arXiv:2304.00445v1 [eess.SP] 2 Apr 2023

AMC-NET：一种有效的自动调制分类网络

张家伟、王天天、冯志希、杨舒媛

中国西安电子科技大学人工智能学院

摘要

自动调制分类（AMC）是无线通信系统频谱管理、信号监测和控制中的关键环节。准确识别调制格式对于后续传输数据的解码至关重要。近年来，端到端深度学习方法已应用于 AMC，其表现优于传统特征工程技术。然而，AMC 在低信噪比（SNR）环境下仍存在局限。为克服这一缺陷，我们提出了一种新颖的 AMC-Net，通过在频域对输入信号进行降噪，同时执行多尺度且有效的特征提取，从而提高识别性能。在两个具有代表性的数据集上进行的实验表明，与当前大多数方法相比，我们的模型在效率和有效性方面表现更佳。

索引词— 自动调制分类、深度学习

1. 引言

随着无线通信技术的快速发展，深度学习已成为一种强大的技术，能够赋能具有复杂拓扑结构和无线电条件的无线网络 [15]。自动调制分类（AMC）作为通信系统中的关键环节，也与深度学习有着诸多结合方式 [16, 17]。传统的 AMC 可分为两类： $likelihood\text{-}based$ (LB) 方法 [2] 和 $feature\text{-}based$ (FB) 方法 [3]。然而，LB 方法依赖于有关信道和信号的先验知识。FB 方法会选取手工设计特征，再使用机器学习算法（如支持向量机 [8]和随机森林 [13]）进行分类。FB 方法高度依赖专家知识。

O'Shea、Corgan 和 Clanc [9] 率先提出了用于 AMC 的卷积神经网络模型，开启了深度学习在 AMC 中的应用。该模型优于依赖人工特征的传统方法。 [10]提出了一种基于长短期记忆网络的模型。Huang 等人 [11] 采用门控循环单元对信号进行分类。West 和 O'Shea [14]采用卷积长短期深度神经网络（CLDNN），显著提高了分类准确率。此外，[5] 提出了卷积神经网络-长短期记忆网络的双流结构，以高效地对信号进行分类。该结构利用 I/Q 通道和幅度/相位的信息来提升性能。 [6]将 I 通道和 Q 通道结合起来，以并行学习信号之间的相关性。此外，Huynh-The 等人 [4] 采用不同的非对称卷积核和跳跃连接来学习空间相关性。Liang 等人 [7] 将注意力机制与复值神经网络相结合，以更好地表示信号。除了关注分类，AMC 和深度学习还拓展到了其他方向。 [18]将对抗生成网络引入 AMC，以增强数据并提高分类性能。Sahay、Brinton 和 Love [12] 研究了 AMC 中的对抗鲁棒性。上述工作拓展了深度学习在 AMC 中的应用。

本文提出了一种新颖的调制分类框架。该框架进一步考虑了调制信号的内在属性。与其他框架相比，该框架针对调制信号采用了若干独特的设计。该框架的贡献可概括如下：

- 为减轻噪声和偏移的影响，我们提出了一种新颖的自适应校正模块（ACM）。通过在频域中学习一组权重来校正频谱，该模块能够消除原始信号中的噪声。
- 为学习调制信号中的多尺度表示，我们设计了多尺度模块（MSM）。该模块由多个具有不同感受野的卷积组成，用于捕获多尺度特征。它能够有效地在不同尺度上捕获信号的特征，例如幅度、相位和频率。
- 为更好地学习信号序列中的时间相关性，我们提出了一种基于自注意力机制的特征融合模块（FFM） [1]。该模块能够处理长距离依赖，并支持并行计算。

