



研究与开发

信号增强网络驱动的调制识别

程风云, 周金

(天津财经大学理工学院, 天津 300222)

摘要: 现有基于深度学习的调制识别在训练阶段需要大量IQ信号样本, 而复杂电磁环境中很难获取大量样本, 导致基于深度学习的调制识别算法泛化性能下降。针对网络泛化能力差的问题, 提出了一种基于信号增强的调制识别 (signal enhancement based modulation recognition, SEBMR) 算法。首先, 设计了捕获IQ信号全局特征的特征提取及重构模块; 其次, 提出了基于辅助分类生成对抗网络 (auxiliary classifier generative adversarial network, ACGAN) 的IQ信号增强网络, 实现了样本数量及质量的双重增强; 最后, 利用支持向量机算法实现了调制方式识别分类。为了实现对复杂信道下调试信号的识别, 训练时采用表征全局特征的重构信号, 测试时采用经历无线衰落的IQ基带信号。实验结果表明, 提出的方法相比现有的基于长短期记忆 (LSTM) 网络、卷积神经网络 (CNN)、注意力机制等识别方法, 在小样本训练集、衰落信道环境下可获得更优的识别准确度。

关键词: 调制识别; 注意力机制; 信号增强; 生成对抗网络

中图分类号: TP929.5

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024090

Modulation recognition driven by signal enhancement

CHENG Fengyun, ZHOU Jin

School of Information Science and Technology, Tianjin University of Finance and Economy, Tianjin 300222, China

Abstract: The existing modulation recognition algorithms based on deep learning theory require a large number of IQ signal samples during the training phase. It is difficult to obtain a large number of samples in complex electromagnetic environments, resulting in a decrease in the generalization performance of modulation recognition algorithms based on deep learning. A signal enhancement based modulation recognition (SEBMR) algorithm was proposed to address the issue of poor network generalization ability. Firstly, a feature extraction and reconstruction module was designed to capture the global features of IQ signals. Secondly, an IQ signal enhancement network based on auxiliary classifier generative adversarial network (ACGAN) was proposed to achieve dual enhancement of sample quantity and quality. Finally, the support vector machine algorithm was employed to achieve modulation recognition and classification. To achieve recognition of debugging signals in complex channels, reconstructed signals representing global

收稿日期: 2023-10-01; 修回日期: 2024-04-07

基金项目: 天津自然科学基金资助项目 (No.22JCYBJC01550); 天津市教委科研计划项目 (No.2023SK105)

Foundation Items: Tianjin Natural Science Foundation of China (No.22JCYBJC01550), Tianjin Education Commission Research Program (No.2023SK105)



features were for training, and IQ baseband signals which experienced wireless fading were used for testing. The experimental results show that the proposed method can achieve better recognition accuracy performance in small sample training sets and fading channel environments compared to existing recognition methods based on long short-term memory (LSTM), convolutional neural network (CNN), attention mechanism, etc.

Key words: modulation recognition, attention mechanism, signal enhancement, generative adversarial network

0 引言

自动调制识别是介于下变频与解调器之间的重要环节,通过对无线电信号的特征分析,确定信号采用的调制方式,实现信号解调。调制识别技术在无线电通信、电子对抗等领域有着广泛的应用^[1-2]。

自动调制识别的传统方法主要分为基于似然函数的方法和基于特征提取的方法。基于似然函数的方法有效地提高了识别准确率,但该方法需要大量的先验知识并且计算复杂度较高,需要大量数据来确定判决阈值。在信道状态信息、干扰等先验知识未知的情况下,基于似然函数的方法很难得到准确的识别结果。基于特征提取的方法相较于基于似然函数的方法计算复杂度较低,特征提取中常用的特征包括瞬时特征^[3]、小波变换特征^[4]、短时傅里叶变换特征^[5]、高阶统计量^[6]等。以上方法均不能解决复杂电磁环境下的调制识别难题。

近年来,机器学习(machine learning, ML)技术广泛应用在图像识别、语音识别等相关领域。自动调制识别本质上是一个模式识别问题,有学者尝试使用机器学习方法解决调制识别、频谱感知等二元分类问题^[7-10]。文献[11]利用卷积神经网络和长短期记忆神经网络对信号数据的星座图进行特征提取。文献[12]同时提取信号的IQ序列数据特征、幅度相位信息特征以及星座图特征,再将多模态的特征进行特征融合进而得到识别结果,但将时序序列转换为星座图时可能引入噪声,从而丢失IQ调制信号的重要特征信息。上述方法只

