

DOI:10.19651/j.cnki.emt.2107042

OFDM 系统中 CNN-GRU 信号检测自编码器^{*}

张祖鹏 曹 阳 彭小峰 文 豪 秦怀军

(重庆理工大学 电气与电子工程系 重庆 400054)

摘要: 针对在双选衰落特性下信道时变和非平稳导致 OFDM 信号检测精度较差的问题,提出了一种基于 CNN-GRU 神经网络(CGNN)信号检测方案。首先使用信道模型生成数据以充分挖掘信道先验知识;然后在离线训练中采用一维卷积神经网络对原始信号进行降维和特征提取,利用门控循环单元的记忆特性恢复受到衰落的信号;最后为减少衰落程度严重的子载波引起的干扰,在网络训练中添加注意力机制,给每个子载波赋予权重,从而进行差异化训练。仿真结果表明,所提检测方法的误码性能提升明显,在平坦衰落信道下,CGNN 能获得 0.3~1 dB 的误码性能增益,在频率选择衰落信道下,CGNN 能获得 2~5 dB 的误码性能增益,并且拥有很强的鲁棒性。

关键词: 信号检测;一维卷积神经网络;门控循环单元;注意力机制

中图分类号: TN911.72 **文献标识码:** A **国家标准学科分类代码:** 510.40

CNN-GRU signal detection autoencoder in OFDM system

Zhang Zupeng Cao Yang Peng Xiaofeng Wen Hao Qin Huaijun

(School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China)

Abstract: Aiming at the problem of poor detection accuracy of OFDM signals caused by channel time-varying and non-stationary under dual-selection fading characteristics, a signal detection scheme based on CNN-GRU (CGNN) is proposed. First, use the channel model to generate data to fully mine the prior knowledge of the channel. Then, use the one-dimensional convolutional neural network in offline training to reduce the dimensionality and feature extraction of the original signal, and use the memory characteristics of the gated loop unit to restore the fading signal. Finally, in order to reduce the interference caused by the severely fading sub-carriers, an attention mechanism is added to the network training, and weights are assigned to each sub-carrier, so as to perform differentiated training. The simulation results show that the error performance of the detection method proposed is significantly improved. In a flat fading channel, CGNN can obtain an error performance gain of 0.3~1 dB. In a frequency selective fading channel, CGNN can obtain an error performance gain of 2~5 dB, and it has strong robustness.

Keywords: signal detection; one-dimensional convolutional neural network; gated recurrent unit; attention mechanism

0 引 言

正交频分复用(orthogonal frequency division multiplexing, OFDM)是一种常用的多载波调制方式,其优点是频谱利用率高,对采样同步误差的鲁棒性强,并广泛应用于抵抗频率选择性衰落的影响。由于多径效应和多普勒效应的影响,使得信道响应应具有双选衰落特性^[1],导致系统对信道先验知识匮乏,因此需要可靠的信号检测算法^[2]恢复信号。

传统的方法有最小二乘法(least squares, LS)、线性最小均方误差法(linear minimum mean square error,

LMMSE)等,尽管 LMMSE 可以得到较理想的误码率性能,但需要提前得到信道先验信息,这在双选衰落信道下难以实现。而近几年,深度学习在无线通信系统中取得了广泛应用^[3],包括信道估计^[4-6]、信号检测^[7-8]等,这表明深度学习与无线通信的结合是一个有前途的方案。信号检测中的一个方向是将无线通信系统视为自编码器^[9-10],即通信自编码器,将发送端,信道和接收端表示为深度神经网络,并对其训练,学习信道的非平稳特性,编码器的简单结构旨在以最小的错误概率恢复原始信息。O'Shea 等^[9]提出将通信系统作为一个端到端的重构任务,在整个单向过程

收稿日期:2021-06-24

^{*} 基金项目:重庆市教委基金项目(KJ120827)、重庆市教委科学技术项目(KJ1500934)、重庆市教委科学技术研究项目(KJ1709205)、重庆市研究生科研创新项目(CYS18311)、重庆市基础与前沿研究计划项目(cstc2015jcyjA40051)、重庆市巴南区科技计划项目(2019TJ07)资助

