

基于多尺度卷积融合编码网络的调制识别方法

李国军^{1,2}, 朱思源^{1,2}, 郑建忠², 王杰^{2,3}, 叶昌荣^{1,2}

(1. 重庆邮电大学光电工程学院, 重庆 400065; 2. 重庆邮电大学超视距可信信息传输研究所, 重庆 400065;
3. 重庆邮电大学通信与信息工程学院, 重庆 400065)

摘要: 为了解决现有调制识别方法因特征提取不足而难以获得高准确率的问题, 提出了一种基于 Transformer 架构的调制识别方法。该模型通过使用不同尺寸的卷积核, 增强了对信号多尺度特征的提取能力, 并将这些特征进行融合, 以提升模型的特征学习能力, 降低后续处理对计算资源的需求。同时, 利用多头自注意力机制对信号进行并行处理, 以捕捉信号的多样化特征。利用双分支多层感知器增强模型的适应性和多样性学习能力, 同时提高模型的运行速度。实验结果表明, 该模型在测试阶段具有良好的稳定性和泛化能力, 在固定训练批次大小的情况下, 测试批次大小改变对模型性能的影响不大。针对 RML2018.01A 数据集, 当信噪比达到 10 dB 时, 识别准确率能够达到 96% 以上。

关键词: 卷积神经网络; 调制识别; Transformer; 多尺度融合; 多层感知器

中图分类号: TN911.7

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025137

Modulation recognition method based on multiscale convolutional fusion coding networks

LI Guojun^{1,2}, ZHU Siyuan^{1,2}, ZHENG Jianzhong², WANG Jie^{2,3}, YE Changrong^{1,2}

1. School of Optoelectronic Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China
2. Lab of BLOS Reliable Information Transmission, Chongqing University of Posts and Telecommunications, Chongqing 400065, China
3. School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract: To address the issue of insufficient feature extraction in existing modulation recognition methods that limited classification accuracy, a Transformer-based modulation recognition method was proposed. Convolutional kernels of varying sizes were employed to enhance multi-scale signal feature extraction, followed by feature fusion to strengthen learning capability while reducing computational demands. A multi-head self-attention mechanism was utilized to enable parallel processing for capturing diverse signal characteristics. A dual-branch multilayer perceptron structure was introduced to further improve adaptability and diversity learning while accelerating operational speed. Experimental results demonstrated the model's robust stability and generalization capability, showing minimal performance variation under different test batch sizes with fixed training batches. On the RML2018.01A dataset, the proposed model achieves over 96% classification accuracy at 10 dB.

Keywords: convolutional neural network, modulation classification, Transformer, multi-scale fusion, multilayer perceptron

收稿日期: 2025-01-02; 修回日期: 2025-04-28

通信作者: 朱思源, 1198595079@qq.com

基金项目: 国家自然科学基金资助项目(No.U22A2006, No.62201106); 重庆市基础研究与前沿探索项目(No.cstc2021ycjh-bgzxm0072)

Foundation Items: The National Natural Science Foundation of China (No.U22A2006, No.62201106), The Chongqing Basic Research and Frontier Exploration Project (No.cstc2021ycjh-bgzxm0072)

0 引言

通信信号的调制识别又称为自动调制识别(AMC, automatic modulation classification),是指在调制信息内容以及调制参数未知的情况下,接收方通过技术手段判断出信号所采用的调制方式,帮助后续信号分析和信号处理的开展。该技术可以在电子侦察、电子对抗^[1]等一系列军事任务中识别敌方发送的干扰信息和关键军事信息,帮助军方制定有针对性的侦察和反侦察战略^[2]。目前,调制识别的方法通常可以分为基于最大似然比、基于特征提取和基于深度学习的方法。

基于最大似然比的方法依赖于统计理论,特别是最大似然估计原理。该方法通过接收信号的先验信息得到一个似然比值,该似然比值可表示该接收信号为不同调制类型的概率,然后选择似然比值最大的调制类型作为最终的分类结果。该方法在理论上可以达到最优的性能,但是在实际应用中,通常需要知道信号的各种先验知识(如信噪比(SNR, signal to noise ratio)、信道状态等),并且计算复杂性较高。

