

文章编号: 1671-251X(2024)08-0144-07

DOI: 10.13272/j.issn.1671-251x.2024070038

基于自监督学习的 IRS 辅助矿井通信系统 信道估计方法

王安义, 李新宇, 李明珠, 李嫒嫒

(西安科技大学 通信与信息工程学院, 陕西 西安 710060)

摘要: 针对矿井复杂环境导致的多径衰落、非视距通信及真实标签获取困难的问题, 提出一种基于自监督学习(SSL)的智能反射面(IRS)辅助矿井通信系统信道估计方法。根据井下 Nakagami-g 衰落信道模型和 IRS 信号传输模型搭建井下通信系统模型, 通过 IRS 技术解决多径衰落和非视距通信问题。通过最小二乘(LS)算法进行初步信道估计, 再采用 SSL 框架下的八度卷积(OCT)神经网络优化信道估计结果。OCT 直接对高频分量和低频分量进行处理, 能同时捕捉信道的粗糙特征和细微差别, 提供全面的信道信息, 从而更准确地估计信道状态; SSL 算法使用接收信号及其带噪版本作为训练数据, 通过未标注数据的内在结构提升 IRS 辅助信道估计的精度和效率, 从而降低对人工标签的依赖。仿真结果表明: ① 引入 IRS 技术能有效降低信道估计误差。② OCT 神经网络的损失值明显低于 CNN, 数据拟合效果更好; OCT 神经网络计算效率高, 可提高通信系统信道估计的整体性能; 在计算资源有限的环境下, OCT 神经网络可保持较低参数量和内存使用量。③ SSL 算法在所有信噪比条件下均能保持较低的归一化均方误差, 验证了其在信道估计中的高效性和鲁棒性。④ 基于 SSL 的 IRS 辅助矿井通信系统信道估计方法在大规模网络中具有较好的扩展性和鲁棒性。

关键词: 矿井通信; 信道估计; 井下智能反射面; 自监督学习; 八度卷积神经网络; Nakagami-g 模型
中图分类号: TD655 文献标志码: A

Channel estimation method for IRS assisted mine communication system based on self supervised learning

WANG Anyi, LI Xinyu, LI Mingzhu, LI Ruoman

(College of Communication and Information Technology, Xi'an University of Science and Technology,
Xi'an 710060, China)

Abstract: A channel estimation method for intelligence reflecting surface (IRS) assisted mine communication system based on self supervised learning (SSL) is proposed to address the problems of multipath fading, non line of sight communication, and difficulty in obtaining true labels caused by complex mine environments. The method builds an underground communication system model based on the Nakagami-g fading channel model and IRS signal transmission model, and solves the problems of multipath fading and non line of sight communication through IRS technology. Preliminary channel estimation is performed using the least squares (LS) algorithm, and then the channel estimation results are optimized using octave convolution (OCT) neural network under the SSL framework. OCT directly processes both high-frequency and low-frequency components, capturing both the rough features and subtle differences of the channel, providing comprehensive channel

收稿日期: 2024-07-10; 修回日期: 2024-08-26; 责任编辑: 胡嫒。

基金项目: 国家自然科学基金项目(62271386)。

作者简介: 王安义(1968—), 男, 山东潍坊人, 教授, 博士, 主要研究方向为矿山无线通信及信息化技术, E-mail: wanganyiyi@xust.edu.cn。通信作者: 李新宇(2000—), 男, 甘肃天水人, 硕士, 主要研究方向为矿山无线通信及信息化技术, E-mail: 1837664483@qq.com。

引用格式: 王安义, 李新宇, 李明珠, 等. 基于自监督学习的 IRS 辅助矿井通信系统信道估计方法[J]. 工矿自动化, 2024, 50(8): 144-150.

WANG Anyi, LI Xinyu, LI Mingzhu, et al. Channel estimation method for IRS assisted mine communication system based on self supervised learning[J]. Journal of Mine Automation, 2024, 50(8): 144-150.



