

DOI:10. 20079/j. issn. 1001-893x. 220721003

一种模型驱动的深度学习的 OFDM 接收机*

刘 檬, 卢 敏, 胡 娟, 李卓敏

(江西理工大学 理学院, 江西 赣州 341000)

摘 要:针对正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)接收机解调精度低和计算复杂度高的问题,采用深度学习方法构建了一种新的模型驱动的接收机模型,称为 FBLTNet (Fully Connected, Bi-LSTM and Transformer-encoder Neural Network)。该模型分为信道估计和信号检测两个部分,其中信道估计以全连接神经网络(Fully Connected Deep Neural Network, FCDNN)替代线性插值,信号检测则使用深度自注意力网络编码器 Transformer-encoder 和双向长短期记忆网络(Bidirectional Long-Short Term Memory, Bi-LSTM)的组合网络,实现信号的解调和比特流的恢复。在瑞利衰落信道下测试了不同调制方式的接收机性能,结果表明 FBLTNet 与基于深度学习的接收机以及传统接收机相比,误比特率性能得到了显著的改善;与数据驱动的无线接收机算法相比,线下训练模型收敛时间和测试时间分别减少了 33.0% 和 25%,网络结构参数减少了 29.5%。

关键词:OFDM 接收机;模型驱动;深度学习;MMSE 信号检测

开放科学(资源服务)标识码(OSID):  微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN85;TP391 文献标志码:A 文章编号:1001-893X(2024)02-0192-08

A Model-driven OFDM Receiver Based on Deep Learning

LIU Meng, LU Min, HU Juan, LI Zhuomin

(College of Science, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract:To overcome the problems of low demodulation precision and high computational complexity in the orthogonal frequency division multiplexing (OFDM) wireless receiver, a new model-driven OFDM receiver model named FBLTNet (Fully Connected, Bi-LSTM and Transformer-encoder Neural Network) including channel estimation and signal detection is proposed on the deep learning technology. Fully Connected Deep Neural Network (FCDNN) is applied to replace linear interpolation in the channel estimation. In the signal detection part, the combination of Transformer-encoder and Bidirectional Long Short Term Memory (Bi-LSTM) is applied to achieve signal demodulation and bit stream recovery. The receiver performance in different modulation modes is tested in the Rayleigh fading channel. Simulation results show that the FBLTNet achieves a significant improvement performance in the bit rate compared with the deep learning based receivers as well as the conventional receivers. Compared with the data-driven wireless receiver algorithm, the offline training model has better performance by reducing the convergence time, testing time and network parameters 33.0%, 25% and 29.5%, respectively.

Key words:OFDM receiver; model-driven; deep learning; MMSE signal detection

* 收稿日期:2022-07-21;修回日期:2022-09-24
基金项目:国家自然科学基金重点项目(U19B2015)
通信作者:卢敏 Email:9119860019@jxust.edu.cn

0 引言

正交频分复用 (Orthogonal Frequency Division Multiplexing, OFDM) 技术因其优异的性能被用于无线通信标准^[1],但传统的 OFDM 系统依赖于数学模型,而复杂的信道环境很难用数学公式表达。

近几年,深度学习 (Deep Learning, DL) 方法因具有很强的非线性能力,能够较好地解决通信系统中描述不准确的问题,在通信系统中得到了广泛的应用,包括信号辨识^[2]、信道估计^[3]、信道解码^[4]、信号解调^[5-8]等方面。文献[9]提出以神经网络构建端到端的通信系统,解决了传统算法不能实现全局优化的问题,但该方法需要同时训练发送端和接收端,训练难度较大。文献[10-11]针对训练难度大的问题,提出了数据驱动的方法,采用全连接神经网络和卷积神经网络实现信息接收。此方法结构简单,误比特率性能较佳,但需要大量的训练数据样本且时间和空间复杂度高。为了降低模型复杂度,文献[12-13]提出了一种模型驱动的接收机,其结合无线通信领域的专家知识,通过传统算法初始化神经网络输入,极大地提升训练效率,减小数据依赖,降低接收机整体复杂度,但是在复杂信道下接收机的抗噪声性能有待提高。

