



专题：通信与 AI 融合

## 基于深度学习的调制识别综述

孙姝君<sup>1</sup>, 彭盛亮<sup>1</sup>, 姚育东<sup>2</sup>, 杨喜<sup>3</sup>

- (1. 华侨大学信息科学与工程学院, 福建 厦门 361021;  
2. 史蒂文斯理工学院电子与计算机工程系, 美国 新泽西州 霍博肯 07030;  
3. 吉首大学信息科学与工程学院, 湖南 吉首 416000)

**摘要:** 调制识别是通信系统的基础任务之一, 在认知无线电、智能通信、无线电监管、电子对抗等领域均有着广泛的应用。近年来, 基于深度学习的调制识别技术以其在特征提取和识别性能方面的优势, 日益成为研究的焦点。系统地梳理了基于深度学习的调制识别技术, 首先介绍了相关基础, 随后详细阐述了其系统架构、数据预处理方式、深度神经网络结构、常用数据集以及评价指标, 最后分析展望了该技术未来的发展方向。

**关键词:** 深度学习; 调制识别; 数据预处理; 深度神经网络

中图分类号: TN929

文献标识码: A

doi:10.11959/j.issn.1000-0801.2021114

## A survey of deep learning based modulation recognition

SUN Shujun<sup>1</sup>, PENG Shengliang<sup>1</sup>, YAO Yudong<sup>2</sup>, YANG Xi<sup>3</sup>

1. College of Information Science and Engineering, Huaqiao University, Xiamen 361021, China  
2. Department of Electrical and Computer Engineering, Stevens Institute of Technology, Hoboken NJ 07030, USA  
3. College of Information Science and Engineering, Jishou University, Jishou 416000, China

**Abstract:** Modulation recognition is one of the fundamental tasks for communications systems, which can be widely applied in various fields, such as cognitive radio, intelligent communications, radio surveillance, electronic warfare, etc. In recent years, deep learning (DL) based modulation recognition has attracted great attention due to its superiority in feature extraction and recognition performance. The techniques of DL based modulation recognition were systematically summarized. Firstly, some knowledge relevant to DL based modulation recognition was introduced. Then, the system architecture, data pre-processing methods, deep neural network structures, prevalent datasets and performance metrics of DL based modulation recognition were illustrated. Finally, the future directions of DL based modulation recognition were also discussed.

**Key words:** deep learning, modulation recognition, data pre-processing, deep neural network

收稿日期: 2021-04-03; 修回日期: 2021-05-20

通信作者: 彭盛亮, peng.shengliang@hqu.edu.cn

基金项目: 国家自然科学基金资助项目 (No. 61861019); 华侨大学中央高校基本科研业务费专项 (No. ZQN-708)

**Foundation Items:** The National Natural Science Foundation of China (No. 61861019), The Fundamental Research Funds for the Central Universities (No. ZQN-708)

## 1 引言

调制识别是要识别出信号采用的调制方案,有着广泛的应用。在认知无线电中,调制识别有助于次级用户了解主用户信号的细节信息,是无线环境全面感知的重要组成部分;在智能通信中,调制识别能够减少调制信息的传输开销,实现信号的盲解调;在无线电监管中,调制识别有利于更精准地判断信号是否满足无线电管理规定;在电子对抗中,识别敌方信号的调制方案是有效实施无线电干扰和欺骗的前提<sup>[1]</sup>。

近年来,随着深度学习(deep learning, DL)的蓬勃发展,基于DL的调制识别技术越来越受到人们的关注。与传统调制识别方法不同,基于DL的方法采用深度神经网络(deep neural network, DNN)作为分类器,具有3方面的优势:第一,能够充分利用通信系统中存在的海量数据,有效改善调制识别精度;第二,能够实现自动提取特征,克服手动提取特征过程依赖专业背景和人工经验的难题;第三,能够持续受益于深度学习工具的快速迭代和演进,具备在复杂场景下解决复杂调制识别问题的潜能<sup>[2]</sup>。

## 2 相关基础

### 2.1 传统算法

传统的调制识别算法可分为两大类,即基于似然(likelihood based, LB)的算法和基于特征(feature based, FB)的算法<sup>[1]</sup>。LB算法将调制识别问题视为一个多元假设检验问题,它可以得到最优解,但其计算复杂度相对较高。参考文献[3]研究了平均似然比和广义似然比在调制识别中的应用。参考文献[4]设计了两种分别基于Gauss-Legendre和Gauss-Hermite求积规则的LB算法,用于识别线性调制。FB算法从信号中提取特征用以区别不同的调制方案,如果特征和分类器选择恰当,该算法可以在保证较低复杂度的同

