

# 基于深度学习的 QPSK 智能接收机模型研究

朱力, 韩会梅, 彭宏

(浙江工业大学 信息工程学院, 杭州 310023)

**摘要:** 针对通信信道中存在噪声等干扰因素时, QPSK 接收机解调接收信号性能较差的问题, 文章研究了一种基于深度学习的 QPSK 智能接收机模型; 该 QPSK 智能接收机模型由 LSTM 神经网络和全连接层构成, 借助了递归神经网络中的内存结构, 也利用了 LSTM 能提取接收信号的时间相关性这一特点; 在信噪比为 0~7 dB 的条件下进行仿真实验, 实验结果表明, 在加性高斯白噪声, 同相和正交失衡以及频率偏差干扰因素影响下, 文章研究的 QPSK 智能接收机模型在 0~7 dB 时的误码率相比于使用传统硬判决方法的通信接收机的误码率得到了显著降低; 其中, QPSK 智能接收机模型在 7 dB 时的误码率低至 0.010 9%, 大约只有传统硬判决方法误码率的 1/7; 在发生频偏及同相和正交时, QPSK 智能接收机模型在 7 dB 时的误码率分别低至 0.014 7% 和 0.019 8%, 都远低于相同条件下传统硬判决方法的误码率; 因此, 采用研究出来的 QPSK 智能接收机模型能够显著提高接收机的检测性能。

**关键词:** 深度学习; LSTM 神经网络; 全连接层; QPSK 调制; 智能接收机

## Research on QPSK Intelligent Receiver Model Based on Deep Learning

ZHU Li, HAN Huimei, PENG Hong

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China)

**Abstract:** Aimed at the interference factors of noise in communication channels and poor performance of quadrature phase shift keying (QPSK) receiver demodulating received signals. In view of the problem, a QPSK intelligent receiver model based on deep learning is studied. The QPSK intelligent receiver model is composed of the long and short-term memory (LSTM) neural network and fully connected layer. With the help of the memory structure in the recurrent neural network, LSTM is also used to extract the characteristic of the temporal correlation for the received signal. Simulation experiments is conducted under the condition of a signal-to-noise ratio of 0 to 7 dB, the experimental results show that under the influences of Gaussian white noise, in-phase and quadrature imbalance, and frequency deviation interference factors, and compared with the traditional hard decision method, the bit error rate of the proposed QPSK intelligent receiver model with the signal-to-noise ratio of 0 to 7 dB is significantly reduced. Among them, the bit error rate of QPSK intelligent receiver model at the signal-to-noise ratio of 7 dB is as low as 0.010 9%, which is only about 1/7 of the bit error rate of the traditional hard decision method. In the conditions of frequency deviation and IQ imbalance, the bit error rate of QPSK intelligent receiver model at the signal-to-noise ratio of 7 dB is as low as 0.014 7% and 0.019 8%, respectively, which are much lower than the bit error rate of the traditional hard decision method under the same condition. Therefore, the proposed QPSK intelligent receiver model can significantly improve the detection performance of the receiver.

**Keywords:** deep learning; LSTM neural network; fully connected layer; QPSK modulation; intelligent receiver

## 0 引言

正交相移键控<sup>[1]</sup>技术 (QPSK, quadrature phase shift keying) 作为一种频谱利用率高、抗干扰强、电路实现较为简单的数字调制方式, 在无线通信领域中应用广泛。在通信传输过程中, QPSK 已调信号受到信道噪声等干扰后会

出现失真。这种干扰失真信号到达接收机端时, 必须经过接收机的解调和译码等相关过程处理之后, 才可能恢复出所需要的原始信息。因此, 接收机在整个通信系统中发挥着极其重要的作用, 它决定着能否正确恢复出所需要的原始信息, 也就决定着通信质量的好坏。

对于传统的 QPSK 接收机而言, 通常采用硬判决方法

收稿日期: 2023-03-28; 修回日期: 2023-04-23。

基金项目: 国家自然科学基金(62001419)。

作者简介: 朱力(2002-), 男, 大学本科。

彭宏(1970-), 女, 硕士, 副教授。

通讯作者: 韩会梅(1990-), 女, 博士, 讲师。

引用格式: 朱力, 韩会梅, 彭宏. 基于深度学习的 QPSK 智能接收机模型研究[J]. 计算机测量与控制, 2024, 32(2): 213-218.

