

DOI:10.20079/j.issn.1001-893x.240613002

基于增强多尺度特征融合的轻量级调制信号识别方法*

吴长城, 孙晓川, 余继科, 李莹琦

(华北理工大学 人工智能学院, 河北 唐山 063200)

摘要:深度学习(Deep Learning, DL)是实现自动调制识别(Automatic Modulation Identification, AMI)技术的有效方法,但通常难以同时兼顾识别精度和效率。为此,提出了一种增强多尺度特征融合的轻量化 AMI 方法。首先,设计了轻量化的多尺度特征融合模块,通过跨尺度卷积结构高效提取调制信号的多尺度特征,以增强模型对不同信号特征的代表能力;其次,构建了自适应特征增强模块,结合深度可分离卷积与注意机制,能够自适应地学习关键特征的通道权重,突出重要信号特征的同时减少无关特征的干扰;最后,设计了差异平衡分类器,通过聚焦细微调制模式的识别,从而实现高效分类。实验结果表明,所提方法在识别精度上平均提高了 5.91%,参数量减少约 8.5×10^5 , 单次迭代时间缩短 0.062 4 s,与对比的先进模型相比具备更高的精度、更快的速度和更少的参数量。

关键词:自动调制识别;深度学习;多尺度特征融合

开放科学(资源服务)标识码(OSID):



微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN761;TP18 文献标志码:A 文章编号:1001-893X(2025)11-1869-09

Lightweight Modulated Signal Recognition Based on Enhanced Multi-scale Feature Fusion

WU Changcheng, SUN Xiaochuan, YU Jike, LI Yingqi

(College of Artificial Intelligence, North China University of Science and Technology, Tangshan 063210, China)

Abstract: Deep learning (DL) is an effective method for achieving automatic modulation identification (AMI) technology. However, DL methods generally struggle to balance recognition accuracy and efficiency simultaneously. To address this, a lightweight AMI method based on enhanced multi-scale feature fusion is proposed. First, a lightweight multi-scale feature fusion module is designed, which efficiently extracts multi-scale features of modulation signals through a cross-scale convolutional structure, enhancing the model's ability to represent different signal features. Next, an adaptive feature enhancement module is constructed, combining depthwise separable convolution and attention mechanisms to adaptively learn channel weights of key features, highlighting important signal features while reducing interference from irrelevant ones. Finally, a differential balance classifier is designed to focus on recognizing subtle modulation patterns, enabling efficient classification. Experimental results show that the proposed method improves recognition accuracy by an average of 5.91%, reduces the number of parameters by approximately 8.5×10^5 , and decreases iteration time per sample by 0.062 4 seconds. Compared with the advanced models, it achieves higher accuracy, faster speed, and fewer parameters.

Key words: automatic modulation identification; deep learning; multi-scale feature fusion

* 收稿日期:2024-06-13;修回日期:2024-09-19

基金项目:国家自然科学基金区域创新发展联合基金重点资助项目(U21A20114)

通信作者:李莹琦 Email:liyinqi@ncst.edu.cn

0 引言

自动调制识别 (Automatic Modulation Identification, AMI) 技术使接收设备能够在非协作通信环境下识别未知接收信号的调制方式,在无线通信领域具有广泛的应用价值。在军事领域,AMI 技术用于发现解译敌方通信信号,为情报监视侦察及电子战提供支持,帮助赢得信息化战争主动权。在民用领域,该技术则用于无线电监测和频谱管理,发现非授权用户,实现信息还原和身份识别,对其进行监视管控,维护合法用户的频谱使用权利。AMI 作为信号检测与解调的重要中间环节,其性能优劣将直接影响通信链路的整体性能。因此,提高 AMI 技术的性能对于优化通信系统至关重要。

深度学习 (Deep Learning, DL) ^[1-3] 技术凭借其强大的模式识别和自动特征提取能力,已经成为实现 AMI 的有效手段。因此,研究人员将大量研究工作聚焦于基于 DL 的 AMI 方法。尽管文献[4-8]的方法通过复杂的模型设计取得了较高识别精度,但极大的参数量与较低的效率使其难以应用于对效率和能耗敏感的嵌入式场景。

为了提高识别效率,大量的研究聚焦于轻量化的 AMI 方法研究。文献[9]提出基于多通道多功能块的轻量级 DL-AMI 方法,以较低模型复杂度获得了较好性能。文献[10]采用渐进可微分架构搜索,搜索出轻量级高效网络,获得了较低计算成本。文献[11]通过剪枝技术减小网络大小,提出改进的轻量级 DL-AMI 方法,实现了较优识别效率。文献[12]基于 MobileNetV3,以较低计算成本实现了较好识别性能。显然,上述方案通过剪枝、量化等模型压缩技术有效降低了计算和存储开销,但其对调制信号的特征表达能力随之减弱,难以在无线通信等资源受限的物联网场景下达到与复杂模型相当的高精度水平。