时获得近似最优的性能,因而逐渐占据了主导地位<sup>[5]</sup>。参考文献[6]提出了一种以高阶累积量(high-order cumulant, HOC)为特征的FB算法,在多径衰落条件下具有较好的鲁棒性。参考文献[7]以近似熵为特征,实现了连续相位调制的识别。在参考文献[8]中,四阶谱特征和压缩感知被用来区分星座图类似的调制信号。此外,在分类器方面,参考文献[9]的研究表明,决策树比人工神经网络更适用于多输入多输出系统。参考文献[10-12]中也提出了基于其他分类器的FB算法,如支持向量机和K最近邻等。

### 2.2 深度学习

DL是当前人工智能浪潮中强有力的工具之一,其本质是一种基于多层神经网络、以海量数据为输入、自动组合低层特征形成高层特征的规则学习方法。最基本的神经网络包括3部分,分别为输入层、隐藏层和输出层<sup>[13]</sup>。其中,输入层的神经元用于接收输入数据,并将数据传输到隐藏层的各神经元;隐藏层中的神经元利用激活函数处理数据,并将处理后的数据传到输出层;最后由输出层的神经元输出结果。在DNN中,隐藏层的层数越多,结构越复杂。此时,整个网络的参数也变得更多,每一层相对上一层的抽象表示也更加深入,因而DNN相较于基本的神经网络具有更强大的性能。

近年来,随着DL的蓬勃发展,DNN也被引入通信领域,用于解决调制识别等传统通信问题。基于DL的调制识别技术,能够充分发挥DNN的性能优势,弥补原有LB和FB算法的不足。

## 3 基于深度学习的调制识别

### 3.1 系统架构

在通信系统中,接收信号通常可表示为如下形式:

$$y(k) = Ae^{j(2\pi f_0 kT + \theta_k)} \cdot \sum_{l=-\infty}^{\infty} x(l)h(kT - lT + \epsilon_r T) + n(k) \quad (1)$$



其中,  $n(k)$  代表加性高斯白噪声 (additive white Gaussian noise, AWGN),  $x(l)$  代表符号序列,  $A$  代表幅度因子,  $f_0$  代表载波频率偏移,  $\theta_k$  代表相位抖动,  $T$  代表符号间隔,  $h(\cdot)$  代表残留信道影响,  $\epsilon_T$  为定时误差。

考虑由  $N$  个接收信号采样点组成的接收向量  $\vec{y} = [y(0), y(1), \dots, y(N-1)]$  和  $M$  种调制方案组成的候选集合  $\{S_0, S_1, \dots, S_{M-1}\}$ , 调制识别的任务是根据接收向量  $\vec{y}$  确定调制方案  $S_i$ 。

$$S_i = f(\vec{y}), i \in [0, M-1] \quad (2)$$

基于 DL 的调制识别的系统结构如图 1 所示。接收到的调制信号首先经过数据预处理, 转换为适当的信号表征; 信号表征再送入 DNN 中处理, 并完成调制方案的识别。在实际应用中, 根据调制候选集和无线环境的不同, 有必要采用适当的数据预处理方法, 设计合理的 DNN 结构, 以满足不同的应用需求。




图 1 基于 DL 的调制识别系统结构

### 3.2 数据预处理

数据预处理作为基于 DL 的调制识别中的关键步骤, 目的在于对原始数据进行变换, 将其表征成恰当的形式, 使之能够适于 DNN 处理。如果数据预处理方式得当, DNN 就能够更好地从数据中提取典型特征, 达到更佳 的识别性能。根据预处理后数据表征形式的不同, 数据预处理方式可以分为三大类: 特征表征、序列表征和图像表征。

特征表征是将接收信号预处理成一个或者多个特征值, 例如 HOC 特征、高阶矩特征、频谱特征及其他统计特征等<sup>[1]</sup>。参考文献[6]将接收信号转换成 HOC 特征, 以对抗多径衰落的影响; 参考文献[10]使用四阶谱特征表征接收信号, 实现了 4 种调相信号的识别; 参考文献[14]研究了多达 28 种特征表征, 并讨论了不同特征值组合对调制识别

