

# 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超分辨率和去噪的神经网络(Global information super resolution denoising neural network, 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, 将其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4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)提升3.37~8.83 dB, 相比于实际信道估计(Practical channel estimation, PCE)算法, MSE提升2.11~6.06 dB, 相比于需要预插值处理的超分辨率卷积神经网络(Super resolution convolutional neural network, SRCNN)+去噪卷积神经网络(Denoising convolutional neural network, DnCNN)方法, MSE性能提升1.37~4.40 dB。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, 计算复杂度也降低了约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) scenarios, to overcome the effect of large Doppler frequency offset on the communication, a channel estimation method based on global information super resolution denoising neural network (GSRDnNet) is proposed. This method considers the channel estimation matrix at the pilot obtained by the least square (LS) estimation algorithm as a low-resolution small-size image and takes it 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 are 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

基金项目: 重庆市自然科学基金(cstc2019jcyj-msxmX0079)。

收稿日期: 2024-06-06; 修訂日期: 2024-11-19

channel estimation (PCE) algorithm, the MSE is improved by 2.11—6.06 dB, and compared with the SRCNN+DnCNN method, which requires pre-interpolation processing, the MSE is improved by 1.37—4.40 dB. And compared with super resolution convolutional neural network (SRCNN) +denoising convolutional neural network (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%.

**Key words:** Doppler frequency offset; global information; super-resolution; denoise; channel estimation

## 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<sup>[1]</sup>。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,如非地面网络(Non-terrestrial network, 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。

卫星在NTN场景中,根据卫星轨道高度,可以将卫星大致分为3类:低地球轨道(Low earth orbit, LEO)卫星<sup>[2]</sup>,中地球轨道(Medium earth orbit, MEO)卫星和同步(Geosynchronous earth orbit, GEO)卫星<sup>[3]</sup>。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7 000 m/s左右的速度围绕地球高速运动<sup>[4]</sup>。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。

传统信道估计方法有最小二乘(Least square, 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。该方法计算较为简单,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<sup>[5-8]</sup>。文献[9-11]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,文献[12]提出用于处理图像超分辨率问题的超分辨率卷积神经网络(Super resolution convolutional neural network, 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

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

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, $F$ 为由参数 $\theta$ 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SRCNN和去噪卷积神经网络(Denoising convolutional neural network, 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,本文提出了一种全局信息提取超分辨率和去噪的神经网络(Global information super resolution denoising neural network, 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

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

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 $H \in \mathbb{C}^{K \times N}$ 。

$$\hat{H}^{LS}(n, k) = X^{-1}(n, k)Y(n, k) \quad (3)$$

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,神经网络从 $\hat{H}_p \in \mathbb{C}^{P \times S}$ 中恢复出 $\hat{H} \in \mathbb{C}^{K \times N}$ 。

## 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、3所示,图3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;

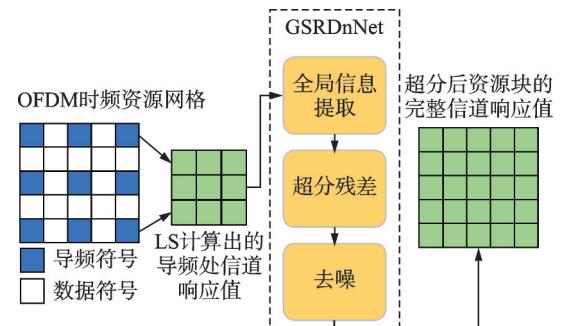


图1 GSRDnNet网络工作原理  
Fig.1 Working principle of GSRDnNet network

(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 7 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 4 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<sup>[14]</sup>,提升网络估计性能。

(1) Conv+参数化修正线性单元(Parametric rectified linear unit, PReLU)、Conv+批归一化(Batch normalization, BN)+PReLU 和 Conv 3 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<sup>[15]</sup>即

