

利用调制参数时频结构差异及分层神经网络的通信信号调制格式识别算法

王中方^{1,2}, 仇昭花^{1,2}, 禹成亮^{1,2}, 魏冬², 黄伟庆²

¹中国科学院大学 网络空间安全学院 北京 中国 100049

²中国科学院信息工程研究所 北京 中国 100093

摘要 无线通信的侦测和监管通常是在未知对方通信方式的场景下进行的, 而其中调制格式的识别是首要解决的问题。然而, 由于实际信号接收环境的复杂性以及不确定性, 同一种类型信号的统计特征可能会发生变化, 导致传统调制识别算法对表征不同类型信号特征的统计参数敏感, 识别分类的效果下降。随着深度学习在信号处理领域的应用, 基于卷积神经网络的自动调制识别算法成为当前研究热点。针对通信信号调制格式的自动识别问题, 本文利用分层卷积神经网络学习不同调制格式信号的时频结构差异, 并利用该差异实现对通信信号调制格式的准确识别。该方法结合了信号特征提取方法及深度学习识别方法的优势, 通过提取信号样本瞬时幅值、瞬时频率及瞬时相位等调制参数, 降低样本中对调制格式识别无用的冗余信息, 并构造各调制参数的时频结构图像; 然后针对不同调制参数时频结构图像, 构造专用的卷积神经网络对图像中独特的时频结构进行学习识别; 最后, 设计了分层神经网络架构级联各专用卷积神经网络, 对调制格式进行准确判决。本文共实现了 11 种通信信号的自动识别, 该方法可有效克服噪声、频偏干扰及接收误差等不利因素, 具有较高的鲁棒性和自动性。实验结果表明, 该方法在信噪比大小为 12dB 且存在干扰和频偏时, 可对 2ASK、2FSK、4FSK、BPSK、QPSK、8PSK、16QAM、32QAM、64QAM、AM、FM 信号进行调制格式自动识别, 单项识别准确率超过 80%, 优于同等条件下基于传统信号特征提取的调制格式识别方法以及基于深度学习的调制格式识别方法。

关键词 调制识别; 信号处理; 图像分类; 卷积神经网络; 分层卷积神经网络

中图分类号 TN911 DOI号: DOI号 10.19363/J.cnki.cn10-1380/tn.2025.09.15

Modulation Recognition Algorithm Based on Time-Frequency Structure Differences of Modulation Parameters and Hierarchical Neural Network

WANG Zhongfang^{1,2}, QIU Zhaohua^{1,2}, YU Chengliang^{1,2}, WEI Dong², HUANG Weiqing²

¹School of Cyber Security, University of Chinese Academy of Sciences, Beijing 100049, China

²Institute of Information Engineering, Chinese Academy of Sciences, Beijing 100093, China

Abstract The detection and supervision of wireless communication is usually carried out in the scene of unknown communication mode, and the recognition of modulation is the first problem to be solved. However, due to the complexity and uncertainty of the actual signal receiving environment, the value of statistical characteristics in the same type signal may change, resulting in the sensitivity of the traditional modulation recognition algorithm to the statistical parameters representing the characteristics of different types of signals, and the reduction of recognition and classification accurate. With the application of deep learning in the field of signal processing, automatic modulation recognition algorithm based on convolution neural network has become the current research hotspot. Aiming at the problem of automatic recognition for communication signal modulation, this paper uses hierarchical convolutional neural network to learn the time-frequency structure differences of modulation parameters, and uses these differences to realize accurate recognition of communication signals. This method combines the advantages of signal feature extraction method and deep learning recognition method, extracts the modulation parameters such as instantaneous amplitude, instantaneous frequency and instantaneous phase, reduces the redundant information for modulation recognition useless in the signal, and constructs the

通讯作者: 魏冬, 博士, 副研究员, weidong@iie.ac.cn.

本课题得到国家重点研发计划项目(No. 2018YFF01014303)资助。

收稿日期: 2020-11-14; 修改日期: 2021-04-07; 定稿日期: 2023-02-22

time-frequency structure image of each modulation parameter. Then, a dedicated convolutional neural network is constructed to learn the unique time-frequency structure of images with different modulation parameters. Finally, the hierarchical neural network architecture is designed to cascade each dedicated convolutional neural network to accurately determine the modulation types. In this paper, a total of 11 kinds of communication signals are automatically recognized. This method can effectively overcome the adverse factors such as noise, frequency offset interference and receiving error, and has high robustness and automaticity. The experimental results show that every identification accuracy of 2ASK, 2FSK, 4FSK, BPSK, QPSK, 8PSK and 16QAM, 32QAM and 64QAM, AM and FM signal is above 80%, in the signal-to-noise ratio of size 12 dB and the presence of interference and frequency offset, is better than that of the same condition of traditional modulation mode recognition method based on signal feature extraction and modulation mode recognition method based on the deep learning alone.

Key words modulation recognition; signal processing; image classification; convolution neural network; hierarchical convolution neural network

1 引言

通信信号调制格式识别在无线电管理、电子对抗、信息安全及智能无线电领域发挥着重要作用。然而由于电磁空间的复杂性,如何在缺少先验信息及存在电磁干扰的情况下,实现对通信信号调制格式高精度且自动化的识别仍面临难点问题,主要表现在调制识别技术采用的算法模型容易受到噪声及干扰的影响,导致模型中参数估计失配,识别准确率下降;另外,模型算法对通信场景的变化适应性差,需要人为干预设置或改变模型参数以适应不同的通信场景,缺乏主动适应能力。

早期的调制识别主要依靠人工完成,操作人员观察信号波形特征判断信号调制格式,识别效果依赖于操作人员的经验知识,受操作人员对信号知识水平的限制。随着调制格式的多样化发展以及对调制识别速度的要求,人工判别方法不再适用,自动调制分类(AMC)技术受到广泛关注和研究。目前,针对调制识别技术的研究可以分为3类:判决理论法、专家特征识别法以及深度学习方法。

判决理论法的思想是将调制格式识别问题视为假设检验,通过计算信号样本的观测序列在各信号类型下的似然函数,取似然函数值最大的结果作为判定依据^[1]。该方法的基本思路是构造信号样本的观测序列集合 $r = \{r_1, r_2, \dots, r_N\}$ 和调制格式集合 $s = \{s_1, s_2, \dots, s_k\}$, 利用统计信号处理方法计算在已有样本观测的条件下该信号属于各调制格式的概率 $p(s_k|r)$, 然后通过贝叶斯(Bayes)公式将求此概率问题转化为求似然函数 $L(r|s_k)$ 问题,使得 $L(r|s_k)$ 最大的 s_k 就是信号 r 所属的调制格式。由于缺少信号 r 的先验信息,构造的似然函数通常包括未知参数,按照对未知参数的处理方式可以将判决理论法分为平均似然比检验(average likelihood ratio test, ALRT)^[2]、广义似然比检验(generalized likelihood ratio test, GLRT)^[3]和混合似然比(hybrid likelihood ratio test,

HLRT)^[4]。Kim 首次在文献[5]中提出 ALRT 算法,成功实现 BPSK 和 QPSK 信号的调制识别; Lay 和 Polydoros^[6]采用 ALRT 和 GLRT 分类器通过对信道的参数估计实现 16PSK、16QAM 和 V.29 信号的识别; Panagiotou 等^[7]联合 GLRT 和 HLRT 的方法对 PSK、QAM、V.39 信号进行了识别。由于该方法依赖方差、信噪比等大量的先验知识,需要对信号进行一定程度的建模,众多的未知参数导致似然函数的计算量增大,算法对模型失配和参数偏差敏感,鲁棒性不强。

