

融合决策树和轻量化神经网络的调制识别方法^{*}

王伟 王浩哲 胡波 赵振禹 王俊珏

(郑州大学电气与信息工程学院 郑州 450001)

摘要: 针对现有决策树方法设置门限值对先验知识依赖大, 神经网络方法在调制识别领域存在的模型尺寸大, 参数量高的问题, 本文提出一种融合决策树的轻量化神经网络调制识别方法。该方法通过引入决策树思想, 对数据集的混淆矩阵进行分析, 根据不同的信号类别特征将数据集划分成了不同的子类, 并使用轻量化卷积神经网络进行分层识别; 为了在分层识别中对每个子类进行有针对性的识别, 通过数据清洗和特征提取来获取每个子类特有的信号特征。实验结果显示, 在公开数据集 RML2016.10a 上, 该方法在信噪比为 0~+18 dB 范围内的整体识别率为 90.03%, 相较对比模型最高提升了 7.49%, 当信噪比为 18 dB 时, 识别率达到 95.03%; 且模型参数量仅为 86 342, 与同精度模型相比降低了 96.85%。

关键词: 调制识别; 轻量化; 决策树; 卷积神经网络; 特征融合

中图分类号: TN911.3; TN911.7 文献标识码: A 国家标准学科分类代码: 510.50

Modulation recognition method integrating decision trees and lightweight neural networks

Wang Wei Wang Haozhe Hu Po Zhao Zhenyu Wang Junjue

(School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: Aiming at the problems that the existing decision tree methods rely heavily on prior knowledge in setting threshold values and the neural network methods in the field of communication signal recognition have large model sizes and high parameter counts, this paper proposes a lightweight neural network modulation recognition method integrating decision trees. This method introduces the idea of decision trees to analyze the confusion matrix of the dataset, divides the dataset into different subclasses based on the characteristics of different signal categories, and uses lightweight convolutional neural networks for hierarchical recognition. To achieve targeted recognition for each subclass in the hierarchical recognition process, data cleaning and feature extraction are employed to obtain the unique signal features of each subclass. Experimental results show that on the public dataset RML2016.10a, the overall recognition rate of this method reaches 90.03% within the signal-to-noise ratio range of 0 to +18 dB, which is 7.49% higher than the highest recognition rate of the comparison models. When the signal-to-noise ratio is 18 dB, the recognition rate reaches 95.03%; and the model parameter count is only 86 342, which is 96.85% lower than that of models with the same accuracy.

Keywords: modulation recognition; lightweight; decision tree; convolutional neural network; feature fusion

0 引言

在通信系统中, 信号由无线信道从发送端传至接收端, 这个过程需通过调制技术实现基带信号到带通信号的变换^[1]。而在无线通信与电磁频谱感知领域, 自动调制识别 (automatic modulation recognition, AMR) 技术更是扮演着重要角色, 在信号检测与解调之间发挥着关键作用, 其性能

直接影响到通信系统的可靠性和安全性^[2]。在民用领域, 尤其是在软件无线电系统中, AMR 技术可显著减轻通信系统负荷并提高频谱利用效率; 在军事领域, 其主要作用在于确保信号传输安全与接收可靠性, 同时具备对敌方信号的识别与干扰抑制功能, 为电磁对抗提供关键技术支撑^[3]。

传统的调制识别方法分为两类: 基于似然理论的调制识别^[4]和基于特征提取的调制识别方法^[5]; 基于似然理论

的调制识别方法依托概率论与假设检验理论,将调制识别问题转化为多重假设检验问题^[6],根据概率密度函数可能性最大的判决结果作为识别结果,但其过于依赖先验知识与参数估计;特征提取的目的是将复杂的信号数据转化为可以供分类器处理的数学表达形式,并依据这些特征构建分类逻辑以完成调制类型的辨识,然而这些特征往往仅对特定类型的信号具备较高的区分能力,当面临混合调制信号的识别挑战时,通常需结合多种特征并借助决策树等分类器实现综合识别,且人工设定的判决阈值在不同信噪比下泛化性较差。值得注意的是,决策树分类器的性能高度依赖于人工设定的判决阈值^[7],这些阈值的选取将直接影响最终的识别精度,且进行阈值的提取和划定非常消耗计算资源与时间,如果有新增的调制类型,还需重新设计特征和阈值。相较于传统的调制识别方法而言,神经网络方法可以从大量的数据中学习到特征,降低了对先验知识的依赖,无需手动划分判决阈值。

