

DOI:10.19651/j.cnki.emt.2518880

基于复值卷积与自适应小波分解的调制识别方法*

刘浩¹ 鲁进^{1,2} 黎鹏¹ 李成星¹

(1. 云南大学信息学院 昆明 650504; 2. 云南大学云南省高校物联网技术及应用重点实验室 昆明 650504)

摘要: 针对现有深度学习调制识别方法在低信噪比条件下识别性能显著下降, 信号特征利用不充分的问题, 提出了一种基于自适应小波分解的多融合复值卷积密集连接神经网络(AW-MCDCN)。AW-MCDCN将IQ与AP信号作为输入, 通过采用密集连接构建深层网络来充分提取IQ信号的时域特征, 同时加入AP信号形成异构特征互补; 并根据复值卷积原理改进了经典的复值卷积网络设计了新的复值交叉卷积网络, 此外, 为解决传统复值网络参数数量过大的问题, 嵌入可学习小波分解层, 自适应地捕捉信号的多尺度特征的同时加入频域特征。实验表明, 在RML2018.01a数据集上, 该模型最高达到98.31%的识别精度, 平均准确率达到64.59%, 相比传统的网络结构提升了1.65%~18.91%, 达到了SOTA性能。

关键词: 调制识别; 复值卷积; 多融合; 密集连接; 自适应小波分解

中图分类号: TN911.3 **文献标识码:** A **国家标准学科分类代码:** 510.5099

Modulation recognition method based on complex-value convolution and adaptive wavelet

Liu Hao¹ Lu Jin^{1,2} Li Peng¹ Li Chengxing¹

(1. School of Information, Yunnan University, Kunming 650504, China; 2. Key Laboratory of Internet of Things Technology and Application in Yunnan Province Universities, Yunnan University, Kunming 650504, China)

Abstract: Aiming at the problem that the existing deep learning modulation recognition methods' recognition rate is low under low SNR conditions and insufficiently extracts and utilizes signal features, an Adaptive Wavelet and Multi-fusion Complex-value Dense Convolutional Neural Networks (AW-MCDCN) is proposed. The AW-MCDCN takes both IQ and AP signals as inputs, employing dense connections to construct a deep network that comprehensively extracts temporal features from IQ signals while incorporating AP signals to form heterogeneous feature complementarity. We further improve the classical complex-valued convolutional network by proposing a novel complex-valued cross convolution network based on complex convolution principles. Additionally, to resolve the excessive parameter quantity in traditional complex-valued networks, we embed a learnable wavelet decomposition layer that adaptively captures multi-scale signal features while incorporating frequencydomain characteristics. Experimental results demonstrate that our model achieves 98.31% peak recognition accuracy and 64.59% average accuracy on the RML2018.01a dataset, outperforming traditional network architectures by 1.65%~18.91% improvement margins, thus attaining SOTA performance.

Keywords: modulation recognition; complex-valued convolution; multi-fusion; densely connected; adaptive wavelet decomposition

0 引言

自动调制识别(automatic modulation recognition, AMR)^[1]是无线通信领域中的重要研究方向, 主要任务是

在未知信号环境下自动识别传输信号所采用的调制方式。AMR在提高认知无线电的频谱资源利用率^[2], 保障无人机通信链路安全性和稳定性^[3], 防范物联网设备遭到干扰上^[4]具有重要作用。传统的AMR方法主要分为基于似然

收稿日期: 2025-05-21

* 基金项目: 国家自然科学基金(61966037)、云南大学专业学位研究生实践创新项目(ZC-202410692)、云南省本科教育教学改革项目(JG2023178)资助

概率^[5]和基于特征^[6]的方法,然而随着现代无线通信系统的快速发展,调制方式变得越来越多样化,传统的手工设计的调制识别方法已难以满足当前复杂信号环境下的需求。基于深度学习^[7]的 AMR 方法凭借其优秀的鲁棒性与自适应力成为当前的主流研究方向。

近年来,以卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN)为代表的深度学习(deep learning, DL)在 AMR 领域实现了基准性能, O'Shea 等^[8]提出将同向正交信号(in-phase and quadrature, IQ)输入卷积神经网络进行训练,并利用 GNU Radio 无线电平台制作 RML2016.10a 数据集。为了解决信号采集过程中产生的相位偏移, Zhang 等^[9]引入了参数估计器和参数转换器来改善相位偏移,提高了模型准确率。文献[10]将 CNN 与 RNN 进行组合,充分利用了模型对空间与时间特征的提取能力,识别结果进一步提升。MCLDNN^[11]在此基础上则考虑 IQ 多通道输入特征,使得识别率优于单通道输入的结果。Zhang 等^[12]提出了一种基于自适应小波分解网络(adaptive wavelet network, AWN-Net)来提取信号的频域特征。王华华团队^[13]更进一步,将 IQ 信号转化成时频图像,通过训练生成对抗网络(GAN)^[14]对信号进行降噪处理,提高了信号在低信噪比条件下的识别准确率,然而该方法在模型参数与计算复杂度上显著提高,且引入 GAN 导致模型的泛化能力差。

虽然目前在深度识别领域对 AMR 有大量研究,但这往往是基于普通的实值卷积,而当前数据集与通信信号的构建往往是基于复值 IQ 信号构建的,复值卷积网络可以直接处理相位与幅值信息,拥有比 CNN 更强大的性能。文献[15]提出使用二维卷积实现复值卷积网络(complex-valued convolutional neural network, C-CNN),实验证明,相比 CNN 拥有更高的识别率。文献[16]用 C-CNN 替换了 CNN,将 CLDNN 扩展到了复数架构,实现了复值计算。

