http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2020.0591

基于调制卷积神经网络的空地数据链信道估计

刘春辉[1,*], 王美琳[2], 董赞亮[2], 王沛[2]
(1. 北京航空航天大学 无人系统研究院, 北京 100083; 2. 北京航空航天大学 电子信息工程学院, 北京 100083)

摘 要: 针对复杂环境下空地数据链正交频分复用(OFDM)系统信道估计精度不足的问题,提出了一种基于调制卷积神经网络(MCNN)和双向长短时记忆网络(BiLSTM)结合的信道估计算法。利用最小二乘算法(LS)提取初始信道状态信息(CSI);利用 MCNN 网络提取初始 CSI 的深度特征,并对网络模型进行压缩;利用 BiLSTM 网络对最终 CSI 进行预测,实现信道估计。利用构建的空地信道模型生成信道系数数据集,实现神经网络模型的训练与测试。仿真结果表明:与传统算法和现有深度学习方法相比,所提出的信道估计算法具有更小的估计误差,高信噪比条件下的系统误码率(BER)性能提升接近一个数量级;由于引入了调制滤波器技术,随着神经网络层数增加,网络模型参数量大幅减少。

关 键 词: 正交频分复用(OFDM); 深度学习; 信道估计; 空地信道模型; 多径效应
中图分类号: V243.5; TN911.72
文献标志码: A **文章编号**: 1001-5965(2022)03-0533-11

空地数据链(air-ground data link)系统是无人机、无人飞艇等无人空中系统的重要组成部分,实现无人空中平台的指挥控制和信息传输功能。当无人空中平台在复杂地理环境中执行任务时,数据链系统常受到“多径效应”的影响。为克服多径效应,正交频分复用(orthogonal frequency division multiplexing, OFDM)技术被广泛应用于空地数据链系统设计[1],OFDM 系统通过在符号之间插入大于无线信道最大多径时延扩展的循环前缀(cyclic prefix, CP),最大限度消除由多径效应产生的符号间干扰[2](inter symbol interference, ISI)。然而,对于一些高度散射信道,较大的多径时延要求 CP 必须很长,但过长的 CP 会导致信息传输速率降低。针对这一问题,通常增加信道估计和信道均衡等模块来减小 CP 的长度,即通过增加系统复杂性换取系统频带利用率的提高。信道估计用于实现无线信道参数的有效估计,包括信道阶数、多普勒频移和多径时延等参数,这些参数均反映在信道冲激响应矩阵中,因此信道估计性能直接影响着空地 OFDM 数据链的整体接收性能。

传统的信道估计算法可分为基于导频的信道估计算法、盲估计和半盲估计,其中基于导频的信道估计算法最为常见。经典的基于导频的信道估计算法有最小二乘算法(least square, LS)[3]、最小均方误差算法(minimum mean-square error, MMSE)[4]和线性最小均方误差算法(linear minimum mean-square error, LMMSE)[5]等。LS 算法计算简单、复杂度低、不需要信道的任何先验信息,因此在实际中被广泛使用;MMSE 算法需要信道的统计信息同时利用信道的相关性抑制噪声,具有较好的信道估计性能,但计算复杂度较高;LMMSE 算法对 MMSE 算法进行了改进,简化了 MMSE 算法的计算,因此在实际应用中常用

收稿日期: 2020-10-19; **录用日期**: 2021-01-17; **网络出版时间**: 2021-02-04 15:55
网络出版地址: kns.cnki.net/kcms/detail/11.2625.V.20210204.1443.003.html
基金项目: 科技创新 2030-“新一代人工智能”重大项目(2020AAA0108200); 北京市自然科学基金(4204102)
* **通信作者**. E-mail: liuchunhui2134@buaa.edu.cn

引用格式: *刘春辉, 王美琳, 董赞亮, 等. 基于调制卷积神经网络的空地数据链信道估计[J]. 北京航空航天大学学报, 2022, 48(3): 533-543. LIU C H, WANG M L, DONG Z L, et al. Channel estimation of air-ground data link based on modulated convolutional neural network [J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48(3): 533-543 (in Chinese).*

LMMSE 算法代替 MMSE 算法。

近年来,深度学习开始应用于 OFDM 信道估计与信号检测领域,颠覆了传统信道估计算法需要在线训练的要求。文献[6]采用大数据训练的方式将 OFDM 接收机视为一个“黑箱子”,利用标准的全连接神经网络实现信道估计与信号检测;文献[7]设计了一种基于模型驱动的深度学习方法用于信号检测;文献[8]利用传统通信理论分别设计了信道估计和信号检测 2 个子网络,不仅使每个子网络都具有清晰的物理意义,还使子网络不依赖于大量的样本数,加快了训练速度;文献[9]提出了利用深度神经网络(deep neural network, DNN)估计信道响应与信道的频域相关系数,实时追踪信道的频域变化;文献[10]基于卷积-长短时记忆-全连接深度神经网络(convolutional, long short-term memory, fully connected deep neural networks, CLDNN)网络结构[11]提出了在高速移动环境下的信道估计算法,采用一维卷积神经网络(convolutional neural network, CNN)与双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)结合的网络结构进行信道估计,克服了多径效应和多普勒效应的影响;文献[12]提出了基于二维 CNN 与 BiLSTM 结合的用于多输入多输出正交频分复用(multiple-input multiple-output orthogonal frequency division multiplexing, MIMO-OFDM)系统的信道估计算法,实现高速移动场景下的快速时变信道估计;文献[13]设计了基于模型驱动的全连接神经网络 OFDM 接收机,补偿了多径效应和非线性失真;文献[14]设计了利用人工智能辅助的 OFDM 接收机,应用在无 CP 的 OFDM 系统中,提升了频谱和能量利用率。

从当前研究现状来看,深度学习方法在空地数据链信道估计领域尚未开展深入研究,这是由于复杂环境下空地信道的多径效应产生机理比一般场景更复杂,信道样本数据的多样性要求更高,造成信道估计难度加大。与蜂窝移动通信或卫星通信系统相比,空地通信系统有其独特的信道特性,因此对空地信道进行准确地建模对提升信道估计算法的估计精度至关重要。

在空地信道建模研究方面,文献[15-17]综合分析了空地信道特点,对不同地表环境下的空地信道进行建模,提出了在经典二径空地信道模型[15]的基础上加入间歇多径分量(multipath component, MPC)形成抽头延时线(tapped delay line, TDL)模型,实现对复杂环境多径空地信道的建模。其中,文献[15]重点介绍水上环境(包括海水和淡水)的空地信道建模方法;文献[16]重点介绍山区环境的空地信道建模方法;文献[17]重点介绍郊区环境的空地信道建模方法。