近年来,深度学习在语音处理与图像识别领域的突破性进展^[8],为无线网络信号调制识别研究提供了重要的理论支撑和技术思路。深度学习的调制识别方法大致可以划分为 3 个步骤:数据预处理、特征提取和信号分类。许多学者采用了更复杂的网络架构,并结合多种变换特征,有效提升了信号调制识别的准确率。陈发堂等^[9]提出一种时空卷积网络调制识别算法,借助信号空间结构,更全面提取其关键特征。彭钰琳等^[10]搭建了以卷积神经网络和门控循环单元为特征提取层的深层学习框架,提取信号的深层特征。Krzyston 等^[11]提出了一种线性组合网络,通过深度学习架构实现复杂卷积运算,并有效提取自然信号实部与虚部的特征。在较低信噪比下提高了识别准确率,但是网络过于复杂,其参数量大。然而,随着物联网与便携式设备的广泛应用,降低计算资源消耗的需求日益凸显。上述方法因对大量计算资源的依赖性,在资源受限场景中的应用受到显著制约。因此设计一种轻量化的低参数的神经网络调制识别方法就显得尤为重要。

在有关调制识别的方法中,对于神经网络轻量化方法的研究在近几年逐渐兴起。Zhang 等^[12]提出了一种用于调制识别的轻量化神经网络,该方法由信号参数估计器和参数转化器两部分组成,虽然网络参数量较小,但其网络层数较多。Dong 等^[13]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较好性能,但其对调制信号的特征表达能力随之减弱。崔天舒等^[14]提出了一种改进的卷积神经网络,该方法虽显著提高了计算效率,但基于二维卷积处理序列数据的方式会导致参数规模增大。在设计轻量化网络时,需要综合考虑减少模型大小、降低计算复杂度和提高计算效率等因素,使其适用于资源受限的场景。而现有的轻量化方法通过剪枝减少参数的同时,会大大降低对数据特征的提取能力;量化方法虽然能压缩模型尺寸,但是引入的量化噪声会导致梯度不稳定,影响网络的

识别结果。

综上,在现有的调制识别方法中,基于决策树的方法对信号的识别太过依赖于人工阈值的设定,基于深度学习的方法在参数量与模型性能之间难以实现理想的平衡。为解决上述问题,本文提出了一种融合决策树的神经网络调制识别方法(decision tree network, DTN),该方法通过将原始数据集根据不同的特点和区分度划分为不同的子类,创新地使用轻量化卷积神经网络代替传统决策树方法中人工提取的判决门限,再对不同的子类提取针对性的统计特征进行识别,以此来避免对先验知识的依赖,降低混合特征对模型识别准确率的影响。通过实验验证,所提方法可有效减少模型尺寸,降低模型复杂度,具有较好的稳定性的同时确保较高的识别准确率。

1 问题分析

在多分类任务中,本文通过引入级联思想,构建层次化决策框架,将整体分类问题解构为具有逻辑递进关系的多级子分类任务。在 RML2016.10a 数据集中,最容易混淆的几类信号是 AM-DSB 与 WBFM; MQAM 类信号与 MPSK 类信号^[15]。针对以上信号中易混淆的情况,进行具体分析。AM-DSB 和 WBFM 作为语音采集信号,在采集过程中存在静音时段。静音期内信号仅包含载波信息而无有效传输内容,导致模型难以提取特征,进而造成 WBFM 在静音阶段的识别准确率降低。MQAM 类信号通过同时调控相位与幅度信息实现调制,随着调制阶数的提升,信号密度增大,符号间距缩小,导致 QAM16 与 QAM64 的区分难度增加。MPSK 类信号则通过控制载波相位变化进行调制,随着调制阶数的增加,相位被等间隔划分得更细,当信号受到干扰时,8PSK 与 QPSK 的识别也面临挑战。而在 MQAM 与 MPSK 类信号之间,由于频域变换操作会使信号对应频谱比较相似,提取到的频率特征会进一步影响网络对 QAM16 与 8PSK 的分类效果。

为了验证上述分析,将原始数据集以 I/Q 信号的形式送入改进的四层卷积神经网络中^[16],混淆矩阵如图 1 所示,可以看出,AM-DSB 与 WBFM 存在着较严重的混淆,在 0 dB 以上 WBFM 识别率仅为 20%,与 AM-DSB 的混淆达到了 73%。而 QAM 类信号的混淆同样严重,QAM64 与 QAM16 的混淆达到了 53%,而两类 MQAM 信号与 8PSK 也存在着一定混淆。

根据上述分析,本文将原始数据集根据不同特征信息的差异性和分类难度分为 7 个子类:AM-DSB, WBFM 为一组; 8PSK, QPSK, 16QAM, 64QAM 为一组; BPSK、CPFSK、GFSK、PAM4、AM-SSB 五种信号各自为一组; 这样就将十一分类问题转化为了二级级联七分类问题,先得到第一层网络的分类结果,以此来减小不同子类之间错误分类的概率,然后再将第一层网络的结果分别送入第二层网络进行二分类与四分类,最终得到所有分类结果。

