

基于LSTM神经网络的QPSK智能接收机设计

朱力, 韩会梅, 翟文超

引用本文

朱力, 韩会梅, 翟文超. 基于LSTM神经网络的QPSK智能接收机设计[J]. 计算机科学, 2023, 50(11A): 230200219-5.

ZHU Li, HAN Huimei, ZHAI Wenchao. Design of QPSK Intelligent Receiver Based on LSTM Neural Network [J]. Computer Science, 2023, 50(11A): 230200219-5.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于边缘引导的多尺度医学影像分割方法](#)

Medical Image Segmentation Based on Multi-scale Edge Guidance

计算机科学, 2023, 50(11A): 220900059-7. <https://doi.org/10.11896/jsjcx.220900059>

[基于语义注意力的医学图像超分辨率方法](#)

Medical Image Super-resolution Method Based on Semantic Attention

计算机科学, 2023, 50(11A): 221200107-6. <https://doi.org/10.11896/jsjcx.221200107>

[一种基于因果推理的垃圾分类方法](#)

Novel Method for Trash Classification Based on Causal Inference

计算机科学, 2023, 50(11A): 220800218-6. <https://doi.org/10.11896/jsjcx.220800218>

[接诉即办智能派单业务调度算法研究](#)

Study on Scheduling Algorithm of Intelligent Order Dispatching

计算机科学, 2023, 50(11A): 230300029-7. <https://doi.org/10.11896/jsjcx.230300029>

[一种噪声容忍的网络流量分类方法](#)

Noise Tolerant Algorithm for Network Traffic Classification Method

计算机科学, 2023, 50(11A): 220800120-7. <https://doi.org/10.11896/jsjcx.220800120>

基于 LSTM 神经网络的 QPSK 智能接收机设计

朱力¹ 韩会梅¹ 翟文超²

1 浙江工业大学信息工程学院 杭州 310023

2 中国计量大学信息工程学院 杭州 310018

(zhu67805@163.com)

摘要 针对正交相移键控(Quadrature Phase Shift Keying,QPSK)接收机检测信号准确率低以及复杂度高的问题,提出了一种基于长短期记忆(Long Short-term Memory,LSTM)神经网络的 QPSK 智能接收机设计方案。该方案中的神经网络模型由 LSTM 和全连接层构成,其利用 LSTM 提取接收信号的时间相关性,具有较低复杂度。仿真实验结果表明,在加性高斯白噪声、同相和正交(Inphase and Quadrature,IQ)失衡、频率偏差信道因素影响下,与现有 QPSK 接收机相比,所提出的 QPSK 智能接收机显著提高了检测性能。

关键词:深度学习;长短期记忆神经网络;智能接收机;QPSK 调制

中图分类号 TN919.3

Design of QPSK Intelligent Receiver Based on LSTM Neural Network

ZHU Li¹, HAN Huimei¹ and ZHAI Wenchao²

1 College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China

2 College of Information Engineering, China Jiliang University, Hangzhou 310018, China

Abstract To solve the problem of low detection accuracy and high complexity of quadrature phase shift keying(QPSK) receiver, this paper proposes a QPSK intelligent receiver based on long short-term memory(LSTM) neural network. The proposed intelligent receiver consists of LSTM and fully connected layers, which employs the LSTM to capture the temporal correlation of the received signal. Furthermore, the proposed intelligent receiver has low complexity. Simulation results show that, compared with the existing QPSK receivers, the proposed QPSK intelligent receiver significantly improves detection performance in the scenarios of additive Gaussian white noise, inphase quadrature imbalance and frequency deviation channel.

