



研究与开发

基于复数生成对抗网络的5G OFDM信道估计方法

陆元智¹, 魏祥麟², 于龙², 姚昌华¹

(1. 南京信息工程大学电子与信息工程学院, 江苏 南京 210044;

2. 国防科技大学第六十三研究所, 江苏 南京 210007)

摘要: 准确的信道估计能够显著地降低误码率 (bit error rate, BER), 提高无线通信效率和质量, 是5G OFDM通信系统接收机设计的关键环节之一。基于最小二乘 (least square, LS) 法和基于最小均方差 (minimum mean square error, MMSE) 的信道估计方法利用系统稀疏性计算信道响应矩阵, 但LS算法计算精度较低, 而MMSE算法计算量过大。为提升估计精度, 业界设计了基于深度学习的信道估计方法。然而, 现有的深度学习方法将复数矩阵拆分成实部和虚部, 没有充分提取信道中的复数特征, 造成估计的信道响应矩阵出现失真。为此, 设计了一种基于复数的生成对抗网络模型, 充分提取信号的复数特征, 从而更准确地估计5G新空口 (new radio, NR) 标准的物理下行链路共享信道 (physical downlink shared channel, PDSCH) 的信道响应矩阵。为了验证所提方法的有效性, 将所提方法分别与LS算法、实际信道估计、超分辨率神经网络、残差神经网络信道估计算法进行了对比分析。结果表明, 当估计的信道响应矩阵与真实矩阵之间的均方差达到0.01时, 采用所提方法实现的无线通信系统的信噪比高于现有方法5 dB左右。

关键词: 5G新NR; 信道估计; 物理下行链路共享信道; 复数神经网络; 生成对抗网络

中图分类号: TN911

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024069

5G OFDM channel estimation method based on complex-valued generative adversarial network

LU Yuanzhi¹, WEI Xianglin², YU Long², YAO Changhua¹

1. School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China

2. The 63rd Research Institute, National University of Defense Technology, Nanjing 210007, China

Abstract: Accurate channel estimation is a critical component in the design of 5G OFDM communication system receivers, since it can significantly reduce the bit error rate (BER), thus improving wireless communication efficiency

收稿日期: 2023-10-20; 修回日期: 2023-12-22

基金项目: 国家自然科学基金资助项目 (No.61971439, No.U22B2002); 江苏省自然科学基金资助项目 (No. BK20191329); 通信抗干扰全国重点实验室基础科研创新基金 (稳定支持) 项目 (No.IFN20230207)

Foundation Items: The National Natural Science Foundation of China (No. 61971439, No. U22B2002), The Natural Science Foundation of Jiangsu Province of China (No. BK20191329), The National Key Laboratory of Wireless Communications Foundation (No. IFN20230207)



and quality. Channel estimation methods based on least square (LS) and minimum mean square error (MMSE) effectively utilize the system's sparsity, but LS algorithms face low computational precision, while MMSE algorithms suffer from high computational complexity. To promote the estimation accuracy, practitioners have presented several deep learning-based channel estimation methods. However, existing methods often split complex matrices into real and imaginary parts, failing to adequately capture the complex characteristics of the channel, leading to distortion in the estimated channel matrix. A complex-valued generative adversarial network (GAN) model that could fully extract the complex features of the signals was proposed, enabling accurate estimation of the channel matrix for the physical downlink shared channel (PDSCH) in the 5G new radio (NR) standard. To validate the effectiveness of the proposed method, the proposed method was compared with LS algorithms, actual channel estimation, super-resolution neural networks, and residual neural network channel estimation methods. Results show that when the mean square error between the estimated channel matrix and the true channel matrix is 0.01, the proposed method-based communication system has a signal-to-noise ratio (SNR) that is 5 dB higher than existing ones.

Key words: 5G new radio, channel estimation, PDSCH, complex valued neural network, generative adversarial network

0 引言

5G NR 标准使用正交频分复用 (orthogonal frequency division multiplexing, OFDM) 作为调制和解调技术, 以充分利用其较强的抗频率选择性衰落特性来提升频谱利用率。在系统设计中, 信道估计用于确定信道的频率脉冲或频率响应, 以此来纠正并准确恢复接收的数据, 是提升无线通信系统效能的关键一环。5G OFDM 信道估计的挑战主要来自两个方面。一方面, 无线信道容易受多径传播、多普勒频移和传输环境的非平稳特性影响; 另一方面, 5G NR 标准利用了子载波数据的大带宽, 其信道频率响应矩阵维度较高, 而解调参考信号 (demodulation reference signal, DM-RS) 仅在信道带宽内的一部分子载波上传输, 对信道估计提出了巨大挑战^[1]。传统的基于导频信号的信道估计方法, 如 LS 算法和最小均方差 (minimum mean square error, MMSE), 都是在接收端利用导频位置处的导频信息估计信道频率响应的未知值。LS 算法利用插值的方法估计信道, 计算量小, 但是没有考虑信道中噪声的影响, 在低信噪比时性能表现较差; 虽然 MMSE 算法能够提高信道估计的准确率, 但是需要信道的统计信息和矩阵的求逆运算来恢复信道, 计算复

杂度高, 难以实际应用^[2]。

为了提升信道估计准确性, 业界开始应用在计算机视觉、自然语言处理等领域取得巨大成功的深度学习技术, 设计了多种信道估计^[3-17]和信道状态信息 (channel state information, CSI) 反馈^[18-19]方法, 在多种环境下取得了较高的估计精度。当前方法大多将 CSI 矩阵拆分成实部和虚部作为训练数据, 然后设计相应的实数深度神经网络来恢复信道响应矩阵。这样操作虽然能够很容易地训练神经网络学习 CSI 矩阵中的信息, 但是却忽略了 CSI 中的相位、频率和幅值等信息, 导致无法充分地提取无线信道中的复数特征。此外, 大部分基于深度学习的信道估计方法并未考虑 5G NR 标准的通信系统。