基于以上分析,针对深度学习的 OFDM 接收机网络参数大、收敛速度慢、计算复杂度高的问题,本文采用深度学习方法,结合专家知识和多种神经网络,构建一种模型驱动的无线接收机模型,即 FBLTNet (Fully Connected, Bi-LSTM and Transformer-

encoder Neural Network)。该接收机分为信道估计和信道检测两个模块,以最小二乘 (Least Squares, LS) 信道估计算法和最小均方误差估计 (Minimum Mean Square Error, MMSE) 信号检测算法初始化神经网络的输入,使得模型的输入具有物理意义,降低模型的复杂度以及提高解调性能。在信道估计模块中,以全连接神经网络 (Fully Connected Deep Neural Network) 替代线性插值部分,实现信道状态信息 (Channel State Information, CSI) 的估计。在信号检测模块,由深度自注意力网络编码器 (Transformer-encoder)^[14]与双向长短期记忆网络 (Bidirectional Long Short Term Memory, Bi-LSTM)^[15]组合的网络实现信号比特流的恢复。

本文将从噪比性能、调制方式、导频数量、循环前缀角度,对比分析 FBLTNet 接收机、传统接收机和现有的深度学习接收机。

1 系统模型

OFDM 无线通信系统包括发射机、信道和接收机,如图 1 所示。系统发射端将输入的二进制数据序列调制为发射符号序列,插入导频符号形成完整的 OFDM 发送符号,符号经过离散傅里叶逆变换 (Inverse Discrete Fourier Transformation, IDFT) 转换为时域信号,接着加入循环前缀 (Cyclic Prefix, CP),以减轻由无线信道的延迟扩展引起的符号间干扰 (Inter-symbol Interference, ISI),形成完整的时域 OFDM 信号。




图 1 OFDM 无线通信系统
Fig. 1 OFDM wireless communication system

OFDM 接收机中,由于信号在传输过程中,发送和接收是异步的,即可能出现发射端的信号在接收端收不到或者接收不完全的情况。为了使得数据能够正常工作,不破坏子载波之间的正交性,接收端在

快速傅里叶变换 (Fast Fourier Transformation, FFT) 变换之前,发射机和接收机必须进行同步操作,之后去除 CP,然后再执行 FFT 变换,将接收信号 $Y(k)$ 表示为第 k 个子载波的接收信号,接着进行信道估计、

信号检测和星座映射解调。

信号通过一个频率选择性衰落多径信道的脉冲响应表示为

$$h_i=\sum_{i=1}^Mh(i)\delta(t-\tau_i)\tag{1}$$

式中: M 为多径条数; τ_i 为第 i 路信号的时延; $h(i)$ 为第 i 路信号的幅度衰减因子。在符号正确同步的情况下,接收端的采样信号为

$$r(nT_s)=\sum_{i=1}^Mh_i(nT_s)s(nT_s-\tau_i)+n(nT_s)\tag{2}$$

式中: T_s 为采样周期; $n(nT_s)$ 为采样的高斯白噪声。当用循环卷积代替信号与信道的线性卷积时,对接收到的信号做快速傅里叶变换后解调出的频域信号为

$$Y_{i,k}=X_{i,k}*H_{i,k}+w_{i,k}\tag{3}$$

式中: $*$ 表示卷积; $H_{i,k}$ 为第 i 个符号在第 k 个子载波处的信道频率响应; $w_{i,k}$ 是均值为 0、方差为 σ_n^2 的高斯白噪声样本值。则第 k 个子载波的接收导频和数据信号可以表示为

$$\begin{cases} Y_{i,k}(P)=X_{i,k}(P)*H_{i,k}+w_{i,k} \\ Y_{i,k}(D)=X_{i,k}(D)*H_{i,k}+w_{i,k} \end{cases}\tag{4}$$

式中: $X_{i,k}(P)$ 和 $X_{i,k}(D)$ 分别表示第 k 个子载波中的导频和发射符号。 $X_{i,k}(P)$ 在接收端是已知的,用于信道估计,而 $X_{i,k}(D)$ 在接收端是未知的,需要根据接收到信号和估计信道进行检测。

基于人工智能(Artificial Intelligence, AI) 的接收机,用神经网络取代传统接收器中的信道估计和信号检测,将大量的无线信号作为神经网络的输入,比特流信号作为输出,通过随机梯度下降算法训练所有参数。下面将详细介绍本文提出的 FBLTNet 接收机。