提取了IQ信号的局部特征,无法提取全局特征,导致类内调制方式以及高阶调制方式识别准确率下降。另外,深度学习网络需要大量训练样本,由于干扰、噪声和复杂信道衰落的影响^[13-14],无线电信号样本数据集的容量较小,无法满足深度学习网络对样本量的要求^[15-17]。因此,近年来小样本条件下的调制识别方法引起了学术界和工业界的关注。例如,文献[18]提出了一种小样本场景下基于生成对抗网络的频谱感知算法。文献[19]提出了一种基于关系网络的小样本水声通信信号调制识别方法,该方法设计了一种基于功率谱和关系网络的调制识别模型,在不同通道建立小样本训练任务来优化该模型。文献[20]提出了一种基于元学习的小样本调制识别算法,该方法设计了一种混合并行特征提取网络,在高信噪比条件下有效地提高了调制识别的性能,但上述方法在复杂衰落信道下性能下降严重。

针对上述问题,本文提出了一种基于信号增强的调制识别算法。首先,为实现识别网络适用于不同衰落信道,构建基于全局特征提取的IQ信号重构模块(recovery module based on global feature extraction, RM-GFE)。其次,为解决IQ样本量小的问题,提出基于带辅助分类器的生成对抗网络(auxiliary classifier generative adversarial network, ACGAN)的数据增强网络,该网络由生成器和判别器构成,为提升IQ信号样本质量,提出基于双重注意力机制的生成器。为提升网络泛化能力,训练和测试时,判别器采用不同的输入信号。在训练阶段,判别器输入信号为生成器输出样本和RM-GFE重构信号,其目的是使网络

获取 IQ 信号的本质全局特征；在测试阶段，判别器输入信号为生成器输出样本和经历严重衰落的 IQ 采集信号。该方法首先利用双重注意力机制对 I/Q 序列信号进行特征提取，之后利用扩充样本后的信号数据集对支持向量机（support vector machine, SVM）进行训练得到调制识别分类结果。

1 相关研究

1.1 无线信号高阶累积量特性

无线信号 $x(t)$ 的 k 阶累积量如式 (1) 所示。

$$C_{kx}(t_1, t_2, \dots, t_k) = \text{Cum}\{x(t), \dots, x(t+t_{k-1})\} \quad (1)$$

其中， $C_{kx}(\cdot)$ 为求累积量运算函数，根据共轭位置的不同，定义 p 阶混合矩为：

$$M_{pq} = E[x^{p-q}(t)x^{*q}(t)], \quad p > q \quad (2)$$

其中， $E[\cdot]$ 为求期望运算， $x^*(t)$ 为 $x(t)$ 的共轭， q 为共轭序列的阶数。根据阶与累积量的转换关系可以得出具有均值为零的平稳复数随机过程 $x(t)$ 的各高阶累积量，可表示为：

$$C_{40} = \text{Cum}(x, x, x, x) = M_{40} - 3M_{20}^2 \quad (3)$$

$$C_{42} = \text{Cum}(x, x, x^*, x^*) = M_{42} - M_{20}^2 - 2M_{21}^2 \quad (4)$$

$$C_{60} = \text{Cum}(x, x, x, x, x, x) = M_{60} - 15M_{20}M_{40} + 30M_{20}^3 \quad (5)$$

$$C_{63} = \text{Cum}(x, x, x, x^*, x^*, x^*) = M_{63} - 6M_{41}M_{20} - 9M_{42}M_{21} + 18M_{20}^2M_{21} + 12M_{21}^3 \quad (6)$$

$$C_{80} = \text{Cum}(x, x, x, x, x, x, x, x) = M_{80} - 28M_{60}M_{20} - 35M_{40}^2 + 42M_{20}^2M_{40} - 630M_{20}^4 \quad (7)$$

1.2 辅助分类生成对抗网络

ACGAN^[21] 的设计思想是将生成对抗网络（generative adversarial network, GAN）与半监督学习相关联。不同于原始 GAN 的训练过程，ACGAN 在生成器和判别器中加入了输入数据的