综上,现有研究难以同时兼顾 AMI 的识别性能和效率。为此,本文提出了一种基于增强多尺度特征融合的轻量级 DL-AMI 方法,即 EMFFNet (Enhanced Multi-scale Feature Fusion Network)。结构上,该方法由多尺度特征融合 (Multi-scale Feature Fusion, MFF)、自适应特征增强 (Adaptive Feature Enhancement, AFE) 以及差异平衡分类器 (Differential Balance Classifier, DBC) 组成。首先, MFF 模块通过轻量化多尺度卷积和跨尺度融合,高效提取并融合调制信号的多尺度特征。其次, AFE 模块通过自动学习不同特征通道的重要性权重,对重要特征分配更多注意力资源,从而实现关键特征的自适应聚焦,同时抑制无关特征的计算。最后, DBC 模块采用差异平衡策略,有效关注调制特征变化,从而通过高维映射提升分类效果。通过上述 3 个模块的协同作用,EMFFNet 在增加网络深度的情况下实现了模型的轻量化,显著提升了模型的识别精度和效率。

1 轻量级调制识别模型

本文提出的基于增强多尺度特征融合的轻量化 AMI 网络模型如图 1 所示。结构上,该模型主要由多尺度特征融合、自适应特征增强以及差异平衡分类器组成。MFF 模块采用轻量级设计,分别通过 3 条不同尺度的特征提取通道提取调制信号的多尺度特征,再将这些特征进行有效融合。这种设计在减轻计算复杂度的同时,最大限度地保留了调制信号的丰富特征信息。AFE 通过深度可分离卷积与不同注意力机制的有效结合,实现对多尺度调制特征的增强,从而聚焦调制信号中的细节特征。DBC 则利用标准差池化与全连接层的结合,将平衡差异化后的调制特征进行高维的特征映射,从而高效识别各种调制类型。

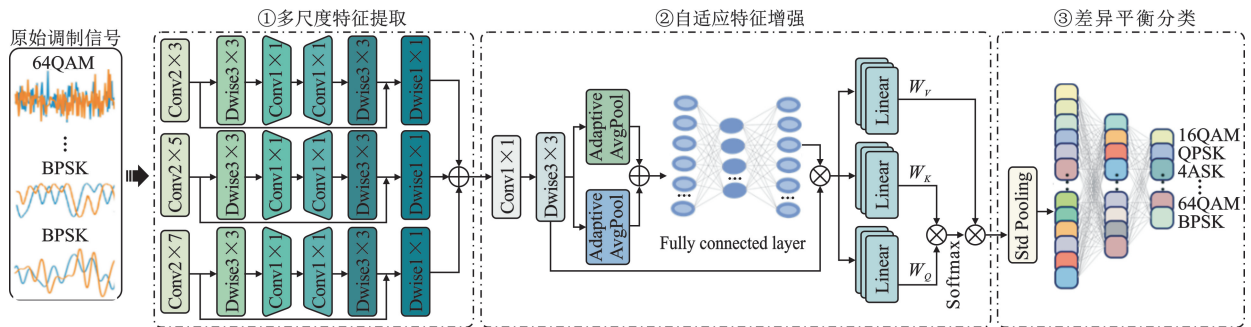


图 1 AMI 的 EMFFNet 网络模型结构

1.1 多尺度特征融合

本文提出了一种新颖的 MFF 模块,总体上包含两个阶段,即多尺度特征提取阶段和特征融合阶段。前者采用 3 条尺度不同但结构相同的特征提取路径进行多尺度调制特征提取,以提取不同尺度下的调制特征表示;后者则将不同尺度的局部调制特征进行融合,以提升模型表征能力。

在多尺度特征提取阶段,不同尺度通道由 2 维卷积(2-Dimensional Convolution, 2DC)、SandGlass^[13]和 2 维深度卷积(2-Dimensional Deep Convolution, 2DDC)串联而成。具体来说,首先,采用不同尺度(2×3、2×5 和 2×7)的 2DC 对输入调制信号 x 进行并行处理,以同时捕获调制信号在多个感受野范围内的局部调制特征 Y_i :

$$Y_i = \delta(\varphi_{2 \times (2i+1)}(x)), i = \{1, 2, 3\} \quad (1)$$

式中: $\varphi_{2 \times (2i+1)}(\cdot)$ 表示卷积核为 $2 \times (2i+1)$ 的 2DC; $\delta(\cdot)$ 表示 ReLU 激活函数。然后,不同尺度的局部调制特征同时通过 SandGlass,其架构为一个残差网络单元,其中不同尺度主通道的初端与末端分别嵌入了两个维持传递通道数稳定的 3×3 空间 2DDC,以提取不同尺度调制特征的空间特性。为了优化瓶颈结构的调制特征处理效率,利用两个 1×1 维度的 2DC 分别执行通道数量的压缩及扩展操作,并将这两个 2DC 置于两个空间 2DDC 之间。通过此设计,使得计算主要集中于更多通道的张量内部进行,从而既保持了网络对调制特征的表征能力又降低了模型的参数量,以获得不同尺度的优化调制特征 Y'_i :

$$Y'_i = \phi_{3 \times 3}(\varphi_{1 \times 1}(\varphi_{1 \times 1}(\phi_{3 \times 3}(Y_i)))) \quad (2)$$

