

DOI: 10.13382/j.jemi.B2104450

基于 AG-CNN 的轻量级调制识别方法*

陶志勇 闫明豪 刘影 杜福廷

(辽宁工程技术大学电子与信息工程学院 葫芦岛 125105)

摘要:针对传统卷积神经网络在调制方式盲识别过程中,存在模型体积大、运算量高、无法部署至移动端等问题,提出了一种基于双注意力机制与 Ghost 模块的轻量级 CNN 模型 AG-CNN(attention and Ghost convolution neural network)调制识别方法,该方法首先将调制信号映射至复空间,并根据归一化点密度对映射点进行颜色处理,得到高阶特征密度星座图;将该特征作为 AG-CNN 模型的输入进行学习训练,最后使用训练好的模型对接收端接收到的未知信号进行识别。实验表明,AG-CNN 模型对散点为 10 000 的密度星座图识别率在 99.95%以上,与相同层数的 CNN 模型相比,卷积层参数量压缩 6.01 倍,计算量压缩 6.76 倍,且相较于 VGG-16、InceptionV3、ResNet-50、Shufflenet、Efficientnet 等卷积网络模型,参数量与浮点数运算数下降明显,且在大幅节省学习参数量、降低模型复杂度的情况下,表现出优秀的分类性能。

关键词:调制盲识别;密度星座图;深度学习;Ghost 模块;双注意力机制

中图分类号: TN911.3 文献标识码: A 国家标准学科分类代码: 510.4010

Lightweight modulation recognition method based on AG-CNN

Tao Zhiyong Yan Minghao Liu Ying Du Futing

(School of Electronic and Information Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: In view of the problems of large model volume, high computation and unable to deploy to mobile terminal in the blind recognition of modulation mode in traditional convolutional neural network, a modulation recognition method of attention and Ghost convolution neural network (AG-CNN) based on dual attention mechanism and ghost module is proposed. The modulation signal is mapped to complex space, the map points are processed by the normalized point density, and the higher order feature density constellation is obtained. The feature is used as input of AG-CNN model for learning training, the trained model is finally used to identify the unknown signal received by the receiver. The experimental results show that the recognition rate of density constellation map with sampling point of 10 000 is over 99.95% by AG-CNN model. Compared with CNN model with the same number of layers, the convolution layer parameter is compressed by 6.01 times and the calculation amount is 6.76 times. Compared with VGG-16, Inception V3, ResNet-50, Shufflenet, Efficientnet and other convolutional network models, the number of parameters and floating-point operations decreases significantly, and in the case of saving learning parameters and reducing the complexity of the model, it shows excellent classification performance.

Keywords: modulation blind recognition; density constellation; deep learning; Ghost module; dual attention mechanism

0 引言

信号的调制自动识别技术即在未知调制信息的情况下,基于信号的原始信息对调制类型实现准确识别,现已成为自适应调制编码、现代通信侦察等非协作通信领域

的一个重要课题。当前调制自动识别算法主要有两种:基于决策理论的方法^[1]与基于特征的方法^[2]。前者使用概率论等数学手段解决调制识别问题,推导较为复杂,需要大量信道先验知识,实用性较差。后者将调制识别问题转换为模式识别问题,对接收信号预处理得到星座图、时频图等高阶特征,使用聚类、神经网络等方法分类调制

收稿日期: 2021-06-21 Received Date: 2021-06-21

* 基金项目:国家重点研发计划项目“新兴产业集成化检验检测服务平台研发与应用”(2018YFB1403303)项目资助

信号,实际应用范围较广,识别精度高,具有良好的稳健性。其中,星座图可以唯一标识任何一种数字幅相调制信号,相对于数字信号的时域、频域或者其他变换域特征,它表示出更直观信号的结构以及各种不同调制状态的关系,是调制方式识别的经典工具。Mobasser^[3]最早提出利用信号星座图作为判决标志,算法采用 C 均值聚类,具有扩展性好等优点。王建新等^[4]在此基础上做出改进,首先利用盲均衡消除信道多径效应,再对信号采用减法聚类方法,提取聚类中心与理想星座图模型进行匹配。近年来,深度学习在机器视觉^[5]、自然语言处理^[6]、语音识别^[7]等领域获得了巨大成功,为模式识别问题提供了全新的思路。研究者们开始利用深度学习解决通过星座图进行调制识别的问题,Peng 等^[8]利用调制信号的星座图输入 CNN 的经典模型 AlexNet 与 GoogleNet 进行训练,实现了 QPSK、8PSK、16QAM 和 64QAM 等的调制类型的分类,并对比灰度图、增强灰度图、三通道星座图对调制识别准确率的影响。Wang 等^[9]提出使用一种 5 层 CNN 结构实现对 MPSK、MQAM 的识别,分析了池化操作与卷积操作对星座图像提取特征信息的优势,与 BP-ANN、SVM 等机器学习算法进行实验对比,证明了 CNN 算法在复杂度方面的可行性。Kumar 等^[10]提出使用新型网络结构模型 Inception_ResNetV2 进行分层识别,即首先对 MASK、MPSK、MQAM 实现分类,再对大类中的不同进制调制方式分类,实验结果证明分层识别在精度上有所提升,但存在计算复杂度过高,模型过大的问题。