解调接收到的失真信号，解调后再经过译码等过程才能恢复出原始信息。但采用这种方法时，接收机处理每个模块时的算法通常是基于理论假设的，如假设不存在共信道干扰以及射频器件是理想的，即不会发生射频损伤等。但这些假设并不一定与接收机所经历的实际过程相符。因此，传统的 QPSK 接收机优化的是在理想假设情况下的最佳性能，但在实际通信时很难达到这种最佳性能。因此，传统的 QPSK 接收机还存在较大的提升空间。

近些年来，随着科学技术的发展，深度学习在计算机视觉、自动控制技术、自然语言处理等众多领域得到了广泛应用，并不断取得新的突破：人脸识别、无人驾驶和 ChatGPT 等，这也引起了科研工作者的广泛关注。在无线通信领域，使用深度学习对通信的研究也越来越多，例如信号检测<sup>[2]</sup>、预编码<sup>[3]</sup>以及信道状态信息反馈<sup>[4-6]</sup>等。由此可以推测，传统无线通信接收机存在的不足也很可能因为深度学习的应用而得到一定程度上的改进。

下面介绍目前与信号解调有关的一些研究结果。在文献 [7-8] 中，LoRa 算法可应用于物理层的解调，但是该算法仅能解调一个扩频信道的数据包。同时，对于相同的扩频信道而言，LoRa 基带信号之间容易发生严重干扰。对于不同的扩频信道而言，它们之间并不能达到完全正交。同相正交 (IQ, inphase and quadrature) 调制器容易出现偏置不理想、光电探测器的响应度失配以及混频器不满足共轭对称性等问题<sup>[9]</sup>。因此，在接收机端也容易发生正交失衡，从而会对 QPSK 信号的正确解调造成影响，导致系统的性能下降。因此，为了消除其影响，需要采用特定的补偿算法<sup>[10-11]</sup>。为了让相干接收机输出的两路信号之间的相位相互正交，从而达到精确地解调出原始信号的目的，文献 [12] 首先采用了施密特正交化算法对相干接收机输出的两路信号进行了理论上的分析，再通过进行具体实验加以验证。实验结果表明，输出的两路信号经过正交失衡算法补偿后，所得到的星座图的性能得到了较大的提高。文献 [13] 中使用了深度信念网络和堆叠的自动编码器来完成短距离多径信道中的信号解调。除硬解调外，文献 [14] 还采用深度神经网络实现软解调，降低了计算复杂度，提高了解调性能。文献 [15] 中使用了双向递归神经网络 (BRNN, bidirectional recurrent neural network) 进行数据序列检测，但在 BRNN 中的解调之后没有包含信道译码模块。从现有的研究结果来看，目前研究的通信接收机几乎没有考虑通信系统在频率偏差和 IQ 失衡等干扰因素下的性能，但这些干扰因素在实际条件下经常存在，从而会干扰接收机的解调过程，最终对通信系统的性能造成较大影响。

为了解决现有 QPSK 通信接收机技术中存在的因信道噪声、频率偏差、IQ 失衡等干扰导致现有 QPSK 通信接收机的解调性能较差的问题，本文将目前广泛应用于计算机视觉、自然语言处理等领域的深度学习 (DL, deep learning) 技术<sup>[16]</sup>引入到 QPSK 通信接收机模型的研究中。采用

深度学习是因为它是一种端到端的方法，与其他机器学习方法<sup>[17-19]</sup>相比，它可以从大量数据中学习更深层次的特征。因此，本文研究了一种新的接收机模型，即基于深度学习的 QPSK 智能接收机模型，用来取代传统的 QPSK 接收机的解调过程。仿真结果表明，当已调信号受到加性高斯白噪声、频率偏差和 IQ 失衡干扰因素影响时，与使用传统的硬判决方法进行解调相比，使用本文所研究出的 QPSK 智能接收机模型能够显著提升解调性能。

## 1 系统模型

一个常见的 QPSK 通信系统如图 1 所示，该系统包括发射机、信道和接收机。首先，在发射机端，原始发送信号经过信源编码、信道编码和 QPSK 调制后成为已调信号。然后，已调信号在信道中传输。由于实际的通信信道中存在着信道噪声等非理想因素的影响，QPSK 已调信号经过信道传输后，到达接收机端时会发生失真。接收机需要对受到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原始的发送信号。

