

基于深度神经网络的低轨卫星信道估计动态映射策略

刘逸飞, 崔高峰, 潘明宇, 王卫东

(北京邮电大学电子工程学院, 北京 100876)

摘要: 在低轨卫星 (LEO, low earth orbit) 通信系统中, 针对星地链路高速运动引发的时延动态变化以及低信噪比的信道环境, 传统的信道估计算法性能表现较差等问题, 在正交频分复用 (OFDM, Orthogonal Frequency Division Mul-tiplexing) 的框架下, 提出一种基于深度神经网络 (DNN, deep neural networks) 与信道响应分块合并结合的低轨卫星通信系统的信道估计算法, 可有效提升低轨卫星非地面网络 (NTN, non-terrestrial networks) 通信环境中数据传输的可靠性与稳定性。该算法将频域导频信道响应矩阵进行分块平均, 并结合深度神经网络, 在不同时延与噪声的信道场景下, 自适应得到导频信道响应分块合并数的最优映射。将该算法与现有的信道估计算法在动态随机时延情况下的误码率性能曲线进行仿真对比。仿真结果表明, 该算法相对于传统信道估计算法, 在添加动态随机时延情况下, 同一信噪比下误码率更低, 具有较强的鲁棒性, 同时相比于现有的神经网络信道估计算法, 能适应较大时延与时延变化情况, 具有更强的泛化性。

关键词: 低轨卫星; 非地面网络; 信道估计; 深度神经网络; 正交频分复用

中图分类号: TN927.2

文献标志码: A

doi: 10.11959/j.issn.2096-3750.XXXX.

Deep neural network-based dynamic mapping strategy for low earth orbit satellite channel estimation

LIU Yifei, CUI Gaofeng, PAN Mingyu, WANG Weidong

School of Electronic Engineering, Beijing University of Posts and Telecommunications, Beijing 100876, China

Abstract: In low-earth-orbit (LEO) satellite communication systems, addressing the poor performance of traditional channel estimation algorithms under dynamic delay variations and low signal-to-noise ratio (SNR) caused by high-speed satellite-terrestrial motion, this paper proposes a deep neural network (DNN)-based channel estimation algorithm combined with sub-block merging of channel responses under an orthogonal frequency-division multiplexing (OFDM) framework. This method enhances the reliability and stability of data transmission in non-terrestrial networks (NTN). The algorithm divides the frequency-domain pilot channel response matrix into sub-blocks for averaging and employs a DNN to adaptively determine the optimal sub-block merging number under different channel conditions with varying delay and noise. The bit error rate (BER) performance of this algorithm is compared through simulations against existing channel estimation methods under dynamically randomized delays. Results demonstrate that the proposed algorithm achieves lower BER at identical SNR levels than traditional methods, exhibiting stronger robustness. Compared to existing neural network-based channel estimation algorithms, it adapts better to larger delays and dynamic delay variations, showing superior generalization capability.

Key words: low Earth orbit satellite, non-terrestrial network, channel estimation, deep neural network, orthogonal frequency-division multiplexing

收稿日期: XXXX-XX-XX; 修回日期: 2025-07-24

通信作者: 崔高峰, cuigaofeng@bupt.edu.cn

基金项目: 国家自然科学基金 (NO.62171052)

Foundation Items: The National Natural Science Foundation of China (NO.62171052)

0 引言

卫星通信以其覆盖范围广的特点,正逐步向大容量、大带宽及承载业务多样化的方向发展^[1]。6G空天地海一体化网络将充分整合不同轨道卫星(包括高、中、低轨道卫星)等空中资源。相较于高、中轨道卫星,低轨卫星具有传输损耗小、时延低、成本低等优势^[2]。因此,低轨卫星通信网络的建设对构建空天地海一体化网络具有深远意义。正交频分复用(OFDM, Orthogonal Frequency Division Multiplexing)作为一种高效的多载波调制技术,凭借其较高的频谱效率及对大带宽传输的良好支持能力,被广泛应用于低轨卫星通信系统中。在低轨卫星OFDM系统中,信道估计是确保信号可靠传输的关键环节。由于NTN信道存在多径效应、噪声干扰以及时变特性,接收端需准确估计信道对每个子载波的影响,才能有效消除信号失真并恢复原始有效数据^[3-6]。在OFDM系统中,基于导频的信道估计是常用方法。传统算法包括最小二乘(Least Squares Method)、最小均方误差(MMSE, Minimum Mean Square Error)和线性组最小均方误差(LMMSE, Linear Minimum Mean Square Error)等^[7-9]。LS算法通过利用导频位置的信道信息进行插值来实现信道估计,其算法复杂度最低、结构最为简单,易于工程实现。然而,该算法未考虑噪声影响,导致其在低信噪比(SNR, Signal-to-noise ratio)条件下性能显著下降^[10]。MMSE和LMMSE算法在低信噪比下性能明显优于LS算法,但其算法结构相对复杂,在实际卫星载荷中难以部署应用。近年来,随着人工智能技术与计算能力的持续发展,神经网络在图像识别、文本分类等诸多领域得到广泛应用^[11-16],同时在低轨卫星通信场景中也发挥着重要作用^[17-28]。文献[29]针对传统LS算法在低信噪比下性能下降以及LMMSE算法复杂度高的问题,提出利用四层深度神经网络对LS信道估计结果进行修正。仿真结果表明,基于深度神经网络信道估计算法在性能与复杂度方面均优于LS和LMMSE算法。文献[30]在时变、频变的无线信道环境下,提出基于卷积神经网络(CNN, Convolutional Neural Network)的信道响应矩阵估计算法,相比传统算法及基于简单神经网络信道估计算法,实现了信道估计精度的提升。然而,文献[29]