传统模式识别方法中人工提取特征较为复杂,且在低信噪比环境下识别精确度无法保证,使用深度学习算法对信号的特征进行分类,避免了人工特征提取环节,减少对复杂先验知识的依赖,增强低信噪比环境下识别鲁棒性,但当前应用至调制识别的深度学习模型规模较大,运算复杂度高,速度较慢,无法适配硬件设备的有限内存与计算资源,阻碍实际部署。本文提出一种基于 AG-CNN 的轻量级调制识别方法,通过引入双注意力机制与 Ghost 压缩模块,实现对 CNN 模型轻量化的效果。该方法首先将调制信号映射至复空间,并根据归一化点密度对映射点进行颜色处理,得到高阶特征密度星座图;将该特征作为 AG-CNN 模型的输入进行学习训练,然后根据训练好的模型对接收端接收到的未知信号进行识别。基于 AG-CNN 的轻量级调制识别方法能够有效提高利用星座图特征进行数字信号调制识别的可实现性和环境适用性,具有较高的使用价值。

1 基于 AG-CNN 的调制信号识别方法

基于 AG-CNN 的调制信号识别方法如图 1 所示,为提高传输效率与传输可靠性,信号会在发射端经过调制

产生调制信号,但由于实际信道传输中的多径效应等因素,调制信号会产生偏移等现象,造成识别阻碍。该方法在接收端接收到调制信号后,送入星座图转换系统,将调制信号映射至复空间,投影到 I 、 Q 轴并进行颜色映射预处理形成密度星座图,再将密度星座图送入 AG-CNN 模型提取特征进行分类识别,得到调制信号的类型及各项参数送至解调器,解调器根据已知信息对接收到的信号进行解调。

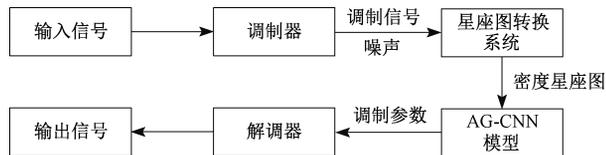


图 1 基于 AG-CNN 的调制信号识别方法

Fig. 1 Modulation signal recognition method based on AG-CNN

1.1 星座图转换系统

在数字通信中,通过正交调制器进行调制的信号可以使用一组互不相干的分量进行表示:同相(in-phase, I)分量和正交(quadrature, Q)分量。

信号 $s(t)$ 经过信道传输后,在接收端以采样率 f_s 进行采样得到离散序列 $r[n]$, $r[n]$ 如式(1)所示。

$$r[n] = \sum_{i=-\infty}^{+\infty} g(nT_s - iT_b - \varepsilon T_b) \cos(2\pi f_c - \varepsilon T_b + \frac{2\pi}{M}(m-1)) \quad (1)$$

其中, m 表示相位状态, M 为调制阶数, ε 为采样定时误差, T_b 是单位能量基带脉冲, f_c 为载波频率, T_s 是发送一个码元的持续时间, i 为当前时刻, n 输入信号序列, g 为持续时间。

设经过采样后的序列 $r[n]$ 的第 i 个点对应的 I 分量大小是 a_i , Q 分量大小是 b_i , 如图 2 所示, 将当前时间对应的 I 和 Q 分量分别投影到正交的 I 轴和 Q 轴上, 即可获得当时信号的星座图。星座图上不同的点代表不同的状态, 每次信号点的转移可以看做完成一次幅度和相位的调制, 因此, 星座图中的每个点包含了当前时刻信号幅度 A 和相位 φ 的信息, 幅度 A 和相位 φ 的计算公式如式(2)、(3)所示。

$$A = \sqrt{a_i^2 + b_i^2} \quad (2)$$

$$\varphi = \arctan\left(\frac{b_i}{a_i}\right) \quad (3)$$

其中, a_i 和 b_i 分别是信号同相和正交分量的大小。

通过映射至 I - Q 平面, 可以将数字载波调制信号信息以二维星座图形式直观表示出来, 对于解决识别幅度失衡、正交误差、相关干扰、调制误差比等调制问题有极大作用。

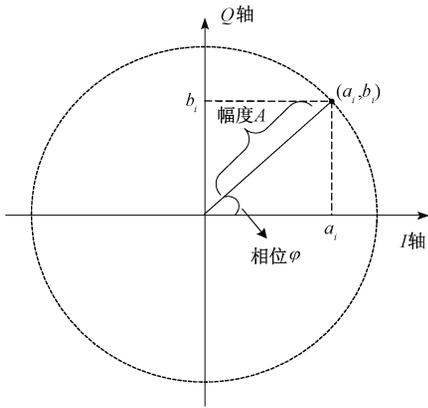


图2 I-Q 调制映射星座图

Fig. 2 I-Q modulation mapping constellation

1.2 星座图特征增强预处理

星座图能够将信号具像化为二维图像,直观的读出信号结构特点。在实际通信环境中,由于噪声影响,信号点的映射会偏离正常位置,且噪声越大,产生的偏移越大。在信噪比可控范围内,偏移点一般集中在正常无噪位置周围,信噪比越高,信号点叠加越集中,文献[11]提出根据归一化点密度对星座图上色以实现特征增强,为星座图增加时间累积特征,使数据特征维度更高,增强星座图可分性,实现特征增强的目的。

针对星座图的识别只需得到理想点聚集方位特征,而无需获得全部散点分布特点,如图3所示,通过对映射空间单位空间内信号映射散点进行个数统计,与信号散点总数的比值即可得到任意单位空间内密度矩阵,映射至提前设定的颜色图谱中,即得到特征增强的信号密度图。

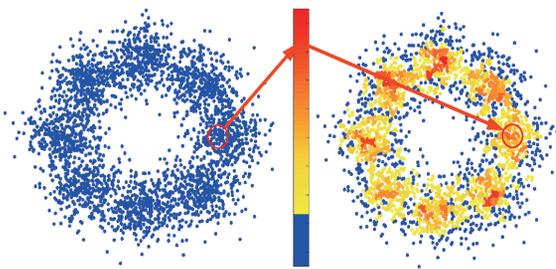


图3 密度星座图生成

Fig. 3 Generation of density constellation

1.3 AG-CNN 模型

卷积神经网络是一种常见的深度学习网络模型,基本原理是模仿人脑中多层神经节点堆叠构成深度神经网络完成认知学习^[12]。将深度学习技术应用至通信系统中,需要实时性、简便性等特点^[13-16]。密度星座图具有提升特征辨识度优势,但将一维数据转化为三通道图片,大

