

基于改进深度可分离复值网络的开集调制识别方法

洪青青 张治中

(南京信息工程大学电子与信息工程学院 南京 210044)

摘要:近年来,调制识别作为无线通信信号处理中的关键技术,在复杂开放环境下面临开集识别能力不足以及深度学习模型对输入相关性利用有限等挑战。针对上述问题,本文提出了一种基于改进深度可分离复值网络的开集调制识别方法。具体而言,该方法在深度可分离复值网络结构中引入多维注意力机制,有效挖掘信号幅度与相位之间的关联特征,并通过解码器辅助特征提取,实现多损失融合优化,包括平滑标签交叉熵、动态中心约束及重构误差,提升特征分布区分性和模型泛化能力。在公共数据集 RadioML2016.10a 上的实验表明,该方法在闭集识别任务中对已知类别的分类准确率达到 95%,在开集识别场景下,已知类别的识别准确率为 93%,未知类别的检测率为 86%,整体开集识别性能为 89%。上述结果展现出优异的开放环境适应能力。

关键词:深度可分离复值网络;开集识别;复值注意力;多维损失

中图分类号: TN92 **文献标识码:** A **国家标准学科分类代码:** 510.5015

Open-set modulation recognition method based on the improved deep separable complex-valued network

Hong Qingqing Zhang Zhizhong

(School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: In recent years, modulation recognition, as a key technology in wireless communication signal processing, has faced challenges such as insufficient open-set recognition capability and limited utilization of input correlation in deep learning models in complex open environments. To address these issues, this paper proposes a modulation signal open-set recognition method that integrates complex-valued attention and multi-dimensional loss functions. Specifically, this method introduces a multi-dimensional attention mechanism into the deep separable complex-valued network structure, effectively mining the correlation features between signal amplitude and phase, and achieves multi-loss fusion optimization through a decoder-assisted feature extraction, including smooth label cross-entropy, dynamic center constraint, and reconstruction error, to enhance the feature distribution discrimination and model generalization ability. Experiments on the public dataset RadioML2016.10a show that this method achieves a classification accuracy of 95% for known categories in the closed-set recognition task, and in the open-set recognition scenario, the recognition accuracy for known categories is 93%, the detection rate for unknown categories is 86%, and the overall open-set recognition performance is 89%. These results demonstrate excellent adaptability to open environments.

Keywords: deep separable complex-valued network; open-set recognition; complex-valued attention; multi-dimensional loss

0 引言

无线通信技术的迅猛发展使得电磁频谱资源日趋紧张,其分配和使用也变得更加复杂。为缓解当前问题,自动调制识别(automatic modulation recognition, AMR)作为调制解调技术的关键分支,在频谱智能管理、军事通信侦察、认知无线电(cognitive radio, CR)动态频谱接入等领域发挥

着不可替代的作用。

传统 AMR 技术主要分为两大类^[1],但其局限性在复杂电磁环境中愈发凸显:基于似然的方法和基于机器学习的方法。基于似然的方法严重依赖“信号服从特定分布”“信道环境已知且稳定”的刚性假设,而这种假设在复杂的电磁环境中并不总是有效。基于机器学习的方法,该类方法以手工设计特征为核心,通过选取适配的分类器训练模

型以寻找最优分类方案。尽管各种分类方法和判别特征在调制识别中的到了广泛的研究,但仍需要广泛的专家知识且泛化能力较弱,难以适配调制方式日益多样的现实通信环境。

近些年,神经网络凭借自动提取高维抽象特征的能力,成为突破传统 AMR 技术瓶颈的主流方向。例如,杨小洪等^[2]提出一种将波形优化与深度识别网络结合的 AMR 方法,该方法在开源数据集上验证了其有效性,相比传统 CNN 方法识别率提升约 7%。然而,该类基于参数化波形优化的方法在带来性能增益的同时,也显著增加了模型的训练复杂度和计算开销;An 等^[3]提出一种阈值自编码器去噪卷积神经网络,通过动态抑制噪声,在 -15 dB 下较传统方法提升 70% 精度,但网络参数量倍增,难以适配嵌入式设备;Shi 等^[4]研究了基于改进的网络复杂性的用于自动调制识别的轻量级网络,通过上下采样调整特征图大小后,通过调整卷积核的数量和叠加大小卷积核来降低网络参数,但实值模型对复值信号的割裂处理仍导致幅度-相位协同信息丢失,在 16QAM 与 64QAM 混淆场景下高误判率。需注意的是,无线通信中的调制信号本质为复值信号,由同相分量与正交分量构成,而现有主流深度模型多基于实值卷积神经网络(convolutional neural networks, CNN)设计,将复值信号的实部、虚部分解为独立通道处理,割裂了两者的内在关联,导致幅度与相位协同信息丢失,严重制约识别性能提升。为充分利用复数信号之间的相关性,改善信号调制识别性能,复值卷积神经网络(complex valued convolutional neural networks, CV-CNN)应运而生:文献[5]首次提出复值卷积层与复值批归一化等,验证了 CV-CNN 在射频信号任务中较实值模型性能提升了 15%;文献[6]进一步将 CV-CNN 与轻量级的深度可分离的卷积网络^[7]结合,通过简化复数运算单元提升特征学习深度,但其仅采用单一损失函数进行分类,难以实现“类内特征紧凑、类间特征可分”的优化目标,且模型局限于闭集识别场景,限制了工业场景部署的实用性。

事实上,针对轻量级深度学习模型在特征提取和优化目标的局限,近期研究已从不同维度上提出改进方案。在损失函数与特征学习层面,文献[8]结合度量学习的多维损失函数,旨在通过压缩类内特征距离来提升开集识别精度。在网络结构层面上,文献[9]设计了一种数据重建和极值理论生成对抗网络(reconstructed data and EVT GAN, RE-GAN),直接证实了在轻量化模型基础上实现高效开集识别的可行性。

然而,上述研究大多从单一维度提升开集识别精度和性能。结构改进类工作未显式优化特征空间以应对未知类别;而 RE-GAN 虽专注于开集识别,但其生成式框架完全脱离了典型模型,在模型效率与判别性上局限。

为此,本文提出一种基于改进深度可分离复值网络的开集调制识别方法。具体而言,本文以文献[6]提出的深度可分离复值网络为基础架构,不仅在结构上引入复值注意力机制以充分挖掘幅度与相位分量的内在相关性;更在优化机制中增设解码器模块,辅助提取调制信号的判别性特征,并采用多维损失融合机制(含平滑标签交叉熵、动态中心约束与重构误差),最终在保持轻量级判别模型高效优势的基础上,全面提升其在新环境下的综合性能。

1 深度可分离复值网络的调制识别方法简述

复值深度可分的调制识别方法继承并拓展了复值网络,将复值网络引入到通信领域调制识别中,该网络结构分为了 3 个部分,分别是输入层、复制深度网络层和分类器层。

输入层的作用是从 IQ 信号中分解出两路信号,经过前置处理后送入网络中。复值深度网络层是从预处理后的复值信号中,高效提取具有区分性的调制特征,同时通过深度可分离结构平衡特征提取能力与计算效率。最后分类器层将特征送入分类器中,将复值深度网络层提取的高级特征映射到具体的调制类型类别,并输出识别结果。如图 1 展示了该方法的总体设计。