在此背景下, 本文在 3GPP 5G NR 标准的基础上, 搭建通信系统进行数据采集, 将收集的信道矩阵以复数形式保存, 提出了一种以复数卷积神经网络为基础的生成对抗网络 (complex-valued CNN based generative adversarial network, CV-GAN) 信道估计算法, 通过训练两个深度复数卷积神经网络, 使其生成器能够估计出更加真实可靠的信道矩阵。本文主要贡献在于以下两个方面。

一是针对 5G NR 标准的 OFDM 通信系统, 提出了一个以复数卷积神经网络为基础的生成对抗

网络的信道估计算法,利用GAN体系结构解决了传统深度学习方法中损失函数设计的难题,并且引入复数卷积神经网络充分提取无线信道中的复数特征,降低了估计信道和真实信道之间的均方差,提升了估计准确性。

二是通过模拟仿真5G NR标准的物理下行链路共享信道,产生不同类型的训练数据和测试数据,评估CV-GAN的性能,结果表明,当估计信道矩阵与真实信道矩阵之间的均方差达到0.01时,所提方法的信噪比可以提升5 dB左右的性能。

1 相关工作

卷积神经网络(convolutional neural network, CNN)可以利用空间、时域和频域中邻近元素的相关性进行信道估计,近年来,利用CNN还原信道矩阵的研究取得了不错的成功。文献[3]利用二维图像呈现信道的时频衰落矩阵,为了更精确地估计信道,将由导频位置的导频信号组成的矩阵视为低分辨率的二维图像,采用超分辨率网络和图像去噪网络结合的ChannelNet来估计信道响应矩阵。文献[4]将深度学习算法与超分辨率重建理念相结合,利用密集卷积神经网络(DenseNet)将低分辨率导频信息图像重建为高分辨率的完整信道脉冲响应(full-channel impulse response, CIR)。在多输入多输出(MIMO)通信系统中,发送端和接收端利用多个天线以提高频谱效率和可靠性,信道估计能够提高接收信号的可靠性。但是,增加的信道系数也会使信道估计变得非常复杂,而且多路径传输也会引入一定的延迟和信号回波,这给信道估计带来巨大的挑战。针对MIMO通信系统的信道估计,文献[5]提出了一种新颖的增强卷积神经的方法,用于克服多路径传输的延迟和信号回波。文献[6]利用基于卷积神经网络自编码器(CNNAE)分类器,对MIMO-OFDM系统的信道进行估计。针对5G移

动通信系统的信道估计,文献[7]在5G NR标准下产生信道矩阵,构建融入残差连接的卷积神经网络的信道估计方法,将信道矩阵视为二维图像,借鉴图像恢复的方法来恢复所需信道矩阵。

不仅CNN可以应用在信道估计中,使用深度神经网络(deep neural network, DNN)进行信道估计也是一个研究的热点。文献[8]使用深度神经网络在OFDM系统中进行信道估计和信号检测,将OFDM调制和无线信道视为黑盒子,该方法能够隐式地估计CSI。针对MIMO系统,文献[10]设计了一种基于张量网络的时变信道估计方法,将DNN隐藏层分解为具有较少参数的张量,从而降低了硬件要求和运行时间。文献[9]提出了一种基于1D-Concatenate的深度神经网络模型优化方法,用于提高无线通信中信道估计的精度。该方法通过一维数据转换和跳跃连接引入DNN模型,有效抑制了梯度消失问题,并恢复了网络训练过程中丢失的数据特征。

RNN对数据的时域相关性十分敏感,能够有效地跟踪时变信道的特征。针对高速移动环境下信道的时变性质,文献[11]提出一种名为ChanEstNet的深度学习网络算法。该网络通过使用双向长短期记忆(BiLSTM)网络来估计信道,通过离线训练数据来学习信道特征,从而在高速环境中提高信道估计的性能。

在信道估计中,传统的深度学习方法主要关注输入与实际信道之间的映射关系。然而,这种映射难以被准确设计与建模。为此,文献[13]引入了条件生成对抗网络(CGAN)来改进信道估计。CGAN通过联合训练生成器和判别器,学习从接收量化信号和导频到实际信道矩阵的映射。这一方法在性能上超越了现有的深度学习方法,为信道估计问题带来了更有效的解决方案,尤其在大规模MIMO系统中具有鲁棒性。文献[12]提出了一种基于生成对抗网络(GAN)的两级信道估计方法N2N-GAN,用于解决大规模多输入多



输出系统中导频序列长度小于发射天线数量时的信道估计问题。该方法首先对接收端的导频信号进行去噪,然后利用条件生成对抗网络估计信道矩阵。

针对 5G 系统中的信号接收问题,特别是子载波间串扰和子符号间干扰,文献[14]提出了一种创新的基于深度学习的信道估计模型 PDAAB。该模型通过将初步估计的信道视为含噪声的低分辨率图像,利用深度学习网络学习低分辨率与高分辨率图像之间的映射关系,从而去除噪声并恢复高分辨率信道图像。

表 1 对比了不同深度学习方法在信道估计领域中的应用场景、方法、网络结构、特点以及优势。这些基于不同深度学习的信道估计方法在各自的应用场景中,通过不同的方法和网络结构,实现了对信道状态信息的估计。它们各自的优点使得它们在特定场景下具有出色的性能。

2 系统模型

本文使用 5G NR 标准协议来构建 OFDM 系统,构建单输入单输出(single input single output, SISO)的 OFDM 系统的 5G 物理下行链路共

享信道(PDSCH)。该系统利用资源元素(resource element, RE)传输数据,每个 RE 对应 OFDM 符号上的一个载波。在一个时隙(slot)中有 N_{sym} 个 OFDM 符号, N_{SC} 个子载波构成一个资源块(resource block, RB),规定 $N_{\text{SC}}=12$,一个时隙可以有 N_{RB} 个 RB,且 N_{RB} 没有具体规定,可根据需求设定。本文设定的参数值为 $N_{\text{sym}}=14$, $N_{\text{SC}}=12$, $N_{\text{RB}}=6$ 。一个时隙的资源网格如图 1 所示,由 N_{sym} 个 OFDM 符号和 N_{SC} 个子载波组成,其中包含两种 RE,分别为解调参考信号(demodulation reference signal, DMRS)和 PDSCH。在 5G NR 系统中,DMRS RE 用来传输导频信息,DMRS 即导频信号,其位置和数量可以灵活配置,数据则通过 PDSCH RE 传输。由于导频信号是已知且固定的,很容易便可获得 DMRS RE 处的频率响应,因此在接收端对数据进行检测和解码前,需要先获取 DMRS RE 处的频率响应,然后通过插值的方法获得 PDSCH RE 处的频率响应值。