类别标签，从而实现生成样本数量和质量的双重提升。在调制识别问题中，判别器不仅要判断给定输入样本的真实性，还应判断输入样本的类别。ACGAN 的生成器和判别器损失函数分别如式 (8) 和式 (9) 所示。 L_S 为数据真实与否的代价函数， L_C 为记录数据分类正确的代价函数。

$$L_S = E_{x \sim P_{\text{data}}(x)}(\lg(D(x))) + E_{z \sim P_z(z)}(\lg(1 - D(G(z)))) \quad (8)$$

$$L_C = E_{c \sim P_{\text{data}}(c)}(\lg(D(c))) + E_{c \sim P_z(z)}(\lg(1 - D(G(c)))) \quad (9)$$

其中， c 为输入的真实数据所对应的调制方式类别标签。要求判别器 D 能够判断生成数据和真实数据，并准确地对数据来源进行分类，因此判别器 D 的损失函数训练为 $L_S + L_C$ 的最大值，同时希望生成器 G 生成的数据被判别器 D 识别为真实数据且正确分类，因此生成器的损失函数训练的最大值为 $L_S - L_C$ 。

2 基于信号增强的调制识别方法

本文提出了一种基于信号增强的调制识别方法。该方法由基于全局特征提取的 IQ 信号重构模块、数据增强模块和识别分类模块构成。RM-GFE 模块通过双重注意力机制提取 I/Q 时序序列及其高阶累积量的关键特征，实现对 IQ 理想信号的全局特征提取，然后利用注意力特征融合（attention feature fusion, AFF）模块重构纯净 IQ 信号，作为训练阶段判别器的输入信号之一。数据增强模块中，设计基于注意力机制的生成器，生成逼近纯净 IQ 信号的样本，提高样本数量与质量。训练好网络后，将真实衰落下变频后的 IQ 信号作为判别器输入信号之一，与生成样本进行比较判别，最终通过 SVM 进行调制样式分类决策。

本文提出的基于信号增强的调制识别（signal enhancement based modulation recognition, SEBMR）的网络架构如图 1 所示，训练阶段时真




图1 基于SEBMR的网络架构

实数据为RM-GFE模块产生的重构IQ信号，测试阶段采用无线信道衰落环境下经过下变频后保留信道衰落特性的基带IQ信号。

2.1 基于全局特征提取的I/Q信号重构模块

2.1.1 基于注意力机制的全局特征提取算法

CNN在局部特征提取领域具有卓越性能，但其全局特征提取能力较差。为获取IQ调制信号的本质关键特征图谱，本文提出基于双重注意力机制的全局特征提取算法。具体方法为，在特征提取时使用双重注意力模块，从而达到有效利用不同通道和空间的特征信息的目的。其中通道注意力提取CNN不同通道之间的关键特征，而空间

特征为IQ信号特征图谱中时-频域构成的联合特征信息。

双重注意力模块由通道注意力模块和空间注意力模块组成，双重注意力结构如图2所示。

通道注意力模块结构如图3所示，该模块通过对输入的特征向量在空间维度上执行全局最大池化和全局平均池化来提取IQ信号的上下文特征。上下文特征作为共享网络的输入，该共享网络由一个多层感知机（multilayer perceptron, MLP）组成。多层感知机中有两个密集连接层，神经元的个数分别为 $8/C$ 和 C ，其中， C 表示通道维度。多层感知机的输出按照元素相加后利用




图2 双重注意力结构



图3 通道注意力模块结构

sigmoid函数生成通道注意力特征图谱。

通道注意力模块的特征提取过程可定义为式(10)。

$$M_C(\mathbf{F}) = \sigma(\text{MLP}(\text{AvgPool}(\mathbf{F})) + \text{MLP}(\text{MaxPool}(\mathbf{F}))) \quad (10)$$

其中, σ 表示 sigmoid 函数, $\mathbf{F}$ 表示输入特征, MLP 表示多层感知机, AvgPool 为平均池化层, MaxPool 表示最大池化层。

空间注意力模块结构如图4所示, 该模块是在通道维度上执行全局最大池化和全局平均池化来生成分别表示两个不同上下文的特征。在不增加计算量的前提下增加模型对特征的提取能力, 本文在对两个不同的上下文特征进行连接时选择了点卷积。点卷积的优势在于它可以在不同的位置上提取互相关度较低的特征, 从而更好地捕捉细节信息。




图4 空间注意力模块结构

空间注意力特征计算过程可定义为式(11)。

$$M_S(\mathbf{F}) = \sigma(f([\text{AvgPool}(\mathbf{F}); \text{MaxPool}(\mathbf{F})])) \quad (11)$$

