

基于深度可分离卷积的自动调制识别

张丹华^{1,2,3}, 冯冀宁^{1,2,3}, 郑荐文^{1,2,3}, 牛江玉^{1,2,3}

(1. 河北师范大学 计算机与网络空间安全学院;

2. 河北省网络与信息安全重点实验室;

3. 供应链大数据分析 with 数据安全河北省工程研究中心, 河北 石家庄 050024)

摘要: 自动调制识别是通信模式识别、电子侦察、干扰检测等领域的重要环节。针对低信噪比条件下自动调制识别准确率不高和网络模型参数量大的问题,提出一种基于深度可分离卷积的轻量级网络模型。该模型主要由深度可分离卷积、RES-SCConv 以及注意力机制组成。首先,利用深度可分离卷积搭建基础特征提取单元,有效提取时频图数据中的多尺度特征;其次,添加轻量级注意力机制,从空间和通道两个维度进行特征提取,突出重要特征信息;最后,在网络中添加 RES-SCConv 模块,进一步减少空间维度和通道维度上的特征冗余,抑制噪声信息干扰。实验结果表明,所提模型在信噪比为 -20~0 dB 的数据集上平均识别准确率达到 90.68%,在信噪比为 0 dB 时识别准确率为 99.8%。与对照模型相比,所提模型在保持轻量级的前提下显著提高了自动调制识别准确率。

关键词: 自动调制识别;深度可分离卷积;注意力机制;低信噪比;轻量级网络

DOI:10.11907/rjdk.241826

扫描二维码阅读全文:



中图分类号:TP391

文献标识码:A

文章编号:1672-7800(2026)003-0086-08

Automatic Modulation Recognition Based on Depthwise Separable Convolutions

ZHANG Danhua^{1,2,3}, FENG Jining^{1,2,3}, ZHENG Jianwen^{1,2,3}, NIU Jiangyu^{1,2,3}

(1. School of Computer and Cyberspace Security;

2. Hebei Key Laboratory of Network and Information Security;

3. Hebei Engineering Research Center for Supply Chain Big Data Analysis and Data Security, Hebei Normal University, Shijiazhuang 050024, China)

Abstract: Automatic modulation recognition is an important part of communication pattern recognition, electronic reconnaissance, interference detection, and other fields. A lightweight network model based on depthwise separable convolution is proposed to address the issues of low accuracy in automatic modulation recognition under low signal-to-noise ratio conditions and a large number of network model parameters. This model mainly consists of depthwise separable convolution, RES-SCconv, and attention mechanism. Firstly, a basic feature extraction unit is constructed using depthwise separable convolution to effectively extract multi-scale features from time-frequency graph data; Secondly, a lightweight attention mechanism is added to extract features from both spatial and channel dimensions, highlighting important feature information; Finally, the RES-SCconv module is added to the network to further reduce feature redundancy in both spatial and channel dimensions, and suppress noise interference. The experimental results show that the proposed model achieves an average recognition accuracy of 90.68% on a dataset with a signal-to-noise ratio of -20~0 dB, and a recognition accuracy of 99.8% at a signal-to-noise ratio of 0 dB. Compared with the control model, the proposed model significantly improves the accuracy of automatic modulation recognition while maintaining lightweight.

Key Words: automatic modulation recognition; depthwise separable convolution; attention mechanism; low signal-to-noise ratio; lightweight network

收稿日期:2025-01-13

作者简介: 张丹华(2000-),女,河北师范大学计算机与网络空间安全学院硕士研究生,研究方向为模式识别;冯冀宁(1973-),男,博士,河北师范大学计算机与网络空间安全学院教授,研究方向为信号处理;郑荐文(2000-),男,河北师范大学计算机与网络空间安全学院硕士研究生,研究方向为卫星导航抗干扰;牛江玉(2000-),女,河北师范大学计算机与网络空间安全学院硕士研究生,研究方向为模式识别。本文通讯作者:冯冀宁。