在 OFDM 系统中,信号经过多径信道和噪声干扰后,第 i 个子载波和第 k 个符号的输入输出关系可以表示为:

表 1 不同深度学习方法在深度学习领域的对比

应用场景	文献	方法	网络结构	特点	优势
OFDM	[3]	基于 CNN	超分辨率网络+图像去噪网络	利用图像处理技术还原时频衰落矩阵	提高信道估计准确性
	[8]	基于 DNN	深度神经网络	将信道和调制视为“黑盒子”,实现隐式的 CSI 估计	降低复杂度,提高信道估计性能
MIMO	[4]	DenseNet	密集卷积层构建的 DenseNet	利用 DenseNet 重建信道脉冲响应	提升信道估计性能,重建高分辨率信道响应
	[10]	基于 DNN	DNN 隐藏层分解为参数更少的张量	降低硬件需求和运行时间,适用于复杂场景	适应 MIMO 系统
MIMO-OFDM	[6]	CNN 自编码器	基于 CNNAE 构建的分类器	利用自编码器对 MIMO 信道进行估计	有效估计 MIMO-OFDM 信道
5G NR	[7]	基于 CNN	融合残差链接的卷积神经网络	将信道矩阵视为图像,结合残差链接,采用图像恢复的方法进行估计	适应 5G NR 标准,提高信道估计精度
高速移动环境	[11]	基于 RNN	双向长短期记忆网络	使用 BiLSTM 网络估计时变信道	适应高速环境下的信道估计,学习快速时变和非平稳信道等
大规模 MIMO	[13]	CGAN	使用 U-net 作为生成器	学习从量化观测值到真实信道的映射	提高信道估计精度,复杂度相对较低,具有鲁棒性




图1 资源网格

$$\mathbf{Y}_{i,k} = \mathbf{H}_{i,k} \mathbf{X}_{i,k} + \mathbf{Z}_{i,k} \quad (1)$$

其中, $\mathbf{H}_{i,k}$ 表示第 k 个符号的第 i 个子载波的信道频率响应; $\mathbf{X}_{i,k}$ 为发送的符号; $\mathbf{Z}_{i,k}$ 为高斯白噪声; $\mathbf{H}$ 表示信道对所有子载波和符号的频率响应。

传统的 LS 方法是借助于导频实现的, 可表示为:

$$\hat{\mathbf{H}}_p^{\text{LS}} = \arg \min_{\mathbf{H}_p} \|\mathbf{y}_p - \mathbf{H}_p \mathbf{x}_p\|_2^2 \quad (2)$$

其中, $\|\cdot\|_2$ 表示欧氏范数, $\hat{\mathbf{H}}_p^{\text{LS}} \in \mathbb{C}^{N_p \times N_p}$ 为估计的信道矩阵; $\mathbf{x}_p$ 和 $\mathbf{y}_p$ 分别为接收端和发送端的导频符号。优化式 (2) 可得到 $\hat{\mathbf{h}}_p^{\text{LS}} = \text{diag}(\hat{\mathbf{H}}_p^{\text{LS}}) = \mathbf{y}_p / \mathbf{x}_p$, 然后利用插值算法可以得到整个信道的频率响应 $\hat{\mathbf{H}}^{\text{LS}}$ 。

除了 LS 算法之外, MATLAB 的 5G Toolbox (工具箱) 中提供了一种实用的信道估计方法 (practical estimator)。该算法是在 LS 算法的基础上改进, 对信道冲击响应进行去噪操作, 有效减少了 LS 算法中噪声的影响。

由于信道响应矩阵包含复数, 因此在接收端引入由复数卷积神经网络组成的生成器。在接收端, 给定发射器和接收器的导频信号 $\mathbf{x}_p$ 、 $\mathbf{y}_p$, 可以使用式 (2) 推导出导频位置的信道矩阵 $\hat{\mathbf{H}}_p^{\text{LS}}$, 再利用插值算法得到 $\hat{\mathbf{H}}^{\text{LS}}$, 最后将 $\hat{\mathbf{H}}^{\text{LS}}$ 输入生成器中, 用于估计信道频率响应矩阵 $\hat{\mathbf{H}}$ 。为了提高估计的准确性, 估计的信道矩阵 $\hat{\mathbf{H}}$ 应尽可能接近

真实信道矩阵, 以减少两者之间的均方差。因此信道估计问题可以表述为以下优化问题:

$$\begin{aligned} \hat{\mathbf{H}} &= f(f_{\text{inp}}(\Theta; \mathbf{h}_p^{\text{LS}}); \Theta_R) \\ \arg \min &\|\mathbf{H} - \hat{\mathbf{H}}\|_2^2 \end{aligned} \quad (3)$$

其中, $f(\cdot)$ 表示生成器, Θ_R 为生成器中所有参数的集合, $\hat{\mathbf{H}}$ 为生成器生成的信道矩阵。

3 基于复数卷积 GAN 的信道估计方法

本文所提出的 GAN 信道估计框架如图 2 所示。在接收端的一个时隙数据中, 接收的导频数据为 $\mathbf{y}_p$, 发射的导频数据为 $\mathbf{x}_p$, 首先通过 LS 算法得到导频位置的信道矩阵 $\hat{\mathbf{h}}_p^{\text{LS}}$, 然后利用插值算法映射到整个信道矩阵, 获得均方差较高的估计矩阵 $\hat{\mathbf{H}}^{\text{LS}}$ 。接下来, 将均方差较高的 $\hat{\mathbf{H}}^{\text{LS}}$ 通过 CV-GAN, 以获得低均方差的信道矩阵 $\hat{\mathbf{H}}$, 此信道矩阵尽可能地拟合实际的信道矩阵, 使二者间的均方差尽可能低。