其中, f 表示点卷积层。

2.1.2 特征融合模块

特征融合指不同层或不同分支的特征组合, 可以通过加权平均、级联或者堆叠等方法实现。特征融合可以有效地提高预测准确率和模型的鲁棒性。为了解决不同尺度特征融合时出现的问题, 本文在进行特征融合时采用了AFF。注意力特征融合模块结构如图5所示, 特征 $\mathbf{X}$ 是无线信号的高阶累积量特征, $\mathbf{Y}$ 是注意力模块提取的特征。两个特征向量通过逐元素加法进行初始特征融合得到多尺度通道注意力模块(multi-scale channel attention module, MS-CAM)的输入特征向量 $\mathbf{F}$ 。MS-CAM负责计算用于加权求和的特征相似度, 该模块通过沿通道维度聚合多尺度上下文信息, 可以同时强调分布更全局的大对象和分布更局部的小对象, 方便网络在极端尺度变化的情况下识别和检测对象。

注意力特征融合过程可以表示为式(12)。

$$\mathbf{Z} = M(\mathbf{X} \uplus \mathbf{Y}) \otimes \mathbf{X} + (1 - M(\mathbf{X} \uplus \mathbf{Y})) \otimes \mathbf{Y} \quad (12)$$

其中, $\mathbf{Z}$ 为融合特征, $\uplus$ 表示初始特征融合, M 代表 MS-CAM, $\otimes$ 代表逐元素乘法算符, 图5中虚线箭头表示运算符 $1 - M(\mathbf{X} \uplus \mathbf{Y})$ 。

2.2 基于ACGAN的数据增强模块

数据增强模块通过辅助分类生成对抗网络来扩充小样本数据集。生成器的输入为噪声向量和调制信号类别标签, 生成器的输出为增强后的调制信号。生成器中加入双重注意力机制模块来增




图5 注意力特征融合模块结构

强重要特征，弱化非重要特征。判别网络有两个输入，分别为生成信号样本和来自真实样本的融合特征。经过3次卷积操作和1次零填充操作得到数据真假判别结果和调制方式分类结果。辅助分类生成对抗网络结构设计见表1，生成器依次由输入层、密集连接层、数据重组层、上采样层、注意力模块、二维卷积层、批归一化层3个级联的上采样层和二维卷积层构成；判别器依次

由输入层、二维卷积层、激活函数层、Dropout层、批归一化层、零填充层、二维卷积层、激活函数层和全局平均池化层构成。基于双重注意力机制的生成器网络结构如图6所示。判别器网络结构如图7所示。

具体实施过程如下。

步骤1 对生成网络与判别网络进行初始化。

步骤2 利用生成网络生成样本信号数据，

表1 辅助分类生成对抗网络结构设计

生成网络	判别网络
Noise=Input()	Input()
Dense()	conv2d_1(Conv2D)
Reshape()	leaky_re_lu_1(LeakyReLU)
Upsampling2D()	dropout_1(Dropout)
Attention module	conv2d_2(Conv2D)
conv2d_1(Conv2D)	leaky_re_lu_2(LeakyReLU)
Batch_normalization_1(BatchNormalization)	dropout_2(Dropout)
Upsampling2D()	Batch_normalization_1(BatchNormalization)
conv2d_2(Conv2D)	Zero_padding2d_1(ZeroPadding)
Batch_normalization_1(BatchNormalization)	conv2d_3(Conv2D)
conv2d_3(Conv2D)	leaky_re_lu_3(LeakyReLU)
Batch_normalization_1(BatchNormalization)	dropout_3(Dropout)
conv2d_4(Conv2D)	Global_average_pooling2d_1
	Dense()




图6 基于双重注意力机制的生成器网络结构




图7 判别器网络结构

将生成样本数据与真实数据输入鉴别网络，同时固定生成网络参数，训练优化鉴别网络可以有效识别信号数据真伪及对应的调制类别。

步骤3 固定鉴别网络参数，鉴别生成网络生成的样本信号数据，得到结果后更新生成网络参数梯度，达到提高生成样本质量的目的。

步骤4 重复迭代步骤2、步骤3，当鉴别网络无法准确识别生成信号与真实信号时，结束训练并保存网络参数。

步骤5 重复迭代步骤2至步骤4，完成对 M 种调制方式在 N 种信噪比情况下 I/Q 信号数据集的样本扩充，停止训练。

基于 ACGAN 的数据增强模块算法如算法 1 所示。

算法1 基于 ACGAN 的数据增强模块算法
初始化生成网络、判别网络

输入：全局特征重构 IQ 信号特征图谱，真实衰落 IQ 信号

输出：增强 IQ 信号样本

for 训练迭代次数 do

for k steps do

随机生成噪声 z ;