专家特征识别法将调制识别问题视为一个统计模式识别问题。该方法包括信号特征提取和分类判决两个主要步骤,特征提取将原始信号中能表征调制格式的参数提取出来,形成特征空间;分类判决利用模式识别中的判决算法实现特征空间到调制格式空间的映射。根据提取的特征可将专家特征识别法分为以下几类:基于瞬时幅度、频率、相位等调制参数变化特征的调制识别方法,以及利用调制参数构造判决特征的识别方法。该方法通过构造通信信号的时域参数及各阶统计量作为特征分类, Nandi 和 Azzouz 在文献[8]中利用该方法提取时域参数的 9 种特征识别不同的低阶数字信号;基于星座几何特征的调制识别方法,星座图在二维空间中反映了调制信号的幅度和相位特征,利用星座图分类需从已调信号中提取出幅度和相位信息实现星座图的恢复重建工作,侯健在文献[9]中提出了一种利用星座图减法聚类对 MQAM 信号进行识别的算法,张路平等在文献[10]中重构星座图时采用了模糊 C 均值聚类法;基于时频分析的调制识别方法,该特征联合时域和频域中信号的分布特征实现调制格式识别,短时傅里叶变换(short-time fourier transform, STFT)、小波变换(wavelet transform, WT)等时频特征比较常用, Ho 首次提出利用 Haar 小波变换提取数字调制信号的瞬时频率和相位跳变信息来识别 PSK 和 FSK 的方法;基于高阶统计量(High-Order Statistics, HOS)的调制识别方法,该方法需从已调信号中恢复出复基

带信号的码元序列, 基于码元序列的幅度和相位构造高阶矩实现调制识别; 基于循环平稳特征的调制识别方法, 大多数信号符合平稳随机过程, 循环统计量能表征平稳随机过程的周期平稳性, 此外, 信号的各种循环谱特征也被用来调制识别分类。以上所列举的特征在实际应用中往往需要联合使用实现多种调制格式的识别工作。专家特征法中采用的判决分类器有基于距离的分类器欧氏距离、K-近邻分类器和模糊逻辑分类器, 常用的机器学习分类器包括决策树、支持向量机(SVM)和人工神经网络(ANN)。文献[11-13]均采用了基于改进的支持向量机算法的分类器实现调制识别; Nandi 等在文献[14]中使用瞬时幅度、相位以及傅里叶变换的频域特征完成了对模拟信号的识别, 后在文献[15]中对该算法进行改进, 提高了识别准确率。从以上叙述中可以看出, 对于专家特征识别法, 最重要的步骤是特征的选取, 涉及信号处理且对信号先验信息需求较多。由特征值映射到调制格式输出时, 每类特征必须保证其取值空间是固定的, 才能建立相应的判决门限值。而在实际情况中, 由于噪声、采样频偏、其他信号干扰的影响, 特征会受这些因素的影响而动态变化, 甚至偏离正常的值域, 并且单个特征往往无法完备表征待识别信号的差异, 需要联合其他特征门限值共同判决, 增加了误判的概率。文献[16]为了解决判决门限值受噪声影响问题, 提出了基于信噪比动态阈值的改进方法, 每次判决前增加信噪比估计的模块, 此方法的局限性在于实际中的噪声是复杂的, 不可能通过理论建模完全地还原。因此, 在实际应用场景中外界环境中不可避免的因素迫使专家特征识别算法对决策门限值进行修改, 且只能根据经验修改。

近几年, 随着深度学习在图像识别、语音处理、目标检测领域的广泛应用并取得显著成果, 不断有研究者将深度学习相关内容应用到调制识别方面。O'Shea^[17]等在 2016 年发表的论文中首次将深度学习用在调制识别中, 信号的 IQ 数据作为卷积神经网络的输入, 经过 2 层卷积层和 2 层全连接层后输出识别结果, 论文与其他调制识别方法进行实验对比表明了该方法的可行性。深度学习实现了端到端的信号调制格式识别, 该方法不需要信号的先验知识, 基本可以对信号进行盲识别, 也不用人为提取特征及设定固定的判决门限值, 避免基于经验的门限判决。此时调制识别致力于改进神经网络的结构, Wu^[18]等利用一个长短时记忆(LSTM)网络能够抓取序列之间

隐藏的信息的特性, 构造了一个 LSTM 和 CNN 组成的深度神经网络(CLDNN), 利用接收信号序列的时间相关性提高分类精度; O'Shea^[19]在深度卷积神经网络通过时域无线电信号的盲特征学习来调制识别的基础上, 增加了注意力模型实现信号同步信息的估计和修复, 能够在不了解信号结构的情况下盲目同步和归一化无线电信号。由于设计的神经网络具有自动抓取信号 IQ 序列中隐含的特征并对其进行学习的能力, 本质上是对信号中所有差异特性的全量表征, 原始 IQ 数据中除了包含调制信息外, 还包括载波、信道噪声等无效或错误信息成分, 导致识别结果的不稳定性。也就是说这种基于数据驱动的神经网络调制识别算法无法筛除无效和错误信息的干扰, 甚至会对其进行学习, 导致需要大量的信号样本进行训练来保证识别准确率。此外, 利用神经网络模型无法对调制格式识别的过程进行溯源, 不方便后续的优化。

基于以上原因, 目前一种调制识别的新思路是将传统的自动调制识别和深度学习相结合, 文献[20]在 O'Shea 模型的基础上, 在全连接层之前增加传统的循环平稳参数作为输入, 相当于在卷积神经网络的卷积层提取的特征的基础上再增多增加一维循环平稳特征, 通过全连接层组合后输出概率最高的调制类别; 文献[21]提出了一种基于特征图像的卷积神经网络调制识别模型, 从信号中提取传统的高阶统计量特征, 并将其映射为二维平面上的点集合, 通过不同调制信号高阶统计量的图像分布不同, 使用卷积神经网络识别特征图像进行分类; Zhao 等人^[22]提取出信号的瞬时幅度瞬时相位信息, 联合信号 IQ 样本组成 4×128 的数组作为信号数据集, 然后通过 CLDNN 网络实现 BPSK、QPSK、8PSK、16QAM、32QAM 调制信号的识别。

本文提出了一种联合调制参数时频结构特征构造及分层神经网络模型的调制格式识别算法。该算法充分借鉴了专家特征提取和神经网络学习的优点, 利用特征提取筛选样本中的调制信息, 降低样本中的信息冗余, 最大化体现不同调制格式之间的各种差异, 构建时频结构差异的图像, 并利用卷积神经网络的学习能力对结构的差异性进行全量表征。一方面, 相比基于时频特征的专家特征识别法, 本文提出的算法首先摆脱人工设置门限值的束缚, 二维时频结构差异图像相比于一维的时频特征统计参数能更精确体现调制格式对信号的影响, 而且基于结构的差异性可以克服突发噪声及采样误差对识别性能的影响; 另一方面, 相比基于原始信号的深度学

习调制识别法, 本文直接将时频结构差异图作为网络的输入, 保证 CNN 提取到的高维特征是与调制格式相关的有效特征, 需要的训练样本少, 可避免过拟合问题、无效样本对模型的影响。此外, 本文所设计的分层 CNN 架构可对调制识别的过程进行准确回溯, 并对局部网络存在的问题进行精确定位和优化。

本文的主要贡献如下:

(1) 首次提出利用神经网络模型对调制参数的时频结构差异进行学习, 可全量表征不同调制信号的差异信息, 有效对抗噪声、频偏及突发干扰对识别性能的影响;

(2) 首次提出分层神经网络架构, 实现对调制结果的回溯, 并对局部问题进行精确定位及优化;

(3) 利用 Python 开发工具建立了调制格式识别系统, 并在实际的信道中利用信号源、频谱仪等仪器对所提算法进行了测试分析。

2 调制信号识别模型及时频结构构建

针对本文提出的提取信号的时频结构差异图像, 作为卷积神经网络的输入, 然后建立分层卷积神经网络(Convolutional Neural Network, CNN)框架的实现调制信号识别的方法, 图 1 将上述思路进行模块化建立调制信号识别模型。