2 接收机设计

2.1 FBLTNet 接收机

将接收端接收到的时域信号 $Y_D \in \mathbb{C}^{M \times N}$, 经过信道的导频 $Y_p \in \mathbb{C}$ 和接收端已知的原始导频 $X_p \in \mathbb{C}$ 作为输入数据,通过所提出的 FBLTNet 接收机获得恢复的比特流信号,其数据流如图 2 所示。




图 2 FBLNet 接收机数据流图

Fig. 2 Data flow diagram of FBLNet receiver

2.1.1 信道估计

信道估计的作用是估计出信道状态信息矩阵。导频辅助信道估计采用 LS 算法,通过利用导频估计导频位置的信道响应,表示为

$$H_{LS}=Y_p/X_p,H_{LS} \in \mathbb{C}^{M \times N}\tag{5}$$

再通过插值方法得到整个信道的状态信息,即信道估计系数矩阵 $\hat{H}$ 。在本文中,则采用全连接神经网络替代传统信道估计算法中的插值部分,由一个特征空间线性变换到另一个特征空间的特性,将导频的信道响应映射到整个信道响应。该网络结构称为信道估计神经网络,简称 CE 网络,如图 3 所示。导频处估计的信道响应 H_{LS} 矩阵是复数类型,但目前深度学习不支持直接处理复数,需要将 H_{LS} 提取复数的实部和虚部分别作为两列向量矩阵,于是 CE 网络的输入数据变成 $H_{LS}' \in \mathbb{R}^{M \times 2N}$,输出信道估计系数矩阵 $\hat{H} \in \mathbb{C}$,这将作为信号检测的一个输入。




图 3 信道估计网络

Fig. 3 Channel estimation network

2.1.2 信号检测

信号检测先利用传统检测算法初始化神经网络的输入,再通过信号检测神经网络(简称 SD 网络)恢复比特流信号,如图 4 所示。




图 4 信号检测网络结构数据流图

Fig. 4 Data flow diagram of signal detection network structure

本文中采用 MMSE 信号检测算法, 该算法以最小均方误差为准则, 最小化实际发送的符号和检测器输出估计值之间的均方误差, 解决宽带通信时的多径时延带来的码间串扰 ISI 问题。其原理是初始化的一个加权矩阵 $\bar{\mathbf{H}} = (\hat{\mathbf{H}}^H \hat{\mathbf{H}} + N_0 \mathbf{I})^{-1} \hat{\mathbf{H}}^H$, 其中, $N_0 = \sigma^2$ 表示接收端计算出的噪声统计信息, $\mathbf{I} \in \mathbb{C}$ 是 $\mathbf{Y}_D$ 的自相关矩阵, $\hat{\mathbf{H}} \in \mathbb{C}$ 是之前估计得到的信道矩阵, $\hat{\mathbf{H}}^H \in \mathbb{C}$ 指的是 $\hat{\mathbf{H}}$ 的转置矩阵。则输出的信号矩阵 $\mathbf{Y}_{\text{MMSE}} \in \mathbb{C}^{M \times N}$ 可表示为

$$\mathbf{Y}_{\text{MMSE}} = (\hat{\mathbf{H}}^H \hat{\mathbf{H}} + N_0 \mathbf{I})^{-1} \hat{\mathbf{H}}^H \mathbf{Y}_D \quad (6)$$

由于此时信号是复数信号, 在输入神经网络前提取 $\mathbf{Y}_{\text{MMSE}} \in \mathbb{C}^{M \times N}$, $\mathbf{Y}_D \in \mathbb{C}^{M \times N}$ 和 $\hat{\mathbf{H}} \in \mathbb{C}^{M \times N}$ 3 个复数特征矩阵复数的实部和虚部, 合并成 6 列的实数矩阵, 则 SD 网络的输入矩阵 $\mathbf{G} \in \mathbb{R}^{M \times 6N}$ 表示为

$$\mathbf{G} = \begin{bmatrix} \text{Re}\{\mathbf{Y}_D\} & \text{Re}\{\hat{\mathbf{H}}\} & \text{Re}\{\mathbf{Y}_{\text{MMSE}}\} \\ \text{Im}\{\mathbf{Y}_D\} & \text{Im}\{\hat{\mathbf{H}}\} & \text{Im}\{\mathbf{Y}_{\text{MMSE}}\} \end{bmatrix} \quad (7)$$