扫码移动阅读

information, and thus more accurately estimating the channel state. The SSL algorithm uses received signals and their noisy versions as training data to improve the precision and efficiency of IRS assisted channel estimation through the intrinsic structure of unlabeled data, thereby reducing reliance on manual labeling. The simulation results show the following points. ① Introducing IRS technology can effectively reduce channel estimation errors. ② The loss value of OCT neural network is significantly lower than that of CNN, and the data fitting effect is better. OCT neural network has high computational efficiency and can improve the overall performance of channel estimation in communication systems. In environments with limited computing resources, OCT neural networks can maintain low parameter and memory usage. ③ The SSL algorithm can maintain a low normalized mean square error under all signal-to-noise ratio conditions, verifying its efficiency and robustness in channel estimation. ④ The channel estimation method for IRS assisted mine communication system based on SSL has good scalability and robustness in large-scale networks.

Key words: mine communication; channel estimation; underground intelligence reflecting surface; self supervised learning; octave convolution neural network; Nakagami-g model

0 引言

在矿井通信系统中,复杂的巷道和硐室使电磁波的传播特性与自由空间中的传播显著不同,且电磁波频繁发生折射、反射和衍射现象。此外,矿工和设备的存在使得多径衰落和非视距通信问题更加突出。这些因素导致电磁波传播损耗大、通信距离短,成为井下无线通信的主要障碍。信道估计是通信技术的核心,其目的是获得完整的信道状态信息(Channel State Information, CSI),信道估计的性能直接关系到整个通信系统的质量。矿井内复杂环境增加了信道估计的难度,使得构建适应井下矿区的无线通信系统面临巨大挑战^[1]。

在矿井环境中进行信道估计时,通常采用最小二乘(Least-Square, LS)算法^[2]和线性最小均方误差(Linear Minimum Mean Square Error, LMMSE)算法。对于系统稀疏度未知的情况,正交匹配追踪算法^[3]可提高信道估计的准确度和频谱利用率。然而,由于直连信道的路径被遮挡,信号传播损耗很大,导致传统方法信道估计精度较低。智能反射面(Intelligence Reflecting Surface, IRS)技术通过在平面上集成大量低成本的无源反射元件,智能地重新配置无线传播环境,从而显著提高无线通信网络的性能^[4-7]。由于 IRS 是被动设备,无法主动发送或接收信号,所以直接利用 IRS 设备进行信道估计十分困难^[8-9]。针对具有稀疏信道的 IRS 辅助通信系统,可通过压缩感知方法^[10]将信道估计转换为稀疏信号恢复问题,或使用机器学习^[11]方法来优化发射和反射波束的形成。文献^[12]提出了一种直接估计级联用户 IRS-基站信道的典型方法。针对单用户多输入单输出系统,文献^[13]使用 LS 算法获取级联信道的估计。对 IRS 辅助通信系统进行信道估计,可提高信号覆盖率和质

量,但现有方法在处理多维信道时复杂度高且难以进一步优化。

深度学习为 IRS 辅助信道估计提供了低复杂度和高性能的解决方案^[14-15]。文献^[16-17]利用合成深度神经网络和卷积神经网络(Convolutional Neural Network, CNN)解决 IRS 辅助通信系统的信道估计问题。文献^[18]采用 CNN 对基于 LS 的信道估计算法进行优化,进一步提升了信道估计精度。深度学习在信道估计中表现优异,但在实际应用中,获取监督学习所需的真实标签较为困难^[19]。自监督学习(Self-Supervised Learning, SSL)能够通过未标注数据的内在结构提升 IRS 辅助信道估计的精度和效率,从而降低对人工标签的依赖。因此,本文提出一种基于 SSL 的 IRS 辅助矿井通信系统信道估计方法。

1 方法原理

基于 SSL 的 IRS 辅助矿井通信系统信道估计方法的整体框架如图 1 所示。根据井下 Nakagami-g 衰落信道模型和 IRS 信号传输模型搭建井下通信系统模型,以生成数据集,在数据集中加入噪声,模拟实际通信环境中的干扰。通过 LS 算法进行初步信道估计,再采用 SSL 框架下的八度卷积(Octave Convolution, OCT)神经网络优化信道估计结果。采用归一化均方误差(Normalized Mean Square Error, NMSE)评估信道估计性能。通过结合 IRS 技术和 SSL 方法,解决矿井环境中的多径衰落、非视距通信及信道估计中真实标签难以获取的问题,实现井下高精度信道估计,提高通信质量和可靠性。