Keywords Deep learning, Long short-term memory neural network, Intelligent receiver, QPSK modulation

1 引言

正交相移键控调制技术具有频谱利用率高、电路实现简单、抗干扰能力强等优点,因此成为了无线通信领域一种常用的调制方式^[1]。QPSK 信号在混杂有噪声以及其他非理想因素干扰的信道中传输时会产生失真。这种干扰失真信号只有经过接收机的处理才能够恢复出原始的发送信号。因此,接收机的设计尤为重要,它决定着干扰失真信号恢复的准确程度,从而影响着通信的质量。

传统 QPSK 接收机通常使用硬判决方法对接收到的失真信号进行解调。但是,传统 QPSK 接收机处理每个模块时的算法通常是基于理论假设,如假设射频器件是理想的,不存在共信道干扰等。但是,这些假设往往与整个通信系统所经历的实际过程有一些差别。因此,传统的 QPSK 接收机所优化的是在假设条件下的最佳性能,但在实际条件下不一定能达到这种最佳的性能。

随着科学技术的发展,深度学习技术在最近几年也成为了科研工作者的研究热点。深度学习在人脸识别、自动控制、

数据分析和预测、信号处理和图像分类等领域都得到了一定程度上的应用。目前,关于深度学习和通信的研究主要与信号检测^[2]、信道状态信息反馈^[3-4]以及预编码^[5-6]等方面有关。在通信传输过程中,由于通信接收机起着重要的作用,使用深度学习研究通信接收机也是当前的一个研究热点,传统无线通信接收机存在的一些缺陷也极有可能因为深度学习的应用而得到一些修复。文献[7]使用堆叠的自动编码器和深度信念网络完成短距离多径信道中的信号解调。但是,这种算法在长距离通信等情况下的解调性能会有所下降。文献[8]采用了深度神经网络达到软解调的目的,不仅使得计算复杂度得到了降低,还提升了解调性能。但是,文献[8]中的网络只能取代接收机的解调模块。文献[9]使用了双向递归神经网络(Bidirectional Recurrent Neural Network, BRNN)进行数据序列检测。但文献[9]忽略了通信中的信道译码模块。除了用深度学习取代接收机的单个处理模块外,一些学者还使用深度学习模型取代接收机的多个处理模块。文献[10]采用了两个独立的神经网络来分别代替均衡模块和译码模块,对这两个网络可以进行联合训练,以获得更好的性能。从以上

基金项目:国家自然科学基金(62001419)

This work was supported by the National Natural Science Foundation of China(62001419).

通信作者:韩会梅(hmhan1215@zjut.edu.cn)

研究结果可以看出,目前深度学习在无线通信接收机中的应用主要集中在用深度神经网络模型替换接收机中的一个或多个(但不是全部)模块上,几乎没有涉及到射频损伤、信道干扰等情况。针对以上问题,文献[11]考虑了射频损伤、无线信道衰落、噪声和干扰的影响,提出了采用深度接收机(Deep Receiver)模型取代接收端的整个信息恢复过程。文献[11]设计了一种一维卷积密集网络结构,其利用全局池化来提高网络对不同输入信号长度的适应性,并使用多个二进制分类器来实现多位信息流的恢复,使得接收机的检测性能相比传统硬判决有所提升。但是,DeepReceiver的缺陷在于它的复杂度、训练时间长、对设备要求高、应用门槛高。此外,DeepReceiver的识别准确率也有待进一步提高。因此,很有必要设计出一种复杂度低、易于实现、对设备要求较低、检测性能更好的智能接收机。

为了解决现有 QPSK 接收机技术中存在的因信道噪声、同相和正交失衡、频率偏差等因素干扰导致的系统性能下降的问题,本文提出了一种基于长短期记忆神经网络^[12]的 QPSK 智能接收机。该接收机所采用的神经网络结构由 LSTM 和全连接层构成。仿真结果表明,在加性高斯白噪声、IQ 失衡、频率偏差信道因素影响下,与使用传统硬判决方法和文献[11]中的 DeepReceiver 方法相比,本文算法在减小复杂度的同时能够提升检测性能。

2 系统模型

考虑如图 1 所示的 QPSK 通信系统,其由发射机、传输信道和接收机三大模块组成。在发射机端,信号经过信源编码、信道编码和调制后成为已调信号。已调信号在信道中传输时会受到信道噪声等非理想因素的影响。接收机对受干扰的已调信号进行解调和译码等过程,以尽可能准确地恢复出所需要的原始信息。由此可知,接收机在整个通信过程中发挥着重要作用,它决定了整个通信系统性能的优劣以及最后恢复出所需信息的准确程度。

