

北京航空航天大学学报

Journal of Beijing University of Aeronautics and Astronautics

ISSN 1001-5965, CN 11-2625/V

《北京航空航天大学学报》网络首发论文

题目: 基于调制卷积神经网络的空地数据链信道估计
作者: 王美琳, 刘春辉, 董赞亮, 王沛
DOI: 10.13700/j.bh.1001-5965.2020.0591
收稿日期: 2020-10-19
网络首发日期: 2021-02-04
引用格式: 王美琳, 刘春辉, 董赞亮, 王沛. 基于调制卷积神经网络的空地数据链信道估计. 北京航空航天大学学报.
<https://doi.org/10.13700/j.bh.1001-5965.2020.0591>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式 (包括网络呈现版式) 排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊 (光盘版)》电子杂志社有限公司签约, 在《中国学术期刊 (网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊 (网络版)》是国家新闻出版广电总局批准的网络连续型出版物 (ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

基于调制卷积神经网络的空地数据链信道估计

王美琳¹, 刘春辉^{2✉}, 董赞亮¹, 王沛¹

(1. 北京航空航天大学 电子信息工程学院, 北京 100191; 2. 北京航空航天大学 无人系统研究院, 北京 100191)

*通信作者 E-mail: liuchunhui2134@buaa.edu.cn

摘要 针对复杂环境下空地数据链正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)系统信道估计精度不足问题, 本文提出了一种基于调制卷积神经网络(Modulated Convolutional Neural Network, MCNN)和双向长短期记忆网络(Bidirectional Long Short-Term Memory, BiLSTM)结合的信道估计算法。首先利用最小二乘算法(Least Square, LS)提取初始信道状态信息(Channel State Information, CSI), 然后利用 MCNN 提取初始 CSI 的深度特征并对网络模型进行压缩, 最后利用 BiLSTM 网络对最终 CSI 进行预测, 实现信道估计。在实验验证方面, 利用构建的空地(Air-Ground, AG)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, 与传统方法和现有深度学习方法相比, 所提出的信道估计方法的具有更小的估计误差, 高信噪比条件下的系统误码率(Bit Error Ratio, 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; 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

文献标识码: A

DOI: 10.13700/j.bh.1001-5965.2020.0591

Channel estimation of air-ground data link based on Modulation Convolutional Neural Network

WANG Meilin¹, LIU Chunhui^{2✉}, DONG Zanliang¹, WANG Pei¹

(1. School of Electronic and Information Engineering, Beijing University of Aeronautics and Astronautics, Beijing 100191, China;

2. Research Institute of Unmanned Aerial Vehicle, Beijing University of Aeronautics and Astronautics, Beijing 100191, China;

Abstract Aiming 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. At 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 compress network model, finally BiLSTM network is used to predict the final CSI and realize Channel estimation. In the aspect of experimental verification, the Air-Ground(AG) channel model constructed is used to generate the channel coefficient data set, 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 with the increase of the number of neural network layers.

Key words OFDM; deep learning; channel estimation; air-ground channel model; multipath effect

空地数据链(Air-Ground Datalink)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

收稿日期: 2020-10-19

基金项目: 2020 年度科技创新 2030 —“新一代人工智能”重大项目(批准号: 2020AAA0108200); 北京市自然科学基金(基金号 4204102)

网络首发时间: 2021-02-04 15:55:55

网络首发地址: <https://kns.cnki.net/kcms/detail/11.2625.V.20210204.1443.003.html>

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。

传统的信道估计方法可分为基于导频的信道估计方法、盲估计和半盲估计, 其中基于导频的信道估计方法最为常见。经典的基于导频的信道估计算法有最小二乘法(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 对 MMSE 算法进行了改进, 简化了 MMSE 的计算, 因此在实际应用中常用 LMMSE 算法代替 MMSE 算法。

最近, 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方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两个子网络, 这种做法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-全连接神经(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方法, 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)系统的信道估计方法, 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(Air-Ground, AG)信道进行准确的建模对提升信道估计方法的估计精度至关重要。