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

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。

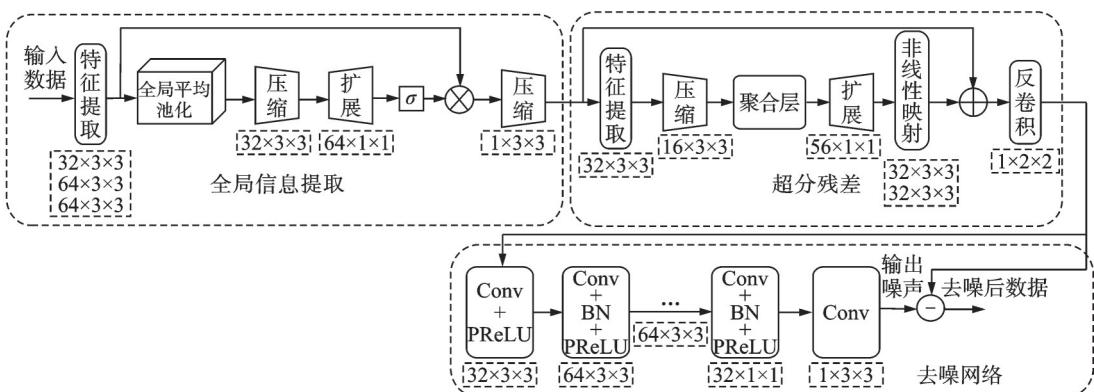


图 3 GSRDnNet 模型架构

Fig.3 GSRDnNet model architecture

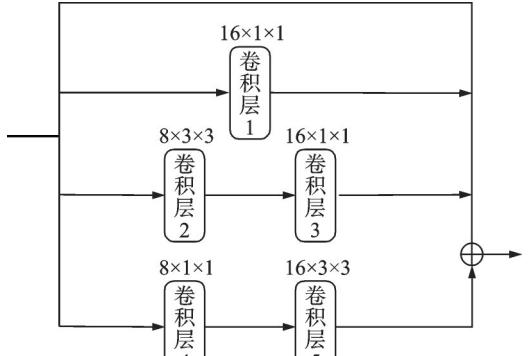


图 2 聚合层架构

Fig.2 Aggregation layer 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38 000个样本,其中训练集和测试集比例为7:3,优化器选择Adam<sup>[16]</sup>,具体训练参数如表1所示。训练数据集可表示为

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

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

$$\hat{H}_O = f(\hat{H}_I, \theta) \quad (7)$$

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,具体表示为

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

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

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

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。

## 3 仿真验证分析

### 3.1 仿真环境配置

依据3GPP协议<sup>[17]</sup>,本次仿真模拟在0~25 dB信噪比下NTN-抽头延迟线(Tapped delay line, 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Type 1,且后置DMRS数量为3。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。

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	26 600
验证集	11 400
优化器	Adam
激活函数	PReLU
损失函数	MSE

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
快速傅里叶逆变换(Inverse fast Fourier transform, IFFT)/快速傅里叶变换(Fast Fourier transform, FFT)点数	1 024
调制方式	16QAM
物理下行共享信道(Physical downlink shared channel, PDSCH)映射类型	Type A
DMRS配置类型	Type 1
后置DMRS数量	3
循环前缀(Cyclic prefix, CP)类型	常规
多普勒频偏/kHz	10/20
信道延迟/ns	300
采样频率/MHz	30.72
信道环境	NTN-TDL-A, B, C, D

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

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

$$y(t) = x(t) \exp^{j2\pi \int_0^t f_{\text{Doppler}}(\tau) d\tau} + w(t) \quad (11)$$

$$y(n) = x(n) \exp^{j2\pi \sum_{p=0}^n f_{\text{Doppler}}(p) T_s} + w(n) \quad (12)$$

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0~25 dB信噪比离散均匀分布的混合数据组成,同时增加10~20 kHz等不同类型的多普勒频偏,然后利用式(3)计算得到的导频处信道响应估计值 $\hat{H}_p \in \mathbb{C}^{306 \times 4}$ 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。