$data_{fake} = \text{TrainModelG}(z, label)$;

$D = \text{TrainModelD}(data_{fake}, f_{fusion})$; //固定生成网络参数

if (Max ($L_S + L_C$))

end for

随机生成噪声 z ;

$G = \text{TrainModel}(z, label)$; //固定判别网络参数，对生成网络进行梯度更新;

end for

2.3 识别分类模块

本文采用 SVM 进行多分类信号调制识别。SVM 的输入可以表示为集合：

$$T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\} \quad (13)$$

其中， x_i 为第 i 个信号样本输入， y_i 为每个输入对应的调制方式类别。本文 SVM 的高斯核函数为：

$$K(x, z) = \exp\left(-\frac{\|x - z\|^2}{2\sigma^2}\right) \quad (14)$$

其中， σ 为核函数参数， σ 越大，高斯核函数将原始特征空间映射到的特征空间维度越高。因本文研究的问题是样本条件下的调制识别，将原始特征空间映射到高维特征空间更易得到正确的分类结果。



3 实验结果及分析

3.1 数据集与实验环境

为增强和验证调制识别网络泛化能力,本文在训练和测试阶段采用了两种不同的数据集。

(1) 训练阶段:数据集采用 RADIOML 2016.10A,数据集包括8种数字调制方式(BPSK、四相移相键控(quadrature phase-shift keying, QPSK)、八相移相位键控(8 phase shift keying, 8PSK)、十六进制正交振幅调制(16 quadrature amplitude modulation, 16QAM)、六十四进制正交振幅调制(64 quadrature amplitude modulation, 64QAM)、高斯频移键控(Gauss frequency shift-keying, GFSK)、连续相位频移键控(continuous phase frequency shift-keying, CPFSK)、脉冲幅度调制(4-level pulse amplitude modulation, 4PAM))和3种模拟调制方式(宽带调频(wideband frequency modulation, WBFM)、单边带调幅(amplitude modulation-single sideband, AM-SSB)、双边带调幅(amplitude modulation-double sideband, AM-DSB))。RADIOML 2016.10A数据集中有220 000个调制信号,共有20种不同的信噪比(signal to noise ratio, SNR),范围均匀分布在-20~18 dB,间隔为2 dB,每种调制方式的每个SNR有1 000个信号。调制信号的采样率为200 kHz,每个样本都由128个采样点组成,其数据格式为 2×128 的矩阵。该数据集添加的是加性白高斯噪声。

(2) 测试阶段:利用MATLAB仿真生成的调制信号经历了频率选择性衰落信道后,再经下变频得到IQ基带信号。

所有实验均在Windows10环境下实现并进行调试,32 GB内存,基于Python完成识别网络的构建,采用Keras深度学习框架,实验的GPU环境为NVIDIA GTX1060。

3.2 人工特征向量选择与构建

以QPSK为例,其推导和计算过程如下。

QPSK调制信号的复包络为:

$$x(t) = \sqrt{E} \sum_n g(t-nT_s) e^{j(\varphi_n - \theta_c)} \quad (15)$$

根据高阶矩的定义, QPSK调制信号的二阶矩为:

$$M_{20} = E[s(t)s(t)] = E[E e^{j\pi(m-1)}] = \frac{E}{4} \sum_m e^{j\pi(m-1)} \quad (16)$$

根据正弦序列正交特性可知:

$$\sum_{n=0}^{N-1} e^{\frac{\pm j 2\pi n k}{N}} = \begin{cases} N, k=Ni \text{ 且 } i \in Z \\ 0, \text{其他} \end{cases} \quad (17)$$