式中: $\text{Re}\{\cdot\}$ 表示取复数值的实部; $\text{Im}\{\cdot\}$ 表示取复数值的虚部。用 $\mathbf{W}_{\text{SD}}$ 表示 SD 子网权重, b_{SD} 表示该神经网络偏置, 则 SD 子网的输出 σ 表示为

$$\sigma = \mathbf{W}_{\text{SD}} \times \mathbf{G} + b_{\text{SD}} \quad (8)$$

2.2 信道估计网络

CE 网络由 3 层的批量归一化 (Batch Normalization) 和两层的全连接层 (Dense) 组成, 全连接层的神经元个数分别是 256 和 128; 采用 ReLU 激活函数; 网络结构见图 3。

Batch Normalization 的作用是使网络层的均值和方差不变, 保证了输入数据各个特征的分布相近, 训练过程中每次迭代都是相同的分布, 减少了网络去学习不同分布的时间, 加快神经网络的学习过程, 增强网络结构泛化性。用 $\mathbf{W}_{\text{CE}}$ 表示信道估计子网的权重, b_{CE} 表示神经网络的偏置, 则信道估计子网的输出 $\hat{\mathbf{H}}$ 为

$$\hat{\mathbf{H}} = \mathbf{W}_{\text{CE}} \times \begin{bmatrix} \text{Re}\{\mathbf{H}_{\text{LS}}\} \\ \text{Im}\{\mathbf{H}_{\text{LS}}\} \end{bmatrix} + b_{\text{CE}} \quad (9)$$

2.3 信号检测网络

SD 网络结构如图 4 所示, 由两个双向长短期记忆网络 (Bi-LSTM)、两个深度自注意力编码器网络 (Transformer-encoder) 及一个全连接网络组成。

2.3.1 Bi-LSTM

使用 ReLU 激活函数, 神经元个数 64, 主要用于

信号序列上下文的学习。Bi-LSTM 为两个单向 LSTM 网络的组合, 其中一个 LSTM 网络进行数据的正向预测, 另一个 LSTM 网络进行反向预测。LSTM 网络中有若干个 LSTM 单元, 每个单元由输入门 i_t 、遗忘门 f_t 、输出门 o_t 、记忆单元 c_t 和隐藏层矢量 l_t 组成, 并且每个单元参数共享, 即每个时间步上神经网络的参数都一样。则单个 LSTM 网络结构的数学描述如下:

$$i_t = \sigma(b_i + U_i x_t + W_i l_{t-1}) \quad (10)$$

$$f_t = \sigma(b_f + U_f x_t + W_f l_{t-1}) \quad (11)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \sigma(b_c + U_c x_t + W_c l_{t-1}) \quad (12)$$

$$o_t = \sigma(b_o + U_o x_t + W_o l_{t-1}) \quad (13)$$

$$l_t = o_t \odot \tanh(c_t) \quad (14)$$

式中: $U_i, W_i, U_f, W_f, U_c, W_c, U_o, W_o \in \mathbb{R}^{d \times d}$ 为网络中的权重矩阵; $b_i, b_f, b_c, b_o \in \mathbb{R}^d$ 为网络的偏置, 权重和偏置在训练学习过程中确定下来; $\odot$ 表示元素乘法; σ 为 sigmoid 函数; d 表示输入序列维度。每个时间步 LSTM 网络的输出 l_t 和隐藏层更新变换公式可以简化为式 (15) 和 (16):

$$l_t = \text{LSTM}(l_{t-1}, x_t, \Theta) \quad (15)$$

$$\hat{h}_t = \tanh(W_{l_{2o}} l_t + b_{l_{2o}}) \quad (16)$$

其中: LSTM 为式 (10) ~ (14) 组合; Θ 表示网络中的所有参数; $W_{l_{2o}}$ 和 $b_{l_{2o}}$ 表示隐藏层到输出的权重和偏置。Bi-LSTM 为两个单向 LSTM 的结合, 因此 Bi-LSTM 网络的输出为 $p_t = \text{Concat}(\hat{x}_t, \hat{x}_t^+)$, 其中, $\hat{x}_t^+$ 为 t 时刻 Bi-LSTM 网络的反向输出, p_t 为 t 时刻 Bi-LSTM 网络的输出, $\text{Concat}(\cdot)$ 函数将两个矢量按指定维度结合起来。将 Bi-LSTM 网络每个时间步的输出变换简写成下式:

$$p_t = \text{BiLSTM}(l_{t-1}, l_{t-1}^+, x_t, x_t^+, \Theta_{bi}) \quad (17)$$

式中: l_{t-1}^+ 为 $t-1$ 时刻 Bi-LSTM 网络的反向隐藏层矢量; $\hat{x}_t^+$ 为 t 时刻 Bi-LSTM 网络的反向输入; Θ_{bi} 和 $\text{BiLSTM}(\cdot)$ 分别表示 Bi-LSTM 网络中的所有参数和变换函数。

2.3.2 Transformer-encoder

Transformer-encoder 的作用主要为了加强信号序列学习的深度, 提取序列的特征, 解决序列中长期依赖问题, 包含注意力机制和残差结构, 分别为层归一化 (Layer Normalization)、多头注意力 (Multi-Head Attention)、失活 (Dropout) 和一维卷积 (Conv1D)。Layer Normalization 表示层归一化函数, 其作用是将输入的特征数值进行规范化转换, 使得整个网络的

计算过程数值更稳定,训练网络收敛速度更快。多头注意力将原输入向量映射为多个不同的查询矩阵 $\boldsymbol{Q}$ 、键矩阵 $\boldsymbol{K}$ 和值矩阵 $\boldsymbol{V}$ 的三元组,然后对每个三元组分别使用点积注意力机制进行计算,最后将不同三元组计算得到的输出进行拼接得到表达能力更多样的新特征向量,数学表示如下:

$$\text{head}_i = \text{Attention}(\boldsymbol{Q}W_i^q, \boldsymbol{K}W_i^k, \boldsymbol{V}W_i^v) \quad (18)$$

$$\text{Mutihead}(\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}) = \text{Concat}_{i=1, \dots, n}(\text{head}_i) W^p \quad (19)$$

式中: W_i^q, W_i^k, W_i^v 为可训练参数; $\text{Attention}(\cdot, \cdot, \cdot)$ 表示单个的点积注意力的计算。

Dropout 层作用是通过在训练期间随机丢弃网络节点,可以使用单个模型来模拟具有大量不同的网络架构,是一种计算低成本且非常有效的正则化方法,以减少过度拟合并改善各种深度神经网络中的泛化误差。合理使用 Dropout 正则化层可以减少过度拟合并提高深度神经网络的泛化能力。

综上,Transformer-encoder 模块的数据流过程可以简化表示为

$$Q^i = \text{LayerNormalization}(X^{i-1}W_Q^i) \quad (20)$$

$$K^i = \text{LayerNormalization}(X^{i-1}W_K^i) \quad (21)$$

$$V^i = \text{LayerNormalization}(X^{i-1}W_V^i) \quad (22)$$

$$X_i = X^{i-1} + \text{Dropout}(\text{MutiHead}(Q^i, K^i, V^i)) \quad (23)$$

$$X_i = \text{LayerNormalization}(X^i) \quad (24)$$

$$X_i = \text{Conv1D}(X^i) \quad (25)$$

$$X_i = \text{Dropout}(X^i) \quad (26)$$

$$X_{\text{out}} = \text{Conv1D}(X^i) \quad (27)$$

式中: W_Q^i, W_K^i, W_V^i 分别是前一层网络的输出 X^{i-1} 变换所得。

2.3.3 Dense 层

SD 网络最后一层是全连接层用于分类,使用 sigmoid 激活函数,表示为

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (28)$$

输出值限制在 0~1 之间,通过公式(29)硬判决的方式,判定输出的值是 1 b 还是 0 b。门限 p 根据 sigmoid 激活函数的输出范围决定,在本文中设定为 0.5。

$$f_{\text{bis}} = \begin{cases} 0, & \phi(x) < p \\ 1, & \phi(x) \geq p \end{cases} \quad (29)$$