在 AG 信道建模研究方面, 文献[15-17]综合分析了 AG 信道特点, 对不同地表环境下的 AG 信道进行建模, 提出了在经典二径 AG 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 AG 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 AG 信道建模方法; 文献[16]重点介绍山区环境的 AG 信道建模方法; 文献[17]重点介绍郊区环境的 AG 信道建模方法。

除了 AG 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。卷积神经网络模型轻量化的研究主要分为两个方向, 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

三类：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 信道估计方法，利用 TDL 模型对复杂环境多径 AG 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 AG 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 算法以及现有的深度学习方法 DNN 相比，本文提出的信道估计方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。

1OFDM 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 通信系统的结构图^[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。

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。其正交性可用公式 (1) 表示为：

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

式中： ω_i 表示第 i 个子载波的角速度， ω_j 表示第 j 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。最后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 $s_n(m)$ 表示为：

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

式中： K 为子载波数， $X_{n,k}$ 为串并转换后的并行传输信号， ω_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。接收信号可表示为：

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

式中： K 为子载波数， $X_{n,k}$ 为串并转换后的并行传输信号， ω_k 为第 k 个子载波的角速度， $H_n(m, \omega_k)$ 为多径传输信道， $Z_{n,k}$ 为加性高斯白噪声。

为了在接收端更好的恢复发射信号，需要进行信道估计，然后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。




图 1 基于 OFDM 的通信系统结构图
Fig.1 Communication system structure based on OFDM

2 空地信道建模

本节基于经典的二径 AG 信道模型，利用包含直射分量、反射分量以及间歇 MPCs 的 TDL 模型对本文需要的 AG 信道进行建模。

2.1 二径信道模型

2.1.1 模型参数

图 2 是简化的空地二径信道模型，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 中， h_A 和 h_G 分别是飞机和地面天线的高度； d 是二者地面距离； ψ 是地面反射分量的掠射角。




图 2 二径信道模型
Fig.2 Two-ray channel model

在二径模型中，地表反射是由地面平整度和地面站的半径 Q 米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：

$$Q = \frac{d h_G}{h_A + h_G} \quad (4)$$

二径模型相关参数计算如下：

$$\begin{cases}
 R_{1,p} = \sqrt{h_A^2 + d^2} \\
 l_{1,p} = \sqrt{h_A^2 + (d - Q)^2} \\
 l_{2,p} = \sqrt{h_G^2 + Q^2} \\
 R_{2,p} = l_{1,p} + l_{2,p} \\
 \Delta R_p = R_{2,p} - R_{1,p} \\
 \sin(\psi_p) = \frac{h_G}{l_{2,p}} \\
 \tau_{0,p} = \frac{R_{1,p}}{c} \\
 \tau_{s,p} = \frac{R_{2,p}}{c} \\
 \alpha_{s,n,p} = R_{1,p} e^{-\frac{j2\pi\Delta R_p}{\lambda}} / R_{2,p}
 \end{cases} \quad (5)$$

式中： $R_{1,p}$ 是直射分量路径长度， $l_{1,p}$ 是反射分量第一段路径长度， $l_{2,p}$ 是反射分量第二段路径长度， $R_{2,p}$ 是反射分量路径总长度， ΔR_p 是反射分量和直射分量路径差， $\tau_{0,p}$ 是直射分量路径时延， $\tau_{s,p}$ 是反射分量路径时延， $\alpha_{s,n,p}$ 是表面相对反射系数， c 是光速， $\lambda = c / f_c$ 是波长， f_c 是载波频率。

依据文献[15-17]， P 时刻的二径 AG 信道的冲激响应为：

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

式中：自由视距(Line of Sight, LOS)振幅分量为 $\alpha_{0,p} = \frac{c}{4\pi f_c R_{1,p}}$ ，自由空间表面反射振幅为

$$\alpha_{s,p} = \frac{c}{4\pi f_c R_{2,p}}。$$

假设 $R_{1,p}$ 为已知，此时 $\alpha_{0,p}$ 和 $\tau_{0,p}$ 也为已知。对公式进行归一化，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)可以重新表达为：