因此,针对现有方法大多数通过实值卷积而忽略 IQ 信号中实部与虚部的关系^[15]且输入单一,网络深度低,无法对高阶 QAM 等复杂调制信号进行正确分类等现状,本文设计了一种基于自适应小波分解的多融合复值卷积密集连接神经网络(adaptive wavelet and multi-fusion complex-value dense convolutional neural networks, AW-MCDCN)。本文的主要贡献有:1)改进了 C-CNN,设计了复值交叉卷积网络(complex-valued cross-convolutional Network, C-CCN),并采用密集连接构建深层网络来充分提取 IQ 信号的时域特征。2)同时加入幅值相位信号(amplitude and phase, AP)形成异构特征互补,增强网络特征提取能力。3)为解决传统复值网络参数数量过大的问题,嵌入可学习小波分解层,引入频域特征提高识别率。

1 信号模型

无线通信系统包括发射段、传输信道与接收端、接收端

得到的经过采样的信号模型可以表示为:

$$y[n] = \sum_k a[k]h[n-k] + w[n] \quad (1)$$

其中, $a[n]$ 是经过脉冲信号采样后的发射端发射的调制信号, $h[n]$ 是等效离散信道响应, $\sum_k a[k]h[n-k]$ 表示发射序列 $a[k]$ 与离散冲击响应的 $h[n]$ 的离散卷积。 $w[n]$ 是噪声采样值。

在实际通信场景中,通常会把将信号转化为 IQ 分量进行存储, IQ 信号的频谱无需对称,仅需保留单边频谱,相比于实信号可以减少 50% 的存储与传输资源。接收信号 $y[n]$ 可表示为:

$$y[n] = I[n] + jQ[n] \quad (2)$$

其中, $I[n]$ 为同相分量,表示信号的实部; $Q[n]$ 为正交分量,表示信号的虚部。

在本文中,为了丰富神经网络所能提取的特征,同时减少复杂的信号提取工作,同时将 IQ 信号转化为幅值 $A[n]$ 和相位 $\phi(n)$ 一起输入,其表达式为:

$$A(n) = |y(n)| = \sqrt{I^2(n) + Q^2(n)} \quad (3)$$

$$\phi(n) = \arg(y(n)) = \arctan\left(\frac{Q(n)}{I(n)}\right) \quad (4)$$

2 基于卷积复运算的多融合神经网络

本节将介绍一种基于自适应小波多融合密集连接复值卷积网络模型,其整体结构如图 1 所示,网络主要由信号预处理模块(Part-A),特征提取模块(Part-B)与自适应小波分解模块(Part-C)组成。

2.1 信号预处理模块

在无线通信系统中,接收端所接收到的 IQ 信号容易受到传输信道的噪声和多径效应产生信号畸变,射频端的硬件条件也有可能引入额外的信号失真。因此,本文在网络的输入前加入相位参数估计器(parameter estimator, PET)^[9]以提取相位偏移相关信息并进行相位参数变换,从而提高模型识别准确率。

PET 模块示意图如图 2 所示,由 part1 的参数估计器和 part2 的参数转换器构成。

Part1 由展平(flatten)层和全连接(full connect-ed, FC)层组成, Flatten 层将 IQ 数据压平成一个向量, FC 层对向量中的数据进行关联输出一个携带相位偏移相关信息的参数 φ 。Part2 是一个自定义层:

$$\hat{Y}_{IQ} = Y_{IQ} e^{-j\varphi} = \begin{bmatrix} I \cos\varphi + Q \sin\varphi \\ Q \cos\varphi - I \sin\varphi \end{bmatrix} = \begin{bmatrix} \hat{I} \\ \hat{Q} \end{bmatrix} \quad (5)$$