FBLNet 接收机的训练以均方误差作为损失函数。公式(30)表示,通过训练学习,不断调整对权

重和偏置,减小真实值与模型预测值之间的误差。

$$\text{Loss} = \sum_{k=1}^N (y(k) - \hat{y})^2 \quad (30)$$

3 仿真分析

OFDM 系统仿真参数如表 1 所示,其中发射机中的导频插入方式为梳状导频,并将发射机生成的信号数据经过瑞利衰落后全部作为神经网络的训练集和测试集。本文的信道采用服从瑞利分布的衰落信道模型,多径瑞利信道的参数使用 COST207 标准模型中的参数^[16],该模型设定为 Jakes 的多普勒类型。接收端的同步技术采用基于导频的符号定时同步操作^[17]。对于训练过程,使用 Adam 优化器,训练学习率为 0.01。其中,当 SNR、导频数量、循环前缀等参数变化时,根据生成的样本数据重新训练接收机模型参数。对于测试过程,本文采用与训练过程相同的参数来评价框架的误码率性能。

表 1 主要仿真参数
Tab. 1 Main parameters of simulation

参数	值
导频数量	8
调制符号数	64
循环前缀	16
FFT 长度	128
子载波数量	64
比特流长度/b	128
多径数量	2
时延拓展/ μs	0.1
0 号路径相对时延/ μs	0
1 号路径相对时延/ μs	0.49
0 号路径功率衰减/dB	0
1 号路径功率衰减/dB	-2

3.1 传统接收机的对比分析

误比特率(Bit Error Ratio, BER)性能是衡量接收机解调性能影响的宏观指标。传统的 OFDM 接收机模型采用 LS 信道估计和 MMSE 信号检测算法组合解调算法进行仿真,称为 LS-MMSE 接收机。实验结果如图 5 和表 2 所示,可见在各种调制方式下, FBLTNet 接收机的性能全面优于 LS-MMSE 方法,说明深度学习接收机更适合调制信号的解调。




图 5 FBLTNet 与 LS-MMSE 接收机信噪比-误比特率曲线
Fig. 5 SNR-BER curve of FBLTNet and LS-MMSE receivers

表 2 瑞利信道下 FBLTNet 接收机和 LS-MMSE 接收机的信噪比对比

Tab. 2 SNR comparison between FBLTNet receiver and LS-MMSE receiver on Rayleigh channel

调制方式	误比特率	信噪比/dB		
		FBLTNet	LS-MMSE	提升
BPSK	10 ⁻²	15. 828	17. 982	2. 154
QPSK	10 ⁻²	17. 485	18. 670	1. 185
16QAM	10 ⁻²	18. 363	19. 432	1. 069
64QAM	10 ⁻²	19. 347	23. 340	3. 993

3.2 深度学习接收机的对比分析

本文将从空间时间复杂度和误比特率两个角度,与数据驱动的 FCDNN 接收机^[10]和模型驱动的 ComNet 接收机^[12]进行对比分析。

3.2.1 空间和时间复杂度

神经网络的空间复杂度,主要指网络模型的参数数量。由于维度的限制,模型的参数越多即空间复杂度越高,训练模型所需的数据量就越大,不仅会导致模型的训练容易过拟合,还会增大训练的难度。时间复杂度主要取决于模型的训练和预测时间,时间复杂度过高,既无法快速地验证想法和改善模型,在实际部署中也无法做到实时解调。表 3、表 4 和图 6 分别比较了 FCDNN、ComNet 和本文所提的 FBLTNet 模型的网络模型参数数量、训练时间及测试时间。

表 3 空间复杂度

Tab. 3 Spatial complexity

模型	模型参数/10 ⁵
FCDNN	2. 055 84
ComNet	0. 966 08
FBLTNet	1. 450 48

表 4 时间复杂度

Tab. 4 Time complexity

模型	收敛轮次	训练时间/s	测试时间/s
FCDNN	67	908	3. 2
ComNet	100	1 430	3. 6
FBLTNet	41	608	2. 4




图 6 模型训练收敛图
Fig. 6 Model training convergence diagram

由表 3 可知,基于数据驱动的 FCDNN 参数量最大,远高于基于模型驱动的 ComNet 和 FBLTNet, FBLTNet 接收机与数据驱动的 FCDNN 接收机相比,网络结构参数减少 29. 5%。其主要原因是模型驱动模型每层之间除神经元之间数据传递外,在连接之间还加入了自定义的数据变换,提取更多有物理意义的信息,降低了网络结构的复杂度。

