

引用格式: 李昱辰, 余尔聪, 潘雪, 等. 干扰环境下通信信号的调制识别技术研究 [J]. 电子科技大学学报, 2025, 54(3): 369-376.  
LI Y C, YU E C, PAN X, et al. Research on modulation recognition technology of communication signals in interference environment[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(3): 369-376.



# 干扰环境下通信信号的调制识别技术研究

李昱辰<sup>1</sup>, 余尔聪<sup>2</sup>, 潘雪<sup>2</sup>, 葛孟佳<sup>1</sup>, 李强<sup>2\*</sup>

(1. 成都飞机工业(集团)有限责任公司, 成都 610073; 2. 电子科技大学通信抗干扰全国重点实验室, 成都 611731)

**摘要:** 自动调制样式识别是非合作通信场景中实现信号检测和解调的关键前提。近年来, 深度学习在自动调制样式识别领域展现了显著的优势。然而, 现有研究普遍忽视了通信过程中随机干扰所带来的挑战。事实上, 由于无线通信的开放性和广播特性, 干扰攻击已成为无线通信中的重大威胁。为了充分发挥自动调制样式识别在无线通信中的潜力, 该文深入探讨了干扰环境下基于深度学习的调制样式识别技术, 针对已知干扰和随机未知干扰两种情况, 设计了相应的基于干扰认知的识别方法, 并通过开放数据集 RML2016.10a 验证了该算法的有效性。

**关键词:** 深度学习; 自动调制样式识别; 干扰认知; 干扰识别

中图分类号: TN92 文献标志码: A DOI: 10.12178/1001-0548.2024255

## Research on modulation recognition technology of communication signals in interference environment

LI Yuchen<sup>1</sup>, YU Ercong<sup>2</sup>, PAN Xue<sup>2</sup>, GE Mengjia<sup>1</sup>, and LI Qiang<sup>2\*</sup>

(1. Chengdu Aircraft Industrial (Group) Co., Ltd., Chengdu 610073, China;

2. National Key Laboratory of Wireless Communications, University of Electronic Science and Technology of China, Chengdu 611731, China)

**Abstract:** Automatic modulation recognition is a critical prerequisite for achieving signal detection and demodulation in non-cooperative communication scenarios. In recent years, deep learning has demonstrated significant advantages in this field. However, existing studies have largely overlooked the challenges posed by random interference and jamming during communication. In fact, due to the open and broadcast nature of wireless communications, interference and jamming attacks have become major threats. To fully harness the potential of automatic modulation recognition in wireless communications, an in-depth exploration of deep learning-based modulation recognition techniques under interference and jamming conditions is conducted. Specifically, the corresponding recognition methods are designed based on interference recognition for two scenarios where interference is either known or unknown, and the effectiveness of our proposed algorithms is validated using the open dataset RML2016.10a.

**Key words:** deep learning; automatic modulation recognition; interference cognition; interference identification

自动调制识别 (automatic modulation recognition, AMR) 是一种在非合作通信场景中用于接收端识别信号调制方式的关键技术<sup>[1]</sup>。其主要目的是在缺乏先验信息的情况下, 实现对无线信号调制样式的自动检测。作为信号检测和解调的关键技术, AMR 在卫星测控、认知无线电、信息对抗等民用和军事领域中发挥着至关重要的作用<sup>[2-4]</sup>。

AMR 在无线通信中的重要性引发了研究关注。传统的 AMR 方法通常分为基于似然理论的方法<sup>[5]</sup>和基于提取特征的方法<sup>[6-7]</sup>。尽管基于似然理论的方法依托于贝叶斯估计框架, 能够实现最优的识别精度, 但其高计算复杂度使得实际应用变得困难。相比之下, 基于特征的 AMR 方法虽然提供了次优的识别性能, 但通常具有较低的计算复杂度和

收稿日期: 2024-09-18

基金项目: 国家级基金项目 (G022023KP01602)

作者简介: 李昱辰, 高级工程师, 主要从事无人机通信系统方面的研究。

\*通信作者 E-mail: liqiang@uestc.edu.cn

识别多种调制样式的能力。然而，基于特征的方法仍存在局限性，主要表现在其对多种特征的提取和融合的依赖性上，这使得其鲁棒性较差。特别是许多特征对噪声和干扰高度敏感，从而限制了基于特征的传统方法的整体性能。

