⁵
SF_CNN	10.06	0.30
SC_attention	471.27	5.36
Proposed	2.79	2.78

的空间复杂度在可以接受的前提下,有着较低的计算复杂度。图3~5分别展示了随着输入信噪比的变化,不同算法估计的总信道矩阵 $\hat{H}$ 的NMSE、估计的级联信道 $\hat{C}$ 的NMSE和估计的直接信道 $\hat{d}$ 的NMSE变化的曲线。图中的纵坐标采用对数坐标便于观察。

从图3中可以看出,总体来讲所提出的算法估计的信道矩阵是最优的。在信噪比小于0 dB时,所提算法NMSE与LS算法相比差了两个数量级,估计误差很小。随着信噪比的增加,所提算法NMSE减小趋势变缓,但是总体而言,该算法的估计性能已达到较优的估计效果。本文所提方法优于传统的LS和LMMSE算法,这归因于LS和LMMSE算法的线性特性,而本文所提方法具有非线性优势。此外,在绝大部分信噪比水平下,所提方法优于两种基于深度学习的方法(SF_CNN算法和SC_attention算法)。由图3可知,SF_CNN算法估计的总信道矩阵的NMSE基本不随信噪比的变化而变化,估计性能不佳,结合表1可知,是因为SF_CNN模型的网络结构过于简单,无法获取捕获数据的复杂特征。SC_attention算法整体来看性能表现也较优,这是因为SC_attention算法和所提出的算法原理都借助于降噪的思想,所以在高信噪比时,接收信号所含噪声较小,两者性能相似;但在信噪比较低时,本文所提算法估计更为精确。SC_attention算法通过自注意力机制进行全局依赖性建模和动态权重分配,这在提升模型表达能力的同时也带来了显著的计算开销,而本文所提算法参数量仅仅为SC_attention算法的0.51倍,计算复杂度有着显著的降低。总体来看,本文所提算法在保持较小的模型参数和计算复杂度下,仍然具备出色的估计性能,这证明了VAE模型能够有效引导UNet模型的编码器学习纯净的特征表示。图




图3 总信道矩阵的NMSE

Fig.3 NMSE of the total channel matrix




图4 级联信道NMSE

Fig.4 NMSE of cascade channels




图5 直接信道的NMSE

Fig.5 NMSE for direct channels

4展示的级联信道NMSE的变化曲线整体与总信道矩阵的NMSE一致,这是因为通信系统中UE到BS的直连信道LOS通信受阻,信道通信基本借助于IRS反射面的辅助来实现。可以看出,所提方法在绝大部分信噪比水平下取得了最佳性能,在高信噪比水平下取得了与SC_attention算法相当的性能。由图5可知,除LS算法外,直接信道估计NMSE基本在0.1~1.5之间;除SF_CNN外,其余算法NMSE均随信噪比的增加而降低;本文所提算法整体表现最优。具体来说,与LMMSE算法相比,所提方法显著提升了5 dB和10 dB处直接信道估计的准确性。与SC_attention算法相比,本文所提算法进一步提升了较低信噪比水平下直接信道估计的准确性,并且保持了较小的计算复杂度和参数量。在输入信噪比为5 dB时,与SC_attention算法相比,本文所提算法在直接通道的信道估计精度基本持平,将级联通道的信道估计精度提高了约10.60%。因此,本文所提算法具有一定的优势。综上所述,本文所提算法有效地实现了高精度的信道估计,证明了基于潜在特征空间噪声抑制的信道估计网络的有效性。

4 结束语

针对用户到基站通信中存在的阻碍问题,本文提出了一种新的基于智能反射面辅助的通信系统的信道估计方法。将VAE模型与UNet模型相结合,利用VAE模型提取纯净的接收信号的潜在特征;利用UNet模型来估计信道参数。通过VAE模型的辅助,迫使UNet模型的编码器学习到纯净的潜在特征向量,从而实现对噪声有效的抑制,显著提高后续解码器在信道估计方面的精确度。在2个阶段的训练后,得到整个神经网络的参数,本文仅需利用UNet模型部分即可实现信道矩阵的估计。最后,通过仿真实验验证了所提方法的有效性。结果表明,本文所提方法不仅能够抑制特征空间中的噪声信息,还能够以更低的时间复杂度实现更准确的信道估计。

参考文献:

- [1] HASHIDA H, KAWAMOTO Y, KATO N. Intelligent reflecting surface placement optimization in air-ground communication networks toward 6G[J]. IEEE Wireless Communications, 2020, 27(6): 146-151.
- [2] HUA M, WU Q, CHEN W, et al. Secure intelligent reflecting surface aided integrated sensing and communication[J]. IEEE Transactions on Wireless Communications, 2024, 23(1): 575-591.
- [3] WU Q, ZHANG R. Towards smart and reconfigurable environment: Intelligent reflecting surface aided wireless network[J]. IEEE Communications Magazine, 2019, 58(1): 106-112.
- [4] GE Y, FAN J, LI G Y, et al. Intelligent reflecting surface-enhanced UAV communications: Advances, challenges, and

- prospects[J]. IEEE Wireless Communications, 2023, 30(6): 119-126.
- [5] BASAR E, DI RENZO M, DE ROSNY J, et al. Wireless communications through reconfigurable intelligent surfaces[J]. IEEE Access, 2019, 7: 116753-116773.
- [6] YANG H, CAO X, YANG F, et al. A programmable metasurface with dynamic polarization, scattering and focusing control[J]. Scientific Reports, 2016, 6(1): 35692.
- [7] 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.
- [8] ELMOSSALLAMY M A, ZHANG H, SONG L, et al. Reconfigurable intelligent surfaces for wireless communications: Principles, challenges, and opportunities[J]. IEEE Transactions on Cognitive Communications and Networking, 2020, 6(3): 990-1002.
- [9] 彭坤, 梁彦, 李飞. IRS辅助大规模MIMO系统中抑制残余硬件损伤的AQBFO无源波束赋形方案[J]. 数据采集与处理, 2024, 39(2): 433-444.
PENG Kun, LIANG Yan, LI Fei. AQBFO-based passive beamforming scheme for intelligent reflecting surface-aided massive MIMO systems with residual hardware impairments[J]. Journal of Data Acquisition and Processing, 2024, 39(2): 433-444.
- [10] LONG R, LIANG Y C, PEI Y, et al. Active reconfigurable intelligent surface-aided wireless communications[J]. IEEE Transactions on Wireless Communications, 2021, 20(8): 4962-4975.
- [11] NING B, CHEN Z, CHEN W, et al. Channel estimation and transmission for intelligent reflecting surface assisted THz communications[C]//Proceedings of the 2020 IEEE International Conference on Communications (ICC). Dublin, Ireland: IEEE, 2020: 1-7.
- [12] HU J, ZHANG H, DI B, et al. Reconfigurable intelligent surface based RF sensing: Design, optimization, and implementation[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(11): 2700-2716.
- [13] BIGUESH M, GERSHMAN A B. Training-based MIMO channel estimation: A study of estimator tradeoffs and optimal training signals[J]. IEEE Transactions on Signal Processing, 2006, 54(3): 884-893.
- [14] WANG Z, LIU L, CUI S. Channel estimation for intelligent reflecting surface assisted multiuser communications: Framework, algorithms, and analysis[J]. IEEE Transactions on Wireless Communications, 2020, 19(10): 6607-6620.
- [15] WU Q, ZHANG R. Intelligent reflecting surface enhanced wireless network: Joint active and passive beamforming design[C]//Proceedings of the 2018 IEEE Global Communications Conference (GLOBECOM). Abu Dhabi, United Arab Emirates: IEEE, 2018: 1-6.
- [16] XU J, XU W, SWINDLEHURST A L. Discrete phase shift design for practical large intelligent surface communication[C]//Proceedings of the 2019 IEEE Pacific Rim Conference on Communications, Computers and Signal Processing (PACRIM). Victoria, Canada: IEEE, 2019: 1-5.
- [17] ZHENG B, YOU C, ZHANG R. Fast channel estimation for IRS-assisted OFDM[J]. IEEE Wireless Communications Letters, 2020, 10(3): 580-584.
- [18] DONG P, ZHANG H, LI G Y, et al. Deep CNN-based channel estimation for mmWave massive MIMO systems[J]. IEEE Journal of Selected Topics in Signal Processing, 2019, 13(5): 989-1000.

作者简介:



叶中付(1959-),通信作者,男,教授,博士生导师,研究方向:阵列信号处理、语音及语言信息处理和图像处理,E-mail:yezcf@ustc.edu.cn。



郭佳愉(1999-),女,硕士研究生,研究方向:阵列信号处理。



于润祥(1998-),男,硕士研究生,研究方向:语音信号处理。



黄心月(2000-),女,硕士研究生,研究方向:阵列信号处理。