### 3.2 仿真结果分析

为直观对比出GSRDnNet相比于其他算法的优势,图5将NTN-TDL-D场景下,信噪比为10 dB,多普勒频偏为10 kHz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5看出,在MSE方面,传统LS算法的MSE为0.210 4,实际信道估计(Practical channel estimation, PCE)算法的MSE为0.099 5,文献[13]中SRCNN+DnCNN的MSE为0.053 8,本文提出的GSRDnNet方法为0.024 8,通过MSE对比可知GSRDnNet方法优于其他方法。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。

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10 kHz和20 kHz场景下对比了GSRDnNet方法、传统LS算法、PCE算法及SRCNN+DnCNN方法<sup>[13]</sup>。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。

表3 20 kHz多普勒参数

参数	参数配置
载波频率 $f_c/\text{GHz}$	2
卫星速度 $V_{\text{sat}}/(\text{m}\cdot\text{s}^{-1})$	6 500
电磁波传播速度 $/(\text{m}\cdot\text{s}^{-1})$	$3 \times 10^8$
地球半径 $R/\text{km}$	6 371
卫星轨道高度 $h/\text{km}$	600
卫星与地面夹角 $\theta/(^\circ)$	60

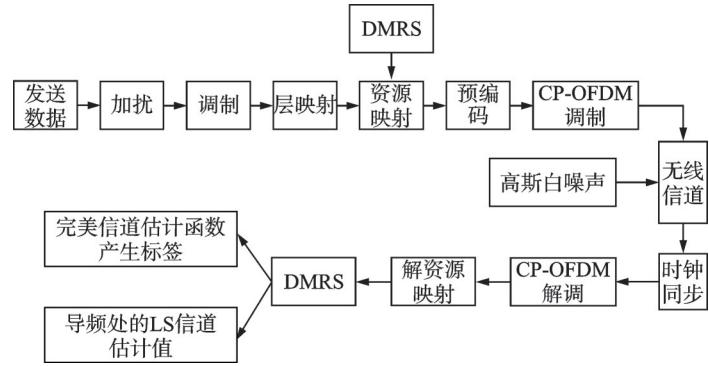


图4 训练数据生成框图  
Fig.4 Training data generation flowchart

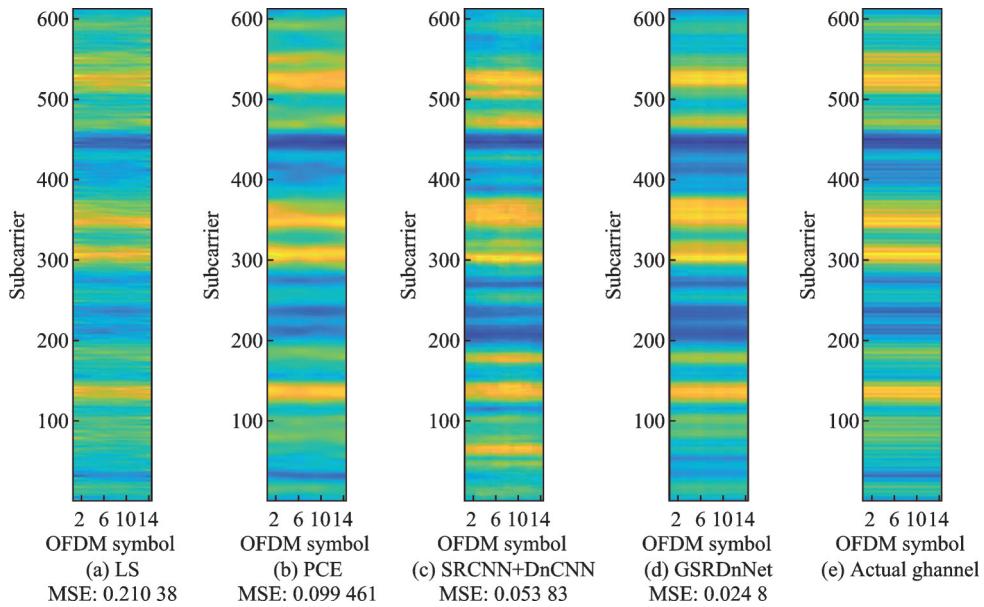


图 5 10 dB 信噪比下 5 种算法信道估计结果

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

在图 6 中对比了 4 种算法在不同 NTN 环境下,多普勒频偏为 10 kHz 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