基于特征提取的方法依赖于从接收信号中提取可区分不同调制类型的信号明显特征,包括高阶累积量特征^[3]、循环谱特征^[4]、谱特征^[5]、小波特征^[6]和星座图特征^[7]等,这些特征被用作传统机器学习分类器,如随机森林^[8]、K邻近^[9]、支持向量机^[10]等的输入,通过分类器对这些特征进行学习,达到信号调制类型识别分类的目的。这种方法相比于基于最大似然比的方法计算复杂度较低,但性能可能受到信噪比和信道条件变化的影响。

随着基于深度学习的AMC技术的快速发展,为传统调制识别方法无法克服的难题带来了新的解决思路^[11]。深度学习可以借助神经网络强大的表征能力自动提取通信信号的特征,并通过相应输出层得到调制识别结果。在针对通信信号调制识别的问题上,国内外专家学者提出了大量方法。2022年,文献[12]提出一种多路径特征融合网络,在18 dB信噪比下,对11种信号的识别精度为99.04%。在低SNR环境下对11种信号的调制识别中,文献[13]提出了一种注意力机制的短链卷积长短时记忆深度神经网络识别模型,对信号进行高精度的识别,并且对特定信号不产生混淆。文献[14]构建的卷积神经网络(CNN, convolutional neural network)-门控循环单元(GRU, gated recurrent unit)-深度神

经网络(DNN, deep neural network)混合模型创新性地引入小波阈值预处理器,在低信噪比区间(-12~0 dB)展现出卓越的噪声抑制能力,其分层特征提取机制有效克服了传统单网络模型的表征瓶颈,但在对高信噪比环境下无性能优势。文献[15]构建了决策级融合框架,通过星座图与时频图的特征协同优化,使多进制相位调制(MPSK, multiple phase shift keying)信号识别准确率产生显著增益,但数据样本中仅含4类相位偏移调制(PSK, phase shift keying)信号,没有对其他类型的信号进行适应性测试。基于自注意力(SA, self-attention)机制的Transformer^[16]最近已成为自然语言处理的标准,视觉Transformer^[17]也被广泛用于图像分类任务,但在信号分类中的应用还相对较少。文献[18]构建的CNN-Transformer异构网络,通过局部感知与全局依赖的协同建模,在RML2016.10b数据集上实现了良好的识别准确率,但此方法信号预处理复杂,且并未充分利用时频谱特征,对于一些调制类型在宽带调频(WBFM, wideband frequency modulation)高信噪比识别准确率仍然较低。文献[19]设计的ResNet-Transformer双流架构,采用决策级融合策略,针对RML2018.01A数据集SNR为10 dB以上时,能够实现93%以上的平均识别准确率,解决了神经网络在提取信号时序信息时的局限性,但模型参数量较大,且具有良好的抗噪声能力。综上,Transformer架构能有效提升调制识别准确率,但现有模型普遍存在特征提取不充分的问题,导致识别准确率低,为此本文设计了多核卷积融合模块和改进Transformer编码器,以实现高调制识别准确率。

1 多尺度卷积融合编码网络结构设计

本文设计了如图1所示的多尺度卷积融合编码神经网络模型,该模型包含多核卷积模块、信号嵌入和位置编码模块、改进的Transformer编码器模块和分类器。

多核卷积模块:将输入信号的维度扩展之后,同时送入5个并行的卷积运算单元进行特征捕获,每个单元的卷积核大小预设为 2×4 、 2×8 、 2×16 、 2×32 、 2×64 。不同的卷积核大小可以捕获不同细节程度上的信号特征信息,以此捕获输入样本的全局特征,增强模型的特征提取能力。每个单元得到的输出结果表示为