大提升了计算复杂度,常用的卷积神经网络模型为提取数据集中更高层次特征,往往采用更深更宽的网络结构,此举在获得识别准确率的同时,也使得网络参数量剧增、训练时长增加。若继续使用传统卷积网络模型对密度星座图分类,会导致算法时间复杂度与空间复杂度过高,无法实现模型落地。

本文提出一种改进的轻量化网络 AG-CNN,应用轻量模块 Ghost 取代卷积层减少卷积运算,降低卷积网络的参数量与运算量,模型使用串行连接,使结构更加简洁,并加入双注意力机制,在参数量较低的情况下聚焦更具有区分度的特征。

1) 双注意力机制

在计算机视觉领域,注意力机制被引入来进行视觉信息处理,文献[17]提出双注意力机制模型(convolutional block attention module, CBAM),如图4所示,CBAM 主要由通道注意力模块与空间注意力模块组成。

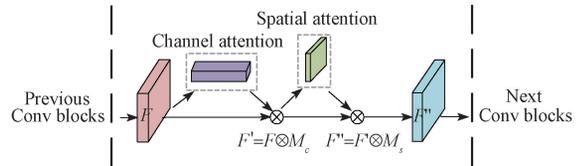


图4 双注意力机制模型

Fig. 4 Dual attention mechanism model

通道注意力机制利用特征的信道间关系生成通道注意力图,关注输入的图像中是否具有检测目标的特征,使用平均池化和最大池化操作聚合注意图的空间信息,生成两个不同的空间描述 F_{avg}^c 和 F_{max}^c ,表示平均池化特征与最大池化特征,然后通过共享全连接层生成注意力通道图 M_c ,计算公式如式(4)所示。

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) = \sigma(W_1(W_0 F_{avg}^c) + W_1(W_0 F_{max}^c)) \quad (4)$$

式中: σ 为 ReLU 激活函数; W_0 和 W_1 分别为共享全连接层 MLP 的权重。

空间注意力机制主要关注目标所在位置的特征信息,是对通道注意力特征图的一个补充。空间注意力模块首先使用两个池化操作将聚合的通道注意力特征分为两个映射 F_{avg}^s 与 F_{max}^s ,然后通过标准卷积层连接和卷积,生成二维空间注意力特征图。其计算公式如式(5)所示。

$$M_s(F) = \sigma(f^{7 \times 7}([AvgPool(F); MaxPool(F)])) = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (5)$$

式中: $f^{7 \times 7}$ 为卷积操作,卷积核为 7×7 的卷积层。

对于一个特征图 $F \in R^{c \times h \times w}$,其中 c, h, w 表示的是特

征图的长度、宽度和通道数,经过注意模块的计算过程如式(6)所示。

$$\begin{cases} F' = F \otimes M_c \\ F'' = F' \otimes M_s \end{cases} \quad (6)$$

其中, \otimes 表示逐元素相乘,双注意力机制模块将输入图像 F 与 M_c 逐元素相乘得到加权后的特征图 F' , F' 作为空间注意力模块的输入与 M_s 相乘得到最终的特征图 M_s 。

2) Ghost 模块

卷积神经网络在训练中为对输入数据有更好的理解,会生成部分冗余特征图,此类操作能获得较好的性能,但却需要驱动卷积层计算,耗费大量的计算资源。为此, Han 等^[18]提出了 Ghost 轻量化卷积模块,核心思想是使用更少的参数获得更多特征,对冗余特征图,可以通过廉价操作(cheap operation)将另一特征图变换而获得,即可以认为其中一个冗余特征图是另一特征图的“幻影”。

在进行卷积运算时,输入数据为 $F \in R^{c \times h \times w}$,其中 c, h, w 表示的是特征图的通道数、长度和宽度,卷积核 $f \in R^{k \times k \times k \times n}$,其中 k 为卷积核大小, n 为卷积核数量,通过标准卷积公式(7)得:

$$Y = X * f + b \quad (7)$$

式中: $*$ 代表卷积操作, b 为偏置项,输出特征图 $Y \in R^{h' \times w' \times n}$,其中 n 为输出特征图通道数, h' 与 w' 为输出特征的长和宽,则标准卷积操作中浮点型运算量为 $n \cdot h' \cdot w' \cdot c \cdot k \cdot k \cdot k$,卷积操作如图 5(a) 所示,其中包含着大量相似的冗余特征。在 Ghost 模块中,采用更廉价的线性操作完成冗余特征的生成,减少大量的卷积运算。Ghost 模块首先利用标准卷积生成 m 层通道的本源特征 $Y' \in R^{h' \times w' \times m}$,其中 m 为本源特征通道数且 $m \leq n$ 。然后基于 Y' 利用简单的线性变化幻影特征,如式(8)所示。

$$y_{ij} = \phi_{i,j}(y_i'), \forall i = 1, \dots, m, j = 1, \dots, s \quad (8)$$

