

# 一种基于 DRSN-GAN 的通信信号调制识别方法 \*

刘高辉, 顾家华

(西安理工大学 自动化与信息工程学院, 陕西 西安 710048)

**摘要:** 针对在小样本和低信噪比条件下通信信号调制识别率低的问题, 提出了一种基于深度残差收缩生成对抗网络 (Deep Residual Shrinkage Network and Generative Adversarial Network, DRSN-GAN) 的深度学习框架。首先, 将信号的同相正交数据 (I/Q data) 作为模型输入, 通过生成器生成的数据对数据集进行扩充, 有效解决了高质量数据稀缺的问题, 增强了模型的泛化能力。利用 DRSN 组成判别器, 将经过扩充的数据送入 DRSN 进行训练。同时, 对输入数据在空间维度上执行全局平均池化, 利用通道注意力模块提取 I/Q 信号的上下文特征, 有效减少了噪声干扰。该方法解决了因固定阈值很难适用于所有样本而导致的识别准确率低的问题, 并在低信噪比环境下显著提高了识别效果。实验结果表明, 所提出的模型在信噪比为 0 dB 时准确率达 92%, 对比其他模型, 整体分类精度提升了 3%, 且在小样本和低信噪比条件下表现出更强的鲁棒性。

**关键词:** 调制识别; 残差收缩网络; 生成对抗网络; 深度学习

中图分类号: TN911

文献标识码: A

DOI: 10.19358/j. issn. 2097-1788. 2025. 05. 006

引用格式: 刘高辉, 顾家华. 一种基于 DRSN-GAN 的通信信号调制识别方法 [J]. 网络安全与数据治理, 2025, 44(5): 35-41.

## A communication signal modulation identification method based on DRSN-GAN

Liu Caohui, Gu Jiahua

(School of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China)

**Abstract:** A deep learning framework based on deep residual shrinkage network and generative adversarial network (DRSN-GAN) is proposed to address the problem of low recognition rate of communication signal modulation under small samples and low signal-to-noise ratio conditions. First, the in-phase orthogonal data (I/Q data) of the signal is used as the model input, and the dataset is expanded by the generative data generated by the generator, which effectively solves the problem of scarcity of high-quality data and enhances the generalization ability of the model. The DRSN is utilized to form a discriminator, and the expanded data is fed into the DRSN for training. Meanwhile, global average pooling is executed on the input data in the spatial dimension, and the channel attention module is used to extract the contextual features of the I/Q signals, which effectively reduces the noise interference. The method solves the problem of low recognition accuracy due to the difficulty of applying fixed thresholds to all samples, and significantly improves the recognition effect in a low signal-to-noise ratio environment. The experimental results show that the model proposed in this paper has an accuracy of 92% at a signal-to-noise ratio of 0 dB, which improves the overall classification accuracy by 3% compared with other models, and exhibits stronger robustness under the conditions of small samples and low signal-to-noise ratio.

**Key words:** modulation recognition; residual shrinkage network; generative adversarial network; deep learning

## 0 引言

自动调制识别是指通过对接收到的信号进行特征提取和分析, 以自动识别和分类不同的调制类型, 其在无

线通信、雷达系统和信号处理等领域中具有重要的应用<sup>[1]</sup>。通过自动调制识别, 系统能够快速准确地识别出发送端使用的调制类型, 从而帮助优化信号处理和通信系统的性能。随着无线通信技术的不断发展, 信号的调制愈加多样, 电磁环境也变得更加错综复杂, 因此, 探

\* 基金项目: 国家自然科学基金 (61671375)

索实时高效的调制识别技术具有重要的现实意义。

传统调制识别方法受限于先验知识依赖、计算复杂度高及特征提取主观性强等问题，难以满足现代通信系统对灵活性、鲁棒性和自适应性的需求<sup>[2-4]</sup>。因此，自动调制识别技术及其与机器学习，特别是深度学习的结合，为这一难题提供了新的解决方案。深度学习以其强大的自动特征提取能力、端到端学习机制及对先验知识要求的低门槛，成为自动调制识别领域的研究热点<sup>[5-7]</sup>。文献[8]将改进的卷积神经网络（Convolutional Neural Networks, CNN）和长短期记忆网络（Long Short-Term Memory, LSTM）相结合，以进一步提高性能并降低深度学习框架的复杂性，结果表明LSTM能更好地利用连续无线信号样本之间的时间特征，进一步提高了对高阶信号的分类能力；文献[9]结合深度残差收缩网络（Deep Residual Shrinkage Network, DRSN）在信号降噪和提升训练效率方面的显著优势，以及门控循环单元在序列特征提取方面的优秀性能，设计了一种轻量化的特征提取和分类识别模型，既保证了信号识别准确率，又显著降低了模型参数量和运算复杂度。