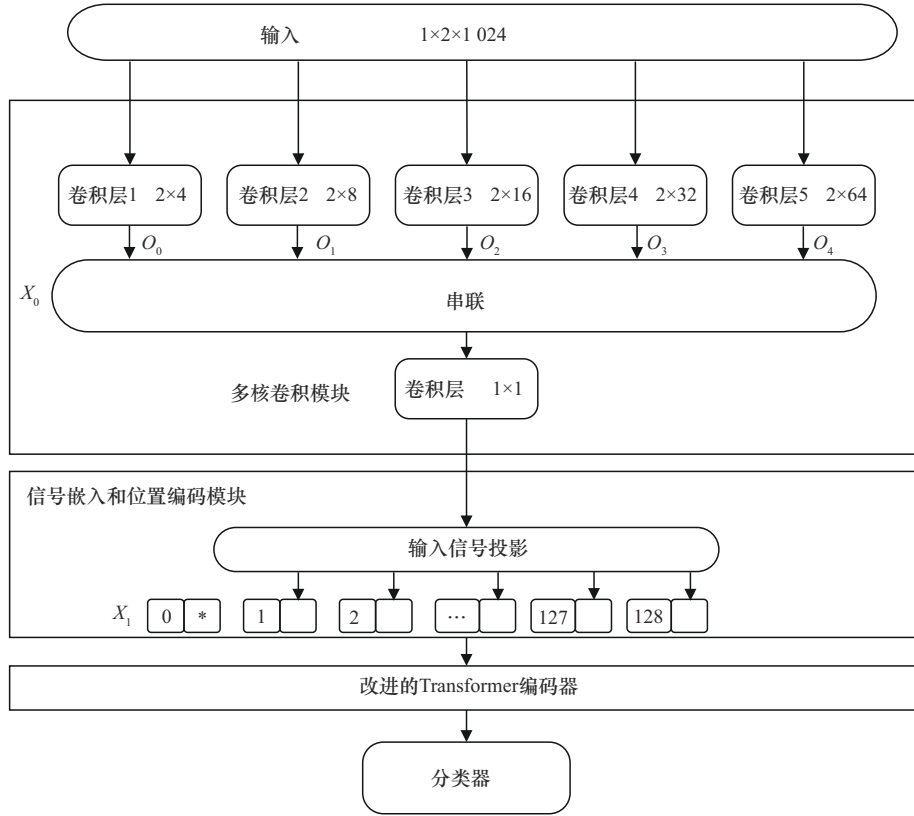


图1 多尺度卷积融合编码神经网络模型

$$O_0 = \text{Conv}(I, W_0, b_0; K_0 = (C_{\text{out}}, 2, 4), S, P_0 = (0, 0)) \quad (1)$$

$$O_1 = \text{Conv}(I, W_1, b_1; K_1 = (C_{\text{out}}, 2, 8), S, P_1 = (2, 0)) \quad (2)$$

$$O_2 = \text{Conv}(I, W_2, b_2; K_2 = (C_{\text{out}}, 2, 16), S, P_2 = (6, 0)) \quad (3)$$

$$O_3 = \text{Conv}(I, W_3, b_3; K_3 = (C_{\text{out}}, 2, 32), S, P_3 = (12, 0)) \quad (4)$$

$$O_4 = \text{Conv}(I, W_4, b_4; K_4 = (C_{\text{out}}, 2, 64), S, P_4 = (30, 0)) \quad (5)$$

其中, I 表示输入通道, W_i 和 b_i 分别是每个卷积运算单元的权重项和偏置项, 步幅 $S = (2, 8)$, P 为填充, C_{out} 为输出通道。

通过将每个单元的输出串联形成一个新的输出, 即 $X_0 = \text{Concat}(O_0, O_1, O_2, O_3, O_4)$ 。最后, X_0 进行 1×1 卷积运算, 实现跨通道信息交互和融合, 并实现维度压缩, 降低后面模型的运算规模。以此在低复杂度的前提下完成多维特征提取, 使模型在各类环境下均能达到更高的识别性能。

信号嵌入: 经过多核卷积模块操作输出的结果定义为 $X_0 \in \mathbb{R}^{C_{\text{out}} \times 1 \times H_{\text{out}}}$, 其中, H_{out} 表示输出特征图高度, C_{out} 表示输出通道总数。通过转置降

维后的输出得到 $X_0' \in \mathbb{R}^{H_{\text{out}} \times C_{\text{out}}}$ 以及与类标记 $X_{\text{cls}} \in \mathbb{R}^{1 \times C_{\text{out}}}$ 进行连接, 最终得到 $X_0'' = \text{Concat}(X_0', X_{\text{cls}})$, $X_0'' \in \mathbb{R}^{(H_{\text{out}} + 1) \times C_{\text{out}}}$ 。