式中: y_i' 为 Y' 中第 i 个本源特征图; $\phi_{i,j}$ 表示第 j 次线性运算,用于生成第 j 个幻影特征 y_{ij} ,即 y_i' 具有一个或多个幻影特征 $\{y_{ij}\}_{j=1}^s$ 。当 $j = s$ 时,保留本源特征不进行变化,如图 5(b) 所示,最终得到 $n = m \cdot s$ 个特征图 $Y = [y_{11}, y_{12}, \dots, y_{ms}]$,作为 Ghost 卷积模块输出,保证最终特征图通道数不变。所以,浮点型运算量包含 1 个本源特征卷积过程与 $m \cdot (s - 1) = n/s \cdot (s - 1)$ 个线性操作两部分,线性操作部分采用的卷积核平均尺寸为 $d \times d$,故理论加速比率 R_s 与压缩比率 R_c 分别如式(9)与(10)所示。

$$R_s = \frac{c \cdot k \cdot k}{\frac{1}{s} \cdot c \cdot k \cdot k + \frac{(s-1)}{s} \cdot d \cdot d} = \frac{s \cdot c}{s+c-1} \approx s \quad (9)$$

$$R_c = \frac{n \cdot c \cdot k \cdot k}{\frac{n}{s} \cdot c \cdot k \cdot k + \frac{s-1}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s+c-1} \approx s \quad (10)$$

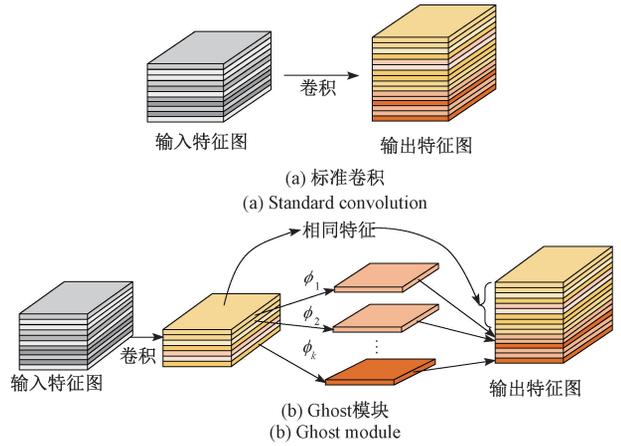


图 5 标准卷积与 Ghost 卷积

Fig. 5 Standard convolution and ghost convolution

3) AG-CNN

基于上述理论,针对调制方式识别任务,本文提出一种 AG-CNN 轻量化网络,如图 6 所示,AG-CNN 网络结构模型使用经典的 CNN 架构,应用 Ghost 模块替代传统卷积层,并在卷积模块之间加入双注意力机制模块。

AG-CNN 网络共包含 3 个 Ghost 模块,3 个双注意力机制模块以及两个全连接层。Ghost 模块串联两部分,即卷积核为 3×3 卷积层与 cheap_operation 模块,前者得到本征特征图后,后者对得到的特征图进行简单变换后与本征特征图进行融合,并送入双注意力机制模块,其中 CA 模块与 SA 模块的具体设置如图 6 所示,经过 3 层 Ghost 与双注意力模块特征拟合后,送入全连接层 FL1, FL2 进行分类。AG-CNN 具体架构如表 1 所示。

超参数即机器学习模型中的框架参数,超参数跟学习训练过程中学习的参数不同,通常是在开始学习过程之前由手工设定,通过不断的试错调整,或根据一系列穷举出的参数进行组合,为学习选择一组最优超参数,以提高学习的性能和效果。

本文对模型中的卷积核大小、迭代次数、学习率,优化器等超参数进行实验设置,训练时设置最大训练轮次为 70,批次大小设置为 128,采用 Adam 作为优化器,学习率设置为 0.001,损失函数为交叉熵函数。

2 实验结果

2.1 数据集生成

本文使用自建数据集,利用 MATLAB 生成 BPSK、QPSK、16PSK、16QAM、32QAM 五类调制信号,并通过高斯信道进行加噪后生成普通与密度两类星座图,为模拟真实通信环境,训练集使用 0~20 dB 噪声随机加噪,每信噪比下生成 100 张星座图,每类调制信号星座图共