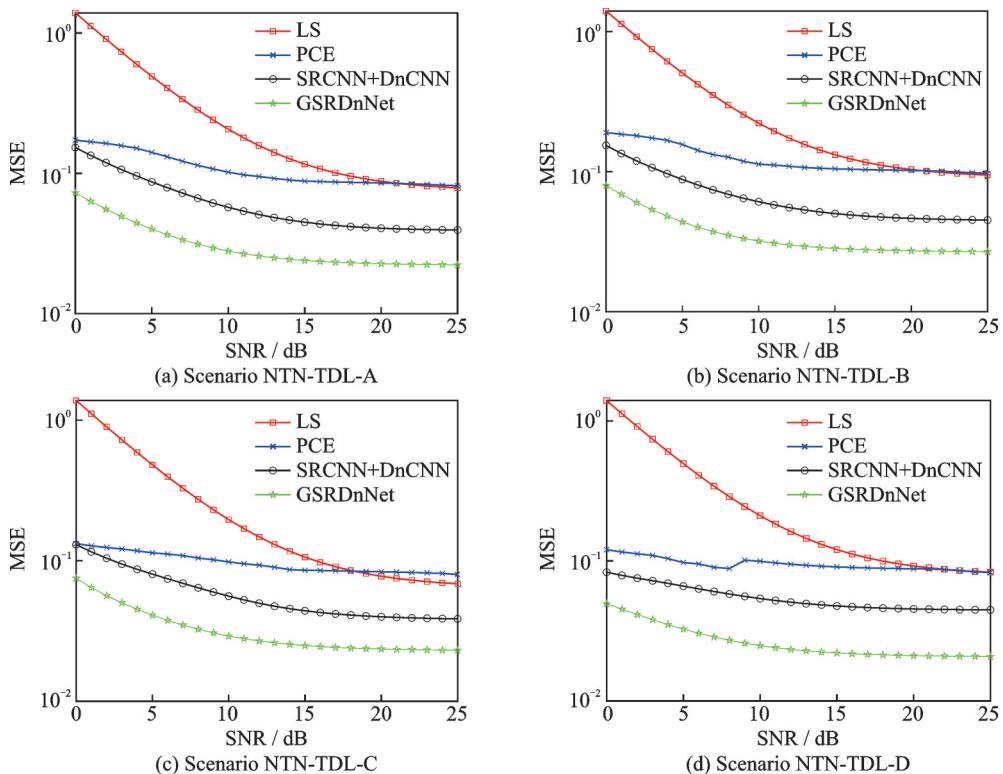


图 6 10 kHz 频偏下 4 种 NTN 场景中的算法性能验证

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

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,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7.83~8.83 dB;相较PCE算法,提升5.33~6.06 dB;相较SRCNN+DnCNN算法,提升2.73~3.14 dB。

图7可以看出,在20 kHz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3.37~7.04 dB;相较PCE,提升2.11~5.75 dB;相较SRCNN+DnCNN,提升1.37~4.40 dB。