近年来，深度学习为通信领域的应用带来了显著的性能提升，其在调制识别中的应用也开辟了新的研究方向。与传统方法相比，深度学习网络能够直接从接收信号中提取关键特征，具有更高的识别准确率<sup>[8]</sup>，并展现出良好的适应性和抗噪性<sup>[9]</sup>。现有研究广泛探讨了深度神经网络（deep neural network, DNN）<sup>[10-11]</sup>、卷积神经网络（convolutional neural network, CNN）<sup>[12-15]</sup>、递归神经网络（recurrent neural network, RNN）<sup>[9,16]</sup>等模型在 AMR 领域的应用潜力。其中，CNN 因其在处理空间特性数据方面的卓越能力，在 AMR 研究中得到了广泛关注。文献 [12] 率先探索了 CNN 在 AMR 中的应用潜力，显著提升了识别精度。文献 [13] 面向信号调制分类提出了一种实时模型，结合 CNN 和三跳残差神经网络，实现了 OFDM 调制信号的识别。此外，文献 [14] 提出了一种基于 3D 卷积的方法，有效实现了多天线系统中的调制样式识别。为应对信号识别任务中数据标注成本高昂的挑战，文献 [15] 进一步提出了一种基于深度学习的半监督信号调制识别算法。

尽管基于深度学习的调制识别算法已取得显著成果，但其在现实系统中的部署仍面临诸多挑战<sup>[16]</sup>。由于无线通信的开放性，干扰攻击成为一种严重的安全威胁<sup>[17]</sup>。电磁环境的日益复杂化导致接收信号中常夹杂环境或人为干扰，且干扰源与待识别信号占据相同的频段，难以在频域上分离出有效信号。如何有效应对敌方的智能干扰，已成为现代无线通信所面临的重大挑战<sup>[18]</sup>。因此，在干扰环境下开展调制信号识别技术的研究具有重要的实际价值。

在以上需求的驱动下，本文深入研究了干扰环境下的 AMR 技术，并针对干扰类型已知和未知的情况展开探索。基于卷积神经网络，本文针对已知干扰类型提出定制网络的调制识别方法（IQ-CNN）。鉴于实际通信系统中的干扰形式往往具有随机性和多样性，本文在信号识别过程中引入了干扰识别算法，并进一步提出了一种基于干扰认知的调制识别方法（AJMR-CNN），以应对实际通信中的复杂挑战。在公开数据集 RML2016.10a<sup>[19]</sup> 上的

仿真验证了所提算法的优越性。

## 1 系统模型

### 1.1 信号数据集

本文考虑了一个单天线通信系统。发射信号经过无线信道传输和离散采样后，接收端观测到的等效基带信号可表示为：

$$y[l] = A e^{j(2\pi f_0 T l + \theta_l)} \sum_{n=-\infty}^{\infty} x[n] h[lT - nT + \epsilon_T T] + n[l] \quad \forall l = 1, 2, \dots, L \quad (1)$$

式中， $L$  是接收机观测到的一个信号样本中的符号数，即采样长度， $y[l]$  是第  $l$  个值； $\{x[n]\}$  是发射机调制后的复数基带符号序列； $A$  是幅值因子； $h[\cdot]$  是信道响应； $T$  是持续时间； $f_0$  是频率偏移； $\theta_l$  是相位偏移； $\epsilon_T$  是定时误差； $n[l] \sim CN(0, \sigma_0^2)$  是方差为  $\sigma_0^2$  的复数加性高斯白噪声（additive white gaussian noise, AWGN）。接收信号可以进一步用同相-正交（I/Q）的形式表示：

$$\mathbf{Y} = \begin{bmatrix} \mathbf{y}_R \\ \mathbf{y}_I \end{bmatrix} \quad (2)$$

式中， $\mathbf{y}_R$  和  $\mathbf{y}_I$  分别为同相分量和正交分量。

基于深度学习的调制识别技术依赖于接收信号集  $\mathbf{Y}$ 。为了训练和验证的有效性，本文采用了当前广泛使用的基准数据集 RML 2016.10a<sup>[19]</sup>。该数据集模拟了现实场景中的调制信号特征，涵盖 11 种常见的调制方式，并考虑了无线通信过程中的时变随机信道，如中心频率偏移、采样率偏移、加性高斯白噪声以及多径效应和衰落等。数据集特征样本维度为  $2 \times 128$ ，数据集大小为 220 000 个，信噪比范围为  $-20 : 2 : 18$  dB，信道参数如表 1 所示。

表 1 RML2016.10a 的信道参数

参数	值
采样频率/kHz	200
采样率偏移标准差/Hz	0.01
最大采样率偏移/Hz	50
载波频率偏移标准差/Hz	0.01
最大载波频率偏移/Hz	500
频率选择性衰落中应用的正弦波数量	8
最大多普勒频移	1
衰落模型	莱斯
莱斯 $K$ 因子	4
功率延迟分布的各样本延时	[0.0, 0.9, 1.7]
与各延迟时间对应的幅值	[1, 0.8, 0.3]
用于插值功率延迟曲线的滤波器长度	8
AWGN 噪声方差 $\sigma_0^2$	$10^{-\frac{\text{SNR}}{10}}$