图 1 调制信号识别模型

Figure 1 Modulation signal recognition model

2.1 信号采集接收模块

非合作通信中信号接收场景一般如下: 天线实时捕获目标频点的无线信号, 通过低噪放大器对信号放大处理后输出中频信号, 进入本机振荡器产生振荡信号, 经低通滤波, 接着利用模数转换进行信号采样, 并分为两路分别进行进一步混频, 最终进行样本的抽取及滤波获得信号的 IQ 样本。接收信号 IQ 样本的表达式为

$$\tilde{I}(n) = A(n)\cos[2\pi f(n)/f_s n + \varphi(n)] \quad (1)$$

$$\tilde{Q}(n) = A(n)\sin[2\pi f(n)/f_s n + \varphi(n)] \quad (2)$$

$\tilde{I}(n)$ 为同相分量, $\tilde{Q}(n)$ 为正交分量; $A(n)$ 为样本幅值, $f(n)$ 为样本的瞬时频率, $\varphi(n)$ 为样本的初始相位。 f_s 为采样频率, 采样点 $n = 1, 2, 3, \dots, N$; 采样

时间 $t = N/f_s$ 。

本文对接收信号的处理识别流程如图 2 所示。




图 2 信号接收及采集流程图

Figure 2 Signal receiving and acquisition flow chart

在接收信号的采集过程中, 由于缺少先验信息, 对接收信号的处理存在误差, 图中红色框图表示合作通信中已知的先验信息, 蓝色框图表示没有先验信息时, 存在误差的模块。载波估计误差会使中频信号与本机振荡器产生的中频余弦信号混频后不能完全去除载波频率分量, 产生频偏, 带有频偏的 IQ 样本的表达式为

$$I(n) = A(n)\cos[2\pi(f(n) + \Delta f)/f_s n + \varphi(n)] \quad (3)$$

$$Q(n) = A(n)\sin[2\pi(f(n) + \Delta f)/f_s n + \varphi(n)] \quad (4)$$

此外, 信号在传输过程中还会受到噪声和其他信号的干扰, 信道的多径效应造成信号幅值随时间的随机衰落。实际情况中, 基于盲接收模型接收到的信号 IQ 样本更接近以下的形式:

$$I(n) = A(n)\cos[2\pi(f(n) + \Delta f)/f_s n + \varphi(n)] + \omega(n) \quad (5)$$

$$Q(n) = A(n)\sin[2\pi(f(n) + \Delta f)/f_s n + \varphi(n)] + \omega(n) \quad (6)$$

$\omega(n)$ 表示传输过程中的噪声, 一般将其建模为高斯白噪声。接收误差和通信环境干扰的存在, 造成信号幅值、相位及频率的随机变化, 扰乱调制特征的变化规律, 对盲信号的识别精度造成影响。

2.2 调制参数时频结构构建

信号的调制就是根据所要发送信息的变化对电磁波的幅度、频率及相位特征进行改变。设调制后的信号为

$$c(t) = A_c \cos(2\pi f_c t + \varphi_c) \quad (7)$$

其中, A_c 是载波的幅度, f_c 是载波的频率, φ_c 是载波的相位。当参数 A_c 的位置承载发送信息时, 基带信号被调制到载波的幅度上, $c(t)$ 成为幅度调制波形; 当参数 f_c 的位置承载发送信息时, 基带信号被调制到载波的频率上, $c(t)$ 成为频率调制波形; 当参数 φ_c 的位置承载发送信息时, 基带信号被调制到载波的相位上, $c(t)$ 成为相位调制波形。因此, 调制后形成

的调幅波、调频波、调相波可分别表示为

$$s_{am}(t) = (A_c + m(t))\cos(2\pi f_c t + \varphi_c) \quad (8)$$

$$s_{fm}(t) = A_c \cos[2\pi(f_c + m(t))t + \varphi_c] \quad (9)$$

$$s_{pm}(t) = A_c \cos[2\pi f_c t + (\varphi_c + m(t))] \quad (10)$$

由信号调制原理的理论分析可知, 已调信号的幅度、频率和相位承载着原始信息, 也最能体现调制格式的差异。例如, 调幅信号的调制特征仅仅体现在已调信号的幅度上, 已调信号的幅度根据原始信息的变化在时间上有规律的变化, 非调幅信号的幅度在时间上的变化是杂乱的, 这就是本文提出的调制参数时频结构差异。

根据公式(8)、公式(9)、公式(10)可以总结出调幅、调频、调相信号的调制参数时频结构差异如表 1 所示。

表 1 调制参数时频结构差异
Table 1 Time domain structure differences of modulation parameters

	调幅信号	调频信号	调相信号
瞬时幅度 $A(t)$	$A_c + m(t)$	A_c	A_c
瞬时频率 $f(t)$	f_c	$f_c + m(t)$	f_c
相位 $\varphi(t)$	φ_c	φ_c	$\varphi_c + m(t)$
瞬时相位 $\varphi(t)$	$2\pi f_c t + \varphi_c$	$2\pi(f_c + m(t))t + \varphi_c$	$2\pi f_c t + m(t) + \varphi_c$

实际通信中的基带信号 $m(t)$ 是经过量化编码技术将原始信号波形变换为有限个离散值组成的序列。因此, 对于经过载波调制的接收端信号来说, 其时域结构的差异性体现在以下方面: 幅度调制中已调信号的幅度会在载波幅值的基础上叠加有限个不同的幅值; 同理, 频率和相位调制信号分别在载波频率和相位的基础上叠加有限个不同的频率值和相位值。本文基于接收信号的瞬时幅度、瞬时频率及相位特征随时间所呈现出的特征值的交替性变化进行时域结构的构建。

根据信号接收模型得到的信号 IQ 样本的形式, 可以从中计算出瞬时幅度、频率和相位的表达式如下。

瞬时幅度特征:

$$A(n) = \sqrt{I^2(n) + Q^2(n)} \quad (11)$$

数字信号处理中, 通常对瞬时幅值进行归一化处理来消除信道增益的影响^[23], 归一化后的瞬时幅度表达式为

$$A_{cn}(n) = \frac{A(n)}{m_a} \quad (12)$$

其中, $m_a = \frac{1}{N} \sum_{n=1}^N A(n)$ 是瞬时幅度的均值。

瞬时相位特征:

$$\varphi(n) = \begin{cases} \arctan \left[\frac{Q(n)}{I(n)} \right], I(n) > 0 \\ \arctan \left[\frac{Q(n)}{I(n)} \right] - \pi, I(n) < 0, Q(n) \leq 0 \\ \arctan \left[\frac{Q(n)}{I(n)} \right] + \pi, I(n) < 0, Q(n) > 0 \\ \frac{\pi}{2}, I(n) = 0, Q(n) > 0 \\ -\frac{\pi}{2}, I(n) = 0, Q(n) \leq 0 \end{cases} \quad (13)$$

瞬时频率特征:

$$f(n) = \frac{d\varphi(n)}{dn} f_s / 2\pi \quad (14)$$

基于以上分析, 本文提出的时频结构差异可以由接收信号的瞬时特征参数处理后获得。

3 调制参数时频结构图分析

本文提出的调制参数时频结构差异性在二维平面上以图像的形式表示更加直观, 本节将对前面提到的影响非合作通信场景下接收信号特征提取的噪声和频偏因素进行分析, 说明时频结构差异特征的抗干扰和抗频偏能力。