此外,为了进一步丰富输入信号信息,减少信号特征提取工作, Part-A 还包括 AP 信号转换,其公式如式(3)、(4)所示。

2.2 特征提取模块

1) 基于复值卷积原理提出的复值交叉卷积

相比起传统的 CNN 无法直接处理这种复数信息,因

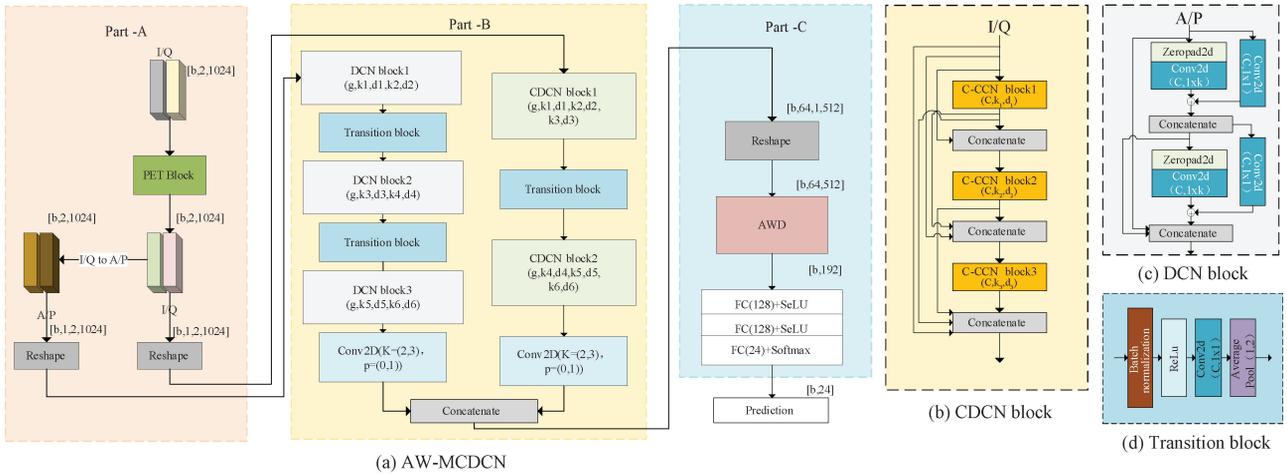


图1 本文提出的网络
Fig. 1 The network proposed in this paper

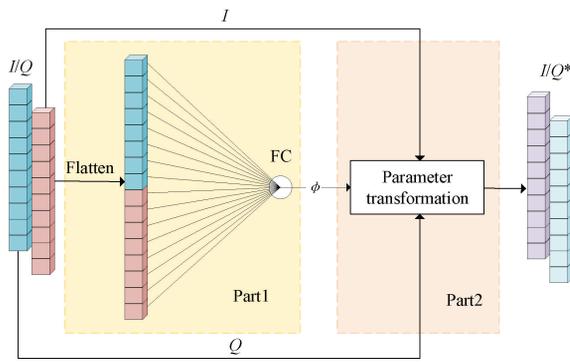


图2 PET模块示意图
Fig. 2 Architecture of the PET

为它们仅处理实数数据(即只考虑实部)。这会导致一些信息损失,尤其是在处理需要复数表示的信号时。因此,在无线通信、信号处理和图像处理等领域,C-CNN展现出了较传统方法更高的性能和潜力,常见的复值网络架构如图3(a)中C-CNN所示。

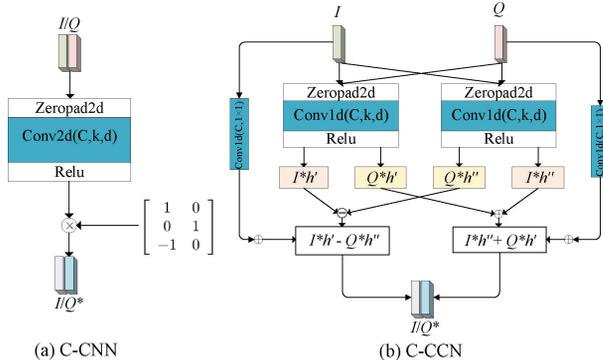


图3 复值网络架构

Fig. 3 Complex-valued network architecture

C-CNN^[15]利用实值卷积来计算复值卷积。对IQ序列 $Y[n] = [I[n], Q[n]]$ 和 $2d$ 卷积核 $h = [h', h'']$ 进行带复

数的卷积运算,可以得到:

$$X_{DL} = [I * h', I * h'' + Q * h'', Q * h''] \quad (6)$$

式中: $*$ 表示卷积运算, h' 和 h'' 为卷积核分量。

然而,序列 $Y[n]$ 与卷积核 h 的一维卷积运算为:

$$X = (I + jQ) * (h' + jh'') = (I * h' - Q * h'') + j(I * h'' + Q * h') \quad (7)$$

其中,对比式(6)和式(7),可以发现 X 是 X_{DL} 线性组合的结果:

$$X = X_{DL} \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ -1 & 0 \end{bmatrix} \quad (8)$$

对比传统的C-CNN需要使用二维卷积和矩阵乘法,运算量较大,本文如图3(b)设计的C-CCN通过两个一维卷积分别模拟二维卷积核中的 h' 和 h'' ,将输入拆成 I 和 Q ,与 h' 和 h'' 进行交叉相乘,经过加减运算后输出的结果与传统C-CNN在本质上是相通的,均为:

$$X = [I * h' - Q * h'', I * h'' + Q * h'] \quad (9)$$

C-CCN的优点是多重的:(1)在可解释性上,两个一维卷积后交叉相加相比于二维卷积后进行矩阵乘法更加直观,更符合复数卷积的表达方式。(2)通过两个一维卷积对二维卷积进行恒等映射,可以促使 h' 和 h'' 输出不同的特征,尽可能保留差异化信息,提高特征提取能力。

同时,在设计C-CCN时加入了 $1 * 1$ 卷积进行残差连接,保留信号的原始特征,为构造深层网络做了准备。

2)所提出的特征提取模块

输入的IQ数据经过相位估计和AP转换,分别将校正后的IQ数据和AP数据如图1所示输入不同的卷积通道进行特征提取。

图1(b)CDCN由3个本文提出的C-CCN进行密集连接构成,CDCN中的 g 表示生长率,表示每通过一次C-CCN会生成 g 个新的特征图,即令C-CCN的卷积通道数

$C = g$, 这些新特征图会与之前所有层的特征图拼接在一起。图 1(d) 的过渡块 (transition block) 由归一化 (batch normalization, BN) 层、ReLU 层、卷积和平均池化层组成。加入过渡块的目的是通过密集连接所得到的特征图计算量十分巨大, 通过卷积和平均池化, 可以减少通道与特征图大小。

在参数选择上 CDCN 的卷积核 k 设置为 $[3, 5, 7, 3, 5, 7]$, 即一层 CDCN 的卷积核尺寸为 $[1, 2, 3]$, 交替使用不同大小的卷积核尺寸, 使得模型在每一层 CDCN 中都能同时捕捉局部和全局信息, 以保持多尺度特征的平衡, 增强模型的表达能力和泛化能力。同时, 本文设置膨胀率 d 设置为锯齿状^[17] $[1, 2, 3, 1, 2, 3]$, 以此扩大感受野, 这样设置的好处有: (1) 保持分辨率的同时捕捉序列上下文信息, 更加适合于长序列任务; (2) 膨胀卷积的加入减少了计算资源开销。