除了空地信道样本建模困难,基于深度卷积神经网络的空地信道估计模型在机载端的部署同样存在难度。这是由于卷积网络模型大规模的网络权重对存储器带宽具有较高的要求,同时为了实现网络中最常见的点积运算需要进行大量的计算,这些都会造成过高的功率开销,为功率受限的机载应用带来较大挑战。针对机载部署问题,需要对神经网络模型进行压缩来获得轻量化的模型。CNN 模型轻量化的研究主要分为 2 个方向:一是模型结构简化,通过设计轻量级的模型减少计算量和参数量;二是模型压缩,减少现有模型的大小,使模型能够部署应用于小型设备。具体研究工作可以分为 3 类:网络剪枝[18]、模型量化[19]、低秩分解[20]。其中,模型量化基于权重共享思想使多个网络连接的权重共用同一权值。调制滤波器(modulated filter)是模型量化的代表性技术,通过生成调制卷积神经网络(modulated convolutional neural network, MCNN)对原始 CNN 网络进行模型压缩。

针对上述问题,本文提出一种基于 MCNN 和 BiLSTM 结合的 OFDM 信道估计算法,利用 TDL 模型对复杂环境多径空地信道进行建模[15-17],仿真生成具有模拟复杂空地环境多径时延扩展特征的信道样本数据,利用调制滤波器对 CNN 网络参数进行压缩,充分发挥 MCNN[21]网络对信道样本特征的提取能力和 BiLSTM 网络[22]对信道样本序列的预测能力,实现多径空地信道的准确估计。同时,本文还通过增减 MCNN 和 BiLSTM 的层数来分析网络层数对信道估计精度的影响。与传统的 LS 算法、LMMSE 算法及现有的深度学习方法 DNN 相比,本文提出的信道估计算法有效提高了不同应用环境中空地数据链的信道估计精度。

1 OFDM 通信系统

OFDM 是一种高速无线传输技术,该技术的基本原理是将高速串行数据变换成多路相对低速的并行数据,进而实现多载波调制。图 1 为 OFDM 通信系统的结构[9]。

如图 1 所示,在通信系统的发射端,发射机发射二进制信号,信号经过调制后进行串并转换将高速的串行比特流转换成 N 条并行的低速数据流,映射到 OFDM 符号的不同子载波上进行传输。

http://bhxb.buaa.edu.cn

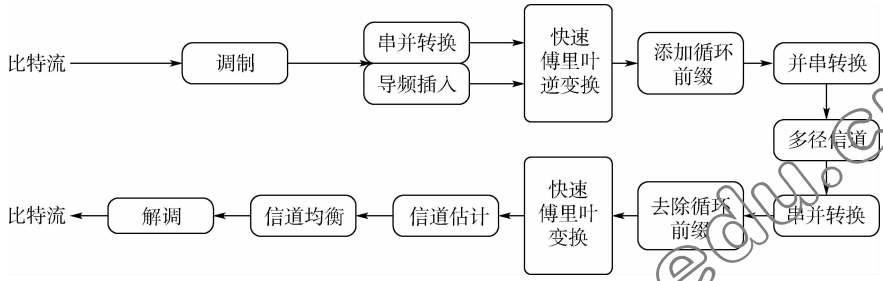

图 1　基于 OFDM 的通信系统结构

Fig. 1　Communication system structure based on OFDM

在 OFDM 系统中,各子载波之间相互正交,且每一个子载波在一个 OFDM 符号周期内都包含整数倍周期,相邻的子载波之间相差一个周期。其正交性可表示为

$$\frac{1}{T}\int_0^T \exp(\mathrm{j}\omega_i t)\exp(\mathrm{j}\omega_j t)\,\mathrm{d}t = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases} \tag{1}$$

式中:ω_i 为第 i 个子载波的角速度。

为了消除符号间干扰和防止载波间的正交性被破坏,需要在 OFDM 符号间添加 CP,CP 的长度一般要大于无线信道的最大时延扩展,这样一个符号的多径分量就不会对下一个符号造成干扰。最终将多载波调制后的并行数据转换成串行数据传输到多径信道中。发送信号第 n 个 OFDM 符号 $s_n(m)$ 为

$$s_n(m) = \frac{1}{\sqrt{K}}\sum_{k=0}^{K-1} X_{n,k}\mathrm{e}^{\mathrm{j}\varpi_k m} \tag{2}$$

式中:K 为子载波数;$X_{n,k}$ 为串并转换后的并行传输信号;ϖ_k 为第 k 个子载波的角速度。

在通信系统的接收端,将接收到的串行数据转换成并行数据后去除 CP,并通过快速傅里叶变换对 OFDM 符号实现解调。接收信号为

$$y_n(m) = \frac{1}{\sqrt{K}}\sum_{k=0}^{K-1} H_n(m,\varpi_k)\mathrm{e}^{\mathrm{j}\varpi_k m}X_{n,k} + Z_{n,k} \tag{3}$$

式中:$H_n(m,\varpi_k)$ 为多径传输信道;$Z_{n,k}$ 为加性高斯白噪声。

为了在接收端更好地恢复发射信号,需要进行信道估计,再利用信道估计结果进行信道均衡,进而实现解调,恢复发送的信号。

2　空地信道建模

本节基于经典的二径空地信道模型,利用包含直射分量、反射分量及间歇多径分量的 TDL 模型对本文需要的空地信道进行建模。

2.1　二径信道模型

2.1.1　模型参数

图 2 为简化的二径空地信道模型,二径信道模型由直射路径分量和反射路径分量组成[15]。

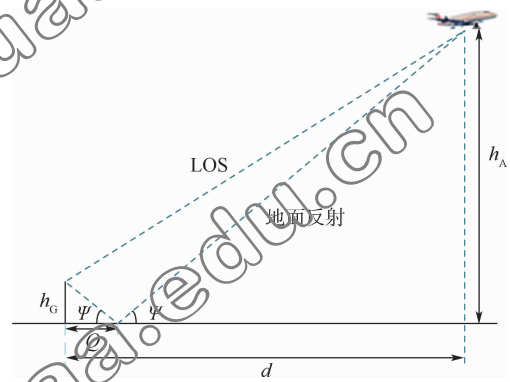

图 2　二径空地信道模型

Fig. 2　Two-ray air-ground channel model

图 2 中:h_A 和 h_G 分别为飞机和地面天线的高度;d 为两者地面距离;ψ 为地面反射分量的掠射角。

在二径信道模型中,地表反射是由地面平整度和地面站的半径 Q 范围内的植被覆盖率决定的,即地面反射点应位于地面站的半径 Q 内。通过相似三角形关系,存在如下等式:

$$Q = \frac{dh_G}{h_A + h_G} \tag{4}$$

二径信道模型相关参数计算如下:

$$\begin{cases} R_{1,p} = \sqrt{h_A^2 + d^2} \\ l_{1,p} = \sqrt{h_A^2 + (d-Q)^2} \\ l_{2,p} = \sqrt{h_G^2 + Q^2} \\ R_{2,p} = l_{1,p} + l_{2,p} \\ \Delta R_p = R_{2,p} - R_{1,p} \\ \sin\psi_p = \dfrac{h_G}{l_{2,p}} \\ \tau_{0,p} = \dfrac{R_{1,p}}{c} \\ \tau_{s,p} = \dfrac{R_{2,p}}{c} \\ \alpha_{s,n,p} = R_{1,p}\mathrm{e}^{-\frac{\mathrm{j}2\pi\Delta R_p}{\lambda}}/R_{2,p} \end{cases} \tag{5}$$