中共同优化发射端和接收端,相较于传统调制有着一定误码性能增益。Dörner 等^[10]提出根据获得的数据对接收器进行微调,该方法解决了信道函数未知的影响,并且通过 SDR 仿真验证了自编码器的实际可用性。因此将自编码器应用到信号检测中是可行的,但现有研究仍存在不足之处。Ha 等^[11]设计了一种集成学习方法,将接收信号作为网络输入,并考虑接收功率的影响,实验结果表明网络能达到预期性能,但集成网络的计算略微复杂。Yi 等^[12]采用超分辨率与图像恢复思想,提出信道条件恢复网络代替传统估计和检测算法,其性能比传统算法更好,且拥有良好的泛化能力,但该方法中去噪器的选用影响着结果的优劣。Wang 等^[13]联合循环神经网络与卷积神经网络设计新的网络架构,有效提取接收信号的序列特征信息,从而恢复原始信号,但双向 LSTM(long short-term memory)网络的计算量较大,其使用范围会受限。Luong 等^[14]采用索引调制来预处理 OFDM 信号和信道信息,然后通过自适应调整网络隐藏层节点数来获得性能与复杂度之间的平衡,但文中未考虑到信号严重衰落的情况。分析上述文献可知,虽然已有基于神经网络的信号检测算法取得了优于传统算法的成果^[15-16],但网络的架构可以进一步优化,且少有文献考虑了子载波衰落不一的影响。

针对双选衰落影响无线通信系统信号恢复性能的问题,提出一种结合卷积神经网络和门控循环单元神经网络(CNN-GRU neural networks, CGNN)信号检测方案,并将其推广到 OFDM 系统中,利用自编码器最小化重构错误。首先在发送端中调整一维卷积神经网络卷积核大小得到信号的低维表示。接收端中将导频与接收信号共同训练提升网络性能,使用门控循环单元提取衰落信号间的时间相关性以降低频偏的影响,并在神经网络训练中完成信号的调制解调。然后加入注意力机制,得到子载波的权重系数之后进行加权求和,从而减少受干扰严重的子载波带来的影响。实验结果表明,本文提出的 CGNN 较传统算法和之前的神经网络架构有着更低的误码率,更好的实时性,且在突发噪声环境下具有较强的鲁棒性。

1 系统模型

OFDM 拥有高速传输能力和抗频率衰落能力,但对于子载波间干扰(ICI)十分敏感^[17],在无线移动通信系统中,由于多径效应以及多普勒效应的存在,会造成严重的 ICI 从而影响系统误比特率。本文考虑具有 N 个子载波,循环前缀长度为 G 的 OFDM 系统,一个符号的第 n 个采样点可以表示为:

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} d(k) e^{-j2\pi kn/N}, G \leq n \leq N-1 \quad (1)$$

$$d(k) = \sum_{l=0}^{L-1} \alpha_l e^{-j2\pi f_p \tau_l} \sigma(\tau - \tau_l) \quad (2)$$

其中, $d(k)$ 是 OFDM 符号中第 k 个载波上的复数表

示; α_l 是第 l 条路径上的信道增益; τ 是信道时延; f_p 是最大多普勒频移; L 为总路径数; $\sigma(\tau - \tau_l)$ 是第 l 条路径信号的冲激响应。接收到的信号可以表示为:

$$y(n) = \sum_{l=0}^{L-1} h_l^l x(n-l)_N + \omega(n), 0 \leq n \leq N-1 \quad (3)$$

其中, h_l^l 表示第 l 条路径在第 n 个采样时刻的信道增益; $\omega(n)$ 是均值为 0 方差为 σ_ω^2 的高斯白噪声; $(\cdot)_N$ 表示循环移位操作。因此可以将接收到的信号用向量形式表示: $\mathbf{y} = [y(0), y(1), \dots, y(N-1)]^T$, 接收信号的模型表示为:

$$\mathbf{y} = \mathbf{H}' \mathbf{x} + \boldsymbol{\omega} \quad (4)$$

$$\mathbf{H}' = \begin{bmatrix} h_0^0 & 0 & \cdots & 0 & h_0^{L-1} & \cdots & h_0^1 \\ h_1^1 & h_1^0 & \ddots & \ddots & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & h_{L-2}^{L-1} \\ h_{L-1}^{L-1} & \ddots & h_{L-1}^1 & h_{L-1}^0 & 0 & \ddots & 0 \\ 0 & h_{L-1}^{L-1} & \ddots & h_{L-1}^1 & h_{L-1}^0 & 0 & \vdots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & h_{N-1}^{L-1} & \cdots & h_{N-1}^1 & h_{N-1}^0 \end{bmatrix} \quad (5)$$

其中, $\mathbf{x} = [x(0), x(1), \dots, x(N-1)]^T$ 为发送信号; $\boldsymbol{\omega} = [\omega(0), \omega(1), \dots, \omega(N-1)]^T$ 为噪声信号; \mathbf{H}' 是一个 $N \times N$ 的信道冲击响应矩阵。

2 CGNN 模型

2.1 OFDM 自编码器

一个简单的无线通信系统由发射器、信道以及接收器组成。发射器需要传输包含 $k \times M$ 个信息位的消息 $s \in k \times M$, 其中 k 为每个符号携带的比特数, M 为符号的长度。通信系统的通信速率为 $R = k/n$ (bit/channel), 传输序列 (n, k) 表示通信系统通过 n 个通道发送 k 比特信息。