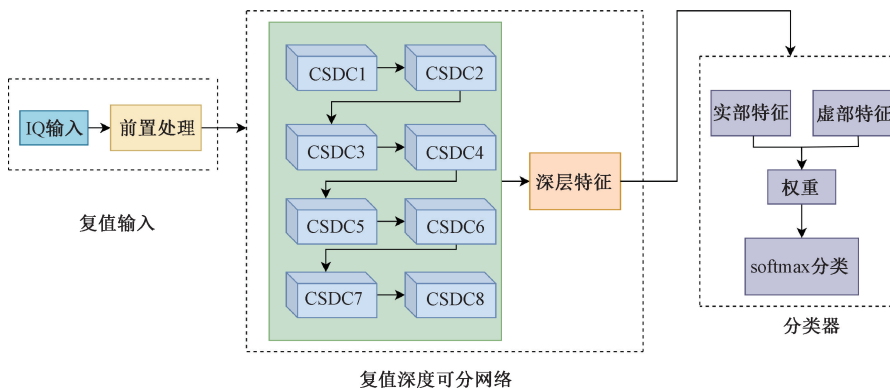


图 1 原始方法设计框架

Fig. 1 Framework of the baseline method

2 基于改进深度可分离复值网络的开集调制识别方法

为提升调制识别的精确性,本文提出了一种改进深度可分离复值网络的开集调制识别方法,图 2 展示了本方法的整体设计框架,由复数输入信号部分、基于改进的深度可分离复值网络、解码器、多损失计算部分和分类器构成。模型首先将输入的复数信号分解为实部和虚部进行预处

理,随后通过级联的深度可分离块提取多层次特征,每个模块均包含深度可分离卷积和双域注意力机制,在减少参数数量的同时增强特征表达能力。解码器部分采用对称结构从深层特征中重构原始信号,通过重构损失约束特征学习。多损失计算部分将 3 类损失融合输入到分类器,最终分类器对多尺度特征进行融合判分并自动搜索最佳阈值后,利用最佳阈值进行分类识别并更新未知类动态特征中心。

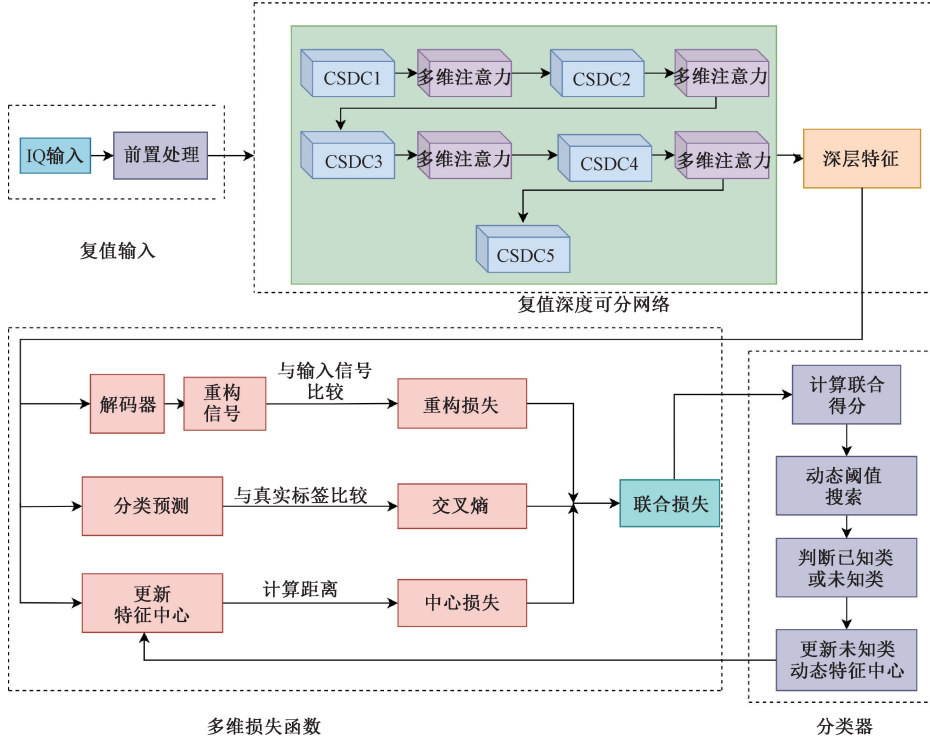


图 2 本文方法设计框架

Fig. 2 Framework of the proposed method

2.1 多维复合注意力模块

注意力机制源于人类视觉系统的选择性关注特性^[10],在深度学习框架中,该机制通过对输入特征实施差异化动态权重分配,使网络能够主动聚焦于输入特征的关键区域。然而针对于调制信号识别任务中,基础的复值深度可分离网络仍对复值信号幅度相位关联挖掘不充分,特别是在一些易混淆信号会在图中相互重叠^[11]。基于此本文设计引入多维注意力机制,旨在深度提高信号识别率。

对于输入张量 $\mathbf{X} \in \mathbb{C}^{B \times 2C \times L}$, B 表示批次大小, $2C$ 表示通道数,分为实部和虚部, L 表示信号长度,其中 \times 表示张量的维度。图 3 展示了复值域注意力机制流程图。添加频域通道注意力,让模型学习到不同频率通道的重要性权重,首先利用复值平均池化和最大池化得到全局特征,其次通过后续处理生成通道权重,得到权重 ca 如下:

$$ca = \sigma(W_1 W_2 (\text{ReLU}(W_{1\text{avg}} W_1 \text{avg})) + W_1 W_2 (\text{ReLU}(W_{1\text{max}} W_1 \text{max}))) \quad (1)$$

其中, W_1, W_2 全连接层参数, σ 为 Sigmoid 激活函数, ReLU 为激活函数。

对通道加权:

$$\mathbf{X}_{ca} = \mathbf{X} \otimes ca \quad (2)$$

其中, \otimes 表示逐通道广播乘法。

为实现学习时间维度上关键区域的权重,首先分解复数信号,得到幅度:

$$mag = \sqrt{(I^2 + Q^2 + \epsilon)} \quad (3)$$

在这里为防止梯度爆炸,设置 $\epsilon = 10^{-6}$, 然后加上相位特征:

$$phase = \text{atan2}(I, Q + \epsilon) \quad (4)$$

和平均值 avg 和最大值 max, 形成空间权重:

$$spatial_feat = \text{concat}([\text{avg}, \text{max}], \text{dim} = 1) \quad (5)$$

其中, 通道维度为 1, concat 为张量拼接。

得到最终的空间加权输出:

$$sa = \sigma(\text{Conv}_{1D}(spatial_feat)) \quad (6)$$

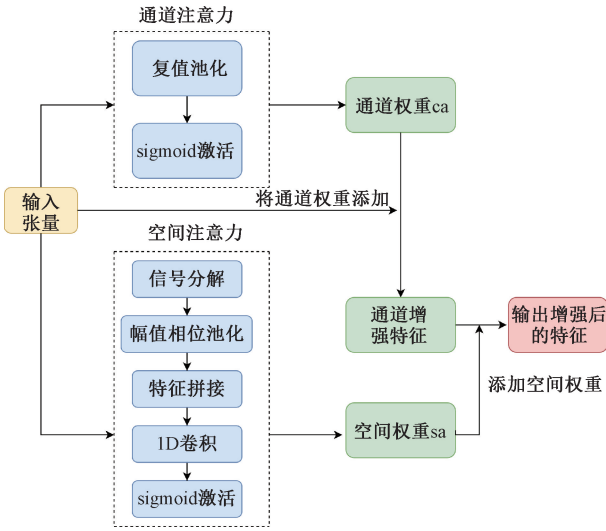


图3 注意力机制流程图

Fig. 3 Flowchart of the attention mechanism

2.2 多维损失函数

本模块针对单一损失无法兼顾多目标优化的痛点,设计所用模型通过反向传播梯度更新参数来优化性能指标。具体采用交叉熵损失、特征中心化损失和重建损失的加权组合作为综合目标,其定义形式为:

$$L_{\text{total}} = \alpha L_{\text{CE}} + \beta L_{\text{Center}} + \gamma L_{\text{Recon}} \quad (7)$$