然而，深度神经网络需要大量样本来进行训练<sup>[10]</sup>，在无线电信号调制识别任务中常常存在样本量不足的情况<sup>[11]</sup>。为了解决这一问题，近年来学术界和工业界对小样本条件下的调制识别方法进行了广泛研究。生成对抗网络（Generative Adversarial Networks, GAN）作为深度学习的一种前沿技术，为调制识别领域带来了新的可能性。在调制识别中，GAN可用于生成多样化的调制信号数据，解决高质量数据稀缺的问题，同时增强模型的泛化能力。此外，GAN还能通过模拟低信噪比环境下的信号变化，帮助模型学习在复杂噪声条件下的有效特征，提升识别性能。文献[12]从数据生成的角度出发，首次将GAN应用于数据的分类识别。文献[13]提出了一种在小样本集条件下基于关系网络的水声通信信号调制识别方法，该方法设计了一种基于功率谱和关系网络的调制识别模型，该模型通过在不同通道中构建小样本训练任务进行优化，这种训练模式提高了识别方法在目标海域只有少量标记样本可用时快速分类的能力。文献[14]提出了一种基于元学习的小样本调制识别算法，该方法设计了一种由CNN和LSTM并联组成的混合特征并行网络，在小样本和高信噪比条件下有效地提高了调制识别的性能，但该方法在低信噪比条件下识别率明显降低。

针对上述问题，本文提出了一种基于DRSN-GAN的通信信号调制识别方法。首先生成网络利用噪声生成高质量的生成数据，将数据集进行扩充；其次设计了一种

由残差收缩单元组成的DRSN作为判别网络，利用DRSN中独特的软阈值化算法与注意力机制优化特征提取，以增强在低信噪比环境下的识别效果。实验表明，本文提出的方法在小样本和低信噪比条件下识别准确率提升效果显著。

## 1 信号模型

考虑高斯环境下的数字调制信号，接收信号的一般表示可以表示为：

$$r(t) = s(t) + n(t) \quad (1)$$

式中， $s(t)$ 和 $n(t)$ 分别表示发射信号和高斯噪声。

对于振幅键控(ASK)、相移键控(PSK)和频移键控(FSK)信号， $s(t)$ 可以表示为：

$$s(t) = \left[ A_m \sum_n a_n g(t - nT_s) \right] \cos(2\pi(f_c + f_m)t + \varphi_0 + \varphi_m) \quad (2)$$

其中， $A_m$ 和 $a_n$ 分别为调制幅度和符号序列， $T_s$ 为符号周期， $f_c$ 为载波频率， $f_m$ 为调制频率， $\varphi_0$ 为初始相位， $\varphi_m$ 为调制相位。 $g(t)$ 是矩形脉冲，可以表示为：

$$g(t) = \begin{cases} 1, & 1 \leq t \leq T_s \\ 0, & \text{其他} \end{cases} \quad (3)$$

而正交调幅(QAM)信号有两个正交载波，分别由 $a_n$ 和 $b_n$ 调制：

$$s(t) = \left[ A_m \sum_n a_n g(t - nT_s) \right] \cos(2\pi f_c t + \varphi_0) + \left[ A_m \sum_n b_n g(t - nT_s) \right] \sin(2\pi f_c t + \varphi_0) \quad (4)$$

因此，接收信号 $r(t)$ 可以表示为：

$$r(t) = \alpha(t) e^{j(2\pi f_c t + \theta_0(t))} s(t) + n(t) \quad (5)$$

其中， $\alpha(t)$ 表示瑞利衰落信道， $f_0$ 和 $\theta_0(t)$ 分别表示由信道衰减引起的频率和相移。在相干处理中， $r(t)$ 通常以I/Q形式表示，即同向分量和正交分量。