图2 GAN信道估计框架

在 GAN 中, 分别有两个复数卷积神经网络组成生成器和判别器。生成器学习从高均方差的信道矩阵 $\hat{\mathbf{H}}^{\text{LS}}$ 到实际信道矩阵 $\mathbf{H}$ 的映射关系, 并生成低均方差的信道矩阵 $\hat{\mathbf{H}}$ 。判别器可以将给定的输入识别为真实标签 “1” (即输入为真实信道矩阵 $\mathbf{H}$) 或者假标签 “0” (即输入为生成器生成的矩阵 $\hat{\mathbf{H}}$)。当生成器完成训练后, 即可使用生成器通过输入 $\hat{\mathbf{H}}^{\text{LS}}$ 来生成估计的信道矩阵 $\hat{\mathbf{H}}$ 。

3.1 复数卷积神经网络

复数卷积神经网络采用复数参数和变量来提



取和分类复数输入数据的特征，网络的主要结构包括输入层、一定数量的隐藏层和输出层。层与层之间全连接，层内无连接，复数卷积神经网络的输入数据为复数，网络权值和偏置初始化为复数形式。在前向传播的过程中，分别对输入和权值加权求和的实部和虚部进行非线性激励。因此，每一层神经元的输出也是复数，网络的训练过程采用复数域的梯度下降算法。考虑一个SISO通信系统，接收端和发送端之间的信道矩阵为复数矩阵，因此可以采用复数卷积提取信道矩阵中的特征。

根据复数的原理，把复数看作二维实数对，记作 $z=A+ib$ 。卷积操作的实质是特征矩阵和权重矩阵的积和累加，记复数权重为 $W=A+iB$ ，复数特征值为 $h=x+iy$ ，使用权重 W 对 h 进行卷积操作可以表示为：

$$W*h=(A*x-B*y)+i(B*x+A*y) \quad (4)$$

其中， A 和 B 表示权重的实部和虚部； x 和 y 表示特征值 h 的实部和虚部。

使用矩阵符号表示复数卷积过程如下：

$$\begin{bmatrix} \Re(W*h) \\ \Im(W*h) \end{bmatrix} = \begin{bmatrix} A & -B \\ B & A \end{bmatrix} * \begin{bmatrix} x \\ y \end{bmatrix} \quad (5)$$

复数卷积操作如图3所示，复数卷积需要完成4次实数卷积操作，然后通过式(4)将这些卷积操作的结果合并成一个新的复数矩阵。

与卷积类似，激活函数也需要进行复数运算，文献[20]提出了modReLU，其定义如下：

$$\text{modReLU}(z) = \text{ReLU}(|z|+b)e^{i\theta_z} = \begin{cases} (|z|+b)\frac{z}{|z|}, & |z|+b \geq 0 \\ 0, & \text{其他} \end{cases} \quad (6)$$

其中， $z \in \mathbb{C}$ ，ReLU表示非线性激活函数， θ_z 为 z 的相位， $b \in \mathbb{R}$ 是一个可变参数。modReLU激活函数先将复数的幅值通过ReLU，然后乘以原始相位角的复数指数，如果 $|z|$ 小于阈值 b ，则




图3 复数卷积操作

modReLU函数范围0，否则返回 $(|z|+b)\frac{z}{|z|}$ 。

除了modReLU激活函数，文献[21]提出CReLU方法，分别在神经元的实部和虚部中使用ReLU函数，其定义如下：

$$\text{CReLU}(z) = \text{ReLU}(\Re(z)) + i\text{ReLU}(\Im(z)) \quad (7)$$

其中， $\Re(z)$ 、 $\Im(z)$ 分别为复数的实部和虚部，ReLU和iReLU分别应用于神经元的实部和虚部。CReLU激活函数能够使网络提取复数输入数据的相位和幅值等信息，以此来提高网络的性能。

3.2 CV-GAN的目标函数

CV-GAN的目的是使生成器生成最接近真实信道矩阵的估计矩阵来欺骗判别器，同时，判别器要学会不容易被生成器生成的估计矩阵欺骗。因此，两个网络相互对抗以获得最佳的网络性能，为了达到这个目的，CV-GAN的损失表示为：

$$\mathcal{L}_{\text{GAN}}(G_\phi, D_\theta, \hat{H}^{\text{LS}}, \mathbf{H}) = E[\log D_\theta(\mathbf{H})] + E[\log(1 - D_\theta(G_\phi(\hat{H}^{\text{LS}})))] \quad (8)$$

其中， G_ϕ 表示生成器用来生成估计的信道矩阵

$\hat{H}$, D_θ 表示判别器用来区分生成的 $\hat{H}$ 和真实信道 H (即输入的是真标签“1”还是假标签“0”)。如式 (8) 所示, 在训练 CV-GAN 时, 首先固定生成器的参数专门训练判别器; 当训练完判别器后, 固定判别器的参数训练生成器, 即先从判别器 D 的角度最大化 $\mathcal{L}_{\text{GAN}}$, 再从生成器 G 的角度最小化 $\mathcal{L}_{\text{GAN}}$ 。

$$\min_{\varphi} \max_{\theta} \mathcal{L}_{\text{GAN}}(G_{\varphi}, D_{\theta}, \hat{H}^{\text{LS}}, H) \quad (9)$$

为了减小生成器生成的信道矩阵与真实矩阵之间的均方差, 引入了如式 (10) 所示的 $\mathcal{L}_2$ 损失。

$$\mathcal{L}_2 = E[\|H - G_{\varphi}(\hat{H}^{\text{LS}})\|^2] \quad (10)$$

将两个损失函数合并, 所提出的 CV-GAN 最终的目标函数为:

$$\min_{\varphi} \max_{\theta} \mathcal{L}_{\text{GAN}}(G_{\varphi}, D_{\theta}, \hat{H}^{\text{LS}}, H) + \mathcal{L}_2 \quad (11)$$