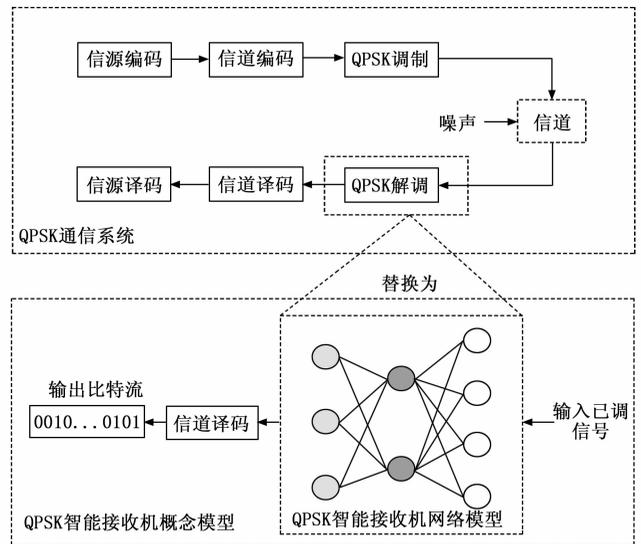


图 1 QPSK 通信系统和 QPSK 智能接收机概念模型

在本文中，我们考虑了影响接收机信号质量的 3 种因素：

1) 加性高斯白噪声 (AWGN, additive white gaussian noise): 由于大气中存在热噪声，通信系统中的电子元器件在工作时也会产生噪声。因此，接收机接收到的已调信号将包含一定量的噪声。噪声和信号混杂在一起，会对信号的正确恢复造成一定的影响。最常见的噪声是加性高斯白噪声，从统计上来说它属于随机无线噪声，特点是其通信信道上的信号分布在很宽的频带范围内。

2) 频率偏差: 发射机和接收机本地振荡器之间的差异将导致接收信号产生频率偏差，简称频偏。频率是无线通信中比较重要的一个性能指标，存在频率偏差的信号会影响到接收机的正确解调，这很可能会导致信息恢复的准确

程度降低。一般而言, 频偏越大, 通信系统在传输信号时的通信质量就越差。

3) IQ 失衡: 由于温度依赖性、生产缺陷和老化, I 路径和 Q 路径中的模拟分量无法完美匹配。IQ 失衡包括幅度和相位上的失衡。IQ 失衡是一个很严重的问题, 它会导致产生镜像产物, 从而影响接收机的吞吐率、解调性能等。另外, 在实际的硬件电路中, 设备本身的物理限制和电路设计出错均可能会导致 I 信号和 Q 信号的相位和振幅不一致, 从而产生 IQ 失衡。

## 2 QPSK 智能接收机模型研究

本文所研究的 QPSK 智能接收机模型由长短期记忆 (LSTM, long short-term memory) 神经网络和全连接层这两种模块组成, 如图 2 所示。