## 2 基于DRSN-GAN的通信信号调制方式识别

### 2.1 DRSN-GAN模型设计

深度网络能够学习到更复杂的特征层次，随着网络深度的增加，网络能够捕捉到数据中的更复杂关系，从而增强模型的表达能力。然而，网络深度的增加也带来了挑战，过于深的网络可能会遇到梯度消失或梯度爆炸、过拟合等问题，且训练可能变得更加困难<sup>[15]</sup>。因此，合理选择网络深度是确保模型整体性能达到最佳的关键。CNN在对信息进行广泛的特征提取方面表现出色，而DRSN擅长改善高噪声环境下的识别精度和提取信号微观特征<sup>[16]</sup>。因此，本文选用CNN作为生成器网络（Generator, G），用由残差收缩模块构成的DRSN作为判别器网络（Discriminator, D）。

为了实现扩充数据并进行调制识别分类的目标，本

文将网络的输出层分为两部分：一部分为判别数据的真假属性，另一部分为判别数据的类别属性。DRSN-GAN 的模型结构如图 1 所示。

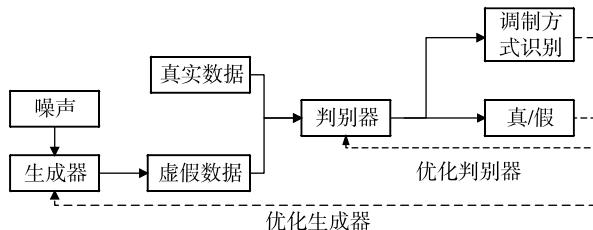


图 1 DRSN-GAN 模型结构

$G$  负责生成与真实数据相似的新数据样本。生成器是一个 CNN，通过对输入的随机噪声进行变换和映射，用于引入随机性，输出高维的数据样本。 $G$  包含多个隐藏层，这些隐藏层通过对输入向量进行非线性变换和组合，逐渐提取和构建出数据的复杂特征。而  $D$  的主要任务是区分输入数据是来自真实数据还是由生成器生成的数据。通过不断地与  $G$  进行对抗训练， $D$  能够通过不断优化增强其辨别真假数据的能力。随着训练的进行， $G$  和  $D$  的能力逐渐提升，最终系统会达到一种稳定状态，称为“纳什平衡”，在这一平衡状态下， $G$  所生成的数据已经难以被  $D$  区分为生成数据。此时， $D$  的判别能力达到了最优， $G$  的生成能力也已达到最优，即  $G$  能够生成与真实数据分布非常相似的样本。

以真实数据  $P_L(x)$  为例，其先验分布用  $P_L(x)$  表示。 $G$  通过随机采样生成数据  $G(z)$ ，其分布记作  $P_G(z)$ ，该分布应尽量逼近真实分布  $P_L(x)$ 。真实数据  $P_L$  和生成数据  $G(z)$  输入到  $D$  中，输出为概率值  $D(G(z))$ ，该值越接近 1，表示生成的数据越像真实数据，反之则表明生成数据与真实数据的差异较大。 $G$  和  $D$  通过一种“零和博弈”机制进行训练，这构成的极大极小问题定义为函数，可表示为：

$$\min_{G} \max_{D} V(D, G) = E_{x \sim P_L(x)} [\log D(x)] + E_{z \sim P_G(z)} [\log(1 - D(G(z)))] \quad (6)$$

其中， $D(x)$  表示判别器对真实数据  $x$  的判定概率，而  $D(G(z))$  则是判别器对生成数据  $G(z)$  的判定概率。 $G$  试图最大化  $D(G(z))$  的值，即让判别器将生成的数据误认为

为真实数据，而  $D$  通过最小化  $D(G(z))$  来提高其对生成数据与真实数据的区分能力。

损失函数由生成器和判别器的损失函数组成，判别器的损失函数为：

$$L_D = -E_{x \sim P_L(x)} [\log D(x)] - E_{z \sim P_G(z)} [\log(1 - D(G(z)))] \quad (7)$$