其中, α, β, γ 分别表示3类损失在总损失中的权重。

为了更好的在特征空间内明确特征分布,模型使用了平滑标签后的交叉熵损失,最大化类间距离。改进后的损失函数为:

$$L_{\text{CE}} = - \sum_{k=1}^K q(k) \log p(k) \quad (8)$$

其中, q 表示平滑后的真实标签概率分布, p 表示模型的预测概率分布。通过平滑硬标签、利用交叉熵衡量模型预测分布与平滑后真实分布的差异,让模型学习平滑后的分布,从而提升泛化能力。

为实现类内特征紧致,聚合类间特征有效分离的表征学习目标,在模型训练过程中引入动态类中心机制:使每个类别的特征中心随样本迭代动态更新,同时通过损失函数的监督,强制特征向动态类中心聚拢。在此过程中,类中心能够根据新输入的训练样本调整,最终实现“类间分离,类内紧凑”的目标。由此,构建动态中心损失的数学表达式:

$$L_{\text{Center}} = \frac{1}{2N} \sum_{i=1}^N \| \mathbf{f}_i - \mathbf{c}_{y_i} \|^2 \omega_{y_i} \quad (9)$$

其中, \mathbf{f}_i 为 $\mathbf{F}(\mathbf{x}_i)$, N 表示训练批次中的样本总数, i 为样本的索引, \mathbf{c}_{y_i} 表示 y_i 真实类别对应的动态类中心, ω_{y_i} 表示权重系数。

为获取重构损失部分,在网络架构编码器后,加上解码器部分,将编码器输出的特征通过表1结构映射到2个

通道(实部和虚部),得到与原始输入下采样之后相同长度的重构信号,采用对称的复值卷积结构,逐步恢复信号的空间分辨率。解码器网络结构参数如表1所示。

表1 解码器层级结构参数

Table 1 Parameters of decoder hierarchy structure

层级	输入通道	输出通道	操作	输出维度
DeConv1	512	256	DeConv	$L \times 256$
DeConv2	256	128	DeConv	$L \times 128$
DeConv3	128	64	DeConv	$L \times 64$
DeConv4	64	2	DeConv	$L \times 2$

表1中 L 表示信号长度。其中提到的复值反卷积操作定义为:

$$\text{DeConv}(\mathbf{Z}, \mathbf{W}) = \text{DeConv}(\mathbf{X} + j\mathbf{Y}, W_r + jW_i) = \text{DeConv}(\mathbf{X} + W_r) - \text{DeConv}(\mathbf{Y} + W_i) + \text{DeConv}(\mathbf{X} + W_i) + \text{DeConv}(\mathbf{Y} + W_r) \quad (10)$$

式中: \mathbf{Z} 表示复数张量, \mathbf{Z} 的实部为 \mathbf{X} , \mathbf{Z} 的虚部为 \mathbf{Y} , \mathbf{W} 为复数核,其中 W_i 为复数核实部, W_r 为复数核虚部。

通过解码器部分,可得到重构信号,利用均方误差衡量重构质量:

$$\text{MSE} = \frac{1}{TL} \sum_{t=1}^T \sum_{l=1}^L |x_t^{(l)} - \hat{x}_t^{(l)}|^2 \quad (11)$$

其中, T 为批处理大小, $x_t^{(l)}$ 表示在时间点 t 上,原始信号的第 l 个通道的值, $\hat{x}_t^{(l)}$ 表示在时间点 t 上,重构信号的第 l 个通道的值。

2.3 动态联合判别分类器

分类器是机器学习系统实现数据分类功能的重要模块,用于将数据样本分为不同的类别^[12]。然而,传统闭集分类器在开放环境下的性能失效,根源在其存在两个本质性缺陷:一是静态特征空间假设:固定类别中心无法适应新增类别;二是单模态判别局限:仅依赖特征距离或重构误差单一维度。在调制识别任务当中,类似于 QAM64 和 QAM16, 8PSK 和 QPSK 等特征空间易重叠,无法有效区分。因此本文提出动态联合判别分类器框架,下面逐步介绍分类器框架。

1) 动态特征中心库

对于每个已知类别,计算其所有训练样本的特征向量的中心:

$$\mathbf{S}_k = \frac{\sum_{j=1}^m \sigma(y_j = k) \mathbf{F}(\mathbf{x}_j)}{\sum_{j=1}^m \sigma(y_j = k)} \quad (12)$$

其中, m 为训练集样本总数, \mathbf{F} 为样本 x 的深度特征提取, σ 是指示函数。

当出现验证信号 I 出现时,并通过网络得到 $\mathbf{F}(I)$, 可以通过欧式距离获得当前特征与每个已知类别 \mathbf{S}_k 的距离 d , 公式如下:

$$d(\mathbf{F}(\mathbf{I}), \mathbf{S}_k) = \sqrt{(\mathbf{F}(\mathbf{I}) - \mathbf{S}_k)^T \sum_k^{-1} (\mathbf{F}(\mathbf{I}) - \mathbf{S}_k)} \quad (13)$$

当 d_I 远超乎阈值或显著异常, 此时模型自适应将其作为未知类特征中心, 初始化其特征中心 \mathbf{S}_u :

$$\mathbf{F}(\mathbf{I}) = \mathbf{S}_u \quad (14)$$

当样本 I 被判定属于已知类别 k , 更新该类的特征中心 $\mathbf{S}_k^{(new)}$:

$$\mathbf{S}_k^{(new)} = \frac{n_k \cdot \mathbf{S}_k + \mathbf{F}(\mathbf{I})}{n_k + 1} \quad (15)$$

同时更新类别 k 的样本计数:

$$n_k^{(new)} = n_k + 1 \quad (16)$$

其中, n_k 为样本更新前类别 k 的累计样本数量。

2) 联合评分机制

本方法采纳了基于评分机制的分类器的核心理念。具体而言, 该方法通过综合考虑已知类别间的距离度量、未知类别间的距离度量以及重构误差, 构建了一个联合得分机制。这一机制旨在评估样本属于已知类别或未知类别的可能性, 从而实现对开集环境中的样本进行有效识别。

对于样本 I 到最近的未知类中心的距离:

$$dist_{unknown} = \min_{u \in U} \sqrt{(\mathbf{F}(\mathbf{I}) - \mathbf{S}_u)^T \sum_k^{-1} (\mathbf{F}(\mathbf{I}) - \mathbf{S}_u)} \quad (17)$$

到最近已知类的中心的距离:

$$dist_{known} = \min_{k \in K} \sqrt{(\mathbf{F}(\mathbf{I}) - \mathbf{S}_k)^T \sum_k^{-1} (\mathbf{F}(\mathbf{I}) - \mathbf{S}_k)} \quad (18)$$

