

文章编号: 1005-5630(2023)06-0060-08

DOI: 10.3969/j.issn.1005-5630.202302260027

基于改进型 Transformer 网络的高阶 QAM 调制分类研究

安 移, 项 澜

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 针对高阶正交振幅调制(quadrature amplitude modulation, QAM)信号难以调制分类的问题, 提出了一种基于改进型 Transformer 的深度学习调制分类方法, 通过并行 2 个 Transformer 的编码器, 分析了在加性高斯白噪声(additive white Gaussian noise, AWGN)信道下, 从 4 QAM 到 4 096 QAM 的 10 种调制格式在信噪比从 -10 dB 到 30 dB 的自动调制分类效果。首先将 QAM 信号的正交、同相分量提取出来并进行预处理操作, 再将预处理过的同相分量和正交分量分别通过 2 个 Transformer 编码器来提取分量特征, 最后将 2 个提取到的分量特征进行组合来判断 QAM 信号的调制格式。实验结果证明: 在没有载波频率偏移影响且信噪比大于 20 dB 时, 网络可以准确识别出 10 种 QAM 调制格式; 在载波频率偏移为 500 Hz 且信噪比大于 26 dB 时, 网络对 10 种 QAM 调制格式的分类准确率高于 98.6%。

关键词: QAM; 智能通信; Transformer 网络; AWGN 信道; 自动调制分类
中图分类号: TN 914 **文献标志码:** A

Research on classification of high order QAM modulation with improved Transformer network

AN Yi, XIANG Lan

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: In communication systems, the modulation classification of high order quadrature amplitude modulation signals is a difficult problem. An improved Transformer deep learning modulation classification method is proposed in this paper. The network parallelizes two Transformer encoders. In the additive Gaussian white noise channel, the automatic modulation classification effect of 10 modulation formats ranging from 4 QAM to 4 096 QAM with SNR ranging from -10 dB to 30 dB was analyzed. First, the quadrature and in-phase components of the QAM signal were extracted and preprocessed. Then the preprocessed in-phase component and quadrature component pass through two Transformer encoders to extract component features.

收稿日期: 2023-02-26

基金项目: 国家自然科学基金(61805144)

第一作者: 安移(1997—), 男, 硕士研究生, 研究方向为信号调制分类。E-mail: 202430391@st.usst.edu.cn

Finally, the two extracted component features were combined to judge the modulation format of the QAM signal. The experimental results prove that the network can accurately identify 10 kinds of QAM modulation formats when there is no influence of carrier frequency offset and the signal-to-noise ratio is greater than 20 dB. When the carrier frequency offset is 500 Hz and the signal-to-noise ratio is greater than 26 dB, the classification accuracy of the 10 kinds of QAM modulation formats is higher than 98.6%.

Keywords: QAM; intelligent communication; Transformer network; AWGN channel; automatic modulation classification

引 言

随着 5G, 6G 等通信技术的快速发展, 用户对通信速率的要求变得越来越高^[1]。高阶正交振幅调制 (quadrature amplitude modulation, QAM) 信号可以提高单个符号所携带的比特量, 因此可以通过增加 M 阶 QAM 信号的调制数 M 来提高通信速率。随着调制数 M 的不断增大, QAM 信号的调制格式变得越来越多, 为了在接收端准确地恢复出原始发送信号, 就需要对接收到的 QAM 信号进行调制分类。

目前针对 QAM 信号的调制分类的主流方式有 2 种: 基于特征提取的分类方法和基于深度学习的分类方法。文献 [2] 通过对信号进行希尔伯特变换来获得信号的瞬时包络, 然后提取瞬时能量分布向量作为特征向量来对 QAM 信号进行调制分类。文献 [3] 通过计算 QAM 信号矢量图的最小环带方差进行 QAM 信号的调制分类。文献 [4] 通过聚类算法并结合模板匹配来对 QAM 信号进行调制分类。文献 [5] 通过信号的四阶累积量以及减法聚类等方法识别 QAM 信号的调制格式。文献 [6] 通过模糊 C 均值与反向传播 (back propagation, BP) 神经网络相结合来对 QAM 信号进行调制分类。文献 [7] 研究了卷积神经网络模型和特征参数结合深度神经网络模型对 QAM 信号的调制分类效果。文献 [8] 通过密集连接网络来对 QAM 信号进行调制分类。