生成器的损失函数为：

$$L_G = -E_{z \sim P_G(z)} [\log D(G(z))] \quad (8)$$

## 2.2 通道注意力机制

通道注意力机制（Squeeze-and-Excitation Network, SENet）是深度神经网络中的一种特殊结构，它旨在增强神经网络对不同特征之间关系的感知能力，同时学习到各个通道特征的重要程度<sup>[17]</sup>。在通信信号的调制识别中，信号分为 I 路和 Q 路两个分支，因此利用通道之间的关系可以提高表达两个分支信号特征的能力，从而提升神经网络模型的泛化能力。

SENet 的整体结构如图 2 所示，它的核心结构由两个关键步骤组成：压缩（Squeeze）和激励（Excitation）。在压缩步骤中，SENet 使用全局平均池化对将每个通道的空间信息汇聚为一个单一的数值，表示该通道的全局特征<sup>[18]</sup>。这一操作能够有效地聚焦于通道级别的全局上下文信息，并为后续的激励步骤提供简洁的通道描述。在激励步骤中，SENet 通过全连接层和激活函数来生成每个通道的权重系数，这些权重反映了各个通道在当前任务中的相对重要性。通过对各通道的特征进行加权，SENet 能够动态地调整每个通道的响应值，从而增强网络对重要特征的表达，抑制无关或冗余信息。这种压缩和激励机制使得 SENet 能够自适应地优化通道的特征表示，提高网络对重要特征的关注，从而显著提升模型的性能。

## 2.3 残差收缩模块

由于噪声对调制识别的影响十分严重，软阈值函数能提升对特征的提取能力，因此经常被用于信号的降噪处理。其导数特性类似 ReLU，有助于抑制梯度问题。软阈值函数是一种非线性函数，其原理是根据预设的阈值，对输入数据进行处理，若输入数据的绝对值小于等于该

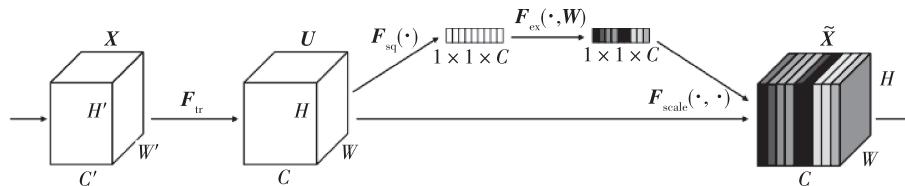


图 2 通道注意力结构<sup>[17]</sup>

阈值，则将该数据置为零；若输入数据的绝对值大于该阈值，则保留该数据，并减去阈值的大小。阈值设置需满足正数、小于输入最大值，且需根据样本噪声含量自适应调整，以有效区分不同信噪比信号，实现精准降噪。然而，选取的固定阈值很难适用于所有样本<sup>[19]</sup>，为了解决这一问题，SENet通过引入子网络的设计，动态地获取每一层输出特征图各通道的阈值。这些阈值随后被送入软阈值函数进行处理，从而得到经过降噪处理后的各通道特征图数值。通过这种方式，SENet在特征处理过程中能够灵活应对不同样本的特征需求，进而显著提升分类任务中的性能表现。软阈值函数的表达式为：

$$y = \begin{cases} x - \tau, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ x + \tau, & x < -\tau \end{cases} \quad (9)$$

其中， $x$  为输入特征， $y$  为输出特征， $\tau$  为阈值。

对式 (9) 求偏导数可得：

$$\frac{\partial y}{\partial x} = \begin{cases} 1, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ 1, & x < -\tau \end{cases} \quad (10)$$

从式 (10) 可以看出，软阈值化在输入特征的绝对值大于阈值时，输出对于输入的偏导数恒定为 1，否则恒定为 0，所以能够有效解决梯度消失的问题，同时避免深度神经网络梯度计算爆炸。

图 3 展示了构成 D 网络的残差收缩模块（Residual Shrinkage Building Unit, RSBU），它是 DRSN 的基本构成单元。DRSN 将深度残差网络、通道注意力机制和软阈值函数结合在一起，构建一个拥有通道注意力机制的小型 SENet 子网络来自动获取所需要设置的阈值。