重构误差:

$$rec_{err} = \|I - Decoder(\mathbf{F}(\mathbf{I}))\|_2^2 \quad (19)$$

其中, U 是未知类中心集合, K 为已知类中心集合,

$Decoder(\cdot)$ 为特征重构网络。

联合得分公式如下:

$$joint_{score} = dist_{unknown} - dist_{known} + \lambda rec_{err} \quad (20)$$

其中, λ 是一个权重参数, 用于调整重构误差在联合得分中的重要性如果联合评分大于阈值, 则将该样本判为未

知类, 调整预测标签为 -1, 否则, 将该样本判为已知类。

3) 自适应阈值最优

在分类器设计中, 阈值选取^[13]是决定模型最终性能的关键环节。本文引入数据驱动的优化策略, 具体流程如下: 首先基于验证集样本计算联合得, 并通过极差归一化将得分映射至 $[0, 1]$ 区间; 随后基于得分分布的分位数分析确定候选阈值范围, 采用网格搜索法以 0.05 为步长系统遍历所有候选阈值; 针对每个候选阈值, 同步计算两个关键性能指标, 反映整体判别效能的 AUROC, 以及平衡精确率与召回率的 F1 分数。当 AUROC 和 F1 分数存在冲突时, 如提高 F1 可能降低 AUROC, 此时引入帕累托前沿分析, 在 AUROC-F1 的二维优化空间中确定最优平衡点, 选取对应阈值作为模型决策边界。该方法通过双重指标约束和系统搜索策略, 确保了阈值选择的客观性和泛化性能。

3 实验及结果分析

3.1 数据集及实验细节

为了评估所提模型的性能, 实验使用数据集 RadioML2016.10a 进行验证。RadioML2016.10a 包含了 220 000 个调制信号, 信噪比范围为 $-20 \sim 18$ dB, 增量步长为 2 dB。它包括 11 种调制信号, 包括 3 种模拟调制 (AM-DSB、AM-SSB 和 WBFM) 和 8 种数字调制 (8PSK、BPSK、CPFSK、GFSK、4-PAM、16-QAM、64-QAM 和 QPSK)。表 2 为数据集信息。在这个数据集中, 每个信号包括 128 个浮点 I/Q 样本, 这些样本是在模拟的恶劣设置中产生的, 受到各种干扰 (如 AWGN、中心频率偏移和多径衰落)。本文已知类数据集按照 2:1 的比例进行分割, 其中 800 个信号作为训练集, 400 个信号作为验证集, 未知类由训练集的排除类的 20% 样本构成验证集未知类部分, 具体细节如表 3 所示。

表 2 RadioML2016. a 信息

类别数	信噪比/ dB	每类别各 信噪比样本数	总样本数	特征 维度
11	$-20 \sim 18$	1 200	220 000	2×128

表 3 数据集划分细节

Table 3 Details of dataset division

数据库	信噪比/dB	数据分配	类别	总样本数
RadioML2016. a	$-12 \sim 18$	I 类	训练集	11 类已知类 140 800
			验证集	11 类已知类 70 400
		II 类	训练集	9/10 类已知类 115 200/128 000
			验证集	10/9 类已知类 + 1/2 类未知类 64 000/57 600 已知类 + 3 200/6 400 未知类

3.2 实验环境和评价指标

本文所使用的实验的环境为 python3.9、pytorch 为 2.0.0、GPU 为 RTX4090(32 GB)、CUDA 为 11.8。

实验对所有模型应用 Adam 优化器,初始学习率设为 1×10^{-3} ,采用余弦退火策略调整学习率;批大小为 128 个,训练迭代次数 50 次。训练为了确保公平的评估,对每个网络进行 5 次独立实验,最终性能指标取 5 次实验的平均值。使用了以下 3 个性能评价指标:

1) 总体精度。指的是正确分类样本数占总样本数的比例,是最常用的分类性能衡量指标,适用于类别分布均衡的任务。

2) F1。包括了精确率和召回率的调和平均,用于衡量模型在不平衡数据下的综合性能,数值越高表示识别更全面且准确。

3) AUROC。表示模型区分正负样本的能力。AUROC 越接近 1,说明模型越能正确判断未知类别与已知类别之间的差异。

3.3 对比实验

1) 基线模型的对比实验

本文提出通过增加注意力机制增强网络,优化信号的识别率。首先为了验证基线模型的有效性,本文选取了经典网络与基于复值卷积的方法进行对比,此外复值卷积的前身是实值卷积,因此,本文设立了 4 种模型的对比:

基于去噪自编码器(denoising autoencoder, DAE)的实值模型^[14]。其核心逻辑是通过 DAE 的编码-解码过程增强输入特征的抗噪性,在传统调制识别任务中应用广泛。但局限性显著:未利用调制信号的相位、幅度的协同关系。将选择其作为对照的基线模型,一方面可以清晰地展示处理复数信号时,实值模型固有的理论局限性与性能瓶颈,另一方面本文借鉴编码-解码过程这一核心思想,生成重构误差作为联合开放集识别判据的核心指标。

复值深度可分离网络(complex-valued depth wise separable convolutional neural network, CSDCNN),属于复值卷积神经网络^[15]的一种,具备处理频域复数信号的能力。网络结构中包含多个 CSDC(complex spectral domain convolutional, CSDC)块,适合调制信号等频域特征显著的任务。相比实值 CNN,该结构在保留信号本征特性方面更具优势。

本文模型以 CSDCNN 为基础架构,继承了 CSDCNN 优异的复数特征提取能力,核心创新是引入多维注意力机制:在 CSDC 块的特征输出端,分别从时域-频域双维度、通道维度设计注意力权重。实现对关键特征的动态校准与增强,从而显著提升了模型在恶劣信道条件下的鲁棒性与识别率。构建一个更加强大的特征提取基础架构,为后续的开放集识别任务奠定了坚实基础。

为了评估本文提出的模型的优化识别信号性能,实验利用表 3 中划分的 I 类数据集,表 4 展示了各类基线架构

在验证集上的性能,其中,本文所提出的模型架构 OA 为 95%,最小验证损失为 0.976 5,准确率较于基本的 CSDCNN 模型上涨了 38.4%,较 DAE 模型上涨 31.5%,和 RE-GAN 模型不相上下;最小损失方面,本文的最小损失最小;参数量方面,较 CSDCNN 下降 17.1%,本文模型与 RE-GAN 准确率相当的情况下,模型的参数下降了较 RE-GAN 下降 9.3%,较 DAE 下降 34.7%。此外,本文提出模型 F1 为 0.724 3,这样高的调和平均的精确率和召回率反映了模型捕获了已知类当中大部分样本,对预测的样本有较高的置信度。综上所述,实验数据充分表明,在准确率、轻量级维度中获取最佳平衡。

表 4 RadioML2016. a 验证集上的性能比较

骨干架构 (SNR18dB)	总体 精度 (OA)/ %	F1	AUROC	时间 (验证/ h)	最小 损失	参数/ M
CSDCNN	68.63	0.570 1	0.633 2	0.038 1	1.038 0	0.35
DAE	72.24	0.370 1	0.621 7	0.044 1	1.893 0	0.46
RE-GAN	94.00	0.721 1	0.880 0	0.030 0	1.014 0	0.32
本文模型	95.00	0.724 3	0.897 1	0.025 0	0.976 5	0.29

图 4 提供了特征空间的可视化结果比较。在可视化结果比较中,可以明显观察到,在 SNR 为 -4 dB 条件下,本模型如图 4(a),大部分类别识别效果良好,仅在 QAM64 和 QAM16 两者之间出现明显重叠;而其余两类模型如图 4(c)和(e)在该 SNR 下几乎失效,无法准确识别,因此,可体现出本模型在低 SNR 下的有效性;在 SNR 为 18 dB 时如图 4(b)所示,本文模型各类间距离较远,类内距离紧凑,特别是本文模型在 8PSK 和 QPSK 和其他调制类型之间表现出更明显的边界,没有明显混淆现象。而其余两类模型如图 4(d)和(f)均未成功分离所有调制识别类型。综合,本模型效果最优,能够成功分类所有类别。