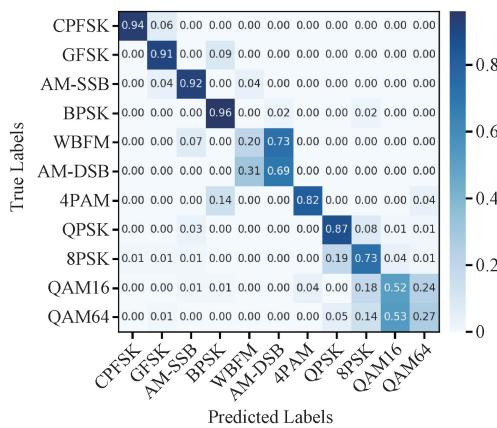


图 1 基于四层卷积神经网络的混淆矩阵

Fig. 1 Confusion matrix of a four-layer convolutional neural network

2 融合决策树的神经网络调制识别方法

2.1 数据预处理

本文所使用的开源数据集 RML2016.10a 包含了 3 种数字调制信号与 8 种模拟调制信号, 分别为 WBFM、AM-DSB、AM-SSB、BPSK、CPFSK、GFSK、4PAM、16QAM、64QAM、QPSK 和 8PSK。根据第 1 节的分析, 秉承着层级间的条件依赖关系, 将原始数据集分为 7 个子类。基于对各个子类中的信号特征提取简单、区分度较高的原则, 分析这 7 种不同子类调制方式的特点, 采取信号的 I/Q 原始数据作为第一级网络的输入, 幅度特征, 相位特征, 四次方谱特征, 归一化包络平方特征作为第二级网络的输入, 并使用信号的零中心归一化瞬时幅度谱密度的最大值特征来进行数据清洗。

本文针对 AM-DSB 与 WBFM 采取先数据清洗再特征提取的方法。AM-DSB 与 WBFM 之所以容易混淆^[17], 是因为采集过程中存在着静音期, 静音期信号因不携带有效信息且缺乏调制特征, 需予以剔除。针对非静音期的 WBFM(非恒包络调制信号), 其与静音期信号(恒包络)的包络特性存在显著差异。通过计算零中心归一化瞬时幅度谱密度的最大值^[18], 并设定阈值实现恒包络与非恒包络调制的分类判别。将该特征小于阈值的 WBFM 从原始数据集中去除, 大于阈值的则保留。具体过程如下, 设 N 为信号取样点数, $a_{cn}(n)$ 为零中心归一化瞬时幅度, 定义零中心归一化瞬时幅度谱密度的最大值 γ_{\max} 为:

$$\gamma_{\max} = \frac{\max | \text{FFT} [a_{cn}(n)]^2 |}{N} \quad (1)$$

通过数据清洗去除掉了一部分原始信号, 为使每种信号送入网络的维度保持一致, 要进行数据增强。数据增强的方法为旋转增强^[19], 本文采用的 I/Q 信号旋转变换增强方法, 通过酉变换群扩展样本空间对称性, 有效模拟了实际通信中的相位偏移与极性反转场景。对 WBFM 与 AM-DSB, 旋转变换数据增强可模拟相位偏移等场景, 扩充样

本, 助模型学习相位不变特征, 提升鲁棒性与泛化能力。具体过程如下, 原始数据集的信号形式为 I/Q 信号, 可表示为复基带信号 $s(t) = I(t) + jQ(t)$ 。

其中, $I(t)$ 和 $Q(t)$ 分别为同相和正交分量。旋转增强通过复指数因子 $e^{j\theta}$ 对信号进行相位旋转, 生成新样本:

$$s_{\theta}(t) = [I(t)\cos\theta - Q(t)\sin\theta] + j[I(t)\sin\theta + Q(t)\cos\theta] \quad (2)$$

在数据清洗后, 采用幅度相位特征区分 AM-DSB 与 WBFM。AM-DSB 幅度随调制信号变化, 相位恒定; WBFM 幅度恒定、相位含调制信息, 特征差异显著易区分。在实际通信环境中, 信号会受到噪声、衰落等干扰的影响, 但幅度和相位的相对关系在一定程度上能够保持稳定, 其表达式为:

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

$$\varphi(t) = \tan^{-1} \left(\frac{Q(t)}{I(t)} \right) \quad (4)$$

8PSK 和 QPSK 的区分难点源于调制阶数与抗噪能力的内在矛盾。8PSK 通过增加相位状态提高了频谱效率, 但牺牲了抗噪性能和解调鲁棒性, 在噪声、多径干扰条件下, 8PSK 的相位密集性导致其信号特征模糊化, 与 QPSK 的区分边界变得不清晰。使用四次方谱 $P_4(f)$ 特征来对 8PSK 与 QPSK 进行区分。四次方谱, 即信号四次方后的功率谱, 通过四阶累积量的傅里叶变换得到, 其表达式为式(5), 它能够捕捉信号的高阶统计特性, 尤其是非高斯和非线性成分。