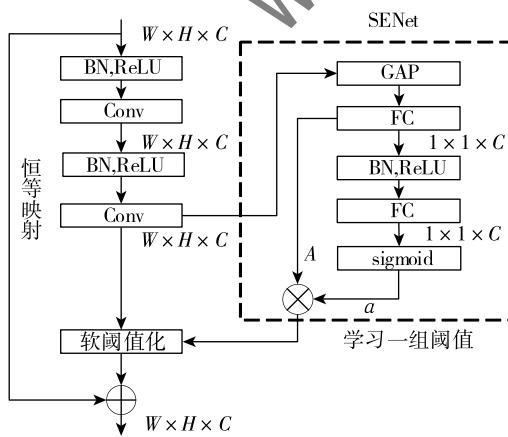


图 3 残差收缩模块

图 3 中输入特征图的宽度为  $W$ 、高度为  $H$ 、通道数为  $C$ 。其中批量归一化（Batch Normalization, BN）层有助于

加速训练过程并提高网络的稳定性，整流线性单元（Rectifier Linear Unit, ReLU）激活函数提供非线性变换以增强网络的表达能力，卷积层（Conv）提取输入数据中的空间特征，恒等映射确保信息的有效传递，阈值学习的子网络则通过自适应的方式学习特征阈值，以优化模型的性能。自适应阈值的设置是软阈值化处理的关键，而注意力机制解决了阈值自动获取困难的问题。这一机制不仅提升了细节特征提取，还抑制无关特征，特别适用于噪声环境。该机制将噪声特征置零，减少干扰，保留相关特征用于后续信号识别，有效提升了通信信号调制方式的识别精度。

### 3 实验仿真与分析

#### 3.1 网络结构设置

鉴于本文设定的小样本学习场景，本文通过大量对比实验得出 G 网络选择 3 层卷积结构，D 网络选择 4 个残差收缩模块时网络的性能最优。表 1 为 G、D 网络的结构设计，其中，Conv 和 RSBU 后括号内第 1 个数据表示卷积核的尺寸，第 2 个数据表示通道的数量。

表 1 网络结构设计

| G 网络结构            | D 网络结构            |
|-------------------|-------------------|
| Noise = Input     | Input             |
| FC                | Conv (2 × 5, 128) |
| Conv (2 × 3, 64)  | RSBU (1 × 9, 64)  |
| Unsampling        | RSBU (1 × 7, 32)  |
| Conv (2 × 3, 128) | RSBU (1 × 5, 16)  |
| Conv (2 × 2, 1)   | RSBU (1 × 3, 8)   |
|                   | BN, ReLU, GAP     |
|                   | FC                |

#### 3.2 仿真环境及数据集

在本研究中，所有网络模型的训练和验证过程均在 Python 编程环境下完成，具体采用基于 TensorFlow 后端的 Keras 深度学习框架。实验平台配置为 13th Gen Intel (R) Core (TM) i9-13900HX CPU, Nvidia GTX 4060 GPU，内存为 16 GB，硬盘大小为 1 TB。实验采用了被广泛用于研究数字通信信号分类的数据集之一：RadioML2016.10b，表 2 为数据集信息。该数据集共有 10 种调制类型，包括 BPSK、QPSK、8PSK、AM-DSB、CPFSK、GFSK、PAM4、QAM、QAM16、QAM64 和 WBFM，信号还包括了载波频率偏移、符号速率偏移、延迟、热噪声等干扰类型<sup>[20]</sup>，使得数据集更贴近实际通信环境。本文按照 8 : 1 : 1 的比例将数据集划分为训练集、测试集和验证集，并基于

不同的信噪比构建识别网络，学习率为 0.000 2，网络优化函数采用 Adam 算法。

表 2 RadioML2016. 10b 数据集信息

| 参数项   | 描述  |
|-------|---|
| 调制类型数 | 10  |
| 样本长度  | 128   |
| 信噪比范围 | -20 dB; 2 dB; 18 dB   |
| 总数据量  | 1 200 000   |
| 调制方式  | 模拟调制：AM-DSB, WBFM；<br>数字调制：BPSK, 8PSK, CPFSK, GFSK,<br>PAM4, QAM16, QAM64, QPSK |
| 信道环境  | 载波频率偏移、符号速率偏移、延迟、热噪声  |

