



# 计算机科学

COMPUTER SCIENCE

## 基于深度学习的自动调制识别研究

焦翔, 魏祥麟, 薛羽, 王超, 段强

### 引用本文

焦翔, 魏祥麟, 薛羽, 王超, 段强. 基于深度学习的自动调制识别研究[J]. 计算机科学, 2022, 49(5): 266-278.

JIAO Xiang, WEI Xiang-lin, XUE Yu, WANG Chao, DUAN Qiang. [Automatic Modulation Recognition Based on Deep Learning](#)[J]. Computer Science, 2022, 49(5): 266-278.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

#### [结合注意力机制与几何信息的特征融合框架](#)

Feature Fusion Framework Combining Attention Mechanism and Geometric Information

计算机科学, 2022, 49(5): 129-134. <https://doi.org/10.11896/jsjcx.210300180>

#### [基于学术知识图谱的辅助创新技术研究](#)

Academic Knowledge Graph-based Research for Auxiliary Innovation Technology

计算机科学, 2022, 49(5): 194-199. <https://doi.org/10.11896/jsjcx.210400195>

#### [基于 QRNN 的网络协议模糊测试用例过滤方法](#)

Testcase Filtering Method Based on QRNN for Network Protocol Fuzzing

计算机科学, 2022, 49(5): 318-324. <https://doi.org/10.11896/jsjcx.210300281>

#### [一种量子安全拜占庭容错共识机制](#)

Quantum Secured-Byzantine Fault Tolerance Blockchain Consensus Mechanism

计算机科学, 2022, 49(5): 333-340. <https://doi.org/10.11896/jsjcx.210400154>

#### [基于素数幂次阶分圆环的 NTRU 型全同态加密方案](#)

NTRU Type Fully Homomorphic Encryption Scheme over Prime Power Cyclotomic Rings

计算机科学, 2022, 49(5): 341-346. <https://doi.org/10.11896/jsjcx.210300089>

# 基于深度学习的自动调制识别研究

焦翔<sup>1</sup> 魏祥麟<sup>2</sup> 薛羽<sup>1</sup> 王超<sup>1</sup> 段强<sup>2</sup>

<sup>1</sup> 南京信息工程大学计算机与软件学院 南京 210044

<sup>2</sup> 国防科技大学第六十三研究所 南京 210007

(jx19970429@163.com)

**摘要** 非合作通信场景下,自动调制识别是实现频谱感知、频谱管理、频谱利用的关键一环,也是进行高效信号处理的重要前提。传统基于模式识别的AMR方法需要手工进行特征提取,面临着设计复杂性高、识别精度低、泛化能力弱等难题。为此,学术界将目光转向以提取数据中隐含特征见长的深度学习方法,提出了多种面向AMR的深度神经网络架构。相比传统方法,ADNN取得了更高的识别精度,且泛化能力更强,适用范围更广。文中对ADNN领域的研究进行了全面的梳理总结,使从业者可以更好地了解该领域的研究现状,明晰该领域存在的问题以及未来的发展方向。首先,介绍了ADNN设计中涉及的典型DL方法;其次,描述了AMR问题的内涵,简述了传统解决方案;然后,详细介绍了ADNN的工作流程、方法分类和各类方法中的典型代表;最后,在公开数据集上对代表性方案进行了实验对比,并指出了该领域未来需要重点研究的几个方向。

**关键词:** 深度学习;深度神经网络;自动调制识别;安全

中图分类号 TN971

## Automatic Modulation Recognition Based on Deep Learning

JIAO Xiang<sup>1</sup>, WEI Xiang-lin<sup>2</sup>, XUE Yu<sup>1</sup>, WANG Chao<sup>1</sup> and DUAN Qiang<sup>2</sup>

<sup>1</sup> School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China

<sup>2</sup> The 63rd Research Institute, National University of Defense Technology, Nanjing 210007, China

**Abstract** Automatic modulation recognition (AMR) is critical to realize efficient spectrum sensing, spectrum management and spectrum utilization in non-cooperative communication scenarios. It is also an important prerequisite for efficient signal processing. Traditional AMR methods based on pattern recognition need to extract features manually, which faces many problems such as high design complexity, low recognition accuracy and weak generalization ability. Therefore, practitioners turn to deep learning (DL) methods, which are good at extracting hidden features from the data, and propose a number of AMR-oriented deep neural network (ADNN) architectures. Compared with traditional methods, ADNN has achieved higher recognition accuracy, higher generalization ability and wider application range. This paper provides a comprehensive survey of ADNN to help practitioners understand the current research status in this field, and analyzes the future directions after pinpointing several open issues. Firstly, typical deep learning methods involved in ADNN design are introduced. Secondly, a few traditional AMR methods are briefly described. Thirdly, typical ADNNs are introduced in detail. Finally, a series of experiments are conducted on an open dataset to compare typical proposals, and several key research directions in this field are put forward.

**Keywords** Deep learning, Deep neural network, Automatic modulation recognition, Security

## 1 引言

用频设备数量的爆炸式增长使得本就短缺的电磁频谱愈发拥挤不堪。作为信号检测和信号解调之间的重要步骤,自动调制识别(Automatic Modulation Recognition, AMR)成为了理解日益拥挤和复杂电磁空间的重要手段,是非合作通信场景下实现高效频谱感知、频谱理解和频谱利用的重要前提,也是近年来无线通信领域研究的重点课题之一<sup>[1]</sup>。

传统AMR方法可以分为两类:基于决策理论的似然性

方法<sup>[2]</sup>和基于统计理论的特征提取方法<sup>[3]</sup>。基于决策理论的似然性方法在分析待识别信号统计特性的基础上,利用概率论、贝叶斯理论计算出信号的似然函数,通过比较由似然函数得到的检验统计量,来实现调制方式的识别。理论上,该类方法能够带来最佳的识别精度,但较高的计算复杂度以及对先验知识较强的依赖性限制了其在实际问题中的应用。基于统计理论的特征提取方法通过选定特征对信号进行特征提取,然后利用训练好的分类器进行调制识别。该类方法的识别精度依赖于所提取的统计特征,且受限于传统分类器的较弱

学习能力,因此其最终识别精度普遍较低。为了解决这些问题,学术界在近三年开始将目光转向在目标识别领域大放异彩的深度学习(Deep Learning, DL)方法,设计了多种面向AMR的深度神经网络(AMR-oriented Deep Neural Network, ADNN)架构。

ADNN方法首先选择合适的神经网络作为模型自动提取的特征,将预处理的信号数据送入神经网络进行训练,然后用训练好的网络完成对未知信号调制方式的识别。相比传统方法,ADNN方法在不依赖人工提取特征的前提下,取得了更高的识别精度,且泛化能力更强,适用范围更广,因此获得了广泛关注。当前,用于设计ADNN的深度神经网络(Deep Neural Network, DNN)类型包括深度卷积神经网络(Convolutional Neural Network, CNN)<sup>[4]</sup>、长短期记忆网络(Long Short-Term Memory, LSTM)<sup>[5]</sup>、图神经网络(Graph Neural Networks, GNN)<sup>[6]</sup>等。基于不同DNN结构设计的ADNN也存在较大差异。

为了帮助从业者更好地了解该领域的研究现状,明晰该领域存在的问题以及未来的发展方向,本文全面梳理总结了ADNN领域的相关现状。本文第2节介绍了用于ADNN设计的主要DNN结构;第3节描述了调制识别问题,简述了传统识别方法,并且分析了传统解决方案的优缺点;第4节给出了ADNN的一般流程,并对当前方法进行了分类;第5—6节对典型ADNN设计进行了详细介绍;第7节通过实验对现有工作进行了总结和对比分析,同时提出了该领域未来需重点研究的方向;最后总结全文。

## 2 ADNN方法概述

得益于算力的快速增长、大规模数据集的不断涌现和算法设计的进步,DL作为机器学习的一个分支,可以快速解决一些复杂、抽象的智能任务<sup>[7]</sup>,近年来在自然语言处理<sup>[8]</sup>、计算机视觉<sup>[9]</sup>、推荐系统<sup>[10]</sup>、辅助决策<sup>[11]</sup>等多个领域取得了巨大成功。

相比传统机器学习方法,DL网络架构通常由多层非线性运算单元组成,且各层之间通过不同的方式连接,前一层的输出将作为后一层的输入<sup>[12]</sup>。这种分层思想使得每一层网络可以对输入数据进行不同程度的自动特征提取,从大量的输入数据中学习数据间的内在关联与规律,用于图像、文字、信号等数据的分析,进而完成各类给定任务。DL的主流方法之一是深度神经网络。深度神经网络由多层神经网络级联而成,各层神经网络均可利用非线性处理单元提取数据特征。其中,浅层网络学习简单特征,深层网络基于简单特征进行深层特征提取,从而得到更抽象的高层特征。层次化的数据处理、特征的内部变化和较高的模型复杂度促进了DNN在多个领域的成功,解决了很多分类、回归难题。