对于通道数 C , 将其设置为 16, 初始 IQ 信号通过一层 CDCN 时, 通道数就会变为 $1 + 16 \times 3 = 49$, 因此在其中引入过渡块, 通过卷积运算将其通道数降为 24, 然后通过最大平均池化将特征图从 $[2, 1\ 024]$ 降为 $[2, 512]$ 。再通过 CDCN, 通道数变为 $24 + 16 \times 3 = 72$, 经过 $C = 48, k = (2, 3), p = (0, 1)$ 的 2 d 卷积, 最终得到 IQ 路的输出为

$[\text{batchsize}, 48, 1, 512]$ 。

不同于 CDCN, 图 1(c) 的 DCN 计划采用实值卷积网络进行特征提取, 以达到交叉互补的目的。DCN 在设计逻辑上与 CDCN 是相同的, 只是把复值卷积部分换成了 2 d 实值卷积, 不同的是, 本文将 DCN 设计为 $[2, 2, 2]$ 的三层结构, 目的是为了实现在 CDCN 不同的差异化提取。同时因为三层结构需要通过两个过渡块, 会使输出变为 $[\text{batchsize}, C, 1, 256]$, 与 IQ 路的特征图不匹配, 因此第二个过渡块不进行最大平均池化。此外设置 AP 路的生长率为 4, 最终 2 d 卷积的 $C = 16$, 其余均保持不变, 使得最终提取的特征 IQ 与 AP 占比为 3 : 1。

3) 自适应小波分解模块

即使通过引入过渡块, 最终得到的两路数据特征数据经过拼接为 $[\text{batchsize}, 64, 1, 512]$, 此时的参数量是相当巨大的, 而且直接展开会导致丢失一定的信息, 因此本文设计引入了自适应小波分解 (adaptive wavelet decomposition, AWD)^[12] 模块, 减少参数量的同时使得模型在复杂环境中表现出更强的特征表达能力。Part-C 的自适应小波分解模块如图 4 所示。

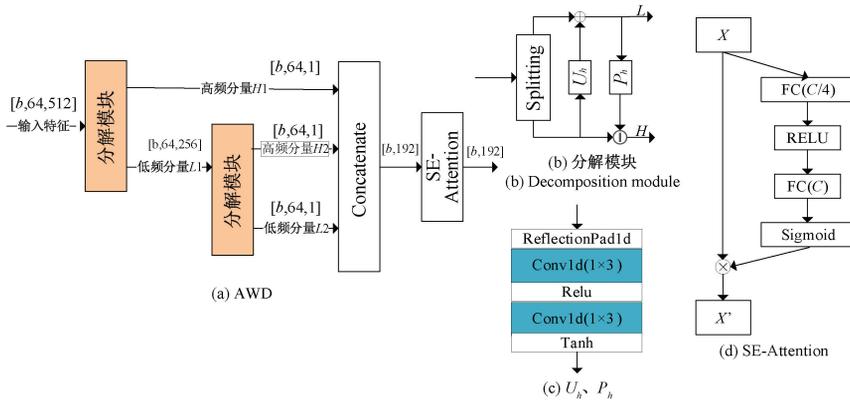


图 4 AWD 模块

Fig. 4 Architecture of the AWD

当特征图输入图 4(a) 中的分解模块时, 会将其特征进行拆分, 并通过多级分解获得不同频率子带的特征 (低频近似分量和高频细节分量), 最终将得到的序列拼接起来, 但不同频带对分类的贡献程度不同。本文通过嵌入 SE-Attention^[18] 网络能够自动学习不同频带特征的权重, 动态增强关键频带的特征响应, 抑制冗余或噪声较多的频带。

其中, 分解模块如图 4(b) 所示, 第一步是将给定输入特征图 $L^{(i)}$ 拆分为奇偶分量:

$$[L_o^{(i)}, L_e^{(i)}] = Split(L^{(i)}) \quad (10)$$

通过预测算子 $P(\cdot)$ 从 L_e 预测 L_o 。由于 L_e 和 L_o 是输入特征图通过拆分所得, 之间具有很强的相关性, 当使用 $P(L_e^{(i)})$ 来预测 L_o 时, 两者之间的差异便是高频细节 H , 这个过程可以表示为:

$$H^{(i+1)} = L_o^{(i)} - P(L_e^{(i)}) \quad (11)$$

式中: $H^{(i+1)}$ 表示生成的高频细节。

之后更新算子 $U(H)$ 通过给予高频细节更新偶分量 L_e , 生成更平滑的低频近似 L , 它可以表示为:

$$L^{(i+1)} = L_e^{(i)} + U(H^{(i+1)}) \quad (12)$$

式中: $L^{(i+1)}$ 表示生成的近似低频。

预测算子 $P(\cdot)$ 和更新算子 $U(\cdot)$ 可以提取局部特征并融合相邻时间步信息, 模拟小波分解的局部相关性; 其结构如图 4(c) 所示, 其结构由反射填充 (reflection padding), 两个 1×3 卷积, ReLU 和 Tanh 激活函数构成。

