

非地面网络场景中基于全局超分去噪的信道估计

任晓宁, 段红光, 黄凤翔, 董诗康

(重庆邮电大学 通信与信息工程学院, 重庆 400065)

摘要: 在非地面网络(Non-terrestrial network, NTN)场景中, 为克服大多普勒频偏对通信的影响, 提出一种基于全局信息提取, 采用超分和去噪的信道估计方法(GSRDnNet)。此方法将最小二乘估计(Least Square, LS)算法得到的导频处信道估计矩阵视为低分辨率小尺寸图像作为神经网络的输入, 输入数据经过GSRDnNet网络处理之后将得到更为精确的高分辨率图像, 即时频资源块完整的信道响应矩阵。采用四种NTN-抽头延迟线(Tapped Delay Line, TDL)A,B,C,D信道模型进行仿真验证, 仿真结果表明GSRDnNet相比于传统LS算法, 均方误差(Mean Squared Error, MSE)性能提升3.37~8.83dB, 相比于实际信道估计(Practical Channel Estimation, PCE)算法, MSE性能提升2.11~6.06dB, 相比于需要预插值处理的SRCNN+DnCNN方法, MSE性能提升1.37~4.40dB。且较SRCNN+DnCNN, GSRDnNet网络模型的输入仅考虑导频处的信道估计矩阵, 因此不仅拥有更高的估计精度, 在计算复杂度方面也降低约84%。

关键词: 多普勒频偏; 全局信息; 超分; 去噪; 信道估计

中图分类号: TN911

文献标志码: A

Channel estimation based on global super-resolution denoising in non-terrestrial network scenarios

REN Xiaoning, DUAN Hongguang, HUANG Fengxiang, DONG Shikang

(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: In Non-terrestrial network (NTN) scenario, in order to overcome the effect of large Doppler frequency offset on the communication, a channel estimation method based on global information extraction using super-resolution and denoising (GSRDnNet) is proposed. This method considers the channel estimation matrix at the pilot obtained by the Least Squares Estimation (LS) algorithm as a low-resolution small-size image as the input to the neural network. The input data is then processed by the GSRDnNet network to obtain a more accurate high-resolution image with a complete channel response matrix for the time-frequency resource block. Four NTN-tapped delay line (TDL) A,B,C and D channel models were used for simulation verification. Simulation results indicate that GSRDnNet improves mean squared error (MSE) performance by 3.37~8.83 dB compared to the traditional LS algorithm. Compared with the Practical Channel Estimation (PCE) algorithm, the performance of MSE is improved by 2.11~6.06dB, and compared with the SRCNN+DnCNN method, which requires pre-interpolation processing, the performance of MSE is improved by 1.37~4.40dB. And compared with SRCNN+DnCNN, the input of GSRDnNet network model only considers the channel estimation matrix at the pilot, so it not only has higher estimation accuracy, but also reduces the computational complexity by about 84%.

Keywords: Doppler frequency offset; Global information; Super-resolution; Denoise; Channel estimation

0 引言

在正交频分复用 (Orthogonal Frequency Division Multiplexing, OFDM)系统中, 接收机处的信道估计对接收性能起到至关重要的作用^[1], 由于发射端和接收端之间的传播路径存在较大随机性,

在一些传输环境十分恶劣的场景中, 如 NTN 通信场景, 通信距离远、运动速度快, 对信道估计提出了更高挑战。

在 NTN 场景中, 根据卫星轨道高度, 可以将卫星大致分为三类: 低地球轨道卫星(Low Earth Orbit,LEO)^[2], 中地球轨道卫星 (Medium Earth Orbit,MEO)和同步卫星(Geosynchronous Earth Orbit, GEO)^[3]。在本文主要针对低轨卫星 LEO 应用场景, 在 LEO 卫星通信系统中, 卫星以 7000m/s 左右的速

基金项目: 重庆市自然科学基金(cstc2019jcyj-msxmX0079)
Foundation Item: Chongqing Natural Science Foundation (cstc2019jcyj-msxmX0079)

度围绕地球高速运动^[4]，此时卫星相对地面终端产生的多普勒频移远大于陆地无线通信系统产生的多普勒频移。且在 NTN 场景中，不仅需要考虑地面系统的多径干扰，还需要考虑电波在空间耗散层、热层和中间层损耗，在平流层和对流层的大气吸收、降雨和云层损耗、及电离层闪烁、对流层闪烁和法拉第旋转造成的影响，这对 NTN 场景中的信道估计提出了更高要求，信道估计的准确性，将直接决定接收机解调性能，这对 NTN 无线通信系统具有重要意义。