2) 分类器方法对比

为了在开放集识别中更好地区分已知类和未知类样本,本文采用了一种联合评分机制,该评分结合了特征空间中样本与类中心之间的欧氏距离以及重构误差。为公正地评估本文所提分类器的性能,选择了具有代表性的方法进行对比,其选取依据与本文方法对比如下:

SoftMax^[16]:作为经典的封闭集分类器,本文选择其作为性能基线。其固有缺陷在于 softmax 层会将所有样本强制输出一个概率分布,导致对未知类样本产生高置信度的错误。本分类器舍弃 softmax 层,设计开放集联合评分机制,从而能主动识别并拒绝未知类样本。

SR2CNN^[17]:提出了一种基于距离的策略,来划分已

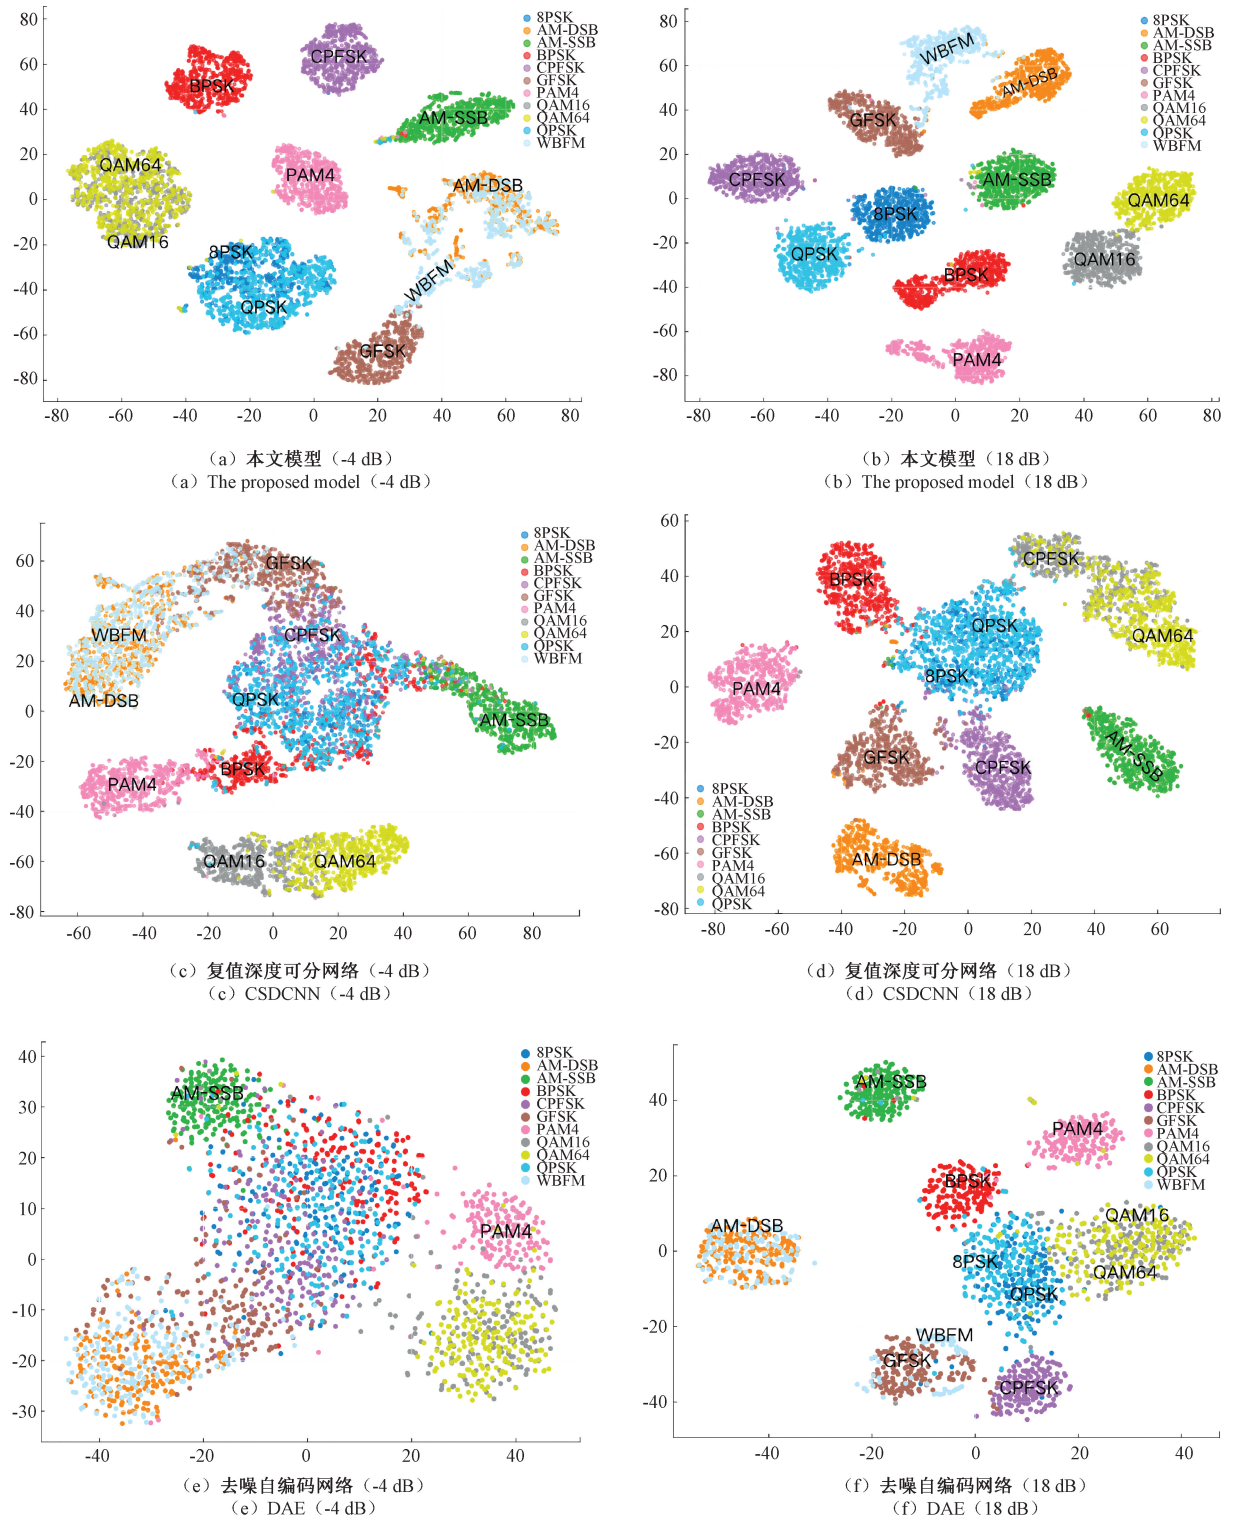


图 4 不同架构在 I 类数据集的特征空间可视化

Fig. 4 Visualization of the feature space of different architectures in class I datasets