中算法仅考虑了噪声对信道估计的影响,未考虑由时延导致的频域符号相位偏转对解调性能的影响。文献[30]中时延模型较为固定且变化范围较小,对于时延变化较快信道,其算法泛化性能较差。

基于上述信道估计算法中存在的问题,本文提出一种基于深度神经网络与信道响应分块合并的信道估计算法。该算法同时考虑噪声与动态时延对信道估计的影响。在低信噪比条件下,算法将频域导频信号处的信道响应进行分块合并以抑制噪声影响。然而,合并数的增加会加剧信道响应的平滑效应,进而扩大时延对信道估计性能的负面影响。因此,本文将信道估计响应分块合并数的优化问题建模为一个分类优化问题,旨在寻求最优的合并数映射以最大化解调性能。该算法可有效提升低轨卫星非地面网络通信环境中数据传输的可靠性与稳定性。

1 LS信道估计算法

1.1 系统与信道模型分析

基于LS信道估计算法的低轨卫星OFDM系统框图如图1所示^[10]。其中 \mathbf{X} 为发送端业务数据频域信号, \mathbf{X}_p 为导频数据频域信号, $x(t)$ 为发送端OFDM调制后时域信号, $w(t)$ 为高斯白噪声信号, $y(t)$ 为经过信道后接收端时域信号, \mathbf{Y} 为接收端业务数据频域信号, \mathbf{Y}_p 为接收端导频频域信号, \mathbf{H}_p 为导频信道响应矩阵, $\hat{\mathbf{Y}}$ 为接收端信道均衡后的业务数据频域信号。

在低轨卫星非地面网络中,卫星以约7.8km/s的速度绕地球运行,导致星地链路呈现显著时变特性。OFDM技术虽能有效抵抗多径效应,且现有时频同步算法可补偿固定传播时延,但在高动态场景下仍存在动态残余时延过大的问题。因此,考虑动态残余时延的信道冲击响应建模如式(1)所示^[29]:

$$h(t, \tau) = \sum_{k=0}^{L-1} \alpha_k(t) \cdot \delta(t - \tau_k(t)) \quad (1)$$

其中 L 为多径数量, $\alpha_k(t)$ 为第 k 径的时变幅度, $\tau_k(t)$ 为第 k 径的时延,包含固定传播时延与动态变化量。NTN信道模型中的多径分量主要来自地面反射(如建筑、地形)和大气散射模型中固定传播时延取决于卫星轨道高度,各径幅度服从莱斯分布或瑞利分布。信道模型中固定传播时延主要取决于卫星轨道高度。动态残余时延量主要由随机时延抖

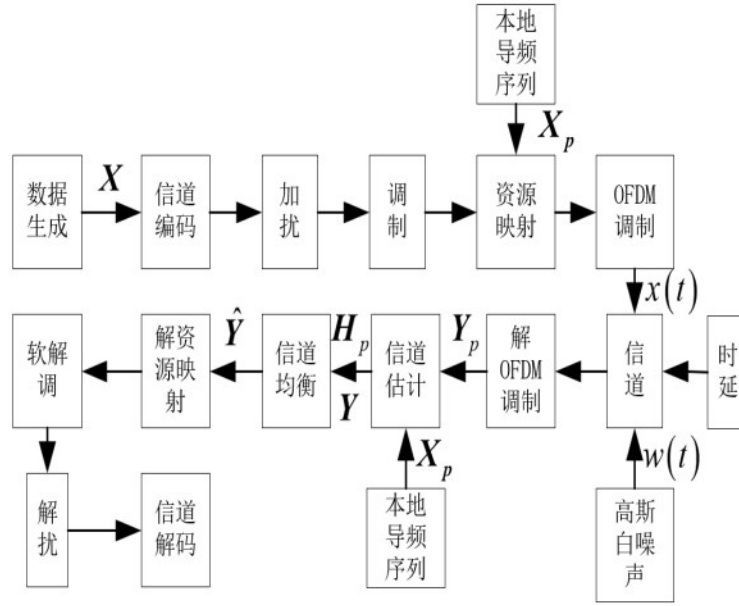


图1 低轨卫星OFDM系统框图

动、卫星与地面站相对运动和时频同步算法的残余时延引起。

1.2 分块合并的LS信道估计算法

在非地面网络信道中，信号第 k 条径的时延表示为 τ ，则接收端时域信号可以表示为：

$$y(t) = x(t - \tau) + w(t) \quad (2)$$

以时隙内单个导频的OFDM符号为例，接收端经OFDM解调后的频域信号表示为：

$$Y(k) = \mathcal{F}\{y(t)\} \\ = X(k) \cdot e^{-\frac{j2\pi k\tau}{N}} + W(k), k = 0, 1, \dots, N \quad (3)$$

其中 $X(k)$ 、 $W(k)$ 、 $Y(k)$ 分别为发送信号 $x(t)$ 、加性高斯白噪声 $w(t)$ 、接收信号 $y(t)$ 的离散傅里叶变换， k 为频域子载波索引， N 为FFT点数。由式(3)可知，时延 τ 对频域信号的影响体现为相位偏转。根据发送端导频放置位置将导频数据提取后，接收端导频信号 $Y_p(k)$ 表示为：

$$Y_p(k) = X_p(k) \cdot e^{-\frac{j2\pi k\tau}{N}} + W(k) \quad (4)$$

基于最小二乘准则，导频位置的信道响应估计值为：

$$H_{p,LS}(k) = \frac{Y_p(k)}{X_p(k)}, k = 0, 2, 4, \dots, N \quad (5)$$

由计算公式可知，由于LS算法并没有考虑噪声项 $W(k)$ 的影响，其在较低信噪比条件下估计误差显著增大，导致性能恶化。为了抑制噪声影响，可采用线性最小均方误差估计，其公式为：

$$H_{p,LMMSE} = R_{HH} \left(R_{HH} + \frac{\beta}{SNR} I \right)^{-1} H_{p,LS} \quad (6)$$