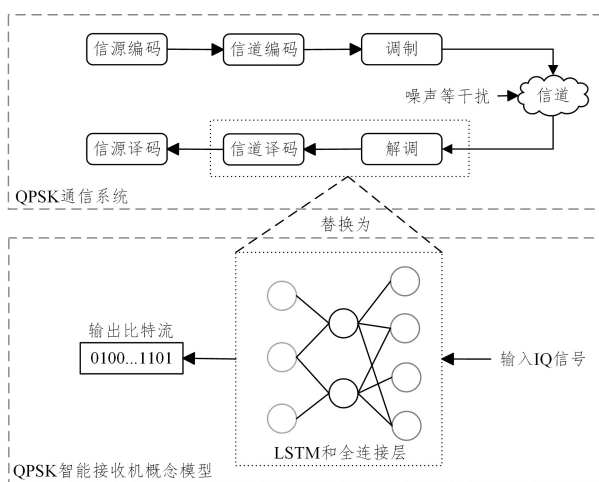


图 1 QPSK 通信系统和 QPSK 智能接收机概念模型

Fig. 1 Conceptual model of QPSK communication system and QPSK intelligent receiver

本文考虑了对接收机接收到的信号的质量影响较大的 3 种因素。

1) 加性高斯白噪声 (Additive White Gaussian Noise, AWGN)。由于电子元器件的存在,通信系统在工作过程中

本身也会产生噪声。因此,发射机发送出的信号经过通信信道传输到达接收机端时,会含有噪声成分。这些噪声混杂在接收信号中,会对信号的正确恢复造成较大的影响。加性高斯白噪声作为目前最常见的噪声之一,在统计学上可以视为随机无线噪声。它的特点是噪声的功率谱均匀分布的频率范围远远大于通信系统的工作频带,而且取值的概率分布服从高斯分布。

2) IQ 失衡。由于温度依赖性、生产缺陷和老化, QPSK 信号中 I 路径和 Q 路径中的模拟分量难以完全匹配,就会出现 IQ 失衡。IQ 失衡包括幅度和相位上的失衡,它很可能会产生镜像产物,从而影响通信接收机的吞吐率和解调性能等。除此以外,在实际的硬件电路中,设备的物理限制和电路设计错误也会造成 I 信号和 Q 信号的相位和振幅不相同,从而导致 IQ 失衡。IQ 失衡可以表示为:

$$y(x) = \text{Re}(x)10^{\frac{\alpha}{10}} \exp\left\{-\frac{j\beta\pi}{360}\right\} + j \text{Im}(x)10^{\frac{\alpha}{10}} \exp\left\{\frac{j\beta\pi}{360}\right\} \quad (1)$$

其中, $\text{Re}(x)$ 和 $\text{Im}(x)$ 分别为信号的实部(I)和虚部(Q)分量; α 为振幅上的失衡,单位为 dB; β 为的相位上的失衡,单位为度。

3) 频率偏差。如果发射机的本地振荡器和接收机的本地振荡器之间存在一些差异,则很可能造成频率偏差。此外,发射机和接收机之间的相对运动也会引起多普勒频移,它可以表示为:

$$\Delta f = \frac{fv \cos \theta}{v_c} \quad (2)$$

其中, f 为信号频率, v 为发射机与接收机之间的相对速度, θ 为运动方向与信号入射方向之间的夹角, v_c 为光速。多普勒频移也属于频率偏差,频率偏差通常简称为频偏。频偏是无线通信系统中的一个十分重要的性能指标之一。频偏的存在会对接收机的正确解调造成一定程度的影响,这极有可能降低信息恢复的准确性。通常来说,在通信传输信号时,频偏越大,接收机接收到的信号的质量会越差。