3.1 噪声对时频特征图的影响

信号由发送天线到接收天线接收的过程中, 一是会受到发送端信源和接收端电子设备内部产生的热噪声、电流噪声等系统噪声的影响, 二是会受到来自外界同频段杂乱电磁波辐射的干扰。带有噪声干扰的接收端信号表达式为

$$r(t) = A(t)e^{j[2\pi f(t)t + \varphi(t)]} + \omega(t) \quad (15)$$

$\omega(t)$ 代表噪声干扰, 由对噪声的定义可知, $\omega(t)$ 是一个时间离散状态离散的随机过程, 即在某些时刻噪声存在, 某些时刻噪声不存在, 噪声本身也是一个随机变量。由表达式可以看出, 噪声相当于在信号本身的基础上叠加了一个随机值, 该随机值的大小决定了噪声对原始信号的影响, 图 3 比较了不同信噪比理想条件下信号的时频结构差异, 图中的噪声服从高斯分布。

图 3~图 5 分别将理想情况下与信噪比为 5、10、20dB 的条件下 2ASK 的瞬时幅值、4FSK 的瞬时频率以及 QPSK 的相位值随时间变化的结果绘制成的图片。在低信噪比情况下, 信号功率和噪声功率相当, 对信号的影响比较大, 导致时频结构图像失真; 信噪比增至 20dB 时, 各类信号的时频结构表现明显, 与理想情况下的时频结构图基本吻合, 证明了本文所提出的调制参数时频结构差异的有效性。

对于时频结构差异图像来说, 噪声会使其在小范围内波动, 而整体的趋势不会改变。另外, 由于信号的失真程度受噪声功率大小影响, 噪声因素无




图3 不同信噪比下的 2ASK 信号归一化瞬时幅值图
Figure 3 Normalized instantaneous amplitude of 2ASK under different SNR




图4 不同信噪比下的 4FSK 信号的瞬时频率图
Figure 4 Instantaneous frequency of 4FSK under different SNR

法完全消除, 本文将通过增加不同信噪比下时频特征图的结构特征来增强调制识别的准确性。

3.2 频偏对时频特征图的影响

接收端对载波频率进行估计之后, 需要对信号进行下变频处理, 但在无任何先验信息下载波频率估计方法的误差, 以及发射端与接收端的振荡器不可能达到完全匹配, 所以接收端经过下变频处理的信号中存在频率偏移:

$$r(t) = A(t)e^{j[2\pi f(t)t + \varphi(t)]}e^{j[2\pi\Delta f(t)t]} \quad (16)$$

信号采集完成后存在频偏的表达式如式(16)所示。

针对本文所提出的时频结构差异, 由 2.2 节的

表 1 中参数的表达式可以看出, 瞬时幅度差异的提取与频偏无关, 因此, 瞬时幅度结构特征本身不受频偏干扰, 具有良好的抗频偏能力。下面将分析频偏对瞬时频率和瞬时相位结构特征的影响。




图5 不同信噪比下的 QPSK 信号的相位图
Figure 5 Phase of QPSK under different SNR

含有频偏的瞬时频率的调制参数时频结构差异表达式可以改为

$$f(t) = f_c(t) + m(t) + \Delta f(t) \quad (17)$$

频偏在原来瞬时频率的基础上叠加了一个随机变量, 频偏远小于信号的符号率, 其本质与 $f_c(t)$ 是相同的。

由 2.2 节可知, 频偏对瞬时幅值图和瞬时频率图影响不大。频偏会使基带信号产生初始相位偏移, 从而导致瞬时相位图的变化。例如, 无频偏和含有频偏的 BPSK 无线调制信号初始相位如图 6 所示。




图6 BPSK 瞬时相位图
Figure 6 Instantaneous phase of BPSK

图 6(a)为 BPSK 信号中无频偏成分的相位结构图, 图 6(b)为带频偏成分的相位结构图, 从两幅图的对比中可以看出, BPSK 信号在两个相位点之间跳变的这种结构特征并没有改变。因此, 对于频偏产生的

影响,以相位结构特征来说,频偏会改变其在特征图上的斜率大小,但并没有改变斜率上承载着的原始信号所呈现出来的特征。

从映射到复平面的角度来说,频偏会随着时间一起连续变化,覆盖信号的某些特征,如星座图。从时域 IQ 信号中获得星座图的可表示为

$$P(n) = A(n)\cos(\varphi(n)) + jA(n)\sin(\varphi(n)) \quad (18)$$

星座图综合反映了调制信号的瞬时幅值和瞬时相位信息,对于相位调制的 PSK、QAM 信号来说,频

偏的累积会使本来应该成散点分布的星座图发生旋转,如图 7 所示。

文献[24]中指出,频偏会造成接收信号的幅度衰减及附加的相位旋转,给信号检测带来困难。由图 7 可以看出,频偏使相位调制信号的星座图产生旋转,形成了类似同心圆结构的星座图,这种频偏在一维数据上会导致有关相位的特征参数无规律的变化,但在二维数据上,类似同心圆结构的星座图是带有频偏的相位信号的典型结构特征。




图 7 16QAM 的频偏星座图

Figure 7 Frequency offset constellation of 16QAM




图 8 32QAM 的频偏星座图

Figure 8 Frequency offset constellation of 32QAM




图 9 64QAM 的频偏星座图

Figure 9 Frequency offset constellation of 64QAM

4 基于分层卷积神经网络的调制识别架构

为了对调制参数的结构差异进行精确学习,并

且对神经网络的识别结果进行回溯,本文设计了一种分层神经网络结构。分层神经网络较之传统的 CNN 网络,其优势在于,传统的 CNN 被设计成顺序卷积的单个输出层,这使得输入的待分类图像在 CNN 网络中经过同样的处理流程,事实上,有些类可能比其他类更难区分,并且类可以按类别的层次结构组织分类,分层 CNN 成功解决了这一问题,对于某些属于同一类的特定类别,使用该类的公共特征把它们从更大的范围中分离出来相对更容易些,然后再在较细的层次上进行归类,由粗到细,逐步完成分类^[25]。

由于调制样式的复杂化,完成不同调制格式之间的信号识别分类涉及多种时域结构特征,本文依据信号调制原理,对多个信号时域结构特征进行组合排序,形成了分层神经网络结构的调制识别框架。在该框架中,提取的每种信号特征均为独立的 CNN 分类器,与上一层或下一层中的其他特征的 CNN 分类器联合共同完成调制信号的识别分类工作。

图 10 是调制识别问题的分层神经网络原理结构图。分层 CNN 网络由多个 CNN 网络级联而成,每个分层的 CNN 网络的输入是时频结构差异特征图,用于识别特定的调制参数时频结构。基于该级联架构,一方面可将识别时频结构差异较大的 CNN 网络置前,降低出错的概率;另一方面,根据各 CNN 网络




图 10 分层神经网络原理结构图

Figure 10 Hierarchical neural network principle structure diagram

的输出结果, 可对整个调制格式识别的结果进行回溯, 对发生错误判决的 CNN 网络进行定位和优化。

4.1 时频结构特征的 CNN 分类器设计

本文针对每种时域调制参数结构图所设计的 CNN 模型结构如图 11 所示: 整个网络共有 11 个隐藏层(8 个卷积层和 3 个全连接层), 卷积层被分为 5 组, 卷积核大小均为 3×3 , 用来提取输入图像的特征图(feature map)。每组卷积层后是大小为 2×2 的最大池化层, 减少参数数量, 防止过拟合。全连接层将卷积层的 feature map 进行组合, 用来捕捉信号特征图不同位置特征之间的相关性。最后利用 softmax 函数作为神经网络分类的输出, 输出图像属于不同类别