式中:$R_{1,p}$ 为直射分量路径长度;$l_{1,p}$ 为反射分量第一段路径长度;$l_{2,p}$ 为反射分量第二段路径长度;$R_{2,p}$ 为反射分量路径总长度;ΔR_p 为反射分量和直

http://bhxb.buaa.edu.cn

射分量路径差;ψ_p 为 p 时刻的掠角;$\tau_{0,p}$ 为直射分量路径时延;$\tau_{s,p}$ 为反射分量路径时延;$\alpha_{s,n,p}$ 为表面相对反射系数;c 为光速;$\lambda = c/f_c$ 为波长,f_c 为载波频率。

依据文献[15-17],p 时刻的二径空地信道的冲激响应为

$$\tilde{h}^{(e)}_{2\text{-ray},F}(\tau,p) = \alpha_{0,p}e^{-\frac{j2\pi R_{1,p}}{\lambda}}\delta(\tau-\tau_{0,p}) + \alpha_{s,p}e^{-\frac{j2\pi R_{2,p}}{\lambda}}\delta(\tau-\tau_{s,p}) \tag{6}$$

式中:自由 LOS 振幅分量 $\alpha_{0,p} = \dfrac{c}{4\pi f_c R_{1,p}}$;自由空间表面反射振幅 $\alpha_{s,p} = \dfrac{c}{4\pi f_c R_{2,p}}$。

假设 $R_{1,p}$ 为已知,此时 $\alpha_{0,p}$ 和 $\tau_{0,p}$ 也为已知。对式(6)进行归一化,使得 LOS 分量的振幅 $\alpha_0 = 1$,延时 $\tau_{0,p} = 0$,则信道冲激响应(channel impulse response,CIR)可以重新表示为

$$h_{2\text{-ray}}(n) \approx e^{-j\theta_1}\delta(n) + \alpha_{s,n,p}\Gamma_{p,F}D_p r_F e^{-j\theta_2}\delta(n-1) \tag{7}$$

式中:θ 为相位;$\Gamma_{p,F}$ 为表面反射系数;D_p 为 p 时刻的散度因子;r_F 为表面粗糙因子。

此时,决定二径空地信道 CIR 的 3 个参数为:表面粗糙因子 r_F、p 时刻的散度因子 D_p 和表面反射系数 $\Gamma_{p,F}$。

2.1.2 表面粗糙因子 r_F

理论上,如果地球表面绝对光滑,则 $r_F = 1$,但实际情况一般 $r_F > 1$。

当反射面为陆地时,表面粗糙因子 $r_F = \exp(-C_r^2/2)$,$C_r = (4\pi s_g \sin\psi_p)/\lambda$,$s_g$ 为地面高度标准差。

当反射面为海洋时,表面粗糙因子 $r_F = \exp(-C_r^2/2)I_0(-C_r^2/2)$,此时 $s_g = 0.005\,2\mu^2$,μ 为风速,m/s。

2.1.3 散度因子 D_p

p 时刻散度因子 D_p 的计算方法为

$$D_p = \left(1 + \frac{2}{k\alpha\sin\psi_p}\cdot\frac{l_{1,p}l_{2,p}}{l_{1,p}+l_{2,p}}\right)^{-\frac{1}{2}} \tag{8}$$

式中:$k = 4/3$;α 为地球赤道半径。

2.1.4 表面反射系数 $\Gamma_{p,F}$

$\Gamma_{p,F}$ 取决于频率、极化、入射角和反射表面介电常数,本节采用简化计算方法,根据文献[23],p 时刻的表面反射系数的简化计算方法为

$$\Gamma_{p,F} = \frac{\eta_1 - \eta_2}{\eta_1 + \eta_2} \tag{9}$$

式中:η_1 为介质 1 的相对介电常数;η_2 为介质 2 的相对介电常数。

2.2 带有间歇多径分量的 TDL 模型

文献[16]提出空地信道 TDL 模型中最多有 9 个抽头,因此本文采用的 TDL 模型的信道冲激响应表达式如下:

$$h_{9\text{-ray}}(n) \approx e^{-j\theta_1}\delta(n) + \alpha_{s,n,p}\Gamma_{p,F}D_p r_F e^{-j\theta_2}\delta(n-1) + \sum_{a=3}^{9}\alpha_a z_a e^{-j\theta_k}\delta(n-a) \tag{10}$$

式中:α 和 θ 分别为振幅和相位;$z \in (0,1)$ 用来描述抽头开关的概率;下标 a 为第 a 次间歇多径分量,a 为 3 ~ 9 的整数。

式(10)中的前 2 项由二径信道模型计算得到。对于式中所有的抽头,相位都是均匀随机地分布在 0 ~ 2π 之间;间歇抽头的相对功率 $10\lg(\alpha_a^2/\alpha_{\text{LOS}}^2)$ 服从高斯分布,且通常随抽头指数(较大的抽头指数意味着较大的延时)而降低[17]。

3 基于深度学习的信道估计技术

针对复杂环境下空地 OFDM 信道估计难题,本文提出的基于深度学习的信道估计神经网络框架如图 3 所示,包括输入层、隐藏层、输出层及网络训练 4 部分。

3.1 网络输入层

首先,利用第 2 节提出的 9 径 TDL 模型对空地信道进行建模,生成信道系数样本数据集。然后,对数据集进行划分,分为导频序列和数据序列,利用 LS 算法处理导频序列,估计得到导频符号处的信道状态信息(channel state information, CSI)[24]:

$$H_{\text{LS}}(q) = \frac{y_{\text{pilot}}(q)}{x_{\text{pilot}}(q)} \tag{11}$$

式中:$H_{\text{LS}}(q)$ 为 LS 算法计算得到的第 q 个子载波处的 CSI;$x_{\text{pilot}}(q)$ 为第 q 个子载波的发送导频信号;$y_{\text{pilot}}(q)$ 为第 q 个子载波的接收导频信号。