3.3 网络结构

CV-GAN 模型如图 4 所示, 其中生成器主要由 n 层卷积层和 n 层反卷积层组成, 在 n 层反卷积层之后添加一层卷积层, 用以进一步提取矩阵特征。判别器由 4 层卷积层组成。CV-GAN 参数见表 2, 生成器前 n 层主要由复数卷积组成, 每一层的卷积核大小为 3×3 , 卷积核通道数为 $d \times 2^{n-1}$ 。每一层的结构一致, 由复数卷积、批量归一化和 CReLU 激活函数组成。在卷积层之后为 4 层的复数反卷积,

用来重新调整卷积之后的数据, 使其恢复成原来矩阵的尺寸, 每一层的反卷积核大小为 3×3 , 反卷积核通道数为 $d \times 2^{n-m}$ 。反卷积层的各层结构一致, 由复数反卷积、复数批量归一化和 CReLU 激活函数组成。为了进一步提炼数据的特征, 在复数反卷积层之后还有一个卷积核大小为 3×3 、卷积核个数为 1 的复数卷积层, 由于信道相应矩阵数据既有正数也有负数, 因此最后一层使用 LeakyReLU 激活函数。为了避免多个非线性操作导致的梯度消失问题, 在生成器的最后引入残差链接, 将模型的输入直接传递到生成器的最后一层。

判别器是一个简单的复数卷积神经网络, 判别器的作用是从输入映射到单个标量输出, 表示输入数据是真还是假。判别器的前 4 层为复数卷积层, 每一层的卷积核大小为 3×3 , 卷积核个数分别为 64、128、256、1, 复数卷积层的前 3 层还包含复数批量归一化和 CReLU, 第 4 层为一个卷积层和 LeakyReLU 激活函数。完成 4 层的卷积操作之后, 需要把特征矩阵映射到单个标量输出, 因此在判别器的最后, 加入展开层、全连接层和 Sigmoid 激活函数, 最后输出真或假的概率。

3.4 网络训练

在完成网络搭建以及生成数据集之后, CV-GAN 进行离线训练, 完整的训练过程如算法 1 所示。在每一轮网络训练中, 首先训练判别器, 对




图4 CV-GAN模型



表 2 CV-GAN 参数

卷积层	卷积核大小	卷积核通道数
生成器		
复数卷积层 1	$3 \times 3 \times 1$	$d \times 1$
复数卷积层 2	$3 \times 3 \times d$	$d \times 2$
...	...	...
复数卷积层 n	$3 \times 3 \times d \times 2^{n-2}$	$d \times 2^{n-1}$
复数反卷积层 1	$3 \times 3 \times d \times 2^{n-1}$	$d \times 2^{n-2}$
复数反卷积层 2	$3 \times 3 \times d \times 2^{n-2}$	$d \times 2^{n-3}$
...	...	...
复数反卷积层 m	$3 \times 3 \times d$	1
结尾层	$3 \times 3 \times 1$	1
判别器		
复数卷积层 1	$3 \times 3 \times 1$	$d \times 1$
复数卷积层 2	$3 \times 3 \times d$	$d \times 2$
复数卷积层 3	$3 \times 3 \times d \times 2$	$d \times 4$
复数卷积层 4	$3 \times 3 \times 4$	1

应算法 1 的第 (5) ~ (10) 步。然后训练生成器，对应算法 1 的第 (11) ~ (15) 步，在生成器的损失函数中，加上了虚假矩阵和真实矩阵之间的均方差。完成网络训练，即可返回训练后的生成器参数 φ ，用以在线估计信道矩阵。

算法 1 CV-GAN 训练

(1) **输入：**真实信道矩阵 $\mathbf{H}$ ，接收端 LS 估计矩阵 $\hat{\mathbf{H}}^{\text{LS}}$ ，生成器参数 φ ，判别器参数 θ ，训练的轮数 max epoch

(2) **输出：**训练后的生成器参数 φ

(3) **初始化参数：**生成器参数 φ ，判别器参数 θ ，epoch=0

(4) While epoch < max epoch do

更新判别器：

(5) 随机抽取一个批次真实样本 $h_{i=1}^{(i)}$ ，其中 m 为批次大小

(6) 从 $\hat{\mathbf{H}}^{\text{LS}}$ 中抽取训练样本 $\hat{h}_{i=1}^{\text{LS}(i)}$ ，作为生成器的输入

(7) 通过生成器网络生成一批虚假的样本 $\hat{h}_{\text{fake}}^{(i)}$

(8) 计算判别器对真实样本和虚假样本的预测概率

(9) 计算判别器的损失函数：

(10) 更新判别器参数：

$$\theta \leftarrow \theta - \alpha \cdot \nabla \theta \cdots_D$$

更新生成器：

(11) 从 $\hat{\mathbf{H}}^{\text{LS}}$ 中重新抽取训练样本 $\hat{h}_{i=1}^{\text{LS}(i)}$

(12) 通过生成器网络生成一批次的虚假

样本 $\hat{h}_{\text{fake}}^{(i)}$

(13) 计算判别器对虚假样本的预测概率

(14) 计算损失函数：

$$\mathcal{L}_G = \mathbb{E}[\log D_\theta(\hat{h}_{\text{fake}}^{(i)})] + \mathbb{E}[|\hat{h}^{(i)} - \hat{h}_{\text{fake}}^{(i)}|^2]$$

(15) 更新生成器参数：

$$\varphi \leftarrow \varphi - \alpha \cdot \nabla \varphi \cdots_G$$

(16) epoch $\leftarrow$ epoch + 1

(17) **输出结果：**返回训练后的生成器参数 φ

4 仿真实验与结果分析

4.1 仿真配置

针对 OFDM 通信系统下的信道估计，本节对提出的基于深度学习的信道估计方案进行了仿真和性能对比，基于 3GPP 5G NR 标准生成波形和信道，仿真系统参数配置见表 3。

表 3 仿真系统参数配置

参数	值
调制方式	QPSK、16QAM、64QAM、256QAM
N_{SC}	12
N_{sym}	14
N_{RB}	6
信道模型	抽头延迟线信道
噪声类型	AGWN
学习率	动态调整
优化器	Adam
迭代次数	200