3 基于 LSTM 神经网络的 QPSK 智能接收机模型

图 2 给出了所提出的 QPSK 智能接收机模型,其由 LSTM 和全连接层两个模块构成。

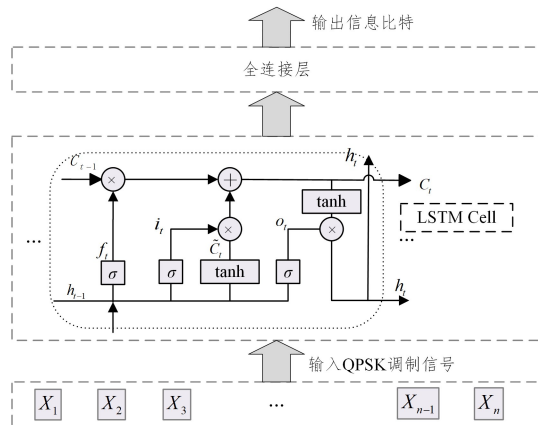


图 2 智能接收机模型

Fig. 2 Intelligent receiver model

该网络的输入数据为原始数据经过 QPSK 调制后的信号 $X_t = [X_1, X_2, \dots, X_n]$ 。网络输出为信息比特,即 0 或 1。

各模块的具体介绍如下。

1) LSTM 层

LSTM 具有长时记忆功能,实现起来也比较简单,可以解决长序列训练过程中存在的梯度消失和梯度爆炸问题。因此,LSTM 在执行预测任务时具有独特的优势。一层 LSTM 由多个 LSTM Cell 组成,LSTM Cell 是 LSTM 的一个单元,每个 LSTM Cell 就相当于一个时间步的处理。如图 2 所示,LSTM 单元包括输入门 i_t 、输出门 o_t 和遗忘门 f_t 。输入门单元尝试从该单元的输入信息中学习新信息。输出门单元将更新的信息从当前时间步传递到下一个时间步。遗忘门选择来自前一个时间步的信息是被记住还是不相关,并且可以被遗忘。所有的门都使用 sigmoid 函数进行选择,并使用 tanh 函数进行变换。LSTM 在整个时间序列中都通过门更新状态单元的信息。在每个时间状态下,根据候选状态 \tilde{C}_t 和先前状态 \tilde{C}_{t-1} 更新当前单元状态 C_t 。可以根据隐藏状态 h_t 得到输出。在第 t 个时间步,LSTM Cell 中的模块的表达式为:

$$i_t = \delta(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (3)$$

$$f_t = \delta(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (4)$$

$$o_t = \delta(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (5)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, X_t] + b_c) \quad (6)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (7)$$

$$h_t = o_t * \tanh(C_t) \quad (8)$$

式(3)~式(6)中, W 和 b 分别为不同结构的权重和偏置因子, δ 为 sigmoid 激活函数。接收机网络模型一共采用了 3 层 LSTM,每一层 LSTM 的神经元个数相同,采用的激活函数都是非线性激活函数 Relu。

2) 全连接层

LSTM 层的输出数据被压平为一维后输入到全连接层中。全连接层作为输出层,采用了 sigmoid 激活函数。sigmoid 可以使得输入向量中的每一个实数被映射为 0~1 之间的实数输出。因此,输出向量中的所有值都介于 0~1 之间。注意,由于网络输出的是信息比特,取值为 0 或 1,因此需要对全连接层的输出进行四舍五入。

损失函数是训练的关键。对于分类任务,最常用的损失函数是交叉熵。本文中设置的训练损失函数为二元交叉熵(Binary Cross Entropy),其定义为:

$$Loss = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad (9)$$

其中,批大小为 N , y 是二元标签 0 或者 1, $p(y_i)$ 是输出为 y_i 标签的概率。QPSK 智能接收机模型训练过程如算法 1 所示。

算法 1 QPSK 智能接收机模型训练过程

输入:训练集 D ,批大小为 N ,最大迭代次数 t_{max} ,初始学习率 a

输出:QPSK 智能接收机神经网络模型 M

1. 随机初始化网络参数。
2. for $t=1, 2, \dots, t_{max}$,从 D 中随机选择 N 个样本,输入到网络中进行训练。
3. 根据式(9)中二元交叉熵损失函数的定义计算出损失。
4. 采用 Adam 算法对损失函数进行优化,对全连接神经网络模型进行反向传播训练,更新网络参数。
5. end for