在无线通信和信号处理领域,学术界也开始将多种类型的DNN用于无线通信的全过程,包括调制识别、射频指纹识别<sup>[13]</sup>和特定辐射源识别<sup>[14]</sup>等。具体来讲,ADNN设计中使用的典型DNN架构包括:

(1)全连接神经网络(Fully Connected Neural Networks, FCNN)。FCNN由输入层、一个或多个隐藏层以及输出层3部分组成。FCNN的每一层中都包括多个神经元(即网络中的节点),相邻层的神经元两两之间存在一条边互连,每条边上赋予了一定的权重。网络中采用激活函数来增强神经网络模型的非线性,典型的激活函数包括Sigmoid<sup>[15]</sup>, tanh和ReLU<sup>[16]</sup>等。输入到FCNN的数据经过每个隐藏层时,都需要将当前的输入矢量乘以与之相连的权重矢量,得到加权和。之后加权和被送入激活函数中激活,激活函数的输出值将作为下一层网络的输入。而在训练阶段,FCNN通过梯度下降方法进行参数训练。

(2)卷积神经网络(CNN)。CNN主要由卷积层、池化层和全连接层3部分组成。卷积层利用卷积核与上一层的输入进行卷积运算得到特征子图,用于提取数据局部区域的特征,不同的卷积核代表不同的特征提取器;池化层主要用于减少特征数量,降低网络参数量,避免过拟合现象的发生,具体操作是对卷积层输出数据中每个区域进行下采样操作,得到一个值作为对这一区域的高度概括;全连接层则是对经过卷积以及池化操作后得到的局部特征进行整合。当前,学术界提出了多种CNN架构,如GoogleNet<sup>[17]</sup>, VGG<sup>[18]</sup>, ResNet<sup>[19]</sup>, Inception-ResNet-v2<sup>[20]</sup>等。

(3)循环神经网络(Recurrent Neural Network, RNN)。不同于FCNN和CNN, RNN利用自反馈的神经元处理任意长度的时序数据,常被用于语音识别、机器翻译、语音模型等领域<sup>[21]</sup>。RNN中神经元之间是有向环状连接,其最大的特点是具有记忆功能,进行预测时不仅依赖当前样本,也依赖之前的样本。RNN一般用于处理序列数据,能够有效地挖掘出数据中的时序信息与语义信息。常见的RNN变体包括回声状态网络(Echo State Networks)、门控神经网络(Gated Recurrent Neural Networks, GRU)、长短期记忆神经网络(LSTM)等。

(4)图神经网络(GNN)。由顶点和边组成的图是承载数据的重要载体,但其结构的不规则性以及各数据节点间的相关性难以用FCNN, CNN和RNN处理。为此,学术界提出了专门用于处理图数据的GNN。对于图结构 $G(V, E)$ ,  $V$ 代表节点集合,  $E$ 代表边集合,用连接两个节点的边来表示节点间的依赖关系。其中连接节点的边可以有向的,也可以是无向的。通过一组神经元来表示图中节点 $v$ 的状态 $h^{(v)}$ ,而节点的初始状态则为其输入特征 $x^{(v)}$ 。图中的每个节点通过接受其邻居节点的信息,来更新各自的状态,更新过程如下:

$$m_t^{(v)} = \sum_{u \in N(v)} f(h_t^{(u)}, h_{t-1}^{(u)}, e^{(u,v)})$$

$$h_t^{(v)} = g(h_t^{(v)}, m_t^{(v)})$$

其中,  $N(v)$ 代表节点 $v$ 的邻居节点,  $e^{(u,v)}$ 表示边 $e^{(u,v)}$ 的特征,  $m_t^{(v)}$ 表示第 $t$ 时刻节点 $v$ 接受的信息。应用最为广泛的GNN包括图卷积网络(Graph Convolution Networks, GCN)和图注意力网络(Graph Attention Networks)<sup>[22]</sup>。

除上述4类神经网络以外,还有一些其他类型的神经网络,如深度信念网络<sup>[23]</sup>、受限玻尔兹曼机<sup>[24]</sup>、自动编码器<sup>[25]</sup>

等。深度信念网络是一种深层的概率有向图模型,该网络由多层节点构成,相邻各层之间节点相互连接,同层节点之间没有连接,其中最顶部的两层属于无向连接,其他各层之间属于有向连接,同时网络最底层的节点被称为可观变量,其他层节点被称为隐节点。自动编码器将一组数据映射到特征空间中,从而得到每个样本的编码,之后通过这组编码重构出与原样本尽可能相似的样本。自动编码器由编码器与解码器两部分组成,该网络擅长处理没有标签的数据。受限玻尔兹曼机则是一个二分图结构的无向图模型,通过输入的数据学习概率分布。此外,实际应用中也会出现神经网络混合或叠加使用的情况,目的是能够更好地提取数据的特征。

### 3 自动调制识别

#### 3.1 问题描述

在通信系统中,调制指利用基带信号改变载波信号中某个或某几个参数,从而将基带信号的全部信息负载在载波信号上并形成调制信号的过程。无线通信的发送方通过信号调制将基带信号变换为易于传输的调制信号。接收方接收到通信信号后,根据先验知识进行信号解调,提取数据中的信息。为了实现数据的有效传输,传输的信号可以采用不同的调制方式,包括幅度键控(Amplitude Shift Keying, ASK)、相移键控(Phase Shift Keying, PSK)、正交幅度调制(Quadrature Amplitude Modulation, QAM)等。

传统的调制识别工作通常是在仪器的辅助下人工完成的,通过对接收的信号进行时域波形、频谱形状等分析,进而分辨出信号的调制方式。然而,随着信号调制方式的数量和复杂性的增加,这种人工识别的方式面临准确性、复杂性和时效性的问题,已经不再适用。因此,开发高效的 AMR 技术的需求也不断增加。AMR 指在调制信号所携带的信息内容未知的前提下,自动判断出通信信号调制方式的过程<sup>[26]</sup>。AMR 早期主要广泛应用于电子战当中,无论是信号检测,还是电磁态势感知,都需要调制识别技术的支持。近年来,随着用频设备的不断增加和用频环境的日益拥挤,AMR 在民用领域也有了广泛的应用需求。例如,在认知无线电环境中,基于 AMR 进行信号参数估计和信号解调,可以显著降低无线电干扰。

设计良好的 AMR 方法应该具有准确性高、复杂性低、时效性高、泛化性好等特性。然而,实现高性能 AMR 并非易事,挑战主要来自 3 个方面。

(1)电磁环境的复杂性。电磁环境日益拥挤,信号密度不断增强,同一信道下无论是在时域、频域还是空域上都可能出现多个待识别信号混叠的情况。多种类型的电磁信号叠加在一起时,不同信号的发射功率和频率各异,难以进行分离,无法提取干净的待识别信号。当不同信噪比信号并行传输时,不同调制类别的信号之间相互干扰,将严重影响信号识别的准确性。若按照传统方法对每一信噪比的信号进行分离并单独进行特征提取,则会导致算法泛化能力较差。

(2)调制信号的多样性。信号的调制方式复杂且多样,主要包括早期的模拟调制、单载波调制以及后期的数字调制、

多载波调制。随着通信业务量的不断增加以及频谱资源的日益紧缺,为了有效利用资源,提高频谱利用率,各类调制方式中不断产生了更多的高阶调制。然而,高阶调制信号往往更难识别,因此,多样的调制方式在提高数据传输速率的同时也加大了调制信号的识别难度。

(3)无线信道的随机性和多变性。作为信号传输的通道,无线信道的性质决定了传输信息的容量以及最终接收数据的质量。传播环境的变化,例如建筑物的遮挡、地形的高低起伏等都会造成无线信道的变化。此外,信号的空间传播带来的反射、衍射现象也会导致信号到达接收端的路径不唯一。总之,无线信道的随机、多变等特性必然会影响最终信号的调制识别。

#### 3.2 传统识别方法

传统 AMR 方法可以分为两大类:基于决策理论的似然性方法和基于统计理论的特征提取方法。

##### 3.2.1 基于决策理论的似然性方法

基于决策理论的似然性方法利用概率论、假设检验理论和决策准则来解决 AMR 问题<sup>[27]</sup>。该方法令假设检验的个数为待识别调制类型的个数,同时假设接收到的信号是离散的,信号之间满足独立同分布,信号数据用  $x[k], k=1, 2, \dots, n$  表示。假设一共包含  $m$  种调制类型,那么就有  $m$  种假设  $H_i, i=1, 2, \dots, m$ 。接收端接收到信号之后,将调制识别问题映射到概率空间,利用概率密度函数对所包含的调制类型建立似然函数,似然函数的表达式如下:

$$L(x|H_i) = \prod_{k=1}^N p(x|H_i), i=1, 2, \dots, m$$

其中,  $p(x|H_i)$  是在  $H_i$  假设下接收到信号数据  $x[k]$  的概率。最后通过计算并比较各类假设下的似然函数值,选择最大的似然函数值所对应的调制类型作为最终的分类结果<sup>[28]</sup>。Wei 等于 2000 年提出使用平均似然(Average Likelihood Ratio Test, ALRT)作为检测的似然比分类器<sup>[29]</sup>。Chavali 等于 2011 年提出采用期望最大化算法通过信道与噪声参数估计的方式对调制方式进行分类,并采用混合似然比(Hybrid Likelihood Ratio Test, HLRT)检测的方法完成调制方式的分类<sup>[30]</sup>。虽然这类方法在理论上能够满足贝叶斯最小误判准则,从而带来最佳的识别精度,但是其计算复杂度高且需要大量先验信息,因此在复杂的通信环境中实施起来比较困难,泛化能力差。