上述国内外研究现状为调制识别提供了丰富的研究基础, 但最高只研究到了 256 QAM 信号的调制分类, 并没有研究 512 及以上的高阶

QAM 信号的调制分类。针对高阶 QAM 信号的调制分类问题, 结合了 QAM 信号的分解特征与 Transformer 编码器的自动调制分类网络^[9], 提出了一种改进 Transformer 编码器网络的自动调制分类网络, 将 QAM 信号的同相分量与正交分量并行通过 2 个 Transformer 的编码器, 再将 2 个编码器的输出结果拼接并进行调制分类。研究了该网络在信噪比 (signal to noise ratio, SNR) 从 -10 dB 到 30 dB (间隔为 2 dB) 的 21 种加性高斯白噪声 (additive white Gaussian noise, AWGN) 信道条件下, 从 4 QAM 到 4 096 QAM 的 10 种 QAM 调制格式的分类效果。

1 信号模型与网络结构

1.1 信号模型

接收到的 QAM 信号模型可表示为

$$r(t) = \sum_{k=1}^N s_k g(t - kT_b) e^{j(2\pi f_c t + \varphi)} + w(t) \quad (1)$$

$$s_k = a_k + j b_k, k = 1, 2, \dots, N \quad (2)$$

式中: s_k 为 QAM 信号的基带码元信号序列, 序列长度为 N ; j 为虚数单位; a_k 为 QAM 信号的同相分量; b_k 为 QAM 信号的正交分量; $g(t)$ 为成形滤波器的冲激响应; T_b 为码元宽度; f_c 为载波频率; φ 为载波相位; $w(t)$ 为加性高斯白噪声。

假设已经对接收到的 QAM 信号序列 $r(t)$ 进行了预处理操作, 包括: 信号的下变频, 匹配滤

波，定时同步以及下采样等操作，得到了 s_k 。当信噪比为 20 dB 时，没有载波频率偏移和载波相位偏移的 16 QAM 和 32 QAM 星座图分别如图 1(a)和(b)所示。

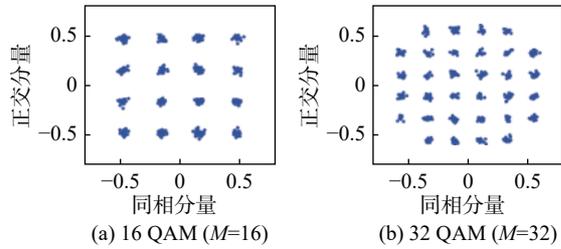


图 1 没有载波频率偏移和相位偏移的 QAM 星座图 (SNR 为 20 dB)

Fig. 1 QAM constellation diagram without carrier frequency offset and phase offset (SNR is 20 dB)

图 2(a)和(c)分别为信噪比为 20 dB 时，没有载波频率偏移和相位偏移的 16 QAM 和 32 QAM 的 a_k 时域散点图；图 2(b)和(d)分别为 16 QAM 和 32 QAM 的 b_k 时域散点图。

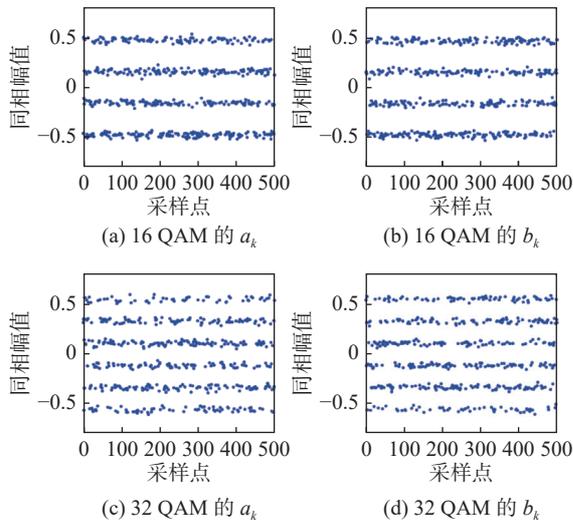


图 2 16 QAM 和 32 QAM 的 a_k 与 b_k 时域散点图 (SNR 为 20 dB)

Fig. 2 Time-domain scatter plots of a_k and b_k for 16 QAM and 32 QAM (SNR is 20 dB)

如图 2 所示，不同调制阶数的 QAM 信号的 a_k 与 b_k 具有不同的分布特征。因此，可以根据 a_k 与 b_k 的组合来对 QAM 信号进行分类。

当信噪比为 20 dB 时，载波频率偏移为 500 Hz 和载波相位偏移为 $\pi/6$ 的 16 QAM 信号的星座图如图 3(a)和(b)所示，相同条件下的 32 QAM 信号的星座图如图 3(c)和(d)所示。