的概率分布, 完成分类任务。

该 CNN 模型结构是基于 VGG 网络的基础上加以设计的。VGG 网络的改进是采用连续的几个 3×3 的卷积核代替较大卷积核, 统一规定最大池化尺寸为 2×2 。对于给定的感受野, 采用堆积的小卷积核优于采用大的卷积核, 因为多层卷积层可以通过增加网络深度来保证学习更复杂的模式, 对特征学习能力更强, 而且代价还比较小(参数更少)^[26], 小的池化核能够带来更细节的信息捕获。VGG 模型以较深的网络结构、较小的卷积核和池化采样域, 使得其能够在获得更多图像特征的同时控制参数的个数, 避免过多的计算量以及过于复杂的结构。




图 11 CNN 模型结构
Figure 11 CNN model structure

激活函数为 CNN 网络提供了非线性建模能力, 解决了样本非线性可分时 CNN 的非线性映射学习能力。在图 10 中, 采用 ReLU 激活函数对卷积层的输出进行分线性映射, 其公式表达为

$$f(x) = \max(0, x) \quad (19)$$

从表达式中看出, ReLU 函数使输出为负值 of 的神经元不被激活, 从而增加了网络的稀疏性^[27-28], 计算简单, 实现稀疏后的模型能够更好地挖掘相关特征, 拟合训练数据。

由于本文中的模型结构深, 为了限制在模型训练中出现过拟合情况, 选择 dropout 的正则化方法^[29], 目的是以一定的概率舍弃网络中的一些神经元, 使其停止参与运算, 降低过拟合的风险, 使模型具有良好的泛化能力。

针对本文中调制信号识别的多分类问题, 采用交叉熵损失函数:

$$J(\theta) = \frac{1}{m} \sum y^{(i)} \log(h(x^{(i)}, \theta)) + (1 - y^{(i)}) \log(1 - h(x^{(i)}, \theta)) \quad (20)$$

其中, θ 为需要优化的参数, m 为样本总数, $x^{(i)}$ 表示第 i 个样本, $y^{(i)}$ 表示第 i 个样本的预测值。在 CNN 模型中, 损失函数衡量的是模型对样本的预测值与真实值之间的差距, 根据损失函数的大小来调整网络内部的参数, 使训练更快收敛。

优化算法能调整模型更新权重和偏差参数的方式, 使参数逼近或达到最优值。实际应用中, Adam 优化算法对于稀疏数据集学习效果更有效, 收敛速度快, 且不需要人为调整学习率。基于本文中信号时域特征图片像素矩阵稀疏的特性, 在训练模型时选择了 Adam 优化算法。

4.2 分层神经网络

基于 2.2 节中对本文提出的所有信号调制参数时域结构的差异分析, 分层神经网络的识别流程可根据调制信号时域特征的独有性和共有性确定。

利用本文提出的调制参数时域结构差异的共有性我们对信号进行类间分类, 确定待识别信号隶属的更小范围类别, 作为分层神经网络的第一层; 得到每类的类内信号后, 再利用该类信号在某些时域调制参数上的独特表现进行类内分类, 作为分层神经网络的第二层; 如果第二层还没有对信号进行完全分类, 再依据小类别中信号所具备的不同特征进行更细层次的划分, 直至所有信号均完成分类。

结合调制参数时频结构特征差异的分析, 本文建立了如图 12 所示的分层神经网络模型。




图 12 分层神经网络模型
Figure 12 Hierarchical neural network model

图中的调制信号中共包含 11 个类别, 按照分层 CNN 架构的思想, 首先利用调制信号类间的时频结构差异特征对这 11 个类别进行类间分类, 将调制信号分为调幅信号、调频信号、调相信号三个大类, 然

后利用子类别中的时频结构差异特征对每个子类进行分类。在该体系结构中, 类间分类是一个 CNN 网络, 每个子类别也是独立的 CNN 网络, 有多个层次的输出, 每次输出都指向更小的类别范围, 直至分

类结果到达叶子节点。

这种网络的好处在于,按层次模型进行分类可以以更可解释的方式进行预测,即使中途分类出错,也减少了该类别的不确定性,比传统的 CNN 分类提供更多的信息。

此外,分层神经网络结合了传统机器学习中的决策树算法的优点,使得分类结果具有可解释性。决策树算法使用的是“白盒”模型,给定模型中节点的特征,可以通过布尔逻辑解释特征的可用性,进而对分类结果进行解释。相反,神经网络是“黑盒”模型,数据进入网络后直接得到最终的输出分类结果,我们并不清楚分类结果的机制以及网络内部运行规则。因此,分层神经网络的每个子节点都代表数据的一类特征,使用 CNN 将该类特征在高维空间中得到非线性分类结果,使得对应节点得到的决策结果具有可解释性,相当于增加了模型的“解释器”。决策树算法本身具有一定的局限性,例如,健壮性较差,训练数据的微小变化可能会导致数的变化加大;基于启发式算法的决策树学习不能保证全局最优决策树;树过于复杂时会出现过拟合,需要剪枝算法;节点特征的选择倾向于具有更多级别的属性特征等。决策树算法适用于规模小且特征高的数据集上,随着数据量上升,对模型能力的要求增加, CNN 的优势凸显。因此,将决策树中的节点以 CNN 代替并指定各节点学习的特征,基于此想法,提出分层神经网络。

对于一个未知信号,在进入分层神经网络之前,我们对信号的时域 IQ 序列进行截取分段处理,分段后的子信号作为输入,经过分层神经网络识别后输出分类结果,统计所有子信号分类结果中各类调制信号所占的比例,占比例最大的信号类型就是该信号所属的调制格式类别。这样做避免了偶然因素对调制识别算法的影响,进一步增强了算法的容错性。

基于分层神经网络思想,本文设计了一种调制格式识别算法,流程图如图 13 所示。

算法以瞬时相位特征作为第一层类间识别 CNN 的调制参数时频结构特征。对于调幅、调频、调相 3 种信号来说,它们的瞬时相位在 3 类信号之间的差异比较明显,由表 1 可以看出,3 类信号的瞬时相位总体趋势都是随时间线性变化的。调幅信号的瞬时相位是一条斜率为载波频率,偏置是载波相位的直线;调频信号瞬时相位的斜率是由有限个离散值组成的,偏置是载波相位,也就是说,调频信号的初始相位由不同斜率的线段构成;调相信号初始相位的斜率

是载波频率,偏置是由有限个离散值组成的,调相信号的瞬时相位是一条阶梯状的斜线。因此,本文选择已调信号的瞬时相位时域结构图实现调幅、调频、调相信号的类间分类。

算法第二层分别建立独立的 CNN 网络实现调幅、调频、调相信号的类内分类。利用瞬时幅值特征图对调幅信号进行分类;利用瞬时频率特征图对调频信号进行分类;利用星座图对调相信号进行分类。

最后将所有分段信号的识别结果进行汇总,以占最大概率的调制格式作为识别结果。

5 实验测试与分析

基于本文提出的调制参数时频结构差异的调制识别方法,搭建了相应的调制信号识别模型系统,实验中还还原非合作通信中信号接收处理场景,对 2ASK、2FSK、4FSK、BPSK、QPSK、8PSK、16QAM、32QAM、64QAM、AM、FM 共 11 种信号进行了测试与分析。

本系统的信号接收采集模块由信号发生器、信号接收机及个人电脑终端组成,如图 14 所示。

信号发生器用于产生不同类型的调制信号。对于数字调制信号,由信号发生器设置相应的调制参数完成基带信号的调制,发送天线将调制信号以电磁波的形式进行辐射覆盖;对于模拟调制信号,直接利用空中现有的特定频点的 AM、FM 信号数据。

在接收端,接收机负责截获发射到空中的无线信号,经过低噪放大以后输出中频信号,由专门的信号采集软件将中频信号转换成时域 IQ 信号样本,并以 mat 文件形式存储在计算机终端。