其中 β 为与调制星座尺寸相关的常数（如QPSK时 $\beta=1$ ）， SNR 为信噪比， I 为单位矩阵， R_{HH} 为真实信道响应 H 的自协方差矩阵。由于LMMSE算法需要已知真实信道的统计特性 H ，而实际NTN环境中时变信道难以实时获取此信息。因此，为规避LMMSE的统计依赖性，设计频域导频响应分块合并方法。将接收端得到的信道响应 $H_p(k)$ 在频域上分为 m 个长度为 L 的块 $H_p^1(k_1), \dots, H_p^m(k_m)$ ，将每个块内信道响应求均值，并进行线性插值，则第 n 个块内信道响应为：

$$\bar{H}_p^n = \frac{\sum_{k_n=0}^{L-1} H_p^n(k_n)}{L} \quad (7)$$

将式(7)中分子进行展开可得：

$$\sum_{k_n=0}^{L-1} H_p^n(k_n) = \sum_{k_n=0}^{L-1} e^{-\frac{j2\pi k_n \tau}{N}} + \sum_{k_n=0}^{L-1} \frac{W(k_n)}{S_p(k_n)} \quad (8)$$

考虑式(8)中第二项中噪声为高斯白噪声，均值为0，方差为 σ^2 ，通过将相邻导频处的信道响应合并求平均的操作达到均值滤波的效果，同时一定程度上增大频域块大小 L ，可以进一步降低噪声的影响。考虑式(8)中第一项中影响，将该项中指数级数展开可得：

$$\sum_{k_n=0}^{L-1} e^{-\frac{j2\pi k_n \tau}{N}} = \frac{e^{-\frac{j2\pi L \tau}{N}} - 1}{e^{-\frac{j2\pi \tau}{N}} - 1} \quad (9)$$

由式 (9) 可知, 当 $L\tau = a$, a 为正整数时, 该项为 0, 即块内的导频处信道特性被抹除。同时当时延 τ 较大时, 增大 L 会导致块内导频处的信道响应特性被抹平, 导致在信道均衡时由于时延 τ 在频域信号上产生的相位偏转无法补偿。具体仿真结果表明, 当合并数小于等于 8 时, 合并操作在抵抗噪声的同时, 对信道响应的抹平效应较弱, 时延引起的相位偏转尚未显著恶化性能; 合并数小于 8 时, 较大的合并块会过度抹平信道响应的时变特性, 导致频域信号相位偏转无法补偿, BER 性能显著下降 (损失超过 3 dB)。

2 基于 DNN 的信道估计合并数最优映射

2.1 深度神经网络基本结构

深度神经网络在 LEO 通信系统中已得到较为广泛的应用。由式 (7) ~ 式 (9) 可以知, 当时延较小时, 增大信道估计合并数可以有效抵抗噪声对信道估计影响。但当时延较大时, 过大的信道估计合并数会将信道响应特性抹平, 对信道估计性能产生负优化。同时考虑低轨卫星星地链路间高动态的时延变化, 可以将该问题抽象为均衡不同时延、噪声下信道估计合并数的分类优化问题。整体步骤如下所示:

步骤 1. 在本地搭建全连接深度神经网络, 输入层为经过数据预处理后的 LS 信道估计向量。合理假设系统带宽为 400MHz, 子载波带宽 120kHz, 因此定义可用子载波总数 N_{sub} 为 3168, 导频频域密度 D_p 为 2, 根据导频子载波计算公式 $N_p = \frac{N_{sub}}{D_p}$, 可得导频所占子载波数 N_p 为 1584。

将接收的导频取出并与本地导频相除得到导频处的 LS 信道估计结果, 此处数据长度为 N_p 。此时将复数数据做实数化处理, 按照实部、虚部间隔放置的方式对数据重构, 处理结束后数据长度为 N_{sub} 。

隐藏层采用递减式神经元数量 (512、256、128) 形成金字塔结构, 符合特征分层提取的逻辑。

第一层 512 个神经元接收输入, 通过较多神经元捕捉原始信道响应中的基础特征 (噪声分布与时延)。

第二层 256 个神经元通过减少神经元数量压缩特征空间, 提取更抽象的中层特征 (噪声与时延的联合影响)。

第三层 128 个神经元进一步降维, 聚焦核心特征 (如最优合并数对应的时延 - 噪声映射关系), 为输出层提供紧凑的决策依据。该结构避免了全连接层直接从高维输入映射到低维输出可能导致的信息丢失, 同时通过逐层降维降低计算复杂度, 防止过拟合。输出层为最优合并数, 维度为 1×1 。