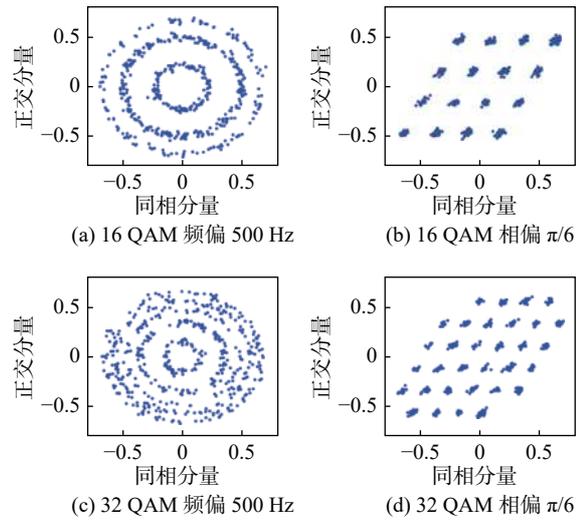


图 3 载波频偏为 500 Hz 或载波相偏为 $\pi/6$ 时 16 QAM 和 32 QAM 的星座图 (SNR 为 20 dB)

Fig. 3 Constellation diagrams of 16 QAM and 32 QAM with carrier frequency offset of 500 Hz or carrier phase offset of $\pi/6$ (SNR is 20 dB)

图 4 为在信噪比为 20 dB 时，QAM 信号受载波频率偏移 500 Hz 影响下的 a_k 和 b_k 的时域散点图。

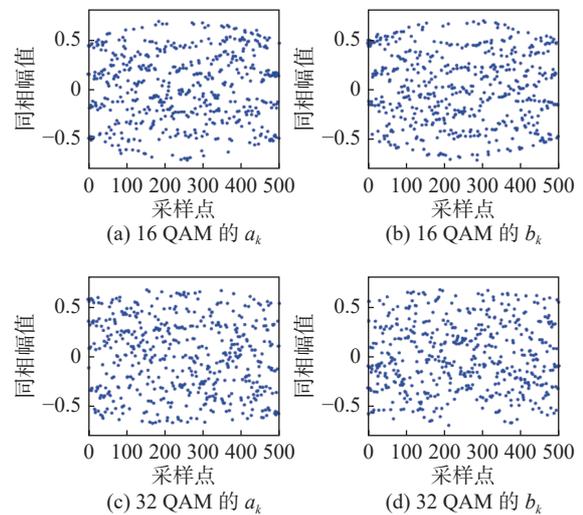


图 4 载波频偏为 500 Hz 时 16 QAM 和 32 QAM 的 a_k 与 b_k 时域散点图 (SNR 为 20 dB)

Fig. 4 Time-domain scatter plots of a_k and b_k for 16 QAM and 32 QAM with a carrier frequency offset of 500 Hz (SNR is 20 dB)

从图 4 中可以发现，当载波频率偏移 500 Hz 时，不同调制阶数的 QAM 信号的 a_k 与 b_k 具有不同的分布。因此，可以根据 a_k 与 b_k 的组合来对 QAM 信号进行分类。

图 5 为在信噪比为 20 dB 下 QAM 信号受载波相位偏移 $\pi/6$ 影响下 a_k 和 b_k 的时域散点图。

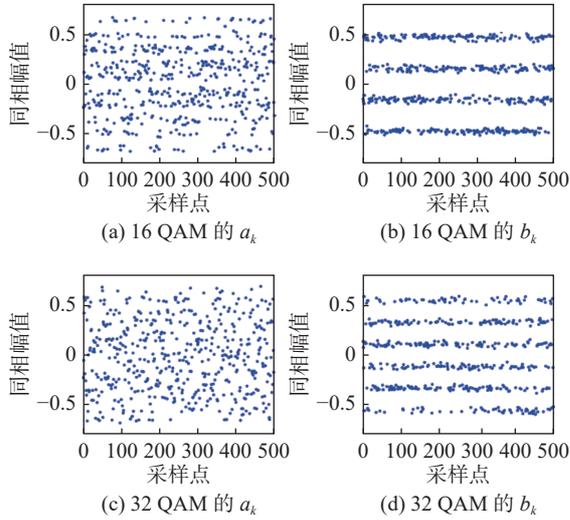


图 5 载波相偏为 $\pi/6$ 时 16 QAM 和 32 QAM 的 a_k 与 b_k 时域散点图(SNR 为 20 dB)

Fig. 5 Time-domain scatter plots of a_k and b_k for 16 QAM and 32 QAM with a carrier phase offset of $\pi/6$ (SNR is 20 dB)

从图 5 中可以发现, 当载波频率偏移 500 Hz 时, 不同调制阶数的 QAM 信号的 a_k 与 b_k 具有不同的分布。因此, 可以根据 a_k 与 b_k 的组合来对 QAM 信号进行分类。

综上所述, 无论是否有载波频率偏移或相位偏移, 不同 QAM 信号的 a_k 和 b_k 具有不同的分布组合。因此, 可以根据信号的 a_k 和 b_k 的组合来对 QAM 信号进行分类。

1.2 网络结构

Transformer 网络主要由编码器和解码器组成^[10]。编码器可以提取输入序列的特征, 因此可以用 Transformer 的编码器结构来提取 QAM 的 a_k 和 b_k 的特征。