知类与未知类界限。本方法延续了 SR2CNN 利用距离,区分在于 SR2CNN 仅依赖单一距离指标,而本方法引入重构误差,形成多因素判据,这种决策使得模型更全面的捕捉未知类的特征。

RE-GAN:作为轻量级开集识别网络模型的代表方法,将它作为对照试验,能更加明确本方法的优势。实验采用表 3 中 II 类数据集,设置一类未知类进行实验,不同开集识别方法性能如表 5 所示。显然,本方法的平均准确

率优于 SoftMax 方法、SR2CNN 方法及文献[9]提出的开集识别方法。本方法已知类识别率较 SoftMax 提升了 40%，相较于 SR2CNN 提升了 20%，与文献[9]相同，未知类较 SoftMax 提升了 72%，相较于 SR2CNN 提升了 8%，较文献[9]上升了 3%。

图 5 展示了不同信噪比下的各方法的识别率，可以观察到，在 -12~-8 dB 附近，本文所提出的开集识别方法无论是添加一类还是两类未知类，已知类识别率都比其他 3 类要高，说明，分类器在低信噪比下表现更优。在 6~18 dB，本方法一类未知类识别率明显升高，其他 3 类方法




图 5 不同信噪比下各分类器的识别率

Fig. 5 Recognition rates of each classifier under different signal-to-noise ratio

3.4 消融实验

1) 多维注意力消融实验

在文献[6]中，实验研究了基线架构中 CDSC 块的数量对其性能的影响(需解决 7 块 CDSC 才能够达到最佳性能)。图 4 同样验证了本文模型与 CDSC 块数量影响关系。实验采取表 3 构建的 I 类数据集划分，设置 SNR 为 16 dB，来验证多维注意力机制对开集识别的有效性。结果表明，可以观察到，配备了 5 个添加多维注意力机制的 CDSC 块的模型在验证集上的效果最佳。

本文的改进方案从根源上应对了这一挑战：复值注意力机制赋予网络对关键特征的聚焦能力，提升了单模块的特征抓取能力；其次解码器重构则通过自监督信号引导网络学习更紧凑、更具判别力的特征表示。因此，如图 6 所示，改进后的网络无需依赖过多的 CDSC 块，即可实现更佳的识别性能。这种设计确保了在减少 CDSC 块数量的情况下，网络仍能学习到丰富且紧凑的特征表示。

2) 多维损失函数的消融实验

在文献[6]中，训练过程中仅用单一的交叉熵损失，致使模型丢失特征，导致信号识别率较低。基于此，本文提

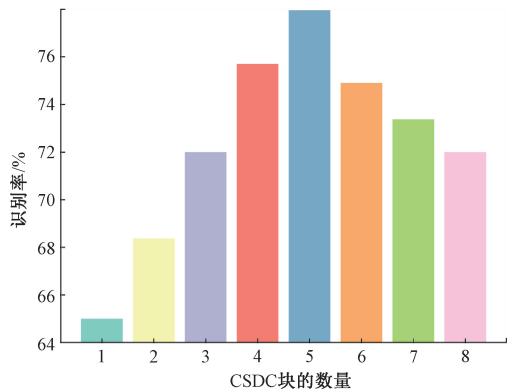


图 6 CDSC 块数量对识别率的影响

Fig. 6 The impact of the number of CDSC blocks on recognition rate

表 5 不同开集识别方法性能

Table 5 Performance of different open set recognition methods

方法	已知类准确率	未知类准确率	平均准确率
本方法	0.93	0.86	0.90
SoftMax	0.66	0.50	0.58
SR2CNN	0.77	0.79	0.78
文献[16]	0.93	0.83	0.88

均有不同程度的上涨，但均未达到本方法识别率，可知本方法识别率最优。

出了多损失函数，在单一损失基础上，添加了重构损失和中心损失，图 7 展示了各类损失随迭代次数的变化。从图 7 训练损失可观察到，总损失函数在前 15 个 epoch 内急剧下降，损失由 42.35 左右下降到 2.3 左右，之后进入缓慢优化阶段，最终收敛在 0.17 附近。

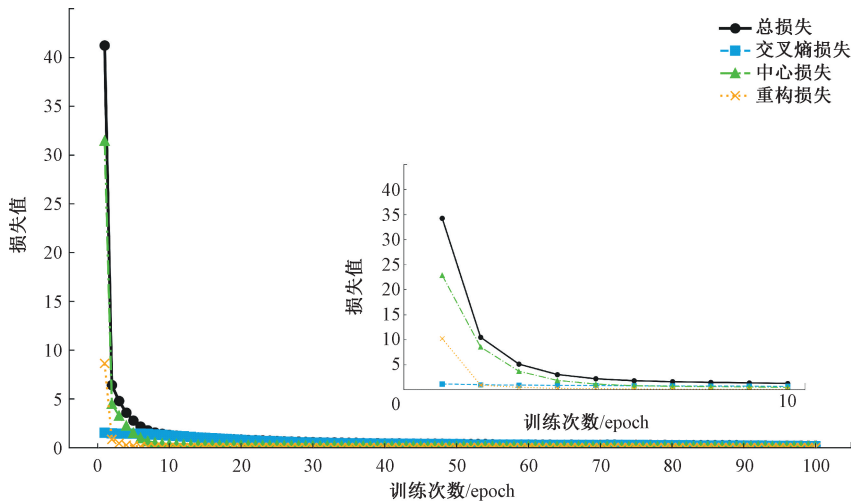


图 7 训练损失

Fig. 7 Training loss

其中重构损失和交叉熵损失都在 epoch10 后稳定缓慢优化,但中心损失直到 25 个 epoch 后才完全稳定,侧面反映了特征空间优化需要更长的训练周期。


实验采取表 3 构建的 II 类数据集划分,设置 SNR 为 16 dB,来验证多损失函数对开集识别的有效性。实验设置采取两种策略,相同数据,一组采用交叉熵损失,另一组采用多损失函数重新训练,其中当设置一类未知类时,将 BPSK 设置为未知类,设置两类未知类为 BPSK 和 WBFM 混合组合,图 8 展示了 2 种策略下的特征空间分布。可以从可视化结果观察到,加入中心损失的类内距离和类内聚集效果更优,在添加一类未知类时,使用单一损失如图 8(a)所示,无法区分叠加的 QAM16 和 QAM64,但是加入多损失函数后如图 8(b)所示,效果明显,95%左右的 QAM16 和 QAM64 能够分离干净,并且每类聚类样本明显增加,说明增强了未知类和已知类的区分,并能够将未知类误分的已知类重新划分。在添加两类未知类后,使用单一损失可以明显观测到如图 8(c)所示,类内距离分散较大,已知类样本数减少,经多损失函数添加后如图 8(d)所

示,类内距离减少,同一种类样本“抱”的更紧密了。这时,有些未知类样本被误判为已知类样本,降低了已知类识别率。综合而言,多损失函数提高了开集识别的性能。

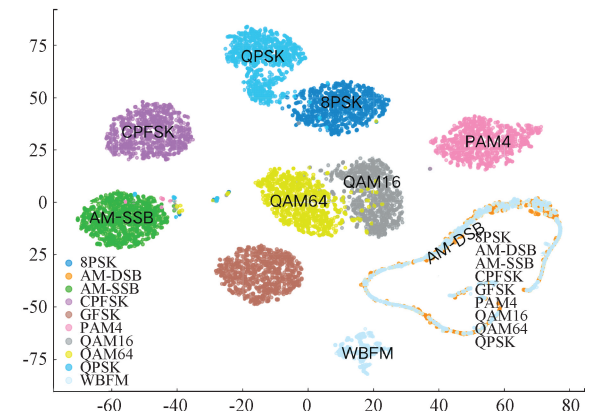
实验通过图 9 混淆矩阵对比分析了不同未知类数量条件下的模型开集识别性能。在一未知类场景下如图 9(a)所示,模型展现出 0.86 的未知类检测准确率和最高 97%的已知类分类准确率,表明其具有优异的开集识别能力。然而,当引入混合两类的未知类时如图 9(b)所示,模型性能下降,体现在未知类识别类下降到 71%,已知类最高分类准确率下降到 91%。这一现象验证了开集识别任务会随着未知类数量增加,模型判别难度增大的基本特性。