式中: $\varphi_{1 \times 1}(\cdot)$ 表示卷积核为 1×1 的 2DC; $\phi_{3 \times 3}$ 代表卷积核为 3×3 的 2DDC。最后,不同尺度的优化调制特征经过 1×1 的 2DDC 单独处理每个通道,从而实现降维和信息的有效压缩。这个步骤筛选了与调制信号相关性低的特征,从而捕获不同尺度下的深层调制特征 M_i :

$$M_i = \delta(\phi_{1 \times 1}(Y'_i)) \quad (3)$$

在特征融合阶段,将不同尺度的深层调制特征通过拼接的方式合并,从而形成更为丰富的多尺度调制特征表示 Z_{MFF} :

$$Z_{\text{MFF}} = \text{Concat}(M_1, M_2, M_3) \quad (4)$$

1.2 自适应特征增强

为增强模型对不同调制模式特征的区别能力,本文构建了一种 AFE 模块。结构上,该模块由深度可分离卷积(Depthwise Separable Convolution,

DSC)、混合注意力机制(Mixed Attention Mechanism, MAM)和多头注意力(Multi-head Attention, MHA)串联组成。该模块通过局部细节、全局统计和内在关联三方面特征,自适应地实现不同调制信号特征的针对性增强。

首先,采用 DSC 对多尺度调制特征 Z_{MFF} 进行通道和空间维度的分组卷积处理。DSC 包含两步:使用 1×1 的 2DC 对 Z_{MFF} 进行通道维度的卷积,实现通道之间的组合;使用 3×3 的 2DDC 在空间维度上进行卷积运算,以提取空间调制特征。这样分解能够极大减少运算量,同时保留了有效的调制特征表示 Y_{DSC} :

$$Y_{\text{DSC}} = \delta(\phi_{3 \times 3}(\beta(\varphi_{1 \times 1}(Z_{\text{MFF}})))) \quad (5)$$

随后,采用 MAM 对 DSC 模块输出的调制特征 Y_{DSC} 进行信息筛选。该机制通过自适应最大池化和平均池化两种操作,分别获取特征图中的显著特征和背景特征,再加权融合这两种特征,提高了模型对关键调制特征的关注度。接着将融合后的调制特征通过两层全连接层进行自适应的特征压缩和扩展,以生成反映不同通道重要性的注意力权重。将此注意力权重与调制特征 Y_{DSC} 按元素乘积融合,来自适应增强网络对关键调制特征的响应,从而动态映射出特征图中最为关键的调制信息区域,获取的细节调制特征表示 Y_{MAM} 为

$$Y_{\text{MAM}} = \lambda \cdot \sigma(\text{FC}(Y_{\text{AP}}(Y_{\text{DSC}}))) + (1-\lambda)\sigma(\text{FC}(Y_{\text{MP}}(Y_{\text{DSC}}))) \quad (6)$$

式中: $Y_{\text{AP}}(\cdot)$ 和 $Y_{\text{MP}}(\cdot)$ 分别表示自适应平均和最大池化操作;FC 表示全连接层; σ 表示 Sigmoid 激活函数; λ 为权重系数。

最后,将带有细节特征的 Y_{MAM} 输入到 MHA 中。不同于传统注意力, MHA 通过并行计算多个注意力头部,每个头部从不同的表示子空间学习关注调制特征的不同方面,再将这些子空间的特征进行融合,从而获得增强后的调制特征 Y_{AFE} :

$$\begin{cases} \text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_K}}\right) \\ \text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \\ Y_{\text{AFE}} = \text{Concat}(\text{head}_1, \dots, \text{head}_n)W^O \end{cases} \quad (7)$$

式中: Q, K, V 分别代表输入序列的查询、键和值; $QW_i^Q, KW_i^K, VW_i^V, W^O$ 为可学习的权重矩阵; head_i 表示第 i 个注意力头; d 表示键向量的维度。

1.3 差异平衡分类

本文设计了一种新型的分类器,结构上由标准

差池化 (StdPool) 和全连接层组成。首先,采用 StdPool 平衡不同调制特征的差异,使模型更加敏感地关注信号特征的变化,从而协助区分从增强特征 Y_{AFE} 中提取的不同类型的调制信号特征,即

$$Y_{StdPool} = \sqrt{\frac{1}{M} \sum_{i=1}^M (Y_{AFE}[i] - \mu)^2} \quad (8)$$

式中: X_i 是调制信号中的特征样本值; M 是信号段中样本的总数; μ 是信号段的平均值。这种池化方式能更好地反映信号的波动性和不稳定性。然后,引入全连接层对 StdPool 层的输出 $Y_{StdPool}$ 进行进一步处理,学习调制信号的高级特征表示 Y ,从而实现高维特征空间到调制类别标签的高效映射。

$$Y = W_2 \cdot \eta(\beta(Y_{StdPool} \cdot W_1 + b_1)) + b_2 \quad (9)$$

式中: W_1 和 W_2 表示线性层的权重; b_1 和 b_2 表示线性层的偏执; $\eta(\cdot)$ 表示激活函数 GELU。

2 实验仿真

2.1 数据集与实验设置

本文采用了开源数据集 RadioML2016. 10b,以验证 EMFFNet 的有效性。该数据集是基于软件无线电平台 GUN Radio 生成的,包含了多种复杂信道环境,如多径衰落和加性高斯白噪声等,以实现真实通信环境模拟,其已广泛用于 AMI 算法评估。表 1 总结了数据集的基本内容。