图 6 为本文提出的网络结构框架图。其中输入数据 Data 为 AWGN 干扰后的 QAM 信号的基带码元序列 s_k ; 数据处理(data preprocessing)模块首先将 s_k 的实部和虚部提取出来, 得到同相分量 a_k 和正交分量 b_k , 然后对 a_k 和 b_k 进行标准化处理并乘以量化系数 res 转为序列编码处理, 最后在序列编码的起始位添加序列标识符 CLK, CLK 会随着编码序列一起在网络进行训练, 并能够很好地保留本组编码序列的特征, 最

后根据训练好的 CLK 对序列进行分类; 词嵌入(embedding)模块将输入的一维序列编码转为多维序列向量, 有利于在高维空间向量中捕捉一维编码序列的特征; 位置嵌入(position embedding)模块用于添加序列编码的位置信息; 将位置嵌入模块的位置向量与词嵌入模块的编码序列向量相加, 形成编码器(encoder)层的输入数据 x 。

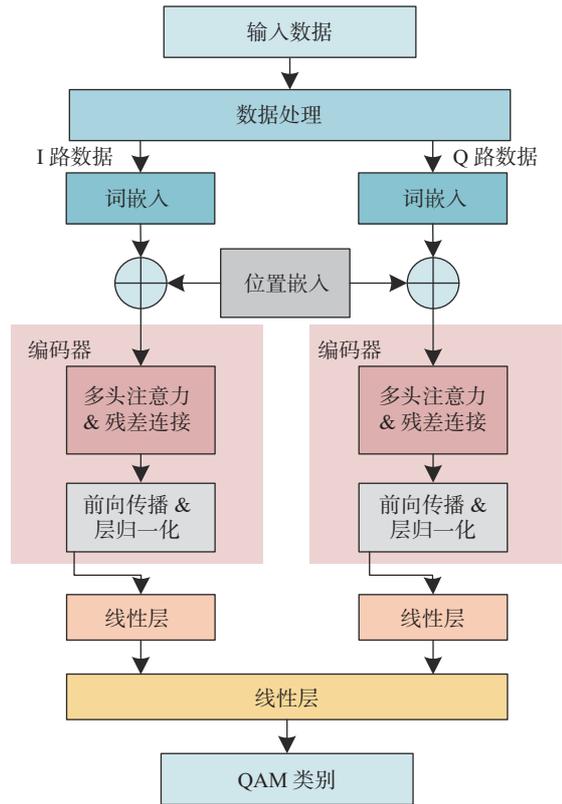


图 6 网络框架图

Fig. 6 Network framework

编码器层由残差连接与层归一化层(Add & Norm)、前向传播网络(feed forward network, FFN)以及多头注意力层(mutil-head attention)构成。

残差连接(residual connection)的作用是用了解决神经网络中的梯度消失和梯度爆炸问题, 同时也可以帮助网络更好地学习到输入数据的特征; 层归一化(layer normalization, LN)是一种类似于批归一化的归一化方法, 但是它是在每个样本的每个神经元上进行归一化处理, 这样可以使得每个神经元的输入分布相同, 从而提高网络的稳定性, 加速网络的训练, LN 层输出的计算式为

$$\text{LN}(\mathbf{x}) = \frac{\gamma \odot (\mathbf{x} - \mu)}{\sqrt{\sigma^2 + \varepsilon}} + \beta \quad (3)$$

式中： γ 和 β 为可学习的缩放和偏移参数； μ 和 σ 为 \mathbf{x} 的均值和标准差； \odot 表示元素乘法； ε 为一个很小的常数，防止分母为零。

全连接层是将输出转换为最终预测结果的关键组成部分，它可以降低数据维度和提取数据特征，增加网络的表达能力，提高网络的泛化能力。

多头注意力机制是一种在 Transformer 模型中广泛使用的注意力机制，它可以将注意力机制应用于多个查询、键和值向量上，从而提高模型的表达能力和泛化能力。图 7 为多头注意力机制的计算流程示意图。首先将输入向量 \mathbf{x} 分别通过线性变换映射为查询向量 \mathbf{Q} (query)，键向量 \mathbf{K} (key) 和值向量 \mathbf{V} (value)，然后将 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 3 个向量映射到 h 个子空间中，得到 h 组子向量；接着对每组子向量分别计算注意力得分向量 \mathbf{A} (如式 (4) 所示)；将 h 个子向量的注意力得分拼接在一起，得到最终的输出向量 \mathbf{Z} (如式 (5) 所示)。最后，将向量 \mathbf{Z} 通过线性变换映射回原始空间，得到最终的输出向量^[10]

$$\mathbf{A}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_{\text{model}}}}\right)\mathbf{V} \quad (4)$$