性能的影响。

序列表征是将接收信号预处理成一个一维向量, 例如正交同相 (in-phase and quadrature, IQ) 序列<sup>[15-17]</sup>、幅度相位 (amplitude and phase, AP) 序列<sup>[18-19]</sup>、快速傅里叶变换 (fast Fourier transform, FFT) 序列<sup>[20]</sup>和幅值直方图序列<sup>[21]</sup>等。参考文献[22]最早将 IQ 表征用于调制识别, 性能较传统方法具有较大优势; 参考文献[16]利用 IQ 序列表征信号, 讨论了不确定噪声条件下的调制识别问题; 参考文献[18]分析了 IQ、AP 和 FFT 3 种序列表征, 同时指出在不同的信噪比 (signal-to-noise ratio, SNR) 条件下, 不同的表征形式具有不同的调制识别精度。

图像表征是将接收信号预处理成一个二维矩阵, 例如星座图<sup>[2,5,23]</sup>、眼图<sup>[24]</sup>、特征点图<sup>[25]</sup>以及经各种变换后产生的谱图<sup>[26-28]</sup>等。参考文献[2]利用接收信号的星座图表征, 将调制识别问题转换成图像识别问题, 并利用 DNN 解决; 参考文献[27]和参考文献[28]分别将接收信号转换成双谱图和循环熵谱图, 也取得了较高的识别精度; 参考文献[29]采用等势星座图替代原始的星座图, 进一步提升了调制识别的性能。

### 3.3 深度神经网络

DNN 是基于 DL 的调制识别的核心部分, 它负责处理信号表征结果, 并完成调制方案的推断和输出。DNN 一般分为三大类, 即深度前馈网络、卷积神经网络 (convolutional neural network, CNN) 和循环神经网络 (recurrent neural network, RNN)<sup>[13]</sup>。

#### 3.3.1 深度前馈网络

深度前馈网络, 也叫前馈神经网络或多层感知机。深度前馈网络的特点是整个网络中无反馈, 信号从输入层到输出层单向传播。其每层神经元与下一层神经元之间完全互连, 各神经元之间不存在同层连接和跨层连接。深度置信网络 (deep belief network, DBN) 是深度前馈网络的典型代

表之一, 由多层受限玻尔兹曼机 (restricted Boltzmann machine, RBM) 组成<sup>[30]</sup>。其中每个 RBM 有两层, 即上层隐藏层和下层可见层。

最近几年, 国内外的研究者已经提出了不少基于 DBN 的调制识别算法。参考文献[31]设计了一种包括 3 个常规 RBM 和 1 个高斯-伯努利 RBM 的 DBN, 用于处理接收信号的谱图表征, 在 SNR 大于或等于 2 dB 时, 对 5 种调制方案的识别精度达到了 90%以上。参考文献[32]提出了一种基于 DBN 和星座图投影的调制识别算法, 利用 DBN 学习星座图投影的潜在特征, 其识别精度接近 LB 算法, 但复杂度更低。

### 3.3.2 卷积神经网络

CNN 通常指包含卷积运算的神经网络。在 CNN 中, 相邻层局部连通, 多层之间利用空间局部相关性实现权重共享, 因此同一个参数可以被不同的神经元多次使用。此外, 隐藏层内的卷积核使得 CNN 的输入层与输出层之间具有稀疏连通性, 从而大大提高了计算效率, 降低了网络存储需求<sup>[33]</sup>。代表性的 CNN 结构有 AlexNet、VGG-Net、GoogLeNet、ResNet 等。

AlexNet 包含 5 个卷积层和 3 个全连接层, 其中卷积层之后还连接了最大池化层, 一共有 6 000 万个参数和 65 万个神经元。参考文献[2]提出了一种基于 AlexNet 和星座图表征的调制识别算法, 利用 AlexNet 学习星座图的特征, 完成了 8 种调制方案的识别。参考文献[28]提出了一种基于 AlexNet 和谱图的调制识别算法, 将谱图送入 AlexNet 进行训练, 并用训练好的 AlexNet 模型推断接收信号的调制方案。为了解决数据不足导致的调制识别性能恶化的问题, 参考文献[34]在 AlexNet 的基础上, 引入生成对抗网络对训练数据进行扩充, 使得整体识别精度提高了 0.1%~6%。为了便于在边缘设备和实时场景中部署基于 DL 的调制识别技术, 参考文献[29]提出采用网络剪枝技术对 AlexNet 进行裁剪。与原始的 AlexNet 相