3 实验结果与性能分析

3.1 数据集与网络参数设计

实验采用表 1 所示的 RML2018.01a^[19] 数据集进行模

拟仿真,并按照6:2:2的比例分成训练集、验证集和测试集。相比常用的RML2016.10^[8]数据集,RML2018数据集新增了更多的调制方式与信道损失模型,覆盖了更多实际通信场景中的复杂信号,拥有更多的信号样本,更加符合当前自动调制识别的需求。

表1 RML2018.01a数据集的参数

Table 1 Parameters of RML2018.01a dataset

参数类别	具体参数
样本长度	IQ数据:2×1 024
样本数量	2 555 904
调制类型数量	24
信噪比范围/dB	-20:2:30
数据集格式	HDF5文件
信道效应	加性高斯白噪声、多径衰弱、载波频率偏移、采样时间偏移等

由于数据集较大,将批处理大小设置为512,初始学习率设置为0.001,采用Adam优化器进行训练。对权重参数进行L2正则化惩罚,权重衰减率为 1×10^{-7} ,偏置参数不进行正则化。训练周期(epoch)的上限为300,并使用早停机制,当验证集上的损失在7轮内没有下降时停止训练,同时采用余弦退火学习率调度器调整模型加快收敛,参数设置上 $T_{\max}=100$,最小学习率为 1×10^{-2} 。实验使用了Pytorch2.0.1和NVIDIA Cuda11.8深度学习框架,CPU为11代酷睿i9处理器,GPU为GeForce RTX 3090。本文损失函数如式(13)所示,式中第1部分是交叉熵损失,用于衡量模型预测概率分布与真实标签之间的差异,是分类任务的核心损失函数;第2部分为自适应小波分解的细节损失,用于约束高频分量(细节系数)的稀疏性,抑制噪声并提升分解质量;第3部分为自适应小波分解的均值损失,保持低频分量(近似系数)在不同分解层级间的一致

性,避免剧烈波动, λ_1 与 λ_2 均设置为0.01。

$$\mathcal{L} = - \sum_{i=1}^K y_i \log(\hat{y}_i) + \lambda_1 \sum_{j=0}^{T-1} |\hat{H}^{(j)}| + \lambda_2 \sum_{j=0}^{T-2} \|\bar{L}^{(j)} - \bar{L}^{(j+1)}\|_2 \quad (13)$$

3.2 不同网络模型的对比实验

本文选用了几种最先进前沿(state of the art,SOTA)模型来进行比较,包括CNN^[8],ResNet^[20],CLDNN^[10],C-CLDNN^[16],MCLDNN^[11],PET-CGDNN^[21],AWN-Net^[12]。

表2展示了各模型在数据集RML2018.01a上的平均识别率、最高识别率、模型参数、训练时间、验证集损失以及训练轮数。CNN作为AMR领域的经典模型在复杂的识别任务中表现出明显局限性,其浅层特征提取能力难以应对信号模式的多样性。CLDNN利用CNN的空间特征提取和LSTM的时序依赖性在建模上的互补能力提升了模型性能,相比之下,C-CLDNN通过加入复值运算,在参数量规模可控的情况下通过复数域运算显著提高了模型的准确率。ResNet通过多层的残差链接构建深度特征映射,证明了深层网络对特征提取的重要性。MCLDNN通过多域特征融合扩展了表征维度,但同时参数量与训练时间也显著增加,训练效率降低。PET-CGDNN对I/Q信号进行了参数估计与转换,在精度提升的同时实现参数压缩,展现出良好的计算-精度平衡。AWN-Net加入了自适应小波分解,有效捕捉信号的多尺度特征,使平均识别率提升0.99%。而本文提出的AW-MCDCN的模型通过多域特征协同与自适应小波增强,使平均识别率达到64.59%,相比其他模型提升了1.65%~18.91%,且最高识别率达到了98.39%,拥有最小的验证损失,虽然训练时间与收敛轮数并未达到最优,但是由于离线训练时间可通过分布式计算进行优化,不影响实时部署性能,且在保持精度优势的前提下,参数量比准确率次优的AWN-Net少了约28.67%,降低了线下部署的压力。

表2 所有模型在RML2018.01a上的性能比较

Table 2 Performance comparison of all models on RML2018.01a

模型	平均识别率/%	最高识别率/%	参数数量	训练时间(epoch/s)	验证集损失	训练轮数(epoch)
CNN	45.68	68.91	1 364 524	109.37	1.424 9	158
CLDNN	54.97	86.50	884 574	56.44	1.214 6	100
C-CLDNN	60.76	94.60	730 672	312.46	1.115 2	54
ResNet	60.95	97.16	148 600	136.20	1.205 3	42
MCLDNN	61.59	97.04	407 863	513.17	1.110 5	156
PET-CGDNN	61.95	96.28	97 142	258.31	1.131 6	78
AWN-Net	62.94	97.37	304 984	179.64	1.094 6	54
AW-MCDCN	64.59	98.39	217 559	333.99	1.041 7	103

图5展示了所有模型在不同信噪比下识别率曲线。CLDNN在SNR为-8 dB时识别准确率超过了CNN,从

图5中可以看出C-CLDNN的精度一直高于CLDNN,证明了复数特征的提取有利于提升模型准确率且拥有强大

的抗噪声性能,加入了多通道输入的 MCLDNN 在 SNR = 2 dB 时,精度超过了 C-CLDNN。虽然在 SNR 为 0 dB 时,各模型的识别率较低,然而,AW-MCDCN 仍能保持最高的准确率,相对其他模型依次提升 13.91%、9.38%、4.9%、7.19%、5.91%、4.89%、3.59%,并且随着信噪比的逐渐提高,尤其是信噪比位于 2~10 dB 的含有一定噪声干扰的条件下,AW-MCDCN 通过提取不同特征进行互补,能在一定噪声干扰的条件下,继续保持最优的性能,最快达到最优性能。