3) 分类器核心模块消融实验

为进一步验证分类器中核心模块,其包含了动态特征中心、重构误差联合判分和自适应阈值三大模块,设计 4 组消融实验,具体细节如表 6 所示。实验设置迭代次数为 50 次,动态中心损失 0.8,静态阈值为 0.6,SNR 为 18 dB,分别加入一类未知类和两类混合未知类的进行消融实验。



(a) 未加多损失一类未知类
(a) Class 1 unknown class without multi-loss



(b) 添加多损失一类未知类
(b) Class 1 unknown class with multi-loss

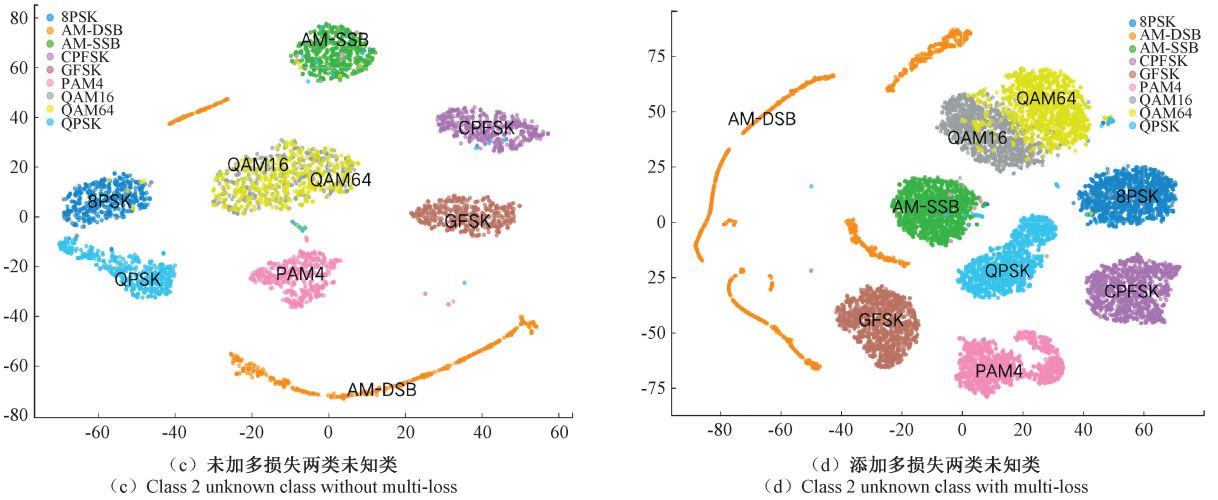


图8 不同损失函数策略在II类数据集上特征空间分布

Fig. 8 Feature space distribution of different loss function strategies on class II datasets

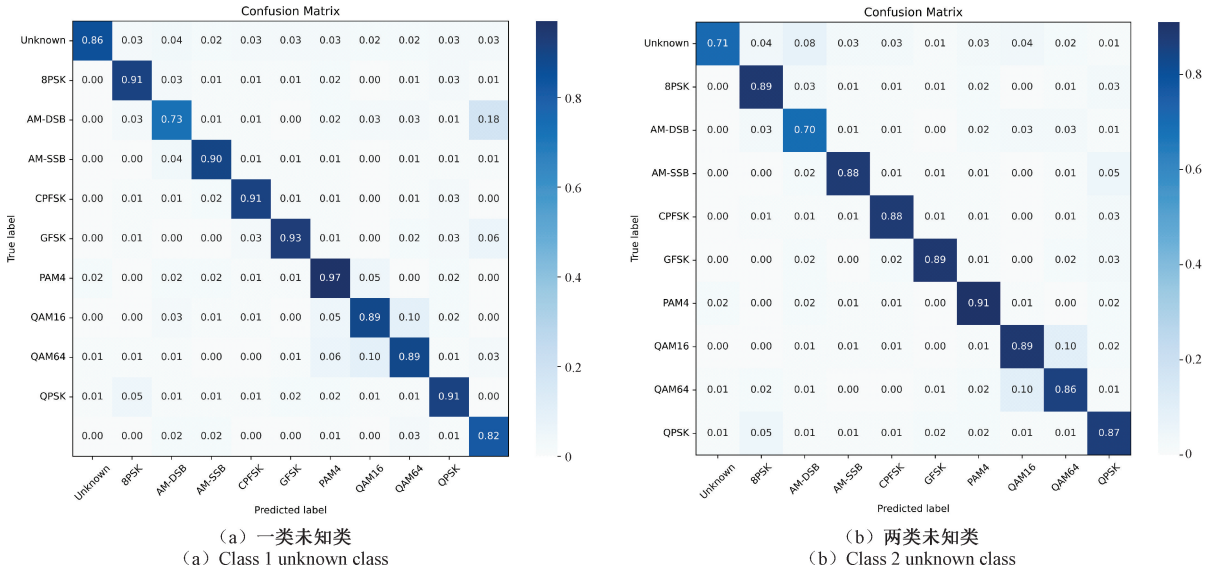


图9 开集混淆矩阵(含未知类)

Fig. 9 Open set confusion matrix (including unknown classes)

表6 分类器消融实验分布

Table 6 Distribution of classifier ablation studies

序号	内容
消融组 1	静态特征中心+距离评分+静态阈值
消融组 2	动态中心+距离评分+静态阈值
消融组 3	动态中心+联合评分+静态阈值
本文完整分类器	包含三大模块

本次消融实验围绕未知类数量和方法复杂度两个变量进行设置,实验结果可以发现无论是一类未知类还是两类未知类场景,依次4组实验,3项指标均表现为持续上涨趋势,由表7结果可观察到:

消融组1的性能显著低于其他组别:一类/两类未知

类场景下F1分数仅0.37/0.33,已知类识别率0.67/0.55,未知类识别率0.56/0.51。考虑是静态特征中心固定初始值,无法随训练优化类内紧凑性与类间分离度,导致已知类特征重叠、未知类与已知类边界模糊。对比消融组2(启用动态中心):一类/两类场景F1提升至0.56/0.54,已知类识别率提升8.9%/18.2%,印证动态中心通过实时更新类中心,有效改善特征分布判别性,为后续评分与决策奠定基础。

消融组2较消融组3(启用联合评分)性能存在差距:一类场景F1从0.56升至0.61,两类场景从0.54升至0.58,未知类识别率从0.63/0.58升至0.73/0.65。当距离评分仅依赖特征距离单一维度,易受噪声干扰;而联合评分融合特征距离差及重构误差,增强对边缘已知类与相