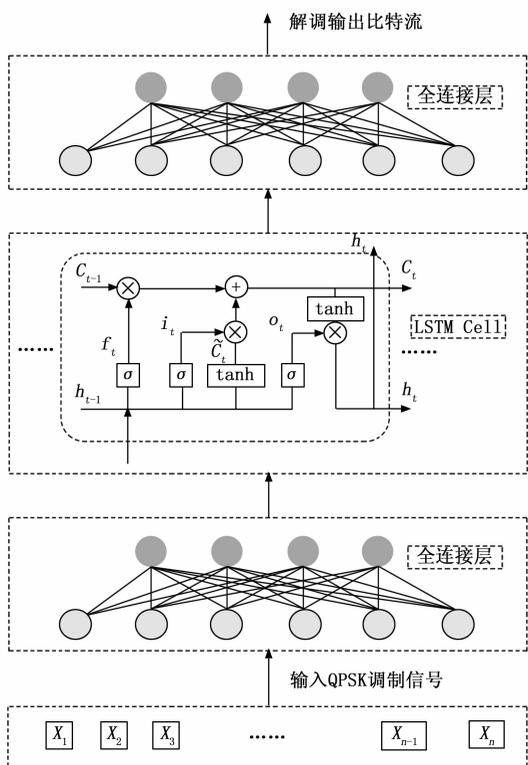


图 2 QPSK 智能接收机模型

图 2 中的 LSTM 神经网络是在递归神经网络 (RNN, recurrent neural network) 拓扑结构的基础上加以改进得来的<sup>[20]</sup>。作为一种性能优越的循环神经网络, LSTM 不仅具有长时记忆功能、实现起来容易, 还可以有效防止长序列训练过程中存在的梯度爆炸和梯度消失问题。因此, LSTM 在执行预测任务的时候具有独特的优势。图 2 中的全连接层则用于增强模型的非线性表达能力, 从而进一步提升整个网络模型的性能。模型中的 LSTM 神经网络我们最终只采用了一层, 是因为我们在进行实验研究的过程中发现: 随着 LSTM 层数的增加, 模型总参数会显著增加, 模型复杂度会大大增加, 训练用时也会变得漫长, 且容易发生过

拟合, 导致最终的模型训练效果不理想。但是, 当全连接层采用两层时, 模型的复杂度不会有很大的增加, 但是整个网络模型的性能相比于只采用一层全连接层会有较大的提高。我们综合考虑了 QPSK 智能接收机模型的复杂度以及模型的最终性能, 研究出了图 2 中的 QPSK 智能接收机模型。

在本文中, 我们将原始信息经过 QPSK 调制以及引入 AWGN 等干扰因素处理后的信号简记为 QPSK 调制信号  $X_t = [X_1, X_2, \dots, X_n]$ 。将  $X_t = [X_1, X_2, \dots, X_n]$  作为 QPSK 智能接收机模型的输入。输入该模型的信号经过模型处理后, 输出的即为解调后的信息比特流, 取值为 0 或 1。该模型用到的 LSTM 和全连接层模块的具体介绍如下。

### 1) LSTM:

如图 2 所示, 一层 LSTM 由多个 LSTM Cell 组成, LSTM Cell 是 LSTM 的一个单元, 每个 LSTM Cell 相当于一个时间步的处理。其中, 一个 LSTM 单元包括输入门  $i_t$ 、输出门  $o_t$  和遗忘门  $f_t$ 。输入门  $i_t$  控制当前时刻的候选状态  $\tilde{C}_t$  有多少信息需要保存, 输出门  $o_t$  控制当前单元状态  $C_t$  有多少信息需要输出给外部状态, 遗忘门控制上一个时刻的内部状态  $\tilde{C}_{t-1}$  需要遗忘多少信息。这 3 种门都是通过对隐藏状态  $h_t$  和输入  $X_t$  应用  $\delta$  函数得到的。使用 sigmoid 激活函数进行选择, 并使用 tanh 函数进行变换。

LSTM 在整个时间序列中均需要通过门更新状态单元中的信息。在每个时间状态下, 根据当前时刻的候选状态  $\tilde{C}_t$  和上一个时刻的内部状态  $\tilde{C}_{t-1}$  来更新当前单元状态  $C_t$ 。根据隐藏状态  $h_t$  可以得到输出。在第  $t$  个时间步, LSTM Cell 中各模块中存在的关系式如下:

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

$$f_t = \delta(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (2)$$

$$o_t = \delta(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, X_t] + b_c) \quad (4)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

式 (1) ~ (4) 中,  $W_i, W_f, W_o, W_c$  和  $b_i, b_f, b_o, b_c$  分别为对应结构的权重系数和偏置项,  $\delta$  为 sigmoid 激活函数。激活函数  $\delta(x)$  和  $\tanh(x)$  可分别表示为:

$$\delta(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$

QPSK 智能接收机神经网络模型中用到了一层 LSTM, 该层的激活函数为非线性激活函数 Relu。

### 2) 全连接层:

全连接层在本文中作为输入层以及最后的输出层。作为输入层时, 经过 QPSK 调制后的已调信号会进入到该全连接层作为输入, 全连接层对已调信号进行处理后再输入到 LSTM 层。全连接层作为输出层时, 用于综合所有信息,