由式(16)和式(17)可知, $M_{20}=0$, $M_{21}=E$ 。其四阶矩、六阶矩和八阶矩分别为 $M_{40}=E^2$ 、 $M_{42}=E^2$ 、 $M_{60}=0$ 、 $M_{83}=E^4$ 。根据上述计算过程可得出QPSK调制方式的高阶累积量具体理论值为 $|C_{20}|=0$, $|C_{21}|=E$, $|C_{40}|=E^2$, $|C_{42}|=E^2$, $|C_{63}|=4E^3$, $|C_{80}|=34E^4$, 本实验基于无线信号的高阶累积量构造人工特征向量,为降低噪声的影响以及有效消除幅度和相位抖动的影响,采用以下几个特征量:

$$\begin{aligned} T_1 &= \frac{|C_{20}|}{|C_{21}|} \\ T_1 &= \frac{|C_{20}|^2}{|C_{41}|} \\ T_3 &= \frac{|C_{42}|}{|C_{21}|^2} \\ T_4 &= \frac{|C_{60}|}{|C_{21}|^3} \end{aligned} \quad (18)$$

3.3 对比实验

3.3.1 不同训练样本量对识别结果的影响对比

图8中SNR=12 dB,数据集中每种调制方式真实样本数量为20、40、60、80、100、120、140和160,使用SVM和本文提出的SEBMR方法的调制识别准确率对比实验结果如图8所示。通过对比可知,本文提出的SEBMR方法的识别准确率较SVM方法均有不同程度的提高。每种调制方式




图8 调制识别准确率对比实验结果

真实信号样本数为20时，识别准确率由24%提高到66%。每种调制方式真实信号样本数为80时，识别准确率由27%提高到89%。每种调制方式真实信号样本数为160时，识别准确率由30%提高到93%。由此可知，当真实信号样本过少时，通过数据增强得到与真实信号数据分布一致的扩充样本后，调制识别结果准确率会提高。

3.3.2 小样本下不同调制识别性能对比

为了验证本文提出方法的有效性，在相同的软/硬件条件下比较了使用LSTM^[22]、CLDNN^[23]、CGDNet^[24]和MCLDNN^[25]的调制样式识别方法以及本文提出的SEBMR在训练数据集RadioML2016和测试用频率选择性衰落信号数据集进行小样本调制识别的效果。比较不同算法的分类准确率，证实了本文方法的泛化性能。

文献[22]提出一种基于IQ信号单一时域特征提取的调制识别方法，该方法利用LSTM网络提取IQ采样序列的时域特性。文献[23]提出一种利用深度神经网络提取IQ信号局部特征的调制识别方法。文献[24]提出一种由CNN、GRU以及深度神经网络构成的调制识别框架。文献[25]提出一种融合一维CNN、二维CNN和LSTM融合模块的调制识别网络，该网络提取并融合IQ信号的时域、空域特征。

为测量非极端恶劣信道下几种调制识别算法的性能，对比分析了当信噪比为12 dB时，本文

方法与文献[22-25]中4种调制识别算法混淆矩阵性能。不同方法识别结果混淆矩阵如图9所示，每种调制方式测试时采用的经历衰落信道的真实样本量为160。混淆矩阵是一种常用的分类模型评估工具，它将实际类别和预测类别分别放在矩阵的行和列中。每一行代表真实数据的实际类别，每一列代表模型预测的类别。根据结果可以明显看出相对于其他4种方法，本文提出的方法在混淆矩阵上由左上至右下的对角线颜色更深，即表明在SNR=12 dB时，本文提出的方法对调制方式预测得到的标签与其真实标签相符合的概率更高。

将LSTM^[22]、CLDNN^[23]、CGDNet^[24]、MCLDNN^[25]和本文提出的方法进行小样本及强噪环境下调制识别准确率对比实验。信噪比范围为-20~18 dB，不同信噪比下的识别结果对比如图10所示。由实验结果可以看出，本文提出的方法在小样本、低信噪比的情况下识别准确率相较于其他4种算法有了提高。尤其当信噪比处于极低环境时，本文方法的识别准确度较其他4种方法有明显提高。主要原因为以下几点。

(1) 对比实验中，4种方法的共性为只提取了IQ信号的局部特征向量或特征图谱，如单一时域维度、时域及空域维度，而4种方法所采用的网络均基于CNN或LSTM，前者只具备优良的局部特征提取能力，后者对时序序列特征提取能力较强，所用方法无法获取IQ信号本身的全局特征。而本文所提方法在生成IQ样本时引入了基于全局特征提取的生成器，因此识别准确度高于其他4种方法。

(2) 对比实验中的4种方法均存在训练样本与测试样本性质近似的特点。如均采用Radio MATLAB2016中的一部分数据集用于训练，另外部分用于测试。当训练样本和测试数据集分布近似时，网络的泛化能力就会下降。而本文所用训练样本虽然也取自Radio MATLAB2016数据集，