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

式中： θ 表示相位。

此时，决定空地二径信道 CIR 的三个参数为：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，粗糙因子 $r_F = \exp(-C_r^2 / 2)$ ，其中 $C_r = 4\pi s_g \sin(\psi_p) / \lambda$ ， s_g 为地面高度标准差， ψ_p 为 p 时刻的掠角， λ 为载波波长。

当反射面为海洋时，粗糙因子 $r_F = \exp(-C_r^2 / 2) I_0(-C_r^2 / 2)$ ，此时 $s_g = 0.0052 \mu^2$ ， 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：

$$D_p = [1 + \frac{2}{k\alpha \sin(\varphi_p)} \frac{l_{1,p} l_{2,p}}{l_{1,p} + l_{2,p}}]^{-\frac{1}{2}} \quad (8)$$

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, 本节中我们采用简化计算方法, 根据文献[23], p 时刻的表面反射系数的简化计算方法为:

$$\Gamma_{p,F} = \frac{\eta_1 - \eta_2}{\eta_1 + \eta_2} \quad (9)$$

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 MPCs 的 TDL 模型

文献[16]提出 AG 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:

$$\begin{aligned} h_{\text{ray}}(n) \approx & e^{-j\theta_1} \delta(n) \\ & + \alpha_{s,n,p} \Gamma_{p,F} D_p r_F e^{-j\theta_2} \delta(n-1) \\ & + \sum_{p=3}^9 \alpha_p z_p e^{-j\theta_1} \delta(n-p) \end{aligned} \quad (10)$$

式中: α 和 θ 分别表示振幅和相位; $z \in (0,1)$ 用来描述抽头开关的概率; 下标 p 表示第 p 次间歇 MPC, p 为 3~9 的整数。

式中的前两项由二径模型计算得到。对于式中所有的抽头, 相位都是均匀随机地分布在 $0 \sim 2\pi$ 之间; 间歇抽头的相对功率 $10 \log(\alpha_p^2 / \alpha_{LOS}^2)$ 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, 输出层以及网络训练四部分。




图 3 基于深度学习的信道估计框架
Fig.3 Channel estimation framework based on deep learning

3.1 网络输入层

首先, 利用第 2 节提出的 9 径 TDL 模型对 AG 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 CSI^[24]:

$$H_{LS}(q) = \frac{y_p(q)}{x_p(q)} \quad (11)$$

式中: $x_p(q)$ 为第 q 个子载波的发送导频信号, $y_p(q)$ 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式为:

$$H = [H(0), \dots, H(n), \dots, H(N-1)] \quad (12)$$

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(Modulated CNN)。

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 $K \times 1 \times M$, 调制滤波器有 K 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 $K \times 1 \times M$ 的调制滤波器, 即可生成 $K \times L$ 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 按公式 (13) 计算:

$$C = \sum_s^K \hat{C} \cdot M_s \quad (13)$$

式中: c 是衍生核, $\hat{c}$ 是原始卷积, M 是调制滤波器, 调制滤波器视为原始卷积核的权重矩阵, M_s 是调制滤波器的第 s 个通道, $\cdot$ 表示矩阵元素相乘。基于调制滤波器的调制过程如图 4。




图 4 基于调制滤波器的调制过程
Fig.4 Modulation process based on the modulation filter

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滤波器, 计算公式如下:

$$m(t) = \sum_{t=0}^{2\pi} \sin(2\pi ft + \theta) \cdot \delta(t - n \frac{2\pi}{f_s}) \quad (14)$$

式中： f_s 是采样频率， θ 是初始相位， 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，其主体结构为两个单向 LSTM 网络。