采用了 sigmoid 激活函数, 以实现分类的功能。sigmoid 函数可以将输入向量中的每一个实数映射为 0~1 之间的实数输出。因此, 输出向量中的所有值都在 0~1 之间。由于网络输出的是解调后的比特流, 取值为 0 或 1, 因此, 我们需要对全连接层的输出结果进行四舍五入。四舍五入后得到的数据再进行信道译码即可恢复出所需要的原始信息。

损失函数在神经网络模型训练过程中起着重要的作用。当执行分类任务时, 通常采用的损失函数为交叉熵。在本文中, 我们采用的训练损失函数为二元交叉熵 (Binary cross entropy)。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  $N$ ,  $y$  为二元标签 0 或 1,  $p(y_i)$  为输出是  $y_i$  标签的概率。下面给出 QPSK 智能接收机模型训练的具体过程。

QPSK 智能接收机模型训练过程:

输入: 训练集  $T$ , 批大小为  $n$ , 最大迭代次数设置为  $t_{\max}$ , 初始学习率为  $lr$ 。

输出: QPSK 智能接收机神经网络模型  $M$ 。

a) 随机初始化所搭建的网络模型的参数。

b) for  $t = 1, 2, 3, \dots, t_{\max}$ :

c) 从  $T$  中随机选择  $n$  个样本, 输入到该网络模型中进行训练。

d) 根据式(9)中二元交叉熵损失函数的定义计算出损失。

e) 用 Nadam 算法对损失函数进行优化, 对搭建的神经网络模型进行反向传播训练, 并更新网络参数。

f) end for。

### 3 模型参数设置及复杂度分析

#### 3.1 参数设置

在本文的参数设置中, 对于信道编码环节, 本文采用了 (7, 4) 汉明码编码。因为汉明码是一种高效的线性分组码, 在实际生活中的应用也比较广泛。仿真实验中所用到的数据集均通过仿真软件 Matlab 2022b 生成, 包含训练集和测试集。数据集中的每个样本的产生过程为: 首先, 将 32 位原始信息比特流进行 (7, 4) 汉明编码得到 56 位的汉明码比特流; 然后, 将得到的 56 位汉明码比特流经过 QPSK 调制, 即可得到已调信号; 之后, 对已调信号先进行根升余弦升滤波并采样, 采样率设置为 8; 然后, 对采样后的信号引入加性高斯白噪声、频率偏差、IQ 失衡作为干扰, 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 的降采样, 即可得到 56 位特征向量。56 位汉明码比特流则作为特征向量所对应的标签。此外, 生成数据集中用到的根升余弦滤波器的滚降系数设置为 0.5。在生成好的数据集中, 对于每个训练集, 信号的信噪比 (SNR, signal to noise ratio) 范围为 0~7 dB, 间隔为 1 dB。每个 SNR 的样本量为 20 万, 因此训练集总样本量为 160 万 (即 20 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 的样本量为 10 万, 因此测试集的总样本量为 150 万 (即 10 万×15)。

仿真实验时, 神经网络模型的训练在 tensorflow2.4.0 (CPU) 框架上完成。训练时采用 Nadam 优化方法。迭代次数设置为 100 次, 批大小设置为 256, 初始学习率设置为 0.001。为了防止模型出现过拟合, 算法还引入了 Keras 中的回调函数 ReduceLRonPlateau, 它可以让学习率在训练过程中实现自适应调整。本文设置为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调整为上次学习率的一半。

#### 3.2 网络复杂度分析

QPSK 智能接收机模型一共有 3 层网络。其中, 第 1 层是全连接层, 作为输入层; 第 2 层为 LSTM 层, 作为中间层; 第 3 层也是全连接层, 作为输出层。各层网络的具体参数设置以及网络复杂度分析如下:

1) 第 1 层是全连接层, 它作为输入层, 共有 128 个神经元, 采用 sigmoid 激活函数, 输入信息长度为 56 位。

在本文中, 全连接层参数计算公式可简化为:

$$N = Input\_size \times Cell\_size + Cell\_size \quad (10)$$

其中:  $Input\_size$  为输入本层的数据尺寸大小。由于输入的数据序列为一维, 因此  $Input\_size$  即为输入信息长度 56, 以下类似。 $Cell\_size$  为本层中的神经元数目, 为 128。因此本层参数总数为:

$$56 \times 128 + 128 = 7296;$$

2) 第 2 层采用的是 LSTM, 共有 128 个神经元。

在本文中, LSTM 层参数计算公式可简化为:

$$N = 4 \times ((Input\_size + Cell\_size) \times Cell\_size + Cell\_size) \quad (11)$$