发送端和接收端的天线数目都为 1，利用 MATLAB 2021a 搭建基于 5G NR 标准的下行链路

的仿真模型产生训练数据和测试数据, 仿真信道为抽头延迟线 (tapped delay line, TDL), 载波为 3 GHz, 子载波间隔为 30 kHz, RB 带宽为 360 kHz。子载波数量为 12, OFDM 符号数为 14, 资源块 (RB) 数量为 6。网络训练次数为 200 次, 学习率使用指数下降法动态调整, 优化器使用自适应矩估计 (adaptive moment estimation, Adam), 批次大小为 128。训练集大小为 10 000, 测试集和验证集大小均为 3 000。

所有仿真在配置 AMD 7950X CPU 和 RTX4090 GPU 的计算机上进行, 内存大小为 32 GB, 采用 Python 3.8 及深度学习框架 Pytorch 按照参数的配置进行训练及测试。

4.2 评估指标

本文使用均方误差 (MSE) 来计算估计的信道矩阵 $\hat{\mathbf{H}}$ 和真实信道矩阵 $\mathbf{H}$ 之间的差异, 表示为:

$$\text{MSE} = \frac{1}{N} \sum_n \left\| \mathbf{H}^n - \hat{\mathbf{H}}^n \right\|_F^2 \quad (12)$$

其中, N 为每次估计的样本数量, $\mathbf{H}^n$ 为第 n 个真实信道矩阵, $\hat{\mathbf{H}}^n$ 为第 n 个估计的信道矩阵。

除了 MSE 作为评估指标, 本文还使用克拉美-罗下界 (Cramer-Rao lower bound, CRLB) 衡量估计结果的无偏性。根据式 (1), 对于估计矩阵 $\mathbf{H}$, 它的 CRLB 可以作为 Fisher 信息逆矩阵, 由此可得出:

$$\text{var}(\mathbf{H}) \leq \text{CRLB}(\mathbf{H}) = \mathbf{I}^{-1}(\mathbf{H}) \quad (13)$$

其中, $\text{var}(\mathbf{H})$ 表示 $\mathbf{H}$ 与估计量 $\hat{\mathbf{H}}$ 的方差; $\mathbf{I}(\mathbf{H})$ 表示 Fisher 信息矩阵, 可定义为:

$$\mathbf{I}(\mathbf{H}) = -E \left[\frac{\partial^2 \ln(p(\mathbf{Y}; \mathbf{H}))}{\partial^2 \mathbf{H}} \right] \quad (14)$$

其中, $\mathbf{Y}$ 表示接收到的信号, $p(\mathbf{Y}; \mathbf{H})$ 表示给定 $\mathbf{H}$ 时 $\mathbf{Y}$ 的条件概率密度。

已知高斯白噪声 Z 满足 $Z \sim N(0, \sigma^2)$, 因此 $p(\mathbf{Y}; \mathbf{H})$ 可以表示为:

$$p(\mathbf{Y}; \mathbf{H}) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum (\mathbf{Y} - \mathbf{X}\mathbf{H})^2 \right\} \quad (15)$$

对 $\mathbf{H}$ 求偏导数得:

$$\frac{\partial^2 \ln(p(\mathbf{Y}; \mathbf{H}))}{\partial^2 \mathbf{H}} = -\frac{1}{\sigma^2} \sum \mathbf{X}^2 \quad (16)$$

可以得到 Fisher 信息矩阵:

$$\mathbf{I}(\mathbf{H}) = \frac{1}{\sigma^2} \sum \mathbf{X}^2 \quad (17)$$

信道估计的 CRLB 可以表示为:

$$\text{CRLB}(\mathbf{H}) = \mathbf{I}^{-1}(\mathbf{H}) = \sigma^2 (\sum \mathbf{X}^2)^{-1} \quad (18)$$

4.3 可变参数对网络的影响

为了了解网络的性能, 本文仿真生成了不同噪声、不同 DMRS 个数和不同的调制方式 3 种数据集, 将 3 种不同类型的数据输入神经网络训练, 分析不同参数下网络模型的均方差。

不同噪声数据集的均方差结果如图 5 所示, 分别取信噪比为 6 dB、12 dB、18 dB、25 dB 以及 0~25 dB 每 1 dB 各 400 个数据作为对比。由图 5 可知, 随着测试数据信噪比的增加, 采用不同训练数据得到的各条曲线的 MSE 都呈现下降的趋势, 这是因为随着信噪比变大, 测试数据噪声变低, 数据更容易估计。其次, 仅采用高信噪比 (>12 dB) 进行模型训练时, 训练得到的模型在信噪比较低场景下表现不佳, 这是因为高信噪比的训练数据不能适应低信噪比的环境。第三, 采用多种信噪比数据进行模型训练时 (对应图 5 中的点为五边形的曲线), 模型综合表现最好, 尤其是当信噪比较低时。

不同曲线存在多个交叉点。比如, 训练数据的信噪比为 25 dB 的 MSE 曲线贯穿了其余 4 条曲线, 分别在约 17 dB、20 dB、21 dB 和 23 dB 的位置产生了交叉。分析来看, 这是因为训练数据的信噪比为 25 dB 的 MSE 曲线在低信噪比的测试数据中表现最差, 而在高信噪比的测试数据中表现较好, 因此其 MSE 曲线斜率最大, 而其他 4 条曲线的 MSE 跨度较小, 因此会造成 25 dB 的 MSE 曲



线贯穿其余4条MSE曲线。训练数据的信噪比为6 dB的模型在低信噪比下性能较好,但在高信噪比的测试数据中均方差最高,低信噪比和高信噪比的MSE相差不大,因此均方差曲线的斜率比较平稳。由于训练数据为12 dB和18 dB的模型的信噪比接近,估计性能接近,两条MSE曲线在15 dB时交叉。训练数据为0~25 dB时,无论是在低信噪比还是高信噪比情况下,采用不同信噪比数据进行混合训练时,得到模型的信道估计均方差比较低,MSE曲线的斜率波动并不大。综上所述,5条均方差曲线由于斜率、最大值和最小值不一致,会出现几个交叉点,训练数据为25 dB的模型斜率最大,会贯穿其他4条曲线。训练数据为全覆盖信噪比时, CV-GAN对于信道矩阵的特征提取的能力最好。基于此,本文所使用的训练数据集为0~25 dB每1 dB产生400个数据。