比, 剪枝后网络仅使用了 1.5%~5% 的参数, 仅耗费了 33%~35% 的识别时间。

VGG-Net 由牛津大学计算机视觉组和 Google DeepMind 公司联合提出, 通过反复堆叠大小为 3×3 的小型卷积核和 2×2 的最大池化层, 构筑了一种 16~19 层深的 CNN 结构, 具有更强的泛化能力和较少的迭代次数。参考文献[15]提出使用 VGG-Net 对接收信号的 IQ 序列进行学习和识别, 在 AWGN 信道下 24 种调制方案的平均识别精度约为 33.5%, 其中 11 种调制方案的平均识别精度约为 54%。

自 2012 年 AlexNet 取得历史性突破直到 GoogLeNet 横空出世以前, 主流的 CNN 结构都是朝着更深、更宽的方向发展, 但增大网络也会使得网络计算复杂度急剧增加。GoogLeNet 由若干 Inception 模块堆叠而成, 采用全局平均池化层代替了最后的全连接层。这种结构在增加 CNN 的深度和宽度的同时, 保证了网络计算量基本恒定。参考文献[2]研究了基于 GoogLeNet 的调制识别, 对 8 种调制方案的平均识别精度约为 89%。

传统的 CNN 在信息传递时或多或少地存在信息丢失和损耗的问题, 同时还可能存在梯度消失或梯度爆炸的风险, 导致网络无法训练。ResNet 在一定程度上解决了这个问题。它通过在网络中增加直连通道, 将输入信息同时绕道传送给输出, 既保护了信息的完整性, 又降低了网络训练的难度, 使得构建超深层网络成为现实。参考文献[27]就提出了一种基于 ResNet 和谱图的调制识别算法, 用于应对非高斯噪声影响。该算法在不同脉冲噪声条件下均能保持较好的识别性能。参考文献[17]在 ResNet 的基础上, 引入了 3 种融合方法用于解决实际接收信号长度不固定的问题。

### 3.3.3 循环神经网络

RNN 是一种擅于处理序列数据的神经网络。在 RNN 中, 网络会存储之前的信息并用于计算当前的输出, 即隐藏层的输入不仅包括上一层的输



出,还包括上一时刻自身的输出。当 RNN 的相关输入与期望输出在时间轴上间隔很长时,网络训练容易产生梯度消失或者梯度爆炸,使得 RNN 的长时记忆失效。为了解决这个问题,长短期记忆(long short-term memory, LSTM)网络应运而生。LSTM 网络将数据维护在独特的 cell 结构中,通过输入门、遗忘门和输出门这 3 个门结构实现信息的添加和删除,以克服传统 RNN 存在的长期依赖问题<sup>[35]</sup>。

参考文献[16]设计了一种由 3 个 LSTM 层堆叠的 RNN,用于对抗调制识别中的瑞利衰落和不确定噪声影响,并增强频率偏移场景下的鲁棒性。参考文献[36]提出了一种基于 LSTM 网络的调制识别算法,用来学习接收信号的 IQ 序列和 HOC 表征,相较于 CNN,它具有更好的识别性能。参考文献[18]利用 LSTM 网络处理接收信号的 AP 序列和 FFT 序列表征,在衰落信道下 11 种调制方案的平均识别精度接近 90%。

### 3.4 常用数据集

为便于评估和对比不同调制识别算法的性能,研究者们创建了一些公开数据集,其中最为流行的是 RadioML 数据集[15,37],包含 RadioML2016.04c、RadioML2016.10a、RadioML2016.10b 和 RadioML2018.01a 等多个版本。