2 井下通信系统模型

2.1 Nakagami-g 模型

由于井下环境复杂,多径效应显著,导致井下无




图 1 基于 SSL 的 IRS 辅助矿井通信系统信道估计方法整体框架

Fig. 1 Overall framework of channel estimation method for intelligence reflecting surface(IRS) assisted mine communication system based on self-supervised learning(SSL)

线信道与室外信道环境存在较大差异。瑞利分布适用于丰富散射环境,但其参数固定,无法适应不同多径效应强度的变化;莱斯分布适用于有强直达路径的环境,在无明显直达路径的矿井环境中表现欠佳;Nakagami-g 模型通过调整形状参数 g (g 越大,对应信道衰落程度越小, $g \geq 1/2$) 来精确描述不同程度的多径衰落^[20-21],可提高井下信道估计精度。因此,采用 Nakagami-g 模型对井下无线信道进行建模。

Nakagami-g 模型的概率密度函数为

$$f(a) = \frac{2g^g a^{2g-1}}{\Gamma(g)\Omega} \exp\left(-\frac{ga^2}{\Omega}\right) \quad a \geq 0 \quad (1)$$

式中: a 为接收的多径信号幅度; $\Gamma(g)$ 为 Gamma 函数; Ω 为平均功率。

2.2 IRS 信号传输模型

假设 x_n 为入射到 IRS 第 n ($n=1,2,\dots,N$, N 为 IRS 反射单元个数) 个反射单元的信号, y_n 为其相应的反射信号, β_n 为第 n 个反射单元对入射信号 x_n 的幅度调节系数, $\beta_n \in [0,1]$, ϕ_n 为第 n 个反射单元对入射信号 x_n 的相位调节系数, $\phi_n \in [0,2\pi)$, 则反射信号 y_n 为

$$y_n = \beta_n \exp(j\phi_n) x_n \quad (2)$$

通过控制器改变特定反射单元的幅度调节系数和相位调节系数,可控制该反射单元对入射信号的幅度和相位进行调整。

IRS 信号传输模型如图 2 所示。未安装 IRS 时,由于用户和基站之间存在障碍物,会阻挡或散射信号,导致信号无法直接通过视距链路传输。在巷道壁上安装 IRS 后,信号通过 IRS 的反射进行传输,从而克服环境带来的信号传输障碍。

考虑基站和 IRS 分别采用 M 个天线和 N 元均匀平面阵列同时为 K 个单天线用户提供服务,设 IRS 到基站的信道为 $M \times N$ 的矩阵 $\mathbf{G}$, 则信道模型为




图 2 IRS 信号传输模型

Fig. 2 Signal transmission model of IRS

$$\mathbf{G} = \sqrt{\frac{MN}{L}} \sum_{l_1=1}^L \alpha_{l_1} \mathbf{b}(\vartheta_{r,l_1}, \psi_{r,l_1}) \mathbf{c}^T(\vartheta_{t,l_1}, \psi_{t,l_1}) \quad (3)$$

式中: L 为 IRS 与基站之间的路径数; α_{l_1} 为第 l_1 条路径的损失; $\mathbf{b}$ 为基站接收信号方向的阵列响应函数; ϑ_{r,l_1} 为信号反射后到达基站的增益或损耗; ψ_{r,l_1} 为基站处的方位角; $\mathbf{c}$ 为信号在 IRS 反射方向的阵列响应函数; ϑ_{t,l_1} 为信号到达 IRS 时的增益或损耗; ψ_{t,l_1} 为 IRS 处的方位角。

IRS 与用户之间的信道可表示为

$$h_k = \sqrt{\frac{N}{L_k}} \sum_{l_2=1}^{L_k} \alpha_{k,l_2}(\vartheta_{t,l_2}, \psi_{t,l_2}) \quad (4)$$

式中: L_k 为第 k ($k=1,2,\dots,K$) 个用户与 IRS 之间的路径数; α_{k,l_2} 为第 k 个用户第 l_2 条路径的增益。

基站节点第 p ($p=1,2,\dots,P$, P 为子帧总数) 个子帧接收到的信号可表示为

$$\mathbf{Y}_p \triangleq \sum_{k=1}^K \mathbf{H}_k \Phi_p \mathbf{X}_p + \mathbf{W}_p \quad (5)$$

式中: $\mathbf{H}_k$ 为第 k 个用户的 $M \times N$ 级联信道; Φ_p 为第 p 帧 IRS 相移矩阵; $\mathbf{X}_p$ 为发射信号向量; $\mathbf{W}_p$ 为加性高斯白噪声。