$$P_4(f) = \text{FFT} \{ E[s^4(t)] \} \quad (5)$$

16QAM 和 64QAM 本质区别在于单个复符号携带的比特信息, 前者 4 比特, 后者 6 比特。在 RML2016.10a 这样信道复杂、噪声严重, 且样本采样点少、符号数少的数据集里, 二者极易混淆。各阶 QAM 信号幅度分布有差异, 归一化包络平方特征能捕捉这一特性。16QAM 星座图点数少, 幅度取值种类相对少, 归一化包络平方分布集中在少数几个值附近。64QAM 星座图点数多, 幅度取值更丰富, 归一化包络平方分布更分散, 所以利用该特征能有效区分这两种信号。归一化包络平方特征 R 表达式如式(6)所示。

$$R(n) = \frac{A^2(n)}{\frac{1}{N} \sum_{k=1}^N A^2(k)}, 0 < n \leq N \quad (6)$$

其中, $A(n)$ 为信号第 n 个采样点的幅度, $A(k)$ 为第 k 个采样点的幅度(k 为求和运算中遍历的采样点序号)。

值得说明的是, 四次方谱特征和归一化包络平方特征在提取后, 两种特征计算的结果并不在同一数量级, 为保证网络的权重更新不受到影响, 提高模型的识别率和鲁棒性, 通过标准化方法^[20]将两种特征改为同一数量级后, 再将两种特征融合后作为网络的输入。数据标准化的流程如下:

- 1) 对于给定数据集中的每个特征, 计算其均值 μ 。
- 2) 计算每个特征的标准差 σ 。

3) 将每个特征的值减去其均值, 再除以该特征的标准差, 使得缩放后的数据均值为 0, 标准差为 1, 得到数据标准化后的新数据 X_{std} 。其计算过程如式(7)所示。

$$X_{std} = \frac{X - \mu}{\sigma} \quad (7)$$

2.2 网络结构

本文所提出的 DTN 方法的结构由两层轻量化卷积神经网络组成, 第一层网络进行七分类的输入是原始 I/Q 信号, 第二层网络二分类的输入是幅度和相位特征, 四分类的输入是四次方谱和归一化包络平方特征。通过 1×8 的卷积核提取局部特征, 2×8 的卷积核捕捉特征之间的相关性, 再通过最大池化层降维, 使模型对输入的小平移不敏感, 增强鲁棒性, 且保留最显著的特征。最后由 FC 层和 Softmax 层完成分类。每一层所使用的网络结构如图 2 所示。

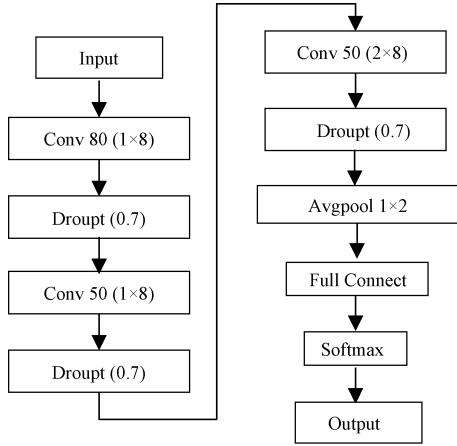


图 2 网络结构

Fig. 2 Network structure

在最大池化层后引入批量归一化(BN)以加速模型收敛并提升精度。为保持 BN 层的自归一化特性, 在 BN 层后添加 Alpha-dropout 层, 并与 SeLU 激活函数结合使用, 确保输入的均值和方差保持稳定, 从而防止过拟合并维持衰减层的自归一化特性。最终通过 Softmax 激活函数将预测结果转换为概率输出。网络参数设置如表 1 所示。

3 实验与分析

3.1 数据集

为验证本文所提方法的有效性, 在开源数据集 RML2016.10a 上进行实验验证。该数据集由 11 种信号调制方式组成, 每种调制方式在每个信噪比下均有 1 000 条信号。数据分为 I、Q 两路, 每一路有 128 个采样点, 数据维度为 $[2, 128]$ 。所用训练样本数为每种调制方式每个信噪比下取 600 个信号, 所用验证、测试样本数为每种调制方式每个信噪比下取 200 个信号, 信噪比范围为 $0 \sim +18$ dB。

3.2 超参数实验

为了设计 DTN 网络的最优结构和网络参数, 本实验

表 1 网络参数设置

Table 1 Network parameter settings

网络层	激活函数	填充	步长	输出维度
Input	无	无	无	$[2, 128]$
Conv2d-1	Relu	Same	1	$[-1, 80, 2, 128]$
Dropout-2	无	无	无	$[-1, 80, 2, 128]$
Conv2d-3	Relu	Valid	1	$[-1, 50, 1, 121]$
Dropout-4	无	无	无	$[-1, 50, 1, 121]$
Conv2d-5	Relu	Valid	1	$[-1, 50, 1, 114]$
Dropout-6	无	无	无	$[-1, 50, 1, 114]$
AvgPool2d-7	Relu	无	1	$[-1, 50, 1, 60]$
Linear-8	Relu	无	无	$[-1, \text{classes}]$
Soft-max	Soft-max	无	无	$[-1, \text{classes}]$