0 引言

自动调制识别 (Automatic Modulation Recognition, AMR) 是一项关键技术,能够在仅获取到部分调制方式未知的通信信号时,无需人工介入即可自动判定信号的调制类型,并精准估计出对应的调制参数。这一能力为后续的信号信息提取奠定了坚实基础,是信号检测与解调流程中不可或缺的核心环节。AMR 技术凭借其卓越性能,在通信模式识别、电子侦察、干扰检测等多个领域均实现了广泛应用。传统的 AMR 方法可以分为基于似然估计的方法和基于特征提取的方法两类^[1-3]。基于似然估计的 AMR 方法实际上是一个多复合假设检验问题,但是基于假设检验的最大似然方法具有较高的计算复杂度,并且只能识别信噪比为正值的调制信号,这在很大程度上限制了其在实际应用中的应用。基于特征提取的模式识别方法需要人工提取特征,如高阶统计量、星座图和循环谱等,特征的选择会直接影响识别准确率,且需要大量依赖人工操作,在实际应用中难以实现。

近年来,深度学习技术在 AMR 领域的应用非常广泛且深入,已成为推动该领域发展的核心驱动力。例如,文献[4]提出一种应用于 AMR 的卷积神经网络 (Convolutional Neural Network, CNN),奠定了后续基于 CNN 方法的研究基础。文献[5]提出对调制信号进行时频分析的方法,将一维时域信号通过短时离散傅立叶变换转换为二维频谱图像,并利用 CNN 对图像进行特征提取与分类,最终提升了识别效果。然而在 -20~0 dB 的低信噪比条件下,该模型的平均识别准确率仅为 75.1%,相对较低。文献[6]对信号特征提取进行了深入优化,首先提取高阶统计量、瞬时时域特征以及循环谱等信息,然后将这些特征输入到 CNN 与门控循环单元并行网络中,以此提升识别准确率。然而该模型参数量较大,导致计算复杂度较高,不适宜于在资源受限的环境中部署。文献[7]将信号的 I/Q 数据输入到通道门控 Res2Net 网络中进行识别,借助 Res2Net 结构增强特征的多样性,但在信噪比为 0 dB 的情况下识别准确率不足 90%,且该模型的参数量较大,对计算资源要求较高。文献[8]构建了一种基于注意力机制的 CNN 调制识别模型,针对 I/Q 数据的不同重要特征赋予不同权重,以更精准地识别信号调制模式,但是该模型在低信噪比条件下的识别准确率仅为 10%。文献[9]将一维信号通过短时离散傅立叶变换转换为二维频谱图图像,设计 CNN 架构来自动识别调制信号,使用高斯滤波器来抑制噪声对识别的影响,但是不能提高带内信号比,并且对于宽带调制信号也是无效的,模型在低信噪比条件下的识别准确率较低。文献[10]首先对 I/Q 数据进行小波阈值去噪,利用软阈值函数的自适应阈值调整消除对 I/Q 数据的噪声影响,然后使用 CGDNN 轻量级网络对去噪后的调制信号进行识别,但是

小波阈值去噪只能对正信噪比的信号进行有效处理,对负信噪比的信号是无效的。

综上所述,上述研究均存在特征提取不够充分的问题,仅从单通道提取信号特征,导致在低信噪比条件下的信号识别准确率较低。此外,部分模型只追求信号识别准确率而忽略了参数量的问题,导致识别效率降低。针对以上问题,本文提出一种基于深度可分离卷积 (Depthwise Separable Convolution, DSC) 的轻量级网络模型,整体流程见图 1,主要创新点为:①以 DSC 为基础构建网络模型,利用其参数量低和特征提取强的优势;②在基础网络中加入注意力机制,使模型在不同信噪比下聚焦于关键特征区域;③对空间和通道重构卷积 (Spatial and Channel Reconstruction Convolution for Feature Redundancy, SCConv) 模块进行改进,向其中加入残差连接,进一步提取细节特征信息,同时加快收敛速度;④将改进 SCConv 模块并与残差块进行融合,有效减少空间维度和通道维度的特征冗余,抑制噪声干扰,同时高效提取细节特征,提高模型的检测精度。