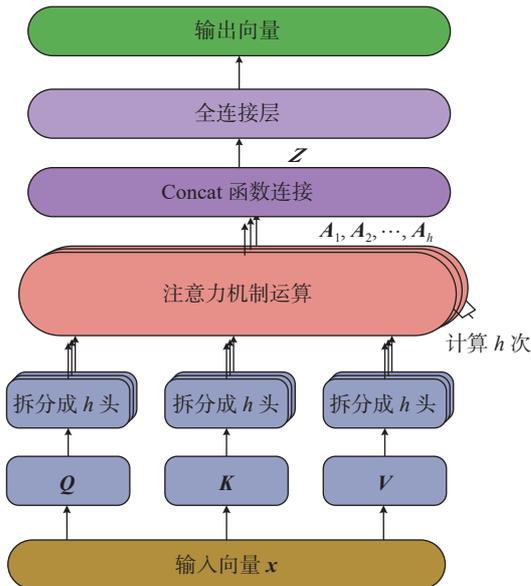


图 7 多头注意力机制计算流程图

Fig. 7 Computational process of multi-head attention mechanism

$$\mathbf{Z}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_h)\mathbf{W}$$

$$\mathbf{A}_i = \mathbf{A}(\mathbf{Q}\mathbf{W}_i^Q, \mathbf{K}\mathbf{W}_i^K, \mathbf{V}\mathbf{W}_i^V) \quad (5)$$

式中： \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 为查询向量、键向量和值向量； d_{model} 为每个编码数字的词向量维度； $\mathbf{W} \in \mathbb{R}^{hd_K \times d_{\text{model}}}$ ， $\mathbf{W}_i^Q \in \mathbb{R}^{d_{\text{model}} \times d_Q}$ ， $\mathbf{W}_i^K \in \mathbb{R}^{d_{\text{model}} \times d_K}$ ， $\mathbf{W}_i^V \in \mathbb{R}^{d_{\text{model}} \times d_V}$ ， i 为第 i 个子空间的参数； $d_K = d_V = d_{\text{model}}/h$ ， h 为注意力头数。

通过编码器层的标识符 CLK 已经保留了序列的特征信息，可以通过 1 层线性层将序列的特征信息取出。最后将 2 路信号的特征进行拼接，通过线性层和 Softmax 层就可以判断 QAM 信号的调制格式。

假设输入的 QAM 信号的基带码元序列 s_k 的调制类型共 M 种，输入网络的数据大小为 $(\text{Batch}, N-1)$ ， Batch 为输入的 batch size 大小，表示每次输入网络的序列有多少组， $N-1$ 为每组输入的序列长度，以同相分量分路 (Data I) 为例 (Data Q 路与 Data I 路中间参数大小都相同)，每层网络的参数输出大小如表 1 所示。

表 1 每层网络的参数输出

Tab. 1 Parameter output of each layer network

网络层名称	网络输出	备注
data preprocessing	(Batch, N)	添加 CLK
embedding	(Batch, N, D)	D 为词向量维度
mutil-head attention input	$(\text{Batch}, h, N, D/h)$	h 为注意力头数
mutil-head attention output	(Batch, N, D)	多头注意力计算
Add & Norm	(Batch, N, D)	归一化
FFN in	$(\text{Batch}, N, 4D)$	非线性
FFN out	(Batch, N, D)	连接
Add & Norm	(Batch, N, D)	归一化
Linear	(Batch, D)	取出 CLK
Linear & Softmax	(Batch, M)	调制分类

2 实 验

2.1 数据集

使用 MATLAB 生成 3 组 QAM 数据集，分

别是没有载波频率偏移和载波相位偏移的 QAM 数据集, 载波频率偏移 500 Hz 的 QAM 数据集以及载波相位偏移 $\pi/6$ 的 QAM 数据集。每个码元的采样点数为 8 个, 成型滤波器与匹配滤波器使用的都是 $\alpha=1$ 的根升余弦滤波器。3 种数据集的格式都一样, 每组数据集一共有 10 种调制格式的 QAM(4 QAM, 16 QAM, 32 QAM, 64 QAM, 128 QAM, 256 QAM, 512 QAM, 1 024 QAM, 2 048 QAM 和 4 096 QAM)信号, 每一种调制格式共有 2 000 组 QAM 信号序列, 每组 QAM 信号序列共有 500 个码元。信道噪声为 AWGN, 每种 QAM 有 21 种信噪比(从 -10 dB 到 30 dB, 间隔 2 dB)。每组数据集的大小为 (mod, snr, groups, length): mod 为调制格式种类, 大小为 10; snr 为信噪比种类, 大小为 26; groups 代表每种调制格式每个信噪比下有多少组信号序列, 大小为 2 000; length 为每组信号序列的长度, 大小为 500。