RadioML2016.04c 是一个利用 GNU Radio 生成的数据集,共涉及 11 种常用信号调制方案,包含 8 种数字调制和 3 种模拟调制,分别是二进制相移键控(binary phase shift keying, BPSK)、正交相移键控(quadrature phase shift keying, QPSK)、8PSK、十六进制正交幅度调制(16 quadrature amplitude modulation, 16QAM)、64QAM、二进制频移键控(binary frequency shift keying, BFSK)、连续相位频移键控(continuous phase frequency shift keying, CPFSK)、四进制脉冲幅度调制(pulse amplitude modulation 4, PAM4)、宽带频率调制(wide band frequency

modulation, WBFM)、单边带调幅(single-sideband amplitude modulation, AM-SSB)、双边带调幅(double-sideband amplitude modulation, AM-DSB)。其采样速率为每符号 8 个采样点,包括 220 000 个调制信号样本,信道类型为多径衰落信道。此外,它还是一个具有中等时钟漂移、轻度衰落的可变 SNR 数据集,可用于不同信号和噪声场景下的调制识别性能测试。

RadioML2016.10a 是 RadioML2016.04c 的一个更干净规范的版本,同样包含了上述 11 种调制方案,信噪比变化范围为-20~18 dB。该数据集考虑了 AWGN 和多径衰落影响,并引入了采样率偏移和中心频率偏移等恶劣条件,以与实际无线通信环境更为相似。

RadioML2016.10b 是 RadioML2016.10a 的扩展版本,一共包含 1 200 000 个信号样本,但只涉及 10 种调制方案,分别为 BPSK、QPSK、8PSK、16QAM、64QAM、BFSK、CPFSK、PAM4、WB-FM 和 AM-DSB。

RadioML2018.01a 对 RadioML2016.10a 中的调制类型进行了增广,共涉及 24 种调制方案,包括通断键控(on-off keying, OOK)、四进制幅移键控(4 amplitude shift keying, 4ASK)、8ASK、BPSK、QPSK、偏移 QPSK、8PSK、16PSK、32PSK、十六进制幅度相移键控(16 amplitude and phase shift keying, 16APSK)、32APSK、64APSK、128APSK、16QAM、32QAM、64QAM、128QAM、256QAM、单边带载波调幅(single-sideband amplitude modulation with carrier, AM-SSB-WC)、单边带抑制载波调幅(single-sideband amplitude modulation with suppressed-carrier, AM-SSB-SC)、AM-DSB-WC、AM-DSB-SC、调频(frequency modulation, FM)、高斯最小频移键控(Gaussian filtered minimum shift keying, GMSK)。数据以浮点复数的形式存储,有 200 万个信号样本,每个样本的长度为 1 024 个采样值。

### 3.5 评价指标

基于 DL 的调制识别性能主要从识别精度和模型复杂度两个方面评价。

#### 3.5.1 识别精度

识别精度的第一个衡量指标为混淆矩阵 (confusion matrix)。混淆矩阵也称误差矩阵, 能够直观反映识别结果的分布状况, 通常为  $M \times M$  的方阵, 其第  $p$  行、第  $q$  列的值  $M(p, q)$  表示有  $M(p, q)$  个调制方案为  $S_p$  的信号样本被识别为调制方案  $S_q$ 。假设候选集中有 2 种调制方案, 即  $M=2$ , 那么, 其混淆矩阵如图 1 所示。

| 混淆矩阵   |        | 预测调制方案 |        |
|--------|--------|--------|--------|
|        |        | 调制方案 1 | 调制方案 2 |
| 真实调制方案 | 调制方案 1 | TP     | FN     |
|        | 调制方案 2 | FP     | TN     |

图 1 混淆矩阵

其中, TP (true positive, TP) 和 TN (true negative, TN) 表示预测结果正确, FP (false positive, FP) 和 FN (false negative, FN) 表示预测结果错误。

识别精度的另一个衡量指标为识别准确率 (accuracy, Acc), 表示识别正确的信号样本数量在所有信号样本中所占的百分比。以  $M=2$  为例, Acc 可具体计算如下:

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \quad (3)$$

#### 3.5.2 模型复杂度

DNN 的模型复杂度主要包括时间复杂度和空间复杂度。时间复杂度可以通过训练时间或识别时间衡量; 空间复杂度取决于模型的参数数量和模型所需的存储空间大小。

为了进一步展示基于 DL 的调制识别算法的性能, 表 1 列举了本文所提及的部分算法识别精

表 1 基于 DL 的调制识别算法对比

| 文献                          | 预处理  | DNN    | 候选调制方案                                                          | SNR/dB | 平均 Acc | 复杂度      |
|-----------------------------|------|--------|-----------------------------------------------------------------|--------|--------|----------|
| Mendis 等 <sup>[26]</sup>    | 图像   | DBN    | 4FSK、16QAM、BPSK、QPSK、OFDM                                       | -2~5   | 94.50% | /        |
| Wang 等 <sup>[32]</sup>      | 图像   | DBN    | BPSK、QPSK、8PSK、16QAM                                            | 0~10   | 97.57% | $O(N)^*$ |
| Peng 等 <sup>[2]</sup>       | 图像   | CNN    | BPSK、QPSK、OQPSK、8PSK、16QAM、64QAM、4ASK                           | 0~10   | 84.15% | 6.6 ms   |
|                             |      |        |                                                                 |        | 89.00% | 18 ms    |
| Li 等 <sup>[28]</sup>        | 图像   | CNN    | BPSK、2ASK、2FSK、4FSK、8FSK、LFM、OFDM                               | -3~10  | 56.35% | /        |
| Tang 等 <sup>[34]</sup>      | 图像   | CNN    | BPSK、4ASK、QPSK、OQPSK、8PSK、16QAM、32QAM、64QAM                     | -6~14  | 91.75% | /        |
| Tu 和 Lin <sup>[29]</sup>    | 图像   | CNN    | 4ASK、BSPK、QPSK、OQPSK、8PSK、16QAM、32QAM、64QAM                     | -6~6   | 91.70% | 19.42 ms |
|                             |      | 剪枝 CNN |                                                                 |        | 91.00% | 6.7 ms   |
| O'Shea 等 <sup>[15]</sup>    | 序列   | CNN    | RadioML2018.01a                                                 | -20~20 | 36.50% | /        |
|                             |      |        |                                                                 |        | 42.00% | 14 h*    |
| Ma 等 <sup>[27]</sup>        | 谱图   | CNN    | BPSK、2ASK、4QAM、8ASK、16QAM                                       | -5~10  | 66.00% | /        |
| Zheng 等 <sup>[17]</sup>     | 序列   | CNN    | BPSK、QPSK、8PSK、OQPSK、2FSK、4FSK、8FSK、16QAM、32QAM、64QAM、4PAM、8PAM | -20~30 | 53.50% | /        |
|                             |      |        |                                                                 |        | 55.00% | /        |
| Hu 等 <sup>[16]</sup>        | 序列   | RNN    | BPSK、QPSK、8PSK、16QAM                                            | 0~20   | 79.00% | 9.2 ms   |
| Zhang 等 <sup>[36]</sup>     | 序列特征 | CNN    | RadioML2016.10a                                                 | -20~18 | 54.50% | /        |
|                             |      | RNN    |                                                                 |        | 55.00% | /        |
| Rajendran 等 <sup>[18]</sup> | 序列   | RNN    | RadioML2016.10a                                                 | -20~20 | 56.00% | 6.4 MB*  |

注:  $O(N)$  为计算复杂度, 14 h 为训练时间, 6.4 MB 为模型大小, 其余均为识别时间。



度和模型复杂度，并给出了它们的数据预处理方式和 DNN 类型。从表 1 可以看出，大部分算法均具有较好的识别性能。其中，候选调制方案越简单，SNR 越高，识别性能越好。

## 4 未来研究方向

虽然基于 DL 的调制识别研究已经取得了一系列的成果，但仍有进一步研究的空间。

首先，从数据预处理的角度看，在同一种信号表征形式下，如果候选调制方案不同，或者无线环境不同，算法的识别精度会有明显差异，因此有必要研究信号表征与调制方案及信道条件之间的关联性，以便根据实际场景选择恰当的数据预处理方式。同时，综合利用信号的特征表征、序列表征和图像表征，已被证实有利于提高调制识别精度，但如何融合这些表征形式还没有得到深入的研究。

其次，从 DNN 的角度看，不同的 DNN 结构擅长处理不同形式的数据，因此未来需要进一步根据数据预处理结果，设计匹配的网络结构，以充分学习信号的典型特征，实现高精度的调制识别。

最后，从模型复杂度的角度看，基于 DL 的调制识别的精度虽然在不断提升，但其模型复杂度也在不断增加，导致其难以部署到资源有限的移动平台和边缘节点上。因此，如何在保证识别精度不明显下降的同时减少网络参数、改善模型效率，值得未来继续研究。