Fig. 1 Overall process of the model

图1 模型整体流程

1 深度可分离网络

为了提高调制信号识别准确率的同时使模型更加轻量化,本文基于 DSC 提出一种深度可分离网络,具体结构如图 2 所示。所提网络模型由 4 个 DSC 块、RES-SCConv 和注意力机制组成,通过向主干网络中加入注意力机制模块来提高模型对时频图特征的关注度;通过添加 RES-SCConv 模块来减少空间维度和通道维度上的特征冗余,并加快网络的收敛速度。

深度可分离网络以 DSC、批量归一化层 (Batch Normalization, BN) 与修正线性单元 (Rectified Linear Unit, Relu) 组合的方式构建 4 个 DSC 块,充分利用 DSC 参数量小、特征提取能力强的优点。在每个 DSC 块内部,输入特征向量 $F_{in} \in R^{S \times C \times H \times W}$ 会经过 DSC、BN 和 Relu 激活函数处理。具




Fig. 2 Deep separable network structure

图2 深度可分离网络结构

体表示为:

$$F_{hid} = \text{Re lu}(BN(DSC(F_{in}))) \quad (1)$$

式中: S 为样本维度, C 为通道维度, H 为特征向量高度, W 为特征向量宽度。

该网络卷积核的宽度为3、步长为1、激活函数为 Re-lu。首先将经过小波变换的时频图数据送入 DSC 块,对输入的进行每个通道进行独立的卷积操作,以提取空间特征;其次,使用 1×1 卷积核对上一步得到的特征图进行卷积,从而整合不同通道的信息。通过引入 RES-SCConv 模块可有效减少空间维度与通道维度之间的数据冗余;同时对 SC-Conv 模块进行改进,高效提取细节特征信息。通过引入注意力机制来动态调整模型对输入数据的关注度,采用通道和空间双维度提取数据特征,然后经过平均池化层进行降维,最后通过全连接层进行分类。

1.1 DSC

为保持模型的轻量化,采用 DSC 替代传统卷积。DSC 是一种高效的卷积操作,由深度卷积和逐点卷积组成,其中深度卷积用于提取空间特征,逐点卷积用于提取通道特征。DSC 通过拆分空间维度与通道维度的相关性,减少了卷积计算所需要的参数量,同时保持与传统卷积操作相似或更高的预测精度。深度卷积对输入特征图的每个通道均使用卷积计算,确保每个通道的卷积核仅在其对应的输入通道上进行卷积运算。深度卷积中的一个卷积核对应一个通道,使输出特征图的通道数与输入特征图的通道数保持相同。因此,深度卷积的参数量为 $W \times H \times M$,其中卷积核大小为 $W \times H$,输入和输出通道数为 M 。深度卷积计算过程如图3所示。

逐点卷积为一个 1×1 的卷积核,以深度卷积的输出作为输入,将不同通道的信息组合在一起。通过在所有输入




Fig. 3 Deep convolution calculation process

图3 深度卷积计算过程

通道上执行卷积操作,并应用 1×1 卷积核,逐点卷积可生成最终的输出特征图。逐点卷积计算过程如图4所示。




Fig. 4 Point by point convolution calculation process

图4 逐点卷积计算过程

将深度卷积的输出作为逐点卷积的输入,得到一组 M 个通道的输入。卷积运算会将上一步的特征图在深度方向上进行加权组合,生成新的特征图,卷积核的数量与特征图相同。逐点卷积的参数量为 $1 \times 1 \times M \times N$,其中卷积核大小为 1×1 , M 为输入通道数, N 为输出通道数。DSC 首先对每个通道进行深度卷积,然后通过逐点卷积合并所有通道