输入序列 s 在传输前被转换为 one-hot 向量 \mathbf{S} , 其大小为 $2^k \times M$, 发射器对消息 \mathbf{S} 进行变换 f 生成发送信息 $\mathbf{x} = f(\mathbf{S}) \in \mathbf{R}^n$, 需要注意的是, 发送信息具有功率限制 $\|\mathbf{x}\|_2^2/n \leq 1$ 。在接收器端, 接收到的消息 $\mathbf{y} \in \mathbf{R}^n$, 此时的 \mathbf{y} 为经过信道受到干扰的信息 \mathbf{x} , 信道由条件概率密度 $p(\mathbf{y} | \mathbf{x})$ 表示。接收到 \mathbf{y} 之后, 接收器经过变换 g 估计发送信息 $\hat{\mathbf{S}} = g(\mathbf{y}) \in \mathbf{R}^n$, 最后根据概率大小恢复原始信息 \hat{s} , 错误概率 P_e 如下:

$$P_e = \frac{1}{M} \sum_{i=1}^M P_e(\hat{s}_i \neq s_i | s_i) \quad (6)$$

式中: s_i 为估计的信号, M 为信号长度。如文献[9]中所述, 通信自编码器的发射器和接收器都可由深度神经网络(deep neural networks, DNN)组成。通信自编码器与常用自编码器的区别是, 常用自编码器的目标是在某个中间层找到输入的低维表示形式, 从而在输出上以最小的误差进

行重构。而通信自编码器是学习消息 s 变换后的 x 到 y 中的信道损失,以便以很小的错误概率恢复原始信息。因此结合 OFDM 通信系统的自编码器框图如图 1 所示。

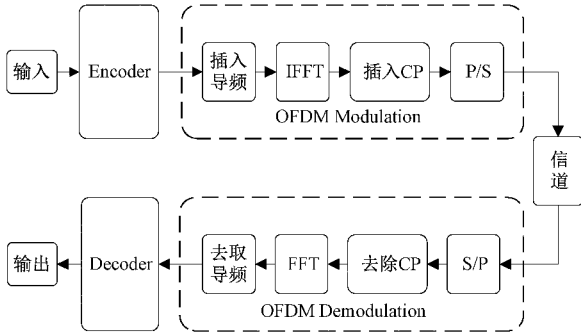


图 1 OFDM 自编码器系统

2.2 GRU 基本单元

GRU 中的 $z(t)$ 称为更新门, $r(t)$ 叫做重置门,其计算公式如下:

$$z(t) = \sigma(W_z^T \cdot [h(t-1), x(t)]) \quad (7)$$

$$r(t) = \sigma(W_r^T \cdot [h(t-1), x(t)]) \quad (8)$$

$$\tilde{h}(t) = \tanh(W_h^T \cdot [r(t) \otimes h(t-1), x(t)]) \quad (9)$$

$$h(t) = (1 - z(t)) \otimes h(t-1) + z(t) \otimes \tilde{h}(t) \quad (10)$$

其中, W_z, W_r 是权重矩阵; $h(t-1)$ 表示上一时刻隐藏层的输出 $x(t)$ 表示当前输入的数据; σ 表示激活函数 sigmoid; $\tilde{h}(t)$ 表示隐藏层; $h(t)$ 表示最终的输出层。

文献[12]中使用双向长短期记忆网络来恢复原始信号,并取得了比全连接网络和卷积神经网络更好的性能,但双向长短期记忆网络计算量过高。门控循环单元是长短期记忆网络的一种变体,因为少了一个门控单元,因此网络结构更加简单,其网络结构如图 2 所示。

2.3 基于 GRU 的神经网络模型

相较于 LSTM,GRU 少了一个门控单元,意味着参数量的减少,网络训练更快,而且 GRU 与 LSTM 有着相近的性能表现,因此将其应用到本文的自编码器中。由于现有




图 2 GRU 单元结构

的深度学习平台 tensorflow、keras 等不支持复数卷积运算,因此需要根据复数乘法运算:

$$(a + bi) \times (c + di) = (ac - bd) + (ad + bc)i \quad (11)$$

将信息分为实数以及虚数两个通道进行,分别计算后再结合起来。在编码器层之后会接上一个功率归一化层以确保输出 x 的物理约束。信道层由固定方差为 $\sigma = (2RE_b/N_0)^{-1}$ 的加性白噪声(AWGN)表示,其中 E_b/N_0 表示每比特能量 (E_b) 与噪声功率谱密度 (N_0) 的比率。在神经网络的训练中,使用不同的激活函数得到的结果并不一样,而在本文的实验中,使用指数线性单元(exponential linear unit, ELU)激活函数和 softmax 函数效果最好,具体实验将在第 3 章详细介绍。