数据符号处的 CSI 初始化为 0,则网络输入数据表达形式为

$$H = [H(0),\cdots,H(n),\cdots,H(N-1)] \tag{12}$$

式中:$H(n)$ 为第 n 个 OFDM 符号处的 CSI。

最后,由于信道数据为复数信号,对网络进行输入之前需要把输入数据的实部和虚部提取出来结合成一个维度。

3.2 网络隐藏层

CNN 具备较强的局部数据特征提取能力,但其结构一般包含多个卷积层,每个卷积层中又蕴含着大量卷积核参数。为了去除 CNN 参数冗余,降低计算复杂度,本文将调制滤波器技术引入一维 CNN,建立了一种生成 CNN 的新型网络结构,即 MCNN。

http://bhxb.buaa.edu.cn

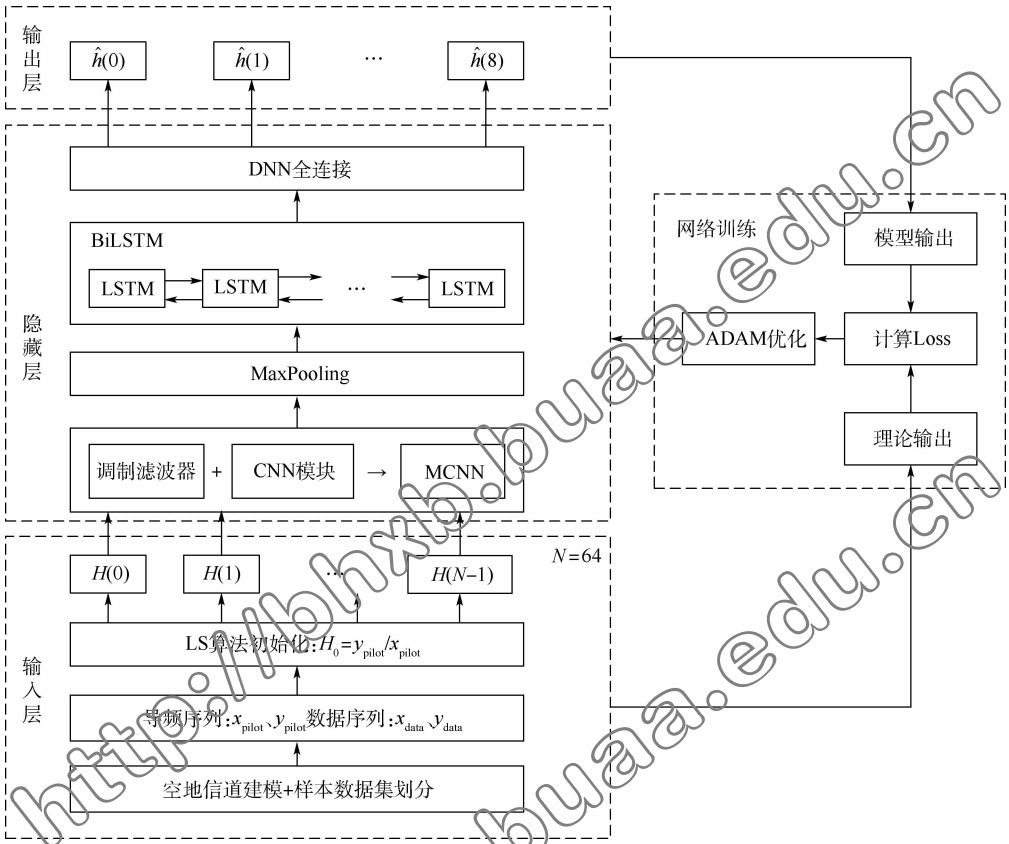

图 3　基于深度学习的信道估计框架

Fig. 3　Channel estimation framework based on deep learning

调制生成卷积核的优点在于：①调制滤波器能增强及引导随机的原始卷积核属性，使网络更高效；②通过引入卷积核调制过程，可通过共享调制滤波器的方式减少深度神经网络参数，使模型更紧致。基于 MCNN 结构，本文提出了一种基于 MCNN 与 BiLSTM 的信道估计网络（以下简称 MC-BI 网络）。

3.2.1　MCNN 网络单元结构

在利用调制方法生成卷积核方面，需要构建一个三维的调制滤波器，其维度为 $N\times 1\times M$，调制滤波器有 N 个通道，每个通道是尺寸为 $1\times M$ 的二维滤波器。其中，M 与每个原始一维卷积核包含的数据量一致。因此，假设已有 L 个随机初始化的原始卷积核，基于维度为 $N\times 1\times M$ 的调制滤波器，即可生成 $N\times L$ 个维度为 $1\times M$ 的衍生卷积核。此时，每个卷积层均共享使用同一个调制滤波器，网络参数得以大幅压缩。

MCNN 按下式计算：

$$\boldsymbol{C}=\sum_{s}^{N}\hat{\boldsymbol{C}}\circ\boldsymbol{M}_s \tag{13}$$

式中：$\boldsymbol{C}$ 为衍生核；$\hat{\boldsymbol{C}}$ 为原始卷积；$\boldsymbol{M}_s$ 为调制滤波器的第 s 个通道；“∘”为矩阵元素相乘。

基于调制滤波器的调制过程如图 4 所示。

基于 OFDM 系统的多载波调制特征，在原滤波器的正弦函数基础上，预先定义了调制滤波器[25]，同时利用多个初始相位和频率来产生调制

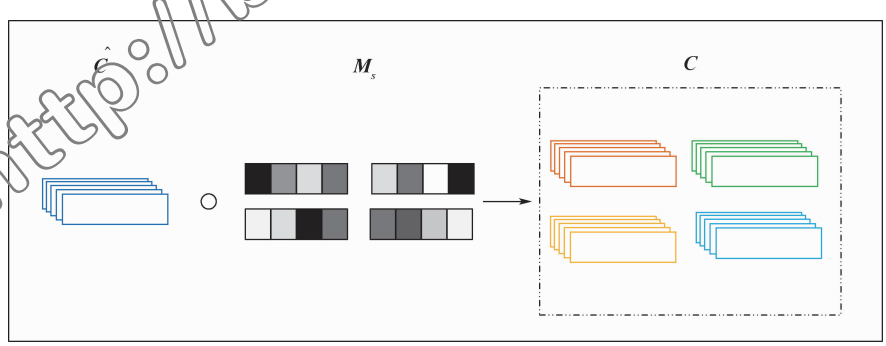

图 4　基于调制滤波器的调制过程

Fig. 4　Modulation process based on modulation filter

http://bhxb.buaa.edu.cn

滤波器,计算式如下:

$$m(t) = \sum_{t=0}^{2\pi} \sin(2\pi f t + \theta)\delta\left(t - n\frac{2\pi}{f_s}\right) \tag{14}$$

式中:f_s 为采样频率;θ 为初始相位;δ 为采样脉冲。

3.2.2 BiLSTM 网络单元结构

本文采取 BiLSTM 网络用于预测多径信道系数,其主体结构为 2 个单向 LSTM 网络。图 5 为 BiLSTM 的网络结构示意图,BiLSTM 为双向循环神经网络,其主体结构是 2 个单向循环网络。