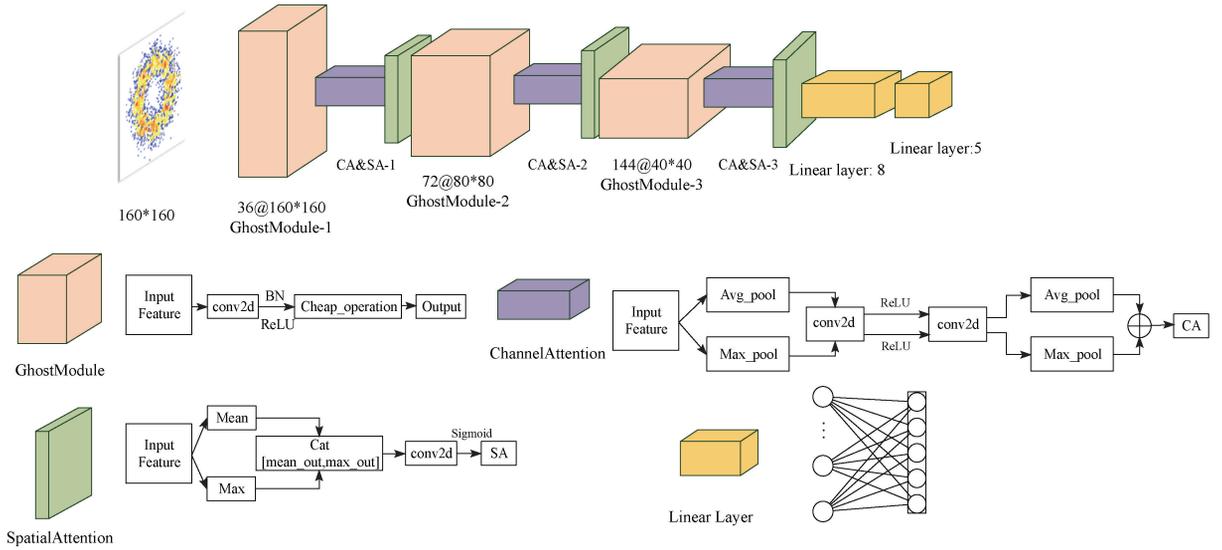


图 6 AG-CNN 轻量化网络
Fig. 6 AG-CNN lightweight network

表 1 AG-CNN 网络结构
Table 1 Network structure of AG-CNN

Block	Type	Filter	Output mapsize	Params
AG-Mouldle_1	G-block	36	160 * 160	720
	CA&SA	-	-	962
	Maxpool	-	80 * 80	0
AG-Mouldle_2	G-block	72	80 * 80	12 132
	CA&SA	-	-	3 554
	Maxpool	-	40 * 40	0
AG-Mouldle_3	G-block	144	40 * 40	47 592
	CA&SA	-	-	13 922
	Maxpool	-	20 * 20	0
Linear Layer	L-1	-	-	460 808
	L-2	-	-	45

2 100 张,共 2 100×5 张,为比较散点数量对识别效率的影响,设置每张星座图的散点个数分别为 2 000、5 000、10 000,如表 2 所示,分为 TrainSet_1~TrainSet_6,验证集与训练集对应,比例为 7 : 3,分为 ValSet_1~ValSet_6,测

试集为 0 ~ 20 dB 特定信噪比下的信号星座图,分为 TestSet_0~TestSet_20,所有生成的星座图均已进行类标签标记。

表 2 数据集
Table 2 Datasets

训练集样式	训练集					
	TrainSet_1	TrainSet_2	TrainSet_3	TrainSet_4	TrainSet_5	TrainSet_6
散点	2 000	2 000	5 000	5 000	10 000	10 000
星座图	普通	密度	普通	密度	普通	密度
对应验证集	ValSet_1	ValSet_2	ValSet_3	ValSet_4	ValSet_5	ValSet_6

2.2 实验环境与评价指标

实验环境为 Ubuntu 64 位操作系统,内存 32 GB, CPU 为 Intel Core i5-6300HQ,GPU 为 GeForce RTX 3090, 基于 Pytorch 框架。

实验通过建立混淆矩阵分析模型表现,在机器学习领域,通常使用识别准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall)、F1 值 (H-mean) 4 种评价指标衡量网络优劣,计算公式分别如式 (11) ~ (14) 所示。

$$Precision = \frac{TP}{TP + FP} \tag{11}$$

$$Recall = \frac{TP}{TP + FN} \tag{12}$$

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \tag{13}$$

$$F1-Measure = \frac{2 \times Precision \times Recall}{Precision + Recall} \tag{14}$$

式中: TP 表示被检测器正确归类的(真正例), FP 表示错误的检测为正例数据的负例样本(假正例), FN 表示错误的检测为负例数据的正例样本(假负例), TN 表示被

正确检测的负类样本。 $F1$ 分数可以同时兼顾分类模型的精确率与召回率,是两类指标的一种调和平均。

4 种评价指标从不同维度分析模型性能,数值越大,表示算法的识别性能越好,反之,算法性能较差。

2.3 实验部分

1) 密度星座图对比试验

本文首先对普通星座图与使用颜色维度增强的密度星座图进行对比,训练集使用 TrainSet_1 ~ TrainSet_6 数据集,测试集使用 ValSet_1 ~ ValSet_6。其中,TrainSet_5 与 TrainSet_6 数据集的对比如图 7 所示。

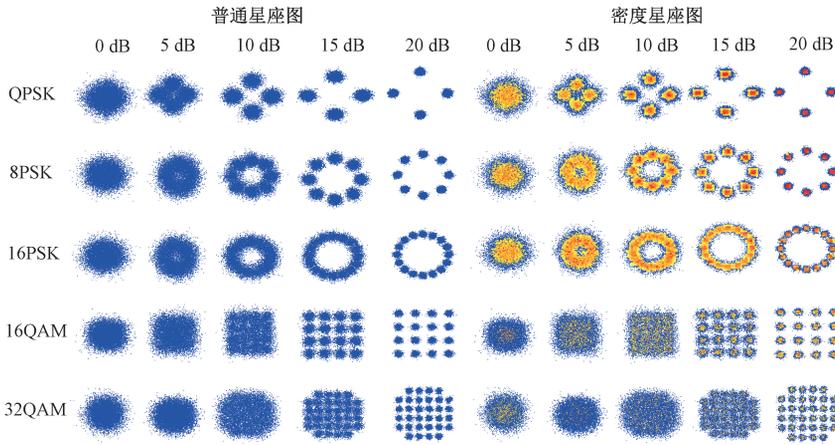


图 7 TrainSet_5 与 TrainSet_6 对比

Fig. 7 Trainset_ 5 and Trainset_ 6 comparison

普通星座图与密度星座图对比实验结果如图 8 所示,因为验证集 ValSet 与训练集 TrainSet 对应,所以可以使用验证集的识别准确率作为评估网络模型训练拟合效果的指标。从识别结果中可以看出,当散点数量较低时,密度星座图的识别率较之普通星座图识别率更高,随着散点数量的增加,信号聚集点逐渐凝实,普通星座图与密度星座图的识别准确率都有所提高,两种星座图的识别准确率接近,当散点达到 10 000 时,识别准确率高于 99.95%。而在实际通信中,由于信号的长度是变化的,因此采用在各种长度下都有较好识别表现的密度星座图更加可靠。