步骤 2. 在本地通过仿真不同时延、噪声组合下误码率最小的信道估计合并数, 并记录当前接收端 LS 信道估计矩阵。其中最佳合并数定义为在特定时延与噪声条件下, 使误码率 (BER) 最小的分块合并数。其核心作用是平衡噪声抑制 (大合并数) 与时延鲁棒性 (小合并数) 的矛盾。在训练数据集的选取中, 采用多样场景数据采样与扩充策略。采用网格搜索与随机采样结合的方式, 在时延-信噪比二维空间中均匀选取 20000 个场景点 (时延每 0.01us、信噪比每 1dB 取点), 每个场景生成 1 条样本, 确保数据集覆盖信道条件的多样性。对部分低概率场景 (如高时延+低信噪比) 通过添加微小噪声扰动、相位偏移等方式扩充样本, 避免模型对罕见场景过拟合。

步骤 3. 将训练好的 DNN 布置在接收端信道估计模块, 将添加噪声与动态随机时延的接收端信道估计矩阵经过数据预处理后输入至 DNN 中, 通过迭代得到最优合并数。

基于 DNN 的信道估计合并数与信噪比、时延映射算法框图如图 2 所示。

本文在仿真时在信道中除添加高斯白噪声外, 添加符合正态分布均值为 \bar{x}_{delay} , 方差为 σ_{delay}^2 的动态随机时延。下面对具体流程进行详细解释。

将式 (5) 中 LS 信道估计结果经过数据预处理输入至 DNN 输入层, 数据预处理主要是将 IQ 复数数据实部虚部拆分为实数数据, 即实部与虚部间隔放置将 $1 \times N$ 的向量扩展为 $1 \times 2N$, 同时进行特征标准化的过程, 如式 (10) 所示:

$$\mathbf{a} = \frac{\mathbf{H}_{LS}^r - \mu}{\sigma} \quad (10)$$

其中 \mathbf{H}_{LS}^r 为式 (5) 中 LS 信道估计结果 $H_{p,LS}(k)$ 实数化处理后的向量, μ 为实数化处理后的均值, σ 为其标准差, \mathbf{a} 为 DNN 输入层输入向量。其激活函数如式 (11) 所示:

$$\begin{aligned} \mathbf{a}^{[l]} &= \text{ReLU}(\mathbf{W}^{[l]}\mathbf{a}^{[l-1]} + \mathbf{b}^{[l]}) \\ &= \max \{ 0, \mathbf{W}^{[l]}\mathbf{a}^{[l-1]} + \mathbf{b}^{[l]} \} \end{aligned} \quad (11)$$

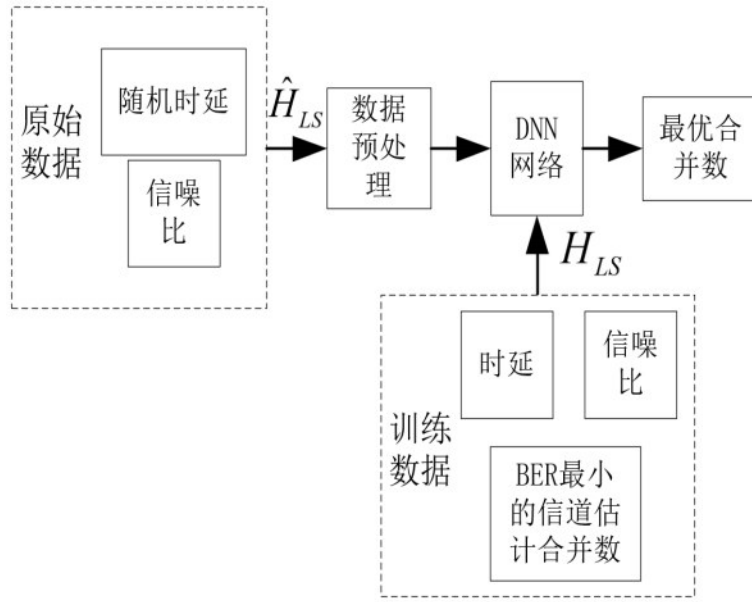


图2 基于DNN的信道估计合并数动态映射算法框图

其中 \mathbf{a}^{l1} 为第 l 层得到的激活函数输出值， \mathbf{W}^{l1} 为第 l 层的权重值， \mathbf{b}^{l1} 为第 l 层的偏置项。输出层的 Softmax 函数如式 (12) 所示：

$$\hat{y}_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}, \mathbf{z} = \mathbf{W}^{l1} \mathbf{a}^{l1} + \mathbf{b}^{l1} \quad (12)$$

其中 \hat{y}_i 为 Softmax 函数归一化后概率分布结果， K 为任务中的类别总数。下面进行损失函数的计算，在分类任务中大多采用交叉熵可以在梯度下降的过程中避免学习率降低的问题，损失函数如式 (13) 所示：

$$\mathbf{J} = -\frac{1}{m} \sum_{i=1}^m \sum_{k=1}^K y_k^{(i)} \log(\hat{y}_k^{(i)}) \quad (13)$$

其中 m 为参与损失计算的样本总数， $y_k^{(i)}$ 表示正确标签， $\hat{y}_k^{(i)}$ 表示预测标签。下面进行反向传播与参数更新。由于损失函数为凸函数，难以通过解析方法求得全局最优解，因此训练过程中一般依赖优化器，通过迭代的方式不断调整模型参数来求得最优解。Adam 优化器作为一种融合动量机制和自适应学习率的参数更新算法，能够根据梯度的一阶矩和二阶矩估计动态调整各参数的学习率，具有较强的鲁棒性，其数学表示如式 (14) 所示：

$$\begin{aligned} m_k &= \beta_1 m_{k-1} + (1 - \beta_1) g \\ v_k &= \beta_2 v_{k-1} + (1 - \beta_2) g^2 \\ \hat{m}_k &= \frac{m_k}{1 - \beta_1^k}, \hat{v}_k = \frac{v_k}{1 - \beta_2^k} \\ \theta_k &= \theta_{k-1} - \frac{\eta}{\sqrt{\hat{v}_k} + \epsilon} \hat{m}_k \\ \beta_1^k &= \beta_1 \cdot \beta_1 \dots \beta_1, \beta_2^k = \beta_2 \cdot \beta_2 \dots \beta_2 \end{aligned} \quad (14)$$