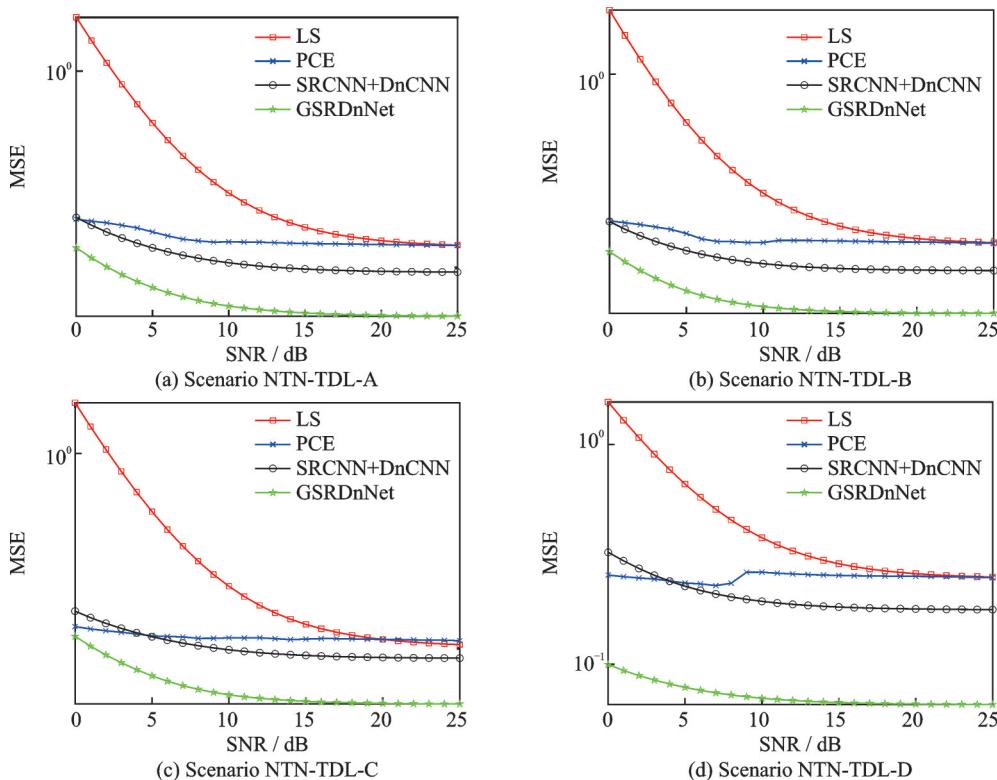


图7 20 kHz频偏下4种NTN场景中的4种算法性能验证

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

### 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,具体为

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

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

通过式(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、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。

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。

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 812 109 312。将全局信息提取、超分残差和去噪3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 947 630 592。

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 5 764 002 048。

综上所述,两个网络模型的具体复杂度对比如表6所示。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 结束语

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]//Proceedings of 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(1): 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(1): 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(6): 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(6): 997-1003.

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	68 034 816
压缩层	22 560 768
扩展层	2 506 752
压缩层	705 024
合计	93 807 360

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	352 512
压缩层	5 640 192
聚合层	3 446 784
扩展层	1 096 704
非线性映射层	31 021 056
反卷积层	156 672
合计	41 713 920

表6 算法复杂度

Table 6 Algorithm complexity

网络模型	模型复杂度
GSRDnNet	947 630 592
SRCNN+DnCNN	5 764 002 048

- [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(4):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(4): 283-290.
- [5] GARLAPATI K, KOTA N, MONDRETI Y S, et al. Deep learning aided channel estimation in OFDM systems[C]// Proceedings of 2022 International Conference on Futuristic Technologies (INCOFT). Belgaum, India: IEEE, 2022: 1-5.
- [6] SIRIWANITPONG A, BOONSIMUANG P, MORI K, et al. A deep learning-based channel estimation for high-speed train environments[C]//Proceedings of 2022 19th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). Prachap 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]//Proceedings of 2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS). Coimbatore, India: IEEE, 2023: 1337-1340.
- [8] LIANG T, YANG Y. Channel estimation algorithm based on deep learning for OFDM system[C]//Proceedings of 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]//Proceedings of 2020 International Conference on Computing, Networking and Communications (ICNC). Big Island, 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]// Proceedings of 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]// Proceedings of 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]// Proceedings of 2023 25th International Conference on Digital Signal Processing and its Applications (DSPA). Moscow, Russian: 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(5):678-684.  
HUANG Fengxiang, DUAN Hongguang, LIU Hexin. Channel estimation based on fast super-resolution reconstruction and residual connection[J]. Telecommunication Engineering, 2024, 64(5): 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]//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, Netherlands: Springer, 2016: 391-407.

## 作者简介:



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的应用,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@stu.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。