##### 3.2.2 基于统计理论的特征提取方法

采用基于统计理论的特征提取方法进行 AMR 时,主要包含两个步骤,即特征提取和模式分类。首先,确定需要提取的特征,对输入的信号进行预处理后再进行特征提取。该方法应用的特征分量类型较丰富,通常包括多种瞬时统计量特征、高阶累积量特征、小波域特征、星座图特征、各种循环谱特征等<sup>[31-35]</sup>。然后,将提取的特征分量送入训练好的基于机器学习的分类器中,完成模式识别。该方法中采取的分类器主要包括人工神经网络、决策树、支持向量机、聚类算法<sup>[36-37]</sup>等,其识别效果主要依赖于特征分量和分类器的选择。此处的特征选择通常是针对固定类型的信号展开的,因此识别精度不高且泛化能力较弱。

### 3.3 调制识别公开数据集

信号数据的获取也是 AMR 问题中一项必不可少的工作,一些文献中产生的标准数据集被广泛使用,这些公共数据集的产生使得研究者可以直接将其应用于实验,无须再收集或生成新的数据集。同时,通过使用这类数据集,便于研究人员直接与已有的工作进行比较。表 1 列出了 3 种数据集的详细信息,下文介绍了几种 AMR 中常见的公共数据集。

(1)RadioML 2016.10a<sup>[38]</sup>。该数据集是由 O'Shea 等于 2016 年通过 GNU 无线电生成的合成数据集。该数据集中共包含 220 000 条调制信号,调制方式涉及 8 种数字调制、3 种模拟调制。为了尽可能模拟实际环境,数据由模拟传播环境生成,受到了 AWGN、多径衰落、采样率偏移等的破坏。之后又产生了 RadioML 2016.10a 的扩展版本 Ra-

dioML2016.10b。RadioML2016.10b 中包含了 1 200 000 条信号,调制方式则包括去除 AM-SSB 以外的其他 10 种类型。

(2)HisarMod2019.1<sup>[39]</sup>。为了增加信号数据集的多样性,Tekbiyik 等创建了 HisarMod2019.1 新数据集,其中包含 5 种不同的调制族(模拟、FSK、PAM、PSK、QAM)组成的共 26 类调制方式,通过 5 个不同的无线通信信道,总共覆盖了 780 000 个信号。

(3)RadioML 2018.01A<sup>[40]</sup>。该数据集考虑的信号种类繁多,涵盖了广泛的单载波调制方案。其中包含了模拟信号、数字信号共 24 种。此外,O'Shea 等还考虑了几种不同的传播方案,其中包括没有合成通道损伤的干净信号下的 OTA 传输通道以及综合各种信道损伤下的无线信道。

表 1 公共数据集的介绍

Table 1 Introduction of public datasets

数据集	信噪比范围	信号长度	数量	调制方式
RadioML 2016.10a	$[-20, +18]$	128	$220 \times 10^3$	数字: BPSK, 8PSK, QPSK, CPFSK, GFSK, PAM4, QAM16, QAM64 模拟: AM-DSB, AM-SSB, WB-FM
HisarMod 2019.1	$[-20, +30]$	1024	$780 \times 10^3$	AM-DSB, AM-SC, AM-USB, AM-LSB, FM, PM, 2-FSK, 4-FSK, 8-FSK, 16-FSK, 4-PAM, 8-PAM, 16-PAM, 16-PAM, BPSK, QPSK, 8-PSK, 16-PSK, 32-PSK, 64-PSK, 4-QAM, 8-QAM, 16-QAM, 32-QAM, 64-QAM, 128-QAM, 256-QAM
RadioML 2018.01A	$[-20, +18]$	1024	$2.5 \times 10^6$	OOK, 4ASK, 8ASK, BPSK, QPSK, 8PSK, 16PSK, 32PSK, 16APSK, 32APSK, 64APSK, 128APSK, 16QAM, 32QAM, 64QAM, 128QAM, 256QAM, AM-SSB-WC, AM-SSB-SC, AM-DSB-WC, AM-DSB-SC, FM, GMSK, OQPSK

## 4 基于神经网络的自动调制识别

### 4.1 ADNN 流程描述

ADNN 提出的初衷是利用 DNN 的自动特征提取能力来提升 AMR 方法的精确性、时效性和泛化能力,并降低其设计复杂性和对专家知识的依赖程度。图 1 给出了 ADNN 的具体流程,其识别过程主要包括 4 个步骤。

(1)数据预处理。接收到信号以后,往往会对数据进行简单的预处理操作,目的是尽可能地消除数据中的噪声、信号混叠等因素对数据的不良影响,提升数据质量,便于提取到更准确的特征。当前,用于 AMR 的信号数据主要是 IQ 数据。IQ 数据指将信号的幅度与相位的信息采用两个相互正交的载波分量表示。此类数据的优势在于能够保留原始信号的相位信息,便于后续对信号特征的提取。此外,信号数据分成 I、Q 两路进行复采样,能够起到降低单个支路采样率的作用。针对这种序列数据,常见的预处理方法包括:滤波、平滑、重采样、小波变换等。也有一些工作将 IQ 数据转换为星座图<sup>[41-42]</sup>、频谱图<sup>[43-44]</sup>或信号眼图<sup>[45]</sup>等,之后利用图像处理的方式进行调制识别。

(2)数据特征提取。当专家知识可用时,通过特征提取步骤可以使 DNN 的输入数据更具辨识度,有利于提高调制方式的识别率。提取的特征主要包括:零中心归一化瞬时幅度的谱密度最大值、归一化瞬时频率绝对值的标准偏差、频谱密度的统计量等<sup>[46]</sup>。但是,ADNN 中,特征提取是可选组件,一般用于提升识别精度或降低网络复杂度。在端到端 ADNN 设计中,预处理后的数据通常被直接送往 DNN 进行训练。

(3)网络训练。将经过数据预处理和特征提取的数据作为 DNN 的输入。此处的 DNN 由选定的网络类型和超参数决定,并通过输入的数据样本和标签信息进行训练。当达到预设的迭代次数或者验证样本集上的误差足够小时,便终止训练过程,获得最终的 DNN 结构和参数。

(4)调制分类。采用训练好的 DNN 网络对无标签信号样本进行调制识别。将需要进行识别的信号样本经预处理或特征提取后,输入训练好的 DNN 中,得到识别结果。




图 1 ADNN 算法的流程

Fig. 1 Flow chart of ADNN algorithm

相比传统 AMR 方法,ADNN 方法采用神经网络的多层次结构来挖掘信号数据的深层特征,具有识别精度高的特性;同时 ADNN 方法无需大量先验知识,也不需要人工提取特征,直接进行端到端的调制识别;此外,ADNN 方法的泛化能力较强,面对程度不大的信道损伤以及更多调制类型的加入仍能表现出强有力的识别能力。

但是,ADNN 方法也存在一些问题:DNN 中涉及大量神经元以及神经元之间的相互连接,网络中的权重数目较多,导致 ADNN 方法的计算复杂度高,通常需要依赖 GPU 来完成,在资源受限的嵌入式平台上往往存在收敛困难的



## 5.2 典型方法

考虑到一些复杂的网络结构往往会带来较大的计算量,常部署跳跃连接来解决此类问题。Huynh-The 等提出了 MCNet 方法,该方法采用跳跃连接的思路,其整体结构如图 3(d) 所示<sup>[47]</sup>。该网络中设计了 3 种特定的卷积块 (Pre-block, M-block, M-block(p)), 通过不同的非对称卷积核学习时空信号相关性。卷积块的结构如图 3(e) 所示,其中 Pre-block 结构中两层平行的非对称卷积核的大小分别设置为  $3 \times 1$  和  $1 \times 3$ 。M-block 作为 MCNet 的核心,用于进一步提取更易于区分的特征,每个 M 块中包含 3 类具有不同核的卷积层,卷积核大小分别为  $3 \times 1$ 、 $1 \times 3$  和  $1 \times 1$  的卷积层被并行排列其中。在每个块输出的深度维度上,所有的特征图都被连接起来。而 M-block(p) 结构与 M-block 的不同点在于  $3 \times 1$  的卷积层之后需要执行最大池化操作,因此该结构可以看作是降维版 M-block。此外,MBNet<sup>[48]</sup>, SCGNet<sup>[49]</sup>, RefNet<sup>[50]</sup>, Chain-Net<sup>[51]</sup> 等也均在各自的网络中采用跳跃连接来组成特殊的特征学习块,进而提升识别精度。