2.2 实验设置

实验使用的服务器 GPU 型号为 3 080 Ti, 显存 12 G; CPU 型号为 AMD EPYC 7451, 核心数为 6 核。数据处理部分(data preprocessing)将输入数据等比量化到 0~255。提出的网络总参数大小为 13.9 k, 网络的训练参数 batch_size 设置为 300, epoch 设置为 500, 词嵌入的词向量参数 d_{model} 设置为 24, 多头注意力层的头数 h 设置为 2, Add & Norm 层的 dropout 设置为 0.1, 优化器使用的是 Adam, 损失函数使用的是交叉熵损失函数(cross entropy loss), 学习率 lr 设置为可变学习率, 初始 lr 设置为 $1/\sqrt{d_{\text{model}}}$, 每个 batch_size 的迭代式为

$$lr = lr * \min\left(\frac{1}{\sqrt{y}}, \frac{y}{1000}\right) \quad (6)$$

式中, y 为迭代次数。

2.3 实验结果与分析

图 8 为没有载波频率偏移与载波相位偏移的 10 种调制格式信号的 QAM 在不同信噪比下的调制分类准确率。

如图 8 所示, 当信噪比大于 20 dB 时, 本文提出的网络可以 100% 识别出所有的调制格式;

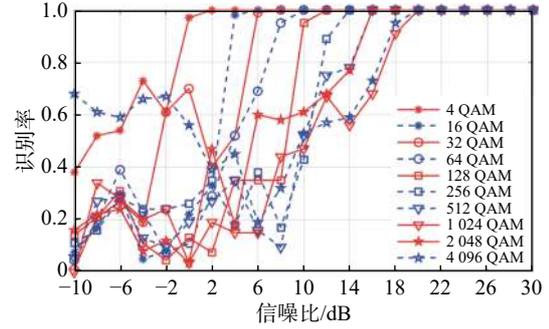


图 8 没有频率偏移与相位偏移的识别率

Fig. 8 Recognition rate without frequency offset and phase offset

当信噪比介于 2~20 dB 时, 随着信噪比的提升, 网络可以逐渐识别出更高阶的 QAM 信号; 当信噪比低于 2 dB 时, 网络无法识别 QAM 信号的调制格式。由此证明当信噪比大于 20 dB 时, 本文提出的网络可以准确识别出没有载波频率偏移与载波相位偏移的 QAM 信号的调制格式。

图 9 所示为载波频率偏移 500 Hz 的 10 种调制格式的 QAM 信号在不同信噪比下的调制分类准确率。

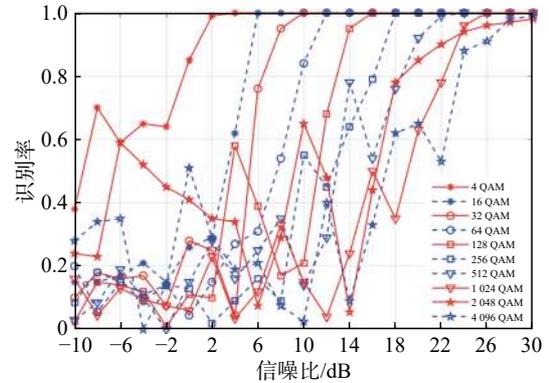


图 9 频率偏移 500 Hz 的识别率

Fig. 9 Recognition rate with frequency offset 500 Hz

从图 9 中可以发现, 当信噪比大于等于 26 dB 时, 4 QAM 到 1 024 QAM 的调制分类准确率为 100%, 2 048 QAM 的调制分类准确率大于 96%, 4 096 QAM 的调制分类准确率大于 91%; 当信噪比介于 2~26 dB 时, 随着信噪比的提升, 网络能够识别更高阶的 QAM 信号; 当信噪比低于 2 dB 时, 网络不能准确识别出 QAM 信号的调制格式。与图 8 对比发现, 网络对载波频率偏移 500 Hz 的 QAM 信号序列识别难度较大。在同等识别准确率条件下, 载波频率偏移 500 Hz

的 QAM 信号序列的信噪比大约是没有载波频率偏移的 QAM 信号序列的信噪比的 1.5 倍。证明了载波的频率偏移对本文提出的网络影响较大, 只有当信噪比大于 30 dB 时, 网络才有可能准确识别出载波频率偏移 500 Hz 的 QAM 信号的调制格式。