本文设计的自编码器结构如图 3 所示,编码器的第 1 个卷积层添加 256 个卷积核, 1×1 卷积核可以保持尺度不变的情况下增加非线性特性,充分提取样本特征。指数线性单元 ELU 用于执行网络的非线性变换,第 2 层卷积减少卷积核个数,再次提取特征相当于对数据进行滤波,并且可以缩减计算量。并在每两层之间添加 BatchNormalization 层使得网络快速收敛。在经过信道层之前,发送符号 x 的实部与虚部需要提取出来,即通过功率归一化层将网络大小压缩到 $M \times 2$, 功率归一化层还可以保证发送符号的物理功率约束。信道层不需要经过训练,因此 Lambda 层可以很好的应用到网络中。在解码器中,直接将接收到的

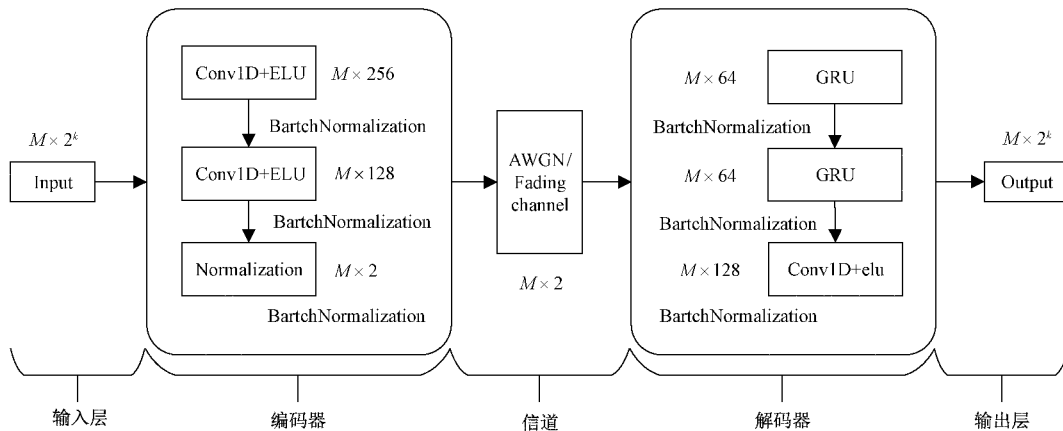


图 3 CNN-GRU 自编码器结构

$\mathbf{y} = [y_r, y_i]$ 作为输入。使用门控循环单元作为恢复网络,两次复用 GRU 网络用以增加数据的相关性,可以有效地抵抗信道衰落。最后输出层使用的非线性激活函数 softmax 用来恢复原始信号。

在网络训练中,因为卷积层的权重共享的特点,所以可以采用任意长度训练,而卷积层有效地提取了数据的空间特征,GRU 网络有效地提取了数据的时间特征,这使得整体网络拥有很强的泛化能力。在本文的实验中,不同信噪比的训练效率未能达到满意的效果,因此在不同码率下分别使用固定信噪比训练网络。网络损失函数采用均方误差函数(mean square error, MSE):

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N \|x_i - \hat{x}_i\|^2 \quad (12)$$

其中, N 是批次; x_i, \hat{x}_i 分别是输入数据和估计值,采用 Adam 优化器进行梯度的更新。在本文的实验中,通过改变传输比特大小与不同的星座映射调制作对比,信道选用突发噪声信道、瑞利衰落信道以及频率选择衰落信道来验证网络有效性,详细内容将在第 3 章分析。

2.4 注意力机制

在上一节的分析中,简洁的自编码器结构能够优化传统的逐块设计通信系统,而在进行信号检测时,各子载波通道遭受的噪声以及干扰具有差异性^[18],即子载波受干扰程度不一。针对此,在 CGNN 的解码器网络中添加加权求和注意力机制,在网络中表示为:

$$\mathbf{D} = \tanh(\mathbf{W}^T \mathbf{Y} + \mathbf{b}) \quad (13)$$

$$attention = \text{Softmax}(\mathbf{D}^T, \mathbf{Y}) \quad (14)$$

$$context = \sum_{i=1}^{\omega} (attention_i \cdot \mathbf{Y}) \quad (15)$$

其中, \mathbf{Y} 是解码器网络的隐层表示; \mathbf{D} 为注意力机制的权重分布; \mathbf{W}, \mathbf{b} 分别表示为权重矩阵和偏置; $attention$ 是权重系数的归一化分布。在得到上一层的权重系数之