为了直观体现 AW-MCDCN 对易混淆信号的区分能力,图 6 展示了信噪比为 8 dB 时所有模型的混淆矩阵。图中纵坐标代表调制信号的真实类别,横坐标表示模型的预测类别,对角线上的方块颜色越深,就表示识别正确率越高。由图 6 可以看出,在 8 dB 时 AW-MCDCN 对常见易混淆信号最优最高的识别率,对 16PSK、32PSK、16APSK、128APSK、32QAM 都具有 100% 的识别率,且对于 64、128、256QAM 的平均识别率都在 90% 以上,且对比其他模型都出现了不同种类的信号出现混淆,AW-MCDCN 较好的解决了此问题,只出现了类内混淆。值得注意的是,所

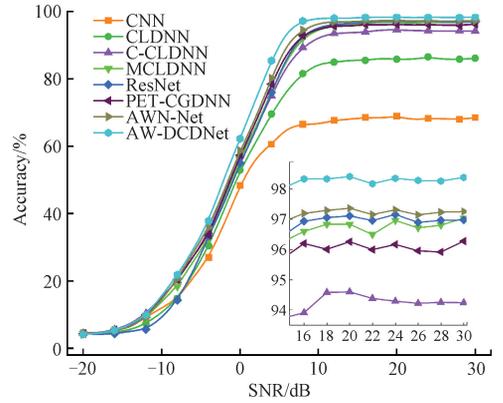


图 5 所有模型在 -20~30 dB 的性能比较

Fig. 5 Performance comparison of all models at -20 dB to 30 dB

有模型都一定程度上的把 AM-SSB-SC 识别成 AM-SSB-WC,这是由于两者均为单边带调制,在频谱上呈现相似的窄带特性,常见的机器学习方法无法检测载波功率占比,导致忽略两者差异,从而产生误判,这也是影响当前自动调制识别方法准确率更近一步的主要因素。

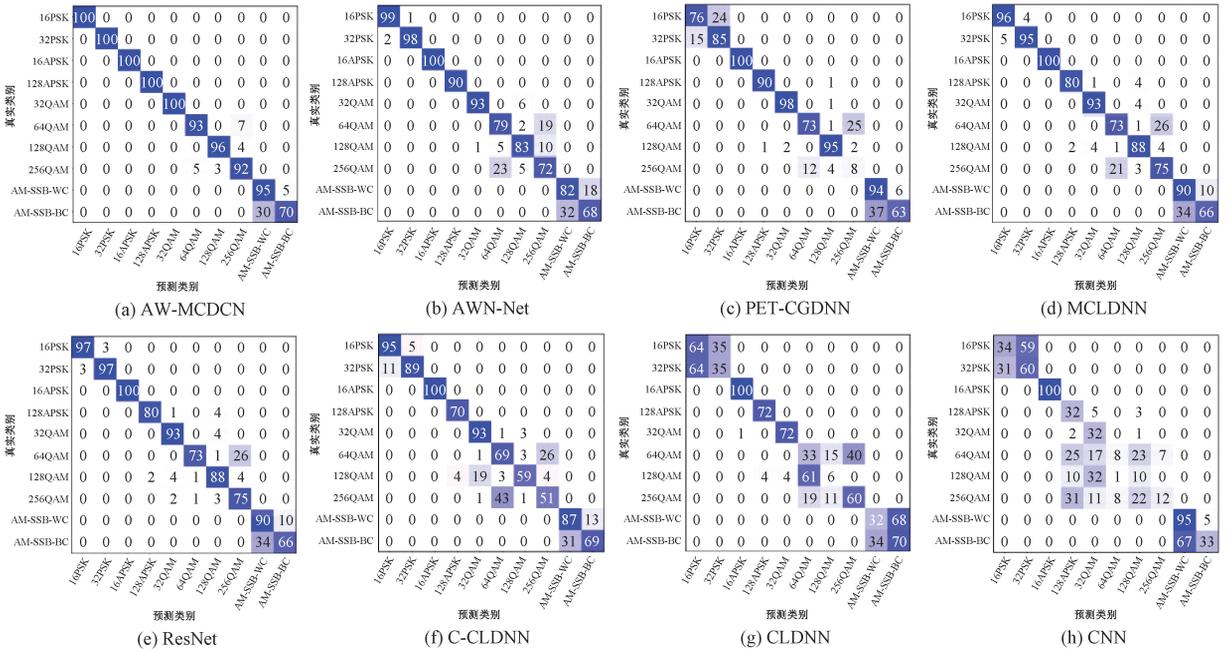


图 6 所有模型在 8 dB 时对易混淆信号的混淆矩阵

Fig. 6 Confusion matrices of all models for ambiguous signals at 8 dB

3.3 消融实验

为了评估模型中不同模块对模型整体性能的影响,本文设置 Model-A(去除 AP 输入与特征提取模块),Model-B(替换 C-CCN 为 C-CNN),Model-C(去除一层特征提取中的密集连接层),Model-D(去除自适应小波分解模块)。需要注意的是,Model-D 的原始架构在去除自适应小波分解模块后,参数量会增加到 4×10^6 ,实验室现有的计算资源