一些研究则致力于将所设计的 ADNN 部署在资源受限的边缘计算或嵌入式平台上,这就要求模型在具备良好分类效果的同时还应具有较小的复杂度。Lin 等设计了一种小型的 VTCNN2 模型<sup>[52]</sup>,其网络结构如图 4(a) 所示。该网络采用剪枝技术优化网络的处理速度,省略了卷积滤波器。Wang 等提出了一种适用于部署在无人机辅助系统以及物联网系统上的 LightAMC 算法<sup>[53]</sup>,网络结构如图 4(b) 所示。该算法为卷积网络中每个神经元分配一个比例因子,通过比例因子选择出多余的神经元,并且最终通过修剪技术将多余的神经元删除。

上述方法均采用 IQ 数据作为网络输入。除此以外,还有一些工作将图像作为网络输入,如星座图、频谱图、信号眼图和矢量图。Huang 等提出了一种基于网格星座矩阵的

AMR 算法,该网格星座矩阵是将接收信号经过较低复杂度的预处理之后提取出来的。其设计的对比完全卷积网络 (Contrastive Fully Convolutional Network, CFCN) 的结构如图 4(c) 所示。该网络采用对比损失作为损失函数参与 CFCN 的训练<sup>[42]</sup>。Lin 等考虑到多个采样点的影响,采用一个窗口函数在星座图上进行滑动,统计落在滑动窗口内的采样点个数,根据不同区域的点密度,利用颜色条将星座图映射成不同的颜色,形成一幅具有 RGB 信息的等势星球图,然后利用该等势星球图分别在 AlexNet 和 GoogleNet 上进行了验证<sup>[54]</sup>。Xu 等提出了一种将信号的时频特性与卷积网络相结合的 TFC-CNN 调制识别算法,网络结构如图 4(d) 所示。通过短时傅里叶变换将信号数据转换为图像形式输入网络,从而同时提取信号的时域与频域特征。此外,该模型采用改变卷积核大小、加深网络结构、改进残差连接等一系列操作,在提升识别率的同时缩短了网络训练与识别时间<sup>[43]</sup>。Zha 等将信号 I、Q 两路眼图以及能够反映信号相位信息的矢量图分别作为网络输入,并提出了一种基于多端神经网络的 AMR 算法。该算法通过预处理工作,将信号的时域波形分别转化为眼图和矢量图,旨在利用不同维度的调制特性,形成信号的浅层表达,提高网络的抗噪声能力。所提出的多端网络则分三阶段进行特征提取。第一阶段对 I/Q 路眼图、矢量图分别进行  $7 \times 7$  的卷积操作、批量标准化 (Batch Normalization, BN)<sup>[55]</sup> 及最大池化操作,然后将 I、Q 两路眼图得到的特征图连接。第二阶段则采用残差结构解决退化问题,同时将两端特征图进行连接,输入第三阶段网络中。第三阶段采用全局最大池化操作降低网络参数量,随后利用 Softmax 层完成调制识别<sup>[45]</sup>,其网络结构如图 5(a) 所示。尽管将频谱图、星座图、眼图和矢量图作为输入的模型能够带来更好的分类效果,但是数据转换、存储等操作将会增加资源开销。

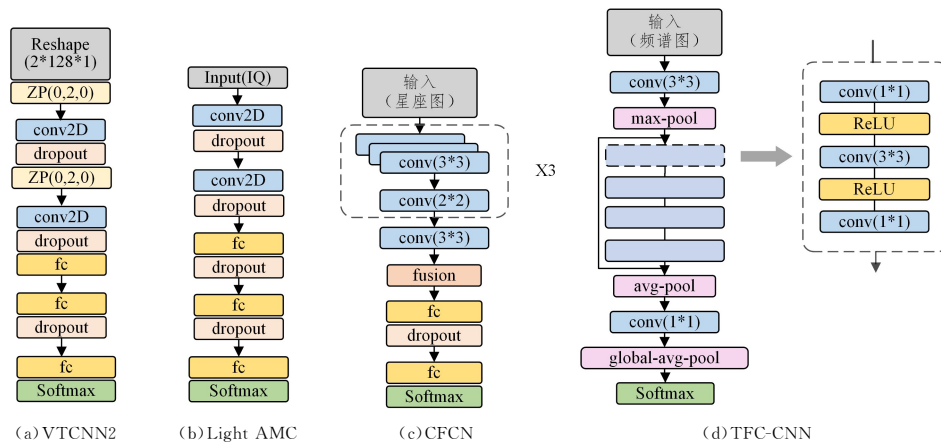
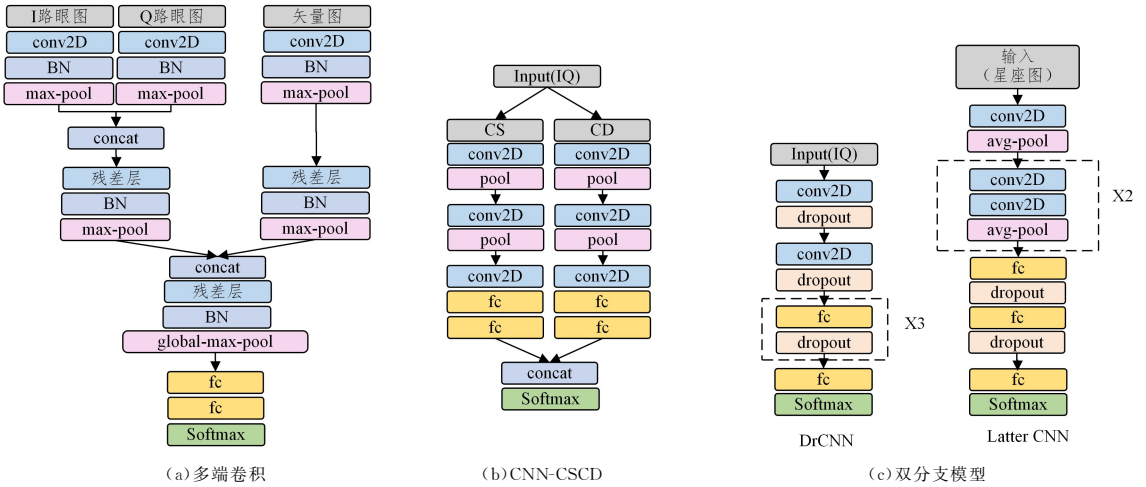


图 4 基于 CNN 的 AMR 模型

Fig. 4 CNN-based AMR model

分级架构也常被用于 AMR 中。Wu 等提出了一种基于卷积网络的多特征融合识别方法,该网络结构如图 5(b) 所示。该模型建立了双分支的 CNN-CSCD 网络,调制信号经过转换分别以循环谱和星座图的形式输入到 CNN 中,最后将二者学习到的特征通过特征融合机制在网络末端进行融合<sup>[56]</sup>。Wang 等同样提出了一种具有两个分类器的分级结构,网络结构如图 5(c) 所示。该模型包含

DrCNN 和 Latter CNN 两部分,主要用于区分相同调制类别的不同调制阶数。DrCNN 采用 CNN 作为分类器,利用 IQ 样本进行输入,实现组间识别; Latter CNN 利用具有密度窗的星座图作为网络输入,实现 QAM16 与 QAM64 的分类<sup>[57]</sup>。此类融合结构的网络最终通过加权平均的方式计算多输入多输出的分类分值,由此判断最终的调制方式的类别。



注: conv2D 表示二维卷积层; dropout 表示随机失活层; pool 表示池化层; avg-pool 表示平均池化层; BN 表示批量标准化; max-pool 表示最大池化层; global-max-pool 表示全局最大池化层; fc 表示全连接层; add 表示元素添加层; con-cat 表示深度连接层

图 5 基于 CNN 的 AMR 模型

Fig. 5 CNN-based AMR model

## 6 非卷积 ADNN 方法

### 6.1 基于 RNN 的 AMR 方法

IQ 数据包含了一定的时序信息,但 CNN 网络通常无法很好地捕获这些信息,因此学术界提出了基于 RNN 的 AMR 方法,旨在利用 RNN 善于提取时序信息与语义信息的优势进行调制识别。最常采用的 RNN 结构是 LSTM,其内部结构如图 6(b)所示。LSTM 网络主要通过学习输入的序列数据之间的时序关系,来分辨出信号的调制方式。LSTM 网络层数的设定是网络设计过程中重点考虑的问题,合适深度的网络有利于更进一步地挖掘信号数据的深层次特征;然而,当网络层数过多时,网络训练的参数也会随之增加,带来更高的时间复杂度,进而影响算法的性能<sup>[58]</sup>。