后,就可以将该系数与下一层的输入点乘,之后的网络层就可以根据权值分布进行差异训练,以避免受干扰严重的子载波影响最终结果。在训练中将数据可视化,其中受干扰的多载波和注意力分布如图 4 所示,图 4(a)中横坐标为子载波数量,纵坐标为训练批次大小,最终加权求和得到的注意力权重分布可视化如图 4(b)所示。




图 4 衰落信号与注意力分布

因此,完整的 CGNN 模型如图 5 所示。单个消息符号 \mathbf{x} 表示 $n/2$ 个复数信号,在编码器的传输中通过傅里叶反变换创建 ω 个等效的独立子信道,将每个消息经过变换分配给每个子载波,并添加导频符号。为了避免符号间干扰和采样同步错误,在网络中添加循环前缀(CP),编码器端的传输符号可以表示为 $\mathbf{x} \in \mathbf{C}^{n/2 \times (\omega l_p + l_{CP})}$, ω 为傅里叶变换长度; l_p 为导频长度; l_{CP} 为 CP 长度,在经过功率归一化后送入信道。联合导频信号和接收信号作为输入得到了比传统 MMSE 算法更好的效果^[17],因此本文在接收端将导频信息 \mathbf{p} 和接收信号 \mathbf{y} 一起送入解码器网络,提升信号检测精度。




图 5 CGNN 模型

3 实验仿真

为验证 CGNN 的有效性和可靠性,在突发噪声信道、瑞利衰落信道和频率选择衰落信道下,选取一定范围的信噪比来验证 CGNN 的性能。在无线通信系统中进行仿真实验,将传输比特 k 分别设置为 4 和 6,从不同调制方式下对比 CGNN 的误码率性能,训练信噪比分别设置 12 dB 和 15 dB,与常用

的 16 正交幅度调制(quadrature amplitude modulation, QAM), 64QAM 在不同信道下进行对比,系统采用自适应学习率算法,采用 Adam 优化器并设置初始学习率为 0.001,当网络精确度长期未增加时学习率下降为初始的 0.1,训练的信噪比为固定的信噪比,使用 Dropout 和 L2 正则化来防止网络过拟合。Batchsize 设置为 64,批次设置为 300,测试数据大小为训练数据的 1/4,仿真参数如表 1 所示。

表1 仿真参数设置

参数	设置
载波频率/GHz	2
系统带宽/MHz	2
子载波数量	64
FFT长度	64
循环前缀长度	16
调制格式	16QAM/64QAM
衰落信道	突发噪声/瑞利衰落/频选衰落

为得到CGNN的最佳性能表现,分别使用不同的激活函数测试网络,根据使用不同激活函数的结果判断CGNN的误码率走向,得到的结果如图6所示。在图6(a)中,横坐标为比特信噪比,纵坐标为误码率,使用的激活函数有修正线性单元(rectified linear unit, ReLU)、指数线性单元(ELU)、双曲正切函数(tanh)以及与其相似的softsign函数。可以看到使用不同激活函数的效果差异较大,而使用ELU激活函数的CGNN性能最好。图6(b)中,横坐标为训练批次,纵坐标为损失函数MSE,训练集损失(loss)和验证集损失(val-loss)随epoch的增加而下降,并在第140个epoch附近平稳下来。




图6 不同激活函数下网络收敛情况

在无线通信环境中,电磁波经过多条路径到达接收机后,信号的强度将服从瑞利分布。因此,在瑞利衰落信道下测试网络性能,假设随机过程是广义平稳的,最大多普勒平移为 9.26 Hz。从图7可知,在衰落信道下,CGNN拥有比传统QAM调制更好的性能,随着调制阶数的增加,两种方法的误码率都在增加,但CGNN的误码率仍优于传统调制,且在高SNR下系统的增益逐渐扩大,在高信噪比下,携带比特 $k=6$ 的CGNN的增益约为1 dB,携带比特 $k=4$ 的CGNN的增益约为0.8 dB,这得益于GRU网络的记忆力机制可以根据相邻信号的相关性来恢复信号。




图7 瑞利衰落信道下误码率对比

为验证注意力机制的影响,本文在瑞利信道下训练和测试网络,图8所示为在瑞利信道下,不同调制阶数下注意力机制的表现情况。可以看到未添加注意力机制的误码率在不同调制阶数下的误码率都高于添加注意力机制的误码率,这表示本文中的注意力机制可以通过赋予子载波权重,有效地抑制信道衰落。




图8 注意力机制的影响

为观察CGNN的抗噪声能力,实验中绘制了10 000个点的神经网络星座图如图9所示,可以看出传统QAM映射与神经网络的不同处,传统QAM星座图是规则对称的,而神经网络映射的星座点因为平均功率归一化的原因分布在不同单位圆上,从原点开始向外发散,星座图 x 轴