传统信道估计方法有 LS、线性最小均方误差 (Linear Minimum Mean Square Error, LMMSE)。传统 LS 信道估计先估计出导频处的信道响应值，然后利用插值获得完整资源块的信道矩阵，该法计算较为简单，但由于没有考虑信道噪声及残留频偏影响，其估计性能较差。LMMSE 利用信道间噪声线性无关特性，消除噪声对信道估计影响，估计性能有较大提升，但因为在其计算过程中包含矩阵求逆操作，运算复杂度较高，在实际工程中通常采用简化算法，影响了 LMMSE 性能。

近年来，随着深度学习发展，越来越多学者尝试将深度学习在图像领域的处理方法移植到信道估计领域^{[5]-[8]}。在文献[9]-[11]中，利用较大的数据集训练神经网络，虽取得较高的信道估计精度，但这也大大增加了网络训练的开销，在文献[12]中，提出用于处理图像超分辨率问题的 SRCNN 模型，它将图像由低分辨率转换为高分辨率，图像分辨率问题可表示为：

$$\hat{P}_h = F(P_l; \theta) \quad (1)$$

(1)式中： P_l 表示含有噪声的低分辨率图像， $\hat{P}_h$ 表示经过超分辨率技术得到的高分辨率图像， F 是由参数 θ 确定的超分辨率技术。

根据 SRCNN 思想，文献[13]提出一种 ChannelNet 网络模型，其将信道矩阵看作 2D 低分辨率图像，输入图像经过图像超分辨率(SRCNN)和去噪(DnCNN)网络得到细化后的高分辨率图像，但 ChannelNet 网络的输入需要对信道响应矩阵进行插值处理，将信道响应矩阵放大至时频资源块大小的尺寸，由此估计性能将受插值算法的局限，同时输入经过插值处理后的高维数据，增加了深度神经网络复杂度。

基于此，本文提出了一种 GSRDnNet，此神经网络的输入为未经插值处理的导频处 LS 信道估计值，输入数据经过本网络，首先进行全局信息提取，然后再经过超分残差和去噪处理，最终得到细化后完整的时频资源块信道估计矩阵。

1 系统模型

在 OFDM 系统中，一个时隙第 n 个 OFDM 符号上第 k 个子载波，其输入输出关系表示为：

$$Y(n, k) = H(n, k)X(n, k) + W(n, k) \quad (2)$$

(2)式中： $X(n, k)$ 为第 n 个 OFDM 符号的第 k 个子载波上的发射信号， $Y(n, k)$ 为对应位置的接收信号， $H(n, k)$ 表示对应位置的信道响应值， $W(n, k)$ 表示高斯白噪声。

传统 LS 算法，如公式(3)所示。假设一个资源块大小为 $K \times N$ ，其中 K 表示一个 OFDM 符号中包含的总子载波数， N 表示一个资源块中总 OFDM 符号数，则一个资源块的信道响应矩阵可表示为 $H \in \mathbb{C}^{K \times N}$ 。

$$\hat{H}_{(n,k)}^{LS} = X_{(n,k)}^{-1} Y_{(n,k)} \quad (3)$$

同时，用 P 表示一个资源块中单个 OFDM 符号所含的导频数量， S 表示具有导频信息的 OFDM 符号总数，由此一个资源块共包含 $P \times S$ 个导频，导频位置的信道矩阵可以表示为 $H_p \in \mathbb{C}^{P \times S}$ 。基于 LS 得到的导频位置处信道估计值可视为公式(1)中含有噪声的低分辨率图像，由此应用全局信息提取，图像超分辨率和图像去噪技术得到最终需要的完整资源块的信道估计矩阵。

由上可知，一个资源块中利用 LS 算法得到的导频处信道估计值为 $\hat{H}_p \in \mathbb{C}^{P \times S}$ ，经过超分神经网络后得到的完整资源块的信道估计矩阵为 $\hat{H} \in \mathbb{C}^{K \times N}$ ，由此超分中的信道估计问题，可以表示为：

$$\hat{H} = F(\hat{H}_p; \theta) \quad (4)$$

具体如图 1 所示，利用 LS 得到的导频处信道估计值作为神经网络模型的输入，输入数据依次经过全局信息提取和超分残差模块后得到含有噪声的资源块信道响应矩阵，然后采用去噪模块对信道响应值进行去噪处理，进一步提高网络估计性能，亦此神经网络从 $\hat{H}_p \in \mathbb{C}^{P \times S}$ 中恢复出 $\hat{H} \in \mathbb{C}^{K \times N}$ 。