其中 m_k 和 v_k 分别为梯度的一阶矩和二阶矩估计； β_1 和 β_2 是控制矩估计的指数衰减率，一般设为 0.9 和 0.999； \hat{m}_k 和 \hat{v}_k 为修正值； ϵ 为非常小的数，防止除零； k 是当前迭代次数，用于做偏差矫正； θ_k 为第 k 次迭代模型的参数。通过链式法则计算反向传播的权重更新公式如式 (15) 所示：

$$\begin{aligned} \mathbf{W}^{l1} &= \mathbf{W}^{l1} - \alpha \frac{\partial \mathbf{J}}{\partial \mathbf{W}^{l1}} \\ \mathbf{b}^{l1} &= \mathbf{b}^{l1} - \alpha \frac{\partial \mathbf{J}}{\partial \mathbf{b}^{l1}} \end{aligned} \quad (15)$$

其中 α 为学习率，根据上面 Adam 优化算法可通过学习率 α 调整梯度步长，使参数逐步收敛到最优值。

2.2 DNN 训练数据集

图 2 中 DNN 网络模型的训练、验证与测试数据生成步骤如下：

步骤 1. 首先仿真固定时延与信噪比下不同合并数的误码率曲线，得到固定时延与信噪比组合的特殊情况下误码率最小的合并数；

步骤2. 更换若干个时延与信噪比组合，并记录不同时延与信噪比组合情况下接收端LS算法得到的信道估计矩阵以及误码率最小情况下的合并数；

步骤3. 将前两步中获得的信道估计矩阵与合并数分组为训练数据与验证数据，输入深度神经网络中进行训练与验证。

本文针对LEO场景下NTN信道进行业务信道解调性能的仿真。一般来说，LEO场景的通信时延为毫秒级别。但本文主要针对业务信道的解调性能，所以在仿真中添加的时延是考虑在完成初始时频同步后的残余时延。文章根据文献[3]与[4]中低轨卫星NTN信道的适用参数进行仿真，其中文献[3]分析了当业务信道的残余时延超过0.3us时，会导致较大的性能衰减；文献[4]仿真所使用一般低轨卫星LEO场景下，具体参数为FR2频段、子载波间隔120kHz。业务信道解调信噪比设置在0~20dB范围内。具有一定的LEO场景适用性。因此在信道中添加0~0.3us动态随机时延与3~20dB信噪比进行链路级仿真。通过对比最低误码率，本文共构建20000条数据集，每条数据集包括维度为1×3168的LS信道估计向量与维度1×1的信道估计最优合并数。按照3:1:1的比例对训练数据集、验证数据集和测试数据集进行划分。

3 仿真测试与结论

链路级仿真平台完成深度神经网络训练数据生成与信道解调性能的仿真，输出解调BER曲线，主要包括：数据生成、信道编码、加扰、调制、转换预编码、资源映射、OFDM调制、信道、时频同步、解OFDM、信道估计、解资源映射、软解调、解扰、信道解码等模块。深度神经网络训练平台根据训练数据集对完成模型的训练与模型生成，主要包括：书数据预处理、DNN网络架构定义与连接、训练参数配置与执行、模型评估与性能验证等模块。

针对传统的信道估计算法、文献[30]中基于神经网络的信道估计算法以及本文算法进行仿真。仿真设置信道环境为理想加性高斯白噪声（AWGN, Additive white Gaussian noise）信道和添加动态随机时延后信道，对比不同算法的误码率（BER, bit error rate）性能曲线和均方误差（MSE, mean squared error）曲线。仿真中低轨卫星OFDM系统

采用实验参数如表1所示：

表1 低轨卫星OFDM系统仿真参数表

参数	参数值设置
载频	20GHz
系统带宽	400MHz
子载波带宽	120kHz
FFT点数	4096
采样频率	491.52MHz
符号内可用子载波数	3168
调制方式	16QAM
码率	0.33203125
编码方式	LDPC
子帧内时隙数	8
时隙内符号数	12
导频时域放置位置	2、5、8
导频频域密度	2
信道估计合并数	1~48
信道	AWGN
随机时延模型	0~0.3us 动态随机时延

仿真中DNN网络训练数据集说明见2.2小节，具体所采用实验参数如表2所示：

表2 DNN仿真参数表

参数	参数值设置
训练数据集个数	12000
验证数据集个数	4000
测试数据集个数	4000
学习率	0.0003
优化器	Adam
激活函数	ReLU、Softmax
训练次数	1000
输入维度	1×3168
输出维度	1×1
隐藏层层数	3
输入神经元数量	3168
输出神经元数量	1
隐藏层神经元数量	512、256、128

首先针对本文第二章中基于分块合并的LS信道估计算法与本文算法进行仿真对比，仿真图如图3所示。由图3可知，在理想AWGN信道下，忽略时延影响，随着信道估计分块合并数的增加，误码率性能得到显著提升，此时本文算法与合并数最高为48时的性能相近，相较于不合并时解调性能提升约4.5dB。

此时将仿真条件中加入动态随机时延模型，在

信道模块添加0~0.3 μ s的动态随机时延，仿真结果如图4所示。由图4可知，添加动态随机时延后，随着合并数的增加，误码率性能出现先增后降的现象，与本文第二章中分析结果相符合，即合并数增