讨论了不同卷积层数、不同学习率、不同批次大小对网络识别性能的影响, 其中新增卷积核的数量与尺寸均固定为 50 和 1×8 。实验结果如表 2 所示, 由表 2 可知: 当采用两层卷积时, 模型在保持较低复杂度的同时实现了较高的识别准确率; 增至 3 层后, 性能达到最优且复杂度仍维持较低水平; 然而继续增加至 4 层时, 网络性能出现下降。这表明 3 层卷积结构能够有效提取调制信号的深层特征, 而进一步增加层数可能导致冗余特征的引入, 从而影响模型性能。故实验中卷积层数选取 3 层。而在学习率为 0.000 1 时, 模型识别性能达到最优。此外, 通过网格搜索参数优化策略, 确定采用训练的批次大小为 32。

网络使用 Adam 优化器, Cross-Entropy 损失函数。初始 epoch 设置为 80 轮, 若验证损失函数在 5 个 epoch 内没有改善, 则使用 Reduce 回调函数以减小学习率的大小; 若学习率在 10 个 epoch 内没有提高, 则使用 Earlystopping 回调函数停止训练, 保存验证损失最小的模型。深度学习环境配置: Python3.0, Pytorch3.7。

表 2 不同超参数对实验结果的影响

Table 2 The impact of different hyperparameters on experimental results

超参数	设置	识别率/%	模型参数量
学习率	0.001	90.03	86 342
	0.000 5	89.45	
	0.000 1	88.67	
批次大小	32	90.03	86 342
	64	90.01	
	128	89.23	
卷积层数	2	89.89	52 504
	3	90.03	86 342
	4	90.01	118 324

不同学习率对 DTN 方法的分类网络收敛速度的影响

如图 3 所示,由图 3 可知,在学习率为 0.000 1 时,曲线下降极缓,前期损失高且下降慢,因步长过小,模型参数更新迟缓,收敛进程拖沓;学习率为 0.000 5 时,下降速率优于 0.000 1,但对比 0.001 仍偏慢,参数更新步长有限,收敛效率待提升;学习率为 0.001 时,初始阶段损失快速下降,前期收敛迅猛,能让模型参数快速逼近较优区域,且最终损失函数值最小,故选择学习率为 0.001。

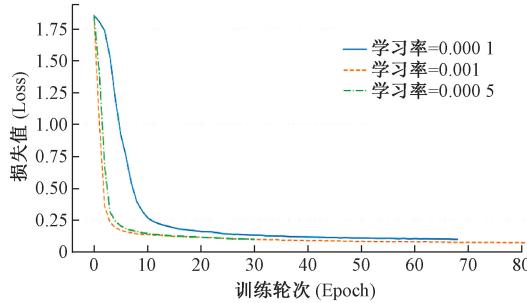


图 3 DTN 方法的损失函数曲线

Fig. 3 Loss function curve of the DTN method

3.3 本文所提 DTN 方法与基于特征融合的神经网络方法对实验性能的影响

本实验对比了融合决策树的神经网络方法和基于特征融合的神经网络方法。先按比例划分数据集,再对 WBFM 进行数据清洗与数据增强,提取 11 种信号的幅度特征、相位特征、四次方谱特征和归一化包络平方特征,将四种特征按维度融合^[21],输入本文所使用的轻量化卷积神经网络,实验结果如图 4 所示。

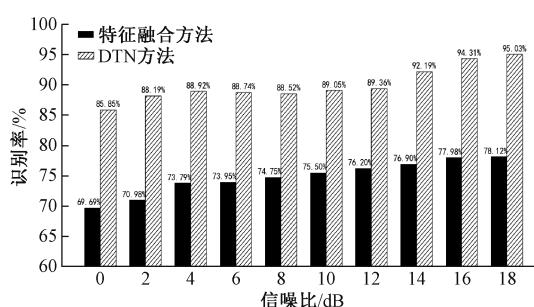


图 4 DTN 方法与特征融合方法的对比

Fig. 4 Comparison between the DTN method and the feature fusion method

可以看出,融合决策树的神经网络方法比特征融合方法在所有信噪比上的分类效果都要好,整体平均识别率高 15%。这是因为原始数据集中包含大量复杂的特征,直接进行多分类时,模型需要在高维且复杂的特征空间中寻找各类别之间的决策边界,而将数据集划分成小类后,每个小类所涉及的特征空间相对简单,模型在较小的特征子空间中更容易找到合适的决策边界,从而降低了分类的难度。