表 1 数据集总结

数据集	参数配置
数字调制	QPSK、PAM4、8PSK、BPSK、CPFSK、BFSK、QAM64、QAM16
模拟调制	AM-DSB、WB-FM
数据集大小	1 200 000
样本尺寸	2×128
SNR 范围/dB	[-20;2;18]
样本格式	IQ 格式
标签	信噪比和调制方法

实验基于 Python 3. 11 和 PyTorch 2. 0. 1 的本地环境进行,在 GeForce GTX 4050 图形处理器上使用 CUDA 11. 7 进行 GPU 加速。在实验中,按照训练集 80%、验证集 10% 和测试集 10% 的比例分割每个信噪比下每种调制类型的数据。使用 Adam 优化器在 100 个周期中训练所提网络,批量大小为 64,初始学习率为 $lr=0.001$ 。特别地,采用一种早期停止机制

来防止过拟合并提高训练效果。具体来说,如果验证损失在连续 10 个训练周期内没有减少,则提前终止训练。

为了验证 EMFFNet 模型的有效性,选择了 5 种基于 DL-AMI 方法进行比较,分别为 DualNet^[14]、MCLDNN^[15]、CLDNN^[16]、ResNet^[17] 和 VT-CNN2^[4]。表 2 总结了这些方法的关键特征及其对信号识别的重要作用。

表 2 基线模型比较

模型	核心贡献	对信号识别的关键作用
VT-CNN2 ^[4]	提出直接从原始 IQ 数据学习的 CNN 架构	提高了低信噪比条件下的识别能力
ResNet ^[17]	引入残差连接的深度 CNN	缓解梯度消失,提升高信噪比下的识别精度
CLDNN ^[16]	结合 CNN 和 LSTM 的混合网络	同时捕获空间和时序特征,增强复杂调制模式识别
MCLDNN ^[15]	多通道学习框架 (1D 卷积、2D 卷积、LSTM)	多角度特征提取和融合,提高特征表示全面性
DualNet ^[14]	CNN-LSTM 双流结构	增强对调制信号时空特性的捕捉能力

通过综合考量评估模型的分类准确性、类间平衡性以及分类一致性,以有效度量模型的 AMI 分类性能。总体准确率 (Overall Accuracy, OA) 表达式为

$$OA = \frac{\sum_{i=1}^C n_{ii}}{N} \quad (10)$$

式中: C 为调制类别数; n_{ii} 为第 i 类被正确分类的样本数; N 为总样本数。

类间平衡性 (Average macro-F1, AMF1) 分数表达式为

$$AMF1 = \frac{1}{C} \sum_{i=1}^C \frac{2p_i r_i}{p_i + r_i} \quad (11)$$

式中: p_i 和 r_i 分别为第 i 类的精确率和召回率。该参数度量了所有调制类型的 AMF1 分数。

分类一致性 (Kappa) 系数表达式为

$$\left\{ \begin{array}{l} \text{Kappa} = \frac{p_o - p_e}{1 - p_e} \\ p_e = \frac{\sum_{i=1}^C a_i \cdot b_i}{N^2} \end{array} \right. \quad (12)$$

式中: a_i 为不同真实调制类型样本数; b_i 为不同预

测调制类型样本数; p_0 为总体准确率 OA。

2.2 性能评估

图 2 展示了 EMFFNet 模型与 5 个对比模型在不同 SNR 下的平均识别准确率。显然,所提方法的识别准确率总体上都优于其他模型。特别地,在低信噪比范围(-20~0 dB)内的识别精度获得了极为显著的提升。以-16 dB 为例,EMFFNet 模型的准确率相较次优模型高出了 4.4%。此外,随着 SNR 的进一步提高,各模型的识别性能均逐渐趋于稳定,但是所提模型依然略优于其他模型。这充分证明了所提模型在识别性能上的优势。




图 2 不同模型在不同 SNR 下的 OA 比较

表 3 综合比较了 EMFFNet 模型在 AMI 任务上的不同性能指标。总体上,所提模型在 OA、AMF1 分数和 Kappa 系数等评估指标上均展现出显著优势,相较于次优模型分别实现了 2.39%、0.026 7 和 0.033 8 的性能提升。此外,从表 3 可看出,所提模型在参数量上优于其他模型,较次优 ResNet 模型降低了 0.5×10^5 ,而较参数最高的 VT-CNN2 模型降低了 2.73×10^6 ;同时,在单次迭代的运算时间上也获得了最低开销,较次优 VT-CNN2 模型节省了 0.002 s,而较最耗时的 CLDNN 模型节省了 0.214 s。这充分证明了所提模型在效率上的优势。