图5 不同噪声数据集的均方差结果

导频对信道估计至关重要,一般来说,加入的导频数量越多,信道估计的性能就会越好,但导频的加入会占用频谱资源,造成频谱资源的浪费。不同DMRS的均方差结果如图6所示,DMRS的类型保持一致,改变DMRS的大小和数量。图6中Len1Add1表示一个DMRS大小为1个OFDM符号,额外添加1个DMRS,即每个时隙总共有3个DMRS,其他曲线以此类推。由图6

可知,随着DMRS数量增大, CV-GAN估计的性能有所提升,导频数量为Len1Add3时, CV-GAN的表现最好。为了使估计的精度最大化,训练数据采用Len1Add3的DMRS数量。




图6 不同DMRS的均方差结果

5G NR标准下的OFDM系统的调制方式可选,本文选取了16QAM、64QAM、256QAM和QPSK共4种调制方式,分析不同调制方式对网络模型的影响。不同调制方式的均方差结果如图7所示,分别展示了CV-GAN、LS、实用信道估计算法和超分辨率神经网络(super-resolution convolution neural network, SRCNN)的均方差曲线,分析图7可知,不同调制方式的均方差基本一致,因此可选任意调制方式,本文选取16QAM作为OFDM的调制方式。

4.4 不同网络深度下的性能对比

为了获取输入和标签之间隐含的复杂映射关系,神经网络往往需要堆叠大量的卷积层,过多或者过少的卷积层设置都可能影响最终的性能。为了探究网络深度对信道估计性能的影响,保持生成器神经网络的总体结构布局不变,分别改变卷积层和反卷积层的数量进行信道估计的仿真测试。

不同层数下的MSE性能如图8所示,给出了生成器中不同数量的卷积层和反卷积层对信道估计MSE性能的影响。由图8可知,层数由3递增




图7 不同调制方式的均方差结果

到6, 其MSE有所下降, 但随着卷积层数的增多, MSE并不是随着信噪比的增大而减少, 而是有所波动。

为4时, MSE均值最小; 层数为3时, MSE均值最大。随着层数的增加, 推理时间由0.919 7 s增大到0.932 5 s。




图8 不同层数下的MSE性能

不同层数的测试数据见表4, 给出了生成器中不同数量的卷积层和反卷积层对信道估计MSE均值和推理速度的测试数据。由表4可知, 层数

表4 不同层数的测试数据

生成器层数	MSE 均值	推理时间/s
3	0.04	0.919 7
4	0.028 1	0.929 4
5	0.034 5	0.931 6
6	0.03	0.932 5

通过仿真可知, 通过适当增加网络层数, 引入更多的非线性映射, 可以一定程度地提高神经网络的拟合能力, 但与此同时也会带来计算量的增加以及内存空间占用的增加, 同时有可能会产生网络退化与过拟合问题。

4.5 算法性能对比

根据第4.4节的对比结果, 本文可变参数的



设置见表5。在相同的训练条件下，随机采集不同信噪比的信道频率响应矩阵作为测试数据，利用不同的信道方法估计。

表5 可变参数的设置

参数	值
调制方式	16QAM
DMRS	Len1Add3
SNR	0~25 dB
信道模型	抽头时延线信道
噪声类型	AGWN
学习率	动态调整
优化器	Adam
迭代次数	200

不同信道估计方法的均方差如图9所示，展示了本文提出的CV-GAN的性能，将其与LS算法、超分辨率神经网络（super-resolution convolution neural network, SRCNN）、残差神经网络^[7]（convolution neural network with residual connection, ReCNet）和实用信道估计算法进行对比。从图9可知，LS算法的性能最差，本文所提出的CV-GAN算法性能最好。LS算法由于其本身没有考虑信道中噪声的影响，只是进行线性插值，故性能最差。CV-GAN、ReCNet、实用信道估计算法在低信噪比（0~6 dB）中均方差基本一致。当信噪比高于5 dB时，本文所提出的CV-GAN均比其他算法性能好。在信噪比高于6 dB时，CV-GAN的性能较ReCNet算法提高了约6 dB，在低于6 dB时，两者性能接近。

未使用复数神经网络对比及CRLB如图10所示，显示了CV-GAN与未使用复数神经网络的实数生成对抗网络（realGAN）的性能对比，并根据式（18）获得相应的CRLB。由图10可知，CV-GAN的MSE显著低于未采用复制神经网络的GAN模型，在低信噪比条件下，二者间的MSE差距更加明显。这是由于未使用复数神经网络，realGAN少了复数运算的步骤，没有充

分提取复数特征，因此会造成MSE较高，但是realGAN能够因此而缩短训练时间。图10中CV-GAN和realGAN的MSE曲线均在CRLB曲线之上，满足了式（13），估计得出的信道矩阵是有效的。




图9 不同信道估计方法的均方差




图10 未使用复数神经网络对比及CRLB

为了更直观地体现信道估计算法的性能，利用上述算法分别估计信噪比为16 dB的一个测试数据，并将结果可视化。不同算法信道估计结果可视化如图11所示，依次为实际的信道信息图像、LS算法、实用信道估计算法、CV-GAN、SRCNN和ReCNet的估计结果。其中，线性插值估计的信道矩阵失真严重，性能最差。PCE算法较线性插值有明显提升，但其均方差比深度神经网络方法高。ReCNet和SRCNN结果接近，但与实际信道信息图像比较有较大的失真。CV-GAN




图 11 不同算法信道估计结果可视化

算法估计的信道矩阵均方差最低, 也最接近实际信道信息图像。

5 结束语

为提升 5G NR 标准下的 OFDM 系统信道估计准确性, 本文提出了一种基于复数神经网络的生成对抗网络 (CV-GAN) 信道估计算法。CV-GAN 的输入为包含信道状态信息的完整复数矩阵, 通过不断优化生成器, 使其生成的信道响应矩阵与真实信道矩阵之间的均方差最小化。此外, CV-GAN 充分利用复数的相位、幅值等参数, 使生成器能够学习信道中的复数特征, 从而提高信道估计的准确性。仿真测试表明, 相对于其他 4 种信道估计算法, CV-GAN 的信道估计算法在提高精度方面表现出色。通过可视化结果的直观观察, CV-GAN 生成的信道响应矩阵更接近实际信道信息图像。