图9 不同方法识别结果混淆矩阵

但训练阶段利用多重注意力机制进行全局特征展平与提取,通过多尺度信号的注意力算法与特征融合,重构出表征纯净IQ调制信号本质特征的增强型数据集。而测试样本为经仿真模拟频率选择

性信道后得到的真实衰落信号。利用训练好的生成器进行样本生成时,判决器具备更强的从衰落信号中捕获纯净调制信号的关键特征,从而可实现对无线衰落基带信号的准确识别。




图10 不同信噪比下的识别结果对比

对比训练参数、最优识别准确率两项量化指标,进一步评估本文提出方法的性能及模型复杂度。网络性能对比见表2。

表2 网络性能对比

方法	训练参数	最优识别准确
LSTM ^[22]	201 099	84.50%
CLDNN ^[23]	164 233	84.60%
CGDNet ^[24]	124 933	82.95%
MCLDNN ^[25]	406 199	92.60%
本文算法SEBMR	589 145	93.70%

由对比结果可知,本文提出的调制识别算法在同量级的训练参数下可以在小样本的条件下实现更高的识别准确率。

4 结束语

针对小样本调制识别问题,本文提出了一种基于信号增强及特征融合调制识别算法。该方法首先利用生成对抗网络中的双重注意力机制模块对原始I/Q序列信号进行特征提取;其次,利用多尺度注意力特征融合模块将得到的IQ序列信号特征与高阶累积量特征进行特征融合,利用生成对抗网络生成与真实数据分布一致的样本数据扩充数据集,并利用扩充样本后的信号数据集对支持向量机进行训练得到调制识别分类结果。本文选择的信道环境为加性白高斯噪声信道,但不能对实际应用信道的环境进行准确描述,后续将

对此进行深入研究。

参考文献:

- [1] 邵凯,朱苗苗,王光宇. 基于生成对抗与卷积神经网络的调制识别方法[J]. 系统工程与电子技术, 2022, 44(3): 1036-1043.
SHAO K, ZHU M M, WANG G Y. Modulation recognition method based on generative adversarial and convolutional neural network[J]. Systems Engineering and Electronics, 2022, 44(3): 1036-1043.
- [2] 郭业才,姚文强. 基于信噪比分类网络的调制信号分类识别算法[J]. 电子与信息学报, 2022, 44(10): 3507-3515.
GUO Y C, YAO W Q. Modulation signal classification and recognition algorithm based on signal to noise ratio classification network[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3507-3515.
- [3] CHEN W H, XIE Z C, MA L, et al. A faster maximum-likelihood modulation classification in flat fading non-gaussian channels[J]. IEEE Communications Letters, 2019, 23(3): 454-457.
- [4] CHAVALI V G, DA SILVA C R C M. Maximum-likelihood classification of digital amplitude-phase modulated signals in flat fading non-gaussian channels[J]. IEEE Transactions on Communications, 2011, 59(8): 2051-2056.
- [5] MENG F, CHEN P, WU L N, et al. Automatic modulation classification: a deep learning enabled approach[J]. IEEE Transactions on Vehicular Technology, 2018, 67(11): 10760-10772.
- [6] AZZA M A, EL MOUSSATI A, MOUSSAOUI O. Implementation of an automatic modulation recognition system on a software defined radio platform[C]//Proceedings of the 2018 International Symposium on Advanced Electrical and Communication Technologies (ISAECT). Piscataway: IEEE Press, 2018: 1-4.
- [7] 安泽亮,张天骐,马宝泽,等. 基于一维CNN的多入多出OSTBC信号协作调制识别[J]. 通信学报, 2021, 42(7): 84-94.
AN Z L, ZHANG T Q, MA B Z, et al. Cooperative modulation recognition based on one-dimensional convolutional neural network for MIMO-OSTBC signal[J]. Journal on Communications, 2021, 42(7): 84-94.
- [8] 张兆军,高银锐,邱天爽,等. 基于双曲正切特征和双特征融合神经网络的调制方式识别[J]. 大连理工大学学报, 2023, 63(1): 93-101.
ZHANG Z J, GAO Y R, QIU T S, et al. Automatic modulation classification based on hyperbolic-tangent-based patterns and dual-feature-fusion neural network[J]. Journal of Dalian University of Technology, 2023, 63(1): 93-101.
- [9] PENG Y, GUO L T, YAN J, et al. Automatic modulation classification using deep residual neural network with masked model-