3.4 DTN 方法的统计显著性实验

为评估模型稳定性,本研究进行了 6 组独立重复实验,

每次使用不同随机种子初始化模型,并在相同测试集上评估准确率,通过 t 检验比较了不同重复实验间的性能差异。实验结果如表 3 所示。

表 3 各组之间的成对 t 检验结果

Table 3 Pairwise t-test results among groups

对照组 1	对照组 2	t 统计量	显著性水平
1	2	0.244 9	0.809 2
1	3	0.064 8	0.948 9
1	4	-0.079 6	0.937 3
1	5	-0.033 2	0.973 8
1	6	-0.239 3	0.813 5
2	3	-0.167 7	0.868 6
2	4	-0.316 9	0.754 9
2	5	-0.267 3	0.792 2
2	6	-0.456 3	0.653 6
3	4	-0.138 3	0.891 4
3	5	-0.093 7	0.926 3
3	6	-0.285 8	0.778 2
4	5	0.043 6	0.965 6
4	6	-0.162 2	0.872 8
5	6	-0.199 9	0.843 7

t 检验证了各组之间的差异不显著(每一组的显著性水平 p 都大于 0.05),说明网络的性能具有一致性。这些结果表明,该网络对实验条件的变化具有较好的鲁棒性,为后续应用提供了可靠的基础。

3.5 DTN 方法中信号混淆情况

为了验证本文方法对不同调制类型的调制识别情况,如图 5、6 所示,给出了不同 SNR 下 DTN 方法的混淆矩阵。信噪比为 0 dB 以上的整体识别率,QAM16 的识别率为 87%,与 QAM64 的混淆率为 11%。QPSK 与 8PSK 的识别率较好,达到了 96%。这是因为通过这种分阶段精细化的分类策略,模型可以避免传统平级多分类问题因类别混淆导致的决策模糊性。在信噪比为 +18 dB 的情况下,WBFM 与 AM-DSB 的识别率达到了 99%,这是因为这两种信号受噪声影响严重,在高信噪比下识别率会有很大提升。且由于采用了分层识别的方法,其他几种信号的区分度很好,基本没有发生混淆。

3.6 不同方法的对比实验

通过在 RadioML2016.10a 数据集上的实验结果评价提出的方法,将所提方法与 Complex^[11]、PETCGDNN^[12]、DSN^[22]与 CLDNN^[23]这 4 种方法进行比较,其实验结果如图 7 所示。在信噪比在 0~12 dB 范围内,所提方法的准确率比 CLDNN 方法和 DSN 方法的准确率高约 7%,在 12~18 dB 范围内,比这两种方法准确率高约 10%;与 PETCGDNN 方法相比,在 12 dB 以上本文所提方法具有

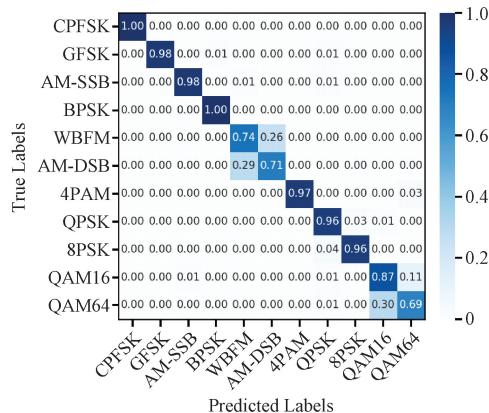


图 5 DTN 方法在 0~18 dB 下的混淆矩阵

Fig. 5 The confusion matrix of the DTN method at 0~18 dB

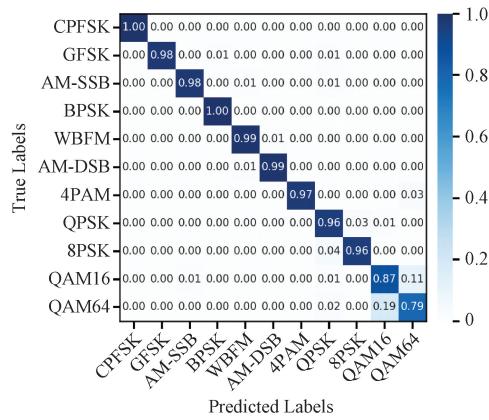


图 6 DTN 方法在 +18 dB 下的混淆矩阵

Fig. 6 The confusion matrix of the DTN method at +18 dB

较高的准确率。在信噪比为 18 dB 时,本方法准确率达到了 95.03%,这是因为通过将数据集划分为不同的子类,模型可以针对每个子类的特点进行专门的学习。且将数据集分类后,可以对每个分类模型进行并行训练,提高训练效率。