图 1 GSRDnNet 网络工作原理

Fig. 1 Working principle of GSRDnNet network

2 GSRDnNet 信道估计

2.1 网络模型结构

GSRDnNet 模型结构分成全局信息提取，超分残差和去噪模块，如图 2、图 3 所示，图中已标出各层结构中包含的卷积核数量和尺寸。

全局信息提取模块：相对传统神经网络，全局信息提取模块对输入的导频处信道响应矩阵具有更强特征提取能力，使其能够更好区分不同“特征图”，此模块还同时考虑局部信息和全局信息，进一步提高网络性能。

- 1、特征提取层完成对输入数据的信道特征提取；
- 2、全局平均池化运算对信道数据进行特征统计；
- 3、压缩层和扩展层分别完成对信道数据的降维和升维操作；
- 4、特征提取层和扩展层的输出合并相乘以恢复原始信道数据维度；
- 5、压缩层对信道数据降维并将其输出作为超分残差模块的输入。

超分残差模块：该模块共包含七层，数据经过此模块将得到完整资源块的信道估计矩阵。

- 1、特征提取层实现对输入信道数据的特征提取；
- 2、压缩层实现对信道数据降维处理，亦将数据通道数从 32 降为 16；
- 3、聚合层通过四条不同路径，从多个尺度提取信

道数据特征，把各个路径得到的“特征图”合并后，输入到扩展层；

- 4、扩展层完成对信道数据升维处理；
- 5、非线性映射层实现对数据的非线性映射；
- 6、残差结构加快模型收敛，避免梯度消失和爆炸；
- 7、反卷积层实现对信道数据的上采样处理，经过该层将获得完整资源块的信道估计值。当输入、输出信道数据的维度改变时，可以通过修改反卷积层的参数来适应不同场景。

去噪网络模块：经过上采样后得到的完整信道响应估计值中含有一定的噪声，因此用 DnCNN 去噪网络进一步滤除信道数据噪声^[14]，提升网络估计性能。

- 1、Conv+PReLU, Conv+BN+PReLU, Conv 三种不同类型的层可以提取出输入信道数据中包含的噪声；
- 2、差值结构从含有噪声的输入信道数据中滤除噪声，得到最终的纯净信道数据；

随着 GSRDnNet 神经网络模型层数的加深，为进一步提升网络估计性能，在超分残差的非线性映射层输出与原始输入数据之间构建残差结构^[15]，如公式(5)所示。

$$y = F(x) + x \quad (5)$$

(5)式中： $F(x)$ 表示非线性映射层输出， x 表示超分残差层原始输入数据， y 表示反卷积层输入。




图 2 聚合层架构

Fig. 2 Aggregation layer architecture




图 3 GSRDnNet 模型架构

Fig. 3 GSRDnNet model architecture

2.2 模型训练与测试

采用 LS 得到导频位置处信道估计值作为神经网络输入，将实际信道的真实值作为标签，对 GSRDnNet 神经网络进行训练，模型训练和测试数据集共有 38000 个样本，其中训练集和测试集比例为 7:3，优化器选择 Adam^[16]，具体训练参数如表 1 所示。训练数据集可表示为：

$$(\hat{H}_p, H) = \{(\hat{H}_p^1, H^1), (\hat{H}_p^2, H^2), \dots, (\hat{H}_p^{N_s}, H^{N_s})\} \quad (6)$$

(6)式中： $\hat{H}_p^i$ 表示第 i 个训练样本， H^i 表示第 i 个训练样本对应的标签。

将神经网络 GSRDnNet 表示为 $f(\cdot)$ 可得：

$$\hat{H}_o = f(\hat{H}_i, \theta) \quad (7)$$

(7)式中： $\hat{H}_i$ 和 $\hat{H}_o$ 分别表示 GSRDnNet 网络的输入和输出。采用 MSE 作为损失函数，具体表示如下：

$$MSE = \frac{1}{n} \sum_{s=1}^n \|H^s - f(\hat{H}_i^s, \theta)\|_2^2 \quad (8)$$