的数据输出特征图,因此其参数量为 $W \times H \times M + M \times N$ 。

DSC 和标准卷积的参数量比较可表示为:

$$\frac{\text{深度可分离卷积参数量}}{\text{标准卷积参数量}} = \frac{W \times H \times M + M \times N}{W \times H \times M \times N} = \frac{1}{N} + \frac{1}{W \times H} \quad (2)$$

因此,DSC 的参数量比标准卷积的参数量降低了 $\frac{1}{N} + \frac{1}{W \times H}$ 倍。

1.2 SCConv 模块

调制信号时频图在低信噪比的条件下受噪声干扰较多,导致提取的特征图在空间和通道维度上存在大量冗余信息,从而削弱了网络的适应性和泛化能力。为此,本文将残差块与 SCConv 模块融合来抑制噪声干扰信息,同时添加残差连接,以高效提取细节特征。SCConv 包括空间重构单元(Spatial Reconstruction Unit, SRU)和通道重构单元(Channel Reconstruction Unit, CRU),分别用于处理空间和通道冗余。改进后的 SCConv 结构如图 5 所示。




Fig. 5 Improved SCConv structure

图 5 改进后的 SCConv 结构

将残差块与改进 SCConv 进行融合能有效减少空间和通道维度上的特征冗余,降低模型的复杂度和计算成本,从而实现模型的轻量化。将残差块与改进 SCConv 模块融合后的结构命名为 Res-SCConv。具体结构如图 6 所示。

SRU 利用分离和重构操作减少输入特征的空间冗余。结构如图 7 所示。分离操作的目的是将信息丰富的特征图与空间内容对应信息较少的特征图分离。对于输入特征图 X ,首先使用归一化层中的比例因子来评估不同特征图的信息内容。计算公式为:




Fig. 7 Structure of SRU

图 7 SRU 结构




Fig. 6 Structure of Res-SCConv

图 6 Res-SCConv 结构

$$X_{\text{out}} = GN(X) = \gamma \frac{X - \mu}{\sqrt{\sigma^2 + \varepsilon}} + \beta \quad (3)$$

式中: μ 和 σ 分别为均值和标准差; ε 为提高除法稳定性而加入的小数; γ 和 β 为可训练的仿射变换。

归一化相关权重的计算公式为:

$$W_\gamma = \{w_i\} = \frac{\gamma_i}{\sum_{j=1}^c \gamma_j}, i, j = 1, 2, \dots, cW_2 \quad (4)$$

将经 W_γ 重新加权的特征映射权值通过 sigmoid 函数映射到(0,1)范围,并通过阈值进行门控(本文阈值设置为0.5)。将高于阈值以上的权重设置为 W_1 ,低于阈值的权重设置为 W_2 。 W 的计算公式为:

$$W = \text{Gate}(\text{Sigmoid}(W_\gamma(GN(X)))) \quad (5)$$

采用重构的方式将信息丰富的特征与信息较少的特征相加,从而增加信息特征,具体计算过程为:

$$\begin{aligned} X_1^w &= W_1 \otimes W_2 \\ X_2^w &= W_2 \otimes X \\ X_{11}^w \oplus X_{22}^w &= X^{w1} \\ X_{21}^w \oplus X_{12}^w &= X^{w2} \\ X^{w1} \cup X^{w2} &= X^w \end{aligned} \quad (6)$$

式中: $\otimes$ 表示逐元素相乘; $\oplus$ 表示逐元素相加; $\cup$ 表示拼接。

为进一步消除 X^w 在通道维度的冗余,CRU 采用分割—准换—融合的策略。在分割阶段将 X_w 分为 X_{up} 和 X_{low} ,其中 X_{up} 被输入到上层转换阶段,采用高效卷积运算提取丰富的代表性特征 Y_1 ; X_{low} 被输入到较低的转换阶段,采用廉价卷积操作生成具有浅层隐藏细节的特征 Y_2 。最后,自