## 1.2 干扰类型

为验证、评估所提方法在干扰环境下的表现, 本文考虑了以下3种经典的干扰类型。

### 1.2.1 单音干扰 (Single-Tone Interference)

单音干扰是最常见的单频点干扰类型, 通常可以用一个正弦信号来表示。其时域的数学模型表达式为:

$$J(t) = \sqrt{P_J} e^{j(2\pi f_J t + \theta)} \quad (3)$$

式中,  $P_J$ 和 $f_J$ 分别表示干扰信号的功率和频率;  $\theta \sim \mathcal{U}(0, 2\pi)$ 为服从均匀分布的初始相位。其功率谱密度在干扰频率处呈现为一个冲激函数:

$$S(\omega) = 2\pi P_J \sigma(\omega - 2\pi f_J) \quad (4)$$

式中,  $\sigma(\cdot)$ 为冲激函数。

### 1.2.2 窄带干扰 (Narrow-Band Interference)

窄带干扰是指在特定频段内高度集中存在的干扰信号。本文采用在干扰频带内集中的高斯白噪声来表征窄带干扰, 其频域表达式为:

$$J_p(k) = \begin{cases} p(k) & k \in f_i \\ 0 & k \notin f_i \end{cases} \quad (5)$$

式中,  $p(k) \sim \mathcal{N}(0, \sigma_i^2)$ 服从高斯分布;  $f_i$ 表示窄带干扰所覆盖的频点集合。设干扰的带宽为 $B_j$ , 系统的总带宽为 $B$ , 则干扰的带占比 $0 < \rho < 1$ 可表示为:

$$\rho = \frac{B_j}{B} \quad (6)$$

### 1.2.3 时域脉冲干扰 (Time-Pulse Interference)

时域脉冲干扰是在信号传输过程中随机出现的短时间、高幅度的脉冲干扰。由于脉冲干扰幅度通常显著高于传输信号和背景噪声, 其对系统性能的影响尤为显著。时域高斯脉冲干扰可以通过以下模型进行描述:

$$I_j(t) = \begin{cases} p(k) & 0 < t \leq \tau_j \\ 0 & \tau_j < t \leq T_j \end{cases} \quad (7)$$

式中,  $p(k) \sim \mathcal{N}(0, \sigma_j^2)$ 服从高斯分布;  $\tau_j$ 是时域脉冲干扰信号的持续时间;  $T_j$ 是干扰的周期。

## 1.3 问题建模

AMR以接收信号为输入, 输出识别的调制样式结果。假设接收的被干扰后的信号为 $\tilde{\mathbf{Y}}$ , 其采用的调制样式为 $m$ 。则干扰环境下的AMR问题可以建模为:

$$\min_{\mathcal{M}} \Delta(\mathcal{M}(\tilde{\mathbf{Y}}), m) \quad (8)$$

其目的在于通过优化调制识别模型 $\mathcal{M}(\cdot)$ , 使得

识别的接收信号的调制样式 $\mathcal{M}(\tilde{\mathbf{Y}})$ 和实际调制样式 $m$ 之间的差异在给定准则 $\Delta(\cdot)$ 下最小。

## 2 基于深度学习的调制识别方法

与传统的调制识别方法不同, 基于深度学习的调制识别无须人工提取信号统计特征, 而是直接使用原始I/Q信号进行端到端的调制识别。这种方法减少了对信号参数估计精度的依赖, 即使在较低的上采样倍数和较短的信号长度下, 仍能保持优异的性能。假设干扰类型已知, 本节提出了一种基于深度学习的调制样式识别方法, 并针对特定干扰类型训练了专用的调制识别模型。

### 2.1 加扰数据集设计

为了得到给定干扰场景下适用的识别网络, 首先构造加扰数据集, 即在RML2016.10a数据集(含噪声、衰落、预处理偏差)的每个原信号样本基础上引入特定的干扰类型(单音、窄带、时域脉冲)。此外, 为提升模型的调制识别准确率, 数据基于连续均值剔除(consecutive mean excision, CME)算法<sup>[20]</sup>和置零抑制进行预处理, 以实现干扰检测及抑制处理。

#### 2.1.1 基于CME算法的干扰检测

CME算法的核心在于识别干扰信号的高能量特征。算法计算接收信号的能量, 认为高于门限值的信号频点或时域样点受到了干扰。

针对频域干扰检测, 单音和窄带干扰的能量主要集中于某些特定频点。假设接收信号的频域信号为 $R(f)$ , 其幅度谱可表达为:

$$A(f) = \sqrt{\Re^2[R(f)] + \Im^2[R(f)]} \quad (9)$$

设定 $S_f$ 表示接收信号中未受到干扰的(频点, 幅度)集合,  $I_f$ 表示接收信号中存在干扰的(频点, 幅度)集合。初始假设所有的频点均未受干扰, 即 $S_f = \{A(f)\}$ 。给定虚警概率 $P_{fa}$ , 可以确定门限因子参数:  $T = \sqrt{-4 \ln(P_{fa})/\pi}$ 。由此, CME算法的干扰检测门限值 $A_{Th}$ 可以表示为:

$$A_{Th} = \mathbb{E}(S_f)T \quad (10)$$

将集合 $S_f$ 中各个频点的幅值与门限 $A_{Th}$ 对比, 若某频点的幅度超过门限, 则将其从集合 $S_f$ 中剔除并加入集合 $I_f$ , 即判定该频点受到干扰。随后, 更新门限因子参数:  $T = A_{Th}$ , 并按照式(10)重新计算干扰检测门限值 $A_{Th}$ 。这个过程将不断迭代, 直至集合中的元素不再发生变化。最终, 包含所有