和 y 轴分别代表数据的第 1 通道和第 2 通道信息。从图 9(a)和(b)的星座图中可以看出,神经网络映射的星座点因为瑞利衰落的原因有些发散,但仍能分辨出星座点呈簇分布,系统拥有健壮的抗噪声性能。

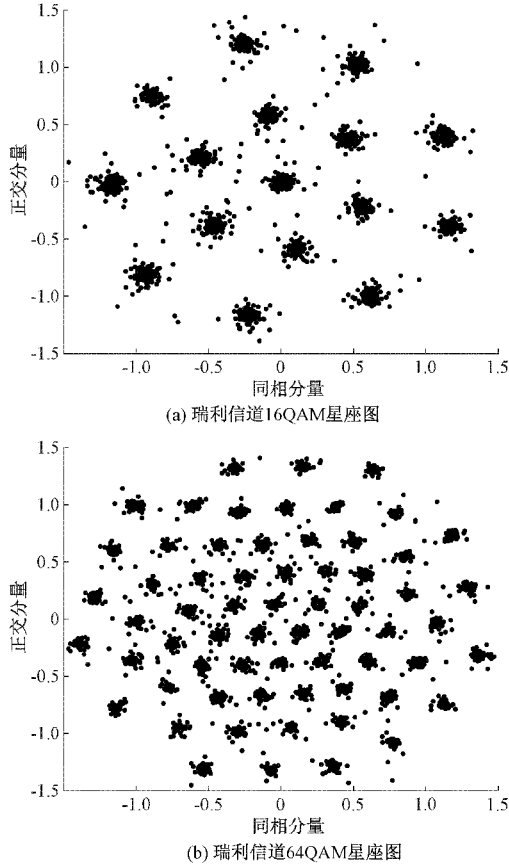


图 9 不同信道下神经网络星座图

GRU 的提取信号的相关性特征能够应对更复杂的通信情况,为了测试 CGNN 应对通道变化的能力,实验测试了网络在非高斯噪声信道下的性能,并在 AWGN 信道下训练网络,在测试中加入发生概率为 10% 的随机突发噪声,且其他噪声的方差与突发噪声的方差比的范围为 0.1~1,在与传统的 QAM 进行比较结果如图 10 所示。




图 10 随机突发噪声下误码率对比

从图 10 中可以看出,CGNN 在应对随机突发噪声情况时也拥有很强的抵抗力,这是因为 GRU 网络的记忆性可以减小突发噪声带来的影响,这也使得 CGNN 在实际中的应用成了可能。在经过以上实验可以得知,CGNN 在简单或者突发噪声的信道下的表现都比传统 QAM 调制更加优异,并且拥有很好的鲁棒性,因此在更复杂的信道下,测试 CGNN 性能,探究实际应用中的性能表现。

根据信道的频率选择性,可以把信道分为平坦衰落信道和频率选择性衰落信道,频率选择衰落信道是由多个具有不同时延的平坦衰落信道组合而成。已有文献实验了端到端系统在瑞利衰落信道上的简单应用^[9],但实际生活中的衰落更加复杂,本文选择在多径频率选择衰落信道上验证 CGNN 的可靠性。本节将通过实验对比基于神经网络的 OFDM 系统与传统调制在多径衰落下的性能,验证神经网络设计的 OFDM 系统具有更好的性能,其中传统的 OFDM 系统中使用 QAM 调制+LS/LMMSE 信道估计+ZF 均衡,并且假设 MMSE 已知信道状态信息。OFDM 系统数据以帧结构发送,其中子载波间隔为 15 kHz,一个帧包含 7 个 OFDM 符号,由于块状导频可以插入 OFDM 所有子载波中,因此本文选用块状导频进行信道估计。衰落信道参考 ITU Pedestrian A (Ped-A),速度为 10 km/h,其中 Ped-A 的参数如表 2 所示。

表 2 ITU Pedestrian A 信道参数设置

抽头幅值/dB	抽头延迟/ns	多普勒功率谱
0	0	Classic
-9.7	110	Classic
-19.2	190	Classic
-22.8	410	Classic

在频率选择衰落信道下的实验结果如图 11 所示,恢复发送信号之前需要均衡信道响应。从图中可以看出 LS 算法的表现最差,这是因为 LS 算法未考虑噪声的影响,而 LMMSE 精度高的原因在已知信道的二阶统计特性,理想信道估计是直接将信道系数传递给接收机,这在实际中是很难实现的。将文献[14]中的设置改为 $N = 64, K = 1, M = 16, 64$ 与 CGNN 进行比对。在 CGNN 中,注意力机制的加入减小了衰落严重的子载波的影响,因此能有效抵抗信道衰落和多普勒频移的干扰,降低系统误码率。从图中可知,随着信噪比增加,不同码率下的本文的 CGNN 都能够得到最低的误码率表现,因 CGNN 有着比传统调制和先前神经网络更好的性能。