其中:  $Input\_size$  指的是输入数据尺寸大小, 即为第 1 层的输出尺寸大小 128。 $Cell\_size$  指的是当前 LSTM 层中设置的神经元的数目, 为 128。因此第 2 层参数总数为:

$$4 \times ((128 + 128) \times 128 + 128) = 131584;$$

3) 第 3 层是全连接层, 它作为输出层, 采用 sigmoid 激活函数。本层参数的计算公式见式 (8)。其中, 输入本层的数据尺寸大小为 128。本层中设置的神经元的数目为 56。因此本层参数总数为:

$$128 \times 56 + 56 = 7224;$$

4) 网络参数总数:

$$7296 + 131584 + 7224 = 146104;$$

因此 QPSK 智能接收机模型的网络复杂度为  $O(146104)$ 。

### 4 仿真实验与结果分析

在本文的仿真实验中, 我们考虑了影响接收机接收到的信号质量的 3 个因素: 加性高斯白噪声、频率偏差、IQ 失衡。以下为与之对应的 3 个仿真实验的仿真结果, 以展示 QPSK 智能接收机模型的性能, 具体分析如下。

1) 加性高斯白噪声 (AWGN): AWGN 作为最基本的

信道噪声干扰模型, 在通信信道中十分常见。我们首先考虑 QPSK 智能接收机模型在 AWGN 下的性能。在 SNR 为 0~7 dB, 且没有其他的影响因素干扰时, 我们在搭建好的深度学习环境中对 QPSK 智能接收机模型进行了训练。训练好后, 我们对它进行了测试, 测试结果如图 3 所示。为了进行比较, 本实验也测试了在相同条件下使用理想硬判决和理想最大似然决策时接收机的性能。其中, 理想硬判决是指在理想假设条件下解调, 然后将解调输出的比特流输入到汉明译码器中, 不受除 AWGN 以外的其它任何因素影响的硬判决方法。理想最大似然决策是指具有理想假设的最大似然译码方法, 即在除 AWGN 之外没有其它任何非理想因素的干扰。由于模拟的信息比特流遵循相等的概率分布, 理想最大似然决策即为理想条件下的 QPSK 接收机所能达到的最佳性能。图 3 中, QPSK 智能接收机模型在 7 dB 时的误码率低至 0.0109%, 而传统硬判决方法误码率约为 0.0772%。因此, QPSK 智能接收机模型在 7 dB 时的误码率大约只有传统硬判决方法误码率的 1/7。从图 3 中可以看出, QPSK 智能接收机模型的整体性能非常接近理想最大似然决策的性能, 明显优于传统的硬判决方法, 这反映出本文研究的智能接收机模型具有接近通信接收机性能极限的潜力。在未经训练的 SNR 上, 智能接收机模型也达到了接近理想最大似然决策的性能, 表明它对 SNR 具有良好的泛化能力。

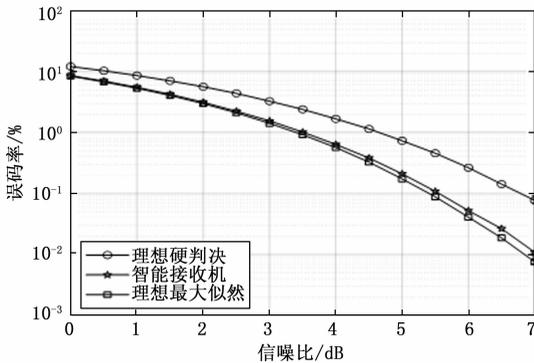


图 3 AWGN 条件下, 不同方案的性能对比

2) 频率偏差: 在无线通信系统中, 在发射机和接收机上分别使用两个独立的本地振荡器。它们的频率可能有一定的偏差。此外, 当发射机和接收机之间存在相对运动时, 会导致多普勒频移。在这些因素的影响下, 接收信号与发射信号之间会有一定的频率偏差。在这一个实验中, 我们分析了信号在存在频率偏差时 3 种解调方法的性能。在仿真中, 归一化载波频率偏移量  $\delta f$  (相对于符号率) 分别设置为 0.001、0.002 和 0.004, 其他设置与之前仿真时的设置相同。与第一个实验类似, 我们先训练 QPSK 智能接收机模型, 训练好后再对它进行测试, 图 4 为 QPSK 智能接收机模型的测试结果。与采用传统的硬判决方法进行解调相比较, 可以看出, 传统的硬判决方法受频偏的影响很大。