- ing for wireless communications[J]. Drones, 2023, 7(6): 390.
- [10] PATHAK N K, BAJAJ V. Automatic modulation classification using bimodal parallel multichannel deep learning framework for spatial multiplexing MIMO system[J]. Physical Communication, 2023, 59: 102071.
- [11] HUANG L, ZHANG Y, PAN W J, et al. Visualizing deep learning-based radio modulation classifier[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(1): 47-58.
- [12] WANG T, HOU Y H, ZHANG H Y, et al. Deep learning based modulation recognition with multi-cue fusion[J]. IEEE Wireless Communications Letters, 2021, 10(8): 1757-1760.
- [13] WEI T, LI Z, BI D, et al. Adaptive multi-dimensional shrinkage block for automatic modulation recognition[J]. IEEE Communications Letters, 2023, 10(11): 2968-2972.
- [14] 王晓波, 尹俊平, 徐岩. 基于鲁棒损失函数的标签有噪声信号调制方式识别[J]. 计算物理, 2022, 39(4): 386-394.
WANG X B, YIN J P, XU Y. Robust loss functions for signal modulation recognition with noise labels[J]. Chinese Journal of Computational Physics, 2022, 39(4): 386-394.
- [15] 曹家乐, 李亚利, 孙汉卿, 等. 基于深度学习的视觉目标检测技术综述[J]. 中国图象图形学报, 2022, 27(6): 1697-1722.
CAO J L, LI Y L, SUN H Q, et al. A survey on deep learning based visual object detection[J]. Journal of Image and Graphics, 2022, 27(6): 1697-1722.
- [16] 吴博, 梁循, 张树森, 等. 图神经网络前沿进展与应用[J]. 计算机学报, 2022, 45(1): 35-68.
WU B, LIANG X, ZHANG S S, et al. Advances and applications in graph neural network[J]. Chinese Journal of Computers, 2022, 45(1): 35-68.
- [17] GERASYOV M, MAKAROV I. Dealing with sparse rewards using graph neural networks[J]. IEEE Access, 2023(11): 89180-89187.
- [18] 周金, 李玉芝, 李斌. 小样本图像处理方法赋能的宽带频谱感知[J]. 电子与信息学报, 2023, 45(3): 1102-1110.
ZHOU J, LI Y Z, LI B. Image processing-driven spectrum sensing with small training samples[J]. Journal of Electronics & Information Technology, 2023, 45(3): 1102-1110.
- [19] WANG H, WANG B, WANG R, et al. Modulation recognition method for underwater acoustic communication signal based on relation network under small sample set[C]//Proceedings of 2021 IEEE 21st International Conference on Communication Technology (ICCT). Piscataway: IEEE Press, 2021: 1287-1291.
- [20] 庞伊琼, 许华, 蒋磊, 等. 基于元学习的小样本调制识别算法[J]. 空军工程大学学报, 2022, 23(5): 77-82, 89.
PANG Y Q, XU H, JIANG L, et al. A few-shot modulation recognition algorithm based on meta-learning[J]. Journal of Air Force Engineering University, 2022, 23(5): 77-82, 89.
- [21] ODENA A, OLAH C, SHLENS J. Conditional image synthesis with auxiliary classifier GANs[J]. arXiv preprint, 2016, arXiv: 1610.09585.
- [22] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Deep learning models for wireless signal classification with distributed low-cost spectrum sensors[J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(3): 433-445.
- [23] WEST N E, O'SHEA T. Deep architectures for modulation recognition[C]//Proceedings of the 2017 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN). Piscataway: IEEE Press, 2017: 1-6.
- [24] NJOKU J N, MOROCHO-CAYAMCELA M E, LIM W. CGDNet: efficient hybrid deep learning model for robust automatic modulation recognition[J]. IEEE Networking Letters, 2021, 3(2): 47-51.
- [25] XU J L, LUO C B, PARR G, et al. A spatiotemporal multi-channel learning framework for automatic modulation recognition[J]. IEEE Wireless Communications Letters, 2020, 9(10): 1629-1632.

[作者简介]



程风云 (1998-), 女, 天津财经大学理工学院硕士生, 主要研究方向为模式识别、调制识别。



周金 (1981-), 女, 博士, 天津财经大学理工学院副教授、硕士生导师, 主要研究方向为信号识别、智能信息对抗。