在个人计算机终端,使用 MATLAB 软件提取 IQ 数据中的时频结构特征,并转成图片保存,形成时频结构图片库;然后 CNN 识别模块采用深度学习的 Tensorflow 框架搭建 CNN 网络,完成对时频特征的识别工作。

受信号发生器发射功率的限制,实验区域为 $10\text{m}\times 8\text{m}$ 的长方形区域。实验过程中信号在特定频点持续产生调制信号经过射频通道 A 口输出,为了模拟无线信号道中噪声对信号的影响,在信号发生器的射频 B 通道口产生一个载波干扰信号与 A 通道口的调制信号一起经天线辐射到空中。

5.1 实验测试分析

实验中测试本文提出的算法时分成两个步骤进行:测试每种时频结构特征的 CNN 分类器能力和测试整个分层神经网络的识别算法的识别能力。




图 13 分层神经网络算法结构流程图

Figure 13 Hierarchical neural network algorithm structure flow chart

5.2 实验场景搭建




图 14 调制信号识别系统

Figure 14 Modulation signal recognition system

表 2 实验设备及品牌型号

Table 2 Experimental equipment and brand


实验设备	品牌型号
矢量信号源	R&S SMW200A
频谱仪	R&S FSP40
天线	华为 SMA 接口增益天线
软件分析工具	MATLAB2018、Python3.5

5.2.1 时频结构特征的识别能力分析


为了验证调制参数时频结构差异的有效性, 针

对瞬时幅度 $A(t)$ 、瞬时频率 $f(t)$ 、瞬时相位 $\phi(t)$ 的时频结构差异对它们所能识别的信号进行了实验。由于本次实验中采用的信号包括幅度和频率联合调制的 QAM 信号, 目前对此类信号的识别一般采用星座图的方式, 实验中涉及的所有 MPSK 和 MQAM 类信号, 采用了星座图的方式进行类内识别。

实验采集信号发生器产生的数字调制信号与空中的模拟调制信号, 模拟真实环境噪声影响, 采集到的信号信噪比为 5~15dB 均匀分布, 利用图 11 所示的时频结构特征的 CNN 分类器完成了 4 类时频结构特征对信号的识别, 测试结果如图 15 所示。



(a) 类间分类识别结果的混淆矩阵




(b) 类间分类识别结果准确率

图 15 类间分类识别准确率


Figure 15 Recognition accuracy of inter-class classification

图 15 是基于瞬时相位特征对调相、调幅、调频信号进行类间分类的结果, 瞬时相位特征将 11 种信号分为 3 类。(1)调相信号: BPSK、QPSK、8PSK、16QAM、32QAM、64QAM。(2)调频信号: 2FSK、4FSK、FM。(3)调幅信号: 2ASK、AM。对三大类信号的分类准确率均达到 98% 以上, 反映瞬时相位时频结构特征对于类间分类的有效性, 为下一层的类内分类提供保证。

下面对调幅信号、调频信号以及调相信号进行类内识别。测试结果如图 16~图 18 所示。




(a) 星座图识别结果的混淆矩阵




(b) 星座图识别结果准确率

图 16 星座图识别准确率

Figure 16 Constellation recognition accuracy



(a) 瞬时频率识别结果的混淆矩阵



(b) 瞬时频率识别结果准确率

图 17 瞬时频率识别准确率

Figure 17 Instantaneous frequency recognition accuracy




图 18 瞬时幅度识别准确率

Figure 18 Instantaneous amplitude recognition accuracy

图 16~图 18 中的时频特征是针对图 15 的类间分类进行的细分。上述各幅图中, 图(a)使用混淆矩阵对 CNN 时频特征分类器的测试集图片分类结果进行了精确的表示, 横坐标是分类标签结果, 纵坐标是真实标签, 从图中可以看出分类错误样本的具体划分结果。图(b)是每类信号的分类准确率的柱状图。从中可以看出, 在所有的分类结果中, 最低的是 QPSK, 准确率是 86.63%, 信号分类结果最高的准确率可达 100%。

瞬时相位、星座图、瞬时频率、瞬时幅度识别结果的总体准确率分别为: 98.78%、92.83%、99.58%、100%, 可见时频结构差异能准确表征信号调制后的差异性, 结合 CNN 分类器使用较少的样本便能将信号进行小范围的区分, 实现了优异的识别性能。

5.2.2 噪声和频偏情况下时频结构特征的识别能力分析

(1) 噪声情况下时频结构特征的识别能力分析

针对通信信道中存在的噪声问题, 本文利用搭建好的实验场景以及设备采集完时域信号 IQ 样本后, 利用 MATLAB 在样本中加入了高斯白噪声, 然后提取不同信噪比下时频特征, 利用 CNN 分类器检验识别能力, 结果如图 19 所示。

从图 19 中可看出, 在同等信噪比情况下, 瞬时相位和瞬时幅值的识别准确率比星座图和瞬时频率识别准

确率要高, 噪声对调幅、调频、调相等信号类间分类与对调幅信号分类的影响不大; 当信噪比大于 6dB 时, 瞬时相位和瞬时幅值在各种信噪比下识别准确率基本不变, 维持在 90%以上, 抗噪能力强; 星座图和瞬时频率识别准确率随信噪比的增加不断上升, 当信噪比为 12dB 时, 识别准确率达到 92%以上, 最终在信噪比为 14dB 后达到稳定, 达到 95%以上的识别准确率。




图 19 不同信噪比下各时频特征识别准确率

Figure 19 The recognition accuracy of time-frequency feature under different SNR

图 20 为将每个时频结构特征的 CNN 分类器所能识别的信号调制格式汇总后所得到的结果。从图中可以看出, 当信噪比大于 12dB 时, 16QAM 识别准确率达到 80%以上; 当信噪比大于 6dB 时, 其他调制格式的信号识别准确率都维持在比较高的水平上。从以上分析可知, 相对于瞬时幅值、瞬时频率而言, 低信噪比下星座图和瞬时频率会受到一定影响, 尤其是星座图特征, 原因是噪声的扰动使信号特征对应的高维空间发生改变, 进而影响分类器的原来训练好的高维决策空间决策失误, 造成分类器性能下降。整体而言, 利用各时频结构特征进行调制格式分类的 CNN 分类器, 在较低的信噪比情况下仍具有较强的抗噪性能。




图 20 不同信噪比下时频结构识别准确率

Figure 20 Signal recognition accuracy under different time-frequency structure

(2) 频偏情况下时频结构特征的识别能力分析

下面将在 5~15dB 混合信噪比下, 0~2kHz 频偏范围内对时频结构特征的识别性能进行讨论分析。

由图 21(a)-(d)以及分析可知, 随着频偏的增大, 识别准确率有所降低, 但有频偏情况下识别结果和

无频偏情况下识别准确率接近。调幅信号识别结果保持较高的准确率, 不受频偏影响, 瞬时幅度结构特征不受频偏干扰, 具有良好的抗频偏能力。瞬时相位受频偏影响较大, 间接导致星座图特征受到影响从而使调相信号分类准确率有较大的波动。然而, 纵使在较大的频偏 2kHz 时, 所有调制格式识别准确率均达到 80% 以上, 由此得出本文提出的时频结构差异特征图能够有效抵抗频偏的干扰。




图 21 频偏存在时结构特征识别准确率

Figure 21 Time-frequency structure recognition accuracy in the presence of frequency offset

5.2.3 分层神经网络的识别能力分析

实验将训练好的单个时频结构特征图的 CNN 网络按照图 12 所示模型进行组合, 搭建分层卷积神经网络, 在 5~15dB 平均分布的混合信噪比信号下对 11 种调制格式信号进行了测试。测试时每类信号的图片各选取了 100 张。下面将经典 O'Shea 算法^[17]、决策论算法分别与本文的算法作对比, 分析算法性能。