实验结果表明，AMC-Net 达到了先进水平（SOTA）的性能。此外，与现有用于 AMC 的深度神经网络相比，我们的模型具有更高的时间效率。

本研究得到中国国家自然科学基金项目（编号：62276205）的资助。

2. 方法

2.1. 问题表述

通常，接收信号 $x_c(t)$ 会被转换为离散形式 $x_c[n]$，其采样率为 $1/T_s$。实际上，$x_c[n] \in \mathbb{C}$ 由同相分量 $I[n] \in \mathbb{R}$ 和正交分量 $Q[n] \in \mathbb{R}$组成。它可表示为 $x[n] = I[n] + j \cdot Q[n]$，其中 $j^2 = -1$。我们将 $I[n]$和 $Q[n]$ 简称为 I 通道和 Q 通道。通过使用 I 通道和 Q 通道，我们将 $x_c \in \mathbb{C}^{1\times L}$ 表示为实数值 $x \in \mathbb{R}^{2\times L}$。总体而言，AMC 旨在根据 $x \in \mathbb{R}^{2\times L}$对调制格式进行分类。

2.2. 模型概述

AMC-Net 的整体架构如图 1 所示。输入信号 $x \in \mathbb{R}^{2\times L}$ 经过 ACM 处理，以获得更具区分性的表示。随后，MSM 将 I 通道和 Q 通道的信息进行整合，再通过三个卷积层提取深层空间特征。提取的特征被送入 FFM，以在时间通道中进行特征融合。最后，经过全局平均池化后，结果被送入分类器进行分类。接下来，我们依次介绍这三个模块。

ACM 本质上从频域学习全局滤波器。其直觉源自卷积定理$\mathcal{F}\{f * g\} = \mathcal{F}\{f\} \cdot \mathcal{F}\{g\}$。对输入信号 x进行离散傅里叶变换，可得到一个复值序列$X_c \in \mathbb{C}^{1\times L}$。通过利用实部和虚部，我们将 $X_c \in \mathbb{C}^{1\times L}$ 表示为实值形式 $X \in \mathbb{R}^{2\times L}$。即：

$$X_c[i] = \sum_{k=0}^{L-1} (x[0,k] + j \cdot x[1,k]) e^{-j\frac{2\pi}{L}ik} \tag{1}$$

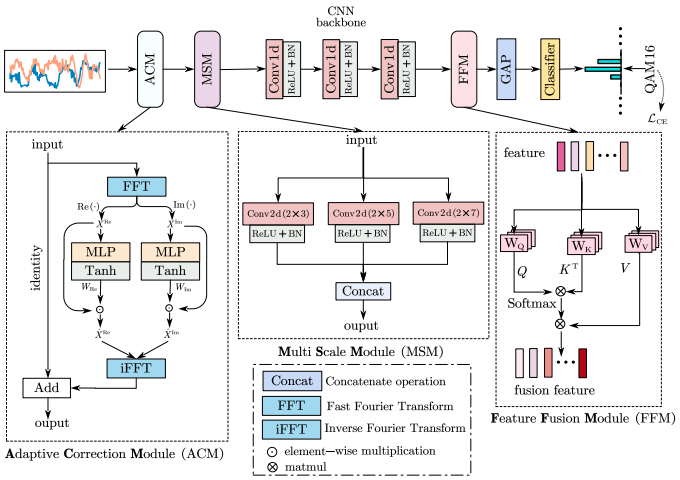


图 1：我们的 AMC-Net 架构。它由三个部分组成，分别是 ACM 、 MSM 和 FFM。

$X_c \in \mathbb{C}^{1\times L}$ 可视为 $X = \left[X^{\mathrm{Re}};\ X^{\mathrm{Im}}\right] \in \mathbb{R}^{2\times L}$。获得校正频谱 $\hat{}X^{\mathrm{Re}}$，$\hat{}X^{\mathrm{Im}}$ 的过程可表示为：

$$\begin{aligned} \hat{X}^{\mathrm{Re}} &= \mathrm{Tanh}\left(\sigma_{\mathrm{Re}}\left(X^{\mathrm{Re}}\right)\right) \odot X^{\mathrm{Re}} \\ \hat{X}^{\mathrm{Im}} &= \mathrm{Tanh}\left(\sigma_{\mathrm{lm}}\left(X^{\mathrm{lm}}\right)\right) \odot X^{\mathrm{Im}} \end{aligned} \tag{2}$$

其中，σ_{Re}，σ_{Im} 分别是两个多层感知机（MLP）的映射函数。我们分别处理实部和虚部。因此，实部和虚部的变化彼此独立，从而提高了频谱在幅度和相位上的可调节性。双曲正切函数将输出限制在范围 $[-1,1]$ 内，防止网络将频谱的值随机映射到不受约束的范围。此操作使处理后的信号保持与原始信号相同的数量级，从而使网络更易于训练。