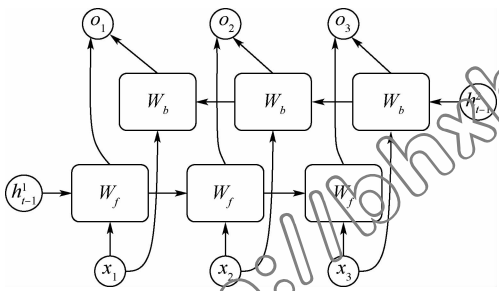

图 5 BiLSTM 网络结构

Fig. 5 BiLSTM network structure

在每个时刻 t,输入会同时提供给这 2 个方向相反的循环网络,2 个网络独立进行运算,各自产生新的状态和输出,而 BiLSTM 的最终输出就是这 2 个单向网络输出的拼接,可用下式表示:

$$\text{out}_t = \text{Concat}(o_t, o_t') \tag{15}$$

式中:o_t 为 t 时刻 BiLSTM 网络的正向输出;o_t' 为 t 时刻 BiLSTM 网络的反向输出;out_t 为 BiLSTM 在 t 时刻的输出;Concat 函数将 2 个矢量按指定维数结合起来。

3.3 网络输出层

网络输出层输出的是最终估计的信道系数的实部和虚部,网络隐藏层通过全连接神经网络将 BiLSTM 网络的输出进行维度变换,对所有输入元素进行加权和,将实部和虚部加在一起得到最终输出。由于本文采用的信道模型为 9 径 TDL 模型,则网络输出为

$$\hat{H} = [\hat{h}_0, \cdots, \hat{h}_l, \cdots, \hat{h}_8] \tag{16}$$

式中:$\hat{H}$ 为神经网络输出结果;$\hat{h}_l$ 为第 l 条路径的 CSI。

3.4 网络训练与应用

本文中的信道估计网络主要分为离线训练和在线测试 2 部分,如图 6 所示。

在离线训练阶段,利用大量空地信道系数数据对学习网络进行训练,使 MC-BI 网络能够学习到反映信道延时、衰减等相关参数的高维特征。在在线应用部分,将训练好的 MC-BI 网络应用在 OFDM 通信系统中。

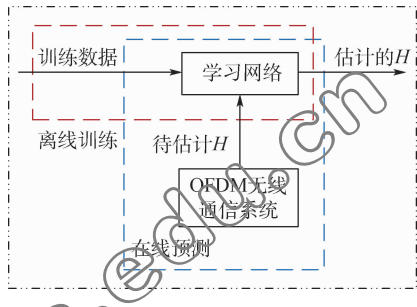

图 6 MC-BI 网络模型的训练与应用

Fig. 6 Training and application of MC-BI network model

本文利用端到端的方式训练得到信道估计网络中的所有权重和偏置,使用 ADAM 算法更新网络的参数集,通过训练网络使得 MC-BI 网络估计得到的信道估计值与信道真实值的差异最小化,因此 MC-BI 网络模型采用的损失函数为均方误差(mean squared error, MSE)函数,预测损失 Loss 为

$$\text{Loss} = \frac{1}{N}\sum_{n=1}^{N}(\text{Hest}_n - H_n)^2 \tag{17}$$

式中:Hest_n 为信道估计值;H_n 为信道真实值;N 为信道样本数。

4 实验结果

4.1 信道建模场景设置

根据文献[15-17],本文选取郊区、山区和海上 3 种典型场景,建立了准静态[26]多径空地信道模型。准静态信道是一种随时间缓慢变化的信道,即在一个 OFDM 帧内信道是不变的,不同帧之间的信道是相互独立的。3 种场景信道模型参数如表 1 所示。

利用表 1 中的场景参数,建立空地信道系数样本集,作为 MC-BI 网络的样本训练集和测试集。相关生成代码和样本数据已开源,参见 https://github.com/liuchunhui2134/AGChannelSimulation。

表 1 信道模型参数

Table 1 Channel model parameters

场景	h_A/m	h_G/m	d/km	n_1	n_2	s_g/m
郊区	1 000	20	46	15	1	0.05
山区	4 000	20	60	5	1	1 000
海上	800	20	25	81	1	0.187 2

4.2 系统参数设置

本文所提的学习网络模型,MCNN 设置为 2 层,BiLSTM 设置为 3 层。在 MCNN 网络中,调制滤波器的维度为 5×1×8,原始卷积核的数量为 8 个。对于离线训练过程,使用的训练集和测试集的样本数分别为 10 000 和 1 000,训练学习率为 0.005。OFDM 系统的主要参数设置如表 2 所示。

http://bhxb.buaa.edu.cn

表 2　OFDM 系统参数设置

Table 2　OFDM system parameter setup

参数	数值
子载波数	64
OFDM 符号数	64
CP 长度	8
导频间隔	8
调制方式	4QAM

4.3　系统接收均方误差分析

如图 7 所示，比较了 LS 算法[3]、LMMSE 算法[5]、现有的全连接 DNN 网络[9]和本文提出的 MC-BI 网络在不同信噪比（signal to noise，SNR）下 3 种典型场景时空地信道估计的归一化均方误差（normalized MSE，NMSE）性能。

从图 7 中可以看出，在 3 种典型场景下，本文提出的 MC-BI 网络的估计精度要优于其他算法，在各种信噪比条件下，比 LMMSE 算法高 2 个数量级，比 LS 算法高近 5 个数量级；相比于 MC-BI 网络，全连接 DNN 网络的估计性能次之，LMMSE 算法由于利用信道的先验统计信息使得估计精度优于 LS 算法；计算复杂度最低的 LS 算法获得的 NMSE 性能最差。

4.4　系统接收误码率分析

OFDM 系统接收端的误码率（bit error ratio，BER）性能是衡量 OFDM 空地数据链系统信道估计性能的重要指标。如图 8 所示，比较了不同信噪比下 3 种典型场景时传统 LS 算法[3]、LMMSE 算法[5]、全连接 DNN 网络[9]和本文所提的 MC-BI 信道估计算法的 BER 性能。