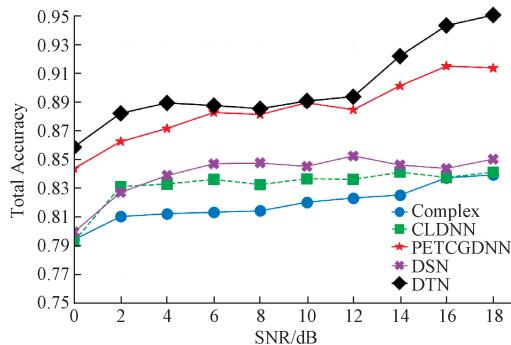


图 7 不同方法结果对比

Fig. 7 Comparison of results from different methods

为了能更直观地展现模型复杂度,本文从参数量和模型尺寸两个维度出发,对模型的复杂度进行分析。各个方

法所用网络模型的模型尺寸和参数量如表 4 所示。

表 4 各个网络模型复杂度与准确率

Table 4 Complexity and accuracy of each network model

模型	模型尺寸/ M	参数量	准确率/%	
			0~18 dB	10 dB
Complex	10.48	2 749 275	82.54	82.10
DSN	0.56	147 443	83.89	84.50
CLDNN	1.80	471 397	83.06	83.64
PETCGDNN	0.27	71 871	88.44	89.04
DTN	0.49	86 342	90.03	89.05

从实验结果来看,DTN 方法在模型尺寸与参数量方面展现出独特优势。在信噪比为 0~18 dB 范围内,其平均准确率相比于 Complex 方法高 7.49%,相比于 DSN 方法高 6.14%,相比于 CLDNN 方法高 6.97%,且模型尺寸与参数量远低于这些网络。PETCGDNN 方法虽然在复杂度上略低于本文所提出的轻量化卷积神经网络,但是识别率降低了 1.59%,其原因是该方法采用的剪枝算法在降低计算开销时,会去除部分权重参数和网络结构,致使模型可学习和存储的信息减少,对调制信号多种细微特征变化规律的捕捉能力下降。而本文所提出的轻量化卷积神经网络层数少,通过分层识别的方法降低了运算复杂度,又兼顾了对信号的识别率,在调制识别任务中具有良好的性能。

4 结 论

本文针对现有决策树识别方法对信号先验知识依赖较大,且大部分神经网络调制识别方法网络复杂度高的问题,提出了一种融合决策树的神经网络调制识别方法。该方法通过引入级联思想,先将数据集中的信号根据不同特征划分为不同的子类,再通过使用轻量化卷积神经网络来代替决策树的判决阈值,并且使用数据清洗与特征提取的方法获取更多维度的数据信息。在开源数据集上验证本方法,在 0~18 dB 范围内的识别率达到 90.03%,高信噪比 +18 dB 下识别率达到 95.03%,且模型参数量较少,具有一定的现实价值,可将其应用于移动设备和物联网通信中。下一步的工作拟将该方法用于小样本情况下的通信信号调制识别。

参考文献

- [1] MAO Q, HE F, QI H. Deep learning for intelligent wireless networks: A comprehensive survey[J]. IEEE Communications Surveys & Tutorials, 2018, 20(4): 2595-2621.
- [2] ZHOU R L, LIU F G, GRAVELLE C W. Deep learning for modulation recognition: A survey with a demonstration[J]. IEEE Access, 2020, 8: 67366-67376.
- [3] 钱磊,吴昊,乔晓强,等.基于特征融合的调制识别增强