在频谱中执行点积后，对 X 应用逆傅里叶变换，以获得去噪信号$\hat{}x$。可表示为：

$$\hat{x}[i] = \frac{1}{L}\sum_{k=0}^{L-1} \hat{X}[k] e^{j\frac{2\pi}{L}ik} \tag{3}$$

采用跳跃连接将$\hat{}x$ 与 x 关联起来，以获得最终输出。使用跳跃连接有助于网络保留信号，并避免 ACM 造成严重的非线性失真。借助我们提出的模块，可以减弱干扰分类的噪声和偏移，从而提升分类效果。

调制格式之间可区分的差异通常出现在多个尺度上，而非单一尺度。因此，需要利用多尺度特征来捕捉这些有用的差异。MSM 中使用了三种卷积，其卷积核尺寸分别为 2×3、 2×5和 2×7 。将从不同感受野尺度学习到的特征图拼接起来，得到多尺度特征图，定义如下：

$$\begin{aligned} X'_k &= \mathrm{ReLU}\left(\mathrm{BN}\left(\mathrm{Conv}_k(X)\right)\right), k \in \{1,2,3\} \\ X'' &= \mathrm{Concat}\left(X'_1, X'_2, X'_3\right) \end{aligned} \tag{4}$$

其中， X 是输入向量，$\mathrm{Conv_k}(\cdot)$表示卷积核尺寸为$(2, 2k+1)$的卷积， X'_k 是$\mathrm{Conv_k}(\cdot)$的输出， X'' 是多尺度特征图。

特征图经过三层卷积层，以进一步提取高层语义特征。高层特征图中的时间特征对预测调制格式至关重要。因此，我们采用多头注意力机制中的编码器结构来融合特征。多头注意力机制拓展了特征表示的子空间，增强了其多样性和适应性

。与以往使用长短期记忆网络、循环神经网络等的方法不同，自注意力能够整合整个序列中的信息，避免长距离依赖问题。此外，它可以并行计算，从而缩短推理时间。自注意力矩阵定义如下：

$$\text{Attention}(Q,K,V)=\text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (5)$$

其中，$Q\in\mathbb{R}^{d_k\times L}$ 是查询，$K\in\mathbb{R}^{d_k\times L}$ 是键，$V\in\mathbb{R}^{d_k\times L}$ 是值，d_k 是查询和键的维度，$\sqrt{d_k}$ 是用于防止点积值过大的缩放因子。Q，K，V由线性投影生成。可表示为：

$$Q=\mathbf{W}_QX+\mathbf{b}_Q, K=\mathbf{W}_KX+\mathbf{b}_K, V=\mathbf{W}_VX+\mathbf{b}_V \quad (6)$$

其中，$X\in\mathbb{R}^{C\times L}$ 是输入特征图，$\mathbf{W}_Q\in\mathbb{R}^{d_k\times C}$，$\mathbf{W}_K\in\mathbb{R}^{d_k\times C}$ 和$\mathbf{W}_V\in\mathbb{R}^{d_k\times C}$ 是线性投影的权重矩阵，b_Q，b_K，$b_V\in R^{d_k}$是偏置。

查询、键和值分别使用不同的投影参数独立投影h次，然后将投影结果拼接起来，以获得最终输出：

$$\text{MultiHead}=\text{Concat}(\text{head}_1,\ldots,\text{head}_h) \quad (7)$$

其中，$\text{head}_i=$注意力(Q^i,K^i,V^i)，而多头是 FFM 的最终输出。

3. 实验评估

本节评估所提出的 AMC-Net 在自动调制分类任务中的性能，并对实验结果进行全面分析。

3.1. 评估数据集

我们在 RML2016.10a 和 RML2016.10b [9] 数据集上进行评估。这两个数据集由 GNU Radio 生成。RML2016.10a 包含 11 种调制格式，信噪比范围为 - 20 至 18 dB，间隔为 2 dB。该数据集共包含 220000 个样本；每种调制格式在每个信噪比下有 1000 个样本，每个样本包含 128 个采样点。数据集中的调制格式包括 8PSK、BPSK、QAM16、QAM64、QPSK、宽带调频、连续相位频移键控、高斯频移键控、AM-DSB、单边带调幅和四电平脉冲幅度调制，均广泛应用于现代无线通信。RML2016.10b 是 RML2016.10a 的扩展版本，包含除单边带调幅外的 10 种调制格式，样本总数为 120 万。这两个数据集均包含实际的信道缺陷，例如信道频偏、采样率偏移和噪声，以模拟不完美的传输。