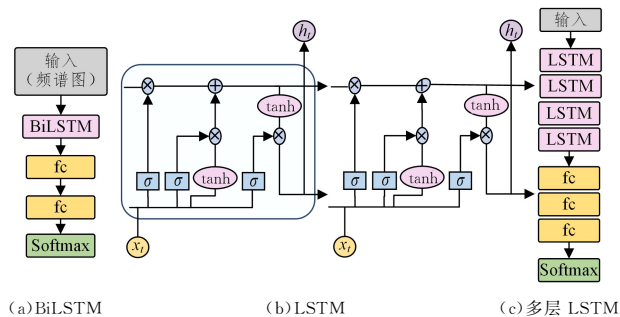


图 6 LSTM 的内部结构以及基于 RNN 的 AMR 方法

Fig. 6 Internal structure of LSTM and RNN-based AMR method

Peng 等提出了基于双向 LSTM 网络进行 AMR 的算法。首先,通过短时傅里叶变换对数据信号进行特征提取,同时针对变换后的频谱图进行一定程度的降维操作,从而减少网络运算量并缩短训练时间。经过处理后的时频分布谱被输入到 BiLSTM 网络中进行训练,最终完成调制方式识别,其结构如图 6(a)所示。相比单向 LSTM, BiLSTM 中加入了反向输入序列,通过融合正向与反向两者的结果共同决定网络的输出,可以学习更深层的特征<sup>[59]</sup>。Zha 等采用多层 LSTM 级联的网络来完成卫星信号调制识别与解调的联合任务。该网络由

4 个 LSTM 单元、3 个全连接层以及最后的 Softmax 层组成。网络中的 4 个 LSTM 单元用于充分提取信号特征信息,后 3 层的全连接结构用于对特征进行加权处理,并且将输出交给最后的 Softmax 层,用于判断调制方式的类型<sup>[60]</sup>。其结构如图 6(c)所示。此外,通过添加新的调制方式,测试了网络的可扩展性。

### 6.2 基于混合神经网络的 AMR 方法

混合神经网络方法指将两种甚至两种以上的网络混合在一起,形成新的网络来进行调制方式的自动识别。该方法的优点在于能够结合不同网络的优势,多方位提取信号数据的特征,形成更好的特征表达,进而提高网络的识别率。Sainath 等于 2015 年提出的卷积、长短时记忆、完全连接的深度神经网络(Convolutional Long Short-Term Deep Neural Network, CLDNN),不仅能够提取数据的空间信息,还可以提取出相应的时间信息。混合神经网络已经在很多领域被使用,CLDNN 网络最早应用于语音识别领域,该网络由 CNN, LSTM 和 DNN 这 3 种网络融合而成,网络结构如图 7(a)所示。融合之后的网络不仅善于提取数据的频域特征,而且因为 LSTM 的加入,能够更好地提取信号的时域特征。

Yang 采用改进版的 CLDNN 网络进行调制方式的识别,网络模型如图 7(b)所示。模型中使用原始信号、信号 4 次方谱和信号包络谱 3 种形式作为网络的输入,并将其分别输入到 3 个 CLDNN 模型中进行特征提取。之后将提取的特征送入单独的分类网络中进行调制识别<sup>[61]</sup>。Zhang 等联合使用复值卷积网络与 LSTM 网络来提取数据的时空特征<sup>[62]</sup>。该网络采用图像作为输入,其结构如图 7(c)所示。首先,采用短时离散傅里叶变换将原本的一维信号数据转换成三维频谱图作为网络输入,接着将频谱图生成的三维矩阵送入实虚处理块单元,将其转换为实部、虚部实值矩阵,转换后的矩阵经过两层复值卷积层与两层平均池化层,提取到多维度的特征,接着连接级联式双向 LSTM 层,进一步提取数据的更高维度特征。最后,将提取的信息送入全连接层进行加权操作,并使用 Softmax 层进行分类。Zhang 等提出了基于 CNN-LSTM

特征交互的双分支 AMR 算法,分别利用 IQ, AP 数据(具有振幅、相位信息)作为输入。双分支中的网络均由卷积核大小分别为  $1 \times 3, 2 \times 3, 1 \times 3$  的 3 个卷积层以及两层 LSTM 串联而成。之后将两类表示中提取出来的不同特征通过融合机制

进行交互,最终经过 Softmax 层完成分类<sup>[63]</sup>。Njoku 等提出了 CGDNet 模型,将 CLDNN 中的 LSTM 单元替换为参数量更少、更擅长以较低计算复杂度学习时序数据的 GRU 单元,并在 CNN 模块中加入了跳跃连接<sup>[64]</sup>。

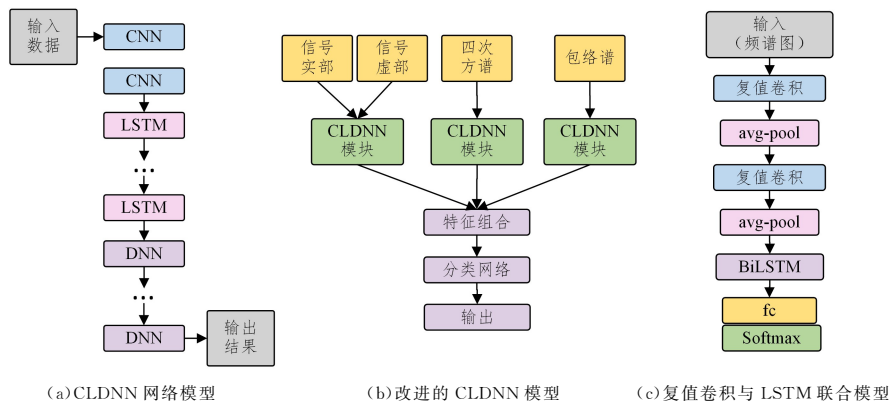


图 7 基于混合神经网络的 AMR 方法

Fig. 7 AMR methods based on hybrid neural network

### 6.3 基于 GNN 的 AMR 方法

在典型的 GCN 分类问题中,每个网络的输入图都是由带有标记与未标记的节点组成,GCN 通过汇集标记节点的信息来对未标记节点进行分类。然而,将该方法应用于调制识别时会面临数据不匹配的问题。调制信号不同于图形数据,无法直接使用 GCN 进行调制识别,因此需要进行数据的转换。

Liu 等将数据分成多个子集,选择一些标记和未标记的信号来生成每张图,其流程包括 3 个部分:特征提取 CNN (FECNN)、图形映射 CNN (GMCNN) 和图卷积 (GCN)。FECNN 采用由 2 个卷积层以及 1 个全连接层组成的 CNN 来完成特征提取任务。提取信号特征后,需要将每个子集映射到一个图  $G(V, E)$  中,使用 GMCNN 来测量子集内每两个信号之间的差异,并输出一个图形。最后,将得到的图形输入到 2 层 GCN 中,获得子集内未标记信号的特征向量,并通过 Softmax 函数映射到最终的分类,完成对未标记信号调制方式的预测<sup>[65]</sup>。

## 7 实验对比及未来研究方向

### 7.1 实验分析

#### 7.1.1 实验设置

实验采用的调制数据集是在调制识别中应用广泛的 RadioML2016, 10a<sup>[38]</sup>。在该数据集上,本文实现并测试了 10 种典型的 ADNN 结构,具体包括:由 3 个全连接层组成的 FCNN, 4 种典型 CNN 架构、基于 LSTM 的 ADNN、4 种基于混合神经网络的 ADNN。其中,4 种 CNN 架构分别为:包含 5 个卷积层的 AlexNet<sup>[66]</sup>、包含 18 个卷积层的 ResNet<sup>[66]</sup>、包含 19 个卷积层的 VGG<sup>[66]</sup> 和包含 2 个卷积层的 VT\_CNN2<sup>[66]</sup>。4 种基于混合神经网络方法的模型包括:CNN\_LSTM<sup>[66]</sup>、CLDNN<sup>[66]</sup>、GCN<sup>[67]</sup> 和 CNN\_LSTM\_attention<sup>[66]</sup>。CNN\_LSTM 与 CNN\_LSTM\_attention 均由 3 层提取空间特征的卷积层和 3 层提取时间特征的 LSTM 层构成,而 CNN\_LSTM\_attention 则通过额外嵌入注意力机制来选择数据中的显著特征。

实验中,不进行数据预处理和特征选择,将 70% 的数据用于训练,将 30% 的数据用于验证,学习率设置为 0.0001,训练的 epoch 设置为 2000, batch size 设置为 1024。所有实验均在 NVIDIA GeForce RTX3090 的计算机上进行;编程环境是 Keras。

#### 7.1.2 结果分析

图 8 给出了 10 种 ADNN 在不同信噪比下的总体识别率。可以看出,信噪比过低时,ADNN 的分类效果普遍较差,且 ADNN 的分类效果会随着信噪比的增加而提高。当信噪比低于 -10 dB 时,各类模型的识别率均不足 30%,分类效果较差,这主要是因为低信噪比条件下,信号中的噪声比例较大,不同调制信号之间的差异较为模糊,各类模型提取的特征不够准确,导致识别率低。随着信噪比的增加,识别率提升显著。在信噪比高于 6 dB 的条件下,CNN\_LSTM\_attention, LSTM, VGG, VT\_CNN2, AlexNet 这 5 类模型的识别率均能达到 80% 以上。其中,表现最好的是 CNN\_LSTM\_attention, 在信噪比为 0 dB 时,识别率可以达到 82%。这是因为混合神经网络可以更好地提取 IQ 信号中包含的时序信息,而注意力机制则进一步增强了 ADNN 提取显著特征的能力。