由表 4 可知,收敛速度、训练时间和测试时间上,FBLTNet 模型最少,FCDNN 次之,ComNet 最多。FBLTNet 接收机与 FCDNN 相比,线下训练模型收敛时间和测试时间分别减少 33. 0% 和 25. 0%。图 6 表明,FBLTNet 模型在训练 41 轮次后收敛过程开始趋于稳定,80 轮次后就会出现过拟合;FCDNN 在 100 轮次都还未出现过拟合;ComNet 收敛最慢,还未达到收敛平稳状态。总之,与 FCDNN 和 ComNet 相比,FBLTNet 的空间和时间复杂度均最小,这表明采用具有强大记忆能力的自注意力网络的 FBLTNet,能够快速捕捉训练数据全局特征和学习数据分布特征。

3.2.2 误比特率

图 7 比较了 FCDNN、ComNet 和本文所提的 FBLTNet 在瑞利衰落信道的误比特率。当接收机达到特定误比特率量级时,实验结果如表 5 所示,可以看出,FBLTNet 接收机信噪比性能与 FCDNN 接近,

信噪比相差在 0.3 dB 左右。但与 ComNet 接收机相比,在 BPSK 调制方式下信噪比性能提高了 1.576 dB,在 QPSK 调制方式下提高了 4.248 dB,在 16QAM 调制方式下提高了 1.013 dB,在 64QAM 调制方式下提高了 0.755 dB,说明 FBLTNet 具有较好的信噪比性能。




图 7 多种接收机模型信噪比-误比特率对比
Fig. 7 Comparison of SNR and bit error rate of various receiver models

表 5 信噪比性能对比				
Tab. 5 Comparison of signal-to-noise ratio performance				
调制方式	误比特率	信噪比/dB		
		FCDNN	ComNet	FBLTNet
BPSK	10 ⁻³	24.589	26.141	24.565
QPSK	10 ⁻³	29.276	32.720	28.472
16QAM	10 ⁻²	30.932	31.628	30.615
64QAM	10 ⁻²	31.878	32.305	31.550

3.3 导频和循环前缀的影响

3.3.1 导频的影响

在 OFDM 通信系统中,接收端数据的同步和相干检测都需要预先知道收发天线之间的信道信息。为了获得信道的频率响应,最常用的方式是利用导频辅助信道估计算法。在传统估计算法中,适合的导频数量能够较为准确地估计出信道频率响应,但导频过多会使得频谱利用率降低。由于深度学习的数据拟合能力,可以采用较少的导频来估计,从而进一步提高频谱利用率。本文采用 64 个子载波的 OFDM 符号,使用梳状的导频插入方式,比较了 QPSK 调制方式下不同导频数量分别为 4,8,16 时的误比特率性能。从图 8 中可以看出,使用 LS-MMSE 算法的表现性能最差,且不同导频数量之间

的误差大。当信噪比高于 15 dB 时,LS-MMSE 接收机的误比特率曲线已经趋于饱和,而基于深度学习方法的 FBLNet 接收机依然具有随着信噪比的提高而降低误码率的能力。在相同量级的误比特率下,不同导频数量的接收机信噪比性能波动范围在 1 dB 左右。这表明 FBLNet 接收机对于导频数量具有鲁棒性,原因在于神经网络对于数学模型的依赖性较低,能够从模型生成的训练数据中学习无线信道的特性。




图 8 导频数量对不同接收机误比特率的影响
Fig. 8 Influence of the number of pilots on the bit error rate of different receivers

3.3.2 循环前缀的影响

在 OFDM 通信系统中,传统接收机高度依赖数学模型中的循环前缀。循环前缀是将符号末尾的信号复制符号最前面,确保每个子载波之间的正交性,一次对整数时间进行 FFT 变换,避免信号之间的干扰,从而对抗多径衰落。但这种做法让 OFDM 符号长度增加,系统在移动情况下对频率误差更敏感,带来了更大的开销并降低信息的传输效率。通过舍弃循环前缀以提高频谱利用率,从图 9 中可以看到,在舍弃循环前缀后,LS-MMSE 接收机表现敏感性最大,信噪比差异接近 10 dB,而 FBLNet 接收机对循环前缀的使用,信噪比差异较小,最大不超过 1 dB。这可解释为传统接收机方法极大依赖数学模型,舍弃循环前缀后使得子载波之间不再正交,接收端的数据对模型产生了较大的影响。反观 FBLNet 接收机,利用深度学习强大的数据拟合能力,且网络模型中引入了注意力机制,能够学习到符号间前后端信息的关系,说明 FBLTNet 接收机具有良好的抗符号间串扰的能力,也证明了在去除循环前缀的情况下深度学习方法是可行的。