受干扰的（频点，幅度）的集合记为  $I_f^*$ 。

类似地，时域脉冲干扰的能量汇聚于某些特定的时间样本点上。对于高斯脉冲干扰在时域上的检测，可以直接在时域样点上应用 CME 算法，省去了傅里叶变换的步骤。包含所有受干扰（时域样点，幅度）的集合记为  $I_t^*$ 。

### 2.1.2 基于置零算法的干扰抑制

频域和时域的干扰检测完成后，随即进行干扰抑制处理。此处采用了一种非线性处理方法——置零算法。该算法的核心思想是将高于设定阈值的信号点幅值直接置为 0，而低于阈值的信号幅值则保持不变。具体而言，就是根据检测结果，将受干扰的频点和时域样点（无论是来自频域集合  $I_f^*$  还是时域集合  $I_t^*$ ）对应的幅值修改为 0。

经过信道传输，并分别受到单音干扰、窄带干扰及时域脉冲干扰的接收信号，在经历干扰检测和干扰抑制处理后，形成了 3 个数据集：RML-ST、RML-NB 和 RML-TP，它们的大小和原始数据集大小相同，均为 220 000。

## 2.2 网络模型

本节设计了一种基于卷积神经网络<sup>[12]</sup>的自动调制识别模型。它以经过干扰抑制处理的 I/Q 信号为输入，输出对应接收信号的调制识别样式预测。该模型命名为 IQ-CNN，其结构如图 1 所示。

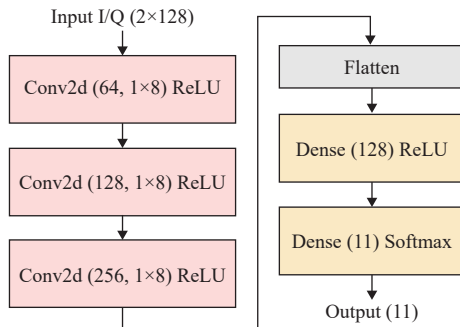


图 1 基于 CNN 的调制识别网络结构

模型的输入为截取的 I/Q 信号，每条信号包含 128 个采样点，因此输入维度为  $2 \times 128$ 。该模型包括 3 个卷积层 (Conv2d) 和 2 个全连接层 (Dense)。所有卷积层的卷积核尺寸均为  $1 \times 8$ ，并且各卷积层的通道数分别为 64、128 和 256；全连接层的节点数分别为 128 和 11。隐层激活函数采用 ReLU<sup>[21]</sup>，而输出层则使用 Softmax 激活函数，以生成关于调制样式类别的概率分布向量。最终，输出值最大的神经元对应的类别被确定为调制识别结果，模型的最终输出为预测的调制样式标签。

基于所提的 IQ-CNN 模型来解决干扰环境下的调制样式识别问题，对于指定干扰类型  $I$ ，问题 (8) 可以改写为：

$$\min_{\Theta_I} \text{Loss} = \Delta(\mathcal{M}_I(\tilde{Y}; \Theta_I, I), m) \quad (11)$$

式中， $m$  为采用独热编码的调制识别向量。即为指定的干扰类型  $I$  设计了对应的模型  $\mathcal{M}_I$ ，通过优化模型参数  $\Theta_I$  来最小化识别结果和实际调制识别样式之间的差异。问题 (11) 实际是一个多分类问题，因此此处采用了分类交叉熵 (categorical cross entropy, CCE) 作为损失函数  $\Delta(\cdot)$ 。

### 2.3 训练流程

每一个加扰数据集都按照 3 : 1 : 1 的比例划分为训练集 (132 000 个)、验证集 (44 000 个) 和测试集 (44 000 个)，其中的样本按照信噪比  $-20 : 2 : 18$  dB 的范围随机加噪。训练过程采用自适应矩估计 (adaptive moment estimation, Adam) 优化器<sup>[22]</sup>。在训练过程中，当验证损失在多个轮次内未出现下降时，将对学习率乘以 0.5 的衰减系数。如果验证损失持续未减少，则认为模型已完成收敛。批大小设置为 256，训练结束后，选择验证损失最小的模型作为最优模型。针对单音干扰、窄带干扰和时域脉冲干扰训练的模型分别命名为 ST-CNN、NB-CNN 和 TP-CNN。