位置编码: 在位置编码环节, 选择使用正弦-余弦位置编码, 为每一个位置生成一个唯一的向量, $E_{\text{pos}} \in \mathbb{R}^{(H_{\text{out}} + 1) \times C_{\text{out}}}$ 。将 X_0'' 和位置信息 E_{pos} 相加, 最终得到输出 $X_1 = \text{Concat}(X_0'', X_{\text{cls}}) + E_{\text{pos}}$, $X_1 \in \mathbb{R}^{(H_{\text{out}} + 1) \times C_{\text{out}}}$ 。

改进的 Transformer 编码器: 该模块由多头自注意力 (MHSA, multi-head self-attention) 机制模块和双分支多层感知器 (MLP, multilayer perceptron) 模块交替组成。层归一化在每个 MHSM 机制模块之前进行, 并在每个模块的前后都设置了跳跃连接, 如图 2 所示。

MHSA 机制: 该机制建立在基于 Query (q)、Key (k)、Value (v) 的 SA 机制上, SA 机制允许模型根据输入特征之间的关系合并输入特征, 而不考虑它们的先后顺序。在注意力机制中, 每个输入元素都仅仅只有一个 q 、 k 、 v 与之对应, 如图 3 所示, 其中, $q_i = W_q \times a_i$, $k_i = W_k \times a_i$, $v_i = W_v \times a_i$ 。

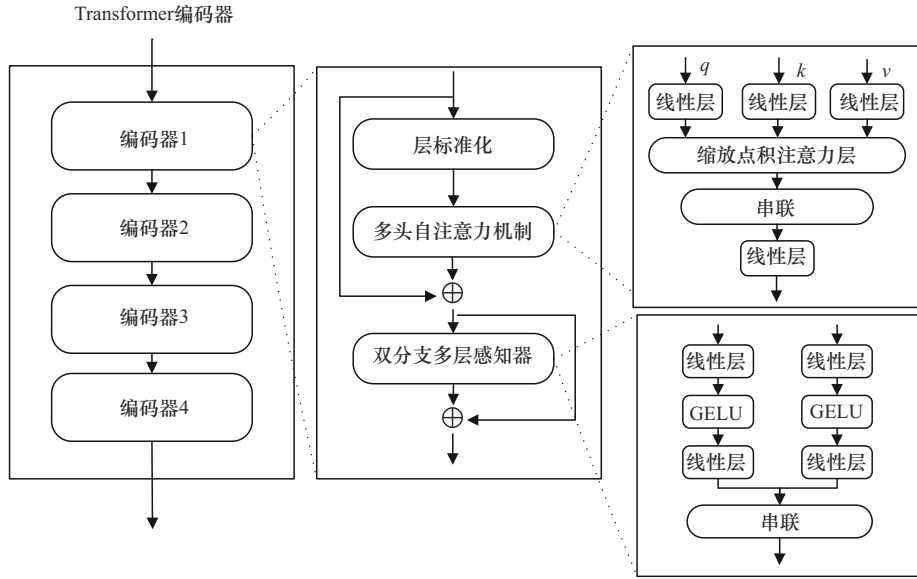


图2 改进的Transformer编码器




图3 注意力机制

在MHSA机制中, q 、 k 、 v 经过线性变换后, 通过缩放点积注意力机制进行集中, 然后将 n 次的缩放点积结果进行拼接, 再进行一次线性变换得到MHSA的结果。每进行一次 q 、 k 、 v 运算称为一个“头”, 且每次 q 、 k 、 v 进行线性变换的参数 W 是不一样的, 最终 $X_{MHSA} \in \mathbb{R}^{(H_{out}+1) \times C_{out}}$ 。

多头注意力机制则是在 a_i 乘以一个 q 、 k 、 v 后, 会再分配多个 q 、 k 、 v , 以2个 q 、 k 、 v 为例, 如图4所示。

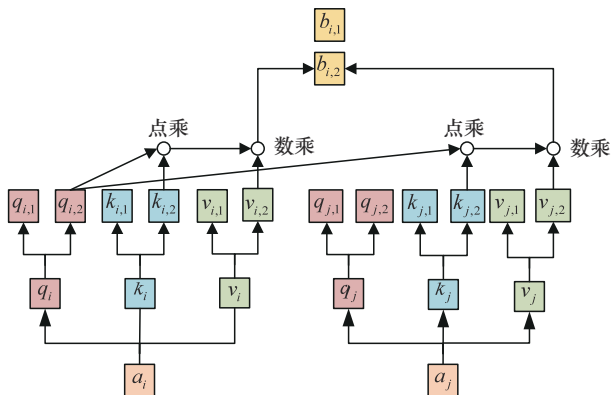


图4 多头注意力机制

图4中, $q_{i,1} = W_{q,1} \times q_i$, $q_{i,2} = W_{q,2} \times q_i$, 将2个头的输出结果 $b_{i,1}$ 、 $b_{i,2}$ 拼接, 再进行转置就得到了注意力输出 b_i , 如图5所示。