图 9 循环前缀对不同接收机误比特率的影响
Fig. 9 Influence of cyclic prefix on bit error rate of different receivers

4 结 论

本文以 OFDM 无线通信系统为研究对象,采用深度学习的方法,结合神经网络和专家知识,提出了一种模型驱动接收机模型 FBLTNet。测试了不同调制方式的多种接收机性能,结果表明,本文提出的 FBLTNet 接收机提高了模型学习符号间关系的能力,不仅能够减少模型训练的收敛时间,还加快了模型的测试时间;在瑞利信道中,与传统接收机相比,对不同的调制方式均具有鲁棒性和泛化性;与基于深度学习的数据驱动接收机相比,降低了接收机的复杂度;与基于深度学习的模型驱动接收机相比,提高了解调精度,降低了误比特率。此外通过对比分析的得出结论,导频数量的变化及循环前缀对 FBLTNet 接收机解调性能影响较小,在实际部署中,可以通过减少导频数量和不使用循环前缀来提高信息的传输效率。

参考文献:

[1] STUBER G L, BARRY J R, MCLAUGHLIN S W, et al. Broadband MIMO-OFDM wireless communications [J]. Proceedings of the IEEE, 2004, 92 (2) : 271-294.

[2] LU M, PENG T, YUE G, et al. Dual-channel hybrid neural network for modulation recognition [J]. IEEE Access, 2021, 9: 76260-76269.

[3] 纪勤文, 朱春华. 基于 BP 神经网络的 OFDM 系统信道估计 [J]. 电讯技术, 2021, 61 (7) : 793-799.

[4] XU W, ZHONG Z, BE' ERY Y, et al. Joint neural network equalizer and decoder [C] // Proceedings of 2018 15th International Symposium on Wireless Communication Systems. Lisbon: IEEE, 2018: 1-5.

[5] 宗志辉. 基于深度学习的数字调制信号解调研究 [D]. 重庆: 重庆邮电大学, 2019.

[6] 周鹏. 基于深度学习的空间调制接收机检测算法研究 [D]. 济南: 山东大学, 2020.

[7] 高君慧. 面向智能通信的 MIMO-OFDM 先进接收机研究与实现 [D]. 南京: 东南大学, 2020.

[8] ZHENG S, CHEN S, YANG X. Deep receiver: a deep learning-based intelligent receiver for wireless communications in the physical layer [J]. IEEE Transactions on Cognitive Communications and Networking, 2020, 7 (1) : 5-20.

[9] O' SHEA T, HOYDIS J. An introduction to deep learning for the physical layer [J]. IEEE Transactions on Cognitive Communications and Networking, 2017, 3 (4) : 563-575.

[10] 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.

[11] ZHAO Z, VURAN M C, GUO F, et al. Deep-waveform: a learned OFDM receiver based on deep complex-valued convolutional networks [J]. IEEE Journal on Selected Areas in Communications, 2021, 39 (8) : 2407-2420.

[12] GAO 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.

[13] YI X, ZHONG C. Deep learning for joint channel estimation and signal detection in OFDM systems [J]. IEEE Communications Letters, 2020, 24 (12) : 2780-2784.

[14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30: 1706-1721.

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

[16] 李煜国. 多径瑞利信道下 OFDM 信号的识别方法研究 [D]. 西安: 西安电子科技大学, 2009.

[17] 王磊. DVB-T2 中基于导频的同步方法研究 [D]. 西安: 西安电子科技大学, 2014.

作者简介:

刘 檬 男, 1998 年生于贵州遵义, 硕士研究生, 主要研究方向为智能通信。

卢 敏 男, 1964 年生于江西于都, 教授, 主要研究方向为网络通信与电子材料器件等。

胡 娟 女, 1997 年生于江西赣州, 硕士研究生, 主要研究方向为智能通信。

李卓敏 女, 1999 年生于江西鹰潭, 硕士研究生, 主要研究方向为智能通信。