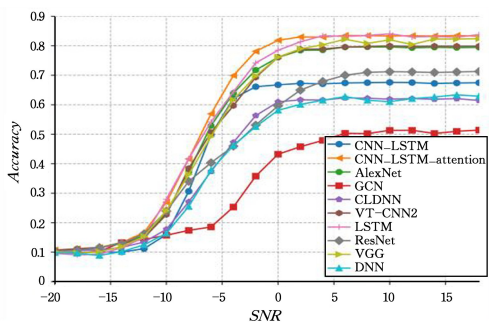


图 8 不同信噪比下 10 种 ADNN 的识别精度

Fig. 8 Accuracy of 10 ADNNs with different SNRs

#### 7.1.3 综合对比分析

图 9 给出了 VGG, LSTM, ResNet 和 VT\_CNN2 这 4 种 ADNN 在信噪比为 18 dB 时的混淆矩阵。混淆矩阵中对角线

上的值对应于各调制方式识别的准确率。通过观察混淆矩阵可以发现,两种模型的识别率较差的情况均出现在模拟调制 WB-FM 以及 QAM16 与 QAM64 上。对于 QAM 而言,识别

率低的原因是模型常常将 QAM16 与 QAM64 混淆,由此表明这些模型在区分同调制类别不同阶数的调制方式时能力较弱,网络对于幅度相位相联合的特征提取较为困难。

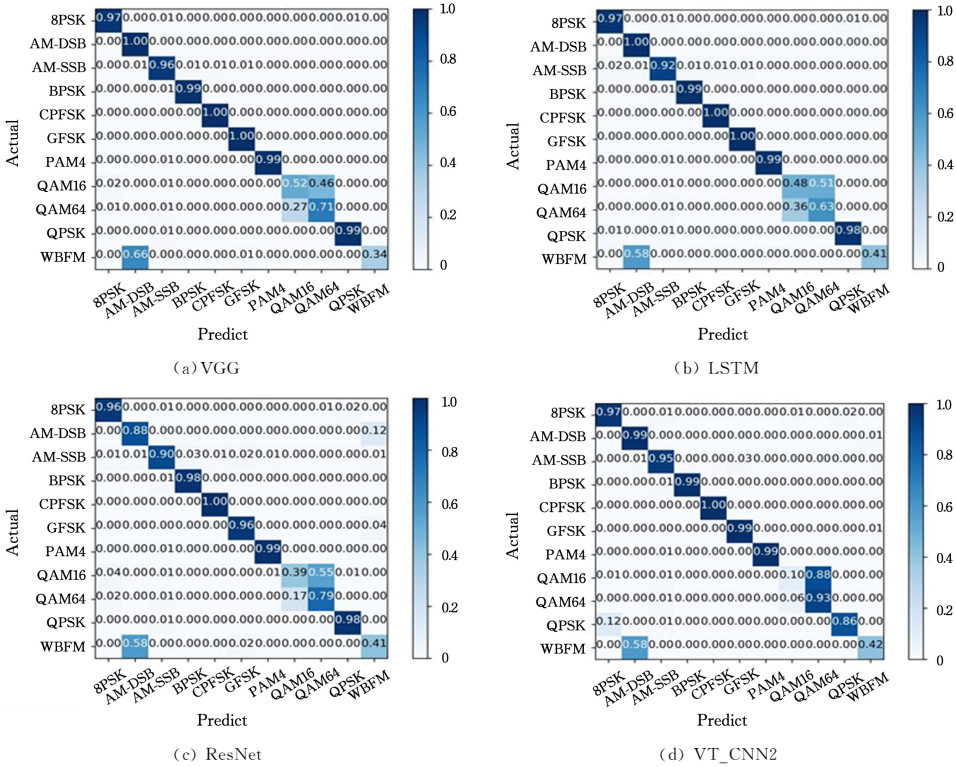


图 9 信噪比为 18 dB 下调制识别数据的混淆矩阵

Fig. 9 Confusion matrix of modulation recognition data with a SNR of 18 dB

观察基于卷积网络方法的 4 种模型可以发现,拥有 19 个卷积层的 VGG 网络表现最佳,识别率最高可以达到 84.45%,具备 18 个卷积层的 ResNet 网络表现最差,而卷积层数较少的 AlexNet 与 VT\_CNN2 表现中等。由当前结果可以发现,基于卷积网络的方法中卷积层数的多少对模型的分

LSTM\_attention 在所有信噪比下都具有更高的识别率,并且当信噪比高于 -2 dB 时,两者的识别率差异明显。因此可以推断,注意力机制的加入能够显著增强模型提取特征的能力,从而带来更好的分类效果。此外,选取了识别效果最好的 VGG 与 CNN\_LSTM\_attention 网络,在信噪比为 18 dB 的情况下绘制出其在不同调制方式下的识别率的曲线图,如图 10 所示。

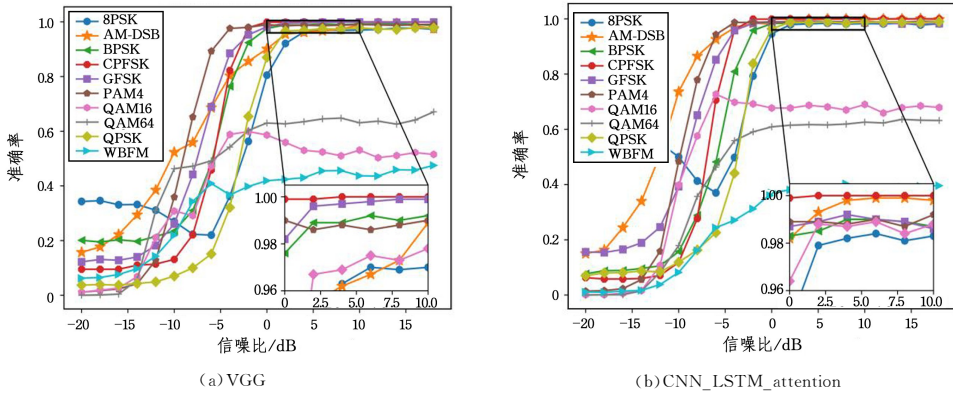


图 10 信噪比为 18 dB 下两类网络不同调制方式的识别精度

Fig. 10 Recognition accuracy of different modulation modes in two types of networks with a SNB of 18 dB

从图 10 可以看出,不同调制方式的识别率之间存在显著差别。多数调制方式的识别率接近 100%;QAM16, QAM64 和 WBFM 这 3 种调制方式的识别精度较低。结合混淆矩阵可以发现,这是因为 QAM16 和 QAM64 经常被神经网络错

分,从而降低了二者的识别率。WBFM 则经常被错分为 AM-DSB,从而导致精度降低。

### 7.2 未来的研究方向

通过上述分析可知,近年来 ADNN 研究领域已经取得

较大的研究进展。然而,AMR任务中仍然存在很多问题值得进一步研究。在未来的工作中,重点关注的方向包括如下几个方面。

(1)低信噪比情况下的精度提升问题。不难发现,在低信噪比情况下,噪声的干扰导致ADNN的识别精度普遍很低<sup>[68]</sup>,这主要是由于较大的噪声掩盖了不同调制方式之间的区别。为此,一些研究者尝试在数据预处理和特征选择阶段降低噪声带来的干扰,以提高识别精度。例如,Li等采用LRR去噪算法,在数据预处理阶段对循环谱图像执行去噪操作<sup>[69]</sup>。但总的来说,低信噪比情况下的结果与理想结果相去甚远,这也是未来研究的重点问题之一。

(2)信号混叠场景下的ADNN设计。日益复杂的电磁环境下,常常会出现同一频带中多个窄带信号混叠的情况,这种混叠情况在时域、频域、空域上都可能存在,并且用信源分离方法很难进行分离<sup>[70]</sup>。针对这种情况,Xue采用胶囊网络完成信号并存情况下的调制识别任务,最终将不固定的混叠信号数量提升到3种<sup>[71]</sup>。同时,有相关文献采用将其他调制方式信号视为干扰以识别主要信号的方法来解决此问题。然而,此类工作大多需要一些先验知识,如信号混叠情况、混叠的类别、信号数量等。总体而言,直接采用神经网络对混叠信号提取特征分类的研究还较少,需要重点关注。

(3)小样本、零样本场景下的数据增强。在复杂的通信环境中,信号的收集工作并不容易并且信号数据也极易受到干扰,这就导致实际的可用数据样本不足。然而,神经网络强大的提取特征的功能离不开大量数据样本的训练,没有数量充足的数据支撑,训练出来的网络效果不佳,无法充分表达数据的信号特征,这将影响信号调制方式的识别精度。因此,对信号调制识别中的小样本数据扩充问题的研究也具有重大意义。目前,Ma等利用生成对抗网络来生成新的样本,并且保证新样本能够拟合原样本,从而达到丰富数据集的作用<sup>[72]</sup>。未来,需围绕此问题开展更深入的研究。