4 性能分析

4.1 参数设置

在本文的参数设置中,对于信道编码,我们使用(7,4)汉明码。本实验中所需要的数据集是通过仿真软件 MATLAB 2022b 生成的,包含训练集、验证集和测试集。数据集中的每个样本的产生过程如下:首先,将 32 位的信息比特流按照(7,4)汉明编码得到 56 位比特流;其次,这 56 位比特流经过 QPSK 调制,得到已调信号;再次,对已调信号先进行根升余弦滤波并采样,采样率设置为 8;然后,采样后的信号再引入加性高斯白噪声、IQ 失衡、频率偏差作为干扰,即可得到干扰失真信号;最后,将得到的干扰失真信号进行采样率为 8 的下采样,即可得到 56 位特征。32 位原始的信息比特流则作为标签。生成数据集的过程中使用的根升余弦滤波器的滚降系数为 0.5。在数据集中,对于每个训练集,信号的信噪比(Signal to Noise Ratio, SNR)范围为 0~7 dB,间隔为 1 dB。每个 SNR 的样本数为 20 万,因此训练集的样本总量为 160 万(20 万×8)。对于每个验证集,信号的信噪比范围也为 0~7 dB,间隔为 1 dB。每个 SNR 的样本数为 2 万,因此验证集的样本总量为 16 万(2 万×8)。对于每个测试集,信号 SNR 的范围为 0~7 dB,间隔为 0.5 dB。每个 SNR 的样本数为 10 万,因此测试集的样本总量为 150 万(10 万×15)。

在仿真实验中,使用 tensorflow2.4.0(CPU)框架完成神经网络模型的训练。训练时采用 Adam 优化方法,批大小设置为 256,迭代次数设置为 10,初始学习率为 0.001。训练时的损失函数为二元交叉熵。为了避免模型过拟合,算法采用了 Keras 中的回调函数 ReduceLROnPlateau,用于学习率的自适应调整。本文设置当迭代次数过去两次而模型的训练损失函数不下降时,下一次迭代时的学习率就会降低为上次学习率的一半。

4.2 网络复杂度分析

QPSK 智能接收机神经网络模型一共有 4 层,其中第 1~3 层均为 LSTM 层,第 4 层是全连接层。各层网络的参数设置以及网络复杂度分析如下。

1)第 1~3 层采用的是 LSTM,LSTM 网络中时间步设置为 56,特征设置为 1。每层 LSTM 均有 32 个神经元。

本文中,LSTM 层参数的计算式可简化为:

$$N = 4 \times ((input_size + cell_size) \times cell_size + cell_size) \quad (10)$$

其中, $input_size$ 指输入数据尺寸; $cell_size$ 指当前 LSTM 层中设置的神经元的数目,为 32;第 1 层输入数据尺寸为 1,因此第 1 层参数总数为:

$$4 \times ((1 + 32) \times 32 + 32) = 4352$$

第 2,3 层输入数据尺寸为 32,其余变量的值与第一层的相同。则第 2,3 层参数总数均为:

$$4 \times ((32 + 32) \times 32 + 32) = 8320$$

2)第 4 层是全连接层,它作为输出层,共有 32 个神经元,采用 sigmoid 激活函数。

本文中,全连接层参数的计算式可简化为:

$$N = input_size \times cell_size + cell_size \quad (11)$$

其中, $input_size$ 为输入本层的数据尺寸大小。由于卷积层

的输出数据经压平为一维后再输入到全连接层,因此输入到本层的尺寸大小为 $56 \times 32 = 1792$ 。 $cell_size$ 为当前本层中设置的神经元的数目,为 32。因此,本层参数总数为:

$$1792 \times 32 + 32 = 57376$$

3) 网络参数总数:

$$4352 + 8320 + 8320 + 57376 = 78368$$

因此, QPSK 智能接收机神经网络模型的网络复杂度为 $O(78368)$ 。经过仿真实验,我们测得 QPSK 智能接收机的训练时长约为 2 h。文献[11]深度接收机的网络复杂度为 $O(1267584)$ 。经过仿真实验,我们测得深度接收机的训练时长约为 6 h。由此可知,本文提出的 QPSK 智能接收机神经网络模型的总参数大约只有深度接收机的 1/16,训练时间大约只有深度接收机的 1/3。因此, QPSK 智能接收机在网络复杂度和训练用时上都比深度接收机更有优势。本文直观地对深度接收机和智能接收机这两种网络模型之间的差异进行了对比,结果如表 1 所列。