表 3 仿真实验对比

模型	OA/%	AMF1	Kappa	参数量/ 10^6	单样本迭代时间/s
VT-CNN2 ^[4]	55.94	0.568 3	0.510 4	2.83	0.015
Resnet ^[17]	63.34	0.633 9	0.592 7	0.15	0.028
CLDNN ^[16]	59.67	0.601 0	0.551 9	0.20	0.227
MCLDNN ^[15]	64.20	0.642 9	0.602 2	0.41	0.086
Dualnet ^[14]	64.37	0.647 3	0.604 1	1.15	0.021
EMFFNet	67.41	0.674 0	0.637 9	0.10	0.013

表 4 展示了在不同特征处理方法和模型设置下各模型的整体性能。显然,使用 MFF、AEF 和 DBC 的 EMFFNet 模型在 OA、AMF1 和 Kappa 系数方面均表现优越。在单一尺度特征的模型中,随着尺度增大,性能有所提升,但其表现仍低于 EMFFNet。这说明多尺度特征提取能够捕捉到更丰富的信息,有助于提高识别准确率。对于未进行 AEF 和 DBC 的模型,其性能也显著低于完整的 EMFFNet 模型。具体来说,去除 AEF 后,模型的准确率下降了约 3.13%,而去除 DBC 后,准确率下降了约 2.03%。这验证了 AEF 和 DBC 模块在提升模型性能中的关键作用。尽管在参数量和单样本迭代时间方面,未进行 AEF 的模型表现出较低的参数量(3×10^4)和较快的时间(0.010 s),但在关键性能指标上,完整的 EMFFNet 模型仍然占据优势。这些结果表明,所提方法在不同特征处理和模型设置下均能够显著提高识别性能。通过这些对比实验,不仅验证了各创新模块对模型性能的提升作用,也进一步证明了 EMFFNet 在 AMI 中的优越性。

表 4 不同模块的效果对比结果

模型	OA/%	AMF1	Kappa	参数量/ 10^6	单样本迭代时间/s
单一尺度 (2×3)	63.86	0.639 7	0.598 5	0.10	0.010
单一尺度 (2×5)	66.34	0.664 9	0.626 1	0.10	0.011
单一尺度 (2×7)	67.08	0.672 05	0.634 2	0.10	0.012
未进行 AEF	64.28	0.641 7	0.603 1	0.03	0.010
未进行 DBC	65.38	0.654 2	0.615 3	0.10	0.013
EMFFNet	67.41	0.674 0	0.637 9	0.10	0.013

图 3 展示了 EMFFNet 与其他 5 种模型在训练过程中的平均识别率变化曲线,可以明显看出,该模型在训练初期迅速提高识别率,并在 20 个 epoch 内达到高水平,最终稳定在 67% 左右。相比之下,其他模型虽然在不同程度上也表现出识别率的提升,但其收敛速度和最终识别率均不及 EMFFNet。这

表明,EMFFNet 在收敛性和识别性能上具有显著优势,特别是在初期训练阶段的快速收敛能力,使其在实践中更具实用性和高效性。

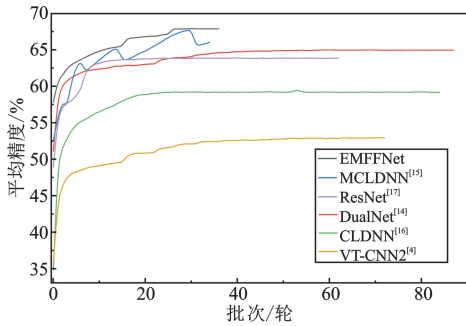


图 3 不同模型在训练过程中的识别率变化对比

图 4 展示了不同模型在 SNR = -4 dB 时不同调制类型的混淆矩阵对比,混淆矩阵的行代表真实的

调制类型,而列代表预测的调制类型。由图 4 可见,所有模型在识别连续调制 WBFM 时均存在较高的混淆率。这是由于 WBFM 在静默期间信号近乎为零,网络难以从这种无效信号中提取特征而导致的随机分类结果。然而,EMFFNet 模型对 WBFM 的分类准确率明显提升,相比于其他基线模型平均提升约 11.22%。此外,16QAM 与 64QAM、8PSK 与 QPSK 两对调制类型之间也容易产生较高混淆。这主要是由于这些调制方式属于相似类型,其星座点分布较为接近,在低 SNR 环境下更易受到噪声干扰导致星座点重叠,从而增加了识别的难度。值得注意的是,EMFFNet 在这些相似调制类型的识别上取得了整体最优的匹配效果,最大限度地缓解了混淆的发生。