(4)对抗样本带来的安全性问题。目前调制信号识别问题的主要关注点都集中在识别精度上,对于对抗样本所带来的安全威胁关注得较少。DL的可解释性较差,这将导致基于DL的AMR模型容易受到对抗样本的干扰。通常,一个细微的扰动都能够瞒住性能良好的网络模型,从而导致调制识别的分类结果产生错误,这将带来调制识别任务中的安全性问题。Lin等将基于标签计算梯度的传统对抗方法应用到ADNN对抗中,显著降低了ADNN的识别精度<sup>[73]</sup>。Wang等则提出了另一种基于特征梯度攻击的方法,针对模型提取到的时空特征进行有效攻击,实验证明该方法的攻击效果以及迁移性相比标签梯度攻击表现更佳<sup>[74]</sup>。此外,Lin等进一步评估对抗样本对基于CNN的AMR任务的攻击效果,对比了多种对抗样本生成算法对CNN的伪装效果。通过重构波形,证明了调制信号中对抗攻击的可行性。然而,目前仅仅只能证明调制识别问题容易受到对抗样本的

攻击<sup>[75]</sup>。下一步,设计针对ADNN的攻击和防御方法是研究的重点。

(5)增量学习场景下的ADNN设计。增量学习能够较好地解决灾难性遗忘问题,即网络模型在处理新知识的同时能够保证模型之前学习的旧知识不被干扰、遗忘,甚至能够达到在了解新知识的同时优化模型,从而学习旧知识。对于调制信号而言,新的调制方式将不断出现,因此ADNN方法不仅要能够识别已知的调制方式,同时还需要能够识别新的调制方式。将增量学习应用于调制识别能够解决随着数据类别增加而导致模型更新的问题。Yang等提出了一种基于增量学习的AMR方法,该方法允许通过类增加的方式持续学习,新的类可以通过一个连续的数据流逐步添加到现有模型中,初步验证了其可行性<sup>[76]</sup>。之后,增量学习的ADNN设计值得更深入的探索。

(6)ADNN模型部署在嵌入式平台。当前ADNN设计的关注点在于识别性能,对ADNN本身的计算和存储复杂性关注不足。事实上,在以FPGA和ARM等嵌入式平台为主的通信设备上,部署计算复杂度高的ADNN模型往往会面临资源不足、计算时间过长等问题。当前,将神经网络裁剪等技术应用到ADNN的设计中已有初步探索<sup>[77]</sup>,这也是该领域下一步研究的重点之一。

(7)大规模公开数据集采集。如7.3.3节所述,当前学术界已经发布了一些公开数据集,但此类数据集普遍规模较小,并且仅通过信噪比来反映复杂的无线通信场景,难以体现自动调制识别的复杂性,同时较少涉及复杂的通信信号识别问题。采集并公开发布大规模、高逼真、易使用的公开数据集也是未来的重点工作之一。

**结束语** AMR任务对于非合作通信场景下的频谱感知、理解和利用非常关键。本文系统地总结了ADNN问题的研究现状,着重总结和介绍了4类ADNN设计及其典型方案,并给出了其网络结构和优缺点分析。在公开数据集上,对10种典型的ADNN方法进行了综合分析对比,指出了未来需要重点研究的7个方向。希望本文能够为学术界和工业界的读者提供参考,并推动ADNN领域的进一步研究和创新。

## 参 考 文 献

- [1] LIANG Y C, TAN J J, DUSIT N. Overview on Intelligent Wireless Communication Technology [J]. Journal on Communications, 2020, 41(7): 1-17.
- [2] SU W, XU J L, ZHOU M. Real-time modulation classification based on maximum likelihood [J]. IEEE Communications Letters, 2008, 12(11): 801-803.
- [3] DOBRE O A, ABDI A, BAR-NESS Y, et al. Survey of automatic modulation classification techniques: classical approaches and new trends [J]. IET Communications, 2007, 1(2): 137-156.
- [4] ALBAWI S, MOHAMMED T A, AL-ZAWI S. Understanding of a convolutional neural network [C] // 2017 International Conference on Engineering and Technology (ICET). IEEE, 2017: 1-6.

- [5] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural computation*, 1997, 9(8): 1735-1780.
- [6] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model [J]. *IEEE Transactions on Neural Networks*, 2008, 20(1): 61-80.
- [7] GOODFELLOW I, BENGIO Y, COURVILLE A. Machine Learning Basics [J]. *Deep Learning*, 2016, 1(7): 98-164.
- [8] YOUNG T, HAZARIKA D, PORIA S, et al. Recent Trends in Deep Learning Based Natural Language Processing [J]. *IEEE Computational Intelligence Magazine*, 2018, 13(3): 55-75.
- [9] MASITA K L, HASAN A N, SHONGWE T. Deep Learning in Object Detection: a Review [C] // 2020 International Conference on Artificial Intelligence, Big Data, Computing and Data Communication Systems (icABCD). IEEE, 2020: 1-11.
- [10] COVINGTON P, ADAMS J, SARGIN E. Deep Neural Networks for YouTube Recommendations [C] // Proceedings of the 10th ACM Conference on Recommender Systems. ACM, 2016: 191-198.
- [11] ZHANG X H, CAO X W. On Military Assistant Decision Based on Deep Learning [J]. *Fire Control & Command Control*, 2020, 45(3): 1-6.
- [12] LECUN Y, BENGIO Y, HINTON G. Deep Learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [13] VARA P, D'SOUZAKEVIN B, BHARGAVAVIJAY K. A Downscaled Faster-RCNN Framework for Signal Detection and Time-frequency Localization in Wideband RF Systems [J]. *IEEE Transactions on Wireless Communications*, 2020, 19(7): 4847-4862.
- [14] HE Z W, HOU S, ZHANG W C, et al. Multi-feature fusion classification method for communication specific emitter identification [J]. *Journal on Communications*, 2021, 42(2): 103-112.
- [15] CYBENKO G. Approximation by superpositions of a sigmoidal function [J]. *Mathematics of Control, Signals and Systems*, 1989, 2(4): 303-314.
- [16] DAYAN P, ABBOTT L F. Theoretical neuroscience: computational and mathematical modeling of neural systems [M]. Cambridge: MIT Press, 2001.
- [17] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 1-9.
- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. *arXiv: 1409. 1556*, 2014.
- [19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778.
- [20] TAN M, LE Q V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks [C] // 2019 International Conference on Machine Learning. ICML, 2019: 6105-6114.
- [21] LIU W B, WANG Z D, LIU X H, et al. A survey of deep neural network architectures and their applications [J]. *Neurocomputing*, 2017, 234(234): 11-26.
- [22] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(1): 4-24.
- [23] CHEN Y, ZHAO X, JIA X. Spectral-spatial classification of hyperspectral data based on deep belief network [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2381-2392.
- [24] FISCHER A, IGEL C. Training restricted Boltzmann machines: An introduction [J]. *Pattern Recognition*, 2014, 47(1): 25-39.
- [25] NG A. Sparse autoencoder [J]. *CS294A Lecture notes*, 2011, 72: 1-19.
- [26] MA Z Y, HAN F L, XIE Z D, et al. Modulation recognition technology of satellite communication signal system [J]. *Acta Aeronautica et Astronautica Sinica*, 2014, 35(12): 3403-3414.
- [27] PANAGIOTOU P, ANASTASOPOULOS A, POLYDOROS A. Likelihood ratio tests for modulation classification [C] // 21st Century Military Communications. Architectures and Technologies for Information Superiority (Cat. No. 00CH37155) (MIL-COM 2000). IEEE, 2000: 670-674.
- [28] HUAN C Y, POLYDOROS A. Likelihood methods for MPSK modulation classification [J]. *IEEE Trans. Commun.*, 1995, 43(2): 1493-1504.
- [29] WEN W, MENDEL J M. Maximum-likelihood classification for digital amplitude-phase modulations [J]. *IEEE Trans. Commun.*, 2000, 48(2): 189-193.
- [30] CHAVALI V G, DA SILVA C R C M. Maximum-Likelihood Classification of Digital Amplitude-Phase Modulated Signals in Flat Fading Non-Gaussian Channels [J]. *IEEE Transactions on Communications*, 2011, 59(8): 2051-2056.
- [31] POPOOLA J J, OLST R V. A Novel Modulation-Sensing Method [J]. *IEEE Vehicular Technology Magazine*, 2011, 6(3): 60-69.
- [32] PARK C S, JANG W, NAH S P, et al. Automatic Modulation Recognition using Support Vector Machine in Software Radio Applications [C] // The 9th International Conference on Advanced Communication Technology. IEEE, 2007: 9-12.
- [33] ASLAM M W, ZHU Z, NANDI A K. Automatic Modulation Classification Using Combination of Genetic Programming and KNN [J]. *IEEE Transactions on Wireless Communications*, 2012, 11(8): 2742-2750.
- [34] PARK C S, CHOI J H, NAH S P. Automatic Modulation Recognition of Digital Signals using Wavelet Features and SVM [C] // 2008 10th International Conference on Advanced Communication Technology. IEEE, 2008: 387-390.
- [35] DAS D, ANAND A, BORA P K, et al. Cumulant based automatic modulation classification of QPSK, OQPSK,  $\pi/4$ -QPSK and 8-PSK in MIMO environment [C] // 2016 International Conference on Signal Processing and Communications (SPCOM). IEEE, 2016: 1-5.
- [36] XU Y, GE L, BO W. Digital Modulation Recognition Method