2) 基于 AG-CNN 的调制分类实验

为验证不同信噪比下各调制方式识别效果,本文调制分类实验采用训练集为 TrainSet_4、TrainSet_6,测试集为各信噪比下的 5 种调制类别集合。

调制分类实验结果如图 9 所示,当使用训练集 TrainSet_4 时,由于散点较少,网络在 SNR = 5 dB 时对 8PSK 与 16PSK 两种调制方式区分度较差。当使用训练集 TrainSet_6 时,随着散点增多,信号聚集处逐渐凝实,对 8PSK 与 16PSK 两种调制方式识别效果提升巨大,在

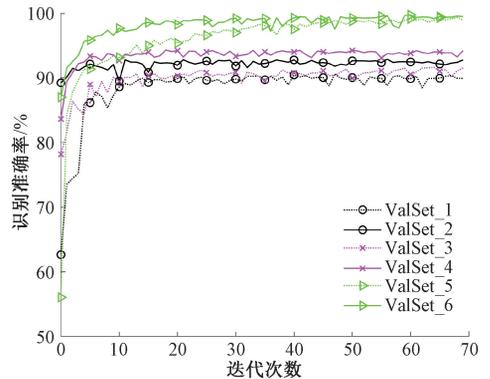


图 8 普通星座图与密度星座图对比实验

Fig. 8 Comparison experiment between ordinary constellation and density constellation

各信噪比下召回率均高于 97%。由图 9 可看出,相较于相移键控调制,正交振幅调制识别召回率更高。

基于 AG-CNN 网络在使用散点个数为 10 000 的数据集时有良好的识别分类效果,在各种信噪比环境下都有良好表现,而随着散点个数的降低,8PSK 与 16PSK 两种调制方式会出现混淆,识别效果出现波动。

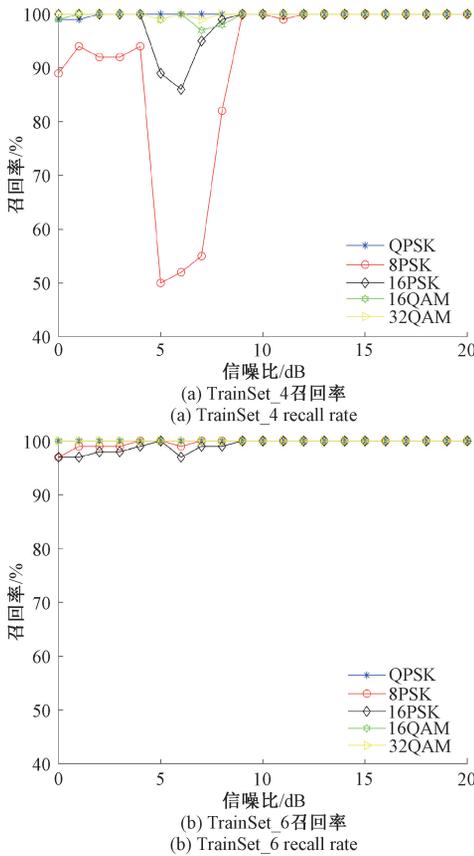


图9 基于 AG-CNN 的调制分类

Fig.9 Modulation classification based on AG-CNN

3) 对比实验

本文首先将 AG-CNN 与 A-CNN、G-CNN 进行对比,卷积层数与 AG-CNN 相同,使用数据集为 TrainSet_6、ValSet_6 与 TestSet_0~TestSet_20。实验结果如表 3、4 与图 10 所示。

表3 AG-CNN 与 A-CNN、G-CNN 对比

Table 3 Comparison of AG-CNN with A-CNN and G-CNN

网络模型	参数量/M	卷积层参数量	Gflop/s
AG-CNN	0.53	60 444	0.17
A-CNN	0.84	363 060	1.15
G-CNN	0.52	60 444	0.16

在 AG-CNN 与 A-CNN 对比中可以看出,使用 Ghost 模块代替卷积层,使得卷积层参数量压缩了 6.01 倍,浮点运算数下降了 6.76 倍,且在相同卷积层数的情况下,A-CNN 的识别率在 91%左右,小于 AG-CNN,且在信噪比环境较差时,识别效果不佳。

在 AG-CNN 与 G-CNN 对比中可以看出,信噪比环境较差时,A-CNN 的各项指标均低于 AG-CNN。因此,在 Ghost 模块之间中添加注意力机制模块,可使得网络收敛速度加快,在样本少或区分度不明显的情况下发挥明显作用。

本文继续与经典卷积神经网络 InceptionV3、ResNet-

50、VGG-16,以及轻量化网络 ShuffleNet、EfficientNet 进行对比,使用数据集为 TrainSet_6、ValSet_6 和 TestSet_0~TestSet_20。