## 3 基于干扰认知的调制识别方法

实际的通信过程中，接收机往往无法直接知晓干扰类型。此外，随着干扰技术的发展，蓄意干扰的方式也从传统的阻塞式干扰转变为更加智能的形式，这对无线通信中的调制样式识别带来了挑战。为应对这一问题，本节进一步提出了一种基于干扰认知的调制识别方法 (AJMR-CNN)。

### 3.1 混合加扰数据集设计

如图 2 所示，为了支持实际通信过程中干扰类型未知的情况，提出了一种基于干扰认知的分步调制样式识别方法。具体地，首先提出了一种基于 CNN 的干扰类型识别模型 (AJR-CNN)。在执行调制样式识别之前，利用 AJR-CNN 实现干扰类型的识别。为了得到最优的 AJR-CNN 模型参数，应构造干扰数据集。

通过混合特定干扰类型的数据集 RML-ST、RML-NB 以及 RML-TP，可以得到混合不同干扰类型的加扰接收信号集 RML-JAM。其中，每个信号样本

仅受到单一类型的干扰影响。各样本携带对应的干扰类型标签, 用于设计受监督的干扰类型识别训练。




图2 基于干扰认知的调制识别系统框图

### 3.2 网络模型

干扰类型未知的调制识别问题可建模为:

$$\min_{\mathcal{J}, \mathcal{M}} \Delta(\mathcal{M}(\tilde{\mathcal{Y}}; \mathcal{J}(\tilde{\mathcal{Y}})), \mathbf{m}) \quad (12)$$

式中,  $\mathcal{J}(\cdot)$ 和 $\mathcal{M}(\cdot)$ 分别为实现干扰类型识别的AJR-CNN模型和实现调制识别的IQ-CNN模型。通过优化模型 $\mathcal{J}(\cdot)$ 和 $\mathcal{M}(\cdot)$ 来实现随机干扰下调制识别样式的最优估计。

由于调制样式的识别依赖于干扰类型的识别结果, 把问题(12)拆分为两个步骤。获取最优干扰类型识别模型 $\mathcal{J}(\cdot)$ 的问题可以建模为:

$$P1: \min_{\Phi} \text{Loss}_1 = \Delta(\mathcal{J}(\tilde{\mathcal{Y}}; \Phi), \mathbf{I}) \quad (13)$$

式中,  $\Phi$ 为对应的模型参数集;  $\mathbf{I}$ 是采用独热编码的二进制向量, 表征干扰类型。其长度为干扰类型数, 类别值的对应位置为1, 其余位置为0。和IQ-CNN类似, AJR-CNN以加扰后的I/Q信号为输入, 输出关于干扰类型的分类概率预测。基于此, AJR-CNN采用了和I/Q-CNN相似的网络模型, 不同之处在于输出层维度修改为3以匹配干扰类型的维度。

假设优化问题(13)获得的最优干扰识别模型为 $\mathcal{J}(\cdot; \Phi^*)$ , 则后续的调制识别过程可以简化为干扰类型已知的情况。即当前的调制识别问题可以建模为:

$$P2: \min_{\Theta_I} \text{Loss}_2 = \Delta(\mathcal{M}_I(\tilde{\mathcal{Y}}; \Theta_I, \mathbf{I}, \mathbf{m})) \quad (14)$$

s.t.  $\mathbf{I} = \mathcal{J}(\tilde{\mathcal{Y}}; \Phi^*)$

P1和P2都属于多分类问题, 此处采用CCE作为它们的损失函数 $\Delta(\cdot)$ 。

### 3.3 训练流程

基于干扰认知的调制识别方法分为干扰类型识别和调制样式识别两个步骤。

RML-JAM数据集的样本数为 $220\,000 \times 3 = 660\,000$ 。

在干扰类型识别阶段, RML-JAM数据集按3:1:1的比例划分为训练集(396 000个)、验证集(132 000个)以及测试集(132 000个)。将训练集输入到AJR-CNN模型中进行训练, 训练过程采用Adam优化器。执行迭代训练, 损失函数收敛后即可得到专用于干扰样式识别的模型。

调制样式识别模型的训练过程和第2.3节类似, 给定的干扰类型 $I$ 为训练好的AJR-CNN的估计结果。在本步骤中, 系统会选择对应干扰类型的模型实现调制样式识别。针对混合的加扰接收信号集训练的基于干扰认知的调制识别模型整体命名为AJMR-CNN。