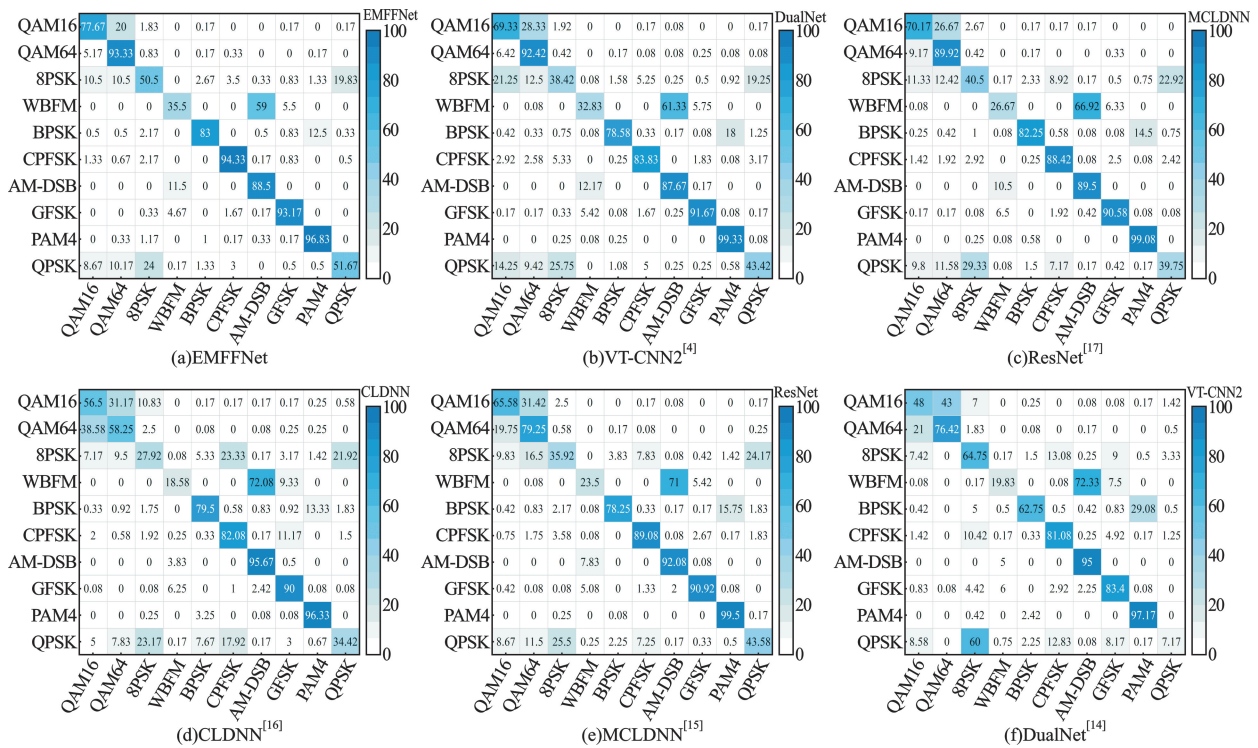


图 4 RML2016. 10b 数据集-4 dB 信噪比下模型混淆矩阵

图 5 展示了不同模型在 SNR = 12 dB 时对 10 种不同调制类型的混淆矩阵对比。由图 5 可见,EMFFNet 在所对比的基线模型中获得了整体最优的分类结果;除 WBFM 之外,其余的调制类型都取

得了超过 98% 的匹配精度。此外,结合图 4 可知,随着信噪比的提高,所有模型的分类混淆都取得了明显的下降,例如,QPSK 的识别性能从 51.67% 提升至 98.5%。