适应地合并上转换和下转换阶段的输出特征 Y_1 和 Y_2 , 得到

通道精细化特征 Y 。CRU 结构如图 8 所示。




Fig. 8 CRU structure

图 8 CRU 结构

1.3 注意力机制

注意力机制通过动态给予输入数据不同的权重,使模型能够专注于最相关的信息,忽略其他无关信息,从而提高其性能和泛化力。现有注意力机制大多只关注通道维度或空间维度上的特征,并且需要引入额外的参数,容易导致模型复杂度升高^[15]。为此,本文引入卷积块注意力机制(Convolutional Block Attention Module, CBAM),在空间维度和通道维度进行特征提取,其为轻量级注意力机制,不会使模型变得更复杂。CBAM 通过在卷积层之间插入注意力模块实现对特征图的自适应调整,使模型更加关注输入数据中的关键信息。具体结构如图 9 所示。




Fig. 9 Structure of CBAM

图 9 CBAM 结构

CBAM 包括通道注意力模块和空间注意力模块。通道注意力模块通过学习不同特征通道之间的相关性和重要性,以动态调整特征图中各个通道的权重,有助于模型更加关注重要的特征通道,提高其对特征的表征能力。首先,该模块输入的特征向量 Y 进行全局平均池化和全局最大池化操作,得到两个池化后的特征向量 $Y_{avg}^c = AvgPool(Y) \in R^{1 \times C}$ 和 $Y_{max}^c = MaxPool(Y) \in R^{1 \times C}$;其次,将这两个特征向量分别送入一个共享连接层 MLP (Multi-Layer Perceptron),对这两个特征向量进行相加;最后,通过 Sigmoid 函数得到通道权重向量,逐通道将其与输入特征图相乘,从而强调重要通道的信息。通道注意力机制结构如图 10 所示,用公式可表示为:

$$M_c(Y) = \sigma(MLP(AvgPool(Y))) + MLP(MaxPool(Y)) \\ = \sigma(W_1(W_0(Y_{Avg}^c)) + W_1(W_0(Y_{Max}^c))) \quad (7)$$

式中: C 为通道维度; σ 为 sigmoid 激活函数; MLP 为多层感知机; AvgPool 为平均池化函数; MaxPool 为最大池化函数; Y_{max}^c 为最大池化特征图; Y_{avg}^c 为平均池化特征图; W_0 、

W_1 为两个 MLP 共享参数。




Fig. 10 Channel attention module structure

图 10 通道注意力模块结构

空间注意力模块关注空间位置之间的依赖关系,结构如图 11 所示。输入特征向量 $M_c(Y)$ 首先分别进行通道维度的最大池化和平均池化操作,得到两个特征向量;其次,将这两个特征向量在通道维度拼接起来,在拼接后的特征图上使用 7×7 卷积核进行降维处理;最后,通过 Sigmoid 函数生成空间权重向量,将其与输入特征图逐像素相乘,以强调重要的空间位置。该过程用公式表示为:

$$M_s(Y) = \sigma([f^{7 \times 7}(AvgPool(M_c(Y))); f^{7 \times 7}(MaxPool(M_c(Y)))])) \\ = \sigma(f^{7 \times 7}([Y_{Avg}^s; Y_{Max}^s])) \quad (8)$$

式中: S 为空间维度; σ 为 sigmoid 激活函数; $f^{7 \times 7}$ 为 7×7 的卷积核; Y_{Max}^s 为最大池化特征图; Y_{Avg}^s 为平均池化特征图。

通道细化特征图 [最大池化, 平均池化] 空间注意力向量




Fig. 11 Spatial attention module structure

图 11 空间注意力模块结构

2 实验方法与结果分析

2.1 实验环境与参数配置

实验数据由 MATLAB 2016 生成,训练部分在 Pycharm 2023 中完成。实验硬件配置为 Intel(R) Core(TM) i7-11800H, NVIDIA GeForce RTX 3060。在训练过程中,采用学习率为 10^{-5} 的 Adam 优化器对模型进行训练优化,选用类别标签的交叉熵作为损失函数。使用学习率调度器,每经过 20 轮,学习率减少为之前的 1/10。如果验证集的损失