3.2. 实验设置

在我们的实现中，ACM 中的多层感知机包含两个全连接层，节点数为 128、48、128，并采用 ReLU 激活。MSM 对每种不同的卷积核尺寸使用 12 个滤波器。CNN骨干网络包含三个卷积层，滤波器数量分别为 64、128、256，滤波器尺寸为 1×3，并采用 ReLU 激活。分类器包含两个全连接层，节点数分别为 512、256 和 11/10。FFM 中使用了 2 个头。标准交叉熵函数用作损失函数。

我们的模型使用 Adam优化器进行训练，学习率为 $\eta=10^{-3}$。对于两个基准数据集，从不同信噪比下的各调制格式中随机选取训练、验证和测试数据集，比例为 6:2:2。所有层的默认参数均采用 Xavier 初始化。当验证损失连续 10 个训练轮次未下降时，训练过程停止。所有实验均使用 PyTorch 1.8.1 库，并在一台配备 GeForce GTX 2080Ti GPU、支持 NVIDIA CUDA 的计算机上进行。

3.3. 基线模型和评估指标

我们将该模型与四种最先进模型 MCNet [4], CCNN-Att [7], MCLDNN [6] 和 Dual-Net [5]进行比较。此外，还与两种传统算法进行比较：支持向量机（SVM） [8] 和随机森林（RF） [13]。

按照常见做法，我们采用总体准确率、宏平均F1分数和Kappa系数作为评估整体分类性能的指标。

3.4. 主要结果

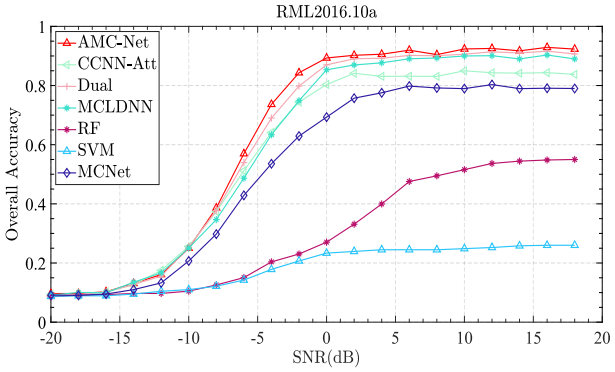
表 I 展示了两组数据集实验的评估指标。传统机器学习算法无法充分处理复杂通信环境下的信号，其性能与深度学习方法存在显著差异。在两个数据集上，AMC-Net 的表现均优于其他深度学习技术中的最先进模型。这证明了 AMC-Net 在自动调制分类任务中的有效性。

表2展示了各模型的推理时间和学习参数数量。推理时间指各方法处理一个信号批次所需的时间。总体而言，AMC-Net 以略微增加参数数量为代价，实现了更快的推理速度和最佳性能，因此具有较高的时间效率。

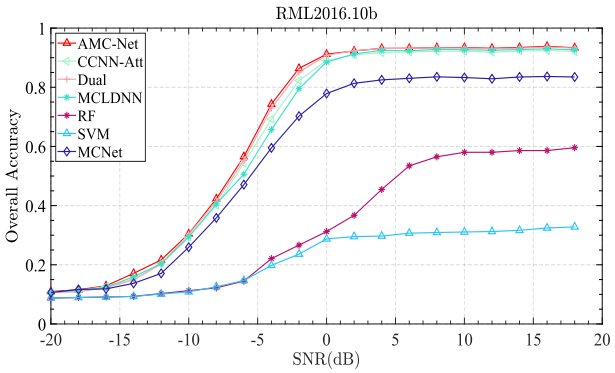
在图2中，我们绘制了不同信噪比下的平均准确率，以进行更全面的分析。在 RML2016.10a 中，当信噪比低于 0 时，AMC-Net 的表现优于所有模型，在高信噪比下也表现出色。由于数据量增加，RML2016.10b 中各模型之间的差距开始缩小。