无法承载,因此会在后面再次接入一层 Transition Block 实现通道数缩减,在保留核心特征的同时维持模型可训练性。实验结果如表 3 所示。

Model-A 中删除了 AP 信号的输入及后续的特征处理部分,可以看出虽然识别率减少了 1.27%,但同时训练轮数也降低了一半,可以知道多种特征一同输入处理识别能够增强模型的特征提取能力,从而提高识别率,但同时会

表3 消融实验结果

Table 3 Ablation study results

模型	测试集 识别率/%	参数量	验证集 损失	训练 轮数
Model	64.59	217 559	1.041 7	103
Model-A	63.32	157 995	1.096 5	41
Δ	-1.27	-59 564	+0.054 8	-62
Model-B	64.13	212 951	1.042 8	103
Δ	-0.46	-4 608	+0.001 1	0
Model-C	63.89	181 779	1.062 9	103
Δ	-0.7	-35 780	+0.021 2	0
Model-D	62.22	1 126 519	0.989 9	103
Δ	-2.37	+908 960	-0.051 8	0

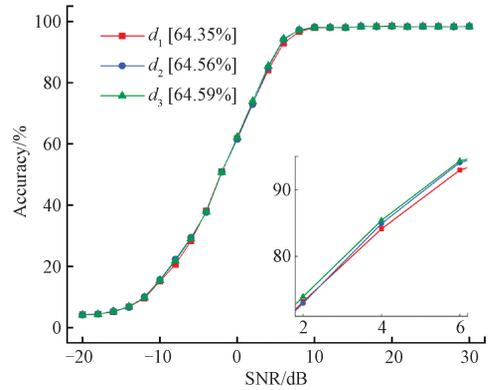
增加训练成本,在具体应用中需要进行权衡。精度下降最多的是 Model-D,删除了自适应小波分解模块后会导致输出序列的长度增加,极大地增加了参数量,从表格中可以看出,验证集的损失反而是在减小的,是因为输入序列的膨胀引发了线性层参数量激增,导致模型的复杂度激增,造成了严重的过拟合现象,从而导致损失减小的同时识别率在降低。Model-B 是将本文设计的 C-CCN 替换为正常的复值卷积 C-CNN,可以看出,C-CCN 在增加极少参数量的同时,使识别率提高 0.46%,证明了所提出模块的有效性,C-CCN 拥有更加强大的性能,其根本原因在于 C-CCN 通过两个一维卷积交叉组合,相比于 C-CNN 一个二维卷积进行线性相加更加灵活,更容易保留实部与虚部之间的差异性特征。

3.4 模型敏感性分析

图 7 展示了本论文模型对不同膨胀率以及损失函数系数敏感性程度。膨胀率为 $d_1 = [1, 1, 1, 1, 1, 1]$ (恒定值), $d_2 = [1, 2, 3, 2, 2, 2]$ ^[17], $d_3 = [1, 2, 3, 1, 2, 3]$, 权重系数 λ 选取了常见的 0.1~0.000 1。从图中可以看出,在权重系数的对比实验上 λ 设置为 0.01 达到了最佳性能,其中 $\lambda_1 = 0.1$ 精度最差,其结果可能是因为过大的权重系数使得高频正则项约束细节系数趋近于零,从而导致信号高频信息丢失。在膨胀率实验中,拥有锯齿状设计的 d_2, d_3 显著高于恒定值 d_1 ,也证明了采用恒定的膨胀率会使一定量的信息处于空洞位置,从而被忽略;虽然两者在高信噪比下结果基本没有区别,但 d_2 在低 SNR 识别精度略微高于 d_3 ,说明本文的设计更具稳定性。

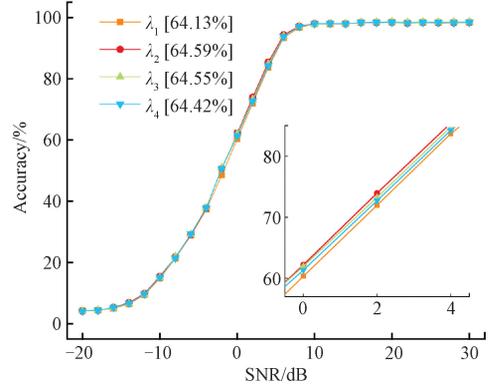
3.5 小波分解层数对模型的影响

不同层数的自适应小波对模型的影响如表 4 所示。 N 表示采用小波分解的层数,从表中可以看出,随着 N 的增加,验证集的损失也在不断下降, $N=1$ 时,测试识别率为 64.08%,而 $N=2$ 时,到达了 64.59%,说明随着 N 的增加,模型复杂度也在不断增加,模型可以更加充分的学习到信号的特征。 $N=3$ 时,虽然验证集损失依旧在下降,但



(a) 不同膨胀率对模型的影响

(a) The influence of different expansion rates on the model



(b) 不同权重系数对模型的影响

(b) The influence of different weight coefficients on the model

图7 敏感性实验结果

Fig. 7 Experimental results of sensitivity testing

是对于测试集识别率反而比 $N=2$ 低了,说明过高的层数分解使得模型的复杂度过高,使得模型对参数信号过于敏感,增加了对噪声的拟合,使得模型的识别率反而降低了,因此,在综合考虑下,本文最终选用两层自适应小波分解。

表4 不同层数自适应小波分解对模型的影响

Table 4 Impact of different wavelet decomposition levels on model performance

层数	测试集识别率/%	参数量	验证集损失
$N=1$	64.08	149 719	1.068 5
$N=2$	64.59	217 559	1.041 7
$N=3$	64.25	289 495	1.026 1