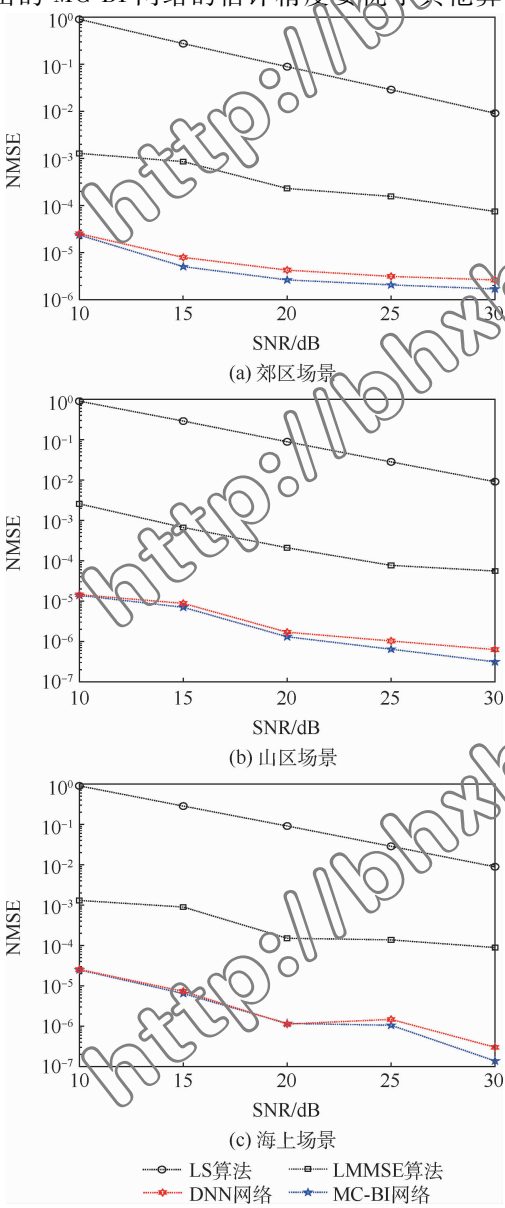

图 7　三种典型场景下不同信道估计算法的 NMSE 比较

Fig. 7　NMSE comparison of different channel estimation algorithms in three typical scenes

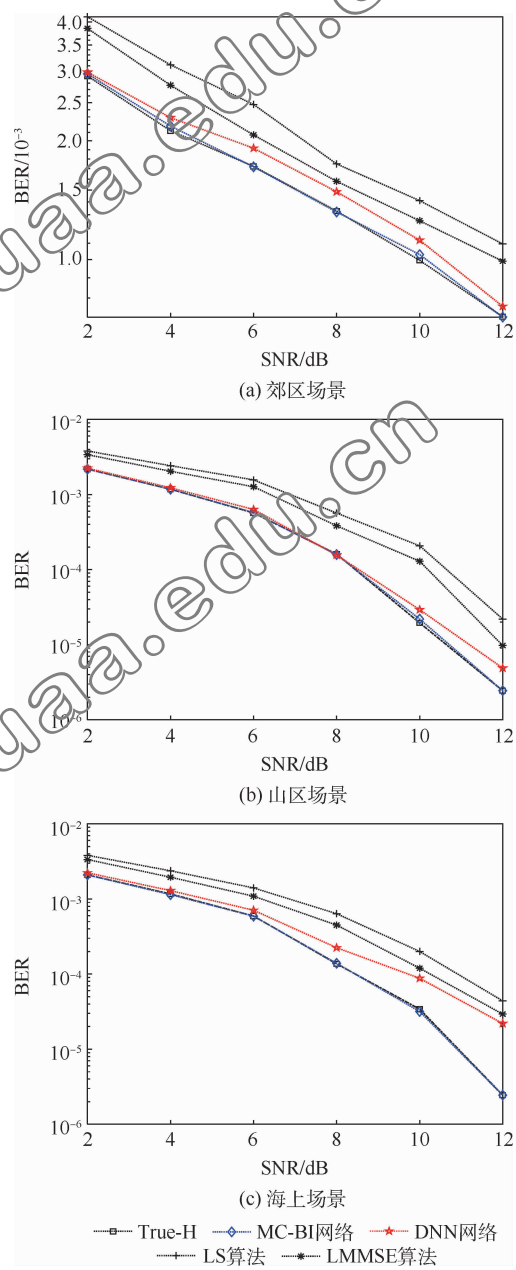

图 8　三种典型场景下不同信道估计算法的 BER 曲线

Fig. 8　BER curves of different channel estimation algorithms in three typical scenes

http://bhxb.buaa.edu.cn

从图 8 可以看出,3 种典型场景下,空地信道环境下各种估计算法的 BER 曲线随着信噪比的增加呈下降趋势;本文提出的 MC-BI 网络获得的 BER 性能最接近真实信道的 BER 理论上限值("True-H"曲线为采用真实信息系数计算出的 BER 结果),说明本文提出的信道估计网络在空地数据链系统下能够更好地利用导频信息实现空地信道估计。

4.5 MCNN 网络的压缩分析

为了实现模型参数压缩,本文将调制滤波器技术引入 CNN 网络中,生成 MCNN 网络。图 9 为卷积层数为 1、2、3、4 时模型压缩前后的参数量对比。可以看出,随着卷积层数的增加,与 CNN 模型相比,MCNN 模型的参数量逐渐减少。

图 10 为山区场景下 2 层 MCNN + 3 层 BiLSTM 结构与 2 层 CNN + 3 层 BiLSTM 结构的信道估计 BER 性能曲线。可以看出,将调制技术引入 CNN 网络之后,2 层 MCNN + 3 层 BiLSTM 结构与 2 层 CNN + 3 层 BiLSTM 结构的信道估计 BER 性能几乎相当。这表明本文提出的 MCNN 网络结构,与相同层数的 CNN 网络结构相比,特征提取能力相近,而模型参数量更少。