### 3.3 实验结果

#### 3.3.1 识别结果分析

图 4 所示的混淆矩阵是在 RadioML2016. 10b 数据集上测试得到的结果，用于衡量模型的分类性能。该矩阵为二维表格结构，其中行表示样本的预测类别，列表示模型的真实类别。通过对实际结果与预测结果的分布情况，可以直观地分析模型的分类准确率、错误分类情况以及可能存在的类别间混淆问题。该混淆矩阵为所有信噪比数据的结果，颜色越深代表该处的样本数量越多，由于三个矩阵的主对角线方向颜色较深，可以得出每一信噪比、每一调制类型的正确预测样本较多，这说明本文设计的模型在数据集上有良好的表现，进一步说明本方法在调制识别领域的可行性。

从混淆矩阵图中可以看出，DRSN-GAN 在绝大多数调制类型的识别上表现良好，在信噪比为 0 dB 时识别准确率可以达到 92%，表明模型能够很好地区分不同的调制类型。

#### 3.3.2 模型对比分析

为了充分说明本文设计的模型能对调制信号实现更高的分类准确率，将 DRSN-GAN 分别与文献 [21] 设计的卷积长短时全连接网络（Convolutional Long short-term memory fully connected Deep Neural Networks, CLDNN）模型、文献 [22] 设计的自编码卷积神经网络（Automatic Convolutional Neural Networks, AUCNN）模型、文献 [23] 提出的多模匹配残差融合神经网络（Residual networks with a Waveform-Spectrum Multimodal Fusion, Resnet-WSMF）算法和文献 [12] 设计的辅助分类 GAN（Auxiliary Classifier GAN, ACGAN）模型进行比较。表 3 为网络分类准确率之间的对比，相比其他 4 种网络，DRSN-

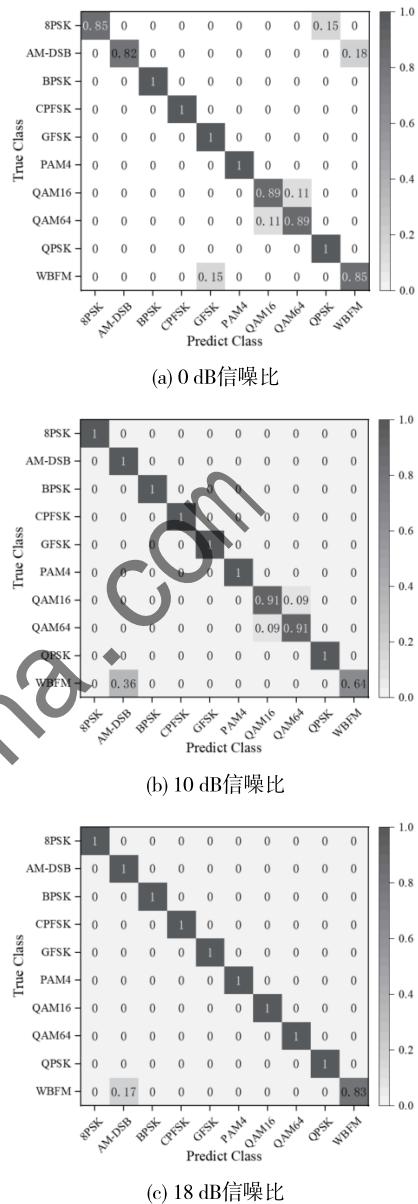


图 4 DRSN-GAN 在 RML2016. 10b 数据集中各信噪比混淆矩阵

GAN 取得了最高的识别准确率。

为了验证本文所提出模型在小样本条件下的性能优势，本文设计了一组对比实验，分别选取不同规模的样本进行测试，并分析模型在不同样本数量下的表现，以评估其在小样本环境中的适应能力和优越性。表 4 为不同样本数量对网络性能的影响，从表 4 中可以归纳出本文所提出的模型在小样本环境下能够更有效地捕捉数据的关键信息，从而提高调制识别的准确性。结合表 3 和表 4 的结果，本文所提的模型不仅能够在小样本的情况下取得优异表现，而且能够有效应对低信噪比环境，具有较高的实际应用价值。