(8)式中： n 表示一个训练批次包含的样本总数， H^s 表示该批次中第 s 个信道响应的真实值(标签值)， $f(\hat{H}_i^s, \theta)$ 表示利用 GSRDnNet 神经网络得到的第 s 个信道响应估计值。

同理，可以把测试数据集表示为：

$$(\hat{H}_{pT}, H) = \{(\hat{H}_{pT}^1, H^1), (\hat{H}_{pT}^2, H^2), \dots, (\hat{H}_{pT}^{N_t}, H^{N_t})\} \quad (9)$$

(9)式中： $\hat{H}_{pT}^i$ 和 H^i 分别表示第 i 个测试样本和标签。

通过测试集数据验证训练好的神经网络模型性能。

表 1 训练参数

Table. 1 Training parameters

参数	参数配置
迭代轮数	100
批次大小	32
学习率	0.001
训练集	26600
验证集	11400
优化器	Adam
激活函数	PReLU
损失函数	MSE

3 仿真验证分析

3.1 仿真环境配置

依据 3GPP 协议^[17]，本次仿真模拟在 0~25dB 信噪比下 NTN-TDL A,B,C,D 场景中的单发单收情况，并在此基础上进行仿真验证，具体仿真参数配置如表 2 所示，在本次仿真中，一个资源块包含 14 个 OFDM 符号，一个 OFDM 符号中包含 612 个子载波，解调参考信号(Demodulation Reference Signal, DMRS)类型配置为 Type1，且后置 DMRS 数量为 3，亦在 14 个 OFDM 符号的资源块中有 4 个符号承载导频信息，且每个导频符号各有 306 个子载波用来承载导频信息。

为了模拟低轨卫星通信系统，采用公式(10)计算多普勒频偏。在表 3 参数配置场景下，多普勒参数为 20KHz。大多普勒频偏对通信系统的影响，如公式(11)(12)所示， $x(\cdot)$ 为发射信号， $y(\cdot)$ 为接收信号， $w(\cdot)$ 为高斯白噪声。

$$f_{Doppler} = f_c \left(\frac{V_{sat}}{c} \right) \left(\frac{R}{R+h} \right) \cos(\theta) \quad (10)$$

$$y(t) = x(t) \exp \left(j 2 \pi \int_0^t f_{Doppler}(\tau) d\tau \right) + w(t) \quad (11)$$

$$y(n) = x(n) \exp \left(j 2 \pi \sum_{p=0}^n f_{Doppler}(p) T_s \right) + w(n) \quad (12)$$

此次仿真结合 Matlab 和 Pytorch, 采用图 4 所示仿真链路, 基于 Matlab 提供的 NTN 信道创建函数(HelperSetupNTNChannel)在 Matlab 中以资源块为单位生成训练和测试数据。把训练数据集和测试数据集输入到 Pytorch 神经网络中训练网络模型, 最后在 Matlab 中测试和验证神经网络模型。

模型训练阶段, 通过 Matlab 产生训练集, 为了提升网络模型普适性, 训练集由 0~25dB 信噪比离散均匀分布的混合数据组成, 同时增加 10KHz~20KHz 等不同类型的多普勒频偏, 然后利用公式(3)计算得到的导频处信道响应估计值 $\hat{H}_p \in \mathbb{C}^{30 \times 6}$ 作为 GSRDnNet 的输入, 利用 Matlab 提供的完美信道估计函数 (nrPerfectChannelEstimate) 计算得到的 $H \in \mathbb{C}^{612 \times 14}$ 作为实际的信道响应真实值, 即样本标签值。

将训练数据分成实部和虚部, 一起送入 GSRDnNet 模型中进行训练, 保存 Pytorch 训练好的神经网络模型, 最后在 Matlab 中分别测试 NTN-TDL-A,B,C,D 场景下神经网络模型的信道估计性能。




图 4 训练数据生成框图

Fig. 4 Training Data Generation Flowchart

表 2 仿真参数

Table. 2 Simulation parameters

参数	参数配置
带宽/MHz	20
子载波间隔/kHz	30
资源块个数	51
IFFT/FFT 点数	1024
调制方式	16QAM
PDSCH 映射类型	Type A
DMRS 配置类型	Type 1
后置 DMRS 数量	3
CP 类型	常规
多普勒频偏/Hz	10KHz/20KHz
信道延迟/ns	300
采样频率/MHz	30.72
信道环境	NTN-TDL-A,B,C, D