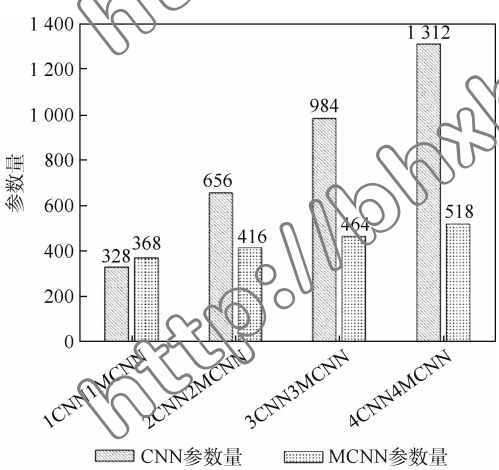

图 9 压缩前后模型参数量比较

Fig. 9 Comparison of model parameters before and after compression

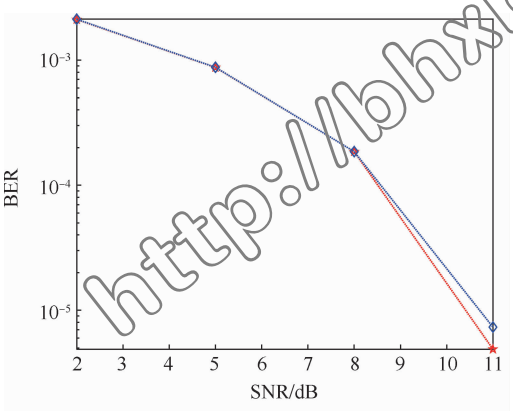

图 10 MCNN + BiLSTM 与 CNN + BiLSTM 网络 BER 对比

Fig. 10 BER comparison between MCNN + BiLSTM network and CNN + BiLSTM network

4.6 网络层数对实验结果的影响分析

为了探究网络层数对 MC-BI 算法信道估计精度的影响,本节对具有不同 MCNN 和 BiLSTM 层数的网络进行了比较。图 11 为在不同 MCNN、

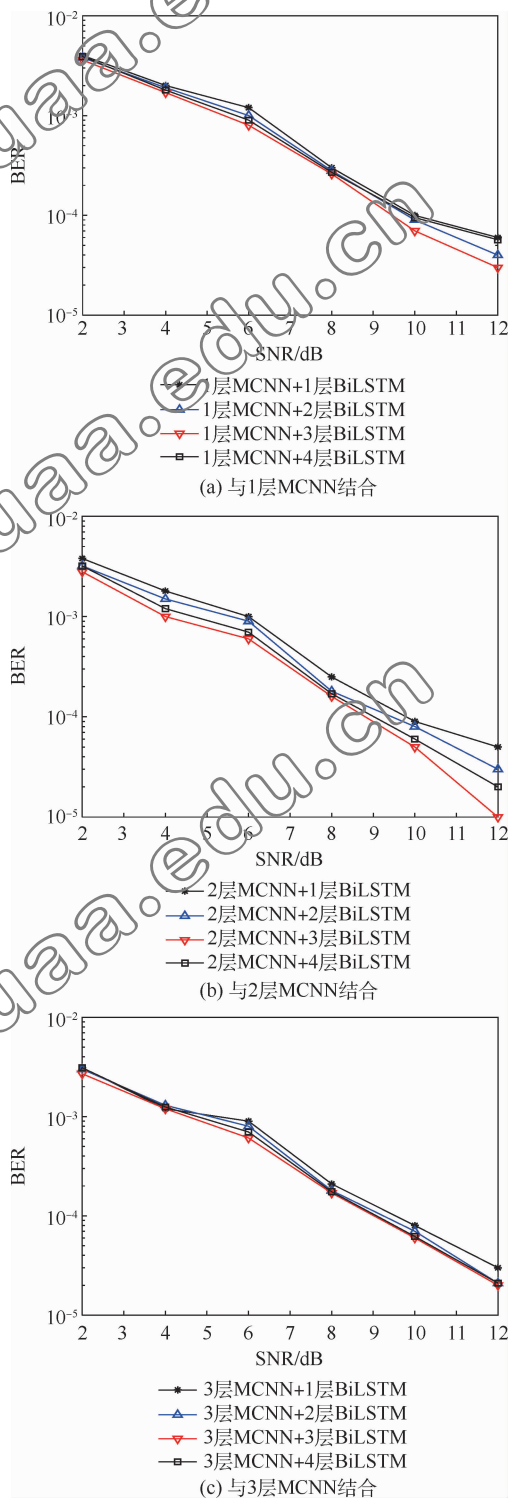

图 11 不同 BiLSTM 层与不同 MCNN 层结合的 MC-BI 算法的 BER 曲线

Fig. 11 BER curves of MC-BI algorithm with different BiLSTM layers and MCNN layers

http://bhxb.buaa.edu.cn

BiLSTM 层数下，MC-BI 网络在山区场景下 OFDM 地空数据链系统中的 BER 性能。

从图 11(a)可以看到，在 MCNN 为 1 层时，选取 3 层 BiLSTM 的 MC-BI 网络 BER 性较好；从图 11(b)可以看到，在 MCNN 为 2 层时，选取 3 层 BiLSTM 的 MC-BI 网络 BER 性能较好；从图 11(c)可以看到，在 MCNN 为 3 层时，选取 2 层 BiLSTM 的 MC-BI 网络 BER 性能较好。

图 12 为 1 层 MCNN + 3 层 BiLSTM、2 层 MCNN + 3 层 BiLSTM 和 3 层 MCNN + 2 层 BiLSTM 三种不同结构的 BER 性能曲线。可以看出，针对本文建立的空地信道样本，2 层 MCNN 与 3 层 BiLSTM 结合的 MC-BI 网络的 BER 性能相对最好。

综合以上分析，适当增加网络层数可以提高 MC-BI 网络的估计精度，而过多地增加层数反而降低了估计精度，其原因在于：随着 MCNN 和 BiLSTM 层数的增加，网络参数增多，模型训练出现了一定程度的“过拟合”现象。

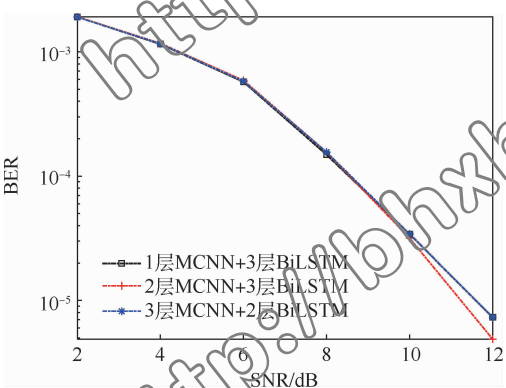

图 12　三种 MC-BI 网络的 BER 比较

Fig. 12　BER comparison of three MC-BI networks

5　结　论

本文提出了一种基于 MCNN 和 BiLSTM 的 MC-BI 网络用于信道估计，在空地高速数据链 OFDM 中进行信道估计实验验证，得到如下结论：

1）通过构建 MC-BI 网络对 OFDM 多径空地信道进行估计表明，与传统 LS 算法、LMMSE 算法及 DNN 网络进行比较，本文算法均获得最佳的 NMSE 和 BER 性能。

2）通过引入调制滤波器技术，生成的 MCNN 网络有效实现模型参数压缩，且特征提取能力与原 CNN 网络相当。

3）通过对比不同网络层数的 BER 性能，表明适当增加 MCNN 和 BiLSTM 的层数可以提高 MC-BI 网络估计的 BER 性能。

本文提出的基于 MCNN 的空地数据链信道估计方法对于“准静态”空地信道的估计性能较好，然而由于无人机等空中平台的飞行姿态多变、飞行速度多样，空地信道估计问题还需考虑存在机身衰落、信道快时变性等因素的影响。因此，建立更加符合实际的空地信道样本数据，进一步优化信道估计网络结构将是下一步研究的重点。

参考文献（References）

[1] 丛玮，李宏. 基于 OFDM 的无人机通信链路[C]//2006 中国无人机大会，2006：629-634.
CONG W，LI H. Communication link of UAV based on OFDM [C]//2006 China UAV Conference，2006：629-634 (in Chinese).

[2] 章勇. OFDM 系统信道估计技术研究[D]. 北京：北京邮电大学，2008：10-12.
ZHANG Y. Research on channel estimation techniques of OFDM system[D]. Beijing：Beijing University of Posts and Telecommunications，2008：10-12 (in Chinese).

[3] 董秀洁，王莉，王素菊. 一种改进的 LS 信道估计算法[J]. 哈尔滨理工大学学报，2009，14(1)：47-50.
DONG X J，WANG L，WANG S J. An improved LS channel estimation algorithm[J]. Journal of Harbin University of Science and Technology，2009，14(1)：47-50 (in Chinese).