(1) 与经典算法对比性能分析

为了验证本文所提出的算法在原有基础上识别准确率有所提高, 本文使用自己采集的 IQ 数据集实现了文献[17]中 O'Shea 提出的端到端 CNN 的调制识别模型, 该文中用到的 CNN 模型结构如表 3 所示。

表 3 O'Shea 模型结构

Table 3 O'Shea model structure

网络层类型	输入尺寸	参数	激活函数
conv 层	128×2	3×1 卷积核	ReLU
		256 个特征映射	
conv 层	256×126×2	dropout 50%	ReLU
		3×2 卷积核	
dense 层	9920×1	80 个特征映射	ReLU
		dropout 50%	
dense 层	256×1	256 个神经元	ReLU
		dropout 50%	
dense 层	256×1	11 个神经元	softmax

分别将信号的 IQ 数据存到两个数组构造 128×2 的二维矩阵并打上标签, 划分好训练集及测试集后, 放入到表 3 所示的 CNN 模型结构中训练了 32 轮之后, 测试集上的识别结果如图 22 所示。




图 22 O'Shea 模型测试结果

Figure 22 Test results of O'Shea model




图 23 分层 CNN 模型与 O'Shea 模型对比测试结果
Figure 23 Comparison test results of layered CNN model and O'Shea model

从图 22 和图 23 中可以看出 O'Shea 模型 QPSK、32QAM、FM、AM 这 4 类信号的识别准确率极低, 尤其是模拟调制信号 FM 与 AM, 识别准确率为 0, 这就导致总体的识别准确率在 58% 左右。由图 23 可知本文提出的分层 CNN 模型总体的识别准确率为 85% 左右, 远远大于 O'shea 模型。由此可以知道, 直接将 IQ 样本输入 CNN 模型中, CNN 确实会学到一些和调制信息无关的特征, 无效特征在不同调制格式的信号中普遍存在, 从而影响识别结果。

(2) 与决策论算法对比性能分析

本文还根据文献[8]中提出的一些时域特征参数, 采用决策论算法对 AM、FM、2ASK、2FSK、4FSK、BPSK、QPSK 7 种调制格式进行了识别, 使用的具体的时域特征参数如表 4 所示。

u_{42}^a 是用来描述瞬时幅度特征的, 该值度量的是瞬时幅度分布的密集性, 可以用来区分瞬时幅度高密度分布的信号和瞬时幅度分布较稀疏的信号, 利用该特征可区分 AM 和 2ASK 信号; 同理, u_{42}^f 衡量的是瞬时频率分布的密集性, 该值可以区分 FM 和 MFSK 信号; σ_{dp} 表征信号相位的变化情况, 可以用来区分不包含相位信息的信号(如 AM、MASK)和包含

相位信息的信号(如 FM、MFSK 和 MPSK); σ_{ap} 表征信号绝对相位的变化, 可以区分包含绝对相位信息的信号(如 QPSK、MFSK、FM)和不包含绝对相位信息的信号(如 BPSK); γ_{max} 表征了信号瞬时幅度的变化情况, 可以反映出调制信号包络的变化特性, 例如 AM、MASK 包括强起伏; MPSK 包络微弱起伏; MFSK 无包络起伏; σ_{af} 表征信号的绝对频率信息, 可以用来区分归一化瞬时频率绝对值为常数的调制格式(2FSK、MSK)和具有绝对频率信息的调制格式(4FSK)。

表 4 时域特征参数及符号表示

Table 4 Time domain characteristic parameters and symbol representation

参数名称	符号表示
零中心归一化瞬时幅度的紧致性	U_{42}^a
零中心非弱信号瞬时相位非线性分量的标准差	σ_{dp}
零中心非弱信号瞬时相位非线性分量的绝对值的标准差	σ_{ap}
归一化瞬时幅度功率谱密度的最大值	γ_{max}
零中心归一化瞬时频率的紧致性	U_{42}^f
零中心归一化非弱信号瞬时频率绝对值的标准差	σ_{af}

依据以上分析, 建立了关于 AM、FM、2ASK、2FSK、4FSK、BPSK、QPSK 这 7 种信号的时频特征决策算法流程图, 如图 24 所示。




图 24 时频特征的决策算法流程

Figure 24 Decision algorithm flow of time frequency characteristics

实验利用 MATLAB 实现表 4 中 6 类时频特征的提取, 按照图 24 中的决策流程实现了上述 7 种信号的识别, 识别结果如表 5 所示。

同时, 我们利用 MATLAB 在采集到的调制信号中加入高斯白噪声, 在不同信噪比下对分层 CNN 算法的测试结果如表 6 所示。

从表 5 和表 6 中的识别结果可以看出, 基于特征提取的决策论算法受噪声影响较为严重, 只对少数两种调制格式 FM 与 QPSK 的识别效果较好。当信噪比大于 12dB 时, 本文算法对各类调制格式识别的正确率超过 80%。在较低的信噪比条件下, 本文提出的识别方法优于同等噪声条件下的基于专家特征的决策论算法。这是由于决策论算法中提取的特征是关于信号的统计量值, 并没有对信号的每个采样值进行充分利用, 统计值很容易受到极端异常值的影响, 从而影响决策门限, 算法稳健性较差。本文中提出的时频特征图片是由每个采样点中的时频结构特征构成的, 充分利用了信号, 且信号中的极端异常值并不会影响时频特征的整体结构, 具有较好的容错性, 具有决策论算法所不具备的优势。

6 结论

通信信号的调制格式识别受信道噪声、干扰以及频偏等因素影响, 本文提出了一种利用调制参数时频结构差异结合深度学习的方法对调制信号类型进行识别, 该方法有效解决了噪声和频偏在内的干扰因素对识别结果的影响; 文章中基于分层神经网络的思想, 依据各类时频结构图像及 CNN 分类器搭建了一种调制信号识别体系架构, 有效实现调制信号类型的识别。在实验中, 基于真实通信接收信号模型的原型进行实验场景的布置, 对接收的 11 种类型的调制信号进行识别, 实验结果表明, 在噪声和频偏存在的情况下, 分层神经网络对每一类的调制信号识别正确率均优于同等条件下的深度学习信号 IQ 数据的方法和专家特征识别法。

表 5 决策论算法的识别结果

Table 5 Recognition results of decision theory algorithm

	0dB	6dB	8dB	10dB	12dB	14dB
AM	0	0	0	26%	80%	97%
2ASK	0	0	0	0	16%	78%
FM	0	100%	100%	100%	100%	100%
2FSK	0	0	0	0	0	7%
4FSK	0	0	0	0	100%	100%
BPSK	0	0	3%	3%	9%	22%
QPSK	0	100%	100%	100%	100%	100%

表 6 分层 CNN 算法的识别结果

Table 6 Recognition results of layered CNN algorithm

	0dB	6dB	8dB	10dB	12dB	14dB
AM	77%	83%	99%	100%	100%	100%
2ASK	69%	71%	100%	100%	100%	100%
FM	91%	92%	95%	96%	99%	99%
2FSK	55%	67%	88%	96%	98%	100%
4FSK	71%	97%	100%	100%	100%	100%
BPSK	45%	60%	100%	100%	100%	98%
QPSK	61%	71%	100%	100%	100%	95%
8PSK	29%	56%	70%	78%	85%	87%
16QAM	74%	87%	90%	91%	92%	93%
32QAM	76%	80%	82%	86%	90%	92%
64QAM	0%	7%	23%	63%	80%	92%

参考文献

[1] He J A, Zhang W Q. The Technology for Modulation Recognition of Communication Signals and Its Development[J]. *Chinese High Technology Letters*, 2016, 26(2): 157-165.
(何继爱, 张文启. 通信信号调制识别技术及其发展[J]. *高技术通讯*, 2016, 26(2): 157-165.)