根据导频序列的正交性,可将接收信号 $\mathbf{Y}_p$ 转换为第 k 个用户的接收信号向量:

$$\mathbf{Y}_k = \mathbf{H}_k \Phi_p \mathbf{X}_p + \mathbf{v}_k \quad (6)$$

式中 $\mathbf{v}_k$ 为噪声向量。

在训练阶段,原始接收信号 $\mathbf{Y}_k$ 用来生成带噪信号,并作为神经网络的输入进行训练。为了估计 $\mathbf{H}_k$,在没有先验信道知识的情况下,采用 LS 算法进行信道估计。

$$\mathbf{H}_{LS} = \mathbf{Y}_k \mathbf{Q}^H (\mathbf{Q} \mathbf{Q}^H)^{-1} \quad (7)$$

式中: $\mathbf{H}_{LS}$ 为采用 LS 估计器得到的信道估计值; $\mathbf{Q}$ 为

不同反射模式的矩阵。

然而,LS算法将信道视为一个确定但未知的常数,没有利用信道的空间特征。因此本文采用OCT神经网络优化LS估计结果。

3 SSL框架下的OCT神经网络

3.1 OCT神经网络设计

OCT^[22]的核心思想是直接对高频分量和低频分量进行处理。低频分量捕捉主要趋势和变化,高频分量详细描绘细节,如边缘和突变,这些特征在传统卷积中可能会丢失。OCT能同时捕捉信道的粗糙特征和细微差别,提供全面的信道信息,从而更准确地估计信道状态。

OCT神经网络由2个子网络模块 h_1 和 h_2 组成,每个子网络模块包含多个卷积层,每个卷积层包含ReLU激活函数和批归一化(Batch Normalization, BN),如图3所示。




图3 OCT神经网络结构

Fig. 3 Octave convolution(OCT) neural network structure

ReLU通过引入非线性来增强模型的表达能力,BN则加速并提高模型的稳定性和泛化能力。每个子网络模块后面有残差模块 g_1 和 g_2 ,残差模块使用Tanh激活函数,主要作用是使网络能够学习更复杂

的特征,对网络的输出进行平滑处理,其中的卷积层负责提取特征。

将复矩阵 A 分解为实部和虚部2个信道并作为OCT神经网络的输入: $Y=[\text{Re}\{A\}, \text{Im}\{A\}]$ 。为了让网络充分利用原始矩阵 A 的全局信息,对信道进行线性变换,将 Y 的实部和虚部交换,得到 $Y_U=[\text{Im}\{A\}, \text{Re}\{A\}]$,将其与第1个残差模块的输出进行平均。从原始输入中减去第2个残差模块的输出,得到最终输出。OCT神经网络仅采用卷积层而未使用全连接层,所以参数量少,降低了网络开销。OCT神经网络参数见表1。Initial_Conv是神经网络处理输入数据的第1个卷积层,用于将输入数据的通道数扩展到网络所需的通道数。

表1 OCT神经网络参数

Table 1 Parameters of OCT neural network

层类型	输出通道数	卷积核大小
Initial_Conv	128	(3, 3)
OctConv	32	(3, 3)
BN	64	—
残差模块(Conv)	64	(3, 3)

3.2 SSL算法实现

在实际应用中,无标签数据比有标签数据更容易获取。SSL能够利用大量的无标签数据,通过生成带噪信号来创建训练样本,从而实现高效的模型训练。由于矿井环境复杂,获取真实的CSI作为标签非常困难。本文提出SSL方法,通过使用接收信号及其带噪版本作为训练数据,避免对真实标签的依赖。

SSL分为训练和测试2个部分,如图4所示。训练阶段的输入是带噪信号 $Y+\varepsilon$,输出为去噪信号 $\hat{Y}$,通过最小化接收信号与其带噪版本之间的损失来训练神经网络。测试阶段输入为LS估计器的初步信道估计结果,输出为OCT神经网络对IRS信道的优化估计结果 $\hat{H}$ 。