表 3 20KHz 多普勒参数

Table. 3 20KHz Doppler parameters

参数	参数配置
载波频率 f_c GHz	2
卫星速度 V_{sat} m/s	6500
电磁波传播速度 c m/s	3×10^8
地球半径 R km	6371
卫星轨道高度 h km	600
卫星与地面夹角 θ	60

3.2 仿真结果分析

为直观对比出 GSRDnNet 相比于其它算法的优势, 图 5 将 NTN-TDL-D 场景下, 信噪比为 10dB, 多普勒频偏为 10KHz 时各算法得到的信道响应估计值和真实信道响应值之间的差异进行可视化处理。

从图看出, 在 MSE 方面, 传统 LS 算法的 MSE 为 0.2104, PCE 算法的 MSE 为 0.0995, 文献[13]中 SRCNN+DnCNN 的 MSE 为 0.0538, 本文提出的 GSRDnNet 方法为 0.0248, 通过 MSE 对比可知 GSRDnNet 方法优于其它方法。同时通过各个信道响应估计值和真实信道响应值图形间的纹理差异性也可以看出, GSRDnNet 方法对应的纹理图最接近于真实的信道响应纹理图。因此无论从 MSE 指标还是在纹理图层面都体现了本文所提算法的优势。




图 5 10dB 信噪比下各算法信道估计结果

Fig. 5 Channel estimation results of various algorithms under 10dB signal-to-noise ratio

为验证 GSRDnNet 算法的链路性能和普适性表现, 分别在多普勒频偏为 10KHz 和 20KHz 场景下对比了 GSRDnNet 方法、传统 LS 算法、PCE 算法及 SRCNN+DnCNN 方法^[13]。同时为验证本文所提算法优势, 由于 LS 算法和 PCE 算法没有频偏抑制功能, 所以当验证这两种算法的性能时, 首先利用传统主同步信号(Primary Synchronization Signal, PSS)频偏估计算法对资源块进行频偏预补偿。

仿真采用 MSE 表示信道估计值 $\hat{H}$ 与信道真实值 H 之间的差异, 由此衡量信道估计准确性。

在图 6 中对比了四种算法在不同 NTN 环境下, 多普勒频偏为 10KHz 时的 MSE 大小。仿真表明, 在此场景下, 由于传统 LS 算法没有考虑信道噪声影响, 信道估计性能最差, PCE 算法在 LS 的基础上进行去噪处理, 性能优于 LS 算法, 文献[13]中的 SRCNN+DnCNN 和本文提出的 GSRDnNet 算法采用深度学习从大量信道相关数据集中学习数据的一般规律和特征, 拥有较强的泛化能力, 效果要优于 LS 和 PCE 算法, 同时本文 GSRDnNet 算法相比于 SRCNN+DnCNN 不受预插值处理算法的局限, 因此性能更优, 且因为 GSRDnNet 网络模型的输入仅为导频处的信道估计值, 所以其不仅拥有更高的估计精度, 在计算复杂度方面也有显著优势。在不同的 NTN 信道环境下, GSRDnNet 算法的 MSE 性能相较 LS 算法, 可提升 7.83~8.83dB; 相较 PCE 算法, 提升 5.33~6.06dB; 相较 SRCNN+DnCNN 算

法, 提升 2.73~3.14dB。




图 6 10KHz 频偏下四种 NTN 场景中的算法性能验证

Fig. 6 Performance verification of algorithms in four NTN scenarios with a frequency offset of 10KHz

同样通过图 7 可以看出在 20KHz 下的 NTN 各场景中 GSRDnNet 算法相对 LS, PCE, SRCNN+DnCNN 也有显著优势。GSRDnNet 算法的 MSE 性能, 相较 LS 算法, 可提升 3.37~7.04dB; 相较 PCE, 提升 2.11~5.75dB; 相较 SRCNN+DnCNN, 提升 1.37~4.40dB。




图 7 20KHz 频偏下四种 NTN 场景中的算法性能验证

Fig. 7 Performance verification of algorithms in four NTN scenarios with a frequency offset of 20KHz