表 7 分类器核心模块消融实验结果

Table 7 Results of ablation experiments for the core module of the classifier

消融组	已知类识别率	未知类识别率	F1 分数	已知类性能 下降幅度/%	未知类性能 下降幅度/%
消融组 1(一类未知类)	0.67	0.56	0.37	28.0	34.9
消融组 2(一类未知类)	0.71	0.63	0.56	23.7	26.7
消融组 3(一类未知类)	0.85	0.73	0.61	8.6	15.1
本文完整方法(一类未知类)	0.93	0.86	0.68	/	/
消融组 1(两类未知类)	0.55	0.51	0.33	36.8	28.2
消融组 2(两类未知类)	0.65	0.58	0.54	25.3	18.3
消融组 3(两类未知类)	0.73	0.65	0.58	12.6	7.9
本文完整方法(两类未知类)	0.87	0.71	0.63	/	/

似未知类的区分能力,直接提升未知类检测的召回率。

完整方法(启用自适应阈值)较消融组 3(静态阈值)性能进一步提升:一类场景 F1 从 0.61 升至 0.68,两类场景从 0.58 升至 0.63,已知类/未知类识别率分别从 0.85/0.73、0.76/0.65 升至 0.93/0.86、0.87/0.71。静态阈值无法适配不同场景的评分分布,易导致漏判未知类或误判已知类;自适应阈值通过搜索最优决策边界,实现 F1 的动态平衡,最终补齐性能短板。

4 结 论

本文提出了改进深度可分离复值网络的开集调制信号识别方法。实验结果表明,本文提出的模型闭集识别率于传统实值网络和基础的深度可分离复值网络,复值深度可分离结构有效保留了信号的相位信息,相比传统实值网络,在-10 dB 低信噪比条件下识别率提升 3.7%。对于闭集识别,模型的识别率能达到 95%左右,可视化结果表明改进后的网络学习到的特征具有更好的类内紧凑性和类间可分性。对于开集识别,添加一类未知类时,已知类识别率在 93%左右,未知类识别率在 86%,添加两类未知类时,已知类和未知类识别类都有所下降,但仍能保持不错水平,已知类识别率在 87%左右,未知类识别率在 71%左右,重构误差分析表明,解码器模块有效增强了模型对噪声干扰的鲁棒性。本研究表明在保持网络轻量化的同时,有效解决了复杂电磁环境下调制信号的开集识别难题,为后续研究提供了新的技术思路。建议后续工作可以重点关注模型在实际通信系统中的部署应用。

参考文献

- [1] CHENNAGIRI R, SEHGAL S, RAVINDER Y. A survey on automatic modulation classification techniques[C]. 2024 Intelligent Systems and Machine Learning Conference(ISML). IEEE, 2024: 94-100.
- [2] 杨小洪,余春泉. 基于波形优化的深度调制识别方法[J]. 电子测量与仪器学报,2020,34(10):186-193.
- [3] YANG X H, YU CH Q. Waveform optimization

based automatic modulation recognition[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(10):186-193.

- [3] AN T T, LEE B M. Robust automatic modulation classification in low signal to noise ratio[J]. IEEE Access, 2023, 11: 7860-7872.
- [4] SHI F Y, YUE CH SH, HAN CH. A lightweight and efficient neural network for modulation recognition[J]. Digital Signal Processing, 2022, 123: 103444.
- [5] MENDIS G J, WEI J, MADANAYAKE A. Deep learning-based automated modulation classification for cognitive radio [C]. 2016 IEEE International Conference on Communication Systems (ICCS). IEEE, 2016:1-6.
- [6] XIAO CH H, YANG SH Y, FENG ZH F. Complex-valued depth wise separable convolutional neural network for automatic modulation classification[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-10.
- [7] 谢坤鹏,仪德智,刘义情,等. SAF-CNN:面向嵌入式 FPGA 的卷积神经网络稀疏化加速框架[J]. 计算机研究与发展,2023,60(5): 1053-1072.
- [8] XIE K P, YI D ZH, LIU Y Q, et al. SAF-CNN: A sparse acceleration framework of convolutional neural network for embedded FPGAs [J]. Journal of Computer Research and Development, 2023, 60(5): 1053-1072.
- [9] 童子滔,张治中,张涛,等. 基于零样本学习和自编码器的调制信号识别研究[J]. 电子测量技术,2024, 47(14): 1-9.
- [10] TONG Z T, ZHANG ZH ZH, ZHANG T, et al. Zero shot learning and autoencoder based modulation signal recognition [J]. Electronic Measurement Technology, 2024, 47(14): 1-9.
- [11] 秦博伟,蒋磊,许华,等. 基于 RE-GAN 的调制信号开

- 集识别算法[J]. 系统工程与电子技术, 2023, 45(10): 3321-3328.
- QIN B W, JIANG L, XU H, et al. Open-set recognition algorithm for modulation signal based on RE-GAN[J]. Journal of Systems Engineering and Electronics, 2023, 45(10): 3321-3328.
- [10] 张起尧, 桑海峰. 深度嵌套注意力下的 SlowFast 信息融合动作识别网络[J]. 电子测量与仪器学报, 2024, 38(3): 159-166.
- ZHANG Q Y, SANG H F. SlowFast information fusion action recognition network based on deeply nested attention mechanism[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(3): 159-166.
- [11] 朱硕, 张绪康, 宾杰, 等. 融合双重观察与注意力机制的灰度图像检测算法[J]. 电子测量与仪器学报, 2025, 39(7): 192-202.
- ZHU SH, ZHANG X K, BIN J, et al. Gray image detection algorithm integrating double observation and attention mechanism [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(7): 192-202.
- [12] 张清华, 支学超, 王国胤, 等. 基于属性代表的多粒度集成分类算法[J]. 计算机学报, 2022(8): 1712-1729.
- ZHANG Q H, ZHI X CH, WANG G Y, et al. Multi-granularity ensemble classification algorithm based on attribute representation [J]. Chinese Journal of Computer, 2022(8): 1712-1729.
- [13] 陈仁祥, 何家乐, 杨黎霞, 等. 基于加权在线样本更新的目标长时跟踪方法[J]. 仪器仪表学报, 2023, 44(6): 66-73.
- CHENG R X, HE J L, YANG L X, et al. Target long-term tracking method based on weighted online sample update [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 66-73.
- [14] KIM H, SHAHID A, FONTAINE J, et al. Automatic modulation classification using relation network with denoising autoencoder[C]. 2022 13th International Conference on Information and Communication Technology Convergence (ICTC), 2022: 485-488.
- [15] CHAE M, KIM H, OH H J, et al. PCDC: Prototype-assisted dual-contrastive learning with depthwise separable convolutional neural network for few-shot fault diagnosis of permanent magnet synchronous motors under new operating conditions [J]. Journal of Computational Design and Engineering, 2024, 11(3): 337-358.
- [16] 李明爱, 张梦, 孙炎珺. 基于小波包和深度信念网络的脑电特征提取方法[J]. 电子测量与仪器学报, 2018(1): 111-118.
- LI M AI, ZHANG M, SUN Y J. EEG feature extraction method based on wavelet packet and deep belief network[J]. Journal of Electronic Measurement and Instrumentation, 2018(1): 111-118.
- [17] DONG Y H, JIANG X H, ZHOU H J, et al. SR2CNN: Zero-shot learning for signal recognition [J]. IEEE Transactions on Signal Processing, 2021 (69): 2316-2329.

作者简介

洪青青(通信作者), 硕士研究生, 主要研究方向为调制识别、深度学习。

E-mail: 872893525@qq.com

张治中, 教授, 博士生导师, 主要研究方向为移动通信与信息、通信网测试与仪表技术、移动大数据、物联网。