加会导致信道估计响应的抹平从而扩大时延因素对解调性能的影响。其中当合并数超过8后，性能损失较为严重。而本文算法综合考虑时延与噪声影响，相较于不合并时解调性能提升1.5dB左右。




图3 AWGN信道不同合并数下SNR-BER曲线

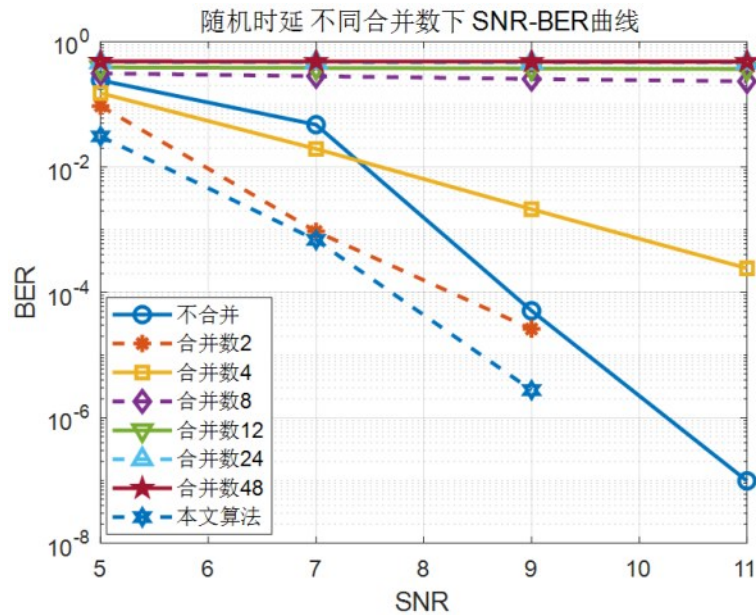


图4 动态随机时延不同合并数下SNR-BER曲线

下面仿真设置四种对比算法，对比LS、LMMSE、文献[30]中现有神经网络算法与本文算法在AWGN信道以及动态随机时延信道下误码率与均方误差，结果如图6~8所示。在AWGN信道下，不考虑时延，此时真实信道响应矩阵约等于全1矩阵，因此LMMSE算法性能为理想情况性能。

由图5可知，本文算法在AWGN信道下对比LS算法解调性能提升4.5dB左右，对比文献[30]算法解调性能提升0.5dB左右，与理想情况下LMMSE算法性能较为接近，性能损失在0.5dB以内。

添加动态随机时延后，真实信道响应矩阵随时延改变，而接收端无法获取准确的真实信道响应矩

阵，此时由图6可知，本文算法在随机时延下不同信噪比的解调误码率均低于其他三种算法。由图7可知，本文算法在不同信噪比下相较于其他算法有更低的MSE。信噪比5dB时本文算法性能相较LS

提升58.26%，相较LMMSE算法提升3.97%，相较文献[30]中算法提升37.06%，证明本文算法在不同噪声与动态时延信道下具有更强的泛化性。

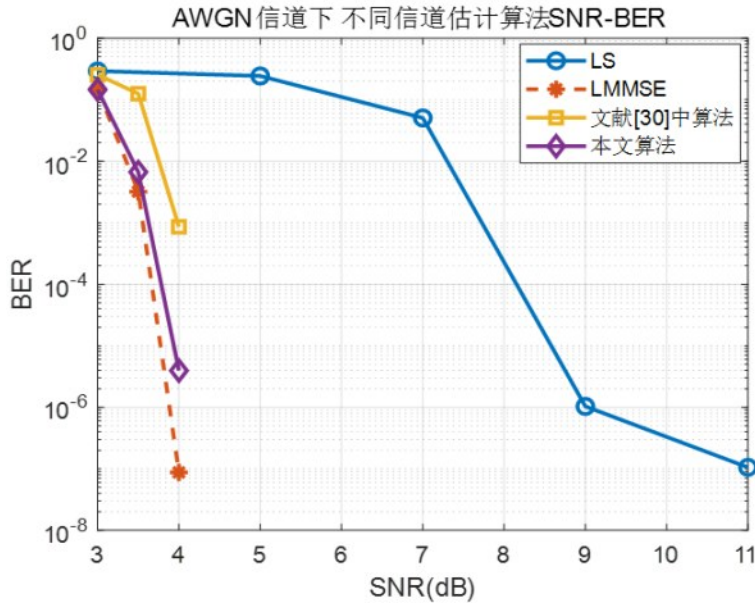


图5 AWGN信道下不同信道估计算法SNR-BER曲线




图6 随机时延下各种信道估计算法的SNR-BER曲线

仿真结果表明，在理想AWGN信道条件下，信道估计分块合并数越大误码率性能越优（最大提升4.5dB）；动态时延信道中，合并数≤8时性能提升（最大1.5dB）、>8时性能损失超3dB，体现噪声抑制与时延鲁棒性的矛盾。本文算法在3~20dB信噪比及0~0.3us动态时延内，误码率和均方误差优

于传统及神经网络算法。此外，该算法总参数约210万，单次计算量 3.57×10^8 次浮点运算，计算延迟0.357ms（远低于LMMSE算法的21.2ms），适配卫星载荷算力，便于工程实现。仿真结论与计算开销综合可得，在工程应用中，低信噪比（<8dB）且时延<0.1us时选6~8合并数，高信噪比（≥8dB）