图 5 BiLSMT 网络结构
Fig.5 BiLSTM network structure

图 5 为 BiLSTM 的网络结构示意图，BiLSTM 为双向循环神经网络，其主体结构是两个单向循环神经网络。在每个时刻 t ，输入会同时提供给这两个方向相反的循环网络，两个网络独立进行运算，各自产生新的状态和输出，而 BiLSTM 的最终输出就是这两个单向网络输出的拼接，可用公式 (15) 表示为：

$$out_t = Concat(o_t, o'_t) \quad (15)$$

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， $Concat$ 函数将两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双向 LSTM 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：

$$\hat{H} = [\hat{h}_0, \dots, \hat{h}_l, \dots, \hat{h}_8] \quad (16)$$

式中： $\hat{h}_l$ 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两部分，如图 6 所示。




图 6 MC-BI 网络模型的训练与应用
Fig.6 Training and application of MC-BI network model

在离线训练阶段, 利用大量 AG 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。

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, 使用自适应矩估计 (ADaptive Moment estimation, 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:

$$Loss = \frac{1}{N} \sum_{n=1}^N (Hest_n - H_n)^2 \quad (17)$$

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、山区和海上三种典型场景, 建立了准静态^[26]多径 AG 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。三种场景信道模型参数如表 1 所示。

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	1000	20	46	15	1	0.05
山区	4000	20	60	5	1	1000
海上	800	20	25	81	1	0.1872

利用表 1 中的场景参数, 建立 AG 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: <https://github.com/liuchunhui2134/AGChannelSimulation>。

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 $5 \times 1 \times 8$, 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 10000 和 1000, 训练学习率为 0.005。OFDM 系统的主要参数设置如表 2 所示。

表 2 OFDM 系统参数设置
Table 2 Simulation system parameters

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

图 7 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 网络在三种典型环境下空地信道估计的归一化均方误差 (Normalized MSE, NMSE) 性能。




图 7(a) 郊区场景下不同信道估计方法的 NMSE 比较
Fig.7(a) NMSE comparison of different channel estimation methods in suburban scene




图 7(b) 山区场景下不同信道估计方法的 NMSE 比较
Fig.7(b) NMSE comparison of different channel estimation methods in mountain scene




图 7(c) 海上场景下不同信道估计方法的 NMSE 比较
Fig.7(c) NMSE comparison of different channel estimation methods under sea scene

从图 7 中可以看出,在三种典型场景下,本文提出的 MC-BI 网络的估计精度要优于其他几类算法,在各种信噪比条件下比 LMMSE 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 MSE 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。图 8 比较了三种典型场景下传统的 LS 算法^[3]、LMMSE 算法^[5]、全连接 DNN 网络^[9]和本文所提的 MC-BI 信道估计方法在不同信噪比下的 BER 性能。




图 8(a) 郊区场景下不同信道估计方法的 BER 曲线

Fig.8(a) BER of different channel estimation methods in mountain scene in suburban scene




图 8(b) 山区场景下不同信道估计方法的 BER 曲线

Fig.8(b) BER of different channel estimation methods in mountain scene




图 8(c) 海上场景下不同信道估计方法的 BER 曲线

Fig.8(c) BER of different channel estimation methods under sea scene

如图 8 所示, 三种典型场景下空地信道环境下各种估计方法的 BER 曲线随着 SNR 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, 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 AG 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 给出卷积层数为 1、2、3、4 时, 模型压缩前后的参数量对比。




图 9 压缩前后模型参数量
Fig.9 Comparison of model parameters before and after compression

如图 9 所示, 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 给出了山区场景下 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。




图 10 MCNN+BiLSTM 与 CNN+BiLSTM 网络 BER 对比
Fig.10 BER comparison between MCNN+BiLSTM network and CNN+BiLSTM network

如图 10 所示, 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。

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 方法信道估计精度的影响, 本节还对具有不同 MCNN 和 BiLSTM 层数的网络进行了比较。图 11 分别展示了在不同 MCNN、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。