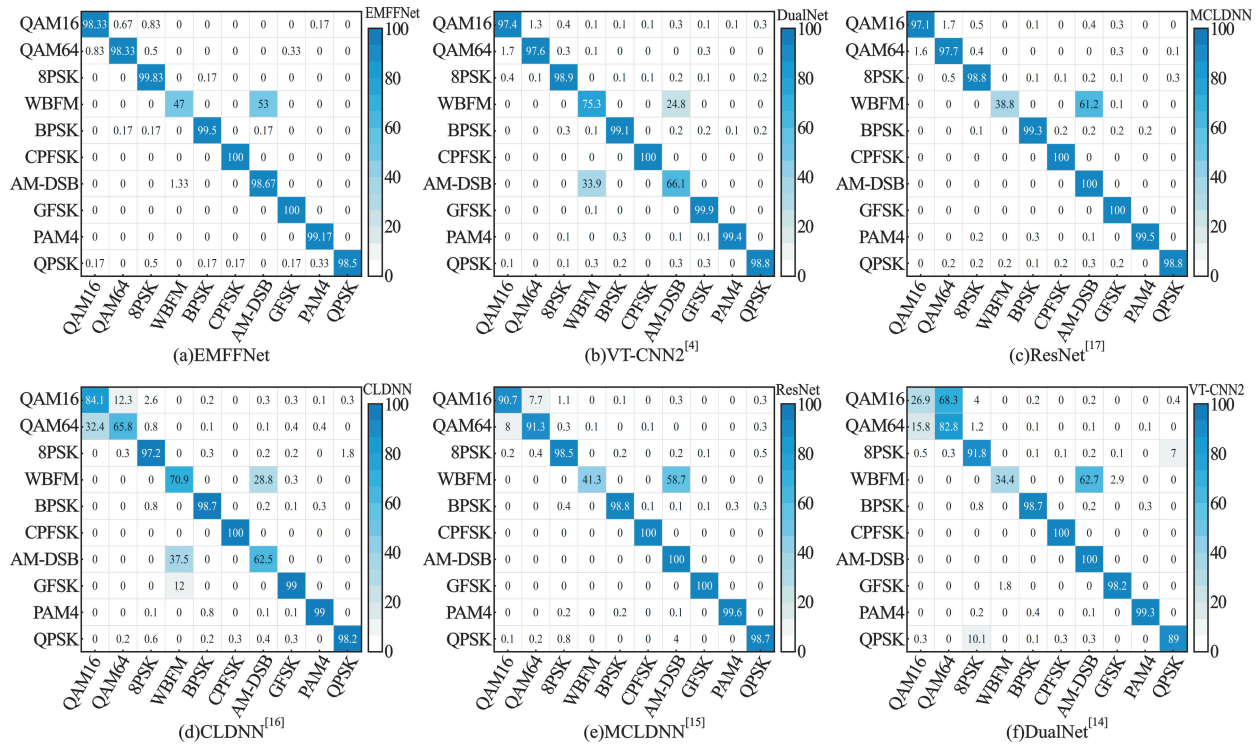


图 5 RML2016.10b 数据集 12 dB 信噪比下模型混淆矩阵

综上所述,本文所提出的 EMFFNet 模型在不同信噪比下的 OA、AMF1 分数、Kappa 系数、参数量、单次迭代时间以及混淆情况方面均取得显著优势,证明了所提模型的可行性和有效性。该优异性能主要归因于该模型的以下三大模块设计:首先,通过 MFF 能够高效捕获原始调制信号中从细粒度到粗粒度的调制特征,从而有效提取调制信号中微小的包络变化,融合多样化的调制特征;其次,使用 AFE 聚焦多尺度特征中的关键调制信号特征,有效实现过滤噪声及放大重要调制信息的作用,从而增强对不同调制类型的特征表示;最后,采用 DBC 对增强后的特征直接建模不同调制方式的统计特征,以关注调制特征的差异,使模型对信号特征变化更加敏感,实现调制信号的高效分类。上述三大创新模块的协同作用,不仅为该模型带来了显著的性能和效率的提升,而且有效缓解了各类型间的分类混淆问题,最终实现 AMI 的高效执行。接下来将重点阐述这些创新模块为 AMI 任务带来的显著优势。

2.3 消融实验

上文概述了 EMFFNet 模型的三大模块 MFF、AFE 和 DBC,通过协同工作为 AMI 任务带来了性能和效率的提升。为定量评估每个模块的贡献,进行

了一系列消融实验。消融实验的目的在于通过移除或替代模型中的特定组件,观测整体性能是否会受到影响及影响程度的大小,从而量化分析该组件的重要性。

表 5 给出了 EMFFNet 模型中移除或替换 MFF 模块对模型性能和参数量的影响。显然,将 MFF 替换为单尺度 Conv2D 或多尺度 Conv2D 时,其性能分别下降了 9.6% 和 3.19%,而参数量仅少量减少。这说明单尺度 Conv2D 缺乏同时捕捉多尺度调制特征的能力,而多尺度 Conv2D 虽有改善,但仍不足以有效提取调制特征。特别地,当完全移除 MFF 模块时,虽然参数减少了 2×10^4 ,但性能却大幅下降了 9.67%,这表明了 MFF 模块在提取多尺度调制信息、保持模型效率和性能中的关键作用。

表 5 MFF 消融实验对比

模型	OA/%	AMF1	Kappa	参数量/ 10^6	单样本迭代时间/s
单尺度 Conv2D	57.81	0.577 2	0.531 3	0.09	0.012
多尺度 Conv2D	64.22	0.642 5	0.602 5	0.09	0.010
移除 MFF	57.74	0.572 1	0.530 5	0.08	0.011
EMFFNet	67.41	0.674 0	0.637 9	0.10	0.013

表 6 给出了 EMFFNet 模型中移除或替换 AFE 模块对模型性能和参数量的影响。显然,将 AFE 替换为 Conv2D+注意力机制或 MHA 时,识别精度相比所提模型分别下降 1.35% 和 3.02%,参数量分别保持不变和下降了 2×10^4 。这表明 AFE 模块通过结合 DSC 和注意力机制的优势,在保证参数量的前提下增强了对调制特征的建模能力,更好地捕获了调制信号在通道和空间维度上的特征依赖关系。特别地,当完全移除注意力机制模块后,虽然模型参数量达到最低,但识别性能却下降了 3.59%。这进一步表明了注意力机制在 AFE 模块中的重要作用,即自适应增强关键调制特征细节。

表 6 AFE 消融实验对比

模型	OA/%	AMF1	Kappa	参数量/ 10^6	单样本迭代时间/s
Conv2D+注意力	66.06	0.660 2	0.622 9	0.10	0.013
MHA	64.39	0.646 3	0.604 2	0.08	0.011
移除注意力	63.82	0.638 8	0.598 0	0.03	0.010
EMFFNet	67.41	0.674 0	0.637 9	0.10	0.013

表 7 给出了 EMFFNet 模型中移除或替换 DCB 模块对模型性能和参数量的影响。显然,将 DBC 替换为自适应平均池化时,模型参数量保持不变,识别性能略微下降了 0.35%。而当完全移除 StdPool 时,模型参数量保持不变,识别性能则较所提模型下降了 2.48%。这些表明了不同调制方案在包络统计特性上存在显著差异,StdPool 在保持这些关键统计信息的同时平衡了模型对关键统计模式的差异,进而显著提升了模型的分类性能。