图5 注意力输出结果

MLP: 为了提升Transformer的性能, 将其中的MLP调整为双分支结构, 通过同时进行线性变换实现多样化的学习, 并在全连接层之后连接了高斯误差线性单元(GELU, Gaussian error linear unit)激活函数。对比现有研究普遍仅使用全连接层的做法, 本文在不显著增加计算复杂度的前提下, 显著增强了模型的灵活性。

将MHSA机制输出的结果按照通道数平均划分2个等份, 即 $X_{mlp1} \in \mathbb{R}^{(H_{out}+1) \times [0:N_0]}$, $X_{mlp2} \in \mathbb{R}^{(H_{out}+1) \times [N_0:C_{out}]}$, 其中 $N_0 = \frac{C_{out}}{2}$, 输出结果表示为

$$X_{db-mlp} = \text{Concat} \left(\text{dense} \left(\text{GELU} \left(\text{dense} \left(X_{mlp1} \right) \right) \right), \text{dense} \left(\text{GELU} \left(\text{dense} \left(X_{mlp2} \right) \right) \right) \right)$$

模型单模块数据输入形状大小和输出形状大小如表1所示。

表1 模型单模块数据输入形状大小和输出形状大小

模块	输入形状大小	输出形状大小
多核卷积模块	(512,1,2,1 024)	(512,64,1,128)
信号嵌入和位置编码模块	(512,64,1,128)	(512, 129,64)
多头自注意力机制模块	(512, 129,64)	(512, 129,64)
双分支多层感知器模块	(512, 129,64)	(512, 24)

2 算法仿真及性能分析

2.1 数据集

使用RML2018.01A数据集^[20]对本文模型进行训练和测试验证。该数据集在生成时考虑了实际通信系统中的常见影响因素,如时延、扩散、载波频率偏移和噪声等。该数据集共包含24种调制信号,分别为通断键控(OOK, on-off keying)信号、四进制幅移键控(4ASK, 4 amplitude shift keying)信号、八进制幅移键控(8ASK)信号、二进制相移键控(BPSK, binary phase shift keying)信号、四进制相移键控(QPSK, quadrature phase shift keying)信号、八进制相移键控(8PSK)信号、16进制相移键控(16PSK)信号、32进制相移键控(32PSK)信号、16进制幅度相位键控(16APSK, 16 amplitude phase shift keying)信号、32进制幅度相位键控(32APSK)信号、64进制幅度相位键控(64APSK)信号、128进制幅度相位键控(128APSK)信号、16进制正交幅度调制(16QAM, 16 quadrature amplitude modulation)信号、32进制正交幅度调制(32QAM)信号、64进制正交幅度调制(64QAM)信号、128进制正交幅度调制(128QAM)信号、256进制正交幅度调制(256QAM)信号、幅度调制单边带宽(AM-SSB-WC)信号、单边带抑制载波调幅(AM-SSB-SC)信号、幅度调制双边带宽(AM-DSB-WC)信号、双边带抑制载波调幅(AM-DSB-SC)信号、频率调制(FM, frequency modulation)信号、高斯最小频移键控(GMSK, Gaussian minimum shift keying)信号、偏移四相相移键控(OQPSK, offset-QPSK)信号。SNR范围为-20~30 dB,步进间隔为2 dB,共计26种SNR,每种调制方式在每个SNR值下均有4 096个信号样本,每条样本数据中包含I/Q两路信号,由1 024个采样点组成,因此信号的数据格式为[1 024, 2]。本文选取信噪比

在0~30 dB的所有信号,并按照3:1的比例划分为训练集和测试集。模型训练进行了200个轮次,初始学习率设置为0.001,并使用Adam优化器。学习率每经过20个轮次按照0.8的倍数递减,损失函数采用分类交叉熵。