## 5 结束语

本文首先回顾了传统的调制识别方法及 DL 的相关基础；然后重点讨论了基于 DL 的调制识别技术，给出了系统架构，阐述了特征表征、序列表征和图像表征 3 种数据预处理方式，着重分析了 3 种常用的 DNN，包括深度前馈网络、CNN 和 RNN，介绍了 RadioML 数据集，列举了识别精

度和模型复杂度两方面的性能指标，并对部分算法进行了总结；接着从数据预处理、DNN 和模型复杂度 3 个角度展望了下一步的研究工作。未来随着 DL 的不断演进，基于 DL 的调制识别技术也将不断完善，取得更大的发展。

## 参考文献：

- [1] 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.
- [2] PENG S L, JIANG H Y, WANG H X, et al. Modulation classification based on signal constellation diagrams and deep learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(3): 718-727.
- [3] PANAGIOTOU P, ANASTASOPOULOS A, POLYDOROS A. Likelihood ratio tests for modulation classification[C]//Proceedings of MILCOM 2000 Proceedings. 21st Century Military Communications, Architectures and Technologies for Information Superiority (Cat. No.00CH37155). Piscataway: IEEE Press, 2000: 670-674.
- [4] SHI Q H, KARASAWA Y. Automatic modulation identification based on the probability density function of signal phase[J]. IEEE Transactions on Communications, 2012, 60(4): 1033-1044.
- [5] XIE X J, NI Y Q, PENG S L, et al. Deep learning based automatic modulation classification for varying SNR environment[C]//Proceedings of 2019 28th Wireless and Optical Communications Conference (WOCC). Piscataway: IEEE Press, 2019: 1-5.
- [6] 董鑫, 欧阳喜, 袁强. 多径信道下基于高阶累积量的通信信号调制识别算法[J]. 信息工程大学学报, 2015, 16(1): 73-78.  
DONG X, OUYANG X, YUAN Q. Automatic modulation classification using cumulant features for communications via multipath channels[J]. Journal of Information Engineering University, 2015, 16(1): 73-78.
- [7] PAWAR S U, DOHERTY J F. Modulation recognition in continuous phase modulation using approximate entropy[J]. IEEE Transactions on Information Forensics and Security, 2011, 6(3): 843-852.
- [8] XIE L J, WAN Q. Automatic modulation recognition for phase shift keying signals with compressive measurements[J]. IEEE Wireless Communications Letters, 2018, 7(2): 194-197.
- [9] CHIKHA W B, DAYOUB I, HAMOUDA W, et al. Modulation recognition for MIMO relaying broadcast channels with direct link[J]. IEEE Wireless Communications Letters, 2014, 3(1): 50-53.