图 11(a) 不同 BiLSTM 层与 1 层 MCNN 结合的 MC-BI 方法的 BER 曲线
Fig.11(a) BER of MC-BI method with different BiLSTM layers and one layer MCNN layer




图 11(b) 不同 BiLSTM 层与 2 层 MCNN 结合的 MC-BI 方法的 BER 曲线
Fig.11(b) BER of MC-BI method with different BiLSTM layers and two MCNN layers




图 11(c) 不同 BiLSTM 层与 3 层 MCNN 结合的 MC-BI 方法的 BER 曲线
Fig.11(c) BER of MC-BI method with different BiLSTM layers and three MCNN layers

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 性能较好; 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 给出 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。




图 12 3 种 MC-BI 网络的 BER 比较
Fig.12 BER comparison of three MC-BI networks

如图 12 所示, 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, 适当的增加网络层数可以提高 MC-BI 网络的估计精度, 而过多的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。

5 总结与展望

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 AG 信道进行估计表明, 与传统方法 LS、LMMSE 以及 DNN 网络进行比较, 本文方法均获得最佳的 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。

本文提出的基于调制卷积神经网络的空地数据链信道估计方法对于“准静态”AG 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, AG 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 AG 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] 丛伟, 李宏. 基于 OFDM 的无人机通信链路[C]//2006 中国无人机大会论文集. 西安: 西北工业大学, 2006: 629-634.
CONG W, LI H. Communication link of UAV based on OFDM. Xi'an: Northwestern Polytechnical University, 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 Technique 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, LI S. 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, et al. Performance comparison of LS, LMMSE channel estimation method in frequency and time domain for OQAM-OFDM system[C]//2017 IEEE 17th International Conference on Communication Technology (ICCT). Xi'an: IEEE Press, 2017: 224-228.
- [6] YE H, LI G Y, JUANG B H F. Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems[J]. IEEE Wireless

- Communications Letters,2017,7(1):114-117.
- [7] HE H T,WEN C K,JIN S,et al.A model-driven deep learning network for MIMO detection[C]//the 6th IEEE Global Conference on Signal and Information Processing,Nanjing: IEEE Press,2018:584-588.
- [8] GAO X,JIN S,WEN C K,et al. Com-Net:Combination of Deep Learning and Expert Know-ledge 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, 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,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.Channel Estimation Method Based on Deep Learning in High-Speed Mobile Environments[J].ACTA Electronica Sinica,2019,47(8):1701-1707(in Chinese).
- [11] SAINNATH 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),New York: 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/OL]. 北京航空航天大学学报: 2020: 1-11[2020-06-20]. <https://doi.org/10.13700/j.bh.1001-5965.2019.0456>.
LIU B H,DING D,YANG L.Channel Compensation and Signal Detection of OFDM Based on neural network[J/OL].Journal of Beijing University of Aeronautics and Astronautics: 2020:1-11[2020-06-20].<https://doi.org/10.13700/j.bh.1001-5965.2019.0456>.
- [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] W.MATOLAK D,SUN R.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] W.MATOLAK D,SUN R.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] W.MATOLAK D,SUN R.Air-Ground Channel Characterization for Unmanned Aircraft Systems-Part III:The Suburban and Near-Urban 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[C]//Conference and Workshop on Neural Information Processing Systems.2015,arXiv:1506.02626v3:1135-1143
- [19] HAN S,MAO H,DALLY W J.Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding[C]// ICLR.2016,ArXiv: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,LonDon,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(CVPR),Beijing:IEEE Press,2018: 840-848.
- [22] MIKE S,KULDIP K,PALIWAL.Bidirectional Recurrent Neural Network[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.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,2017, 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 A N,TELLAMBURA,C.Intercarrier Interference Self-Cancellation Space-Frequency Codes for MIMO-OFDM[J].IEEE Transactions on Vehicular Technology,2005,54(5):1729-1738.