图4 SSL流程

Fig. 4 Self-supervised learning(SSL) flow

SSL的核心在于通过设计前导任务自动生成标记数据,这些前导任务与信道估计高度相关。本文的前导任务是对接收信号进行去噪。

在训练阶段,从通信系统模型中获取信号 Y ,从预定义的噪声分布中生成噪声 ε , ε 通常为高斯噪

声。将噪声 ε 加到信号 Y 上,得到 $Y+\varepsilon$ 。训练数据集包含原始信号 Y 及其带噪版本 $Y+\varepsilon$ 。模型训练步骤:

1) 输入信号 $Y+\varepsilon$, 相应的标签为未受干扰的原始接收信号。

2) 采用随机梯度下降法, 结合适当的学习率对网络参数进行迭代更新。

3) 进行迭代过程, 整个训练过程分为多个训练周期, 每个周期处理小批量数据。

4) 在每次迭代中, 向输入数据注入新的噪声, 以增强模型的泛化能力和鲁棒性。

5) 使用均方误差作为损失函数, 以评估模型输出与标签之间的偏差。

模型测试步骤:

1) 模型固化, 完成训练后, 模型参数固定, 不再进行更新。

2) 输入数据, 即通过 LS 算法得到的初步信道估计结果。

3) 进行迭代过程, 采用 OCT 神经网络对 LS 估计结果进行进一步优化, 得到最终的信道估计结果。

4 仿真分析

使用 Matlab 和 Python 进行仿真, IRS 辅助矿井通信系统信道数据集在 Matlab 2022a 上产生, 共生成 96 000 个数据, 按 4:1 的比例划分为训练集和测试集。仿真参数设置: IRS 的反射单元个数为 64, 基站天线个数为 16, 用户个数为 6, 信噪比 (Signal to Noise Ratio, SNR) 范围为 $-10 \sim 10$ dB, 步长为 1 dB。矿井无线衰落信道模型为 Nakagami-m 信道。

4.1 IRS 技术对信道估计的影响


为了验证 IRS 对井下信道估计的影响, 分别在 IRS 环境和无 IRS 环境下采用 LS 和 LMMSE 算法进行信道估计, 结果如图 5 所示。仿真结果表明, 无论是 LS 算法还是 LMMSE 算法, 引入 IRS 技术均能有效降低信道估计误差。

4.2 OCT 神经网络性能验证


为验证 OCT 神经网络的性能, 对其训练损失、运行时间和参数量进行分析。

设定 SNR 为 0, 对 OCT 神经网络和传统 CNN 进行 100 个周期的训练, 结果如图 6 所示。随着训练周期的增加, 2 种神经网络都表现出较快的收敛速度, OCT 神经网络的损失值明显低于 CNN, 表明在相同的训练条件下, OCT 神经网络对数据的拟合效果更好, 在处理训练数据时更加有效。

OCT 神经网络、CNN 及传统的 LS 算法、LMMSE 算法在每个周期的运行时间见表 2。可看出 OCT 神



(a) IRS 技术对 LS 算法的影响



(b) IRS 技术对 LMMSE 算法的影响

图 5 引入 IRS 技术前后算法性能对比

Fig. 5 Comparison of algorithm performance before and after introducing IRS technology




图 6 2 种算法训练结果对比

Fig. 6 Comparison of training results of two algorithms

经网络的训练时间和测试时间均比 CNN 短, 深度学习算法的测试时间与传统算法相比明显缩短。仿真结果说明 OCT 神经网络计算效率高, 可提高通信系统信道估计的整体性能。

表 2 不同算法的运行时间

Table 2 The running time of different algorithms

算法	训练时间/s	测试时间/s
深度学习	CNN	119.04
	OCT	84.86
传统算法	LS	1.200
	LMMSE	0.722

将 80 000 个样本按 4:1 的比例划分为训练集和测试集, 分别使用 CNN、OCT 神经网络、残差网络 (Residual Network, ResNet) 和密集连接网络 (Densely Connected Network, DenseNet) 进行测试, 记录不同模

型的参数量和内存使用量,结果见表3。OCT神经网络的参数量接近CNN,由于ResNet引入了多个残差块,所以参数量明显增加。DenseNet的参数量最大,原因是DenseNet采用密集连接以增强模型的表达能力,但也导致参数量大幅增加。OCT神经网络的当前内存和峰值内存使用量均低于CNN、ResNet和DenseNet,这是因为OCT神经网络通过频率分离减少了计算量,从而减少了内存占用。在计算资源有限的环境下,OCT神经网络可保持较低参数量和内存使用量,性能最优。