表 7 DBC 消融实验对比

模型	OA/%	AMF1	Kappa	参数量/ 10^6	单样本迭代时间/s
自适应平均池化	67.23	0.673 1	0.635 9	0.10	0.013
移除 StdPool	64.97	0.654 6	0.610 8	0.10	0.013
EMFFNet	67.41	0.674 0	0.637 9	0.10	0.013

3 结束语

本文提出了一种轻量化的 DL-AMI 方法,通过轻量化的设计获取调制信号的高质量的特征表示,从而提升调制识别的整体性能。结构上,由 MFF、

AFE 和 DBC 等模块组成,能够充分挖掘不同尺度下的调制信息,聚焦精细的特征表示,最终实现高效的调制识别。实验表明,模型的综合精度达到 67.16%,在 16 dB 时达到 93.7% 的最高识别准确率,同时模型的参数和训练时间较对比模型也获得了最优的表现。这说明通过多尺度特征融合与自适应特征增强的结合,在降低模型参数的情况下有效提升了识别精度。

尽管本文提出的模型在多数情况下表现优异,但对于某些复杂的调制类型,其识别效果可能受到限制,这需要在后续研究中进一步探讨和解决。在未来工作中,为了进一步提高模型的泛化性,将在迁移学习框架下继续探索 EMFFNet 的适用性,以应对更广泛的信号类型和复杂的环境条件。

参考文献:

- [1] 陈发堂,刘泽,范子健.基于时空卷积网络的通信信号调制识别[J].电讯技术,2025,65(4):518-524.
- [2] XU D W, LI J P, CHEN Z Z, et al. Imperceptible UAPs for automatic modulation classification based on deep learning [J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2024, 71(2): 987-991.
- [3] LI L, DONG Z Y, ZHU Z G, et al. Deep-learning hopping capture model for automatic modulation classification of wireless communication signals [J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(2): 772-783.
- [4] O' SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks [C] // Engineering Applications of Neural Networks. Cham: Springer, 2016: 213-226.
- [5] 李辉,龚晓峰,雒瑞森.基于时频融合的深度学习调制识别算法[J].电讯技术,2024,64(1):22-28.
- [6] 国强,聂孟允,戚连刚,等.基于单通道多尺度图神经网络的自动调制识别[J].电子与信息学报,2023,45(5):1575-1584.
- [7] ELSAGHEER M M, RAMZY S M. A hybrid model for automatic modulation classification based on residual neural networks and long short term memory [J]. Alexandria Engineering Journal, 2023, 67: 117-128.
- [8] WEI T, LI Z, BI D X, et al. Adaptive multi-dimensional shrinkage block for automatic modulation recognition [J]. IEEE Communications Letters, 2023, 27(11): 2968-2972.
- [9] DONG B, LIU Y C, GUI G, et al. A lightweight decentralized-learning-based automatic modulation classification method for resource-constrained edge devices [J]. IEEE Internet of Things Journal, 2022, 9(24): 24708-24720.
- [10] ZHANG X X, CHEN X F, WANG Y, et al. Lightweight

- automatic modulation classification via progressive differentiable architecture search[J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9(6):1519–1530.
- [11] LIN Y, TU Y, DOU Z. An improved neural network pruning technology for automatic modulation classification in edge devices[J]. IEEE Transactions on Vehicular Technology, 2020, 69(5):5703–5706.
- [12] VALADÃO M, SILVA L, SERRÃO M, et al. MobileNetV3-based automatic modulation recognition for low-latency spectrum sensing [C]//2023 IEEE International Conference on Consumer Electronics. Las Vegas:IEEE, 2023:1–5.
- [13] ZHOU D Q, HOU Q B, CHEN Y P, et al. Rethinking bottleneck structure for efficient mobile network design [C]//2020 European Conference on Computer Vision. Cham:Springer, 2020:680–697.
- [14] ZHANG Z F, LUO H, WANG C, et al. Automatic modulation classification using CNN-LSTM based dual-stream structure [J]. IEEE Transactions on Vehicular Technology, 2020, 69(11):13521–13531.
- [15] 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.
- [16] TU Y, LIN Y, HOU C B, et al. Complex-valued networks for automatic modulation classification [J]. IEEE Transactions on Vehicular Technology, 2020, 69(9):10085–10089.
- [17] LIU X Y, YANG D Y, EL GAMAL A. Deep neural network architectures for modulation classification[C]//2017 51st Asilomar Conference on Signals, Systems, and Computers. Pacific Grove:IEEE, 2018:915–919.

作者简介:

吴长城 男,1998 年生于福建建瓯,2021 年获学士学位,现为硕士研究生,主要研究方向为无线通信、自动调制识别、深度学习。

孙晓川 男,1983 年生于山东莱阳,2013 年获博士学位,现为副教授,主要研究方向为无线资源管理、无线流量预测、深度学习。

余继科 男,2000 年生于安徽阜阳,2022 年获学士学位,现为硕士研究生,主要研究方向为无线通信、深度学习。

李莹琦 女,1984 年生于河北唐山,2010 年获硕士学位,现为副教授,主要研究方向为语义通信和蜂窝网络流量分析、资源分配。