2.2 实验结果与分析

2.2.1 不同训练批次大小下的识别准确率

较小的训练批次可以提供更频繁的参数更新,但可能会增加训练时间;较大的训练批次可以减少训练时间,但可能会导致参数更新不够频繁,从而影响模型的收敛速度和性能。通常,测试批次大小与训练批次大小相同,以便在测试过程中保持一致的计算和评估方式。

本节通过控制变量法探究不同训练批次参数对模型性能的影响。首先采用不同的训练批次大小来对模型进行训练,接着,采用不同的测试批次大小针对模型性能进行测试,最终给出本文模型在不同训练批次大小的情况下,使用不同的测试批次大小进行测试时的识别准确率,如图6所示。

实验结果表明,当训练批次大小不同时,采用不同的测试批次大小进行测试,所得结果存在差异;当训练批次大小相同时,测试批次大小对本文模型的信号平均识别准确率无影响。其中,当训练批次大小分别为128、256和512时,信号总体平均识别准确率分别为91.16%、91.26%和90.77%,各批次大小下平均识别准确率相近,这表明本文模型对批次大小平均敏感性低,在实际应用时可以根据硬件条件选择合适的批次大小。

此外,本节给出了训练批次大小和测试批次大小相同情况下所提模型识别结果的混淆矩阵,如图7~图9所示。从实验结果可以看出,有11种信号的识别准确率达到95%以上,并且没有出现如文献[18]中的对某类调制方式无法识别的情况。

通过实验可知,随着训练批次大小的增加,模型的平均识别准确率并未显著提高。这表明本文模型在训练过程中并不适合使用较大的训练批次大小。训练批次大小发生改变时,会影响模型对于不同调制信号的平均识别准确率,这种影响既可能带来正面效果,也可能导致负面效果;而在训练批次大小保持不变的情况下,调整测试批次大小对模型的信号平均识别准确率几乎没有影响。




图 6 不同测试批次大小下本文模型的平均识别准确率




图 7 混淆矩阵(批次大小均为 128)




图8 混淆矩阵(批次大小均为256)

2.2.2 同信噪比下的识别准确率

当信噪比较高时，信号中的有用信息相对较强，而噪声相对较弱，信号的特征更加明显，与噪声的区分度更高，使得信号更容易被识别和分类。相反，当信噪比较低时，噪声的强度增加，可能会掩盖或干扰信号的特征，导致特征的混淆或失真，使得信号的识别和分类变得更加困难。

将信号的信噪比从0~30 dB依次划分为单一信噪比的数据集，并根据信噪比的顺序对模型进行训练和测试。本节展示了本文模型在相同的训练批次大小和测试批次大小条件下，不同信噪比下的信号识别准确率的对比，如图10~图12所示。

由图10~图12可知，在不同的信噪比条件下，各类信号的平均识别准确率随着信噪比的升高均呈现总体上升的趋势，且这一趋势是相同的。除了AM-SSB-WC信号的识别结果相对欠佳之外，其他

信号都能够得到较好的识别。不同信噪比下模型的平均识别准确率如图13所示。由图13可知，在信噪比为6 dB时，平均识别准确率能够达到90%，当信噪比达到10 dB时，则能够达到96%以上。在信噪比为16 dB时，本文模型对比文献[18]的峰值准确率有2%的提升。信噪比0~30 dB范围内平均识别准确率由文献[19]的88.7%提升到90.8%，特别地，在信噪比为10 dB时，本文模型对比文献[19]的平均识别准确率有3%的性能提升。

2.2.3 两类轻量级神经网络模型对比

轻量级神经网络模型凭借其卓越的工程适用性，在资源受限环境中展现出显著的技术优势。该类网络通过结构优化与算法创新实现四大核心特性：计算效能优越性、存储空间高效性、能耗经济性和部署灵活性。相较传统调制识别方法存在的人工特征工程依赖性强、计算复杂度呈指数增长以及




图9 混淆矩阵(批次大小均为512)




图10 不同信噪比下的信号识别准确率(训练批次大小和测试批次大小均为128)




图 11 不同信噪比下的信号识别准确率(训练批次大小和测试批次大小均为 256)




图 12 不同信噪比下的信号识别准确率(训练批次大小和测试批次大小均为 512)