4 结论

本文提出了一种基于自适应小波分解与复值卷积的多融合密集连接神经网络,该模型将原始 IQ 信号通过 PET 模块进行相位修正,并将其转换为 AP 信号一同输入构建的双通道密集连接网络中进行特征提取,同时本文基于卷积复运算的原理,设计了一种全新的复值卷积网络 C-CCN,并运用于密集连接网络中,为解决常规复值网络参

数量过大的问题,通过嵌入自适应小波分解模块减少网络参数。仿真实验结果表明,本文提出的 C-CCN 相比于 C-CNN 在计算参数量提升不大的同时,能够在不同信噪比下提升调制信号识别准确率,尤其在低信噪比条件下的表现极为出色,且最高准确率达到 98.3%,同时消融实验证明提出的 C-CCN 比通用的 C-CNN 具有更强的信号表征能力。但是,该模型还是在一定程度上容易把 AM-SSB-SC 识别成 AM-SSB-WC,因此,在后续工作中考虑提高模型对载波抑制状态的敏感度的方法,尝试减少误判现象。

参考文献

- [1] WANG T G, YANG G S, CHEN P H, et al. A survey of applications of deep learning in radio signal modulation recognition [J]. *Applied Sciences-Basel*, 2022, 12(23):12052.
- [2] 张承琰,郑明魁,刘会明,等.一种基于类小波变换的无线电频谱监测数据无损压缩方法[J].*电子测量与仪器学报*,2024,38(7):152-158.
ZHANG CH Y, ZHENG M K, LIU H M, et al. Lossless compression method for radio spectrum data based on wavelet-like transform [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(7):152-158.
- [3] ZHANG D N, DING W R, ZHANG B CH, et al. Automatic modulation classification based on deep learning for unmanned aerial vehicles [J]. *Sensors*, 2018, 18(3):924.
- [4] ZHANG R Y, CHANG SH, WEI ZH Q, et al. Modulation classification of active attacks in internet of things: Lightweight MCBLDN with spatial transformer network [J]. *IEEE Internet of Things Journal*, 2022, 9(19): 19132-19146.
- [5] 郝顺义,李建文,卢航,等.基于 ML 估计的高动态 GNSS 信号快速捕获检测方法[J].*电子测量与仪器学报*,2024,38(8):87-94.
HAO SH Y, LI J W, LU H, et al. Fast detection method for high dynamic GNSS signal acquisition based on ML estimation [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(8): 87-94.
- [6] 吴云戈,张天骐,李春运,等.基于特征融合的 UFMC 系统调制识别算法[J].*电子测量技术*,2024,47(11): 51-58.
WU Y G, ZHANG T Q, LI CH Y, et al. Modulation and recognition algorithm of UFMC system based on feature fusion [J]. *Electronic Measurement Technology*, 2024,47(11):51-58.
- [7] 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.
- [8] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]. *International conference on engineering applications of neural networks*. Cham: Springer International Publishing, 2016: 213-226.
- [9] ZHANG F X, LUO CH B, XU J L, 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.
- [10] ZHANG Z F, LUO H, WANG CH, et al. Automatic modulation classification using CNN-LSTM based dual-stream structure [J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(11): 13521-13531.
- [11] XU J L, LUO CH 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.
- [12] ZHANG J W, WANG T T, FENG ZH X, et al. Toward the automatic modulation classification with adaptive wavelet network [J]. *IEEE Transactions on Cognitive Communications and Networking*, 2023, 9(3): 549-563.
- [13] 王华华,张睿哲,黄永洪.基于生成式对抗网络和多模态注意力机制的扩频与常规调制信号识别方法[J].*电子与信息学报*, 2024, 46(4): 1212-1221.
WANG H H, ZHANG R ZH, HUANG Y H. Spread spectrum and conventional modulation signal recognition method based on generative adversarial network and multimodal attention mechanism [J]. *Journal of Electronics & Information Technology*, 2024, 46(4): 1212-1221.
- [14] ZHOU T, LI Q, LU H L, et al. GAN review: Models and medical image fusion applications [J]. *Information Fusion*, 2023, 91: 134-148.
- [15] KRZYSTON J, BHATTACHARJEA R, STARK A. Complex-valued convolutions for modulation recognition using deep learning [C]. *2020 IEEE International Conference on Communications Workshops (ICC Workshops)*, 2020.
- [16] HE Z J, ZENG X D. Research on communication signal modulation recognition based on a CCLDNN [J]. *Electronics*, 2024, 13(9): 1604.

- [17] WANG P Q, CHEN P F, YUAN Y, et al. Understanding convolution for semantic segmentation[C]. 2018 IEEE winter conference on applications of computer vision(WACV), 2018: 1451-1460.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [19] 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.
- [20] LIU X Y, YANG D Y, GAMAL A E. Deep neural network architectures for modulation classification[C]. 2017 51st Asilomar Conference on Signals, Systems, and Computers. IEEE, 2017: 915-919.
- [21] 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 SH 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.

作者简介

刘浩, 硕士研究生, 主要研究方向为调制信号识别、深度学习。

E-mail: liuahao1@stu.ynu.edu.cn

鲁进(通信作者), 博士, 副教授, 主要研究方向为压缩感知、频谱感知、机器学习、随机共振。

E-mail: lujin211636@ynu.edu.cn

黎鹏, 博士, 高级实验师, 主要研究方向为电磁场、通信信号处理。

E-mail: 772504799@qq.com

李成星, 硕士研究生, 主要研究方向为轻量级网络自动调制识别。

E-mail: 1627754083@qq.com