## 4 实验结果及分析

### 4.1 实验设置

所有网络模型均基于Keras框架构建, 后端使用TensorFlow-gpu 2.5.0实现, 训练过程中的GPU型号为NVIDIA GeForce RTX 4060。实验中, 预设干扰的存在状态是已知的, 这一点可以通过CME干扰检测算法实现。对于有干扰的信号, 信干比(signal-to-interference ratio, SIR)设置为 $\text{SIR} = -20\text{ dB}$ 。为验证所提方法的有效性, 本文考察了以下指标: 1) 调制样式识别率: 调制样式识别模型(IQ-CNN和AJMR-CNN)在给定场景的测试集上的分类准确率; 2) 干扰类型识别率: 干扰类型识别模型(AJR-CNN)在混合的加扰信号测试集(RML-JAM)上的分类准确率; 3) 混淆矩阵: 混淆矩阵直观展示了分类问题的准确性。真实标签位于纵轴, 预测标签位于横轴。每个单元格的数值表示被预测为对应类别的样本数, 单元格颜色越深表示准确率越高。

### 4.2 固定干扰下的系统性能分析

图3展示了IQ-CNN模型在 $-20\text{ dB}$ 强干扰条件下, 针对单音干扰、窄带干扰和时域脉冲干扰的

调制样式识别准确率。假设干扰类型已知，在各种通信条件下，IQ-CNN 能够成功识别 11 种调制方式，尤其在 DSB-AM、SSB-AM、GFSK、CPFSK、PAM4 和 BPSK 的识别任务中表现出色。随着信噪

比增长，在 SNR > 0 dB 时调制样式识别率趋于稳定。在 -20 dB 强干扰情况下，ST-CNN、NB-CNN 和 TP-CNN 的最高识别率分别为 77.7%、71.5% 和 67.2%。




图 3 IQ-CNN 在不同干扰时的调制样式识别率

### 4.3 干扰样式识别的准确率分析

图 4 展示了 AJR-CNN 模型在测试集中对 3 种加扰信号的识别准确率曲线。该模型能够精准捕捉并学习各种加扰信号的特征，从而有效区分不同类型的信号。在 [-36, 2] dB 的 SNR 范围内，AJR-CNN 达到了 94.5% 的平均识别准确率，且随着 SNR 的增加，模型性能逐渐提升。当 SNR > -20 dB 时，AJR-CNN 对单音干扰、窄带干扰和时域脉冲干扰 3 种信号的识别准确率均接近 100%。这一表现源于在 SNR > -20 dB 的噪声环境中，SIR = -20 dB 的各类强干扰信号都维持了明显的特征。

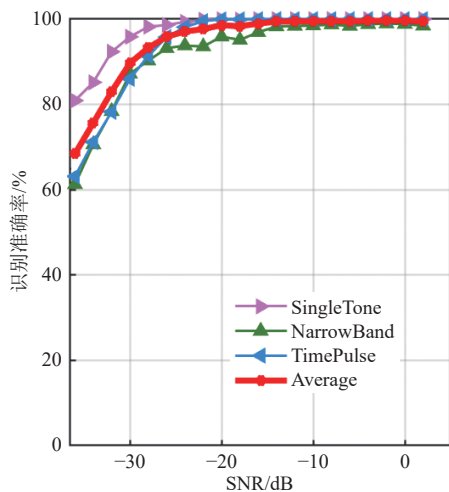


图 4 AJR-CNN 在随机干扰下的干扰类型识别率

为进一步说明 AJR-CNN 在 SNR > -20 dB 时的优越表现，图 5 展示了该模型在该信噪比条件下

对 3 种加扰信号的混淆矩阵，揭示了不同干扰类型之间可能发生的误判情况。混淆矩阵表明，当 SNR > -20 dB 时，3 种加扰信号之间的区分度极高，只有少量的窄带干扰信号被误判为单音干扰信号，整体的错误率仅为 0.79%。这主要由于窄带干扰信号的低带宽占比与单音干扰信号具有相似的频谱特征，导致在区分这两种干扰时偶尔出现混淆。

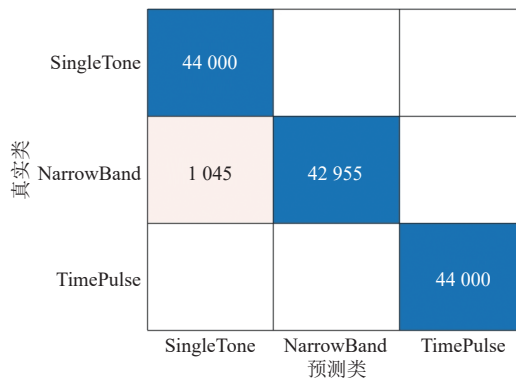


图 5 AJR-CNN 在随机干扰下的混淆矩阵

### 4.4 干扰抑制对系统性能的影响分析

图 6 展示了基于 CME 干扰检测和置零干扰抑制的预处理手段对调制识别性能的提升。其中，“NOCME”后缀代表没有预处理过程的模型。可以看出，去掉干扰抑制环节后的模型无法达到与 ST-CNN、NB-CNN、TP-CNN 同等的识别水平，模型的最佳识别率均有降低。具体地，单音模型 ST-CNN 和时域脉冲模型 TP-CNN 在去掉预处理后识别率发生下降，分别降低了约 20.1% 和 24.5%，