环境适应性差等局限, 轻量级神经网络通过端到端特征学习、自适应计算以及知识蒸馏等创新机制实现突破, 能够在保持较高识别准确率的同时, 显著降低计算复杂度和内存占用。

本文按照文献[21]复现了稀疏连接卷积神经网络模型, 2个模型进行相同的实验。本节实验设定的训练批次大小分别为128、256和512, 测试批次大小分

别为2、4、8、16、32、64、128、256和512, 最终得到如图 14 所示的平均识别准确率。从图 14 可以看出, 本文模型在不同的测试批次大小下能够保持相同的平均识别准确率, 而稀疏连接卷积神经网络模型在相同条件下无法保持稳定的识别准确率。

2种模型在识别准确率、参数数量和运行时间上的对比如表 2 所示。




图 13 不同信噪比下模型的平均识别准确率




图 14 2种模型的平均识别准确率

表 2 2种模型在识别准确率、参数量和运行时间上的对比

模型	识别准确率	参数量	运行时间/(ms·样本 ⁻¹)
多尺度卷积融合神经网络	90.77%	229 480	1.65
稀疏连接卷积神经网络	89.57%	174 568	5.32

由表 2 可知, 虽然稀疏连接卷积神经网络的参数量少, 但在识别准确率和运行时间上都比本文模

型性能差。从网络搭建上发现稀疏连接卷积神经网络采用的是卷积神经网络进行累叠, 虽然通过深度可分离卷积层和分组卷积层减少了计算量, 但网络深度较大, 使模型训练和测试过程变慢。

实验结果表明, 本文方法解决了稀疏连接卷积神经网络存在的因测试批次大小不同造成的识别准确率大幅度下降的问题, 可以保证在不同测试批次下模型对于样本信号的分类能力, 即使测试数据不足, 其识别准确率也不会受到明显影响。

3 结束语

本文提出了一种基于 Transformer 架构的调制识别方法,用于信号的调制识别分类。该方法首先通过多尺度卷积核捕捉样本不同尺度下的特征信息,并通过卷积融合操作实现通道上的降维,降低模型的运算规模。其次,通过位置编码增强信号的空间信息的同时,利用多头自注意力机制对特征进行深入学习和权重分配。此外,引入双分支多层感知器来增强本文模型的适应性和多样性学习能力,使模型能够更好地适应不同的信号特征和复杂环境,增强了模型的泛化能力。最后,本文模型通过 Softmax 分类器输出最终的分类结果。结果表明,本文模型训练并不需要过大的训练批次,这有助于减少计算资源的消耗;在固定训练批次大小的情况下,测试批次大小对模型性能的影响不大,这有助于在实际应用中处理测试数据不足的问题;针对 RML2018.01A 数据集,在高信噪比环境下,本文模型的识别准确率超过 96%,显示出模型在信号调制识别任务中的高效性能。

参考文献:

- [1] 吴美霖,高瑜翔,涂雅培,等.基于特征融合和 MACLNN 的通信信号自动调制识别[J].无线电工程,2022,52(11):1970-1976.
WU M L, GAO Y X, TU Y P, et al. Automatic modulation recognition of communication signals based on feature fusion and MACLNN[J]. Radio Engineering, 2022, 52(11): 1970-1976.
- [2] ZHANG F X, LUO C B, XU J L, et al. Deep learning based automatic modulation recognition: models, datasets, and challenges[J]. Digital Signal Processing, 2022, 129: 103650.
- [3] 解辉,姚智刚,马俊涛,等.一种基于高阶累积量的复杂调制样式识别方法[J].电讯技术,2019,59(8):925-929.
XIE H, YAO Z G, MA J T, et al. A complex modulation pattern recognition method based on higher order cumulants[J]. Telecommunication Engineering, 2019, 59(8): 925-929.
- [4] WEI Y J. Modulation pattern recognition and parameter estimation based on cyclic spectrum[D]. Chengdu: University of Electronic Science and Technology of China, 2015.
- [5] 吴振兴,阮怀林,何宇.基于谱特征的雷达信号脉内编码调制样式识别[J].电子信息对抗技术,2015,30(2):16-20,66.
WU Z X, RUAN H L, HE Y. Intra-pulse coding modulated recognition technology of radar signals based on spectrum characteristics[J]. Electronic Information Warfare Technology, 2015, 30(2): 16-20, 66.
- [6] 冯旭哲,罗飞路,杨俊,等.基于小波支持向量机的数字通信信号调制识别[J].电子测量与仪器学报,2009,23(3):87-92.
FENG X Z, LUO F L, YANG J, et al. Automatic modulation recognition using support vector machines based on wavelet transform[J]. Journal of Electronic Measurement and Instrumentation, 2009, 23(3): 87-92.
- [7] WANG Y, LIU M, YANG J, et al. Data-driven deep learning for automatic modulation recognition in cognitive radios[J]. IEEE Transactions on Vehicular Technology, 2019, 68(4): 4074-4077.
- [8] DONG Y N, DU B, ZHANG L P. Target detection based on random forest metric learning[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(4): 1830-1838.
- [9] ZHANG S C, LI X L, ZONG M, et al. Efficient kNN classification with different numbers of nearest neighbors[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(5): 1774-1785.
- [10] WU X H, ZUO W M, LIN L, et al. F-SVM: combination of feature transformation and SVM learning via convex relaxation[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(11): 5185-5199.
- [11] DOWNEY J, HILBURN B, O'SHEA T, et al. Machine learning re-makes radio[J]. IEEE Spectrum, 2020, 57(5): 35-39.
- [12] LEI Z H, JIANG M X, YANG G S, et al. Towards recurrent neural network with multi-path feature fusion for signal modulation recognition[J]. Wireless Networks, 2022, 28(2): 551-565.
- [13] ZOU B H, ZENG X D, WANG F Q. Research on modulation signal recognition based on CLDNN network[J]. Electronics, 2022, 11(9): 1379.
- [14] 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.
ZHOU S Y, LU H, HU Q, et al. Low signal-to-noise ratio automatic modulation recognition method based on CGDNN[J]. Application Research of Computers, 2024, 41(8): 2489-2495.
- [15] 孙会楠.基于深度学习的多进制相移键控信号调制识别研究[J].太原学院学报(自然科学版),2024,42(1):54-64.
SUN H N. Research on modulation recognition of MPSK signal based on deep learning[J]. Journal of Taiyuan University (Natural Science Edition), 2024, 42(1): 54-64.
- [16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. arXiv Preprint, arXiv: 1706.03762, 2017.
- [17] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: transformers for image recognition at scale[J]. arXiv Preprint, arXiv: 2010.11929, 2020.
- [18] 杨静雅,齐彦丽,周一青,等. CNN-Transformer 轻量级智能调制识别算法[J].西安电子科技大学学报,2023,50(3):40-49.
YANG J Y, QI Y L, ZHOU Y Q, et al. Algorithm for recognition of lightweight intelligent modulation based on the CNN-transformer networks[J]. Journal of Xidian University, 2023, 50(3): 40-49.
- [19] 沈丹阳,麦文.基于 ResNet-Transformer 的通信信号自动调制识别[J].计算机工程,2025, doi: 10.19678/j.issn.1000-3428.0069677.
SHEN D Y, MAI W. Automatic modulation recognition of communication signals based on ResNet-transformer network[J]. Computer Engineering, 2025, doi: 10.19678/j.issn.1000-3428.0069677.
- [20] O'SHEA T J, ROY T, CLANCY T C. Over-the-air deep learning based

radio signal classification[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 168-179.

- [21] TUNZE G B, HUYNH-THE T, LEE J M, et al. Sparsely connected CNN for efficient automatic modulation recognition[J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 15557-15568.

[作者简介]



李国军 (1978-), 男, 四川资阳人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为复杂恶劣环境超视距无线通信与网络。



郑建忠 (1970-), 男, 四川营山人, 重庆邮电大学高级工程师, 主要研究方向为智能信号处理、电子对抗。



王杰 (1994-), 男, 重庆人, 重庆邮电大学博士生, 主要研究方向为超视距无线通信与网络。



朱思源 (1999-), 女, 重庆人, 重庆邮电大学硕士生, 主要研究方向为信号调制识别、深度学习。



叶昌荣 (1989-), 男, 四川荣昌人, 博士, 重庆邮电大学副教授, 主要研究方向为微弱生物信号的提取与检测、天波广域协作传输技术。