- 与迁移演化[J]. 电子测量技术, 2022, 45(18): 153-160.
- QIAN L, WU H, QIAO X Q, et al. Enhanced modulation recognition and migration evolution based on feature fusion [J]. Electronic Measurement Technology, 2022, 45(18): 153-160.
- [4] ZHANG C Y, PARTAS P, HADDADI H. Deep learning in mobile and wireless networking: A survey[J]. IEEE Communications Surveys & Tutorials, 2018, 21(3): 2224-2287.
- [5] GOULDIEFF V, PALICOT J, DAUMONT S. Blind modulation classification for cognitive satellite in the spectral coexistence context[J]. IEEE Transactions on Signal Processing: A publication of the IEEE Signal Processing Society, 2017, 65(12): 3204-3217.
- [6] 秦子杰. 基于机器学习的通信信号调制识别方法研究[D]. 北京: 北京交通大学, 2021.
- QIN Z J. Research on modulation recognition methods of communication signals based on machine learning [D]. Beijing: Beijing Jiaotong University, 2021.
- [7] 刘鹏飞, 克兢, 王雪, 等. 一种基于高阶累积量和谱特征结合的卫星信号调制识别方法[J]. 时间频率学报, 2023, 46(1): 320-332.
- LIU P F, KE J, WANG X, et al. A satellite signal modulation recognition method combining higher-order cumulants and spectral features [J]. Time and Frequency Science, 2023, 46(1): 320-332.
- [8] 曹洁, 刘锦辉, 宋蓓蓓. 一种轻量化的 IQ 路信号调制方式识别方法[J]. 无线通信技术, 2024, 33(3): 18-23.
- CAO J, LIU J H, SONG B B. A lightweight method for modulation recognition of IQ signals[J]. Wireless Communication Technology, 2024, 33(3): 18-23.
- [9] 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.
- CHEN F T, LIU Z, FAN Z J. Communication signal modulation recognition based on spatiotemporal convolutional network [J]. Telecommunication Engineering, 2025, 65(4): 518-524.
- [10] 彭钰琳, 文红, 侯文静, 等. 深层卷积神经网络的自动调制识别方法[J]. 通信技术, 2023, 56(6): 714-718.
- PENG Y L, WEN H, HOU W J, et al. Automatic modulation recognition method based on deep convolutional neural network [J]. Communication Technology, 2023, 56(6): 714-718.
- [11] KRZYSTON J, BHATTACHARJEE R, STARK A. Complex-valued convolutions for modulation recognition using deep learning [C]. 2020 IEEE International Conference on Communications Workshops. Dublin: IEEE, 2020: 1-6.
- [12] ZHANG F X, LUO C 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.
- [13] 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.
- [14] 崔天舒, 崔凯, 黄永辉, 等. 卷积神经网络卫星信号自动调制识别算法[J]. 北京航空航天大学学报, 2022, 48(6): 986-994.
- CUI T SH, CUI K, HUANG Y H, et al. Convolutional neural network based algorithm for automatic modulation recognition of satellite signals [J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48(6): 986-994.
- [15] 黄杰, 张顺生, 陈爽. 基于深度学习网络融合的自动调制分类方法[J]. 信号处理, 2023, 39(1): 42-50.
- HUANG J, ZHANG SH SH, CHEN SH. Automatic modulation classification method based on deep learning network fusion[J]. Signal Processing, 2023, 39(1): 42-50.
- [16] 邵敏兰, 周鸿渐, 张浩然. 基于卷积神经网络的调制信号识别算法[J]. 实验室研究与探索, 2021, 40(8): 28-31, 41.
- SHAO M L, ZHOU H J, ZHANG H R. Modulation signal recognition algorithm based on convolutional neural network [J]. Research and Exploration in Laboratory, 2021, 40(8): 28-31, 41.
- [17] 李辉, 龚晓峰, 雍瑞森. 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.
- LI H, GONG X F, LUO R S. A deep learning modulation recognition algorithm based on Time-Frequency fusion[J]. Telecommunication Engineering, 2024, 64(1): 22-28.
- [18] 占锦敏, 赵知劲. 常规调制信号与扩频信号的调制识别算法[J]. 信号处理, 2020, 36(4): 511-519.
- ZHAN J M, ZHAO ZH J. Modulation recognition algorithm for conventional modulated signals and spread spectrum signals[J]. Signal Processing, 2020, 36(4): 511-519.
- [19] 孙久淞. 基于数据增强与深度学习网络的调制识别算法研究[D]. 南京: 南京信息工程大学, 2024.
- SUN J S. Research on modulation recognition algorithm based on data augmentation and deep network [D]. Nanjing: Nanjing University of

Information Science and Technology, 2024.

- [20] 杨颖. 标准化数据模型在机器学习中的应用研究[J]. 中国标准化, 2025(6): 39-41.
YANG Y. Research on the application of standardized data models in machine learning [J]. China Standardization, 2025(6): 39-41.

- [21] 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 recognition algorithm for UFMC system based on feature fusion[J]. Electronic Measurement Technology, 2024, 47(11): 51-58.

- [22] TU Y, LIN Y, HOU CH B, et al. Complex-Valued networks for automatic modelation classification[J]. IEEE Transactions on Vehicular Technology, 2020, 69(9): 10085-10089.

- [23] 张军, 符杰林, 林基明. 基于 CLDNN 的调制信号识别方法[J]. 计算机应用与软件, 2021, 38(10): 216-

220,277.

ZHANG J, FU J L, LIN J M. Modulation signal recognition method based on CLDNN[J]. Computer Applications and Software, 2021, 38 (10): 216-220,277.

作者简介

王玮(通信作者), 副教授, 主要研究方向为无线通信、信号处理等。

E-mail: iewwang@zzu.edu.cn

王浩哲, 硕士研究生, 主要研究方向为信号调制识别。

E-mail: 844572159@qq.com

胡坡, 博士研究生, 主要研究方向为通信信号智能分析与处理。

E-mail: hupo@hafu.edu.cn

赵振禹, 博士研究生, 主要研究方向为语义通信、图像处理、智慧交通等方向。

E-mail: zhenyuzhao@gs.zzu.edu.cn

王俊珏, 研究员, 主要研究方向为边缘计算。

E-mail: junjuewang01@gmail.com