表1：RML2016.10a和RML2016.10b上总体准确率、宏平均F1值和Kappa系数的比较。

模型	RML2016.10a数据集		
	OA	宏平均F1值	Kappa系数
SVM	18.55%	0.1923	0.1472
RF	29.73%	0.3023	0.2733
MCLDNN	61.23%	0.6344	0.5776
CCNN-Att	60.30%	0.6243	0.5609
Dual-Net	61.11%	0.6328	0.5731
MCNet	57.38%	0.5879	0.5360
AMC-Net	**62.51 %**	**0.6483**	**0.5885**
模型	RML2016.10b 数据集		
	OA	宏平均F1值	Kappa系数
SVM	21.83%	0.2214	0.1833
RF	32.46%	0.3318	0.2841
MCLDNN	62.78%	0.6338	0.5874
CCNN-Att	63.03%	0.6364	0.5901
Dual-Net	64.05%	0.6399	0.6017
MCNet	62.34%	0.6279	0.5832
AMC-Net	**64.63 %**	**0.6487**	**0.6081**



(a)



(b)

图2：RML2016.10a (a) 和 RML2016.10b (b) 上不同最先进方法在各信噪比下的平均准确率比较。

表2：两个数据集的学习参数和推理时间。

模型	学习参数	推理时间（毫秒/批次）
SVM	-	0.018
RF	-	0.015
MCLDNN	0.41M	4.24
CCNN-Att	0.38M	1.93
Dual-Net	0.83M	9.12
MCNet	0.13M	1.78
AMC-Net	0.47M	1.52

表3：消融实验的总体准确率、宏平均F1值、Kappa系数。

模型	OA	宏平均F1值	Kappa系数
AMC-Net（无 MSM）	0.6135	0.6336	0.5749
Δ	-1.16%	-1.47%	-1.36%
AMC-Net（无 ACM）	0.6038	0.6277	0.5641
Δ	-2.13%	-2.06%	-2.44%
AMC-Net（不含 FFM）	0.6093	0.6304	0.5702
Δ	-1.58%	-1.79%	-1.83%
AMC-Net	**0.6251**	**0.6483**	**0.5885**

3.5. 消融实验

我们进行了消融实验，以评估所提出模块的贡献。

我们分别移除了 MSM、FFM 和 ACM，表 4 展示了消融实验的结果。移除 ACM 后，模型准确率下降幅度最大，表明 ACM 确实有效。移除 FFM 和 MSM 的影响则依次略小。我们认为，这是因为 ACM 会调整输入信号分布，使后续网络能够更好地学习。因此，移除 ACM 后，MSM 和 FFM 主要在噪声信号分布中进行高级特征提取，从而导致次优解。

4. 结论

本文提出了一种用于自动调制分类任务的新型神经网络。为应对调制信号传输过程中严重的噪声和偏移干扰，我们的模型在频域中采用自适应校正模块来重建信号。同时，我们提出了多尺度模块和特征融合模块，以高效提取和融合特征。这三个模块的结合使 AMC-Net 达到了新的最先进水平。具体而言，AMC-Net 展示了将频域引入时间序列的优势，未来有望应用于其他时间序列分类任务。

5. 参考文献

[1] Ashish Vaswani、Noam Shazeer、Niki Parmar、Jakob Uszkoreit、Llion Jones、Aidan N Gomez、ŁukaszKaiser 和 Illia Polosukhin，《注意力就是你所需要的一切》，神经信息处理系统进展，第 30 卷，2017 年。

[2] Prokopios Panagiotou、Achilleas Anastasopoulos 和 A Polydoros，“用于调制分类的似然比检验”，载于*MILCOM 2000* 论文集：*21*世纪军事通信、信息优势架构与技术（目录编号 *00CH37155*）。IEEE，2000 年，第 2 卷，第 670–674 页。