表3 不同模型性能对比

Table 3 Performance comparison of different models

网络模型	参数量/个	内存使用量/GiB	
		当前	峰值
CNN	230 272	10.1	11.6
OCT	226 816	5.4	6.2
ResNet	369 280	8.3	9.0
DenseNet	821 760	7.3	8.1

4.3 SSL 算法性能验证

为了展示SSL算法的优势,将其与LMMSE、LS、监督学习(Supervised Learning, SL)算法进行对比,结果如图7所示。可看出SSL算法在各种SNR下表现均优于其他算法,尤其是在高SNR条件下,SSL算法的NMSE显著低于传统的LS和LMMSE算法。SSL算法在所有SNR条件下均能保持较低的NMSE,验证了其在信道估计中的高效性和鲁棒性。




图7 不同算法的NMSE对比

Fig. 7 Comparison of normalized mean square error(NMSE) of different algorithms

4.4 大规模网络中的扩展性验证

为了验证基于SSL的IRS辅助矿井通信系统信道估计方法在大规模网络中的可扩展性,通过增加用户和基站数量进行测试。在SNR=0的条件下,设置3种规模的网络环境。小规模网络:基站天线个数为16,用户个数为6,IRS的反射单元个数为64;中

等规模网络:基站天线个数为32,用户个数为12,IRS的反射单元个数为64;大规模网络:基站天线个数为64,用户个数为24,IRS的反射单元个数为64。不同规模网络中本文方法的NMSE与内存使用情况见表4。

表4 不同规模网络中的NMSE与内存使用情况

Table 4 NMSE and memory usage in networks of different scales

网络规模	NMSE	内存使用量/GiB
小	0.114	5.4
中	0.255	8.5
大	0.381	14.6

由表4可看出,随着网络规模的扩大,NMSE呈现上升趋势,表明信道估计的精度下降。这是因为随着用户数量的增加,用户之间干扰增多,在多输入多输出系统中,这种干扰会导致信道估计变得更困难。同时,天线数量增加也导致信道的复杂性增加,很难捕捉和估计信道特征,从而导致精度下降。随着用户数量和天线数量的增加,内存使用量也会增大。仿真结果表明,本文方法在大规模网络中具有较好的扩展性和鲁棒性,虽然大规模网络的资源需求明显增加,但可通过分布式计算和分块处理等优化策略,有效应对这些挑战。

5 结论

- 1) 结合IRS技术构建了矿井无线通信系统模型,解决多径衰落和非视距通信问题。
- 2) 采用SSL框架下的OCT神经网络优化初步信道估计结果,解决了矿井环境中真实标签难以获取的问题,提高了信道估计精度。
- 3) 仿真结果表明:①引入IRS技术能有效降低信道估计误差。②OCT神经网络的损失值明显低于CNN,数据拟合效果更好;OCT神经网络计算效率高,可提高通信系统信道估计的整体性能;在计算资源有限的环境下,OCT神经网络可保持较低参数量和内存使用量。③SSL算法在所有信噪比条件下均能保持较低的NMSE,验证了其在信道估计中的高效性和鲁棒性。④基于SSL的IRS辅助矿井通信系统信道估计方法在大规模网络中具有较好的扩展性和鲁棒性。

参考文献(References):

[1] 霍振龙,肖松,孟玮,等. 矿井5G无线通信系统关键技术及装备研发与示范应用[J]. 智能矿山, 2022, 3(4): 55-60.
HUO Zhenlong, XIAO Song, MENG Wei, et al.