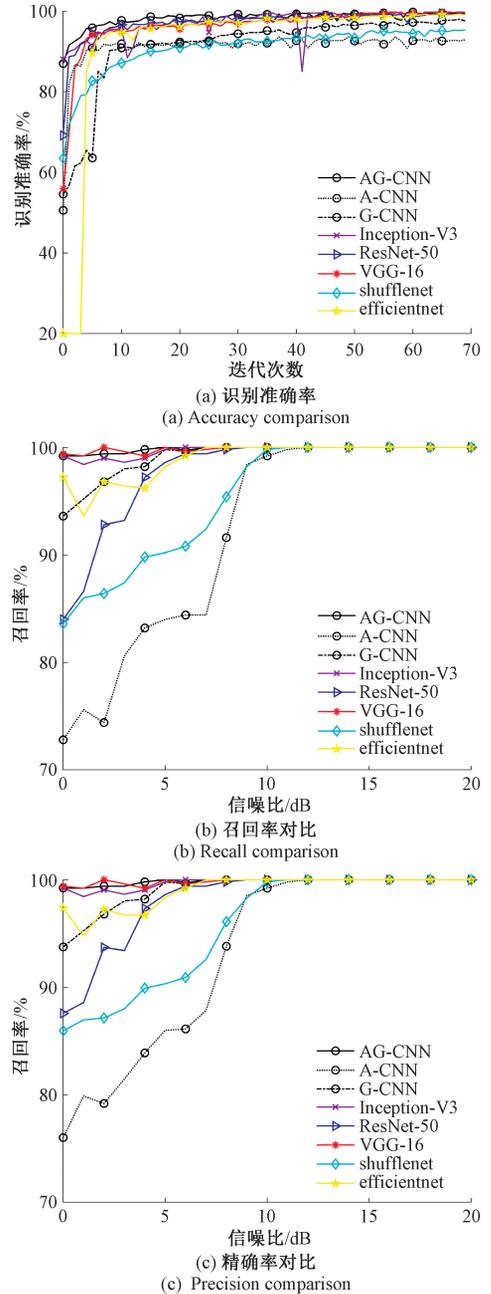


图10 AG-CNN 与常用卷积网络模型对比

Fig.10 Comparison of AG-CNN and common convolutional network models

由图 10 及表 4 可知,AG-CNN 模型在与常用卷积神经网络 InceptionV3、ResNet-50、VGG-16 及轻量化网络 ShuffleNet、EfficientNet 模型对比中,模型收敛速度以及识别准确率方面优于其他各类网络,模型拟合能力强,对特征敏感度高,识别性能出色。在分信噪比测试中,AG-

CNN 依旧有上佳表现,召回率与精确率在 0~20 dB 区间内均超过 99%,其中,在 0~4 dB 区间内,VGG 网络具有

一定的识别优势,在其余信噪比环境中,相较于其他网络,AG-CNN 模型召回率、精确率、F1-measure 优势明显。

表 4 SNR=0~8 dB 时 F1-measure 对比

Table 4 Comparison of F1 measure when SNR = 0~8 dB

网络模型	信噪比(SNR)								
	0 dB	1 dB	2 dB	3 dB	4 dB	5 dB	6 dB	7 dB	8 dB
AG-CNN	0.992 0	0.992 0	0.994 0	0.994 0	0.998 0	1.000 0	1.000 0	1.000 0	1.000 0
A-CNN	0.743 8	0.776 9	0.767 2	0.810 3	0.835 4	0.849 8	0.852 5	0.860 8	0.926 9
G-CNN	0.936 7	0.952 3	0.968 0	0.980 1	0.982 0	0.998 0	0.996 0	1.000 0	1.000 0
InceptionV3	0.992 1	0.984 1	0.990 2	0.986 2	0.990 2	0.998 0	1.000 0	1.000 0	1.000 0
ResNet-50	0.857 5	0.875 8	0.932 5	0.933 0	0.972 6	0.986 1	0.994 0	0.994 0	0.998 0
VGG-16	0.994 0	0.992 0	1.000 0	0.996 0	0.992 0	1.000 0	0.996 0	0.998 0	1.000 0
ShuffleNet	0.847 6	0.864 8	0.867 7	0.877 0	0.898 6	0.902 6	0.908 5	0.924 9	0.957 5
EfficientNet	0.972 8	0.941 8	0.970 2	0.965 6	0.964 4	0.982 7	0.992 0	1.000 0	1.000 0

卷积网络的空间复杂度可以使用模型待训练参数量与模型大小衡量,AG-CNN 与 VGG-16、InceptionV3、ResNet-50、ShuffleNet、EfficientNet 的空间复杂度对比如表 5 所示,由于 Ghost 模块的“廉价”操作,节省大量的卷积运算,使得网络的训练参数量及模型大小压缩效果可观,相较于 VGG-16、InceptionV3、ResNet-50、ShuffleNet、EfficientNet,参数量分别减少了 99.56%、97.57%、97.75%、38.37%、86.78%。

时间复杂度可以使用浮点运算数(floating point operations,FLOPs)进行衡量,在相同的实验条件下,如表 5 所示,AG-CNN 模型的 FLOPs 相较于 VGG-16、InceptionV3、ResNet-50、ShuffleNet、EfficientNet 分别下降了 98.79%、97.03%、95.86%、-30.77%、70.18%。

表 5 空间复杂度与时间复杂度对比

Table 5 Comparison of space complexity and time complexity

网络模型	训练参数量/M	模型大小/MB	GFLOPs
VGG-16	121.68	464.17	14.00
InceptionV3	21.80	83.14	5.73
ResNet-50	23.51	89.69	4.11
ShuffleNet	0.86	3.28	0.13
EfficientNet	4.01	15.31	0.57
AG-CNN	0.53	2.06	0.17

由对比实验可知,AG-CNN 模型在保证各项指标优秀的基础上,可有效压缩体积与浮点型运算量,使得模型空间复杂度与时间复杂度均大幅下降,因此本文提出的基于 AG-CNN 的调制识别方法是可行的,具有一定的研究价值。

3 结 论

调制方式识别在非协作通信等领域具有十分重要作用,本文将深度学习与调制类型识别进行结合,针对传统神经网络模型体积大、运算量高、无法部署至移动端等问

题,提出一种 AG-CNN 模型进行分类识别,引入双注意力机制模块与 Ghost 模块。与传统方法对比,能够减少对复杂先验知识的依赖,避免了人工特征提取复杂等问题。较之其他深度学习算法,AG-CNN 模型各项评价指标均领先其他深度神经网络,且模型空间复杂度与时间复杂度更低。深度学习的发展为通信等传统行业带来变革,其中通信领域产生的通信大数据又能有效支持深度学习研究的展开与应用。在接下来的工作中可以将深度学习引入信道编码与调制方式联合识别。

参考文献

[1] XU J L, SU W, ZHOU M. Likelihood-ratio approaches to automatic modulation classification [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 2010, 41(4): 455-469.