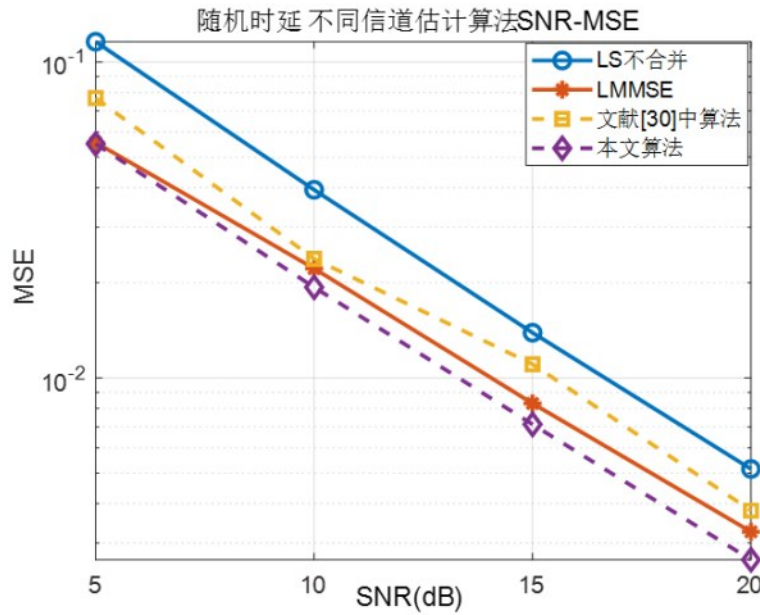


图7 随机时延下各种信道估计算法的SNR-MSE曲线

或时延 $>0.2\mu\text{s}$ 时选2~4合并数，动态时延剧烈波动时启用DNN动态映射。在算力受限场景下，可通过模型轻量化平衡算力与性能，将隐藏层神经元数量压缩至256-128-64（参数降至80万），计算量减少60%且性能损失 $<0.3\text{dB}$ ；非高动态时段可延长DNN推理间隔至10ms，高动态时段缩短至1ms，在开销与响应速度间取得平衡。

4 结束语

针对低轨卫星高动态时延与低信噪比的信道环境下的可靠性传输问题，本文提出一种基于深度神经网络与导频信道响应分块合并的信道估计算法。本文的创新点在于首次将深度神经网络应用于低轨卫星通信的信道估计合并数优化问题。算法同时考虑噪声与动态时延的影响，将合并数优化问题转化为分类优化问题，利用DNN的非线性建模与特征提取能力，实现时延和噪声场景下合并数的自适应映射。仿真结果表明，该算法具有良好的泛化性。然而，本研究聚焦于时延与噪声双因素优化，未涵盖低轨卫星信道中其他关键干扰因素如阴影效应、多普勒频偏、多用户干扰以及相位噪声等。后续研究需扩展信道模型，引入上述因素的联合优化机制，并探索多任务DNN架构（联合优化合并数、时偏补偿与干扰抑制）及跨场景迁移学习方法，以提升算法在复杂信道条件下的普适性。

参考文献：

- [1] 苏昭阳,刘留,艾渤,等. 面向低轨卫星的星地信道模型综述[J]. 电子与信息学报,2024,46(05):1684-1702.
SU Z Y, LIU L, AI B, et al. Survey of satellite-terrestrial channel modeling for low earth orbit satellites[J]. Journal of Electronics & Information Technology, 2024, 46(05): 1684-1702.
- [2] 张更新,廖磊瑶,何元智. 面向空地海一体化的卫星通信关键技术研究[J]. 电信科学,2024,40(06):11-24.
ZHANG G X, LIAO L Y, HE Y Z. Research on key technologies of satellite communications for space-air-ground-sea integration [J]. Telecommunications Science, 2024, 40(06): 11-24.
- [3] H. ZHAO, Y. ZHANG, K. WEI, et al. Channel estimation for 5G non-terrestrial[C]//Proceedings of 2024 5th Information Communication Technologies Conference (ICTC). Nanjing, China: IEEE, 2024: 210-215.
- [4] W-Y. YEO, D-J. LEE, et al. Uplink time synchronization based on time drift measurements in non-terrestrial networks[J]. IEEE Access, 2024, 12: 168877-168893.
- [5] X. HUANG, L. CHEN, X. CHEN, et al. Wireless channel estimation and equalization based on deep learning[C]//Proceedings of 2024 10th IEEE International Conference on Intelligent Data and Security (IDS). NYC, NY, USA: IEEE, 2024: 47-52.
- [6] H. FENG, Y. XU, Y. ZHAO, et al. Deep learning-based joint channel estimation and CSI feedback for RIS-assisted communications [J]. IEEE Communications Letters, 2024, 28(8): 1860-1864.
- [7] S. YALLAPU, S. P. K. R. S, et al. Robust channel estimation and performance evaluation of OFDM through AWGN channel[C]// Proceedings of 2024 2nd International Conference on Device Intelligence, Computing and Communication Technologies