- Based on Self-Organizing Map Neural Networks[C]//2008 4th International Conference on Wireless Communications, Networking and Mobile Computing. IEEE,2008:1-4.
- [37] ORLIC V D, DUKIC M L. Multipath channel estimation algorithm for automatic modulation classification using sixth-order cumulants[J]. *Electronics Letters*,2010,46(19):1348-1349.
- [38] RF Datasets For Machine Learning[OL]. <https://www.deepsig.ai/datasets>.
- [39] TEKBIYIK K, EKTİ A R, GÖRÇİN A, et al. Robust and Fast Automatic Modulation Classification with CNN under Multipath Fading Channels[C]//2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring). IEEE,2020:1-6.
- [40] 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.
- [41] 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.
- [42] HUANG S, JIANG Y, GAO Y, et al. Automatic Modulation Classification Using Contrastive Fully Convolutional Network[J]. *IEEE Wireless Communication Letters*,2019,8(4):1044-1047.
- [43] XU M, HOU J, WU P J, et al. Convolutional Neural Networks Based on Time-Frequency Characteristics for Modulation Classification[J]. *Computer Science*,2020,47(2):175-179.
- [44] ZENG Y, ZHANG M, HAN F, et al. Spectrum Analysis and Convolutional Neural Network for Automatic Modulation Recognition[J]. *Wireless Communications Letters IEEE*,2019,8(3):929-932.
- [45] ZHA X, PENG H, QIN X, et al. Modulation Recognition Method Based on Multi-inputs Convolution Neural Network[J]. *Journal of Communications*,2019,40(11):30-37.
- [46] YI Y Q, LV L Q, LU Y Y, et al. Complex Signal Type Modulation Recognition Technology Based on Neural Network[J]. *Electronic Information Warfare Technology*,2020,35(6):16-21.
- [47] HUYNH-THE T, HUA C H, PHAM Q V, et al. MCNet: An Efficient CNN Architecture for Robust Automatic Modulation Classification[J]. *IEEE Communications Letters*,2020,24(4):811-815.
- [48] TUNZE G B, HUYNH-THE T, LEE J M, et al. Multi-shuffled Convolutional Blocks for Low-complex Modulation Recognition[C]//2020 International Conference on Information and Communication Technology Convergence (ICTC). IEEE,2020:939-942.
- [49] 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.
- [50] HUYNH-THE T, HUA C H, DOAN V S, et al. Accurate Modulation Classification with Reusable-Feature Convolutional Neural Network[C]//2020 IEEE Eighth International Conference on Communications and Electronics (ICCE). IEEE,2021:12-17.
- [51] HUYNH-THE T, DOAN V S, HUA C H, et al. Chain-Net: Learning Deep Model for Modulation Classification Under Synthetic Channel Impairment[C]//2020 IEEE Global Communications Conference(GLOBECOM 2020). IEEE,2020:1-6.
- [52] LIN Y, TU Y, DOU Z. An Improved Neural Network Pruning Technology for Automatic Modulation Classification in Edge Devices[J]. *IEEE Transactions on Vehicular Technology*,2020,69(5):5703-5706.
- [53] WANG Y, YANG J, LIU M, et al. LightAMC: Lightweight Automatic Modulation Classification via Deep Learning and Compressive Sensing[J]. *IEEE Transactions on Vehicular Technology*,2020,69(3):3491-3495.
- [54] LIN Y, TU Y, DOU Z, et al. Contour Stella Image and Deep Learning for Signal Recognition in the Physical Layer[J]. *IEEE Transactions on Cognitive Communications and Networking*,2021,7(1):34-46.
- [55] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//International Conference on International Conference on Machine Learning. JMLR,2015:448-456.
- [56] WU H, LI Y, ZHOU L, et al. Convolutional neural network and multi-feature fusion for automatic modulation classification[J]. *Electronics Letters*,2019,55(16):895-897.
- [57] 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.
- [58] GREFF K, SRIVASTAVA R K, KOUTNİK J, et al. LSTM: A Search Space Odyssey[J]. *IEEE Transactions on Neural Networks & Learning Systems*,2016,28(10):2222-2232.
- [59] PENG C X, CHENG W, LI X B, et al. Method of Modulation Recognition for Communication Signals Based on STFT-BiLSTM[J]. *Journal of Air Force Early Warning Academy*,2020,34(1):39-45.
- [60] ZHA X, PENG H, QIN X, et al. Satellite Amplitude-Phase Signals Modulation Identification and Demodulation Algorithm Based on the Cyclic Neural Network[J]. *Acta Electronica Sinica*,2019,47(11):2443-2448.
- [61] YANG J. Research on Modulation Recognition for Communication Signals Based on Deep Learning[D]. Changsha: National University of Defense Technology,2018.
- [62] ZHANG B, LIU K, ZHAO M W. Deep Learning Modulation Recognition Algorithm Based on Time-frequency Analysis[J]. *Industrial Control Computer*,2020,33(5):66-68,71.
- [63] ZHANG Z, LUO H, WANG C, et al. Automatic Modulation

- Classification Using CNN-LSTM Based Dual-Stream Structure [J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(11): 13521-13531.
- [64] NJOKU J N, MOROCHO-CAYAMCELA M E, LIM W. CGD-Net: Efficient Hybrid Deep Learning Model for Robust Automatic Modulation Recognition [J]. *IEEE Networking Letters*, 2021, 3(2): 47-51.
- [65] LIU Y, LIU Y, YANG C. Modulation Recognition With Graph Convolutional Network [J]. *IEEE Wireless Communication Letters*, 2020, 9(5): 624-627.
- [66] Automatic modulation recognition based on deep learning [OL]. <https://github.com/wzjialang/Automatic-modulation-recognition-based-on-deep-learning>.
- [67] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional Radio Modulation Recognition Networks [C] // *Engineering Applications of Neural Networks (EANN 2016)*. Springer, 2016: 213-226.
- [68] CHEN J Y, CHENG K H, ZHENG H B. Deep Learning Based Modulation Recognition Method in Low SNR [J]. *Computer Science*, 2020, 47(S1): 283-288.
- [69] LI R, LI L, YANG S, et al. Robust Automated VHF Modulation Recognition Based on Deep Convolutional Neural Networks [J]. *IEEE Communications Letters*, 2018, 22(5): 946-949.
- [70] WEI S, KOSINSKI J A, MING Y. Dual-use of Modulation Recognition Techniques for Digital Communication Signals [C] // *2006 IEEE Long Island Systems, Applications and Technology Conference*. IEEE, 2006: 1-6.
- [71] XUE Y H. Automation modulation recognition of the communication signals based on deep learning [D]. Harbin: Harbin Institute of Technology, 2020.
- [72] MA X B, ZHANG B N, GUO D X, et al. Modulation Recognition of Digital Communication Signals under Small Sample Conditions [J]. *Communications Technology*, 2020, 53(11): 2641-2646.
- [73] LIN Y, ZHAO H, TU Y, et al. Threats of Adversarial Attacks in DNN-Based Modulation Recognition [C] // *IEEE Conference on Computer Communications*. IEEE, 2006: 2469-2478.
- [74] WANG C, WEI X L, TIAN Q, et al. Feature Gradient-based Adversarial Attack on Modulation Recognition-oriented Deep Neural Networks [J]. *Computer Science*, 2021, 48(7): 25-32.
- [75] LIN Y, ZHAO H, MA X, et al. Adversarial Attacks in Modulation Recognition With Convolutional Neural Networks [J]. *IEEE Transactions on Reliability*, 2021, 70(1): 389-401.
- [76] YANG Y, CHEN M, WANG X Y, et al. Modulation Recognition based on Incremental Deep Learning [C] // *2020 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE)*. IEEE, 2020: 1701-1705.
- [77] ZHANG S C, LIN Y, TU Y, et al. Electromagnetic signal modulation recognition technology based on lightweight deep neural network [J]. *Journal on Communications*, 2020, 41(11): 12-21.



**JIAO Xiang**, born in 1997, postgraduate. Her main research interests include deep learning and modulation recognition.



**WEI Xiang-lin**, born in 1985, Ph.D, associate research fellow. His main research interests include edge computing, deep learning and wireless network security.

(责任编辑:喻黎)