[4] WANG J，WEN O Y，LI S Q. Soft-output MMSE MIMO detector under ML channel estimation and channel correlation[J]. IEEE Signal Processing Letters，2009，16(8)：667-670.

[5] ZHANG K，XUE L S，LIU X P，et al. Performance comparison of LS，LMMSE channel estimation method in frequency and time domain for OQAM/OFDM systems[C]//2017 IEEE 17th International Conference on Communication Technology (ICCT). Piscataway：IEEE Press，2017：224-228.

[6] 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.

[7] HE H T，WEN C K，JIN S，et al. A model-driven deep learning network for MIMO detection[C]//2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Piscataway：IEEE Press，2018：584-588.

[8] GAO X X，JIN S，WEN C K，et al. ComNet：Combination of deep learning and expert knowledge in OFDM receivers[J]. IEEE Communications Letters，2018，22(12)：2627-2630.

[9] 廖勇，花远肖，姚海梅. 基于深度学习的 OFDM 信道估计[J]. 重庆邮电大学学报(自然科学版)，2019，31(3)：348-353.
LIAO Y，HUA Y X，YAO H M. Channel estimation based on deep learning for OFDM systems[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition)，2019，31(3)：348-353 (in Chinese).

[10] 廖勇，花远肖，姚海梅，等. 高速移动环境下基于深度学习的信道估计方法[J]. 电子学报，2019，47(8)：1701-1707.
LIAO Y，HUA Y X，YAO H M，et al. Channel estimation method based on deep learning in high-speed mobile environments [J]. Acta Electronica Sinica，2019，47(8)：1701-1707 (in Chi-

http://bhxb.buaa.edu.cn

nese).

[11] SAINATH T N, VINYALS O, SENIOR A, et al. Convolutional, long short-term memory, fully connected deep neural networks [C]// 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE Press, 2015: 4580-4584.

[12] LIAO Y, HUA Y X, CAI Y L. Deep learning based channel estimation algorithm for fast time-varying MIMO-OFDM systems [J]. IEEE Communications Letters, 2020, 24(3): 572-576.

[13] 刘步花,丁丹,杨柳. 基于神经网络的OFDM信道补偿与信号检测[J]. 北京航空航天大学学报, 2020, 46(7): 1363-1370.
LIU B H, DING D, YANG L. Channel compensation and signal detection of OFDM based on neural network [J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(7): 1363-1370 (in Chinese).

[14] ZHANG J, WEN C K, JIN S, et al. Artificial intelligence-aided receiver for a CP-free OFDM system: Design, simulation, and experimental test [J]. IEEE Access, 2019, 7: 58901-58914.

[15] MATOLAK D W, SUN R Y. Air-ground channel characterization for unmanned aircraft systems—Part I: Methods, measurements, and models for over-water settings [J]. IEEE Transactions on Vehicular Technology, 2017, 66(1): 26-44.

[16] MATOLAK D W, SUN R Y. Air-ground channel characterization for unmanned aircraft systems—Part Ⅱ: Hilly and mountainous settings [J]. IEEE Transactions on Vehicular Technology, 2017, 66(3): 1913-1925.

[17] MATOLAK D W, SUN R Y. Air-ground channel characterization for unmanned aircraft systems—Part Ⅲ: The suburban and nearurban environments [J]. IEEE Transactions on Vehicular Technology, 2017, 66(8): 6607-6618.

[18] HAN S, POOL J, TRAN J, et al. Learning both weights and connections for efficient neural networks [EB/OL]. (2015-10-30) [2020-10-15]. https://arxiv.org/abs/1506.02626v3.

[19] HAN S, MAO H Z, DALLY W J. Deep compression: Compressing deep neural networks with pruning, trained quantization and huffman coding [EB/OL]. (2016-02-15) [2020-10-15]. https://arxiv.org/abs/1510.00149.

[20] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 2818-2826.

[21] WANG X D, ZHANG B C, LI C, et al. Modulated convolutional networks [C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 840-848.

[22] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks [J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673-2681.

[23] 姚宜东,徐毅,杨新华,等. 介质表面电磁波反射和透射能量的分析与计算[J]. 通信技术, 2016, 49(5): 558-562.
YAO Y D, XU Y, YANG X H, et al. Analysis and calculation on reflection and transmission energy of electromagnetic wave at dielectric interface [J]. Communications Technology, 2016, 49(5): 558-562 (in Chinese).

[24] WEN C K, SHIH W T, JIN S. Deep learning for massive MIMO CSI feedback [J]. IEEE Wireless Communications Letters, 2018, 7(5): 748-751.

[25] ZHANG D N, DING W R, LIU C H, et al. Modulated autocorrelation convolution networks for automatic modulation classification based on small sample set [J]. IEEE Access, 2020, 8: 27097-27105.

[26] DAO D N, TELLAMBURA C. Intercarrier interference self-cancellation space-frequency codes for MIMO-OFDM [J]. IEEE Transactions on Vehicular Technology, 2005, 54(5): 1729-1738.

http://bhxb.buaa.edu.cn

Channel estimation of air-ground data link based on modulated convolutional neural network

LIU Chunhui[1,*], WANG Meilin[2], DONG Zanliang[2], WANG Pei[2]

(1. Institute of Unmanned System, Beihang University, Beijing 100083, China;
2. School of Electronics and Information Engineering, Beihang University, Beijing 100083, China)

Abstract: Aimed at the inaccuracy of channel estimation of orthogonal frequency division multiplexing (OFDM) system in the complex air-ground data link environment, this paper proposes a channel estimation algorithm based on the modulated convolutional neural network (MCNN) and bidirectional long short-term memory (BiLSTM) network. First, least square (LS) algorithm is used to extract the initial channel state information (CSI), then MCNN network is used to extract the depth characteristics of the initial CSI while compressing the network model, and finally BiLSTM network is used to predict the final CSI and realize channel estimation. In the aspect of experimental verification, the air-ground channel model constructed is used to generate the channel coefficient dataset, so as to realize the training and testing of neural network model. The simulation results show that compared with the traditional methods and the existing deep learning method, the proposed channel estimation method has a lower estimation error, and the performance of the bit error ratio (BER) of the system under the condition of high SNR is improved by nearly an order of magnitude. Due to the introduction of the modulation filter technology, the number of network model parameters decreases remarkably with the increase of the number of neural network layers.

Keywords: orthogonal frequency division multiplexing (OFDM); deep learning; channel estimation; air-ground channel model; multipath effect

http://bhxb.buaa.edu.cn

Received: 2020-10-19; **Accepted**: 2021-01-17; **Published online**: 2021-02-04 15:55

URL: kns.cnki.net/kcms/detail/11.2625.V.20210204.1443.003.html

Foundation items: Science and Technology Innovation 2030-Key Project of "New Generation Artificial Intelligence" (2020AAA0108200); Beijing Municipal Natural Science Foundation (4204102)

* **Corresponding author**. E-mail: liuchunhui2134@buaa.edu.cn