随着频偏的增加, 采用传统硬判决方法进行解调的 QPSK 接收机的性能显著下降。由图 4 可知, 当  $\delta f=0.004$  时, SNR 在 0~7 dB 范围内时, 采用传统硬判决方法进行解调的 QPSK 接收机的误码率高于 1%。这在实际的通信过程中难以被接受。对比而言, QPSK 智能接收机模型在 7 dB 时的误码率低至 0.0148%, 而且受载波频率偏差的影响则很小, 随着载波频率偏差的增加, 它的性能只是略有下降, 误码率依然处于很低的水平, 且十分接近理想最大似然决策的性能, 反映出 QPSK 智能接收机模型具有很强的抗频偏能力。

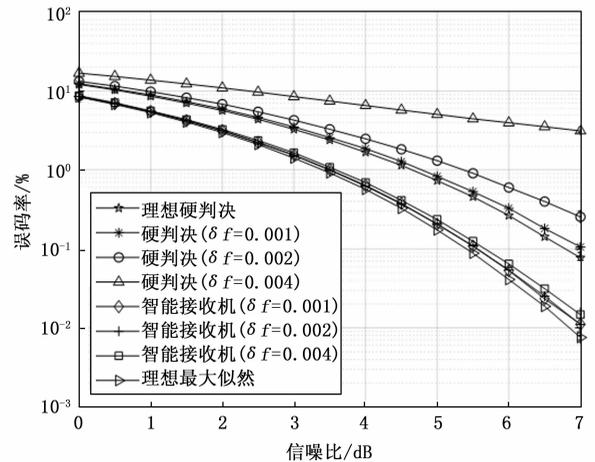


图 4 出现频偏时, 不同方案的性能对比

3) IQ 失衡: 由于射频设备的非理想性, 接收到的 IQ 信号可能存在 IQ 失衡, 即 I 信道和 Q 信道的振幅和/或相位不平衡。IQ 失衡可以用一组参数  $(\alpha, \beta)$  来描述, 其中  $\alpha$  代表振幅失衡,  $\beta$  代表相位失衡。存在 IQ 失衡的已调信号在信道中传输的过程中会发生失真, 从而导致接收机接收到的信号的质量变差, 进而导致误码率升高。在这一个实验中, 我们分析了信号存在 IQ 失衡时 3 种解调方法的性能。本实验一共考虑了 3 种 I 失衡配置:  $(5, -6)$ 、 $(-3, 10)$  和  $(-3, -2)$ 。其他设置与第一个仿真实验时的设置相同。与上两个实验类似, 我们先训练 QPSK 智能接收机模型, 训练好后再对它进行测试, 图 5 为 QPSK 智能接收机模型的测试结果。从图 5 中可以看出, 采用硬判决方法进行解调的接收机性能受 IQ 失衡影响较大, 误码率也有较大的升高, 整体性能不佳。而 QPSK 智能接收机模型的误码率依然处于很低的水平, 在 7 dB 时的误码率低至 0.0198%。在不同 IQ 失衡配置的情况下, QPSK 智能接收机模型的性能几乎稳定不变, 且十分接近理想最大似然决策的性能。从该实验的结果中可以得出 QPSK 智能接收机模型具有优良的抗 IQ 失衡的能力。