表3 各模型分类准确率结果对比

| 网络          | 信噪比 SNR/dB |      |      |      |      |      |
|-------------|------------|------|------|------|------|------|
|             | -4         | 0    | 4    | 8    | 12   | 16   |
| CLDNN       | 0.63       | 0.74 | 0.77 | 0.82 | 0.83 | 0.84 |
| AUCNN       | 0.72       | 0.76 | 0.82 | 0.83 | 0.88 | 0.87 |
| Resnet-WSMF | 0.65       | 0.80 | 0.88 | 0.92 | 0.92 | 0.92 |
| ACGAN       | 0.67       | 0.78 | 0.78 | 0.79 | 0.79 | 0.79 |
| DRSN-GAN    | 0.75       | 0.92 | 0.94 | 0.94 | 0.95 | 0.98 |

表4 不同样本数量对网络性能的影响

| 网络          | 样本数量 |      |      |      |       |        |        |
|-------------|------|------|------|------|-------|--------|--------|
|             | 540  | 600  | 660  | 720  | 3 600 | 15 000 | 60 000 |
| CLDNN       | 0.19 | 0.22 | 0.26 | 0.29 | 0.44  | 0.63   | 0.79   |
| AUCNN       | 0.22 | 0.25 | 0.36 | 0.37 | 0.50  | 0.72   | 0.83   |
| Resnet-WSMF | 0.19 | 0.20 | 0.25 | 0.28 | 0.40  | 0.66   | 0.90   |
| ACGAN       | 0.23 | 0.24 | 0.27 | 0.29 | 0.46  | 0.76   | 0.86   |
| DRSN-GAN    | 0.85 | 0.90 | 0.98 | 0.98 | 0.98  | 0.98   | 0.98   |

## 4 结论

本研究通过引入深度残差收缩生成对抗网络(DRSN-GAN)模型,提出了一种新的通信信号调制识别方法。通过生成器生成多样化的调制信号数据,并结合判别器进行对抗训练,有效解决了传统方法中高质量数据稀缺的问题,显著提升了模型的泛化能力和识别性能。同时,针对低信噪比环境下的识别难题,结合深度残差收缩网络中软阈值化算法与注意力机制优化特征提取,进一步增强了模型的鲁棒性。实验结果表明,基于DRSN-GAN的调制识别模型在小样本低信噪比条件下的识别准确率优于其他模型。未来的研究可以将本文提出的DRSN-GAN模型应用到调制信号的开集识别中,同时针对部分识别混淆的信号进行预处理,以实现更加高效、准确的通信信号调制识别。

## 参考文献

- [1] 郭业才, 姚文强. 基于信噪比分类网络的调制信号分类识别算法 [J]. 电子与信息学报, 2022, 44 (10): 3507–3515.
- [2] 马碧云, 元达鹏, 刘娇蚊. 基于似然函数的双曲调频信号参数估计快速算法 [J]. 电子与信息学报, 2021, 43 (5): 1228–1234.
- [3] ABU-ROMOH M, ABOUTALEB A, REZKI Z. Automatic modulation classification using moments and likelihood maximization [J]. IEEE Communications Letters, 2018, 22 (5): 938–941.
- [4] MI X J, TIAN Y, KANG B Y. A hybrid multi-criteria decision making approach for assessing health-care waste management technologies based on soft likelihood function and D-numbers [J]. Applied Intelligence, 2021, 51 (10): 6708–6727.
- [5] O’ SHEA T J, CORGAN J, CLANCY T C, et al. Convolutional radio modulation recognition networks [C]//Proc. of the International Conference on Engineering Applications of Neural Networks, 2016: 213–226.
- [6] ZHANG C, PATRAS P, HADDADI H. Deep learning in mobile and wireless networking: a survey [J]. IEEE Communications Surveys & Tutorials, 2019, 21 (3): 2224–2287.
- [7] XIE X, PENG S, YANG X. Deep learning-based signal-to-noise ratio estimation using constellation diagrams [J]. Mobile Information Systems, 2020, 2020: 1–9.
- [8] SANG Y, LI L A. Application of novel architectures for modulation recognition [C]//2018 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS), 2018: 159–162.
- [9] 查燕平, 王红军, 沈哲贤. 特征融合式轻量化调制识别方法设计与研究 [J/OL]. 小型微型计算机系统, 1–10 [2025–03–05]. <http://kns.cnki.net/kcms/detail/21.1106.TP.20240926.1434.014.html>.
- [10] WEI T, LI Z, BI D, et al. Adaptive multi-dimensional shrinkage block for automatic modulation recognition [J]. IEEE Communications Letters, 2023, 10 (11): 2968–2972.
- [11] GERASYOV M, MAKAROV I. Dealing with sparse rewards using graph neural networks [J]. IEEE Access, 2023 (11): 89180–89187.
- [12] ODENA A. Semi-supervised learning with generative adversarial networks [C]//Proc. of the Data Efficient Machine Learning