[2] 邱钊洋,黄焱,欧阳喜. 基于星座图统计的盲载波同步算法[J]. 系统工程与电子技术,2016,12:2855-2862.

QIU ZH Y, HUANG Y, OUYANG X. Blind carrier synchronization algorithm based on statistical constellation[J]. Systems Engineering and Electronics, 2016, 12: 2855-2862.

[3] MOBASSERI B G. Digital modulation classification using constellation shape [J]. Signal Processing, 2000, 80(2):251-277.

[4] 王建新,宋辉. 基于星座图的数字调制方式识别[J]. 通信学报,2004,25(6):166-173.

WANG J X, SONG H. Digital modulation recognition based on constellation diagram [J]. Journal on Communications,2004,25(6):166-173.

[5] 王立刚,张志佳,李晋,等. 基于卷积神经网络的 LED 灯类字体数字识别[J]. 电子测量与仪器学报,2020,34(11):148-154.

WANG L G, ZHANG ZH J, LI J, et al. Digital recognition of LED lights based on convolutional neural networks [J]. Journal of Electronic Measurement and Instrumentation,2020,34(11):148-154.

- [6] ZHENG X, WANG Y, YUAN Z, et al. Sentiment analysis of micro-blog short text based on convolutional memory neural network [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(3) : 195-200.
- [7] 郑昌艳, 杨吉斌, 张雄伟. 在波形网络中融合相位信息的骨导语音增强 [J]. 声学学报, 2021, 46 (2) : 309-320.
ZHENG CH Y, YANG J B, ZHANG X W. Bone-conducted speech enhancement using WaveNet fused with phase information [J]. Acta Acustica, 2021, 46 (2) : 309-320.
- [8] PENG S, JIANG H, WANG H, et al. Modulation classification based on signal constellation diagrams and deep learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018(99) : 1-10.
- [9] WANG D, ZHANG M, LI J, et al. Intelligent constellation diagram analyzer using convolutional neural network-based deep learning [J]. Optics Express, 2017, 25(15) : 17150.
- [10] KUMAR Y, SHEORAN M, JAJOO G, et al. Automatic modulation classification based on constellation density using deep learning [J]. IEEE Communications Letters, 2020, DOI: 10.1109/LCOMM.2020.2980840.
- [11] 张思成, 林云, 涂涯, 等. 基于轻量级深度神经网络的电磁信号调制识别技术 [J]. 通信学报, 2020, 41(11) : 16-25.
ZHANG S C, LIN Y, TU Y, et al. Electromagnetic signal modulation recognition technology based on lightweight deep neural network [J]. Journal on Communications, 2020, 41(11) : 16-25.
- [12] GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks [J]. Pattern Recognition, 2015, DOI: 10.1016/j.patcog.2017.10.013.
- [13] NEUMANN D, WIESE T, UTSCHICK W. Learning the MMSE channel estimator [J]. IEEE Transactions on Signal Processing, 2018, 66(11) : 2905-2917.
- [14] GRUBE T, CAMMERER S, HOYDIS J et al. On deep learning-based channel decoding [C]. 2017 51st Annual Conference on Information Sciences and Systems (CISS), 2017 : 1-6.
- [15] YE H, LI G Y, JUANG B H F. Power of deep learning for channel estimation and signal in OFDM system [J]. IEEE Wireless Communications Letters, 2018, 7(1) : 114-117.
- [16] WEN C K, SHIH W T, JIN S. Deep learning for massive MIMO CSI feedback [J]. IEEE Wireless Communications Letters, 2018, 7(5) : 748-751.
- [17] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [J]. European Conference on Computer Vision, 2018 : 3-19.

- [18] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020 : 1580-1589.

作者简介



陶志勇, 2000 年和 2005 年于辽宁工程技术大学分别获得学士、硕士学位, 2015 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为智能信息处理。

E-mail: xyzmail@126.com

Tao Zhiyong received his B. Sc. degree and M. Sc. degree from Liaoning Technical University in 2000 and 2005, received his Ph. D. degree in 2015 from Liaoning Technical University. Now he is an associate professor of Liaoning Technical University. His main research interest includes intelligent information processing.



闫明豪, 2018 年于山东建筑大学获得学士学位, 现为辽宁工程技术大学在读硕士, 主要研究方向为深度学习、信号处理。

E-mail: yanminghao95@foxmail.com

Yan Minghao received his B. Sc. degree in 2018 from Shandong Jianzhu University. Now he is a M. Sc. candidate in Liaoning Technical University. His main research interests include deep learning and intelligent signal processing.



刘影, 2006 年于黑龙江科技大学获得学士学位, 2008 年于吉林大学获得硕士学位, 2011 年于吉林大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为无线定位、非接触式识别。

E-mail: lycommunication@126.com

Liu Ying received her B. Sc. degree in 2006 from Heilongjiang Institute of Science and Technology, received her M. Sc. degree in 2008 from Jilin University, received her Ph. D. degree in 2011 from Jilin University. Now she is an associate professor in Liaoning Technical University. Her main research interests include wireless localization and non-contact identification.



杜福廷, 2018 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学在读硕士, 主要研究方向为图像处理中的缺陷识别检测。

E-mail: 771517816@qq.com

Du Futing received his B. Sc. degree from Liaoning University of Engineering and Technology in 2019. He is now a M. Sc. degree candidate from Liaoning University of Engineering and Technology. His main research interest includes defect recognition and detection in image processing.