[2] Wei W, Mendel J M. A New Maximum-Likelihood Method for Modulation Classification[C]. *Conference Record of The Twenty-Ninth Asilomar Conference on Signals, Systems and Computers*, 2002: 1132-1136.

[3] Le Martret C, Boiteau D. A General Maximum Likelihood Classifier for Modulation Classification[C]. *9th European Signal Processing Conference*, 2015: 1-4.

[4] Hong L, Ho K C. BPSK and QPSK Modulation Classification with Unknown Signal Level[C]. *MILCOM 2000 Proceedings. 21st Century Military Communications. Architectures and Technologies for Information Superiority*, 2002: 976-980.

[5] Kim K, Polydoros A. Digital Modulation Classification: The BPSK Versus QPSK Case[C]. *MILCOM 88, 21st Century Military Communications - What's Possible? ' . Conference record. Military Communications Conference*, 2002: 431-436.

[6] Lay N E, Polydoros A. Modulation Classification of Signals in Unknown ISI Environments[C]. *Proceedings of MILCOM '95*, 2002: 170-174.

[7] Panagiotou P, Anastasopoulos A, Polydoros A. Likelihood Ratio Tests for Modulation Classification[C]. *MILCOM 2000 Proceedings. 21st Century Military Communications. Architectures and Technologies for Information Superiority*, 2002: 670-674.

[8] Nandi A K, Azzouz E E. Algorithms for Automatic Modulation Recognition of Communication Signals[J]. *IEEE Transactions on Communications*, 1998, 46(4): 431-436.

[9] Hou J, Wang H K. MQAM Recognition Based on Research of Constellation Clustering[J]. *Radio Communications Technology*, 2009, 35(3): 35-38.
(侯健, 王华奎. 一种基于星座图聚类的 MQAM 识别方法[J].

无线电通信技术, 2009, 35(3): 35-38.)

- [10] Zhang L P, Wang J X. Modulation Classification Using Weighted Constellation Matching[J]. *Journal of Applied Sciences*, 2009, 27(1): 19-23.
(张路平, 王建新. 星座图加权匹配的调制方式识别[J]. *应用科学学报*, 2009, 27(1): 19-23.)
- [11] Nandi A K, Azzouz E E. Modulation Recognition Using Artificial Neural Networks[J]. *Signal Processing*, 1997, 56(2): 165-175.
- [12] Teng X Y, Tian P W, Yu H Y. Modulation Classification Based on Spectral Correlation and SVM[C]. *2008 4th International Conference on Wireless Communications, Networking and Mobile Computing*, 2008: 1-4.
- [13] Wang L X, Ren Y J, Zhang R M. Algorithm of Digital Modulation Recognition Based on Support Vector Machines[J]. *2009 International Conference on Machine Learning and Cybernetics*, 2009, 2: 980-983.
- [14] Nandi A K, Azzouz E E. Automatic Analogue Modulation Recognition[J]. *Signal Processing*, 1995, 46(2): 211-222.
- [15] Yin Z D. Research of Communication Signal Modulation Scheme Recognition Based on One-Class SVM Bayesian Algorithm[C]. *2009 5th International Conference on Wireless Communications, Networking and Mobile Computing*, 2009: 1-4.
- [16] Yang Y Q, Zhang X Q. A Modified Method for Digital Modulation Recognition Based on Instantaneous Signal Features[C]. *2019 3rd International Conference on Electronic Information Technology and Computer Engineering*, 2020: 1351-1354.
- [17] 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.
- [18] Wu Y L, Li X J, Fang J. A Deep Learning Approach for Modulation Recognition via Exploiting Temporal Correlations[C]. *2018 IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications*, 2018: 1-5.
- [19] O'Shea T J, Pemula L, Batra D, et al. Radio Transformer Networks: Attention Models for Learning to Synchronize in Wireless Systems[C]. *2016 50th Asilomar Conference on Signals, Systems and Computers*, 2017: 662-666.
- [20] Kumar Arumugam K S, Kadampot I A, Tahmasbi M, et al. Modulation Recognition Using Side Information and Hybrid Learning[C]. *2017 IEEE International Symposium on Dynamic Spectrum Access Networks*, 2017: 1-2.
- [21] Lee J H, Kim K Y, Shin Y. Feature Image-Based Automatic Modulation Classification Method Using CNN Algorithm[C]. *2019 International Conference on Artificial Intelligence in Information and Communication*, 2019: 1-4.
- [22] Zha X, Qin X, Zhou Y M, et al. Power of Deep Learning for Amplitude-Phase Signal Modulation Recognition[C]. *2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference*, 2019: 454-458.
- [23] Yang J, Liu H, Bu X Y. Modulation recognition for communication signals[M]. Beijing: Posts & Telecom Press, 2014.
(杨杰, 刘珩, 卜祥元. 通信信号调制识别: 原理与算法[M]. 北京: 人民邮电出版社, 2014.)
- [24] Yang Ming, Wang Wei. Analysis of the influence of frequency offset on LTE signal reception SNR and related detection performance[J]. *Telecommunications Technology Research*, 2013(5): 19-22.
(杨铭, 王巍. 频偏对 LTE 信号接收信噪比及相关检测性能的影响分析[J]. *电信技术研究*, 2013(5): 19-22.)
- [25] Zhu X Q, Bain M. B-CNN: Branch Convolutional Neural Network for Hierarchical Classification[EB/OL]. 2017: arXiv: 1709.09890. <https://arxiv.org/abs/1709.09890>
- [26] Suresh R, Keshava N. A Survey of Popular Image and Text Analysis Techniques[C]. *2019 4th International Conference on Computational Systems and Information Technology for Sustainable Solution*, 2020: 1-8.
- [27] Glorot X, Bordes A, Bengio Y. Deep Sparse Rectifier Neural Networks[C]. *The 14th International Conference on Artificial Intelligence and Statistics*. 2011:315-323.
- [28] Qu J Y, Sun X, Gao X. Remote Sensing Image Target Recognition Based on CNN[J]. *Foreign Electronic Measurement Technology*, 2016, 35(8): 45-50.
(曲景影, 孙显, 高鑫. 基于 CNN 模型的高分辨率遥感图像目标识别[J]. *国外电子测量技术*, 2016, 35(8): 45-50.)
- [29] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving Neural Networks by Preventing Co-Adaptation of Feature Detectors[EB/OL]. 2012: arXiv: 1207.0580. <https://arxiv.org/abs/1207.0580>



王中方 于 2013 年在北京邮电大学信号与信息处理专业获得硕士学位。现在中国科学院大学通信与信息系统专业攻读博士学位。研究领域为通信安全。研究兴趣包括: 信号盲识别、无线通信灵巧干扰。Email: wangzhongfang@iie.ac.cn



仇昭花 于 2020 年在山东师范大学通信工程专业获得学士学位。现在中国科学院大学网络空间安全专业攻读硕士学位。研究领域为信号处理。研究兴趣包括: 无线安全、信号识别、巨型低轨互联网星座干扰分析。Email: qiuzaohua@iie.ac.cn



禹成亮 于 2018 年在大连海事大学通信工程专业获得学士学位。现在中国科学院大学计算机技术专业攻读硕士学位。研究领域为图像识别。研究兴趣包括: 信息安全、信号检测、行为识别。
Email: yuchengliang@iie.ac.cn



魏冬 于 2013 年获得北京邮电大学通信与信息系统专业博士学位。现任中国科学院信息工程研究所第四研究室副研究员。研究领域为无线通信物理层安全、调制识别、信号处理。Email: weidong@iie.ac.cn



黄伟庆 现任中国科学院信息工程研究所第四研究室主任、中国计算机学会信息保密专委会秘书长。研究方向为无线通信安全、电磁信号处理、网络安全保密技术、物联网安全、云计算安全技术等。