- Research, development and demonstration application of key technologies and equipment of mine 5G wireless communication system[J]. *Journal of Intelligent Mine*, 2022, 3(4): 55-60.
- [2] 孙翠珍, 毛昕蓉, 马延军. 井下 OFDM 信道估计算法研究[J]. *工矿自动化*, 2014, 40(9): 39-43.
SUN Cuizhen, MAO Xinrong, MA Yanjun. Research of underground OFDM channel estimation algorithm[J]. *Industry and Mine Automation*, 2014, 40(9): 39-43.
- [3] 樊佳恒. 基于压缩感知的煤矿井下信道估计技术研究[D]. 徐州: 中国矿业大学, 2020.
FAN Jiaheng. Research on channel estimation technology in coal mine based on compressive sensing[D]. Xuzhou: China University of Mining and Technology, 2020.
- [4] BASAR E, DI RENZO M, DE ROSNY J, et al. Wireless communications through reconfigurable intelligent surfaces[J]. *IEEE Access*, 2019, 7: 116753-116773.
- [5] NADEEM Q U A, ALWAZANI H, KAMMOUN 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.
- [6] HUANG Chongwen, ZAPPONE A, ALEXANDROPOULOS G C, et al. Reconfigurable intelligent surfaces for energy efficiency in wireless communication[J]. *IEEE Transactions on Wireless Communications*, 2019, 18(8): 4157-4170.
- [7] 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.
- [8] KISSELEFF S, CHATZINOTAS S, OTTERSTEN B. Reconfigurable intelligent surfaces in challenging environments: underwater, underground, industrial and disaster[J]. *IEEE Access*, 2021, 9: 150214-150233.
- [9] CHEN Jie, LIANG Yingchang, CHENG H V, et al. Channel estimation for reconfigurable intelligent surface aided multi-user mmWave MIMO systems[J]. *IEEE Transactions on Wireless Communications*, 2023, 22(10): 6853-6869.
- [10] XIE Wenwu, XIAO Jian, ZHU Peng, et al. Deep compressed sensing-based cascaded channel estimation for RIS-aided communication systems[J]. *IEEE Wireless Communications Letters*, 2022, 11(4): 846-850.
- [11] CHEN J C. Machine learning-inspired algorithmic framework for intelligent reflecting surface-assisted wireless systems[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(10): 10671-10685.
- [12] ZHOU Gui, PAN Cunhua, REN Hong, et al. Channel estimation for RIS-aided multiuser millimeter-wave systems[J]. *IEEE Transactions on Signal Processing*, 2022, 70: 1478-1492.
- [13] JENSEN T L, DE CARVALHO E. An optimal channel estimation scheme for intelligent reflecting surfaces based on a minimum variance unbiased estimator[C]. *IEEE International Conference on Acoustics, Speech and Signal Processing*, Barcelona, 2020: 5000-5004.
- [14] WANG Tianqi, WEN Chaokai, WANG Hanqing, et al. Deep learning for wireless physical layer: opportunities and challenges[J]. *China Communications*, 2017, 14(11): 92-111.
- [15] ELBIR A M, PAPAFAFEIROPOULOS 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.
- [16] GAO Shen, DONG Peihao, PAN Zhiwen, et al. Deep multi-stage CSI acquisition for reconfigurable intelligent surface aided MIMO systems[J]. *IEEE Communications Letters*, 2021, 25(6): 2024-2028.
- [17] LIU Shicong, GAO Zhen, ZHANG Jun, 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.
- [18] KUNDU N K, MCKAY M R. A deep learning-based channel estimation approach for MISO communications with large intelligent surfaces[C]. *IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications*, London, 2020: 1-6.
- [19] LIU Chang, LIU Xueming, NG D W K, et al. Deep residual learning for channel estimation in intelligent reflecting surface-assisted multi-user communications[J]. *IEEE Transactions on Wireless Communications*, 2022, 21(2): 898-912.
- [20] 李涛, 蒋磊, 陈博文. 独立不同分布 Nakagami-m 衰落信道下最大比合并性能分析[J]. *空军工程大学学报 (自然科学版)*, 2018, 19(6): 84-89.
LI Tao, JIANG Lei, CHEN Bowen. A performance analysis of maximal ratio combining under condition of non-identically distributed nakagami-m fading channels[J]. *Journal of Air Force Engineering University (Natural Science Edition)*, 2018, 19(6): 84-89.
- [21] 张长森, 张艳芳. 矿井移动通信中 Nakagami 衰落信道模型的研究[J]. *计算机工程与应用*, 2014, 50(7): 238-241.
ZHANG Changsen, ZHANG Yanfang. Research of Nakagami fading channel model in mine mobile communication[J]. *Computer Engineering and Applications*, 2014, 50(7): 238-241.
- [22] CHEN Yunpeng, FAN Haoqi, XU Bing, et al. Drop an octave: reducing spatial redundancy in convolutional neural networks with octave convolution[C]. *2019 IEEE/CVF International Conference on Computer Vision*, Seoul, 2019: 3435-3444.