CGNN 拥有比传统算法更好性能的原因在于如下几点:一维卷积神经网络可以提取信号隐藏特征;门控循环单元有效的利用了信号之间的相关性特征;注意力机制的加入也降低信道衰落带来的影响;且网络中参数设置较小可以得到较好的实时性。而为了验证 CGNN 的强鲁棒性,

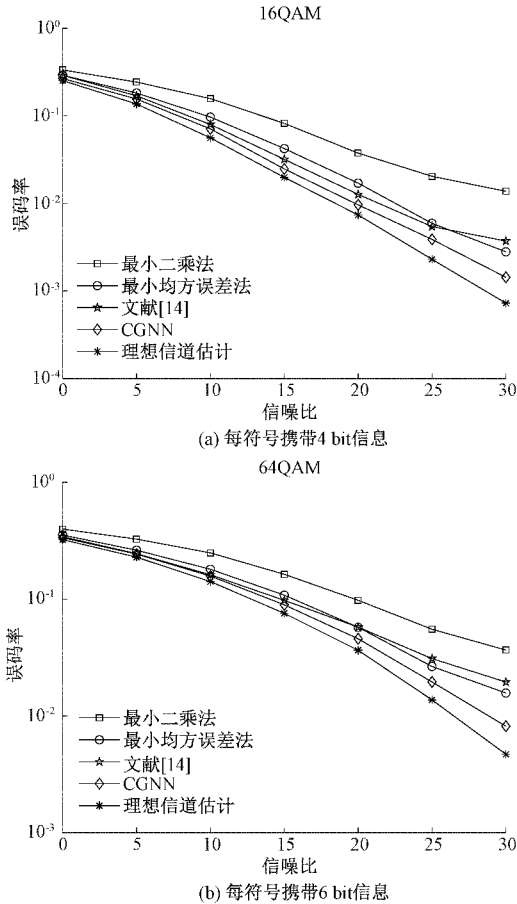


图 11 10 km/h 下误码率对比

继续测试在高速多普勒频移下自编码器网络的性能。新的衰落信道为 ITU Vehicular A (Veh-A), 速度设置为 120 km/h, Veh-A 参数如表 3 所示。

表 3 Veh-A 信道参数设置

抽头幅值/dB	抽头延迟/ns	多普勒功率谱
0	0	Classic
-1	310	Classic
-9	710	Classic
-10	1 090	Classic
-15	1 730	Classic
-20	2 510	Classic

图 12 所示为在速度为 120 km/h 时各算法的误码率曲线, 每种曲线的误码率都有所增加。其中 LS 算法的误码率曲线最高, 说明 LS 算法性能遇到瓶颈。LMMSE 算法的误码率仍然较差, 低信噪比下文献[14]的误码率与 LMMSE 算法的误码率接近, 高信噪比情况下其误码率高于 LMMSE 算法。CGNN 拥有最出色的误码率曲线, 随着信噪比增加 CGNN 的误码率始终保持最低。

为分析本文的自编码器的复杂度, 训练了两个模型,

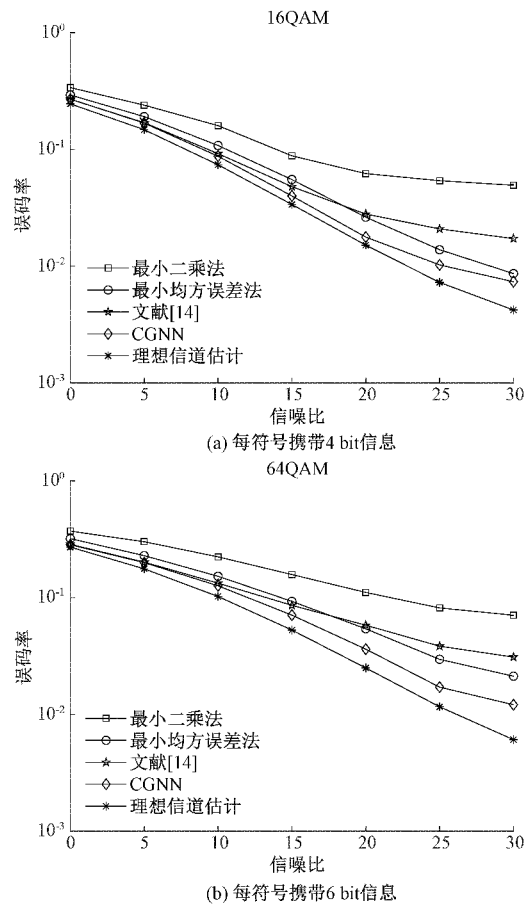


图 12 120 km/h 下误码率对比

然后设置相同的信道环境, 计算同等长度传输符号的运行时间, 结果如表 4 所示。

表 4 算法运行时间对比

不同调制	LS	LMMSE	文献[14]	CGNN
16QAM	0.009	0.120	0.015	0.014
64QAM	0.009	0.134	0.017	0.026