- (DICCT). Dehradun, India: IEEE, 2024: 514-517.
- [8] Z. HUANG, D. HE, Z. WANG, et al. Two-stage LMMSE/DNN receiver for high-order modulation[J]. *IEEE Communications Letters*, 2023, 27(8): 2068-2072.
- [9] R. A. S. P. M., KULKARNI K. 5G Channel Estimation for Downlink SISO Channels Using Convolutional Neural Networks[C]//2025 International Conference on Intelligent and Innovative Technologies in Computing, Electrical and Electronics (IITCEE). Bangalore: India, 2025:1-5.
- [10] 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(01):36-42.
- WANG Y Y, CHANG J, LU Z K, et al. Deep learning-assisted channel estimation for 5G OFDM systems[J]. *Telecommunications Technology*, 2024, 64(01): 36-42.
- [11] A. AMROUCHE. DNN-based Arabic printed characters classification[C]//Proceedings of 2024 2nd International Conference on Electrical Engineering and Automatic Control (ICEEAC). Setif, Algeria: IEEE, 2024: 1-5.
- [12] D. CUI, G. SUN, X. ZHAN, et al. Dangerous behavior image recognition algorithm of smart port based on deep neural network [C]//Proceedings of 2023 9th Annual International Conference on Network and Information Systems for Computers (ICNISC). Wuhan, China: IEEE, 2023: 94-98.
- [13] MATOS J B P, LIMA FILHO E B, BESSA I, et al. Counterexample guided neural network quantization refinement[J]. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 2024, 43(4): 1121-1134.
- [14] CHENG Q, HU X, XIAO H, ZHOU Y, DUAN S. High-Performance Method and Architecture for Attention Computation in DNN Inference[J]. *IEEE Transactions on Biomedical Circuits and Systems*, 2025, 19(2):404-415.
- [15] LEE S, KIM J, KIM Y. Accuracy Performance Analysis of Quantized DNN Models Using Approximate 4-2 Compressor Based Multipliers[C]//2025 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC). Fukuoka: Japan, 2025:1031-1033.
- [16] B. R. SRI, T. S. BALAKRISHNAN. Classification of pests in agricultural farms using convolutional neural network compared to artificial neural network[C]//Proceedings of 2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT). Kamand, India: IEEE, 2024: 1-4.
- [17] QIAO Y, TENG S, LUO J, SUN P, LI F, TANG F. On-Orbit DNN Distributed Inference for Remote Sensing Images in Satellite Internet of Things[J]. *IEEE Internet of Things Journal*, 2025, 12(5): 5687-5703.
- [18] WANG Q, CHEN S, YANG C, LI Z, WANG Y, CHEN T. Minimizing Energy and Latency in LEOS-Assisted Open RAN Architecture Toward AI of Things[J]. *IEEE Internet of Things Journal*, 2025, 12(11): 16813-16828.
- [19] A. ALATAWI, H. R. SADJADPOUR, Z. REZKI, et al. Adaptive deep neural network for non-stationary wireless channels[C]//Proceedings of 2024 11th International Conference on Wireless Networks and Mobile Communications (WINCOM). Leeds, UK: IEEE, 2024: 1-6.
- [20] M. B. M., V. MALATHY, J. KAUR, et al. Exponential linear unit and Swish with deep neural network based resource allocation in wireless communication systems[C]//Proceedings of 2024 International Conference on Distributed Systems, Computer Networks and Cybersecurity (ICDSCNC). Bengaluru, India: IEEE, 2024: 1-5.
- [21] M. PALESI, E. RUSSO, A. DAS, et al. Wireless enabled inter-chiplet communication in DNN hardware accelerators[C]//Proceedings of 2023 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW). St. Petersburg, FL, USA: IEEE, 2023: 477-483.
- [22] WANG Q, et al. Energy-Efficient Resource Allocation in LEO-Assisted UAV Architecture for Internet of Things[J]. *IEEE Internet of Things Journal*, 2025, 12(8):9614-9626.
- [23] I. VAJS, P. IVANIŠ, D. DRAJIĆ, et al. CNN and LSTM neural networks for spectral efficiency improvements in LEO satellite networks[C]//Proceedings of 2024 32nd Telecommunications Forum (TELFOR). Belgrade, Serbia: IEEE, 2024: 1-4.
- [24] Y. WU, et al. MP-DPD: Low-complexity mixed-precision neural networks for energy-efficient digital predistortion of wideband power amplifiers[J]. *IEEE Microwave and Wireless Technology Letters*, 2024, 34(6): 817-820.
- [25] R. R. V. S. S. BHARATTEJ, et al. Application of computer software in chemical data processing using spider monkey optimization algorithm[C]//Proceedings of 2024 Second International Conference on Networks, Multimedia and Information Technology (NMITCON). Bengaluru, India: IEEE, 2024: 1-4.
- [26] GUPTA H, SRIVASTAVA N, BORMAN L. AI-Based Handover Decision Algorithm for Conditional Handover in Non-Terrestrial Networks (NTNs)[C]//2025 International Conference on Computing, Networking and Communications (ICNC). Honolulu: USA, 2025:128-132.
- [27] M. CARRATÙ, S. D. IACONO, G. DI LEO, et al. Smart water meter based on deep neural network and undersampling for PWNC detection[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1002211.
- [28] M. AL-FAROUNI, B. PANDURI, M. A. ALKHAFIJI, et al. Comparative approach on machine learning and deep learning techniques based diabetic retinopathy detection[C]//Proceedings of 2024 Second International Conference on Networks, Multimedia and Information Technology (NMITCON). Bengaluru, India: IEEE, 2024: 1-5.
- [29] A. K. GIZZINI, M. CHAFIL, A. NIMR, et al. Enhancing least square channel estimation using deep learning[C]//Proceedings of 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring). Antwerp, Belgium: IEEE, 2020: 1-5.

- [30] R. ONISHI, T. SATO, T. IDE, et al. An evaluation of channel estimation method using deep learning for OFDM system[C]//Proceedings of 2024 Fifteenth International Conference on Ubiquitous and Future Networks (ICUFN). Budapest, Hungary: IEEE, 2024: 50-54.