窄带模型 NB-CNN 降低约 8.3%。在强干扰情况下, 接收信号的特征将被干扰信号主导, 这使得调制识别过程中对有效信息的辨识变得异常困难。这验证了干扰抑制在调制识别系统中的重要作用。

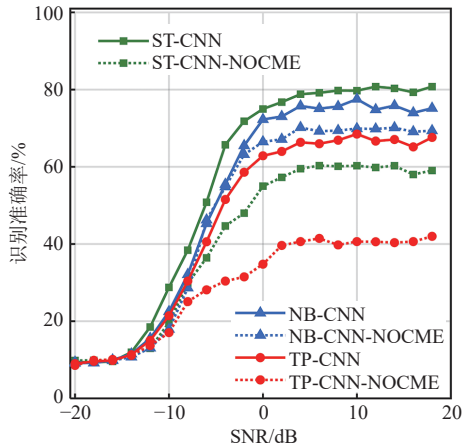


图6 模型在有、无干扰抑制预处理时的性能对比

#### 4.5 随机干扰下的系统性能分析

图7展示了基于干扰认知的调制识别方法(AJMR-CNN)在单一类型随机干扰条件下的调制样式识别准确率。结果表明, 在  $SIR = -20$  dB 的强随机干扰环境中, 模型的整体识别率最高可达约 74.5%; 在全范围信噪比  $[-20, 18]$  dB 内, 平均识别率约为 50.1%。AJMR-CNN 在随机干扰环境下表现出与已知干扰情况下的 IQ-CNN 模型相当的性能, 证明了 AJMR-CNN 在恶劣通信条件下的有效性。




图7 AJMR-CNN 在随机干扰下的调制样式识别率

图8展示了 AJMR-CNN 模型在随机加扰条件下的混淆矩阵。从图中可以看出, 易发生混淆的调制样式包括 QPSK 与 8PSK、16QAM 与 64QAM, 以及 WB-FM 与 DSB-AM。QPSK 与 8PSK、16QAM

与 64QAM 混淆的根源在于星座点的重叠。而 WB-FM 与 DSB-AM 的混淆则归因于 RML2016.10a 数据集的特性, 两者样本均基于相似的生成策略, 来源于含有间歇的音频信号。随着信噪比提升, 混淆的现象会逐渐减弱。

真实值 \ 预测类	PAM4	BPSK	QPSK	8PSK	16QAM	64QAM	GFSK	CPFSK	WB-FM	DSB-AM	SSB-AM
PAM4	2391	282	36	37	53	115	63	41	29	43	910
BPSK	116	2196	142	50	34	18	64	61	25	41	1253
QPSK	31	119	1277	594	119	132	81	307	24	40	1276
8PSK	39	87	570	1349	112	108	101	292	24	52	1266
16QAM	91	45	228	398	957	1227	86	115	14	37	802
64QAM	89	39	173	377	983	1601	73	98	20	19	528
GFSK	13	13	13	4	8	3	2510	23	229	93	1091
CPFSK	27	24	51	56	40	21	154	2336	27	48	1216
WB-FM	6	5	3	3	6		191	5	3091	594	878
DSB-AM	6	7	8	2	4		64	4	736	2314	855
SSB-AM	32	21	21	5	11	2	84	18	47	97	3662

图8 AJMR-CNN 在随机干扰下的混淆矩阵

图9对比了本文所提方法在不同通信环境下的调制样式识别性能。其中, “噪” “衰” “偏” “随机扰” 分别代表噪声、衰落、预处理偏差和随机干扰。




图9 本文方法在不同通信环境下的调制样式识别性能对比

在无干扰场景下, 采用 IQ-CNN 模型; 而在有干扰场景下则采用了 AJMR-CNN 模型。尽管严苛的通信环境(如衰落、预处理偏差和干扰)给调制识别任务带来了挑战, AJMR-CNN 在强干扰环境下(尤其是在低信噪比条件下)仍能保持与无干扰环境相当的性能, 进一步验证了 AJMR-CNN 在应对未知随机干扰时的有效性。

## 5 结束语

本文探讨了干扰环境下的调制识别算法, 针对干扰类型已知和未知这两种场景展开了探索。对于干扰类型已知的情况, 采用定制化网络的策略, 即为特定干扰类型设计专用网络。针对干扰类型随机、未知的通信环境, 提出了一种基于干扰认知的调制识别方法。具体而言, 本文方法设计了专用于干扰样式识别的卷积神经网络模型, 并实施了基于干扰认知的识别策略, 通过干扰识别结果选择相应的调制识别网络。本文在数据集 RML2016.10a 上验证了该方法在恶劣通信条件下的合理性和有效性。尽管本文探讨了 3 种典型的单一干扰类型, 但本方法并不局限于这些特定干扰。面对多种干扰叠加的复杂场景, 可以将这些叠加干扰视为一种新型的干扰类型, 基于深度学习的数字驱动特性, 训练新的模型, 从而增强模型的适应能力和泛化性能。同时, 针对更多智能干扰及更为复杂的叠加干扰组合, 探索针对任意叠加干扰的系统设计, 将是未来的研究方向。