3.3 复杂度分析

忽略激活函数 PReLU 的计算成本, 本文采用文献[18]中的方法来衡量神经网络模型的复杂度, 具体如公式(13)所示:

$$O\{(m_c \times n_c \times C_{in} \times C_{out}) \times W_d \times H_d\} \quad (13)$$

(13)式中: $m_c \times n_c$ 表示卷积核尺寸, C_{in} 和 C_{out} 分别表示输入, 输出通道数, $W_d \times H_d$ 为输入信道数据的尺寸。

通过公式(13)可看出网络模型的复杂度和输入信道数据的尺寸成正比。根据式(13)和图 2、图 3 中各个卷积层的参数配置, 可计算出 GSRDnNet 网络中涉及的复杂度运算如下:

全局信息提取模块: 在该模块包含的所有卷积层运算中, 其输入信道数据的尺寸均等于原始信道数据尺寸, 即 $W_d \times H_d = 306 \times 4$ 。由此可计算出在全局信息提取模块中涉及的复杂度运算如表 4 所示:

表 4 全局信息模块复杂度

Table. 4 Global information module complexity

模块结构	模块复杂度
特征提取层	68034816
压缩层	22560768
扩展层	2506752
压缩层	705024
合计	93807360

超分残差模块: 同全局信息提取模块, 该模块所有卷积层中包含的卷积运算其输入信道数据尺寸也是 $W_d \times H_d = 306 \times 4$ 。但该模块中的反卷积层会将原始小尺寸的输入数据即导频处信道估计值升维成整个时频资源块大小的信道响应数据即 $W_d \times H_d = 612 \times 14$ 。具体复杂度计算如表 5 所示:

表 5 超分残差模块复杂度

Table. 5 Super-resolution residual module complexity

模块结构	模块复杂度
特征提取层	352512
压缩层	5640192
聚合层	3446784
扩展层	1096704
非线性映射层	31021056
反卷积层	156672
合计	41713920

去噪网络模块: 在经过超分残差模块的反卷积层作用后, 去噪网络模块中包含的所有卷积运算其

输入信道数据的尺寸均为: $W_d \times H_d = 612 \times 14$ 。将每个卷积层涉及的复杂度相加后, 得到去噪网络模块的总复杂度为 812109312;

将全局信息提取, 超分残差和去噪三大模块中涉及到的复杂度相加, 得到 GSRDnNet 网络模型的总复杂度为 947630592;

同理, 由于 ChannelNet 网络的输入需要对信道响应矩阵进行插值处理, 将信道响应矩阵放大至时频资源块大小的尺寸, 因此在该网络包含的所有卷积层运算中, 其输入信道数据的尺寸均为: $W_d \times H_d = 612 \times 14$, 再结合 ChannelNet 网络中各个卷积层的参数配置, 得出该网络模型的总复杂度为 5764002048。

综上所述, 两个网络模型的具体复杂度对比如表 6 所示:

表 6 算法复杂度

Table. 6 Algorithm complexity

网络模型	模型复杂度
GSRDnNet	947630592
SRCNN+DnCNN	5764002048

由此得出, GSRDnNet 网络模型的复杂度相比 SRCNN+DnCNN 降低约 84%, 保存模型需要的存储空间更小, 更加有利于实际部署。

4 结论

本文研究了在 NTN-TDL 场景下信道估计相关算法。提出将 GSRDnNet 模型用于信道估计, 经仿真验证 GSRDnNet 方法性能要远优于传统 LS 算法, 去噪 LS 算法(PCE)。GSRDnNet 方法取消预插值处理算法约束, 网络模型的输入仅为导频处的信道估计值, 相比于 SRCNN+DnCNN 方法是低维数据, 所以无论是在信道估计性能方面还是在计算复杂度方面都有显著优势。

参考文献:

- [1] LIU J. Wireless multipath fading channels modeling and simulation based on Sum-of-Sinusoids[C]//2016 First IEEE International Conference on Computer Communication and the Internet (ICCCI). Wuhan, China: IEEE, 2016: 165-168.
- [2] 周赫, 高晓铮, 丁旭辉, 等. 天空地多层异构融合网络性能分析及切换协议优化 [J]. 数据采集与处