可以看到 LS 算法的运行时间最短, 但是其误码率最高; LMMSE 算法的运行时间最长; 文献[14]的计算时间与 CGNN 结果相近; CGNN 的运行时间虽不是最短, 但误码率最低。由于采用 one-hot 编码, 在高阶调制下的输入矩阵会增大, 计算量会小幅增加, 综合考虑下, CGNN 拥有最好的性能。

4 结 论

针对 OFDM 通信传统受到信道时变, 非线性影响导致信号检测性能受限的问题, 通过联合多层卷积神经网络和 GRU 网络构建 CGNN 来进行信号检测, 并添加注意力机制用以降低衰落严重的子载波的影响。在简化系统整体结构的同时提升系统性能, 为频率选择衰落场景提供一

个新的学习方案。所设计的 CGNN 拥有可解释性强以及训练参数少,数据相关性高的特点。在经过实验仿真后,证明了该网络在多种信道下都具有较高的准确率,在突发噪声的情况下也表现出强鲁棒性。

参考文献

- [1] 洪丹阳,王巍,周成阳,等.基于非均匀快速傅里叶变换的正交频分复用水声通信多普勒估计与补偿方法[J].仪器仪表学报,2021,42(4):67-74.
- [2] 何怡刚,隋永波,FARHAN A,等.自适应 OFDM 系统的时域信道预测研究[J].电子测量与仪器学报,2021,35(5):100-110.
- [3] 史蕴豪,许华,郑万泽,等.基于集成学习与特征降维的小样本调制识别方法[J].系统工程与电子技术,2021,43(4):1099-1109.
- [4] 张舒然,武岩波,朱敏.基于 MCMC 采样器的簇稀疏水声信道估计方法[J].仪器仪表学报,2019,40(8):201-212.
- [5] 王瑞,芮国胜,张洋.利用张量模型的 MIMO-OFDM 中继系统信道估计[J].电子测量技术,2017,40(12):246-250.
- [6] 孙婷.基于压缩感知的移动通信信道估计方法[J].国外电子测量技术,2021,40(4):32-36.
- [7] YE H, LI G Y, JUANG B. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. IEEE Wireless Communications Letters, 2018, 7(1): 114-117.
- [8] 卢俊男,肖本贤.基于信道状态信息的后向散射信号检测[J].电子测量与仪器学报,2019,33(5):95-101.
- [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] DÖRNER S, CAMMERER S, HOYDIS J, et al. Deep learning based communication over the air[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1):132-143.
- [11] HA C, SONG H. Signal detection scheme based on adaptive ensemble deep learning model [J]. IEEE Access, 2018, 6: 21342-21349.
- [12] 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.
- [13] WANG S, YAO R, TSIFTISIS T A, et al. Signal detection in uplink time-varying OFDM systems using RNN with bidirectional LSTM [J]. IEEE Wireless Communications Letters, 2020, 9(11): 1947-1951.
- [14] LUONG T V, KO Y, VIEN N A, et al. Deep learning-based detector for OFDM-IM [J]. IEEE Wireless Communications Letters, 2019, 8(4):1159-1162.
- [15] WANG T, WEN C, WANG H, et al. Deep learning for wireless physical layer: Opportunities and challenges[J]. China Communications, 2017, 14(11): 92-111.
- [16] ZHU B, WANG J, HE L, et al. Joint transceiver optimization for wireless communication PHY using neural network[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6):1364-1373.
- [17] BAI Q, WANG J, ZHANG Y, et al. Deep learning-based channel estimation algorithm over time selective fading channels[J]. IEEE Transactions on Cognitive Communications and Networking, 2020, 6 (1): 125-134.
- [18] 蔡君. 5G/B5G 系统中信道估计及信号检测关键技术研究[D].南京:南京邮电大学,2020.

作者简介

张祖鹏,硕士研究生,主要研究方向为通信信号处理、智能信息处理。

E-mail:1290777597@qq.com

曹阳,教授,主要研究方向为无线电电子学、通信信号处理。

E-mail:caoyang@cqut.edu.cn

彭小峰,高级实验师,主要研究方向为无线电电子学。

E-mail:pxf@cqut.edu.cn

文豪,硕士研究生,主要研究方向智能通信系统。

E-mail:929388258@qq.com

秦怀军,硕士研究生,主要研究方向为智能信号处理。

E-mail:1870919694@qq.com