## 参考文献

- [1] ZHANG F, LUO C, XU J, et al. Deep learning based automatic modulation recognition: Models, datasets, and challenges[J]. *Digital Signal Processing*, 2022, 129: 103650.
- [2] BHATTI F A, KHAN M J, SELIM A, et al. Shared spectrum monitoring using deep learning[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2021, 7(4): 1171-1185.
- [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] ZHANG W, FENG M, KRUNZ M, et al. Signal detection and classification in shared spectrum: A deep learning approach[C]//2021 IEEE Conference on Computer Communications. Vancouver: IEEE, 2021: 1-10.
- [5] DULEK B. Online hybrid likelihood based modulation classification using multiple sensors[J]. *IEEE Transactions on Wireless Communications*, 2017, 16(8): 4984-5000.
- [6] PARK C S, CHOI J H, NAH S P, et al. Automatic modulation recognition of digital signals using wavelet features and SVM[C]//2008 10th International Conference on Advanced Communication Technology. Gangwon: IEEE, 2008: 387-390.
- [7] XU Y, GE L, WANG B. Digital modulation recognition method based on self-organizing map neural networks[C]//2008 4th International Conference on Wireless Communications, Networking and Mobile Computing. Dalian: IEEE, 2008: 1-4.
- [8] 张富鑫. 基于深度学习的自动调制识别技术研究[D]. 成都: 电子科技大学, 2023.  
ZHANG F X. Research on deep learning based automatic modulation recognition technology[D]. Chengdu: University of Electronic Science and Technology of China, 2023.
- [9] 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.
- [10] SHI W, LIU D, CHENG X, et al. Particle swarm optimization-based deep neural network for digital modulation recognition[J]. *IEEE Access*, 2019, 7: 104591-104600.
- [11] XIE W, HU S, YU C, et al. Deep learning in digital modulation recognition using high order cumulants[J]. *IEEE Access*, 2019, 7: 63760-63766.
- [12] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//Engineering Applications of Neural Networks: 17th International Conference. Aberdeen: Springer International Publishing, 2016: 213-226.
- [13] ZHANG L, LIN C, YAN W, et al. Real-time OFDM signal modulation classification based on deep learning and software-defined radio[J]. *IEEE Communications Letters*, 2021, 25(9): 2988-2992.
- [14] HUYNH-THE T, NGUYEN T V, PHAM Q V, et al. MIMO-OFDM modulation classification using three-dimensional convolutional network[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(6): 6738-6743.
- [15] 张柏林, 姬港, 朱宇轩, 等. 基于深度学习的半监督信号调制样式识别算法[J]. *电子科技大学学报*, 2024, 53(4): 511-518.  
ZHANG B L, JI G, ZHU Y X, et al. A semi-supervised signal modulation mode recognition algorithm based on deep learning[J]. *Journal of University of Electronic Science and Technology of China*, 2024, 53(4): 511-518.
- [16] HU S, PEI Y, LIANG P P, et al. Deep neural network for robust modulation classification under uncertain noise conditions[J]. *IEEE Transactions on Vehicular Technology*, 2019, 69(1): 564-577.
- [17] YAO F, JIA L. A collaborative multi-agent reinforcement learning anti-jamming algorithm in wireless networks[J]. *IEEE Wireless Communications Letters*, 2019, 8(4): 1024-1027.
- [18] LIAO C, XU K, XIA X, et al. IRS-assisted anti-jamming transmission for an integrated satellite-UAV-terrestrial network with imperfect CSI: A game-based perspective[J]. *IEEE Internet of Things Journal*, 2023, 10(23): 20484-20497.
- [19] O'SHEA T J, WEST N. Radio machine learning dataset generation with gnu radio[C]//Proceedings of the GNU Radio Conference. Boulder: GNURadio, 2016: 1-6.
- [20] HENTTU P, AROMAA S. Consecutive mean excision algorithm[C]//IEEE 7th International Symposium on Spread Spectrum Techniques and Applications. Piscataway: IEEE, 2002: 450-454.
- [21] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines[C]//Proceedings of the 27th International Conference on Machine Learning (ICML-10). Madison: Omnipress, 2010: 807-814.
- [22] KINGMA D P, BA J. Adam: A method for stochastic optimization[C]//Proceedings of the International Conference on Learning Representations (ICLR). San Diego: [s.n.], 2015: 448-456.