[3] Elliott Moser、Michael K Moran、Erric Hillen、Dong Li 和 ZhiqiangWu，“基于瞬时特征的自动调制分类”，载于*2015* 年国家航空航天与电子会议（*NAECON*）。IEEE，2015 年，第 218–223 页。

[4] Thien Huynh-The、Cam-Hao Hua、Quoc-Viet Pham 和 Dong-Seong Kim，“Mcnet：一种用于鲁棒自动调制分类的高效卷积神经网络架构”，*IEEE Communications Letters*，第 24 卷，第 4 期，第 811–815 页，2020 年。

[5] Zufan Zhang、Hao Luo、Chun Wang、Chenquan Gan 和 Yong Xiang，“基于卷积神经网络-长短期记忆网络双流结构的自动调制分类”，*IEEETransactions on Vehicular Technology*，第 69 卷，第 11 期，第 13521–13531 页，2020 年。

[6] Jialang Xu、Chunbo Luo、Gerard Parr 和 Yang Luo，“一种用于自动调制识别的时空多通道学习框架”，*IEEE WirelessCommunications Letters*，第 9 卷，第 10 期，第 1629–1632 页，2020 年。

[7] Zhi Liang、Mingliang Tao、Jian Xie、Xin Yang 和 Ling Wang，“ 一种基于复值卷积神经网络和自注意力机制的无线电信号识别方法”，*IEEETransactions onCognitive CommunicationsandNetworking*，2022 年。

[8] Jie Li、Qingda Meng、Ge Zhang、Yang Sun、Lede Qiu 和 Wei Ma，“使用支持向量机和纠错输出码的自动调制分类”，载于*2017 IEEE* 第 *2* 届信息技术、网络、电子与自动化控制会议 *(ITNEC)*。IEEE，2017 年，第 60–63 页。

[9] Timothy J O’Shea、Johnathan Corgan 和 T Charles Clancy，《卷积无线电调制识别网络》，载于神经网络工程应用国际会议。Springer，2016 年，第 213–226 页。

[10] Sreeraj Rajendran、Wannes Meert、Domenico Giustiniano、Vincent Lenders 和 Sofie Pollin，《采用分布式低成本频谱传感器进行无线信号分类的深度学习模型》，*IEEE* 认知通信与网络汇刊，第 4 卷，第 3 期，第 433–445 页，2018 年。

[11] Sai Huang、Rui Dai、Juanjuan Huang、Yuanyuan Yao、Yue Gao、Fan Ning 和 Zhiyong Feng，“使用门控循环残差网络进行自动调制分类”，*IEEE*物联网期刊，第 7 卷，第 8 期，第 7795–7807 页，2020 年。

[12] Rajeev Sahay、Christopher G Brinton 和 David JLove，“存在对手时基于频率的自动调制分类”，载于*ICC 2021-IEEE* 国际通信会议。IEEE，2021 年，第 1–6 页。

[13] Kostis Triantafyllakis、Manolis Surligas、George Var- dakis 和 Stefanos Papadakis，“ Phasma：一种基于随机森林的自动调制分类系统”，载于*2017 IEEE*动态频谱接入网络国际研讨会 *(DySPAN)*。IEEE，2017 年，第 1–3 页。

[14] Nathan E. West 和 Tim O’Shea，《用于调制识别的深度架构》，*2017*年*IEEE*动态频谱接入网络国际研讨会（*DySPAN*），第1–6页，2017年。

[15] Qian Mao、Fei Hu 和 Qi Hao，《面向智能无线网络的深度学习：全面综述》，*IEEE*通信综述与教程，第20卷，第4期，第2595–2621页，2018年。

[16] Fuxin Zhang、Chunbo Luo、Jialang Xu、Yang Luo 和 FuChun Zheng，《基于深度学习的自动调制识别：模型、数据集与挑战》，2022年。

[17] Mathieu Goutay，《深度学习在增强型无线通信系统设计中的应用》，2022年。

[18] Mansi Patel、Xuyu Wang 和 Shiwen Mao，《利用条件生成对抗网络进行数据增强以实现自动调制分类》，载于第*2*届*ACM*无线安全与机器学习研讨会论文集，2020年，第31–36页。