Workshop at International Conference on Machine Learning, 2016.

- [13] WANG H, WANG B, WANG R, et al. Modulation recognition method for underwater acoustic communication signal based on relation network under small sample set [C]//Proceedings of 2021 IEEE 21st International Conference on Communication Technology (ICCT). Piscataway: IEEE Press, 2021: 1287 – 1291.
- [14] 庞伊琼, 许华, 蒋磊, 等. 基于元学习的小样本调制识别算法 [J]. 空军工程大学学报, 2022, 23 (5): 77 – 82, 89.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Delving deep into rectifiers: surpassing human-level performance on image net classification [C]//Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1026 – 1034.
- [16] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16 (7): 4681 – 4690.
- [17] HU J, SHEN L, SUN G. Squeeze-and-Excitation networks [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 7132 – 7141.
- [18] 张奕涵, 柏正尧, 尤逸琳, 等. 自适应模态融合双编码器MRI脑肿瘤分割网络 [J]. 中国图象图形学报, 2024, 29 (3): 768 – 781.
- [19] FU W. Research on noise reduction of partial discharge signal of

high voltage cable based on improved threshold function [J]. Electronic Measurement Technology, 2020, 43 (11): 138 – 141.

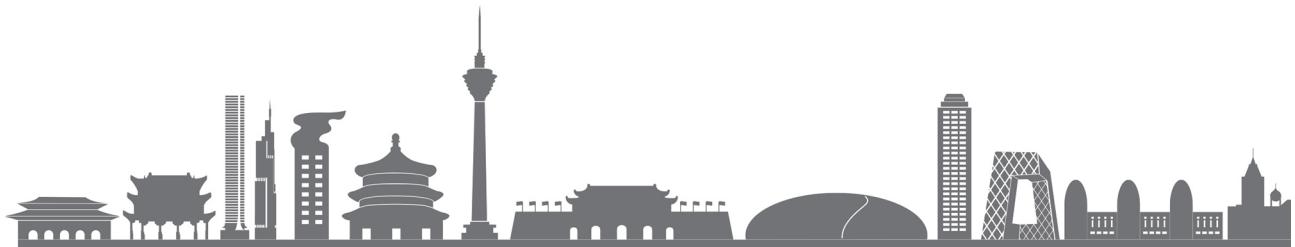
- [20] 国强, 聂孟允, 戚连刚, 等. 基于单通道多尺度图神经网络的自动调制识别 [J]. 电子与信息学报, 2023, 45 (5): 1575 – 1584.
- [21] O'SHEA T J, ROY T, CLANCY T C. Over-the-air deep learning based radio signal classification [J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12 (1): 168 – 179.
- [22] WANG J, WANG W F, LUO F X, et al. Modulation classification based on denoising autoencoder and convolutional neural network with GNU radio [J]. The Journal of Engineering, 2019, 19: 6188 – 6191.
- [23] QI P H, ZHOU X Y, ZHENG S L, et al. Automatic modulation classification based on deep residual networks with multimodal information [J]. IEEE Trans. on Cognitive Communications and Networking, 2021, 7 (1): 21 – 33.

(收稿日期: 2025 – 03 – 05)

#### 作者简介:

刘禹辉 (1968 – ), 通信作者, 男, 博士, 教授, 主要研究方向: 通信信号处理、认知无线电、雷达信号处理和导航技术。  
E-mail: liugh68@xaut.edu.cn。

顾家华 (1998 – ), 男, 硕士研究生, 主要研究方向: 通信信号调制识别。



## 版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部