图 10 所示为载波相位偏移 $\pi/6$ 的 10 种调制格式的 QAM 信号在不同信噪比下的调制分类准确率。

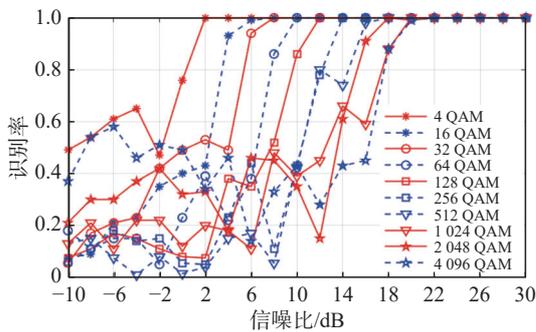


图 10 相位偏移 $\pi/6$ 的识别率

Fig. 10 Recognition rate with phase shift $\pi/6$

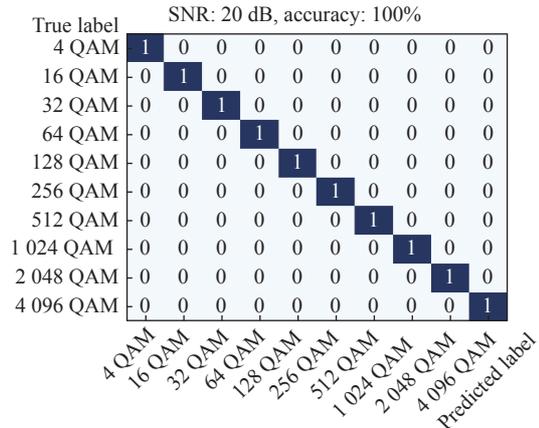
从图 10 中可以发现, 当信噪比大于等于 20 dB 时, 本文提出的网络可以 100% 识别出所有 QAM 信号的调制格式; 当信噪比介于 2~20 dB 时, 随着信噪比的增加, 网络可以识别更高阶的 QAM 信号的调制格式; 当信噪比低于 2 dB 时, 网络无法准确识别出 QAM 信号的调制格式。与图 8 对比发现, 网络对载波相位偏移 $\pi/6$ 的 QAM 信号与没有载波相位偏移的 QAM 信号具有几乎相同的识别准确率。证明了本文提出的网络几乎不受载波相位偏移的影响, 在信噪比大于 20 dB 时, 网络能准确地识别出载波相位偏移 $\pi/6$ 的 QAM 调制格式。

图 11 为 3 个数据集在信噪比为 20 dB 时, 本文提出的网络对 QAM 信号的调制分类准确率的混淆矩阵图。

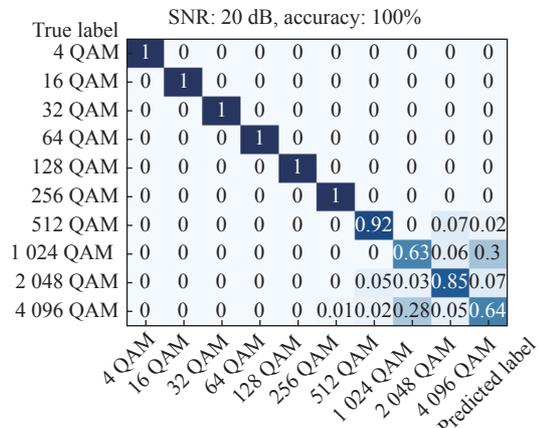
图 12 显示了 3 个数据集在 20 dB 信噪比下模型的训练集与测试集的调制分类准确率和损失曲线。

2.4 与其他方法对比

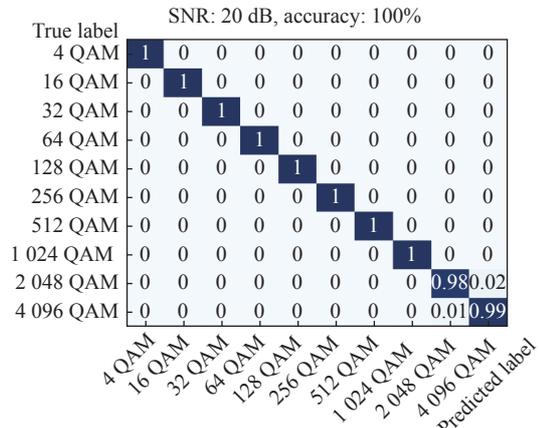
表 2 列出了本文提出的调制分类方法与文献 [5]、文献 [8] 的调制分类方法的对比结果, 以 5 种调制方式分类准确率大于 95% 为条件,



(a) 没有载波频率偏移和载波相位偏移



(b) 载波频率偏移 500 Hz



(c) 载波相位偏移 $\pi/6$

图 11 3 个数据集的混淆矩阵 (SNR 为 20 dB)

Fig. 11 Confusion matrix on three datasets (SNR is 20 dB)