表 1 两种网络模型对比

Table 1 Comparison of two network models

类型	深度接收机	智能接收机
初始学习率	0.001	0.001
批量大小	256	256
训练次数	8 次	10 次
优化器	SGD	Adam
损失函数	二元交叉熵	二元交叉熵
网络复杂度	$O(1267584)$	$O(78368)$
模型训练用时/h	约 6	约 2

5 仿真分析

为了体现本文所提出的 QPSK 智能接收机神经网络模型的性能,在进行仿真实验时,本文考虑了影响接收信号质量的 3 个因素:加性高斯白噪声、IQ 失衡、频率偏差。下面给出各因素下的仿真结果。

1) 加性高斯白噪声 (Additive White Gaussian Noise, AWGN)。加性高斯白噪声作为最基本的噪声与干扰模型,被广泛存在于通信信道中。我们首先考虑信号在 AWGN 的干扰条件下接收机的性能。在 SNR 为 $0 \sim 7$ dB 时,本实验对多种检测方案的性能进行了仿真测试,仿真结果如图 3 所示。




图 3 AWGN 条件下,不同检测方案的性能对比

Fig. 3 Performance comparison of different detection schemes under AWGN conditions

图 3 中,理想硬判决指在完美假设下进行解调,然后将解调后的比特流输入到汉明译码器中,不受除 AWGN 以外的其他任何非理想因素影响。理想最大似然决策指具有理想假设的最大似然解码方法,即不受除 AWGN 之外其他任何非理想因素的影响。由于模拟的信息比特流中 0

和 1 的概率分布相等,因此理想最大似然决策的性能也代表了接收机在理想条件下的最佳性能。从图 3 中的曲线可以看出,智能接收机的性能非常接近理想最大似然决策的性能,并远远超过了理想硬判决方法的性能,也超过了深度接收机的性能。这说明本文提出的智能接收机具有接近通信接收机性能极限的潜力。在未经训练的 SNR 上,智能接收机的性能也接近理想最大似然决策的性能,这说明它对 SNR 具有很好的泛化能力。因此,仿真结果反映出 QPSK 智能接收机具有优良的抗 AWGN 性能。

2) IQ 失衡。由于射频设备的非理想性,接收到的 IQ 信号可能会发生 IQ 失衡,也就是 I 信道和 Q 信道的振幅和/或相位不平衡。我们通常会采用一组参数 (α, β) 来描述 IQ 失衡。 α 反映了振幅失衡的程度, β 反映了相位失衡的程度。一般来说, α 或 β 的绝对值越大, IQ 失衡就越严重,接收机接收到的信号的质量也会越差,从而导致误码率升高。在这个仿真实验中,接收机接收到的信号存在 IQ 失衡,我们分析和测试了接收机采用不同检测方案的性能。该实验考虑了 3 种 IQ 失衡配置: $(5, 10)$, $(-3, 10)$ 和 $(-3, -2)$ 。从图 4 中可以看出,采用硬判决方法的接收机的性能受 IQ 失衡影响较大。但是通过对比分析发现, QPSK 智能接收机的性能受 IQ 失衡影响很小。而且,智能接收机的误码率依然很接近理想最大似然决策的结果,并且智能接收机的性能仍然优于深度接收机的性能。因此,仿真结果反映出 QPSK 智能接收机具有较强的抗 IQ 失衡的能力。




图 4 IQ 失衡时,不同检测方案的性能对比

Fig. 4 Performance comparison of different detection schemes when inphase and quadrature imbalance occurs