函数在20轮内没有变化,则停止训练。

2.2 数据集

本文使用的数据集基于 MATLAB 仿真生成,包括10种调制信号,其中有7种数字调制信号(4ASK、QPSK、2FSK、QAM16、8PSK、GFSK、BPSK),3种模拟调制信号(AM_DSB、AM_SSB、WBFM)。仿真采用高斯白噪声信道,信噪比范围为 $-20\sim 0$ dB,间隔为2 dB。该数据集严格按照其调制方式进行仿真,以4ASK信号为例,在时域图中,该信号通过4种不同的电平值精确地表示二进制数据,这4种离散电平对应不同的符号,完整地展现了实际通信系统中信息传递的动态过程,使得4ASK信号在时域上展现出真实的幅度调制效果。在频域图中,4ASK信号的频谱不仅反映了频带内的能量分布,而且展示出由于幅度变化产生的频率成分和带宽特性。在仿真过程中,数据集严格遵循实际系统中的调制方式,使得时频图更加贴近真实传输中出现的频谱特征。4ASK纯净信号和加噪声信号仿真图如图12所示。

每个信噪比下每种调制信号生成400个样本,同一个信噪比下有10种调制信号,样本数为4000个,所有信噪比下的样本总数为44000个。使用多观测样本累积提高调制信号的信噪比,然后通过小波变换转换为时频图,每个时频图的大小设置为 224×224 。将该数据集按照5:3:2的比例随机分为训练集、验证集和测试集,本文所有实验均基于该数据集进行。

2.3 实验结果与分析

2.3.1 比较实验

采用代表性网络模型与本文模型进行比较,以识别准确率和参数量为评价指标,分析不同模型在调制信号识别任务中的性能差异。对照模型包括CLDNN^[11]、DenseNet^[12]、ResNet101^[12]、改进CNN^[13]和Shuffle Net V2^[14]。不同模型在不同信噪比下的识别准确率见图13。可以看出,本文模型在不同信噪比下一直保持领先的识别准确率。具体来说,当信噪比大于 -10 dB时,本文模型的识别准确率可达到95%以上。

不同模型的参数量和平均识别准确率见表1。可以看出,本文模型与ResNet101模型的平均识别准确率最为接近,但是ResNet101模型的参数量比本文模型多590倍左右。本文模型与CLDNN模型的参数量最为接近,但是本文模型的平均识别准确率比CLDNN模型高出12.58%。综上所述,本文模型在较小的参数量下实现了较高的识别准确率。

为进一步证明本文模型的有效性,将信噪比为 -2 dB时各模型的识别结果以混淆矩阵的形式表现出来,具体如图14所示。混淆矩阵图中横轴表示真实调制方式,纵轴表示预测调制方式,若预测值与真实值重合则表示识别结果正确,没有重合则表示识别结果错误,错误预测值所在的位置表示分类错误的调制方式^[15-16]。混淆矩阵中对角




Fig. 12 4ASK signal simulation diagram

图12 4ASK信号仿真图




Fig. 13 Recognition accuracy of different models under different signal-to-noise ratios

图13 不同模型在不同信噪比下的识别准确率

Table 1 Comparison of parameter counts and average recognition accuracy of different models

表1 不同模型参数量与平均识别准确率比较

模型	参数量	平均识别准确率/%
本文模型	70 026	90.68
CLDNN	701 834	78.10
Shuffle Net V2	2 631 778	83.10
DenseNet	6 962 954	82.60
ResNet101	41 361 226	86.70
改进CNN	82 480 970	75.10