对比 3 种方法所需的最小信噪比的大小, 所需最小信噪比越小则说明该调制分类方法效果越好。

如表 2 所示, 本文提出的方法在满足较高准确率的同时所需信噪比最小, 证明了本文提出的方法优于其他 2 篇文献中的方法。

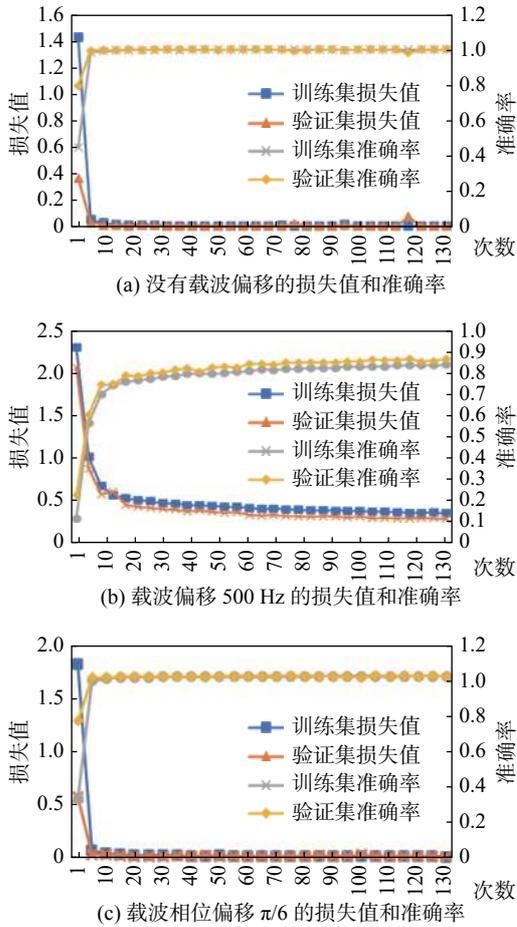


图 12 3 个数据集的调制分类准确率和损失曲线 (SNR 为 20 dB)

Fig. 12 Training and testing modulation classification accuracy and loss curves of three datasets (SNR is 20 dB)

表 2 本文网络与其他方法对比

Tab. 2 Comparison of the results in this article and the results obtained by the other methods

调制格式	文献[5]	文献[8]	本文
16 QAM	10 dB	20 dB	6 dB
32 QAM	14 dB	30 dB	8 dB
64 QAM	10 dB	20 dB	10 dB
128 QAM	14 dB	25 dB	12 dB
256 QAM		25 dB	14 dB

3 结 论

本文提出的改进型 Transformer 网络的高阶 QAM 自动调制分类网络具有网络结构简单, 训练参数少的优点, 且对所有从 4 QAM 到 4096

QAM 调制信号具有很好的分类效果。当信噪比大于 20 dB 时, 网络可以准确识别出没有载波频率偏移影响的所有 QAM 信号的调制格式; 当信噪比大于 30 dB 时, 网络可以识别出所有 QAM 信号的调制格式。与其他方法对比, 本文提出的方法在同样的调制分类准确率条件下所需信噪比比其他方法低, 而且本文研究了 512 QAM 及以上的高阶的 QAM 信号的调制分类, 这对使用高阶 QAM 调制通信的研究具有重要意义。

参考文献:

[1] 王胡成, 徐晖, 程志密, 等. 5G 网络技术研究现状和发展趋势 [J]. 电信科学, 2015, 31(9): 156 – 162.

[2] 褚衍杰, 胡年福, 巢凯今, 等. 通带 QAM 信号调制方式识别方法 [J]. 西安电子科技大学学报 (自然科学版), 2008, 35(5): 932 – 937.

[3] 张路平, 王建新. QAM 信号调制方式盲识别 [J]. 电子与信息学报, 2011, 33(2): 332 – 336.

[4] 曹颖, 周丽丽, 王晓亚. 高阶 QAM 信号调制样式识别算法研究 [J]. 火控雷达技术, 2013, 42(2): 23 – 26.

[5] 张华娣, 楼华勋. QAM 信号调制方式自动识别方法 [J]. 通信学报, 2019, 40(8): 200 – 211.

[6] LIU A S, ZHU Q. Automatic modulation classification based on the combination of clustering and neural network[J]. The Journal of China Universities of Posts and Telecommunications, 2011, 18(4): 13 – 19,38.

[7] 胡佩聪, 杨文东, 李佩. 莱斯衰落信道下 QAM 信号调制方式自动识别方法 [J]. 陆军工程大学学报, 2022, 1(3): 22 – 28.

[8] 葛战, 李兵, 孙磊, 等. 基于星座图和密集连接网络的 QAM 信号识别 [J]. 电子信息对抗技术, 2023, 38(1): 43 – 48.

[9] 宋婷婷, 吴赛君, 裴颂文. 融合 BiLSTM 的双图神经网络文本分类模型 [J]. 上海理工大学学报, 2023, 45(2): 103 – 111,119.

[10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017: 6000 – 6010.

(编辑: 李晓莉)