## 5 结束语

为了解决因信道噪声、频率偏差、IQ 失衡等干扰导致的现有 QPSK 通信接收机的解调性能较差的问题, 本文研

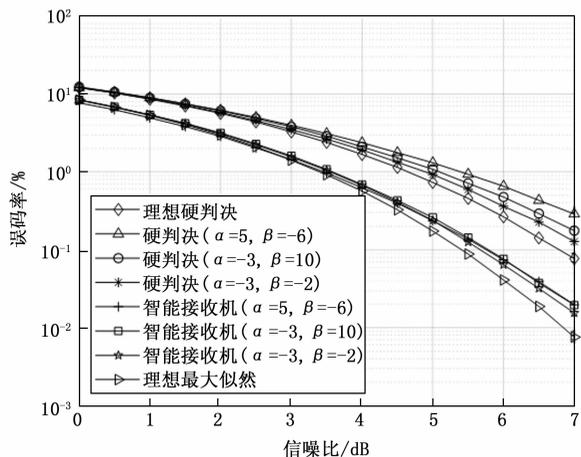


图 5 IQ 失衡时, 不同方案的性能对比

究了一种基于深度学习的 QPSK 智能接收机模型, 用于替换传统通信接收机的解调环节。该神经网络模型主要由 LSTM 和全连接层构成, 借助了递归神经网络中的内存结构, 也利用了 LSTM 能提取接收信号的时间相关性这一特点, 从而提高接收机的性能。本文在加性高斯白噪声、频率偏差、IQ 失衡 3 种干扰条件下进行了仿真实验。仿真结果表明, 与使用传统的硬判决方法进行解调相比, QPSK 智能接收机模型的性能有很大提高。因此, 本文研究出的 QPSK 智能接收机模型具有一定的实用价值, 很有可能在未来的通信领域得到一定程度上的应用。

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] 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.

[4] 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.

[5] 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.

[6] 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.

[7] CROCE D, GUCCIARDO M, MANGIONE S, et al. Impact of LoRa imperfect orthogonality: analysis of link-level performance [J]. IEEE Communications Letters, 2018, 22 (4): 796 - 799.

[8] BELTRAMELLI L, MAhMooD A, ÖSTERBERG P, et al. LoRa beyond ALOHA: an investigation of alternative random access protocols [J]. IEEE Transactions on Industrial Informatics, 2021, 17 (5): 3544 - 3554.

[9] CHUNG H S, SUN H C, KIM K, et al. Effects of carrier phase estimation on front-end IQ mismatch compensation in DP-QPSK coherent receiver [C] // Optoelectronics and Communications Conference Held Jointly with 2013 International Conference on Photonics in Switching. New York, USA: IEEE, 2013.

[10] SAVORY S J. Digital coherent optical receivers: algorithms and sub-systems [J]. IEEE Journal of Selected Topics in Quantum Electronics, 2010, 16 (5): 1164 - 1179.

[11] WANG X J, LEIBLE B, WANG W H, et al. Joint IQ imbalance compensation and channel estimation in coherent optical OFDM systems [C] // 2016 10th International Conference on Signal Processing and Communication Systems. New York, USA: IEEE, 2016: 1 - 6.

[12] 李鹏霞, 柯熙政. 相干光通信系统中 QPSK 调制解调实验研究 [J]. 激光技术, 2019, 43 (4): 127 - 132.

[13] FANG L, WU L. Deep learning detection method for signal demodulation in short range multipath channel [C] // IEEE International Conference on Opto-electronic Information Processing, IEEE, 2017: 16 - 20.

[14] SHENTAL O, HOYDIS J. "Machine Learning": Learning to Softly Demodulate [C] // 2019 IEEE Globecom Workshops (GC Wkshps), Waikoloa, HI, 2019: 1 - 7.

[15] NARIMAN F, ANDREA G. Neural network detection of data sequences in communication systems [J]. IEEE Transactions on Signal Processing, 2018, 66 (21): 5663 - 5678.

[16] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521 (7553): 436 - 444.

[17] QIU J, WU Q, DING G, et al. A survey of machine learning for big data processing [J]. EURASIP Journal on Advances in Signal Processing, 2016, 2016 (1): 1 - 16.

[18] SIMEONE O. A very brief introduction to machine learning with applications to communication systems [J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4 (4): 648 - 664.

[19] ZHENG S, CHEN S, YANG L, et al. Big data processing architecture for radio signals empowered by deep learning: Concept, experiment, applications and challenges [J]. IEEE Access, 2018, 6 (6): 5907 - 5922.

[20] BUKHARI A H, RAJA M, SULAIMAN M, et al. Fractional neuro-sequential ARFIMA-LSTM for financial market forecasting [J]. Computers, Networks & Communications, 2020 (99): 1.