线的颜色越深,表示整体识别准确率越高^[17-18]。由图14可以看出,在相同的信噪比下,本文模型的信号识别效果最优。其他模型中错误分类较严重的为PSK信号,但是本文模型可以较好地识别PSK信号,平均识别准确率可达到100%;而ResNet101、DenseNet、Shuffle Net V2、改进CNN和CLDNN模型的平均识别准确率分别为95.9%、95.9%、95.0%、81.3%和72.0%。




Fig. 14 Confusion matrix of different models at a signal-to-noise ratio of -2dB

图14 信噪比-2 dB时不同模型的混淆矩阵

2.3.2 消融实验

为探究在轻量级网络中加入注意力机制和Res-SCConv模块的效果,设置以下消融实验。比较模型有5种:①模型一为4个基础的DSC块,能在减少计算量和参数量的前提下更加有效地提取空间特征;②模型二在模型一的基础上加入残差块,通过残差连接将输入直接传递到输出,在网络层数加深时仍然能有效传递梯度,缓解梯度消失问题;③模型三在模型二的基础上加入注意力机制,使模型更聚焦于重要特征,抑制无关特征,减少噪声对特征的影响;④模型四在模型三的基础上融合了SCConv模块,可有效整合空间和通道信息,提升特征表达能力;⑤模型五在模型四的基础上改进了SCConv模块,即本文模型,可有效减少空间和通道维度的特征冗余,抑制噪声干扰,同时高效提取细节特征。不同消融模型在不同信噪比下的识别准确率见图15。可以看出,随着信噪比的增加,各模

型的识别准确率随之增加,且本文模型的识别准确率一直保持领先水平。




Fig. 15 Recognition accuracy of different ablation models under different signal-to-noise ratios

图15 不同消融模型在不同信噪比下的识别准确率

不同消融模型的平均识别准确率见表 2。可以看出,随着模块的增加,模型的平均识别准确率逐渐提升。具体来说,基础模型加入残差块后平均准确率有 3.7% 的提升,加入注意力机制后平均准确率有 3.53% 的提升,融合 SC-Conv 后平均准确率有 0.81% 的提升,改进 SCConv 后平均准确率有 1.44% 的提升。添加所有改进模块后获得本文模型,同时也达到最高的平均识别准确率。

Table 2 Average accuracy of different ablation models

表 2 不同消融模型的平均识别准确率 (%)	
模型	平均识别准确率
模型一	80.80
模型二	84.50
模型三	88.03
模型四	89.24
本文模型	90.68

3 结语

针对网络模型参数量较大以及低信噪比下 AMR 准确率较低的问题,本文提出一种结合多项优化策略的改进模型。首先,对调制信号进行多观测样本累积以提高信噪比;其次,通过小波变换将信号转换为时频图,将时频图输入到基于 DSC 的网络结构中,利用其低参数量和高效特征提取能力的优势搭建基础网络,同时加入注意力机制,使模型能够聚焦于重要特征区域;最后,将残差块与改进 SC-Conv 模块进行融合,有效减少了空间和通道维度上的特征冗余,抑制噪声干扰,进一步优化了识别精度。验证实验表明,所提模型在低信噪比下的识别准确率显著提升,同时保持了较低的参数量。在信噪比为-20 dB 时,该模型的识别准确率达到 63%,为资源受限场景的应用提供了较优选择。然而,本文模型特征提取单一,未来将进一步融合多样化特征,以提高低信噪比条件下的调制类型分类性能,增强模型在复杂信号环境中的适应性和泛化能力^[19]。

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), 2011, 41(4): 455-469.

[2] HUANG S, LIN C, XU W, et al. Identification of active attacks in Internet of Things: joint model- and data-driven automatic modulation classification approach[J]. IEEE Internet of Things Journal, 2021, 8(3): 2051-2065.

[3] WANG Y, GUI G, OHTSUKI T, et al. Multi-task learning for generalized automatic modulation classification under non-gaussian noise with varying SNR conditions [J]. IEEE Transactions on Wireless Communications, 2021, 20(6): 587-3596.

[4] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks [C]//The 17th International Conference on Engineering Applications of Neural Networks, 2016: 213-226.