- [10] XIE L J, WAN Q. Automatic modulation recognition for phase shift keying signals with compressive measurements[J]. *IEEE Wireless Communications Letters*, 2018, 7(2): 194-197.
- [11] KHARBECH S, DAYOUB I, ZWINGELSTEIN-COLIN M, et al. On classifiers for blind feature-based automatic modulation classification over multiple-input-multiple-output channels[J]. *IET Communications*, 2016, 10(7): 790-795.
- [12] ASLAM M W, ZHU Z C, NANDI A K. Automatic modulation classification using combination of genetic programming and KNN[J]. *IEEE Transactions on Wireless Communications*, 2012, 11(8): 2742-2750.
- [13] GOODFELLOW I J, BENGIO Y, COURVILLE A C. *Deep Learning*[M]. Massachusetts: MIT Press, 2016.
- [14] LEE J, KIM B, KIM J, et al. Deep neural network-based blind modulation classification for fading channels[C]//*Proceedings of 2017 International Conference on Information and Communication Technology Convergence (ICTC)*. Piscataway: IEEE Press, 2017: 551-554.
- [15] 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.
- [16] HU S S, PEI Y Y, LIANG P P, et al. Deep neural network for robust modulation classification under uncertain noise conditions[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(1): 564-577.
- [17] ZHENG S L, QI P H, CHEN S C, et al. Fusion methods for CNN-based automatic modulation classification[J]. *IEEE Access*, 2019(7): 66496-66504.
- [18] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Deep learning models for wireless signal classification with distributed low-cost spectrum sensors[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2018, 4(3): 433-445.
- [19] HONG S, ZHANG Y B, WANG Y, et al. Deep learning-based signal modulation identification in OFDM systems[J]. *IEEE Access*, 2019(7): 114631-114638.
- [20] MOSSAD O S, ELNAINAY M, TORKI M. Deep convolutional neural network with multi-task learning scheme for modulations recognition[C]//*Proceedings of 2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC)*. Piscataway: IEEE Press, 2019: 1644-1649.
- [21] KHAN F N, ZHONG K P, AL-ARASHI W H, et al. Modulation format identification in coherent receivers using deep machine learning[J]. *IEEE Photonics Technology Letters*, 2016, 28(17): 1886-1889.
- [22] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//*Proceedings of Engineering Applications of Neural Networks*. [S.l.:s.n.], 2016.
- [23] HUANG S, CHAI L, LI Z N, et al. Automatic modulation classification using compressive convolutional neural network[J]. *IEEE Access*, 2019(7): 79636-79643.
- [24] WANG D S, ZHANG M, LI Z, et al. Modulation format recognition and OSNR estimation using CNN-based deep learning[J]. *IEEE Photonics Technology Letters*, 2017, 29(19): 1667-1670.
- [25] DAVIDSON K L, GOLDSCHNEIDER J R, CAZZANTI L, et al. Feature-based modulation classification using circular statistics[C]// *Proceedings of IEEE MILCOM 2004*. Piscataway: IEEE Press, 2004: 765-771.
- [26] MENDIS G J, WEI J, MADANAYAKE A. Deep learning-based automated modulation classification for cognitive radio[C]// *Proceedings of 2016 IEEE International Conference on Communication Systems (ICCS)*. Piscataway: IEEE Press, 2016: 1-6.
- [27] MA J T, LIN S C, GAO H J, et al. Automatic modulation classification under non-Gaussian noise: a deep residual learning approach[C]//*Proceedings of ICC 2019 - 2019 IEEE International Conference on Communications (ICC)*. Piscataway: IEEE Press, 2019: 1-6.
- [28] LI Y B, SHAO G P, WANG B. Automatic modulation classification based on bispectrum and CNN[C]// *Proceedings of 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC)*. Piscataway: IEEE Press, 2019: 311-316.
- [29] TU Y, LIN Y. Deep neural network compression technique towards efficient digital signal modulation recognition in edge device[J]. *IEEE Access*, 2019(7): 58113-58119.
- [30] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, 18(7): 1527-1554.
- [31] MENDIS G J, WEI-KOCSIS J, MADANAYAKE A. Deep learning based radio-signal identification with hardware design[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2019, 55(5): 2516-2531.
- [32] WANG F, WANG Y C, CHEN X. Graphic constellations and DBN based automatic modulation classification[C]//*Proceedings of 2017 IEEE 85th Vehicular Technology Conference (VTC Spring)*. Piscataway: IEEE Press, 2017: 1-5.
- [33] WANG Q, DU P F, YANG J Y, et al. Transferred deep learning based waveform recognition for cognitive passive radar[J]. *Signal Processing*, 2019, 155: 259-267.
- [34] TANG B, TU Y, ZHANG Z Y, et al. Digital signal modulation classification with data augmentation using generative adversarial nets in cognitive radio networks[J]. *IEEE Access*, 2018, 6: 15713-15722.






- [35] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: a search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2222-2232.
- [36] ZHANG M, ZENG Y, HAN Z D, et al. Automatic modulation recognition using deep learning architectures[C]//Proceedings of 2018 IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Piscataway: IEEE Press, 2018: 1-5.
- [37] O'SHEA T J, WEST N. Radio machine learning dataset generation with GNU radio[Z]. 2016.

#### [作者简介]



孙姝君（1997-），女，华侨大学信息科学与工程学院硕士生，主要研究方向为无线通信、人工智能。



彭盛亮（1982-），男，博士，华侨大学信息科学与工程学院副教授、硕士生导师，主要研究方向为认知无线电、人工智能、物联网等。

姚育东（1960-），男，博士，史蒂文斯理工学院电子与计算机工程系终身教授。2011年当选国际电气电子工程师协会会员（IEEE Fellow），2015年当选美国国家发明家科学院院士（Fellow of National Academy of Inventors），2017年当选加拿大工程院院士（Fellow of Canadian Academy of Engineering）。主要研究方向为通信信息技术、人工智能、健康物联网。

杨喜（1978-），男，博士，吉首大学信息科学与工程学院教授、硕士生导师，主要研究方向为认知无线电、统计信号处理、智能信息与信号处理。