- 理, 2024,39(01):95-105.
- ZHOU He, GAO Xiaozheng, DING Xuhui, et al. Performance Analysis and Handover Protocol Optimization of Sky-Ground Multilayer Heterogeneous Integrated Networks[J]. Journal of Data Acquisition and Processing, 2024,39(01):95-105.
- [3] 贾森浩, 曲伟智, 李立斌, 等. 基于相对距离估计的空间非合作目标跟踪方法[J]. 南京航空航天大学学报, 2023,55(06):997-1003.
- JIA Senhao, QU Weizhi, LI Libin, et al. A space non-cooperative target tracking method based on relative distance estimation[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023,55(06):997-1003.
- [4] 鲁东明, 陈少峰. 低轨卫星物联网星地距离时间同步及多普勒频偏补偿技术[J]. 现代导航, 2023,14(04):283-290.
- LU Dongming, CHEN Shaofeng. Technology of satellite-Earth distance time synchronization and Doppler frequency offset compensation for low-orbit satellite Internet of Things[J]. Modern navigation, 2023,14(04):283-290.
- [5] GARLAPATI K, KOTA N, MONDRETI Y S, et al. Deep Learning Aided Channel Estimation in OFDM Systems[C]//2022 International Conference on Futuristic Technologies (INCOFT). Belgaum, India: IEEE, 2022: 1-5.
- [6] SIRIWANITPONG A, BOONSRIMUANG P, MORI K, et al. A Deep Learning-Based Channel Estimation for High-Speed Train Environments[C]//2022 19th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). Prachuap Khiri Khan, Thailand: IEEE, 2022: 1-4.
- [7] HASINI D, REDDY K R L. Channel estimation and signal detection in OFDM systems using deep learning[C]//2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS). Coimbatore, India: IEEE, 2023, 1: 1337-1340.
- [8] LIANG T, YANG Y. Channel Estimation Algorithm Based on Deep Learning for OFDM System[C]//2023 35th Chinese Control and Decision Conference (CCDC). Yichang, China: IEEE, 2023: 3078-3081.
- [9] MEHRABI M, MOHAMMADKARIMI M, ARDAKANI M, et al. A deep learning based channel estimation for high mobility vehicular communications[C]//2020 International Conference on Computing, Networking and Communications (ICNC). Big Island, HI, USA: IEEE, 2020: 338-342.
- [10] 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.
- [11] LIAO Y, HUA Y, DAI X, et al. ChanEstNet: A deep learning based channel estimation for high-speed scenarios[C]//ICC 2019-2019 IEEE international conference on communications (ICC). Shanghai, China: IEEE, 2019: 1-6.
- [12] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 38(2): 295-307.
- [13] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [14] KANG M J, LEE J H, CHAE S H. Channel estimation with DnCNN in massive MISO LEO satellite systems[C]//2023 Fourteenth International Conference on Ubiquitous and Future Networks (ICUFN). Paris, France: IEEE, 2023: 825-827.
- [15] USATYUK V S, EGOROV S I. 2D/3D ResNet Deep Neural Network for 4G and 5G NR Wireless Channel Estimation[C]//2023 25th International Conference on Digital Signal Processing and its Applications (DSPA). Moscow, Russian Federation: IEEE, 2023: 1-4.
- [16] 黄凤翔, 段红光, 刘何鑫. 基于快速超分辨率重建与残差连接的信道估计[J]. 电讯技术, 2024,64(05):678-684.
- HUANG Fengxiang, DUAN Hongguang, LIU Hexin. Channel Estimation Based on Fast Super-Resolution Reconstruction and Residual Connection[J]. Telecommunication Engineering, 2024,64(05):678-684.
- [17] 3GPP. TS 38.211. Physical channels and modulation[S].

France: 3GPP Organizational Partners, 2019.

- [18] Dong C, Loy C C, Tang X. Accelerating the super-resolution convolutional neural network[C]//Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part II 14. Springer International Publishing, 2016: 391–407.



任晓宁(1999-), 男, 硕士研究生, 研究方向: 卫星通信、深度学习、信道估计。

E-mail: s220101127@stu.cqupt.edu.cn



段红光(1969-), 通信作者, 男, 正高级工程师, 硕士生导师, 研究方向: 5G NR 信号处理技术、深度学习在信号处理中应用。E-mail: duanhg@cqupt.edu.cn



黄凤翔(1999-), 男, 硕士研究生, 研究方向: 深度学习、信道估计。E-mail: s210101053@cqupt.edu.cn



董诗康(2000-), 男, 硕士研究生, 研究方向: 卫星通信、信道估计。

E-mail: s220101026@stu.cqupt.edu.cn