本文的实验基于仿真实现, 在应用于实际工

程可能会面临以下挑战。

(1) 数据需求: CV-GAN 的性能很大程度上依赖大量高质量的训练数据。在实际工程应用中, 获取足够丰富和有代表性的信道数据充满挑战。

(2) 实时性要求: 如果应用于实时通信系统, CV-GAN 需要在很短的时间内完成信道估计, 因此算法的实时性也是需要考虑的一个挑战。

下一步, 将针对这些实际问题开展仿真算法的工程化实现, 利用小样本学习、神经网络加速等技术, 提高算法的实际应用可行性。

参考文献:

- [1] NOH G, HUI B, KIM J, et al. DMRS design and evaluation for 3GPP 5G new radio in a high speed train scenario[C]//Proceedings of the GLOBECOM 2017-2017 IEEE Global Communications Conference. Piscataway: IEEE Press, 2017: 1-6.
- [2] 高尚蕾, 张治中, 段浴, 等. 5G 系统中基于解调参考信号的信道估计方法[J]. 电讯技术, 2021, 61(2): 191-196.



- GAO S L, ZHANG Z Z, DUAN Y, et al. A channel estimation method based on demodulation reference signal in 5G system[J]. Telecommunication Engineering, 2021, 61(2): 191-196.
- [3] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [4] LIN B, WANG X D, YUAN W H, et al. A novel OFDM autoencoder featuring CNN-based channel estimation for Internet of vessels[J]. IEEE Internet of Things Journal, 2020, 7(8): 7601-7611.
- [5] KAPULA P R, SRIDEVI P V. Channel estimation in 5G multi input multi output wireless communication using optimized deep neural framework[J]. Cluster Computing, 2022, 25(5): 3517-3530.
- [6] KALPHANA I, KESAVAMURTHY T. Convolutional neural network auto encoder channel estimation algorithm in MIMO-OFDM system[J]. Computer Systems Science and Engineering, 2022, 41(1): 171-185.
- [7] 王义元, 常俊, 卢中奎, 等. 深度学习辅助的 5G OFDM 系统的信道估计[J]. 电讯技术, 2024, 64(1): 36-42.
- WANG Y Y, CHANG J, LU Z K, et al. Channel estimation of deep learning-assisted 5G OFDM system[J]. Telecommunication Engineering, 2024, 64(1): 36-42.
- [8] YE H, LI G Y, JUANG B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. IEEE Wireless Communications Letters, 2018, 7(1): 114-117.
- [9] 卢敏, 秦泽豪, 陈志辉, 等. 基于 1D-Concatenate 的信道估计 DNN 模型优化方法[J]. 电信科学, 2023, 40(4): 72-86.
- LU M, QIN Z H, CHEN Z H, et al. 1D-Concatenate based channel estimation DNN model optimization method[J]. Telecommunications Science, 2023, 40(4): 72-86.
- [10] GE L J, GUO Y C, ZHANG Y, et al. Deep neural network based channel estimation for massive MIMO-OFDM systems with imperfect channel state information[J]. IEEE Systems Journal, 2022, 16(3): 4675-4685.
- [11] LIAO Y, HUA Y X, DAI X W, et al. ChanEstNet: a deep learning based channel estimation for high-speed scenarios[C]//Proceedings of the ICC 2019-2019 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2019: 1-6.
- [12] 华郁秀, 李荣鹏, 赵志峰, 等. 基于生成对抗网络的 MIMO 信道估计方法[J]. 电信科学, 2021, 37(6): 14-22.
- HUA Y X, LI R P, ZHAO Z F, et al. GAN-based channel estimation for massive MIMO system[J]. Telecommunications Science, 2021, 37(6): 14-22.
- [13] DONG Y, WANG H, YAO Y D. Channel estimation for one-bit multiuser massive MIMO using conditional GAN[J]. IEEE Communications Letters, 2020, 25(3): 854-858.
- [14] 张昀, 周婧, 黄经纬, 等. 基于深度学习的正交频分复用系统信道估计[J]. 通信学报, 2023, 44(12): 125-133.
- ZHANG Y, ZHOU J, HUANG J W, et al. Channel estimation for OFDM system based on deep learning[J]. Journal on Communications, 2023, 44(12): 125-133.
- [15] MELGAR A, DE LA FUENTE A, CARRO-CALVO L, et al. Deep neural network: an alternative to traditional channel estimators in massive MIMO systems[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(2): 657-671.
- [16] JIANG P W, WEN C K, JIN S, et al. Dual CNN-based channel estimation for MIMO-OFDM systems[J]. IEEE Transactions on Communications, 2021, 69(9): 5859-5872.
- [17] LIU C, LIU X, 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, 2021, 21(2): 898-912.
- [18] GUO J, WANG L, LI F, et al. CSI feedback with model-driven deep learning of massive MIMO systems[J]. IEEE Communications Letters, 2021, 26(3): 547-551.
- [19] LIU Q, ZHANG Z, YANG G, et al. CSI feedback based on complex neural network for massive MIMO systems[J]. IEEE Access, 2022(10): 78414-78422.
- [20] ARJOVSKY M, SHAH A, BENGIO Y. Unitary evolution recurrent neural networks[J]. JMLR. org, 2015. doi: 10.48550/arXiv.1511.06464.
- [21] TRABELSI C, BILANIUK O, ZHANG Y, et al. Deep complex networks[J]. arXiv preprint, 2017, arXiv: 1705.09792.

[作者简介]



陆元智 (1997-), 男, 南京信息工程大学硕士生, 主要研究方向为深度学习、信道估计。

魏祥麟 (1985-), 男, 博士, 国防科技大学第六十三研究所副研究员, 主要研究方向为频谱智能计算。

于龙 (1981-), 男, 博士, 国防科技大学第六十三研究所高级工程师, 主要研究方向为通信抗干扰、智能通信博弈。

姚昌华 (1982-), 男, 博士, 南京信息工程大学教授, 主要研究方向为智能无人集群、智能无线通信。