3) 频率偏差。在无线通信系统中,如果发射机的本地振荡器和接收机的本地振荡器之间存在一些差异,则很可能会引起频率偏差,简称为频偏。当发射机和接收机之间存在相对运动时,就会发生多普勒频移。在以上这些因素的影响下,接收信号与发射信号之间会存在一定的频偏。频偏的存在,会对接收机的正确解调造成一定程度的影响,这极有可能降低信息恢复的准确程度,从而导致误码率升高。在这个实验中,我们研究了当存在频偏时,采用智能接收机和其他方法对接收信号进行检测的性能。在仿真实验中,归一化载波频率偏移量 δ_f (相对于符号率) 分别设置为 0.001, 0.002, 0.004。图 5 给出了用测试集对不同检测方案进行测试所得出的结果。通过对比可以看出,采用传统硬判决方法,接收机受频偏的影响很大,因此抗频偏能力差。尤其是当 $\delta_f = 0.004$, SNR 在 $0 \sim 7$ dB 范围内时,使用硬判决方法的误码率超过了 0.01,难以达到实际的通信传输质量要求。但从图 5 中可以看出,随着频偏的增加, QPSK 智能接收机的性能只受到很小的影响。同时,它的性能仍然优于深度接收机的性能,且接近理想

最大似然决策的性能。因此,仿真结果反映出 QPSK 智能接收机具有很强的抗频偏能力。




图5 发生频偏时,不同检测方案的性能对比

Fig. 5 Performance comparison of different detection schemes when frequency offset occurs

结束语 针对 QPSK 接收机检测信号准确率低以及复杂度高的问题,本文提出了一种基于 LSTM 神经网络的 QPSK 智能接收机设计方案。该方案中的神经网络模型由 LSTM 和全连接层构成,充分利用了 LSTM 能提取接收信号的时间相关性这一特点。仿真实验结果表明,本文提出的 QPSK 智能接收机相比传统接收机和深度接收机而言,不仅算法复杂度得到了降低,检测性能也得到了很大提升。

参考文献

- [1] MILEANT A, HINEDI S. On the effects of phase jitter on QPSK lock detection [J]. IEEE Transactions on Communications, 1993, 41(7): 1043-1046.
- [2] XIA J J, DENG D, FAN D. A note on implementation methodologies of deep learning-based signal detection for conventional MIMO transmitters [J]. IEEE Transactions on Broadcasting, 2020, 66(3): 744-745.
- [3] ZHANG Y B, WANG J, SUN J L, et al. CV-3DCNN: complex-valued deep learning for CSI prediction in FDD massive MIMO systems [J]. IEEE Wireless Communications Letters, 2021, 10(2): 266-270.
- [4] WANG J, GUI G, OHTSUKI T, et al. Compressive sampled CSI feedback method based on deep learning for FDD massive MIMO systems [J]. IEEE Transactions on Communications, 2021, 69(9): 5873-5885.

- [5] HUANG H J, SONG Y W, YANG J, et al. Deep-learning-based millimeter-wave massive MIMO for hybrid precoding [J]. IEEE Transactions on Vehicular Technology, 2019, 68(3): 3027-3032.
- [6] MA W Y, QI C H, ZHANG Z C, et al. Sparse channel estimation and hybrid precoding using deep learning for millimeter wave massive MIMO [J]. IEEE Transactions on Communications, 2020, 68(5): 2838-2849.
- [7] FANG L, WU L. Deep learning detection method for signal demodulation in short range multipath channel [C] // 2017 IEEE 2nd International Conference on Opto-Electronic Information Processing (ICOIP), 2017: 16-20.
- [8] SHENTAL O, HOYDIS J. "Machine LLRning": Learning to softly demodulate [J]. arXiv:1907.01512, 2019.
- [9] NARIMAN F, ANDREA G. Neural network detection of data sequences in communication systems [J]. IEEE Transactions on Signal Processing, 2018, 66(21): 5663-5678.
- [10] XU W, ZHONG Z, BE'ERY Y, et al. Joint neural network equalizer and decoder [C] // 2018 15th International Symposium on Wireless Communication Systems (ISWCS), 2018: 1-5.
- [11] ZHENG S, CHEN S, YANG X. DeepReceiver: A Deep Learning-Based Intelligent Receiver for Wireless Communications in the Physical Layer [J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(1): 5-20.
- [12] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory [J]. Neural Computation, 1997, 9: 1735-1780.



ZHU Li, born in 2002. His main research interests include communication receiver and deep learning.



HAN Huimen, born in 1990, Ph.D. graduate supervisor. Her main research interests include random access schemes for massive MIMO systems, machine-to-machine communications, machine learning, intelligent reflecting surface, and federated learning.