[5] ZENG Y, ZHANG M, HAN F, et al. Spectrum analysis and convolutional neural network for automatic modulation recognition [J]. IEEE Wireless

Communications Letters, 2019, 8(3): 929-932.

[6] LIU X Y, YANG D Y, ALY E G. Deep neural network architectures for modulation classification [C]//51st Asilomar Conference on Signals, Systems and Computers, 2017: 915-919.

[7] CHEN H, GUO W P, KANG K. Automatic modulation recognition based on channel gated Res2Net convolutional neural network [J]. Telecommunication Engineering, 2023, 63(12): 1869-1875.

陈昊, 郭文普, 康凯. 通道门控 Res2Net 卷积神经网络自动调制识别 [J]. 电讯技术, 2023, 63(12): 1869-1875.

[8] YIN Z, WANG C J, CHENG Z H, et al. An automatic modulation recognition algorithm based on an attention mechanism convolutional neural network model [J]. Chinese Journal of Radio Science, 2023, 38(5): 773-779.

殷赞, 王超杰, 程子恒, 等. 一种基于注意力机制卷积神经网络模型的自动调制识别算法 [J]. 电波科学学报, 2023, 38(5): 773-779.

[9] ZHOU S Y, LU H, HU Q, et al. A low signal-to-noise ratio automatic modulation recognition method based on CGDNN [J]. Computer Applications and Research, 2024, 41(8): 2489-2495.

周顺勇, 陆欢, 胡琴, 等. 基于 CGDNN 的低信噪比自动调制识别方法 [J]. 计算机应用研究, 2024, 41(8): 2489-2495.

[10] ZENG Y, ZHANG M, HAN F, et al. Spectrum analysis and convolutional neural network for automatic modulation recognition [J]. IEEE Wireless Communications Letters, 2019, 8(3): 929-932.

[11] ZHANG J, FU J L, LIN J M. Modulation signal recognition method based on CLDNN [J]. Computer Applications and Software, 2021, 38(10): 216-220.

张军, 符杰林, 林基明. 基于 CLDNN 的调制信号识别方法 [J]. 计算机应用与软件, 2021, 38(10): 216-220.

[12] LIU X Y, YANG D Y, GAMAL A E L. Deep neural network architectures for modulation classification [C]//Proceedings of 2017 51st Asilomar Conference on Signals, Systems, and Computers, 2017: 915-919.

[13] ZHANG J, YU L, HOU C B, et al. Modulation recognition of frequency-hopping signals based on time-frequency features [J]. Journal of Terahertz Science and Electronic Information Technology, 2022, 20(1): 40-46.

张静, 于蕾, 侯长波, 等. 基于时频特征的跳频信号调制识别 [J]. 太赫兹科学与电子信息学报, 2022, 20(1): 40-46.

[14] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [DB/OL]. <https://arxiv.org/abs/1807.11164>.

[15] ZHANG F, LUO C, XU J, et al. An efficient deep learning model for automatic modulation recognition based on parameter estimation and transformation [J]. IEEE Communications Letters, 2021, 25(10): 3287-3290.

[16] LIN S, ZENG Y, GONG Y. Learning of time-frequency attention mechanism for automatic modulation recognition [J]. IEEE Wireless Communications Letters, 2022, 11(4): 707-711.

[17] ZHANG X, ZHAO H, ZHU H, et al. NAS-AMR: neural architecture search-based automatic modulation recognition for integrated sensing and communication systems [J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(3): 1374-1386.

[18] LEBLEBICI M, ÇALHAN A, CICIOĞLU M. CNN-based automatic modulation recognition for index modulation systems [J]. Expert Systems with Applications, 2024, 240: 122665.

[19] JDID B, HASSAN K, DAYOUB I, et al. Machine learning based automatic modulation recognition for wireless communications: a comprehensive survey [J]. IEEE Access, 2021, 9: 57851-57873.

(责任编辑:尹晨茹)